

UNIVERZITET U BEOGRADU

MAŠINSKI FAKULTET

Velimir R. Ćirović

**ISTRAŽIVANJE MOGUĆNOSTI PRIMENE
VEŠTAČKE INTELIGENCIJE U
PREDVIĐANJU PERFORMANSI
KOČNOG SISTEMA MOTORNIH VOZILA**

doktorska disertacija

Beograd, 2012

UNIVERSITY OF BELGRADE
FACULTY OF MECHANICAL ENGINEERING

Velimir R. Ćirović

**THE POTENTIAL APPLICATION OF
ARTIFICIAL INTELLIGENCE IN
PREDICTION OF MOTOR VEHICLES
BRAKING SYSTEM PERFORMANCE**

Doctoral Dissertation

Belgrade, 2012

Komisija za pregled, ocenu i odbranu doktorske disertacije

Mentor: Doc. dr Dragan Aleksendrić
Univerzitet u Beogradu, Mašinski fakultet

Članovi komisije: Prof. dr Branko Vasić
Univerzitet u Beogradu, Mašinski fakultet

Prof. dr Gradimir Ivanović
Univerzitet u Beogradu, Mašinski fakultet

Prof. dr Zoran Miljković
Univerzitet u Beogradu, Mašinski fakultet

Prof. dr Aleksandra Janković
Univerzitet u Kragujevcu, Fakultet inženjerskih nauka

Datum odbrane doktorske disertacije: _____.2012.

PREDGOVOR

Ovaj rad je nastao kao rezultat višegodišnjeg istraživanja u okviru laboratorije za bezbednost motornih i priključnih vozila LaBMV Mašinskog fakulteta Univerziteta u Beogradu. U cilju uvođenja inteligenčnog upravljanja performansama kočnog sistema pomoću metoda iz oblasti veštačke inteligencije, tokom istraživanja su se postavljali različiti izazovi, ali i složeni zadaci koje je trebalo rešiti. Imajući to u vidu, ovom prilikom želim posebno da se zahvalim svom mentoru Prof. dr Draganu Aleksendriću na predloženoj temi, stručnim savetima, velikoj podršci, strpljenju i maksimalnoj pomoći pri predlaganju i rešenju mnogih ideja u vezi sa ovako kompleksnom i multidisciplinarnom oblašću. Imao sam posebnu čast i sreću koja se retko ukazuje da sarađujem sa Prof. Aleksendrićem, koji me je uveo u ovu oblast i postavio temelje mog daljeg rada i usavršavanja. Pored toga, veliku zahvalnost želim da izrazim svojim roditeljima Stanojki i Radojku, na moralnoj i finansijskoj podršci, razumevanju i preuzimanju svih ostalih obaveza koje su se u međuvremenu dešavale, kako bih bio maksimalno posvećen istraživanju. Takođe veliku zahvalnost dugujem devojci Jasmini na pomoći oko pripreme i sređivanja teksta doktorske disertacije, ogromnom razumevanju, strpljenju i pružanju podrške tokom njene izrade. Zahvaljujem se i kolegama Mr. Draganu Milkoviću i Dušanu Smiljaniću, koji su mi pružili nesebičnu pomoć tokom eksperimentalnog dela istraživanja, kao i prijateljima i svima onima koji su iskazali razumevanje i podršku za moj rad. U tom kontekstu, posebnu zahvalnost dugujem SP „Lasta“ iz Beograda, koje mi je stavilo na raspolaganje vozilo za sproveđenje eksperimentalnih istraživanja prikazanih u ovom radu. Pored toga, želim da izrazim i zahvalnost vozaču Saši Lakićeviću iz Smedereva, kao i Željku Stevanoviću i Žiki Ivkoviću iz Ljiga na pomoći.

Beograd, jun 2012.

Velimir Ćirović, dipl.inž.maš.

ISTRAŽIVANJE MOGUĆNOSTI PRIMENE VEŠTAČKE INTELIGENCIJE U PREDVIĐANJU PERFORMANSI KOČNOG SISTEMA MOTORNIH VOZILA

Rezime

Osnovni zahtevi koji se postavljaju pred današnje kočne sisteme motornih i priključnih vozila, u pogledu bezbednosti vozila i saobraćaja, se odnose na njihovo dalje unapređenje kroz razvoj novih, inteligentnih, rešenja. Suština ovih zahteva jeste da se omogući pomoć vozaču kroz inteligentno upravljanje sistemima na vozilu, odnosno njihovim performansama u različitim, dinamički promenljivim, radnim uslovima. Pošto kočne performanse vozila zavise od performansi kočnica, koje funkcionišu na principima trenja i samim tim imaju vrlo nepredvidiv karakter, i od usklađenosti tih performansi sa trenutnim uslovima prijanjanja u kontaktu pneumatika sa tlom, koji se mogu intenzivno menjati tokom samo jednog ciklusa kočenja, realizacija ovih zahteva je izuzetno kompleksna. To je osnovni razlog za sprovođenje istraživanja u pogledu razvoja i implementacije intelligentijih načina upravljanja performansama kočnog sistema na osnovu uslova prijanjanja u kontaktu pneumatik-tlo. U ovoj doktorskoj disertaciji su istraživane mogućnosti primene tehnika iz oblasti veštačke inteligencije u cilju modeliranja složenih dinamičkih uticaja radnih režima kočnica motornih vozila i uslova u kontaktu pneumatik-tlo, kao i predviđanja ovih uticaja u cilju upravljanja performansama kočnica, a time i performansama kočnog sistema, u toku ciklusa kočenja. Zbog nemogućnosti modeliranja složenih dinamičkih uticaja radnih režima kočnica motornih vozila na njihove izlazne performanse, odnosno na vrednosti klizanja u kontaktu pneumatika i puta pomoću klasičnih matematičkih metoda, uvedena je nova intelligentna metoda bazirana na dinamičkim veštačkim neuronskim mrežama i fazi logici. U skladu sa time, u ovoj disertaciji su istraživane mogućnosti primene dinamičkih veštačkih neuronskih mreža i fazi logike u cilju modeliranja, predviđanja i intelligentnog upravljanja performansama kočnica, odnosno performansama kočnog sistema. Predmetno istraživanje je usmereno ka razvoju sposobnosti kočnog sistema ka intelligentnom prilagođavanju sile kočenja

dinamičkim promenama podužnog klizanja točka (pneumatika) u kontaktu sa putem u toku ciklusa kočenja. Ovakav koncept upravljanja performansama kočnog sistema, na osnovu prethodnih i trenutnih vrednosti posmatranih uticajnih veličina i identifikovanih uslova prijanjanja tokom kočenja, podrazumeva predviđanje potrebne vrednosti pritisaka aktiviranja kočnice, na prednjoj i zadnjoj osovini, za date uslove kočenja (vrednosti pritiska aktiviranja kočnice, vrednosti brzine točka na prednjoj/zadnjoj osovini, temperature u kontaktu frikcionog para kočnice na prednjoj/zadnjoj osovini i vrednosti klizanja u kontaktu pneumatik-tlo) kako bi se u kontaktu pneumatika i tla postiglo željeno (optimalno) klizanje u podužnom pravcu. Sve ovo je neophodno omogućiti uz razvoj mogućnosti intelligentnom kočnom sistemu da kontinualno uči, tokom svakog ciklusa kočenja, o složenim i stohastičkim uticajima između navedenih veličina. S obzirom da je ovo naročito važno za privredna vozila, fokus istraživanja je bio usmeren na mogućnosti unapređenja performansi elektronski upravljanog kočnog sistema, kako bi se u kontaktu pneumatika i tla ostvarila optimalna vrednost klizanja ne samo u podužnom pravcu, već i kasnija optimizacija klizanja u odnosu i na poprečno klizanje točka. Složena i dinamički promenljiva funkcionalna korelacija između pritiska aktiviranja kočnice i klizanja točka u podužnom pravcu tokom kočenja, brzine točka i temperature kočnice u toku ciklusa kočenja, modelirana je putem razvoja inverzne funkcionalne veze između ovih veličina. Razvojem inverznog dinamičkog modela procesa kočenja i njegovih efekata na podužno klizanje u kontaktu pneumatik-tlo, omogućeno je istovremeno učenje o toj funkcionalnoj vezi sa svakim novim kočenjem. Pored toga, omogućeno je i testiranje trenutnog „znanja“ dinamičkog modela, kao i podešavanje „performansi predviđanja“ modela novonastalim promenama podužnog klizanja točka. Ovakvim pristupom je omogućeno da željena dinamička promena klizanja u kontaktu pneumatika i tla može da bude postavljena na nivou koji obezbeđuje iskorišćenje maksimalnog prijanjanja točka (pneumatika) u podužnom i/ili bočnom pravcu. Ovim se obezbeđuju maksimalne kočne performanse, odnosno pruža mogućnost za optimizaciju sile kočenja u pogledu podužnog i bočnog usporenja, tj. stabilnosti vozila, posebno pri kočenju u krivini.

Razvojem ovakvog dinamičkog modela, pomoću dinamičkih veštačkih neuronskih mreža, za kočnice prednje i zadnje osovine, stvoreni su uslovi za razvoj odgovarajućih neuronskih i neuro-fazi kontrolera za upravljanje, tj. selekciju pritisaka aktiviranja kočnica na prednjoj i zadnjoj osovini u zavisnosti od željenog klizanja, željenih kočnih performansi i potrebne raspodele sile kočenja. U skladu sa tim, u doktorskoj disertaciji su projektovani posebni neuro i neuro -fazi kontroleri u pogledu razvoja potrebnih „znanja“, tj. inteligentnih osobina kontrolera za dinamičko upravljanje pritiskom aktiviranja kočnica na prednjoj i zadnjoj osovini na osnovu željenog klizanja u kontaktu pneumatika i tla.

Ključne reči: kočni sistem, kočne performanse, veštačka inteligencija, intelligentno upravljanje.

Naučna oblast: Mašinstvo

Uža naučna oblast: Motorna vozila

UDK broj: 629.017:004.8.032.26:007.52(043.3)

THE POTENTIAL APPLICATION OF ARTIFICIAL INTELLIGENCE IN PREDICTION OF MOTOR VEHICLES BRAKING SYSTEM PERFORMANCE

Abstract

In terms of vehicle and traffic safety, the main demands imposed to the braking systems of motor vehicles and trailers are related to their further improvement through development of new, intelligent, solutions. It could enable the driver assistance function through an intelligent control of the vehicle systems performance in different and dynamically changing operating conditions. Since the braking performance of vehicles depend on the performance of the brakes, which based their function on the friction, it is difficult to control stochastically changed the brakes performance. Furthermore, harmonization of that performance with the actual conditions in the tire-road contact, which is also intensively changed during a braking cycle, the realization of demands towards an intelligent control the braking system performance is very complex. This is the main reason for conducting research regarding development and implementation of more intelligent ways for control of the braking system performance. In this doctoral thesis, possibilities for employing of an artificial intelligence have been investigated in order to model and predict the impact of the brakes operating regimes and the complex conditions in the tire-road contact in order to provide intelligent controlling of the braking system performance during a braking cycle. Due to the impossibility for modeling of complex dynamic influences of brakes' operating conditions on their performance and consequently on the value of the longitudinal wheel slip using conventional mathematical methods, a new method has been introduced based on an integration of dynamic neural networks and fuzzy logic. Accordingly, this thesis investigated possibilities for the proper integration of dynamic artificial neural networks and fuzzy logic in modeling, prediction, and intelligent control of the brakes' performance, i.e. performance of the braking system. It should provide inherent capabilities of the braking system towards an intelligent adaptation of the braking forces to the dynamic changes of

the longitudinal slip ratio in the tire-road contact during a braking cycle. This concept for control of the braking system performance, based on previous and current values of observed influential factors, means predicting of the brake applied pressure values, on the front and rear axle, for the given braking conditions (brake applied pressure, wheel speed on the front/rear axle, brake interface temperature on the front/rear axle, and wheel slip) in order to achieve the desired and/or optimal slip level in the longitudinal direction. Furthermore, the braking system should continuously learn about the complex and stochastic influences between these factors during a braking cycle. Since this is especially important for commercial vehicles, the focus of research has been directed on possibilities for improving the performance of electronically controlled braking system. It is done not only to achieve the optimal value of the longitudinal wheel slip in the tire-road contact, but also enables later optimization of the lateral wheel slip. The complex and dynamic changing a functional correlation between the brake actuation pressure and the wheel slip in the longitudinal direction, the wheel speed, and the brake interface temperature during a braking cycle is modeled through development of an inverse relationship between these quantities. The developed inverse dynamic model of the braking process, which includes the transfer of generated braking force from the tire to road, enabled the following: (a) the simultaneous learning about that functional relationship with each new brake application, (b) testing of the current "knowledge" of dynamic model, and (c) adjusting of the model's prediction capabilities according to the new changes of the wheel slip. This approach enables setting of the desired dynamic change of the wheel slip in the contact of tires and road at the level that ensures utilization of the maximum wheel adhesion in the longitudinal and/or lateral direction, which in turn provides maximum braking performance and offers possibilities for the braking force optimization with respect to longitudinal and lateral deceleration.

Developed the dynamic neural models of the braking process, for the front and rear axle, have created the conditions for the further development of appropriate neural and neural-fuzzy controllers that could be used for the control of braking system performance, i.e. selection of the brake actuation pressures depending on

the desired wheel slip ratio, actual braking performance, and the brake force distribution. Accordingly, the separate neural and neuro-fuzzy controllers have been designed for dynamic control of the brake actuation pressures, on the front and rear axle, based on the desired wheel slip level in the contact between the tire and the road.

Key words: braking system, braking performance, artificial intelligence, intelligent control.

Scientific discipline: Mechanical engineering

Scientific sub discipline: Motor vehicles

UDK number: 629.017:004.8.032.26:007.52(043.3)

SADRŽAJ

1. Uvod	1
2. Pregled stanja u oblasti istraživanja	7
3. Predmet i cilj istraživanja	25
3.1. Predmet istraživanja	25
3.2. Cilj istraživanja	27
4. Kočni sistemi privrednih vozila	29
4.1. Uvod	29
4.2. Karakteristike i zadaci kočnih sistema motornih vozila	31
4.3. Performanse kočnih sistema	35
4.4. Fenomeni u kontaktu frikcionih površina kočnice	38
4.5. Ponašanje vozila tokom kočenja	46
4.6. Karakteristike i zadaci elektronskih sistema za upravljanje performansama kočnog sistema	50
4.6.1. Uvod	50
4.6.2. Protivblokirajući uređaj (PBU)	51
4.6.3. Elektronski upravljan kočni sistem (EBS)	60
4.6.4. Elektronska kontrola stabilnosti (ESC/ESP) kod privrednih vozila	64
4.7. Inteligentno upravljanje performansama kočnog sistema	66
5. Interakcija pneumatika i puta	74
5.1. Uvod	74
5.2. Uticaj karakteristika pneumatika na interakciju	

pneumatika i puta	76
5.3. Prijanjanje u kontaktu pneumatika i tla	80
5.4. Klizanje u statičkim i dinamičkim uslovima	87
5.4.1. Uvod	87
5.4.2. Teorijski (statički i dinamički) modeli kontakta pneumatik-tlo	90
5.5. Dinamičko određivanje položaja trenutnog maksimuma krive klizanja	108
6. Veštačka inteligencija	116
6.1. Pojam veštačke inteligencije	116
6.1.1. Uvod	116
6.1.2. Učenje	118
6.1.3. Podaci	119
6.1.4. Rešavanje problema	120
6.2. Veštačke neuronske mreže	121
6.2.1. Uvod	121
6.2.2. Pregled razvoja veštačkih neuronskih mreža	122
6.2.3. Osnovne karakteristike veštačkih neuronskih mreža	124
6.2.4. Biološke osnove	126
6.2.5. Veštački neuron	129
6.2.6. Arhitektura neuronske mreže	131
6.2.7. Podela veštačkih neuronskih mreža	132
6.2.8. Veštačke neuronske mreže sa prostiranjem signala unapred	135
6.2.9. Radijalne funkcije i vejljet mreže	136

6.2.10. Rekurentne veštačke neuronske mreže (mreže sa povratnom spregom)	137
6.2.11. Obučavanje veštačkih neuronskih mreža	140
6.2.12. Primena veštačkih neuronskih mreža	141
6.2.13. Projektovanje strukture neuronske mreže	142
6.2.14. Modeliranje pomoću veštačkih neuronskih mreža	146
6.2.15. Izbor modela	150
6.2.16. Dinamički „model crne kutije“	151
6.2.17. Prostorni i ulazno-izlazni oblik modela	152
6.2.18. Normalni oblik modela	153
6.2.19. Metodologija modeliranja	156
6.2.20. „Offline“ i „online“ obuka	158
6.2.21. Neuronsko modeliranje dinamičkih sistema pomoću rekurentnih mreža	158
6.2.22. Regresiono modeliranje dinamičkih sistema	162
6.2.23. Nelinearno modeliranje pomoću mreža sa prostiranjem signala unapred	163
6.2.24. Karakteristike rekurentnih neuronskih mreža	167
6.2.25. Obuka rekurentnih neuronskih mreža	172
6.3. Fazi logika	175
6.3.1. Uvod	175
6.3.2. Fazi logika i upravljanje	177
6.3.3. Fazi skupovi i funkcije pripadanja	178
6.3.4. Logičke operacije i „ako-onda“ pravila	180
6.3.5. Sistem fazi upravljanja	182

6.3.6. Struktura fazi kontrolera	183
6.4. Genetski algoritmi	189
6.4.1. Uvod	189
6.4.2. Globalna optimizacija	189
6.4.3. Evolucioni algoritmi	194
6.4.4. Osnovne karakteristike genetskih algoritama	195
6.4.5. Analiza karakteristika genetskih algoritama	199
7. Inteligentno upravljanje performansama kočnog sistema privrednog vozila	203
7.1. Uvod	203
7.2. Eksperimentalna istraživanja	205
7.3. Obrada izmerenih podataka	216
7.4. Inteligentno upravljanje performansama kočnice pomoću metode veštačkih neuronskih mreža	221
7.4.1. Inverzni dinamički modeli klizanja za prednju i zadnju osovinu	226
7.4.2. Dinamičko upravljanje procesom kočenja za prednju i zadnju osovinu	230
7.4.3. Verifikacija „performansi“ predviđanja neuronskih modela za prednju i zadnju osovinu	237
7.4.4. Upravljanje performansama kočnog sistema pomoću neuronskih modela za prednju i zadnju osovinu	247
7.5. Inteligentno upravljanje performansama kočnice pomoću kombinovanog neuro-fazi pristupa	263
7.5.1. Razvoj fazi logičke podrške	269

7.5.2. Upravljanje performansama kočnog sistema pomoću neuro-fazi modela za prednju i zadnju osovinu	275
7.6. Inteligentno upravljanje performansama kočnice pomoću kombinovanog neuro-genetskog pristupa	290
7.6.1. Algoritam funkcionisanja neuro-genetskog modela	294
7.6.2. Razvoj neuronskog modela procesa kočenja	295
7.6.3. Mogućnosti primene neuro-genetskog pristupa za optimizaciju pritiska aktiviranja kočnice	298
8. Zaključak	305
Literatura	

1

UVOD

Potreba ka stalnom unapređenju performansi motornih vozila i razvoju „pametnijih“ i bezbednijih motornih i priključnih vozila, nedvosmisleno dovodi do razvoja inteligentnih vozila, a time i do uvođenja novih rešenja u oblasti sistema koji su odgovorni za bezbednost vozila i saobraćaja, kao što je to kočni sistem. Razvoj intelligentnih kočnih sistema i obezbeđenje uslova za tzv. intelligentno kočenje predstavlja jedan od najznačajnijih izazova 21. veka, ne samo u pogledu ukupnih dinamičkih performansi vozila već i kao izuzetno važan društveni, tehnološki i ekonomski izazov, uzimajući u obzir broj pогinulih i visinu šteta prouzrokovanih velikim brojem saobraćajnih nesreća.

Mobilnost putnika i robe je izuzetno važna za savremeno društvo, ali istovremeno predstavlja ozbiljan problem u pogledu bezbednosti saobraćaja, uticaja na okolinu i izazvanih zastoja u saobraćaju. Drumski saobraćaj na području Evropske Unije je praćen velikim brojem saobraćajnih nesreća (1,3 miliona saobraćajnih nesreća) sa preko 41000 pогinulih svake godine i štetom čija cena premašuje 200 milijardi dolara godišnje. Ova cena predstavlja 2% bruto nacionalnog dohotka Evropske unije. Dosadašnja istraživanja pokazuju da je u 90% slučajeva ljudska greška uzrok saobraćajnih nesreća. Stoga, najvažniji zahtev negde preko 300 miliona vozača na putevima Evropske Unije, kao i drugih zemalja u okruženju, je drastično smanjenje verovatnoće nastanka saobraćajne nesreće i povređivanja putnika. Zbog toga usmeravanje pažnje inženjera u automobilskoj industriji ka razvoju intelligentnih vozila, a time i sistema na vozilu, vodi ka stvaranju uslova kada će sudar između vozila biti praktično nemoguć. Time intelligentna vozila postaju nova paradigma bezbednosti vozila i saobraćaja, primene savremenih tehnologija i opravdanih ulaganja u naučna istraživanja u ovoj oblasti.

Dosadašnji razvoj kočnog sistema, posebno privrednih vozila, je doživeo značajne rezultate, pre svega u oblasti prenosnih mehanizama kočnih sistema, kroz uvođenje elektronike i elektronskog prenosa komandi od vozača. Time su obezbeđeni uslovi za brz odziv kočnog sistema u odnosu na želje vozača i/ili sistema koji upravlja performansama kočnog sistema, kao što su ABS/ASR/ESP/ESC. Inteligentno kočenje, tj. inteligentno upravljanje performansama kočnica, čiji se rad temelji na principima trenja, ne zahteva samo brz prenos komandnog signala, od vozača do izvršnih elemenata kočnog sistema (kočnica), već i bolje razumevanje rada samih kočnica, preko kojih se realizuje zahtevani moment kočenja, bilo da je on određen željom vozača i/ili zahtevom sistema koji upravlja radom kočnog sistema u datom trenutku. U tom smislu se otvara nekoliko vrlo kompleksnih problema u oblasti daljeg razvoja kočnog sistema, a time i bezbednosti vozila uopšte. To se pre svega odnosi na razumevanje uticaja radnih režima kočnice na njene performanse, istraživanje mogućnosti predviđanja ovih uticaja promenu momenta kočenja, odnosno prenos tako generisanog momenta kočenja sa kočnice, preko točka (pneumatika), na podlogu. Sa tim u vezi i istraživanje uslova prijanjanja u kontaktu pneumatik-tlo. Očigledno je da je potrebno inovativnije i mnogo preciznije rešiti problem postizanja one vrednosti momenta kočenja koju je moguće preneti na podlogu u datom trenutku, u skladu sa željom vozača. Inteligentnim usklađivanjem performansi kočnice (momenta kočenja) i uslova prijanjanja u kontaktu pneumatik-tlo bi se istovremeno omogućilo maksimiziranje kočnih performansi vozila, bilo u podužnom i/ili bočnom pravcu u različitim uslovima kretanja vozila (vrsta podлогe, stanje i tip pneumatika, stanje kočnica i friкционih površina kočnice, režimi kočenja, kočenje na pravcu, kočenje u krivini, itd). Sve ovo mora biti usklađeno sa željom vozača. Međutim, postoje situacije kada su želje vozača u saglasnosti sa trenutnim uslovima prijanjanja između pneumatika i tla ali i kada su želje vozača, u pogledu pritiska aktiviranja kočnica, zbog svojih evidentnih ograničenja, koja se odnose pre svega na brzinu i mogućnosti (nemogućnosti) opažanja/razumevanja složenih kontaktnih fenomena u kočnici i interakciji pneumatika i tla, takve da se ne mogu realizovati sa stanovišta prijanjanja, što izaziva tendenciju blokiranja točkova. Sa druge strane, usled uzdržanog kočenja od strane vozača, odnosno nedovoljnog

pritiska aktiviranja kočnica, često dolazi do toga da se ne koriste optimalne mogućnosti prijanjanja. Kočni sistem treba da poseduje inteligentne sposobnosti prepoznavanja neadekvatno odabrane sile na komandi kočnog sistema, odnosno tako izabranog pritiska aktiviranja kočnica, od strane vozača i mogućnosti za korigovanje pritiska aktiviranja kočnice tokom ciklusa kočenja. Kako bi se unapredio osećaj sile kočenja na komandi sistema za radno kočenje, inteligentni kočni sistem treba da vrši ne samo korekcije pritiska aktiviranja kočnice u slučajevima kada je vozač izvršio neadekvatnu selekciju pritiska, odnosno kada je došlo do promene uslova prijanjanja sa putem, već i u slučajevima kada kočnica, zbog uticaja brzina kočenja, temperatura kočnica, trenutnih pritisaka aktiviranja, konstrukcije kočnice, vrsta i karakteristika elemenata friкционог para (diska/doboša i kočnih obloga), ne postiže željene kočne performanse. Na osnovu ovoga možemo zaključiti da je u cilju ne samo veće sveukupne bezbednosti vozila, već i maksimiziranja kočnih performansi vozila, skraćenja puta kočenja, odnosno poboljšanja stabilnosti vozila, potrebno uvesti rešenja koja obezbeđuju „pametnije“ funkcije kočnog sistema. Ovo se pre svega odnosi na postizanje potrebnih kočnih performansi, kroz intelligentno adaptivno upravljanje klizanjem u kontaktu pneumatik – tlo, kako bi se prethodno generisan moment kočenja u kočnici mogao preneti na podlogu u skladu sa trenutnim uslovima prijanjanja. Obezbeđenje intelligentnog ponašanja kočnica je usko vezano sa „učenjem“ kočnog sistema o postignutim performansama iz prethodnih „iskustava“, za poznatu dinamičku promenu uticajnih veličina kao što su promene pritiska aktiviranja kočnice, brzine i temperature u kontaktu friкционог para. Dakle, jedna od suštinskih stvari bitnih za unapređenje performansi kočnica i njihovo usaglašavanje sa promenljivim uslovima prijanjanja između pneumatika i tla, je obezbeđenje kontinualnog učenja kočnog sistema o tome na koji način pomenute uticajne veličine, u toku ciklusa kočenja, utiču na moment kočenja, tj. performanse kočnice. Na osnovu monitoringa performansi kočnica i kontinualnog učenja o tome kako i na koji način se one mogu menjati (usaglašavati) sa različitim zahtevima (vozača i/ili sistema odgovornih za bezbednost vozila) moguće je upravljati pritiskom aktiviranja kočnice u toku ciklusa kočenja. Sa druge strane, praćenjem uslova prijanjanja između pneumatika i tla, odnosno vrednosti klizanja u njihovom

kontaktu, moguće je podesiti pritisak aktiviranja kočnice, u skladu sa ostalim režimima kočenja, kako bi generisali optimalnu silu kočenja koja obezbeđuje, ne samo najkraći put kočenja, već istovremeno i stabilnost vozila u datim uslovima prijanjanja. Ovo predstavlja osnovnu hipotezu i suštinu istraživanja sprovedenih u okviru ove doktorske disertacije. Doktorska disertacija se bavi istraživanjem sa ciljem pronalaženja rešenja problema vezanih za obezbeđenje funkcije inteligentnog kočenja, funkcije „pametnih“ kočnica i kako, u dinamičkim i jako promenljivim kontaktnim uslovima između elemenata friкционог para kočnice i friкционог para pneumatika i puta, obezbediti upravljanje klizanjem pneumatika tokom kočenja, čija željena vrednost opet može dinamički da se menja, tj. usklađuje u zavisnosti od promene uslova prijanjanja.

Imajući u vidu složenost procesa upravljanja performansama kočnog sistema i klizanjem pneumatika u kontaktu sa podlogom, nije teško zaključiti da realizacija upravljanja klizanjem točka ne može biti isključivo bazirana na sposobnostima vozača, što dalje nameće potrebu da se rešavanje celokupnog problema mora sagledati na višem nivou, koji ne isključuje uticaj vozača, ali i ne prihvata sve njegove zahteve, posebno one koji će dovesti do pogoršanja trenutne situacije u pogledu kočnih performansi vozila. Realizacija ovih zahteva, koji se postavljaju pred savremena motorna vozila u pogledu aktivne bezbednosti vozila, je jako kompleksna i njihova implementacija mora biti bazirana na metodama i tehnikama koje će obezbediti osobine intelligentnosti kočnog sistema. Ovo je moguće uraditi kroz razvoj takvih osobina kočnog sistema koje će omogućiti stalno (on-line) učenje o procesu kočenja i time obezbediti podršku donošenju odluka vezanih za selekciju pritisaka aktiviranja kočnica i raspodelu sila kočenja, između osovina motornih i priključnih vozila, za date uslove prijanjanja pneumatika i tla. Da bismo obezbedili realizaciju ovih zahteva, u ovoj disertaciji su analizirane mogućnosti dinamičkog modeliranja procesa kočenja, u toku ciklusa kočenja, i razvoja uslova za kontinualno učenje o složenim i stohastičkim uticajima između pritisaka aktiviranja kočnice, ugaone brzine točka i temperature kočnice, sa jedne strane, i momenta kočenja, odnosno klizanja u kontaktu pneumatik-tlo, sa druge strane.

U skladu sa svim ovim, u ovoj disertaciji su istraživane mogućnosti intelligentnog upravljanja performansama kočnog sistema, na osnovu željene dinamičke promene klizanja u kontaktu pneumatika i puta, pomoću metoda koje obezbeđuju učenje, ali i intelligentno prilagođavanje promenama velikog broja parametara koji utiču na performanse kočnice, odnosno vrednost klizanja u kontaktu pneumatika i tla. S obzirom da je ovo naročito važno za privredna vozila, fokus istraživanja je bio usmeren na mogućnosti unapređenja performansi elektronski upravljanog kočnog sistema, kako bi se u kontaktu pneumatika i tla ostvarila željena i/ili optimalna vrednost klizanja u podužnom pravcu.

Kompleksna, dinamički promenljiva, funkcionalna korelacija između pritiska aktiviranja kočnice i klizanja točka, ugaone brzine točka i temperature u kontaktu friкционog para kočnice, u toku ciklusa kočenja, je modelirana kroz razvoj inverzne veze između ovih veličina. Razvojem inverznog dinamičkog modela procesa kočenja, koji predviđa pritisak aktiviranja kočnice, u zavisnosti od stvarne promene klizanja pneumatika, brzine točka i temperature kočnice, je omogućeno istovremeno učenje o toj funkcionalnoj vezi, sa svakim novim kočenjem, testiranje „sopstvenog znanja“ dinamičkog modela kao i podešavanje „performansi predviđanja“ modela novonastalim promenama. Ovakav dinamički model predstavlja osnovu intelligentnog kočnog sistema koji bazira svoj rad na tzv. friкционim kočnicama. Ovako koncipiran dinamički model dalje omogućava predviđanje pritiska aktiviranja kočnice, za poznate trenutne vrednosti brzine točka, stvarnog i željenog klizanja između pneumatika i tla i temperature kočnice, koji treba da omogući usklađivanje, tj. intelligentnu adaptaciju pritiska aktiviranja kočnice željenoj i/ili realno mogućoj, odnosno optimalnoj dinamičkoj promeni klizanja u kontaktu pneumatik – tlo. Ta željena dinamička promena klizanja u kontaktu pneumatika i tla ujedno može da bude postavljena na nivou koji obezbeđuje iskorišćenje maksimalnog prijanjanja točka (pneumatika) u podužnom i/ili bočnom pravcu čime se obezbeđuju maksimalne kočne performanse, odnosno pruža se mogućnost za optimizaciju sile kočenja u pogledu podužnog i bočnog usporenja, tj. stabilnosti vozila, posebno pri kočenju u krivini.

Razvojem ovakvih dinamičkih modela, za kočnice prednje i zadnje osovine, na bazi dinamičkih neuronskih mreža, sposobnih da dinamički modeliraju pomenute složene uticaje u toku samog ciklusa kočenja, se otvara prostor za razvoj neuronskog kontrolera za upravljanje, tj. selekciju pritisaka aktiviranja kočnica na prednjoj i zadnjoj osovini u zavisnosti od željenog klizanja, željenih kočnih performansi i raspodele sile kočenja. U doktorskoj disertaciji su prikazane suštinske buduće osobine neuronskog i neuro-fazi kontrolera za upravljanje pritiskom aktiviranja kočnice na osnovu željenog klizanja u kontaktu pneumatika i tla. Projektovan je neuro-fazi kontroler, koji pored znanja vezanih za proces kočenja i klizanje pneumatika i tla, dobijenih tokom obuke dinamičkih neuronskih mreža, koristi i ekspertska znanja izražena kroz fazi logička pravila, za slučaj neodređenih situacija u kojima kočni sistem može da se nađe, odnosno za slučaj eventualne pojave grešaka u predviđanju inverznog dinamičkog modela procesa kočenja, s obzirom na široke mogućnosti promene velikog broja uticajnih veličina. Dakle, pored istraživanja primene dinamičkih neuronskih mreža, za razvoj inteligentnih osobina kočnog sistema, analizirana je primena i fazi logike i genetskih algoritama, kao važnih tehnika veštačke inteligencije. U doktorskoj disertaciji je razvijen i testiran novi hibridni neuro-fazi dinamički model upravljanja pritiskom aktiviranja kočnica, odnosno kočnim performansama autobusa sa elektronskim kočnim sistemom.

2

PREGLED STANJA U OBLASTI ISTRAŽIVANJA

S obzirom na predmet i cilj istraživanja ove doktorske disertacije, u ovom poglavlju je dat pregled istraživanja koja ukazuju na dosadašnja dostignuća i trenutno stanje u toj oblasti. Imajući u vidu kompleksnost istraživanja i multidisciplinarnost teme, obuhvaćena su istraživanja različitih problema koji su vezani za funkciju kočnog sistema, mogućnosti inteligentnog upravljanja performansama kočnog sistema, a time i kočnica, kao i složenu interakciju između pneumatika i puta. Posebno su u fokusu bili problemi vezani za mogućnost dinamičkog modeliranja rada kočnice/interakcije pneumatik-tlo tokom ciklusa kočenja. Pored toga, istraživana su dosadašnja dostignuća na polju unapređenja upravljanja performansama kočnih sistema u smislu postizanja željenog/optimalnog nivoa klizanja u kontaktu pneumatika i puta, a posebno sa stanovišta uspešnosti primene tehnika veštačke inteligencije poput veštačkih neuronskih mreža, fazi logike i genetskih algoritama u rešavanju istih ili sličnih problema.

Kako je jedan od presudno važnih faktora za uvođenje inteligentnog upravljanja performansama kočnice dobro razumevanje složenih kontaktnih fenomena koji se javljaju u spoju između elemenata tzv. friкционог para (diska kočnice i friкционог materijala), prvo ćemo analizirati istraživanja koja se odnose na ovu interakciju i eventualne mogućnosti modeliranja relevantnih uticajnih veličina na performanse kočnice. Pri tome su posebno razmatrana istraživanja koja se odnose na uticaj veličine i stabilnosti koeficijenta trenja u kontaktu friкционог para kočnice i ona koja se odnose na veličinu i mehanizme habanja friкционih materijala (materijala diska i friкционih obloga).

Prema [1], nasuprot velikom broju ispitivanja i stalnom razvoju kočnica motornih vozila i friкционih materijala, veoma malo je poznato o stanju u kontaktu

frikcionih površina na mikroskopskom nivou. Klizanje površine friкционог materijala po kočnom disku (najčešće izrađen od sivog liva) dosta se razlikuje od većine triboloških sistema. Istraživanje izloženo u [1] uključuje sveobuhvatno ispitivanje strukture, mehaničkih osobina i sastava materijala disk pločica, koristeći elektronski mikroskop velike rezolucije i trodimenzionalnu profilometriju. Posebno je pažnja bila usmerena na uticaj udela pojedinih sirovina u sastavu friкционih materijala na njihove performanse. U [2] je dat opšti pogled na situaciju u kontaktu friкционih površina disk pločice i diska, pri čemu je posebna pažnja usmerena na mehanizme koji dovode do pojave varijacije koeficijenta trenja tokom kočenja. Pored toga, analizirano je kakav uticaj na promenljivost koeficijenta trenja u kontaktu friкционog para kočnice imaju fenomeni kao što su rast i razaranje kontaktnih slojeva, nastajanje tzv. trećeg tela u kontaktu i transfer materijala. Kako je to objašnjeno u [3], friкционi materijali kočnica, odnosno njihov sastav i uslovi proizvodnje se smatraju jednom od ključnih komponenti koje utiču na performanse kočnica, a time i na ukupne performanse kočenja vozila. Osetljivost performansi friкционог materijala i prema tome performansi kočnice u odnosu na različite radne režime je oduvek bio važan aspekt njihovog funkcionisanja. U [3] su posebno razmatrani sinergijski uticaji radnih režima kočnice i uticaji uslova proizvodnje i sastava friкционог materijala u odnosu na obnavljanje performansi friкционог materijala kočnica. Za modeliranje navedenih uticaja su iskorišćene veštačke neuronske mreže pa je u skladu sa tim razvijen neuronski model obnavljanja performansi friкционог materijala. Istraživanje uticaja istih ovih parametara na promene C karakteristike kočnice sprovedeno je u [4,5]. U oba slučaja, modeliranje performansi friкционih materijala je obavljenо primenom veštačkih neuronskih mreža u uslovima tzv. hladne kočnice. U [5] je izvršeno predviđanje performansi friкционог materijala u slučaju hladne kočnice u dva slučaja: pre i posle testova opadanja efikasnosti i obnavljanja performansi. Prema [6], osetljivost friкционог materijala na temperaturu u kontaktu friкционih površina je oduvek bio kritičan aspekt tokom obezbeđivanja njihovog lakog i pouzdanog funkcionisanja. Zbog toga je neophodno da se ta osetljivost konstantno optimizira. Upravo zbog toga je u ovom radu istraživana mogućnost za predviđanje

performansi friкционог материјала при повишенoj температури коčnice помоћу веštačkih neuronskih мreža, узимајући у обзир njihov сastav i uslove proizvodnje.

U istraživanjima sprovedenim u [7,8,9,10,11] je pokazano da je moguće razviti model koji može da objedini uticaje velikog broja parametara koji se odnose na сastav i uslove proizvodnje friкционих материјала коčnice na performanse коčnice. U [10] je napravljen iskorak u odnosu na ostala istraživanja uzimanjem u obzir i uticaja radnih režima коčnice na performanse friкционог para i razvojem posebnih neuronskih modela performansi i modela istrošenja friкционог материјала. Zajedničko za sva ova istraživanja je to što se pokušaji razvoja modela performansi friкционог материјала zasnivaju na istraživanju mogućnosti korišćenja веštačkih neuronskih мreža. U [7] je korišćena Elmanova мreža, dok su u ostalim radovima razvijeni стаtički neuronski modeli performansi friкционих материјала, базирани на neuronskim мrežama sa prostiranjem signala unapred i obučavani помоћу backpropagation algoritma.

Habanje i istrošenje friкционог материјала коčnice može takođe u значајnoj meri da utiče na performanse friкционог para, односно performanse коčnice, a time i коčног система. Istrošenje zavisi od dosta faktora као што су температура, оптерећење, брзина klizanja, особине материјала и издржливост преносног слоја (површински слој friкционог материјала посредством кога се остварује тренje u kontaktu friкционог para коčnice). Zbog тога je mogućnost предвиђања истрошenja friкционог материјала u зависности od njegovog сastava i uslova proizvodnje u sinergiji sa režimima rada коčnice istraživana u [12]. U ovom radu, особине веštačких neuronskih мreža да успоставе функционалну зависност između ulaznih i izlaznih parametara su искоришћene за предвиђање истрошenja friкционог материјала u odnosu na uticaj navedenih faktora. Istraživanja u [13] se odnose na главни механизам habanja kod disk коčница, pri čemu je представљен динамиčки model коeficijenta тренja, где су и тренje i habanjeузети u обзир. Ovaj model objašnjava mnogo отворених пitanja o principu funkcionisanja коčних система. Dinamički model koji je razvijen prema [13] opisuje dinamičko ponašanje коeficijenta тренja i njegovu зависност od temperature u friкционом слоју. Takođe su detaljno objašnjeni efekat feedinga (pada performansi usled dejstva visoke temperature),

kao i složena zavisnost koeficijenta trenja od brzine klizanja. Pokušaji da se opiše mehanizam habanja frikcionog materijala, kao i kako on može da utiče na performanse kočnice je takođe proučavan u [14,15,16].

Imajući u vidu da dinamičko predviđanje performansi kočnog sistema u velikoj meri zavisi i od mogućnosti prenošenja generisanog momenta kočenja posredstvom pneumatika na površinu puta, veoma je važno poznavanje trenutno važećih uslova u kontaktu pneumatika i tla u pogledu karaktera promene klizanja i koeficijenta prijanjanja. Upravo zbog toga u savremenoj nauci istraživanjima na temu mogućnosti upravljanja klizanjem u kontaktu pneumatik-tlo se poklanja velika pažnja od strane mnogih autora. U skladu sa tim mogu se sresti različiti pristupi problemu upravljanja klizanjem u kontaktu pneumatika i tla, bilo da se radi o kočenju ili propulziji. Imajući u vidu temu ove doktorske disertacije, glavna pažnja je usmerena na istraživanja koja su u tesnoj vezi sa upravljanjem klizanjem točka tokom kočenja. Radovi poput [17,18], koji proučavaju klizanje točka pri ubrzavanju vozila, se čine kao interesantni u smislu analize same ideje i njenih dostignuća u primeni za proučavanje uticaja klizanja točka na kočne performanse. Osnovni cilj istraživanja u [17] je optimizacija propulzivnih performansi vozila na točkovima kako bi klizanje u kontaktu pneumatik-tlo bilo na željenom nivou. Analiziran je uticaj položaja težišta vozila i ugla nagiba puta na maksimalnu vrednost propulzivne sile u kontaktu pneumatika i tla koja može biti preneta, a da pri tome podužno klizanje točka ne pređe nivo od 20%. U [18] je predloženo rešenje bazirano na razvijenom kontroleru čiji zadatak predstavlja održavanje klizanja pogonskih točkova na željenom nivou. Kontroler je razvijen pomoću tzv. „sliding-mode“ tehnikе upravljanja koja se zasniva na primeni isprekidanog upravljačkog signala koji prinuđuje sistem upravljanja da „kliza“ duž krive koja predstavlja željeno dinamičko ponašanje sistema. Ono što se može uočiti kao nedostatak ove metode jeste odsustvo povratne informacije o tome da li je željeni nivo klizanja točka stvarno i postignut.

U slučaju kočenja, u većini radova koji se bave problemom upravljanja klizanjem točka najveća pažnja je posvećena mogućnostima za unapređenje ABS-a ili mogućnostima za razvoj i uvođenje novih načina upravljanja klizanjem točka koje

su slične onom na kome se zasniva ABS, ali koje mogu biti upotrebljene kao alternativa. Tako je u [19,20] predloženo rešenje kočnog sistema motornog vozila sa inteligentnim osobinama, pri čemu je mehatronski pristup pomogao da se izbegnu neke od mana uočenih kod konvencionalnih kočnih sistema. Iako je prvobitni ABS sistem neprekidno usavršavan do danas kroz nekoliko generacija, i dalje se vrše mnogobrojna istraživanja u toj oblasti kako bi se upravljanje klizanjem točka usavršilo [21]. Cilj korigovanja pritiska aktiviranja kočnice, koju vrši ABS tokom svog rada, je da se klizanje točka zadrži što je moguće bliže maksimumu krive klizanje–koeficijent prijanjanja, odnosno maksimalnoj vrednosti koeficijenta prijanjanja. Bilo koja vrednost klizanja koja odgovara tački na krivoj klizanja sa nižim koeficijentom prijanjanja vodi do gubitka efikasnosti procesa kočenja. Isto tako, prevelike vrednosti klizanja točka dovode do tendencije ka blokiranju točka, što takođe utiče na gubitak efikasnosti kočenja i stabilnosti vozila. Zbog toga je u ovom radu razmatrano na koji način bi bilo moguće unaprediti upravljačku jedinicu ABS-a da bi mogla da koristi povratnu informaciju o trenutno ostvarenom nivou klizanja točka i o intenzitetu momenta kočenja, kako bi se obezbedilo bolje upravljanje klizanjem. Pokušaji da se upravljanje klizanjem točka dodatno unapredi su sprovedeni i u [22,23] uvođenjem elektrootpornog modulatora pritiska aktiviranja kočnice kojim se upravlja preko odgovarajućeg kontrolera. U pitanju je tzv. „sliding mode“ kontroler čiji primarni zadatak predstavlja postizanje željenog nivoa klizanja točka, koji je zatim implementiran preko tzv. HILS (engl. *Hardware in the loop simulation*) platforme, koja je u [23] iskorišćena za istraživanje mogućnosti za dalje unapređenje ABS i ESP sistema. Za identifikaciju i analizu uticajnih parametara iskorišćen je tzv. model četvrtine vozila, koji se zasniva na analizi dinamičkog ponašanja samo jednog točka vozila.

U [24] su razmatrani problemi u identifikovanju parametara koji karakterišu interakciju pneumatika sa različitim površinama puta. Odgovarajuće metode nadgledanja stanja u kontaktu pneumatik-tlo predložene su na bazi fazi logičkog pristupa. Analizirani su najpoznatiji modeli kontakta pneumatik-tlo koji se mogu podeliti na modele sa empirijski uspostavljenim vezama između parametara i modele koji su zasnovani na predstavljanju točka kao mehaničkog sistema. Cilj

rada je bio da se napravi iskorak ka primeni metoda veštačke inteligencije, odnosno fazi logike za identifikaciju parametara u kontaktu pneumatik-tlo (klizanja točka i koeficijenta prijanjanja) koji bi dalje mogli da se koriste od strane sistema za upravljanje performansama kočnog sistema, što je dalje detaljno analizirano u [25]. Adaptivni neuro-fazi pristup je iskorišćen u [26] za upravljanje kočnim sistemom, odnosno za projektovanje kontrolera koji bi mogao da reguliše klizanje točka. Implementirana struktura upravljanja sastoji se od konvencionalnog kontrolera i neuro-fazi kontrolera sa povratnom spregom. Prvi je potreban da garantuje opštu asimptotičku stabilnost sistema i kao inverzni referentni model za simulaciju odziva kočnog sistema. Njegov izlaz se koristi kao signal greške za postepeni algoritam učenja kako bi se ažurirali parametri neuro-fazi kontrolera. U simulacijama i eksperimentalnim proučavanjima, predložena strategija upravljanjem klizanjem je testirana na modelu ABS sistema. Ovaj pristup takođe odlikuje velika složenost u pogledu strukture i veliki računski zahtevi jer sadrži veliki broj komponenata. Promene vertikalnog opterećenja, koeficijenta trenja u kontaktu pneumatika i puta, nagiba puta i druge nelinearnosti u pogledu dinamičkog ponašanja točka mogu značajno uticati na performanse ABS sistema ili bilo kog drugog sistema za upravljanje klizanjem u kontaktu pneumatika i tla. Zbog toga je potrebno dinamičko prilagođavanje sistema da bi se prevazišli ovi problemi. U [27] je razvijen adaptivni PID koncept sa naglaskom primene kod ABS sistema i to u kombinaciji fazi logike i genetskih algoritama. Cilj ovakve strategije upravljanja je bio skraćenje zaustavnog puta, uz istovremeno održavanje klizanja točka unutar željenog opsega. Rezultati simulacije prikazuju upravljanje klizanjem sa prihvatljivom tačnošću, ali se nedostatak kao i kod prethodno analiziranih radova ogleda u tome da nije razvijen dinamički model koji bi obuhvatao i uticaje fenomena u kontaktu friкционog para kočnice i uticaje interakcije pneumatik-tlo.

Pokušavano je takođe i sa razvojem numeričkih modela na kojima bi se zasnivala strategija za upravljanje klizanjem točka. Prema [28,29], modeliranje rada ABS-a je ključno u cilju simulacije dinamičkog ponašanja vozila tokom kočenja i ostvarivanja dobrog odnosa između modela vozila i eksperimentalnih podataka. Upravljačka jedinica ABS je testirana na probnom stolu sa ciljem da se

istraži mogućnost razvoja numeričkog modela ABS sistema. Napravljeno je nekoliko simulacija kočenja na suvoj i mokroj podlozi sa najčešće zastupljenim situacijama pri kojima se aktivira ABS da bi se napravilo poređenje između implementiranog ABS modela i realnog ABS sistema testiranog na tzv. HILS platformi. Veoma sličan pristup je predložen i u [30], gde je akcenat stavljen na istraživanje mogućnosti unapređenja ESC sistema na analogan način. Istraživanja prezentovana u [31,32] se odnose na mogućnost razvoja sistema za upravljanje momentom zakretanja oko vertikalne ose putem regulacije klizanja točkova kako bi se poboljšala stabilnost vozila. Istraživanja su obavljena pomoću nelinearnog modela vozila sa osam stepeni slobode koji uključuje i statički model kontakta pneumatik-tlo zasnovan na tzv. Magičnoj formuli [32]. Istraživanje objavljeno u [33] je interesantno sa stanovišta tehnike koja je primenjena za upravljanje klizanjem točka – tzv. tehnike pokretne klizeće površine koja se translira i/ili rotira ka drugoj površini. Ova tehnika je primenjena za upravljanje klizanjem da bi se ostvario snažan i brz odziv sistema i zasniva se na praćenju greške između referentnog (željenog) i stvarnog klizanja. Nedostatak ovakvog pristupa je upravo to što se za upravljanje klizanjem koristi samo jedan parametar, tj. nepostojanje modela koji bi dinamički i istovremeno mogao da objedini uticaje više parametara koji utiču na nivo klizanja u kontaktu pneumatik-tlo. U [34] je razmatrano kakav uticaj imaju oscilacije karkase pneumatika koje ABS uzrokuje tokom rada na dinamičko ponašanje vozila i promenu klizanja u kontaktu pneumatik-tlo. Razvijen je model pneumatika namenjen za analizu oscilacija koji obezbeđuje simuliranje različite bočne krutosti, praćenje promene krutosti pneumatika u uslovima male brzine i praćenje ponašanja klizanja u kontaktu pneumatik-tlo u skladu sa statičkim uslovima prema modelu tzv. Magične formule. U [35] je istraživano zbog čega je važno da ovi dodatni elektronski upravljeni sistemi (ABS, ASR, ESP, BAS) ispravno obavljaju svoju funkciju u smislu upravljanja klizanjem točka i kakav je uticaj njihovog otkaza na dinamičko ponašanje vozila i zahteve vozača saopštenih preko točka upravljača, potrebnih da se vozilo zadrži na željenom pravcu. Dva sistema za kontrolu zakretanja vozila oko vertikalne ose, zasnovana na upravljanju klizanjem točka po ugledu na ABS pristup, razvijena su u [36]. Cilj razvoja kontrolera koji upravljuju zakretanjem vozila oko vertikalne ose u slučaju kočenja i

upravljanja je da se unapredi stabilnost vozila u poprečnom pravcu. Kontroleri su razvijeni na osnovu ABS strategije upravljanja klizanjem i upravljanja zakretanjem oko vertikalne ose pomoću PID pristupa. Koncept upravljanja je zasnovan na određivanju za koliko je potrebno korigovati nivo klizanja svakog točka da bi se ostvarila željena promena momenta zakretanja oko vertikalne ose.

Tema istraživanja velikog broja radova [37,38,39,40,41] su bila istraživanja na polju uvođenja hardverskih i softverskih poboljšanja elektronskih komponenata ABS sistema u cilju boljeg upravljanja klizanjem kočenih točkova. Tako je u [37] predložen davač sa unapređenim karakteristikama, čiji osnovni zadatak predstavlja prikupljanje podataka o uslovima u kojima se vrši kočenje vozila, kao i „prepoznavanje“ kritičnih situacija. Ovakve unapređene karakteristike davača, koje mu omogućavaju da vrši „prepoznavanje“ kritičnih situacija su obezbeđene hardverskom implementacijom mikroprocesora koji na osnovu broja obrtaja koji davač meri izračunava klizanje u realnom vremenu. Osnovni cilj razvoja ovakvog davača je smanjenje opterećenosti elektronske upravljačke jedinice usled obrade velikog broja podataka koje prikuplja i obrađuje, što može doprineti njenom bržem radu, mada ovakav način izračunavanja klizanja točka ne garantuje bitno unapređenje performansi sistema. U [38] je razmatrana mogućnost uvođenja hibridnog načina upravljanja u cilju unapređenja performansi ABS sistema. Hibridno upravljanje predloženo u ovom radu podrazumeva kontrolere bazirane na upravljanju sa i bez povratne sprege kojima je moguće kompenzovati uticaj promenljivosti koeficijenta trenja u kontaktu pneumatik-tlo. Performanse ovakvog upravljanja ABS-om su testirane putem kompjuterske simulacije. Prilikom razvoja kontrolera koji funkcioniše na principu povratne sprege, metodologija upravljanja ABS-a je predstavljena i analizirana kao problem upravljanja klizanjem točka u zatvorenoj petlji. U drugom slučaju, razvijen je tzv. feedforward kontroler pri čemu je referentno klizanje održavano na konstantnom nivou koji može da varira u zavisnosti od promene koeficijenta trenja u kontaktu pneumatik-tlo. Osnovni cilj ovog dela sistema upravljanja je bio održavanje klizanja tokom rada ABS-a na nivou koji obezbeđuje maksimalnu silu kočenja. Oba kontrolera se zasnivaju na matematičkom modelu rada kočnog sistema. Uz prepostavku da se usporenje

vozila može iskoristiti kao pokazatelj vrednosti koeficijenta prijanjanja u kontaktu pneumatika i tla, u radu je istraživana mogućnost njegovog korišćenja za podešavanje referentne (željene) vrednosti klizanja točka pod pretpostavkom da je na vozilo ugrađen davač usporenja u podužnom pravcu. Predmet istraživanja izloženog u [39] se odnosi na projektovanje načina upravljanja kočnim sistemom u cilju optimizacije sile kočenja. Kao u velikoj većini radova na ovu temu, osnovna ideja je da se odredi pri kojoj vrednosti klizanja točka je dostupno maksimalno prijanjanje prilikom intervencije ABS-a. Nedostatak pristupa predloženog u ovom radu se ogleda u tome što je identifikacija referentne (optimalne) vrednosti klizanja pri kojoj je dostupno maksimalno prijanjanje bazirana na statičkom modelu interakcije pneumatik-tlo razvijenom od strane Pacejke [39]. Izvorni model definisan preko tzv. „Magične formule“ je u određenoj meri modifikovan kako bi se sveo na dve promenljive koje moraju biti određene neposredno pre primene. Predloženi metod upravljanja je verifikovan pomoću simulacionog modela baziranog na modelu četvrtine vozila. U [40,41] je predložen fazi-genetski kontroler za unapređenje rada ABS sistema. Ulazne veličine u kontroler su merene pomoću davača broja obrtaja točkova i davača usporenja u podužnom pravcu. Istraživanje je karakteristično po tome što su parametri funkcija pripadanja (domeni, raspored i tip) i fazi logičkih pravila određeni (optimizovani) pomoću genetskog algoritma. Funkcija cilja optimizacije parametara fazi kontrolera je definisana tako da se klizanje točka održava na nivou koji obezbeđuje postizanje maksimalne sile kočenja, a time i maksimalnog usporenja vozila u podužnom pravcu. Rezultati simulacije pokazuju da kontroler pokazuje zadovoljavajuće performanse upravljanja sistemom za različita stanja podloge po kojoj se vrši kočenje. Imajući u vidu činjenicu da se optimizacija parametara fazi kontrolera pomoću genetskog algoritma vrši u tzv. offline režimu, glavni nedostatak ovog pristupa je nemogućnost prilagođavanja sistema upravljanja dinamičkoj promeni ulaznih veličina u realnom vremenu, tj. adaptacije parametara fazi kontrolera u toku njegovog rada. Veoma slična strategija upravljanja klizanjem je predložena u [42]. Razlika u odnosu na prethodne pristupe se ogleda u tome što je kao glavna komponenta sistema upravljanja korišćen kontroler zasnovan na tzv. „sliding-mode“ konceptu upravljanja. Hibridni neuro-fazi sistem za upravljanje

performansama ABS-a je predstavljen u [43]. Odziv sistema na upravljački signal je simuliran pomoću PD kontrolera, koji prestavlja inverzni referentni model rada ABS-a. Njegov izlaz je iskorišćen za ažuriranje parametara neuro-fazi kontrolera sa povratnom spregom. Integralni član je naknadno spregnut sa PD i neuro-fazi kontrolerom u hibridni sistem za upravljanje klizanjem točka. Istraživanja izložena u [44,45,46] se oslanjaju jedino na fazi logički pristup upravljanja klizanjem tokom rada ABS sistema. U [44] je istraživano na koji način je moguće metodu fazi logike načiniti robusnom. Rezultati simulacije su pokazali da predloženi koncept upravljanja može u određenoj meri doprineti poboljšanju odziva ABS sistema, kao i poboljšanju sposobnosti prilagođavanja sistema različitim podlogama na kojima se vrši kočenje vozila. Rezultati su takođe pokazali da je robusnjom fazi logičkom metodom takođe moguće, u određenoj meri, poboljšati upravljanje klizanjem u kontaktu pneumatik-tlo i samim tim uticati na skraćenje zaustavnog puta, međutim, nedostatak ovakvog pristupa je tzv. pasivan rad, odnosno sistem nema sposobnost da uči tokom rada i da se prilagođava novim zahtevima vozača, promenama režima kočenja, stanja opterećenosti vozila, kao i promenama uslova u kontaktu pneumatika i tla. U [45] se išlo korak dalje u smislu pokušaja da se algoritam po kome ABS upravlja klizanjem točka načini „inteligentnijim“. Posebna pažnja je posvećena uslovima kočenja pri kojima se pojedini točkovi vozila tokom kočenja nalaze na podlogama sa različitim uslovima prijanjanja. Razvijen je fazi kontroler ABS sistema u cilju podešavanja klizanja svakog točka u zavisnosti od stanja podloge po kojoj on koči. Na osnovu poznate vrednosti trenutnog nivoa klizanja točka, fazi kontroler ima zadatak da obezbedi konvergenciju te trenutne vrednosti ka optimalnoj. Rezultati simulacije potvrđuju dobre mogućnosti u pogledu sprečavanja blokiranja točka. Budući da se zasniva na korektivnom delovanju, odnosno na konceptu *a posteriori* upravljanja, uočeni nedostaci ovog pristupa se odnose na odsustvo istraživanja u pravcu predviđanja performansi ABS-a i razvoju modela koji bi mogao da upravlja klizanjem točka na inteligentniji način. Metod upravljanja klizanjem točka predložen u [46] je veoma sličan prethodnom uz razliku što su u okviru sistema korišćena dva fazi kontrolera, razvijena prema Takagi-Sugeno metodologiji. U [47] su takođe istraživane mogućnosti unapređenja performansi ABS sistema pomoću fazi logičkog pristupa. Detaljno je analizirana

razlika između ABS sistema koji svoju funkciju baziraju na praćenju ugaonog usporenja točka i onih koji su bazirani na praćenju klizanja točka. Pokazano je da prvi mogu da obavljaju funkciju bez informacije o tome kolika je brzina vozila, ali imaju nedostatak što u tom slučaju maksimalnu vrednost sile koju podloga može da prenese nije moguće iskoristiti u potpunosti. U ovom radu je razmatrano unapređenje drugog načina funkcionisanja ABS-a, baziranog na praćenju klizanja točka, kako bi se omogućilo iskorišćenje maksimalno dostupne sile koju tlo može da prenese. U skladu sa tim potrebno je realizovati tri važna zadatka: (i) identifikovati trenutne uslove puta, odnosno odrediti koeficijent prijanjanja u slučaju već poznatog klizanja točka, (ii) razviti metod za pronalaženje „idealnog“ nivoa klizanja točka, tj. pronaći vrednost klizanja točka pri kojoj se ostvaruje maksimalno prijanjanje u kontaktu pneumatik-tlo za date karakteristike pneumatika i tla, kao i stanje opterećenosti vozila, i (iii) razviti metod za upravljanje klizanjem točka, odnosno održavati ga na željenom nivou. Fokus u [47] je postavljen na ovaj poslednji, treći zadatak. Razvijen je fazi logički kontroler sa ciljem da se unaprede performanse ABS-a u pogledu održavanja klizanja točka na željenom nivou. Pored toga, istraživane su mogućnosti da se predloženim pristupom unapredi osećaj sile na pedali od strane vozača.

Rešavanju drugog zadatka koji sistem za upravljanje klizanjem treba da omogući, a koji je definisan u [47], posvećena je posebna pažnja u istraživanjima predstavljenim u [48,49,50,51]. U [48,49] je pokazano kako je moguće odrediti maksimum krive klizanja u dinamičkim uslovima imajući u vidu da je to parametar koji definiše granični uslov stabilnosti vozila pri kočenju. Predloženi koncept je analiziran i testiran u slučajevima kada informacija o klizanju u podužnom pravcu jeste i nije dostupna. Izvršena je i analiza na koji način je moguće primeniti predloženi koncept za nadgledanje rada postojećeg ABS sistema, kako bi se povećala bezbednost vozila i ujedno poboljšale karakteristike ABS-a. U [50] je predložen koncept izračunavanja klizanja točka u realnom vremenu bez potrebe za merenjem brzine kretanja vozila. Preciznost izračunavanja je unapređena uzimanjem u obzir i vrednosti otpora kotrljanja, međutim, ovakav koncept zahteva još dosta rada na polju unapređenja imajući u vidu da ne daje očekivane rezultate

pri simulaciji kočenja na različitim podlogama. U [51] je razvijen algoritam za izračunavanje brzine kretanja vozila (kao najvažnijeg parametra za izračunavanje klizanja točkova) na osnovu merenja broja obrtaja svih točkova i ubrzanja/usporenja u podužnom pravcu. Osnovni cilj rada se odnosi na razvoj koncepta koji ne zahteva komplikovano i dugo izračunavanje, odnosno veliko opterećenje procesora računarske jedinice, što ga čini posebno pogodnim za primenu u elektronskim kontrolnim jedinicama ABS-a i/ili ASR-a.

Efikasnost procesa kočenja u velikoj meri zavisi od koeficijenta prijanjanja u kontaktu pneumatika i puta. Posebno je značajno utvrditi pri kojoj vrednosti klizanja točka je dostupna njegova maksimalna vrednost za datu podlogu i karakteristike pneumatika. Analizirano je nekoliko radova koji se bave ovom problematikom. U [52,53,54] su korišćeni pristupi bazirani na statičkom modelu interakcije pneumatik-tlo koji uzima u obzir jedino klizanje točka kao ulazni parametar. U [53] je matematičkom modelu dodat neuronski model kako bi se eliminisao uticaj pojave nelinearnosti tokom određivanja sile kočenja pomoću klasičnih modela. Pristup prezentovan u [55] se odnosi na određivanje koeficijenta prijanjanja radi formiranja krive klizanja u statičkim uslovima primenom proširenog Kalmanovog filtra, dok je u istu svrhu u [56] korišćen adaptivni koncept baziran na matematičkom pristupu, odnosno diferencijalnim jednačinama kretanja vozila. Posebnu pažnju privlači istraživanje objavljeno u [57] gde je razvijen dinamički model kontakta pneumatik-tlo u podužnom pravcu. Model razvijen u ovom radu se zasniva na dinamičkom modelu trenja ranije razvijenom za potrebe izučavanja kontaktnih fenomena pri idealizovanom dodiru u jednoj tački, poznatiji pod nazivom Lu-Gre model. Usvajanjem kontaktne površi između pneumatika i tla mogu se razviti parcijalne diferencijalne jednačine za raspodelu sile trenja duž te površi. U radu je pokazano da za razliku od uobičajenih statičkih modela kontakta pneumatik-tlo ovakav dinamički pristup ima potencijal da tačno identificuje promenljivi karakter sile trenja tokom prelaza između kočenja i ubrzanja. Uspostavljena je statička zavisnost sile trenja od podužnog klizanja, koja zavisi od brzine klizanja i omogućava lako podešavanje parametara modela u poređenju eksperimentalno dobijenim podacima.

Da bi se razvio sistem za predviđanje, odnosno inteligentno upravljanje performansama kočnog sistema, u ovom poglavlju su takođe analizirana rešenja zasnovana na upotrebi metoda iz domena veštačke inteligencije. U [58,59,60] su predstavljeni pristupi zasnovani na veštačkim neuronskim mrežama, pri čemu su razvijeni neuronski modeli obučavani korišćenjem backpropagation algoritma. U fokusu ovih radova je bilo prediktivno upravljanje pomoću veštačkih neuronskih mreža. Radovi su karakteristični po tome što je višeslojni perceptron izabran da predstavi NARX model nelinearnog sistema. Pokazano je da takav NARX dinamički model, koji se zasniva na tzv. feedforward arhitekturi, nudi dobre sposobnosti aproksimacije, zajedno sa robusnošću i tačnošću predviđanja.

U [61,62] su izvršena veoma važna i korisna istraživanja u vezi sa generalnim konceptom upravljanja nelinearnim sistemima pomoću veštačkih neuronskih mreža. U [61] su istaknute prednosti korišćenja veštačkih neuronskih mreža za modeliranje rada nelinearnog procesa u opštem smislu, kao i prednosti primene dobijenih prediktivnih kontrolera u predviđanju performansi nelinearnih procesa. Pokazano je da je implementacija prediktivnog neuronskog kontrolera u stanju da eliminiše najznačajnije prepreke koje se javljaju kod rešavanja problema u vezi sa upravljanjem nelinearnim sistemima. Time se značajno olakšava razvoj nelinearnih modela i obezbeđuje brzo i pouzdano rešenje upravljačkog algoritma. U [62] je uvedena veštačka neuronska mreža zasnovana na višeslojnem perceptronu i opisano je kako se ona može iskoristiti za aproksimiranje različitih funkcija. Pri tome se mora voditi računa da ne dođe do zasićenosti podacima iz seta za obuku i da onda podaci ne uspevaju da budu dobro generalizovani u novim situacijama. Razmatrano je nekoliko tehnika za poboljšavanje generalizacije. U radu se takođe analiziraju tri opšte arhitekture koje se mogu koristiti za upravljanje: model adaptivnog upravljanja na osnovu referentnog modela, model prediktivnog upravljanja i upravljanje sa povratnom spregom. Ove arhitekture demonstriraju različite načine na koje veštačke neuronske mreže mogu biti korišćene kao osnovni blokovi u lancu upravljanja. Iskorišćavanjem sposobnosti veštačkih neuronskih mreža da vrše univerzalnu aproksimaciju, opisivanje dinamičkog ponašanja nelinearnog procesa je u [63] izvršen korišćenjem

rekurentne Elmanove mreže. Obučavanje mreže je implementirano u realnom vremenu i zasnovano je na backpropagation algoritmu. Zasnovana na neuronskom modelu, implementirana je strategija prediktivnog upravljanja, primenjena za upravljanje eksperimentom u laboratoriji. Eksperimentalni podaci za nekoliko različitih uslova rada ne samo da pokazuju održivost korišćenja veštačkih neuronskih mreža sa učenjem implementiranim u realnom vremenu već i, znajući njihove osobine prilagođavanja, potvrđuju da su one izuzetan izbor i za sisteme koji imaju jako izražene dinamičke promene parametara. Sličan zaključak je donešen i na osnovu istraživanja obavljenog u [64], gde su vršene simulacije koristeći Matlab/Simulink i analize praktične primene kontinualno obučavanih neuronskih kontrolera u realnom vremenu da bi se identifikovala promena složenog nelinearnog dinamičkog ponašanja sistema napajanja. Šira i sadržajnija analiza metode pod nazivom model prediktivnog upravljanja data je u [65]. Predstavljen je pregled nekih od najvažnijih unapređenja na polju razvoja ove teorije i razmatrane su dalje mogućnosti za njihovu primenu u praksi. Iako je došlo do značajnog napretka ove metode, postoji još uvek nekoliko otvorenih pitanja vezanih za njenu robusnost, prilagođavanje, nadgledanje performansi, formiranje modela, proračunavanje i implementaciju.

Posebnu pažnju tokom istraživanja u ovoj doktorskoj disertaciji zauzimaju metode za dinamičko, tzv. „on-line“ obučavanje, odnosno načini realizovanja sistema za upravljanje kako bi on bio u stanju da se obučava u realnom vremenu za nove situacije i promene u radnim uslovima. Imajući u vidu da je to relativno novi pravac u okviru trenda razvoja sistema inteligentnog upravljanja, u literaturi se može sresti mali broj radova koji se bave problemima na tu temu. Tako je u [66,67] predložen algoritam za obuku veštačke neuronske mreže u realnom vremenu koji se zasniva na metodi obuke putem nasumične pretrage, odnosno tzv. algoritma nasumične promene težinskih odnosa (engl. Random Weight Change - RWC). Rezultati simulacije pokazuju da se obukom veštačke neuronske mreže pomoću ovog algoritma mogu dobiti veoma slični efekti kao i sa backpropagation algoritmom. Za razliku od backpropagation algoritma, pomenuta metoda može biti implementirana u mešovitom digitalnom/analognom hardveru, a da pri tome i

dalje ima značajno kratko vreme ciklusa obuke. U [68] se predlažu modeli sa dva tipa on-line učenja: jedan zasnovan na gradijentnim metodama i analizama osetljivosti izlaznih performansi modela u odnosu na parametre modela i drugi, zasnovan na varijacionom proračunu, koji vodi do off-line rešenja i tehnike koja pretvara off-line rešenje u on-line. Detaljna analiza ovih, kao i ostalih rešenja obučavanja koja se mogu sresti je izložena u [69]. Posebna pažnja je posvećena tzv. Atiya-Parlos algoritmu za obuku rekurentnih neuronskih mreža. Cilj je dobijanje uvida u ponašanje algoritama i kako su oni povezani sa tehnikom minimiziranja izlazne greške. Atiya-Parlos algoritam se zasniva na izračunavanju gradijenta greške na bitno različit način od ostalih algoritama. Prostor u kom algoritam pretražuje težinske odnose je visokodimenzionalan i stoga je veoma teško opisati strukturu tog prostora. Karakterizacija strukture tog prostora i lokacija minimuma greške može voditi boljem razumevanju algoritama i do budućih poboljšanja. Drugi važan aspekt obuke rekurentnih neuronskih mreža je analiziran u [69], gde je analizirano kako promene težinskih odnosa utiču na stabilnost predviđanja neuronske mreže. Pokušaj da se odgovori na ovo pitanje napravljen je proverom kontrolnih tačaka mreže tokom procesa obuke. Na primeru izrazito nelinearnog sistema, u [70] su testirane mogućnosti različitih strategija upravljanja zasnovanih na veštačkim neuronskim mrežama koje imaju sposobnost obučavanja u realnom vremenu. Paralelno su analizirana rešenja sa mrežama sa prostiranjem signala unapred i rešenja bazirana na rekurentnim neuronskim mrežama na osnovu kojih su projektovani odgovarajući kontroleri. Rezultati su pokazali da ako se pojave poremećaji u sistemu, veštačka neuronska mreža ima sposobnost da nauči kako da prevaziđe takve iznenadne promene parametara. Struktura i način obučavanja ovakve dinamičke neuronske mreže je detaljnije analizirana u [71].

Opšte karakteristike veštačkih neuronskih mreža, a posebno dinamičkih su detaljno analizirane u [72,73,74]. Imajući u vidu njihove opšte osobine, u ovoj doktorskoj disertaciji je istraživano na koji način dinamičke, a posebno rekurentne, neuronske mreže mogu biti iskorišćene za modeliranje i upravljanje performansama različitih sistema, a što bi moglo uz određena unapređenja da se primeni i slučaju dinamičkog upravljanja performansama kočnice, odnosno kočnog

sistema u toku ciklusa kočenja. Prema [75], upravljanje performansama ABS sistema predstavlja izazovan problem zbog nelinearne dinamike kočenja i vremenski promenljive prirode parametara. U ovom radu je predstavljen adaptivni hibridni kontroler zasnovan na veštačkoj neuronskoj mreži. Hibridni kontroler se zasniva na veoma dobro poznatoj feedback linearizaciji, u kombinaciji sa dve feedforward neuronske mreže koje su uvedene kako bi se naučile nelinearnosti koje se javljaju tokom rada ABS sistema. U [76,77,78] su istraživane mogućnosti primene adaptivnih rekurentnih neuronskih mreža za rešavanje različitih problema. Opšti zaključak je da se podešavanjem parametara mreže u smislu broja skrivenih slojeva, broja neurona, karakteristika funkcije prenosa, vrednosti težinskih odnosa i bias-a u toku njenog rada mogu dobiti zadovoljavajući rezultati u pogledu predviđanja. Stabilnost ovakvih varijabilnih modela može biti verifikovana pomoću teorije Ljapunova. Novi pristup za upravljanje nelinearnim diskretnim dinamičkim sistemima, koji se oslanja na identifikaciju diskretnog modela sistema pomoću neuronske mreže, predložen je u [79]. U [80] je analizirano na koji način arhitekture veštačkih neuronskih mreža utiču na uspešnost predviđanja, tj. sposobnost generalizacije mreža za isti set podataka za obuku i testiranje. Kompleksni postupak razvoja veštačkog neuronskog modela je demonstriran na primeru disk kočnice. Modeliran je uticaj radnih uslova disk kočnice (pritiska aktiviranja, početne brzine i temperature) na njene maksimalne performanse kao i performanse opadanja i obnavljanja efikasnosti. Veštački neuronski model je razvijan kroz istraživanje na koji način sinergija različitih parametara mreže, poput algoritma učenja, funkcije prenosa i broja neurona u skrivenim slojevima, utiče na sposobnosti neuronskog modela da predviđa performanse disk kočnice. U ovom radu je pokazano da kompleksne nelinearne zavisnosti između posmatranih ulaznih i izlaznih parametara mogu biti modelirane odgovarajućom analizom i podešavanjem parametara veštačke neuronske mreže. Sledećih nekoliko istraživanja predstavljenih u [81,82,83,84,85,86,87] se odnose na to kako je moguće razviti dinamički neuronski model koji ima sposobnosti da realno oslikava proces koji se modelira i da vrši stabilno predviđanje u dinamičkim radnim uslovima tokom dužeg vremenskog perioda. Razvijeni dinamički neuronski modeli su obučavani u tzv. off-line režimu, pri čemu su pretežno korišćene

kombinacije feedforward i rekurentnih mreža. U [86,87] se posebno ističe korisnost NARX rekurentne neuronske mreže za upravljanje složenim dinamičkim sistemima. Ovaj tip dinamičke neuronske mreže je iskorišćen i u [88,89]. U [88] su istraživane mogućnosti razvoja metode za predviđanje uticaja radnih režima disk kočnice na pojavu tzv. „stick – slip“ fenomena tokom ciklusa kočenja. Korišćenjem dinamičkih neuronskih mreža, razvijen je dinamički model uticaja radnih uslova disk kočnice na pojavu kontaktnih fenomena i način promene momenta kočenja. U [89] je pokazano da je dinamičko modeliranje i predviđanje momenta kočenja veoma važno za dalje unapređenje performansi kočnica motornih vozila putem preciznijeg upravljanja njihovim performansama u zavisnosti od zahteva vozača i promene uslova u kontaktu pneumatika i puta. Rekurentne neuronske mreže su pokazale izuzetne sposobnosti u modeliranju, predviđanju i upravljanju dinamičkom promenom momenta kočenja u toku ciklusa kočenja u zavisnosti od različitih radnih režima kočnice.

Mogućnosti genetskih algoritama kao jedne od tehnika veštačke inteligencije su takođe analizirane od strane velikog broja autora. Prioritet u ovom pregledu je dat radovima koji se odnose na mogućnosti kombinovanja ove metode sa ostalim tehnikama iz domena veštačke inteligencije (veštačkim neuronskim mrežama i fazi logikom) u cilju upravljanja performansama različitih sistema. U [90] je pokazano kako je moguće obučavati rekurentnu veštačku neuronsku mrežu pomoću genetskog algoritma. Algoritmi obuke za rekurentne neuronske mreže, zasnovani na gradijentu greške, veoma su nestabilni u svojoj potrazi za minimumom i zahtevaju više vremena za izračunavanje kada su broj skrivenih slojeva ili neurona visok. Problemi koji se javljaju u skladu sa tim doveli su do potrebe razvoja novih načina obuke. Pored genetskih algoritama, kao tehnike za traženje globalnog rešenja, u [91] je dodatno analizirana i mogućnost upotrebe tehnike pod nazivom „Simulated Annealing“ (takođe jedna od optimizacionih metoda baziranih na traženju globalnog rešenja) za obučavanje neuronskih mreža, pri čemu su njihove osobine upoređene međusobno i sa backpropagation algoritmom. Tzv. Monte Karlo studija je izvedena u cilju testiranja prikladnosti ovih tehnika za globalnu pretragu u optimizaciji parametara neuronskih mreža. Dobijeni rezultati pokazuju

superiornost ovih tehnika nad backpropagation algoritmom zbog njegove podložnosti ka zarobljavanju u lokalnom minimumu. Detaljniji osvrt na upoređenje backpropagation i genetskog algoritma je analiziran od strane istih autora u [92]. U [93] je predstavljen način kombinovanja fazi logike i neuronskih mreža (FNN pristup), gde je primenjen kontinualni genetski algoritam za učenje veze između fazi ulaza i izlaza. Za razliku od tradicionalnog fazi sistema zaključivanja za koji su potrebni fazifikovani ulazi i fazifikovani izlazi, fazifikovani brojevi ili oni stvarni mogu biti ulaz u FNN.

3

PREDMET I CILJ ISTRAŽIVANJA

3.1. PREDMET ISTRAŽIVANJA

Sve veći i složeniji zahtevi u pogledu performansi koji se postavljaju pred savremene kočne sisteme motornih i priključnih vozila iziskuju njihova dalja unapređenja kroz razvoj novih, intelligentnih, rešenja. U cilju uvođenja intelligentnog upravljanja performansama kočnog sistema motornog vozila, koji svoju funkciju izvršavaju u različitim i izrazito dinamički promenljivim radnim uslovima, nameće se potreba za istraživanjem na koji način radni režimi kočnice utiču na njene performanse i kako je ove uticaje moguće predvideti da bi se generisala vrednost momenta kočenja, koja odgovara trenutnim uslovima prijanjanja u kontaktu pneumatik-tlo, pravilnom selekcijom pritiska aktiviranja kočnica u skladu sa zahtevima vozača.

Evidentno je da kočne performanse vozila zavise prvenstveno od performansi kočnica kao izvršnih elemenata kočnog sistema, kao i od usklađenosti tih performansi sa trenutno raspoloživim uslovima prijanjanja u kontaktu pneumatika sa podlogom. Imajući u vidu da vozač, zbog svojih ograničenja, ne može da pravovremeno vrši sve potrebne korekcije pritisaka aktiviranja kočnice, niti može da ih precizno usklađuje sa uslovima prijanjanja točkova (pneumatika), kočni sistem treba da poseduje intelligentne sposobnosti.

Iz svega navedenog je jasno da je realizacija ovih zahteva, koji se postavljaju pred savremena motorna vozila u pogledu aktivne bezbednosti vozila, veoma složena, što dalje dovodi do potrebe da se implementacija intelligentnog upravljanja performansama kočnog sistema bazira na metodama i tehnikama koje će obezbiti intelligentne osobine kočnom sistemu u smislu usklađivanja performansi kočnog sistema sa uslovima prijanjanja točkova, kako u podužnom,

tako i bočnom pravcu. To podrazumeva poznavanje funkcionalne veze između pritiska aktiviranja kočnice, brzine točka, temperature kočnice i momenta kočenja, odnosno mogućnosti za prenos momenta kočenja na tlo i to tokom ciklusa kočenja. Ovo jasno pokazuje da je neophodno uvesti dinamičko modeliranje procesa kočenja, u toku ciklusa kočenja, i stvaranje uslova za neprekidno učenje o tome kako radni režimi kočnice utiču na njene performanse i kako se to reflektuje na interakciju pneumatika i tla, odnosno na nivo klizanja u kontaktu pneumatik-tlo. Pored toga, u literaturi su nedovoljno istražene mogućnosti uvodenja veštačke inteligencije u modeliranju i predviđanju performansi kočnica i kočnog sistema motornih vozila u dinamičkim radnim uslovima (u toku ciklusa kočenja) kao i uvođenje intelligentnog adaptivnog upravljanja performansama kočnog sistema sa stanovišta klizanja pneumatika u kontaktnu sa tlom. Zbog svega toga modeliranje performansi kočnica, odnosno kočnog sistema, nije ni malo lak zadatak, pogotovo ako se za to koriste klasične matematičke metode. Imajući u vidu da se pomoću klasičnih matematičkih metoda ne mogu modelirati složeni dinamički uticaji radnih režima kočnica motornih vozila na njihove izlazne performanse, odnosno vrednost klizanja u kontaktu pneumatika sa podlogom, javlja se potreba za primenom drugih sofisticiranih metoda. Zbog toga je predmet istraživanja u ovoj doktorskoj disertaciji upravo usmeren na metode iz domena veštačke inteligencije.

Predmet ove doktorske disertacije su kompleksna teorijska i eksperimentalna istraživanja u cilju modeliranja složenih dinamičkih uticaja radnih režima kočnica motornih vozila i uslova u kontaktu pneumatik-tlo, kao i predviđanja ovih uticaja u cilju intelligentnog upravljanja performansama kočnica u toku ciklusa kočenja. Polazna pretpostavka tokom istraživanja se odnosi na to da predviđanje i upravljanje performansama kočnog sistema motornog vozila, za date radne režime kočnica, može biti izvršeno ukoliko postoje dinamički modeli koji opisuju datu promenu i ako postoji mogućnost identifikacije uslova prijanjanja pneumatika u toku ciklusa kočenja. Dalje, posmatrani uticaji radnih režima kočnice na njene izlazne performanse, izraženi preko dinamičkog modela koji je sposoban da neprestano uči i donosi zaključke na osnovu istorije događaja je od suštinskog značaja. Vrlo važan segment istraživanja se odnosi na to da li je modeliranje,

odnosno razvoj dinamičkog modela performansi kočnica, kao izvršnih organa sistema za radno kočenje motornog vozila, moguće izvesti metodama čiji se rad bazira na paralelnom procesiranju eksperimentalno dobijenih podataka tokom procesa kočenja, kako bi se na osnovu toga omogućila inteligentna adaptacija performansi kočnog sistema. To je glavni razlog zbog koga se u ovoj doktorskoj disertaciji istražuju mogućnosti inteligenčnog upravljanja performansama kočnog sistema pomoću metoda veštačke inteligencije (dinamičkih veštačkih neuronskih mreža, fazi logike i genetskih algoritama), a na osnovu željene dinamičke promene klizanja u kontaktu pneumatika i puta. Pri tome je posebno važno da pomenute metode imaju sposobnost da omoguće kontinualno učenje, kao i inteligenčno prilagođavanje promenama parametara koji utiču na performanse kočnice, odnosno vrednost klizanja u kontaktu pneumatika i tla.

Za konkretnu realizaciju teorijskih i eksperimentalnih istraživanja u okviru ove doktorske disertacije korišćena je odgovarajuća merna oprema i uređaji za akviziciju podataka, u kombinaciji sa primenom savremenih softverskih paketa sa integrisanim okruženjima za rad sa pomenutim metodama veštačke inteligencije. Osim toga, istraživanja u ovom radu obuhvataju i sveobuhvatan pregled relevantne literature i rezultata u oblasti istraživanja.

3.2. CILJ ISTRAŽIVANJA

Naučni cilj istraživanja u okviru ove doktorske disertacije je da se primenom savremenih teorijskih i eksperimentalnih metoda istraže mogućnosti primene metoda veštačke inteligencije za inteligenčno upravljanje performansama kočnica, a u skladu sa time i performansama kočnog sistema, kako bi se ostvarilo inteligenčno prilagođavanje dinamičkim promenama podužnog klizanja u kontaktu pneumatika i puta tokom ciklusa kočenja. Pored toga, istraživanje se odnosi i na mogućnosti predviđanja performansi kočnica motornih vozila u toku ciklusa kočenja, na osnovu razvijenog dinamičkog modela procesa kočenja, čime će se omogućiti njihovo usklađivanje sa trenutno važećim uslovima prijanjanja u kontaktu pneumatik-tlo. Dinamički model procesa kočenja treba da omogući kasnije upravljanje performansama kočnica, a time i kočnog sistema, na taj način

što će biti omogućeno predviđanje potrebnog pritiska aktiviranja kočnica, za date radne režime kočnice, u cilju postizanja i održavanja željenog klizanja u kontaktu pneumatik-tlo u podužnom pravcu.

Istraživanje mogućnosti razvoja dinamičkog modela procesa kočenja, baziranog na tehnikama veštačke inteligencije, treba da omogući uvođenje intelligentnih sposobnosti kočnog sistema. Budući intelligentni kočni sistem bi mogao, na osnovu prethodno razvijenog dinamičkog modela procesa kočenja, da predviđi potrebne vrednosti pritisaka aktiviranja kočnica na prednjoj i zadnjoj osovini za date uslove kočenja (trenutne vrednosti pritiska aktiviranja kočnice, trenutne vrednosti brzine i ugaonog usporenja točka na prednjoj/zadnjoj osovini, temperature u kontaktu friкционog para kočnice na prednjoj/zadnjoj osovini i trenutne vrednosti klizanja u kontaktu pneumatik-tlo) kako bi se postiglo željeno klizanje u kontaktu pneumatika i tla.

Podjednako važan cilj je analiza mogućnosti i domena primene tehnika veštačke inteligencije (fazi logike i dinamičkih veštačkih neuronskih mreža) u procesu modeliranja, predviđanja i upravljanja performansama kočnica, odnosno kočnog sistema. Kao naučni cilj istraživanja se nameće i istraživanje mogućnosti unapređenja aktivne bezbednosti privrednih motornih vozila, sa elektronskim kočnim sistemom, uvođenjem dinamičkog, tzv. hibridnog modela, koji je zasnovan na integraciji različitih tehnika veštačke inteligencije. Sve ovo sa ciljem da se obezbede mogućnosti upravljanja performansama kočnog sistema odnosno obezbedi optimalna vrednost podužnog klizanja u kontaktu pneumatika i tla. Cilj predstavlja i istraživanje mogućnosti razvoja „baze znanja“, bazirane na inverznom dinamičkom modelu klizanja u kontaktu pneumatik tlo, koja će biti korišćena od kontrolera za upravljanje, tj. selekciju pritisaka aktiviranja kočnica na prednjoj i zadnjoj osovini u zavisnosti od željenog klizanja, trenutnih kočnih performansi, raspodele sile kočenja i želje vozača.

4

KOČNI SISTEMI PRIVREDNIH VOZILA

4.1. UVOD

Aktivna bezbednost vozila zavisi od performansi kočnog sistema, odnosno kočnica kao njegovih izvršnih elemenata, kao i od stanja u kontaktu pneumatik-tlo. To nameće potrebu da se izvrši dinamičko praćenje, modeliranje i upravljanje performansama kočnice kako bi se klizanje u kontaktu pneumatika i puta dovelo na željeni nivo. Upravo to je razlog što su u okviru ovog poglavlja najpre analizirane osnovne karakteristike kočnih sistema motornih i priključnih vozila i zahtevi koji se postavljaju pred savremene kočne sisteme. Posebna pažnja je posvećena performansama kočnog sistema kao najvažnijoj funkcionalnoj karakteristici, a detaljno u okviru toga i performansama kočnica, odnosno fenomenima koji se dešavaju u kontaktu frikcionih površina kočnice.

U okviru daljih istraživanja analizirane su karakteristike postojećih elektronskih sistema za upravljanje performansama kočnog sistema koji se primenjuju na savremenim privrednim vozilima i to pre svega ABS-a, ESC-a i EBS-a, kako bi se prevazišli problemi usko povezani sa održavanjem stabilnosti i upravljivosti vozila tokom kočenja. Ovakvi sistemi su elektronski upravljeni i svojom funkcijom doprinose unapređenju aktivne bezbednosti vozila tokom kočenja vozila, a posebno na površinama puta sa niskim koeficijentom prijanjanja. Na taj način pružaju podršku vozaču da zadrži upravljivost vozila, da izbegne prepreke na putu i da, u određenom broju slučajeva, svede dužinu puta kočenja na minimum. Svi pomenuti sistemi baziraju svoju funkciju na što efikasnijem prenosu momenta kočenja generisanog u samoj kočnici, odnosno sile kočenja na površinu puta po kome se vozilo kreće, što nesumnjivo zavisi od nivoa klizanja u poduznom/bočnom pravcu u kontaktu pneumatika i tla.

Uvođenje elektronski upravljanog kočnog sistema (EBS-a) koji integriše sve pomenute funkcije (ABS/ASR/ESC) za sada predstavlja najvažnije unapređenje u domenu razvoja kočnih sistema privrednih vozila. Zahvaljujući elektronskom prenosu signala do izvršnih komponenata kočnog sistema (proporcionalni rele ventil za prednju i osovinski modulator za zadnju osovinu), EBS obezbeđuje njihov brži odziv u skladu sa zahtevima vozača. Na osnovu analize karakteristika pomenutih elektronski upravljenih sistema sprovedena su dalja istraživanja u cilju identifikovanja prostora, kao i mogućnosti za njihovo dalje unapređenje. Osobine EBS-a da vrši elektronski nadzor i upravljanje tzv. indeksom pritisaka između proporcionalnog rele ventila (za prednju osovinu) i osovinskog modulatora (za zadnju osovinu) nude mogućnost u pogledu osnove za dalje unapređenje na polju razvoja novih rešenja za inteligentno upravljanje performansama kočnih sistema. To se posebno odnosi na unapređenje ABS-a i raspodele sila kočenja između prednje i zadnje ili više osovine vozila, kao najvažnijih funkcija integrisanih u okviru EBS-a, koje svoj rad zasnivaju na praćenju nivoa klizanja u kontaktu pneumatika i puta.

Da bi se to ostvarilo, eksperimentalna identifikacija načina funkcionisanja EBS sistema, kao i uticaja pojedinih parametara na njegove performanse je od izuzetne važnosti, a posebno sa stanovišta utvrđivanja karaktera promene klizanja u kontaktu pneumatik-tlo u zavisnosti od različitih uslova, odnosno režima kočenja, zahteva vozača, vrste puta po kome se vozilo kreće i trenutnih uslova prijanjanja. To dalje nameće potrebu za razvojem novih inovativnih rešenja i unapređenje postojećeg upravljačkog programa EBS sistema.

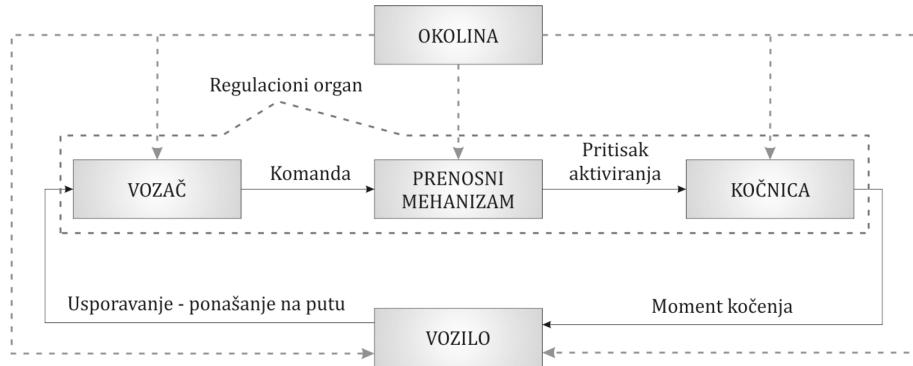
4.2. KARAKTERISTIKE I ZADACI KOČNIH SISTEMA MOTORNIH VOZILA

Kočni sistem je značajan sastavni deo svih motornih i priključnih vozila, veoma uticajan na njihovu opštu funkciju i kvalitet [94,95,96,97,98,99]. Pored toga, pravilno funkcionisanje kočnog sistema je posebno važno sa stanovišta bezbednosti vozila u saobraćaju, kao i sa stanovišta njegove stabilnosti. Funkcionisanje kočnica kao glavnih izvršnih elemenata u sastavu kočnih sistema motornih i priključnih vozila je takođe veoma važno imajući u vidu da se od njih zahtevaju visoke performanse, kako bi rad kočnog sistema tokom procesa kočenja bio što efikasniji [100].

Kočni sistemi motornih i priključnih vozila su projektovani u cilju izvršavanja veoma važnih zadataka među kojima se kao najvažniji ističe zaustavljanje vozila [101,102]. Značaj kočnih sistema posebno dolazi do izražaja u slučajevima kada se mora zaustaviti vozilo koje se kreće velikom brzinom na kratkom rastojanju, a posebno ako je to neophodno ponoviti više puta u određenom vremenskom intervalu [101,102]. Pri tome očekujemo da neće doći do greške ili gubitka stabilnosti vozila. Prema [98], osnovni zadaci kočnog sistema mogu najbolje da se objasne uz pomoć funkcionalnog modela prikazanog na slici 4.1, koji definiše veze u procesu kočenja između vozača, vozila i okoline. Vozač i kočni sistem vozila čine regulacioni organ sistema upravljanja, koji kočnim momentom, kao izlaznom karakteristikom, deluje na vozilo, tj. na objekt upravljanja. Na taj način se vozilo usporava ili zaustavlja, a na određen način i ponaša na putu [98,101], što dalje utiče na njegovu upravljivost i stabilnost.

U skladu sa slikom 4.1 okolina je u ovom sistemu prisutna na više načina. Potreba za kočenjem ne mora da bude rezultat samo želje vozača već i određenih zahteva okoline (na primer opasnost na putu). Okolina takođe ima nezanemarljiv uticaj na ponašanje vozila na putu, što je neposredno povezano sa prijanjanjem i mogućnostima prijema kočnih i drugih reaktivnih sila, ali i sa makro-reljefom puta i/ili poprečnim nagibom [98]. Vozač aktivira kočni sistem, tj. kočnice kao glavne izvršne elemente tako što deluje silom na komandu sistema za radno kočenje koja se dalje prenosi posredstvom prenosnog mehanizma do kočnica. Dejstvom pritiska

aktiviranja ostvaruje se odgovarajuća sila aktiviranja, koja dovodi do generisanja momenta kočenja, a koji dalje u zavisnosti od trenutnih uslova prijanjanja, odnosno od mogućnosti njegovog prenošenja na podlogu, utiče na vozilo, tj. njegove kočne performanse.



Slika 4.1. Funkcionalni model kočnog sistema

U skladu sa [103], vozilo ostvaruje kretanje posredstvom sile trenja koja deluje u kontaktu pneumatika i podloge. Bilo da se radi o kočenju, upravljanju ili ubrzavanju, odgovarajuće sile moraju biti generisane u kontaktu relativno male površine pneumatika i podloge. Jedino sila jednaka ili manja od proizvoda vertikalnog opterećenja i koeficijenta prijanjanja može biti prenešena u kontaktu između pneumatika i tla [104]. Zbog toga je veoma važno znati, pored toga da li je ostvarena potrebna vrednost momenta kočenja u kočnici, da li je tu vrednost momenta kočenja moguće preneti posredstvom točka na podlogu.

Sa stanovišta bezbednosti motornog vozila tokom procesa kočenja, kočni sistem i pneumatički su njegove najvažnije komponente [103]. Oni moraju da bezbedno obavljaju svoju funkciju pod različitim radnim uslovima, uključujući i stanje u kontaktu pneumatika i tla, odnosno različitu vrstu podloge po kojoj se vozilo kreće (podloge sa različitim koeficijentom prijanjanja), različito stanje date podloge (suva, mokra, klizava, prljava, itd.), u slučaju neopterećenog ili opterećenog stanja vozila, prilikom kočenja na pravcu ili u krivini, sa novim ili pohabanim kočnim oblogama i slično. Pri tome je veoma važno obratiti pažnju na zadovoljenje uslova stabilnosti vozila tokom kočenja, raspodelu sila kočenja između pojedinih točkova, prijanjanje u kontaktu pneumatika i tla, kočenje tokom promene pravca kretanja

(skretanje), modulaciju sile na pedali kočnice, zaustavni put i istrošenost kočnih obloga.

Prema [98,105], funkcija cilja kočnog sistema može da se definiše na više načina. Kočni sistem se može definisati kao sistem koji ima zadatak da obezbedi usporavanje i zaustavljanje vozila, sa usporenjima koja odgovaraju potrebama i raspoloživom prijanjanju uz stabilno kretanje vozila za vreme kočenja. Ukoliko se zadacima kočnog sistema da naglasak sa stanovišta bezbednosti saobraćaja, može da se kaže da je zadatak kočnog sistema da spreči udes u saobraćaju u okolnostima kada je kočenje moguće i kada pojava udesa zavisi od usporenja i stabilnosti vozila za vreme kočenja. Osim toga, kočni sistem motornog ili priključnog vozila treba da izvršava svoje zadatke, tj. da izvršava svoju funkciju cilja, pod svim uslovima puta i okoline u kojima vozilo može da se koristi, tj. u kojima može da izvršava svoje zadatke [105].

Zbog navedenih zadataka kočni sistemi motornih vozila imaju izuzetno veliki značaj, posebno sa stanovišta bezbednosti vozila i saobraćaja. U ovom pogledu posebno je važan zadatak kočnih sistema da u trenucima neočekivane opasnosti na putu omogući vozaču da vozilo zaustavi na što kraćem rastojanju kako bi se izbegao sudar. Zbog toga su, u skladu sa potrebama istraživanja u ovoj doktorskoj disertaciji, u narednom izlaganju upravo analizirane karakteristike kočnih sistema motornih i priključnih vozila sa stanovišta njihove bezbednosti.

Kočni sistemi savremenih motornih i priključnih vozila moraju da zadovolje brojne zahteve kvaliteta, nametnute zakonskim obavezama sa stanovišta bezbednosti vozila i saobraćaja, a zatim i razvojem vozila i njihove primene, razvojem tehnologije i novih materijala, ekonomskim ograničenjima, itd. [98,100]. Takođe prema [21,98,103], kočni sistem jednog vozila mora da obezbedi:

- ✓ usporavanje i zaustavljanje vozila u svim okolnostima kada je to potrebno, sa zahtevanim usporenjima, tj. potrebnom efikasnošću
- ✓ stabilno kretanje vozila tokom kočenja, tj. sprečavanje pojava koje dovode do gubitka upravljaljivosti i stabilnosti vozila

- ✓ mirno i postepeno kočenje, uz puni osećaj vozača (srazmernost sile na komandi i usporenja)
- ✓ aktiviranje kočnica sa što manjim silama na komandi kočnog sistema, tj. uz što manje napore vozača
- ✓ visoku pouzdanost u svim predviđenim radnim uslovima, tj. funkcionisanje sistema sa što manjom verovatnoćom pojave otkaza
- ✓ funkcionisanje uz potrebu što manjeg i što jednostavnijeg održavanja, tj. mogućnost rada u dužim vremenskim periodima bez potreba za nekim posebnim intervencijama ili kontrolama
- ✓ kočenje bez škripe ili drugih neželjenih pratećih pojava

U skladu sa [103], stepen zadovoljenja svih do sada navedenih zahteva predstavlja meru kvaliteta kočnog sistema. Kvalitet kočnih sistema može da se definiše pomoću funkcionalnih karakteristika od kojih se kao najvažnija sa stanovišta istraživanja sprovedenih u ovoj disertaciji odnosi na sposobnost usporavanja i zaustavljanja vozila bez gubitka stabilnosti kretanja, odnosno na performanse kočnog sistema. Zbog toga će ova funkcionalna karakteristika kočnih sistema biti detaljnije analizirana u daljem tekstu.

4.3. PERFORMANSE KOČNIH SISTEMA

Prema Pravilniku ECE-13 (Aneks 4) [104], osnovnu karakteristiku kočnog sistema koja se odnosi na njegove performanse predstavlja usporenje kojim se vozilo koči, odnosno srednja maksimalna vrednost usporenenja koja može da se ostvari i/ili put kočenja ili zaustavljanja vozila (zaustavni put). Pored toga, analogno zaustavnom putu, može se razmatrati i vreme kočenja kao kvalitativna karakteristika performansi kočnog sistema. Očigledno je međutim da je performanse kočnog sistema najbolje ocenjivati na osnovu puta zaustavljanja, pošto je to prava mera kvaliteta kočnog sistema u odnosu na sprečavanje udesa, odnosno pravovremeno zaustavljanje vozila kako do udesa ne bi ni došlo [98]. Međutim, performanse kočnog sistema se mogu ocenjivati preko tzv. kočnog koeficijenta q , koji se definiše kao odnos usporenenja vozila i gravitacionog ubrzanja, a u skladu sa jednačinom 4.1.

$$q = \frac{a}{g} \quad (4.1)$$

Performanse kočnog sistema mogu biti određene putem merenja puta kočenja u funkciji od početne brzine vozila i/ili putem merenja srednjeg maksimalnog usporenenja vozila [104]. Pri tome se zaustavni put definiše kao rastojanje koje vozilo pređe od trenutka kada vozač započne dejstvo na komandu sistema za radno kočenje do trenutka kada se vozilo potpuno zaustavi. Pod početnom brzinom se podrazumeva brzina u trenutku kada vozač započne dejstvo na komandu sistema za radno kočenje i ne sme biti manja od 98% od brzine koja je definisana za određeni test. Maksimalno dozvoljeni put kočenja se definiše u vidu binoma oblika (jednačina 4.2):

$$S_m = A v_1 + \frac{v_1^2}{B} \quad (4.2)$$

i to u funkciji od početne brzine. Koeficijenti A i B, početne brzine, kao i dozvoljene sile na komandi kočnice se definišu za svaku kategoriju vozila posebno. Srednje maksimalno usporenje (a_m) se izračunava kao osrednjeno usporenje u odnosu na

rastojanje pređeno u intervalu ograničenom brzinama v_b do v_e u skladu sa jednačinom 4.3 [104].

$$a_m = \frac{v_b^2 - v_e^2}{25.92(s_e - s_b)} [m/s^2] \quad (4.3)$$

gde su:

v_0 - početna brzina vozila u km/h

v_b - brzina vozila pri $0.8 \cdot v_0$ u km/h

v_e - brzina vozila pri $0.1 \cdot v_0$ u km/h

s_b - rastojanje pređeno između v_0 i v_b u metrima

s_e - rastojanje pređeno između v_0 i v_e u metrima

Vrlo bitne performanse kočnog sistema, koje će za vozilo korišćeno za eksperimentalna istraživanja u okviru ove doktorske disertacije biti detaljnije analizirane u narednom tekstu, odnose se na stabilnost vozila pri kočenju, odnosno na osobine ponašanja vozila prilikom kočenja. Propisi koji se odnose na ove osobine kočnih sistema utvrđuju zahteve u vezi sa blokiranjem točkova pri kočenju [98,104]. Zahtevi stabilnosti su u izvesnom smislu oprečni zahtevima performansi. Ako se traže visoke performanse stabilnost je teže obezbediti, odnosno visoki zahtevi stabilnosti moraju da tolerišu i nešto niže performanse [101]. U osobine koje u širem smislu reči predstavljaju performanse kočnih sistema spada i sposobnost sistema da po želji vozača ostvaruje postepen i miran porast usporenja u srazmeri sa silom na komandi, kao i da se koči bez škripe ili drugih neželjenih uticaja na okolinu [98,101].

Zahtevi u pogledu bezbednosti koji se postavljaju pred kočne sisteme mogu da se zadovolje različitim rešenjima, ali propisi utvrđuju i izvesna ograničenja, odnosno osnovne direktive koje se moraju najpre zadovoljiti preko konstrukcionih zahteva [103]. Imajući u vidu da rešavanje konstrukcionih zahteva nije u fokusu ove disertacije, ovde su pomenute samo osnovne konstrukcione karakteristike kočnih sistema bitne sa stanovišta bezbednosti vozila. Prema tim zahtevima, a u

skladu sa [98,103,104], kočni sistem kao složena struktura treba da ima sledeće osnovne podsisteme: za radno, pomoćno, parkirno i dopunsko kočenje. Podsistem za radno kočenje preuzima izvršavanje najvažnijih zadataka kočnog sistema, odnosno kočenje vozila maksimalnim usporenjima (u slučaju opasnosti) i sva blaža, kratkotrajna kočenja, u normalnim uslovima kretanja. Ovaj podsistem je dakle najvažniji deo kočnog sistema, kome se obraća posebna pažnja [103,105]. Podsistem za pomoćno kočenje se uvodi isključivo radi povećanja bezbednosti vozila u saobraćaju, odnosno u cilju ostvarivanja veće pouzdanosti kočnog sistema. Njegov zadatak je da omogući kočenje vozila i u slučaju ako dođe do otkaza u podsistemu za radno kočenje. Propisi dozvoljavaju da performanse podsistema za pomoćno kočenje budu u određenom stepenu niže od performansi podsistema za radno kočenje [98]. Podsistem za parkirno kočenje ima zadatak da obezbedi trajno kočenje vozila u mestu. Ukoliko se ovaj podsistem reši tako da se može aktivirati i pri kretanju vozila, što se najčešće i radi, podsistem za parkirno kočenje može da preuzme i zadatke pomoćnog kočenja. U tom slučaju se podsistemi za pomoćno i parkirno kočenje objedinjuju (slika 4.3). Podsistem za dopunsko kočenje je prevashodno namenjen blagom, dugotraјnom kočenju pri kretanju vozila na dužim padovima. U tom smislu njegovo obavezno postojanje propisano je samo za vozila većih ukupnih masa.

U skladu sa [102,103], svaki od navedenih podsistema uključuje sledeće funkcionalne komponente: komandu, prenosni mehanizam i kočnicu. Od svih navedenih funkcionalnih elemenata najvažnije su kočnice, koje predstavljaju izvršne elemente kočnih sistema. Pomoću kočnica se osnovni zadaci kočnih sistema i realizuju, pa je zbog toga njihov značaj u okviru kočnog sistema posebno izražen. Izuzev najnovijih konceptualnih rešenja kočnica koje funkcionišu na principu beskontaktnog dejstva (baziranog na elektro-magnetnoj interakciji između elemenata), sve vrste kočnica koje se danas koriste na motornim vozilima funkcionišu na principu trenja [98,103]. Detaljna analiza na koji način ostvareno trenje u kontaktu friкционih površina kočnice, kao i fenomeni koji se tu javljaju, utiču na njene izlazne performanse je data u poglavljju 4.4.

4.4. FENOMENI U KONTAKTU FRIKCIIONIH POVRŠINA KOČNICE

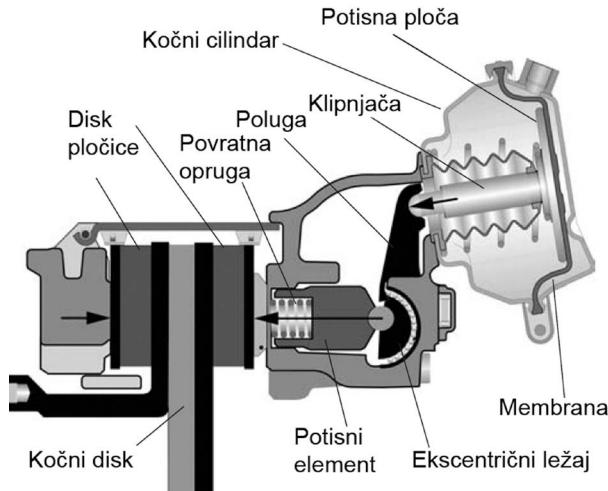
Sila trenja koja se javlja u kontaktu površina u dodiru koje se relativno kreću jedna u odnosu na drugu, odnosno u kontaktu frikcionog para kočnice predstavlja jedan od najinteresantnijih i najvažnijih fizičkih fenomena u vezi sa procesom kočenja. Prema [106], Leonardo da Vinči je 1490. godine ustanovio da se sa povećanjem normalnog opterećenja na telo u kontaktu povećava i sila trenja. U daljim istraživanjima je otkrio da je ta sila trenja između tela u kontaktu nezavisna od nominalne kontaktne površine. To je 200 godina kasnije formulisao Amonton u tzv. „Amontonsove zakone trenja“:

1. sila trenja je direktno proporcionalna normalnom opterećenju
2. sila trenja je nezavisna od nominalne površine u kontaktu frikcionog para.

Odnos između sile trenja i normalne sile se naziva koeficijent trenja (μ). Usled složenosti uslova u kojima se odvija kontakt frikcionih površina nije konstantna veličina [10,106].

Prema [10,106], osnovna veličina koja određuje izlazne performanse kočnih sistema motornih vozila je vrednost i stabilnost sile kočenja u kontaktu frikcionog para. Sila kočenja u kontaktu frikcionog para, odnosno generisani moment kočenja je rezultat sinergije većeg broja vrlo složenih fenomena koji se dešavaju tokom procesa kočenja [5,10]. To dalje ukazuje na to da se problemu interakcije frikcionog para diska kočnice i disk pločica (frikcionog materijala), slika 4.2, odnosno tribološkim procesima koji se odvijaju u njihovom kontaktu, mora posvetiti mnogo veća pažnja. Imajući u vidu da predmet istraživanja u ovoj disertaciji ne obuhvata analizu uticaja osobina i sastava frikcionih materijala, ovo se pre svega odnosi istraživanje sinergijskih uticaja složenih triboloških procesa na nivo i stabilnost koeficijenta trenja, a time i na performanse disk kočnica. U skladu sa [2,10,50,106], koeficijent trenja u kontaktu frikcionog para kočnice mora biti relativno visok i stabilan bez obzira na temperaturu kočnice, trenutnu brzinu vozila, vlažnost, stepen istrošenja elemenata frikcionog para, prisustvo vode ili prljavštine u kontaktu. Situacija u kontaktu frikcionog para disk kočnice i dalje nije

dovoljno istražena i shvaćena sa stanovišta načina uticaja pojedinih uticajnih faktora (režimi kočenja, karakteristike materijala u kontaktu, itd.) [1], a posebno u smislu mogućih načina dinamičkog modeliranja i korigovanja izlaznih performansi disk kočnice u toku ciklusa kočenja, tj. u dinamičkim uslovima rada kočnice.

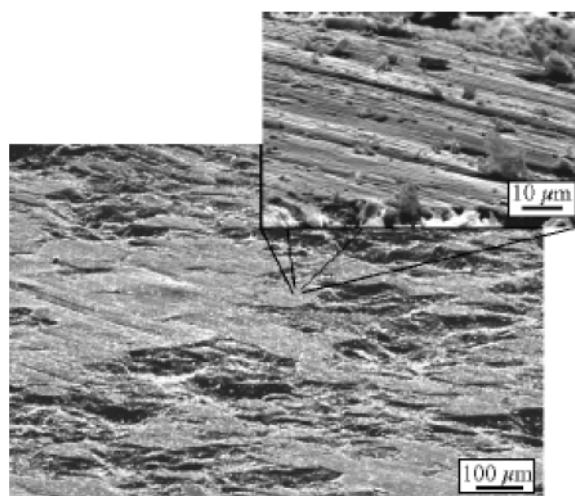


Slika 4.2. Disk kočica kod privrednih vozila

Postizanje željenog nivoa performansi i održavanje njihove stabilnosti, kao rezultat ostvarenog koeficijenta trenja u kontaktu friкционог para u toku ciklusa kočenja, je prema tome najvažniji zadatak u radu kočnice. Koeficijent trenja predstavlja odnos između sile trenja i normalne sile (sile aktiviranja kočnice) i nije konstantna veličina usled složenosti uslova u kojima se odvija kontakt friкционог para, pa su prema [10] zakoni njene promene, za posmatrane radne uslove, do danas ostali vrlo teško predvidivi. O složenosti triboloških procesa koji se dešavaju u kontaktu friкционог para govori i činjenica da zakoni kojima bi se oni mogli opisati na molekularnom nivou pripadaju domenu mehanike, termodinamike i hemije [13,15,107]. Pored toga, kompleksnosti triboloških procesa u kontaktu doprinosi i to što su frikcionii materijali vrlo složeni kompoziti sa izraženo različitim osobinama sirovina od kojih su napravljeni [106,108,109]. Širok spektar karakteristika sirovina koje se koriste u izradi friкционih materijala utiče na različitost u postignutim friкционim performansama i veličinama habanja. Neravnomerno habanje površina friкционih materijala može dovesti do izdizanja pojedinih zona u kontaktu u odnosu na ostali deo površine i stvaranja tzv. kontaktnih slojeva [110]. U [10] je pokazano da se između inicijalnih kontaktnih

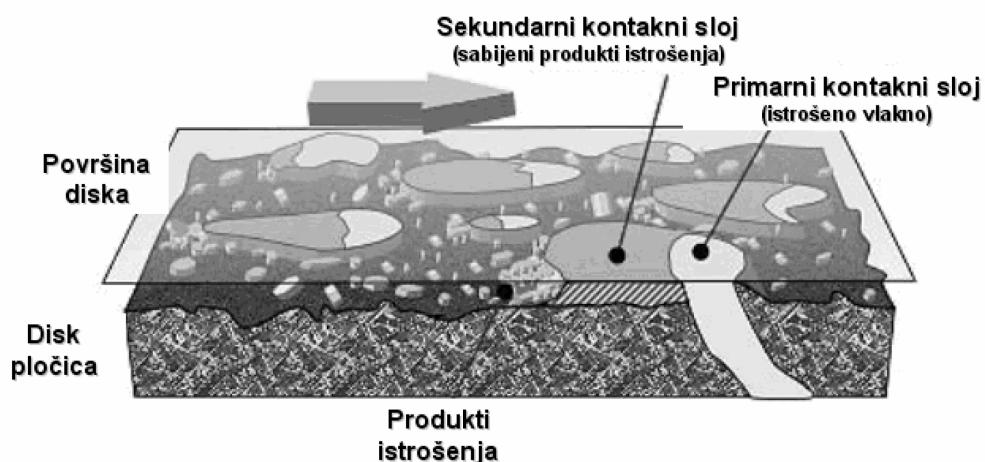
površina diska i disk pločice tokom kočenja razvijaju novi slojevi čiji su sastav i osobine potpuno nepredvidivi i rezultat su većeg broja mehaničkih i hemijskih procesa. Formiranje friкционog sloja ili trećeg tela u velikoj meri može da utiče na performanse kočnice [10,111]. Način sabijanja produkata istrošenja u kontaktu friкционog para tokom kočenja igra glavnu ulogu u formiranju posebnog friкционog sloja ili filma između površina u kontaktu. Ovaj sloj se neravnomerno raspoređuje po frikcionoj površini i utiče na razvoj i razaranje tzv. primarnih i sekundarnih kontaktnih slojeva friкционog para.

Tokom kočenja neprekidno se događaju razaranja postojećih i stvaranja novih kontaktnih slojeva, što menja njihovu strukturu i osobine friкционog filma u skladu sa promenom uslova okoline [10,112]. Preko ovih površina tzv. stvarnog kontakta se prenosi sila trenja koja se razvija u kontaktu. U slučaju kada su ovi slojevi izloženi visokom opterećenju, tj. visokoj vrednosti pritiska aktiviranja, zahvaljujući stišljivosti materijala dolazi do transfera opterećenja na susedne slojeve i boljоj raspodeli opterećenja [10]. Zbog toga veličina i sastav ovih slojeva suštinski utiče na ponašanje friкционog materijala, a time i na performanse friкционog para, odnosno kočnice. Ovakva mesta mogu biti uočena golum okom kao sjajna i ravna mesta prečnika između 50-500 μm i visine do nekoliko mikrona, izdignuta u odnosu na površinu pločice, slika 4.3. Njihov broj je prema [106] reda veličine 10^5 , a zajedno mogu zauzimati 10-30% od nominalne kontaktne površine pločice.



Slika 4.3. Neravnomerno habanje friкционog materijala prema [110]

Primarni slojevi se formiraju zahvaljujući većoj otpornosti na habanje mehanički stabilnijih sirovina friкционog materijala. U drugoj fazi ovako formirana mesta mogu poslužiti za razvoj sekundarnih slojeva pošto produkti istrošenja mekših sirovina u friкционom materijalu relativno malih dimenzija neprestano kruže kroz kanale koji se formiraju u kontaktu friкционog para usled hrapavosti površina u kontaktu. Zbog toga njihovo kretanje često biva sprečeno od strane primarnih, prvo formiranih, slojeva što izaziva njihovo nagomilavanje, a potom i sabijanje u okruženju primarnih slojeva [10,106], slika 4.4. Ovo njihovo sabijanje je izazvano kombinacijom pritiska, sile trenja i topoteke koji se javljaju u kontaktu friкционog para što izaziva dalji rast sekundarnih slojeva. Tokom procesa kočenja veličina produkata istrošenja se dalje smanjuje i kada postanu dovoljno mali oni ili postaju deo kontaktnih slojeva ili bivaju izbačeni iz kontakta. To ukazuje da sekundarni kontaktni slojevi ne mogu postojati bez primarnih slojeva koji su sastavljeni od mehanički stabilnijih sirovina što znači da nestajanjem primarnih nestaju i sekundarni kontaktni slojevi [10,106,110].

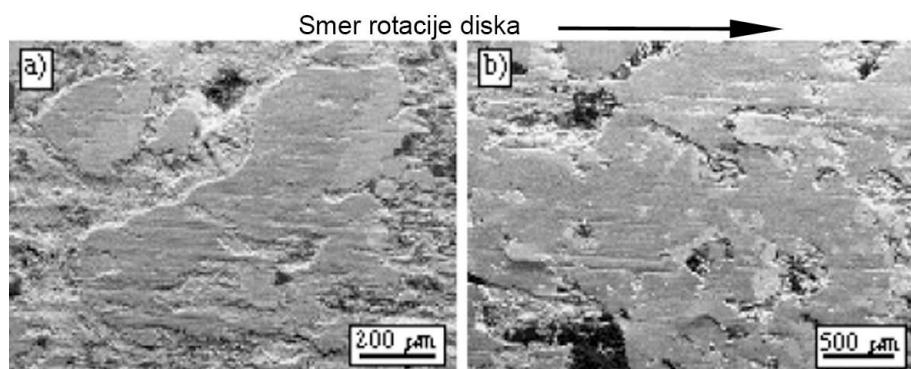


Slika 4.4. Formiranje primarnih i sekundarnih kontaktnih slojeva prema [10]

Prema [10], nestajanje sekundarnih slojeva je rezultat istrošenja ili otkidanja dela vlakana u friкционom materijalu, mada uzrok mogu biti i nečistoće koje se mogu javiti u kontaktu. Kao što dolazi do habanja dela površine friкционog materijala u okruženju kontaktnih slojeva, koji nisu izdignuti na njihovom nivou, sekundarni kontaktni slojevi takođe se habaju usled abrazivnog dejstva trećeg tela u kontaktu [1]. Kada su ovi mehanizmi habanja dominantni onda dolazi do

razaranja sekundarnih kontaktnih slojeva bez obzira na postojanje primarnih slojeva ojačani prisustvom vlakana koji se nalaze u materijalu. Pored toga, sekundarni slojevi zahtevaju stabilne uslove trenja sa dovoljno velikom silom aktiviranja kočnice pošto svaki put kada se pritisak aktiviranja smanji tokom kočenja dolazi do otkidanja delova ovih slojeva i njihovo emitovanje u okolinu [1,10,106].

Veličina kontaktnih slojeva je detaljno istraživana u [2,110,113]. Pokazano je da njihova veličina varira u zavisnosti od pritiska aktiviranja kočnice. Već je objašnjeno da tokom blagih kočenja kontaktni slojevi zauzimaju 10-30% nominalne površine disk pločice, slika 4.5a. Prema [106], u nekim slučajevima, pod dejstvom visokih temperatura i pritisaka u kontaktu, kontaktni slojevi mogu da narastu do veličine koja se meri u milimetrima i mogu zauzeti veći deo površine disk pločice, slika 4.5b.



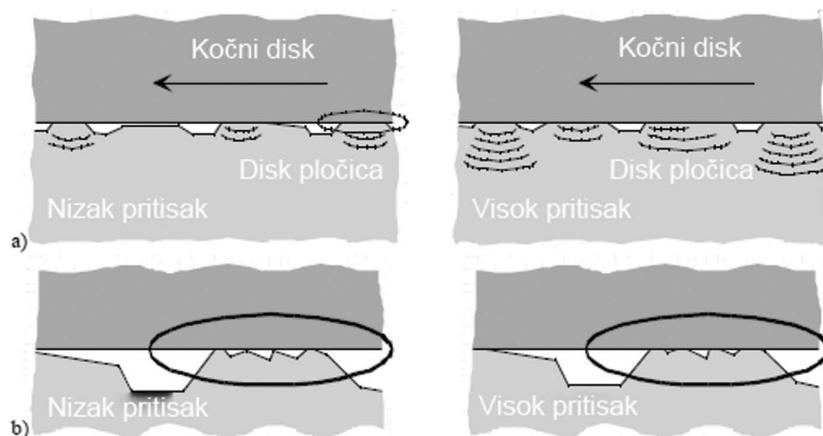
Slika 4.5. Promena veličine kontaktnog sloja prema [106]

Kako je istaknuto u [10], objašnjenje fenomena nastanka i porasta kontaktnih slojeva je vezano za povećanje pritiska aktiviranja čime se smanjuje veličina hrapavosti, odnosno veličina kanala koji postoje usled hrapavosti materijala u dodiru. Time se veća količina materijala koji se nalazi u sloju između friкционog para sabija, a samim tim i pospešuje rast sekundarnih kontaktnih slojeva (slika 4.4). Prema drugom objašnjenju, povećanje temperature u kontaktu zajedno sa povećanjem pritiska dovodi do stvaranja još boljih uslova za razvoj sekundarnih slojeva [2]. Međutim, rast kontaktnih slojeva ne može biti objašnjen kao potreba za većom površinom u kontaktu friкционog para da bi se prenelo veće normalno opterećenje [106]. Zbog toga, kada dolazi do smanjenja pritiska aktiviranja kočnice

mehanizam razaranja slojeva je dominantan u odnosu na mehanizam njihovog stvaranja pa će i veličina sekundarnih slojeva biti smanjena [2,106].

U skladu sa [2,10,106] promenljiva sila aktiviranja kočnice rezultira promenom elastičnog sabijanja friкционog materijala disk pločice. Ovo sabijanje friкционog materijala (slika 4.6) dovodi do:

1. povećanja stvarne površine u kontaktu kroz povećanje broja kontaktnih slojeva (slika 4.6a),
2. preraspodele opterećenja između primarnog i sekundarnog dela u okviru svakog sloja, i
3. povećanja opterećenja na kontaktnim slojevima koji su već u kontaktu (slika 4.6b).



Slika 4.6. Promena stvarne kontaktne površine usled mikrodeformacija prema [106]

Pored ovih tzv. „brzih“ kontaktnih fenomena koji se odigravaju u vrlo kratkom vremenskom periodu, postoji i niz tzv. „sporih“ procesa za čiju pojavu je potrebno određeno vreme. Prema [2,10,106] u takve fenomene spadaju:

1. formiranje, rast i razaranje kontaktnih slojeva,
2. oblikovanje kontaktnih slojeva na mikro nivou,
3. oblikovanje kontaktnih slojeva na makro nivou,
4. termički izazvane deformacije na makro nivou,
5. termički izazvane promene osobina frikcione površine, i

6. procesi „kontaminacije“ i čišćenja površina u kontaktu.

Pored svega ovoga, još jedan, prema [10] veoma važan, uticaj na prirodu posebnog sloja materijala, odnosno tzv. trećeg tela u kontaktu ima transfer materijala. Transfer materijala kod metala, koji je u većini analogan tribološkim interakcijama koje se dešavaju tokom procesa kočenja, potiče od mikromehanizma poznatog kao „formiranje pramca“ [10]. Proces formiranja pramca podrazumeva postojanje tačaka veze, u regionu stvarnog kontakta tela u dodiru, koje se odupiru relativnom klizanju između površina, dovode do plastičnih deformacija, porasta veličine te veze i konačno do pucanja, što dovodi do delimičnog ili potpunog odvajanja čestica koje su formirale tu vezu [10].

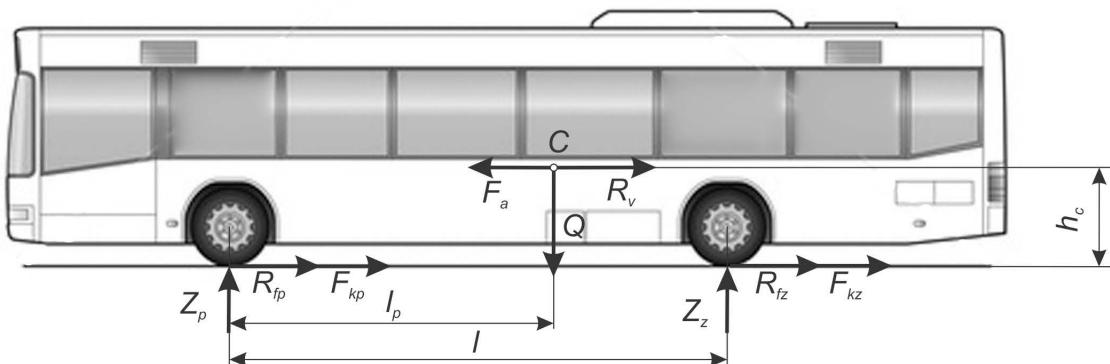
Imajući sve navedeno u vidu, može se naslutiti da je uticaj fenomena u kontaktu friкционog para kočnice na njene izlazne performanse vrlo složen, pogotovo što je stvarna kontaktna površina, između elemenata friкционog para, daleko manja od nominalne kontaktne površine [7,12]. Tokom kočenja, kontakt se ostvaruje preko promenljivog broja kontaktnih površina [13,14]. Ovakva dinamički promenljiva interakcija između površina friкционog para, u zavisnosti od radnih uslova kočnice, tj. promene pritiska aktiviranja, brzine klizanja, temperature, veličine i načina habanja, određuje nivo i stabilnost performansi disk kočnice u toku ciklusa kočenja. Osim toga, na lokalnim kontaktnim površinama se kao rezultat trenja razvija velika količina toplove, koja u sadejstvu sa pomenutim uticajima menja kontaktni profil i time dovodi do promene raspodele pritiska u kontaktu, a time i do dinamičke promene performansi disk kočnice, narušavanja stabilnosti izlaznih performansi, kao i pojavе vibracija, buke, „stik-slip“ fenomena, ali i načina i veličine habanja materijala u kontaktu. Kako je to objašnjeno u [10], generisana toplota tokom kočenja povećava temperaturu u kontaktu friкционog para što može da izazove hemijske i mehaničke promene površina u kontaktu. Ovim su neopterećeni kontaktni slojevi izloženi različitim vidovima kontaminacije kao rezultat kombinovanih mehaničkih i hemijskih reakcija uključujući oksidaciju i prevlačenje produktima istrošenja i praštine iz okoline, što utiče na promenu njihovog sastava, a time i na osobine trenja [10]. To za posledicu može da ima povećanje koeficijenta trenja na kraju kočenja tokom dugotrajnih kočenja, histerezisa koeficijenta trenja

usled promenljivosti pritiska u kontaktu ili njegove varijacije, što dalje direktno utiče i na stabilnost izlaznih performansi kočnice. Na vrednost stvarne temperature u kontaktu friкционог para kočnice, a time i na njene performanse, prema [114,115] utiče geometrija elemenata friкционог para, termička provodljivost materijala i Pekletov broj, koji direktno zavisi od brzine klizanja.

Kako bi se predupredila pojava neželjenih kontaktnih fenomena, a naročito loših i nestabilnih performansi disk kočnice, evidentno je da je potrebno obezbediti praćenje, modeliranje i dinamičko upravljanje, promenu ili usklađivanje, performansama disk kočnice u toku ciklusa kočenja, a u zavisnosti od trenutne želje vozača, odnosno potreba vozila u pogledu stabilnosti i raspodele sila kočenja.

4.5. PONAŠANJE VOZILA TOKOM KOČENJA

Prema [98,116,117], zakoni kretanja vozila u procesu kočenja mogu da se definišu na osnovu opštih postavki mehanike, uz pomoć ravnoteže sila i momenata. U ovoj disertaciji, analiza sila i momenata koji deluju na vozilo tokom kočenja je obavljena na primeru autobusa šematski prikazanog na slici 4.7, koji se koči na ravnom putu sa isključenom spojnicom.



Slika 4.7. Sile koje deluju na vozilo tokom procesa kočenja

Polazeći od opšte diferencijalne jednačine kretanja u obliku:

$$\frac{dv}{dt} = -\frac{\sum R}{\delta \frac{G}{g}} \quad (4.4)$$

i imajući u vidu da je suma horizontalnih sila koje se suprotstavljaju kretanju vozila jednaka:

$$\sum R = R_v + R_f + F_k = kAv^2 + G_f + G_\varphi \quad (4.5)$$

gde su osim ranije datih oznaka:

$$R_v = kAv^2 \quad \text{- otpor vazduha,}$$

$$R_f = R_{fp} + R_{fz} = G_f \quad \text{- ukupan otpor kotrljanja,}$$

$F_k = F_{kp} + F_{kz} = G_\varphi$ - ukupna sila kočenja na obimu svih točkova (kočenja na svim točkovima),

diferencijalna jednačina kretanja vozila u procesu kočenja ima oblik:

$$\frac{dv}{dt} = -\frac{g}{\delta G}(kAv^2 + G_f + G_\varphi) \quad (4.6)$$

Treba napomenuti da se često vrši na podužno nagnutom putu, tako da gravitacione sile mogu da deluju kočeći (kretanje uzbrdo) ili propulzivno (kretanje nizbrdo). U slučaju kočenja na podužnom nagibu nizbrdo, diferencijalna jednačina kretanja bi dobila oblik:

$$\frac{dv}{dt} = -\frac{g}{\delta G}(kAv^2 + G_f \cos \alpha - G \sin \alpha + G\varphi \cos \alpha) \quad (4.7)$$

Dok bi u slučaju kretanja uzbrdo, kada gravitaciona sila deluje kao otpor kretanju, tj. kočeći, zakon kretanja vozila mogao da se opiše diferencijalnom jednačinom oblika:

$$\frac{dv}{dt} = -\frac{g}{\delta G}(kAv^2 + G_f \cos \alpha + G \sin \alpha + G\varphi \cos \alpha) \quad (4.9)$$

Iz diferencijalne jednačine kretanja mogu da se odrede i sve osnovne kočne karakteristike, kao mere performansi procesa kočenja. To je pre svega usporenje, a zatim i vreme i put kočenja. Ako se prepostavi da je brzina vozila na početku kočenja dovoljno mala, tako da otpor vazduha može da se zanemari i da se kočne sile ostvaruju na svim točkovima, izraz (4.6) može da se napiše u jednostavnijem obliku:

$$-\frac{dv}{dt} = a = (\varphi + f) \frac{g}{\delta} \quad (4.10)$$

Iz ovog izraza sledi da je u posmatranom slučaju vrednost usporenja direktno zavisna od prijanjanja između kočenih točkova i puta, kao i od koeficijenta otpora kotrljanju. Pošto je veličina koeficijenta otpora kotrljanju na dobrim putevima relativno mala (po pravilu ispod 0,02), to sledi da najveći uticaj ima koeficijent prijanjanja. U tom smislu, a uz prepostavku da je i koeficijent uticaja obrtnih masa mali, odnosno približno ravan jedinici ($\delta \approx 1$), maksimalno usporenje koje može da se ostvari pri kočenju na svim točkovima, tj. uz puno iskorišćenje raspoloživog prijanjanja ima vrednost:

$$a_{\max} = g\varphi \approx 10\varphi \quad (4.11)$$

Zaokruživanju gravitacionog ubrzanja na 10 ide u prilog i zanemarivanje otpora kotrljanju u procesu kočenja, što se inače obično radi. Imajući u vidu da su maksimalne vrednosti prijanjanja bliske jedinici, maksimalno usporenje može teorijski da dostigne vrednosti bliske ili bar uporedive sa ubrzanjem Zemljine teže [98,116]. Zbog ovoga, a i iz praktičnih razlika, ocena kočnih svojstava vozila se obično vezuje za relativni odnos usporenja i gravitacije, tj. za tzv. kočni koeficijent (vidi jednačinu 4.1). Kočni koeficijent predstavlja meru iskorišćenja raspoloživih mogućnosti usporenja. Na ovoj osnovi definisani su zahtevi u mnogim propisima koji se odnose na performanse kočnih sistema, kao na primer u propisima za tehničke preglede. Pojam kočnog koeficijenta se koristi i u Pravilniku ECE-13. Prema [98,101,104], kočni koeficijent može da se iskaže i kao:

$$q = \frac{F_k}{mg} = \frac{\sum F_{ki}}{\sum Z_i} \quad (4.13)$$

gde je:

$F_k = \sum F_{ki}$ - ukupna sila kočenja, jednak zbiru kočnih sila na svim kočenim točkovima,

$mg = \sum Z_i$ - sila od ukupne mase vozila, jednak zbiru svih normalnih reaktivnih sila na kočenim točkovima.

Poseban značaj ima definicija stepena iskorišćenja prijanjanja po osovinama vozila, koja se definiše kao odnos kočne sile na i-toj osovini (F_{ki}) i odgovarajuće normalne reakcije te osovine (Z_i) odnosno kao mera iskorišćenog prijanjanja na i-toj osovini:

$$\varphi_{si} = \frac{F_{ki}}{Z_i} \quad (4.14)$$

U dinamičkim uslovima, precizno izračunavanje trenutne vrednosti koeficijenta prijanjanja u kontaktu pneumatika i puta u podužnom pravcu znatno zavisi od trenutne vrednosti vertikalnog opterećenja koje deluje na dati kočeni točak [101,117]. Da bi se definisao izraz pomoću kojeg je moguće odrediti koeficijent prijanjanja u tom slučaju neophodno je odrediti dinamičke reakcije u kontaktu

pneumatika i tla, odnosno dinamičke vrednosti vertikalnog opterećenja točkova na prednjoj i zadnjoj osovini vozila. Prema [104,117], sila F_a koja nastaje usled delovanja poduzne komponente usporenja vozila a_x u njegovom težištu (slika 4.7) izaziva pojavu dinamičke preraspodele opterećenja vozila sa zadnje na prednju osovinu. Postavljanjem uslova ravnoteže momenata u odnosu na tačku kontakta točka zadnje osovine i puta dobija se trenutna vrednost vertikalnog opterećenja točka na prednjoj osovini (slika 4.7):

$$Z_{pd} = \frac{m(l_z \cdot g + h_c a_x)}{l} = \frac{mg(l_z + qh_c)}{l} \quad (4.15)$$

gde je sa m označena ukupna masa vozila, sa h_c visina težišta vozila, l_z rastojanje između težišta vozila i zadnje osovine i l predstavlja međuosovinsko rastojanje. Odgovarajuća vrednost vertikalnog opterećenja točka na zadnjoj osovini je jednaka:

$$Z_{zd} = G - Z_{pd} = mg - Z_{pd} \quad (4.16)$$

Pomoću definisanog stepena iskorišćenja prijanjanja može da se oceni i kočni koeficijent posmatrane osovine vozila, tj. udeo svake osovine u ostvarivanju ukupnog koeficijenta, saglasno izrazu:

$$q = \frac{\sum F_{ki}}{mg} = -\frac{\sum \varphi_{si} Z_i}{mg} \quad (4.17)$$

4.6. KARAKTERISTIKE I ZADACI ELEKTRONSKIH SISTEMA ZA UPRAVLJANJE PERFORMANSAMA KOČNOG SISTEMA

4.6.1. Uvod

Tokom poslednje dve decenije kočni sistemi privrednih vozila su doživeli značajna unapređenja na polju upravljanja njihovim performansama uvođenjem elektronski upravljenih sistema [118]. U oblasti razvoja kočnih sistema, projektant mora da uzme u obzir široki spektar namene vozila i ukupnih masa u opterećenom i neopterećenom stanju - od lakih do teških teretnih vozila sa prikolicama, poluprikolicama ili autobusa, kod kojih se koriste različita izvođenja kočnih sistema. Osim toga, različiti uslovi korišćenja moraju biti zadovoljeni. Na kraju, ali podjednako važno, postoje veoma različiti pristupi projektovanju podsistema za radno kočenje. Svedoci smo ere elektronski upravljenih sistema sa povratnom spregom koji su takođe dali značajan doprinos unapređenju kočnih sistema privrednih vozila. Kao izuzetno važna činjenica može se navesti da taj proces unapređenja kočnih sistema motornih i priključnih vozila neprekidno traje, uporedo sa daljim razvojem elektronike i elektronski upravljenih komponenata koji ulaze u njihov sastav [118].

Protivblokirajući sistem (ABS) je prvi sistem za elektronsko upravljanje performansama kočnih sistema i njegova serijska ugradnja na privrednim vozilima je počela još davne 1981. godine. Evropsko zakonodavstvo je prepoznalo značajna unapređenja na polju bezbednosti koje je omogućio ABS, čineći ga obaveznom opremom kod vozila određenih kategorija [104]. ABS sistemu je 1987. godine pridodat sistem protiv proklizavanja pogonskih točkova (ASR), koji je omogućio unapređenja na polju propulzije putem aktiviranja kočnica na pogonskim točkovima. Pojačan pritisak konkurenčije na tržištu je takođe uticao na povećanje zahteva koji se postavljaju pred kočne sisteme. Usledilo je predstavljanje elektronski upravljanog kočnog sistema (EBS) 1996. godine. Ovaj korak predstavlja značajno povećanje nivoa bezbednosti i primetno povećanje ekonomičnosti održavanja vozila. Pokušaji da se unapredi stabilnost privrednih vozila su ostvareni putem proširenja funkcija ABS-a i EBS-a. ECE pravilnici su

prihvaćeni širom Evrope i primenjuju se paralelno sa EU direktivama. Iz različitih razloga, datumi predstavljanja EC i ECE pravilnika su različiti, pa su onda i datumi početka obavezne primene ABS sistema različiti. Teška privredna vozila ukupne mase preko 16 t (kategorija N3, itd.) su u obavezi da imaju ugrađen ABS sistem počev od Oktobra 1991.

4.6.2. Protivblokirajući uređaj (PBU)

Uprkos velikom napretku i razvoju kočnica privrednih vozila, potencijalne incidentne situacije često nastaju kada se koči na klizavim površinama puta. Tokom paničnog ili čak normalnog režima kočenja na klizavom putu, može se dogoditi da više nije moguće preneti svu silu kočenja na površinu puta zbog niskog koeficijenta prijanjanja između pneumatika i kolovoza. Sila kočenja je u tom slučaju prekomerna i točkovi imaju tendenciju ili u kraјnjem slučaju prelaze u stanje potpunog blokiranja. Kada su točkovi blokirani, maksimalno se iskorišćava ukupna reaktivna sila u podužnom pravcu, pa je tada sila u bočnom (poprečnom) pravcu jednaka nuli. To veoma često ima opasne posledice kao što su nemogućnost upravljanja vozilom, zaokretanje vozila uprkos suprotnom korigovanju pravca kretanja vozila od strane vozača pomoću točka upravljača i/ili zanošenje [21,118].

Kako je pokazano u [121], točak koji se kreće po mokrom ledu ima veoma nisko prijanjanje pa prema tome može da prenese malu silu kočenja na led. Na suvom asfaltu situacija je znatno drugačija jer je mnogo veće prijanjanje dostupno i u skladu sa tim je moguće i optimalno kočenje ili ubrzavanje. Koeficijent trenja (μ) u kontaktu pneumatika i puta se ostvaruje usled relativnog pomeranja njihovih površina u dodiru, tj. razlike između brzina relativnog pomeranja površina u kontaktu, a to se naziva relativno klizanje (λ) i obično se izražava u procentima. U skladu sa tim, 0% klizanja podrazumeva da su brzine površina pneumatika i puta jednake, dok klizanje od 100% pri kočenju znači da je točak prestao da se kotrlja (rotira), odnosno da je ugaona brzina točka jednaka nuli, pri čemu je vozilo još uvek u pokretu. Ovakav slučaj maksimalne razlike između brzina površina u kontaktu se naziva potpuno blokiranje točka pri kočenju [120,121].

Prema naučnim istraživanjima mnogobrojnih autora objavljenim u [21,57,75, 117,120,122,123], najveću efikasnost procesa kočenja u smislu ostvarivanja optimalnog usporenja, uključujući procese koji se dešavaju u samoj kočnici i interakciju pneumatik-tlo, je moguće postići kada je podužno klizanje točkova u granicama između 10-30%. Ove granice treba uslovno shvatiti imajući u vidu različitost u veličini ukupnih masa pojedinih kategorija vozila i različite uslove prijanjanja u kontaktu pneumatika i tla. Aktiviranje kočnica sa prevelikim pritiskom može da izazove potpuno blokiranje točkova (klizanje od 100%), tako da sistem koji ovo sprečava može da poboljša efikasnost kočenja. Da bi se to realizovalo, razvijen je protivblokirajući uređaj, odnosno elektronski upravljan sistem za sprečavanje blokiranja kočenih točkova (engl. *Anti-Lock Braking System - ABS*) [120,121].

Međutim, prema [122], sprečavanje blokiranja točka radi poboljšanja efikasnosti procesa kočenja nije najvažniji razlog za uvođenje ABS sistema. Kada je točak blokiran, on onda ne omogućava nikakvo upravljanje vozilom u bočnom pravcu, i u slučaju da je više točkova vozila blokirano, ono će početi se zakreće oko vertikalne ose (zanošenje vozila u stranu). To znači da ako zadnji točkovi blokiraju vozilo će težiti da se zaokrene (zadnji kraj vozila teži da ide napred), a ako prednji točkovi blokiraju, vozilo više nije upravljivo. Zadržavanje vozila na željenoj putanji je najvažniji razlog za upotrebu ABS-a [120,122].

Pokazano je da je za loše uslove puta (pesak, led, sneg, voda, itd.), sistem koji sprečava blokiranje točka i koji je doprineo značajnom povećanju upravljivosti vozila u zamenu za mali gubitak ukupnog zaustavnog puta, obezbedio da se poboljšaju ukupne performanse vozila pri kočenju. Ovo je postignuto pomoću elektronske kontrolne jedinice (engl. ECU) koja dobija informacije o ugaonoj brzini svakog točka, a onda vrši korekciju, odnosno daje signal za smanjenje pritiska aktiviranja kočnica na točkovima koji pokazuju tendenciju da blokiraju [123].

Zbog kompromisa u pogledu klizanja u kontaktu pneumatika i tla u podužnom i bočnom pravcu, intervencija ABS-a može u nekim slučajevima dovesti do povećanja zaustavnog puta (to najviše zavisi od uslova u kontaktu pneumatika i tla, odnosno vrste i stanja podloge po kojoj vozilo koči), ali je značajno povećanje

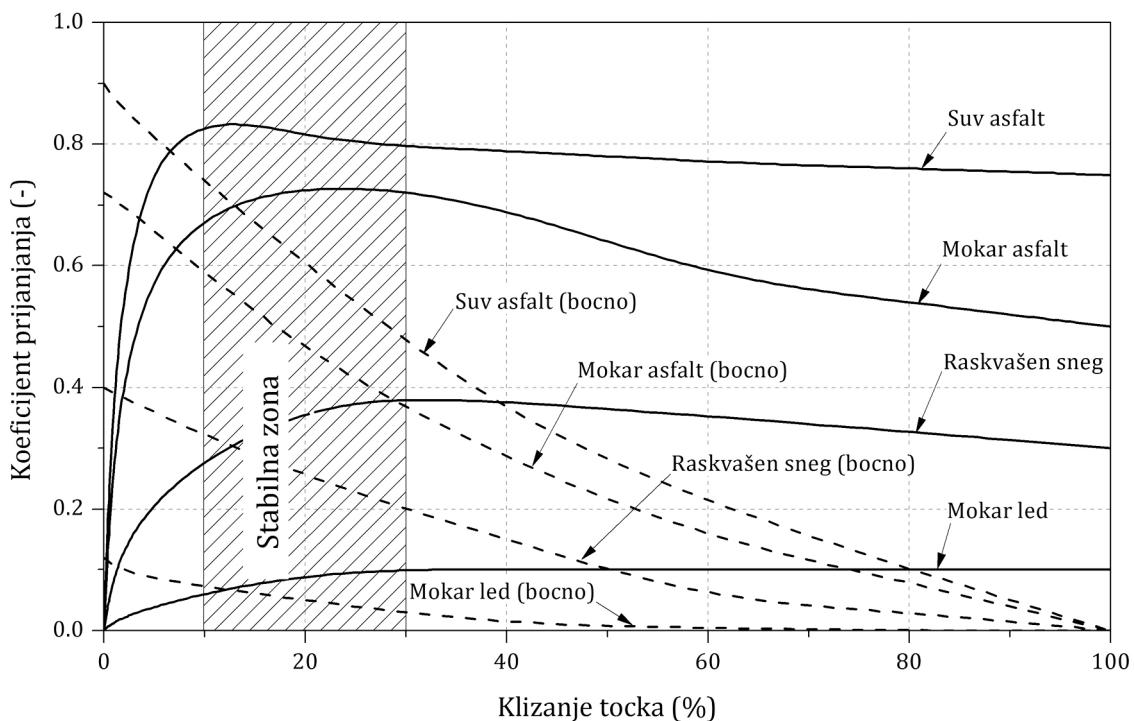
mogućnosti upravljanja vozilom, a posebno u situacijama naglog kočenja. Takav kompromis se smatra veoma korisnim za prosečnog vozača savremenih motornih vozila. Prema tome, osnovni cilj ABS-a je da se sačuva stabilnost vozila i omogućavanje vozaču da nastavi upravljanje vozilom tokom iznenadnog (naglog) kočenja, sa prihvatljivim kompromisom koji se odnosi na nešto duži zaustavni put vozila [120]. U isto vreme, frikcioni kontakt između pneumatika i puta treba da bude potpuno optimiziran, kako bi se smanjio put kočenja i vozilo usporavalo sa maksimalnim usporenjem [124].

Kočni koeficijent, odnosno koeficijent prijanjanja između točka i puta u podužnom pravcu određuje nivo sile kočenja koja može biti preneta. Zavisi od klizanja koje se ostvaruje u kontaktu pneumatika i puta i između ostalog od sledećih uticajnih faktora:

- ✓ stanja puta i pneumatika
- ✓ opterećenja točka ili osovine
- ✓ brzine vozila
- ✓ temperature
- ✓ ugla klizanja pneumatika ili ostvarene bočne sile.

Održavanje stabilnog prijanjanja u poprečnom pravcu je jako bitan zahtev za upravljanje vozilom. Koeficijent prijanjanja u poprečnom pravcu se smanjuje mnogo brže nego što je to slučaj sa kočnim koeficijentom. Da bi se ovo sprečilo, ABS sistem obično održava maksimum koeficijenta prijanjanja u zoni između 10% i 30% klizanja [124]. U skladu sa [121,124], mali procenat klizanja je potreban da bi se ostvarilo maksimalno raspoloživo prijanjanje između pneumatika i puta, ali ako klizanje postane prekomerno smatra se da točak ima tendenciju ka blokiranju tokom kočenja. Nivo raspoloživog prijanjanja zavisi od mnogo faktora, od kojih su najznačajniji stanje pneumatika i površine puta, kao i procenat klizanja u njihovom kontaktu. Slika 4.8 ilustruje nekoliko tipičnih primera zavisnosti raspoloživog prijanjanja od klizanja točka za različite podloge u podužnom pravcu, odnosno uslove puta u slučaju privrednih vozila. Većina ovih zavisnosti pokazuje da se koeficijent prijanjanja samo blago smanjuje u trenutku kada točak počinje da

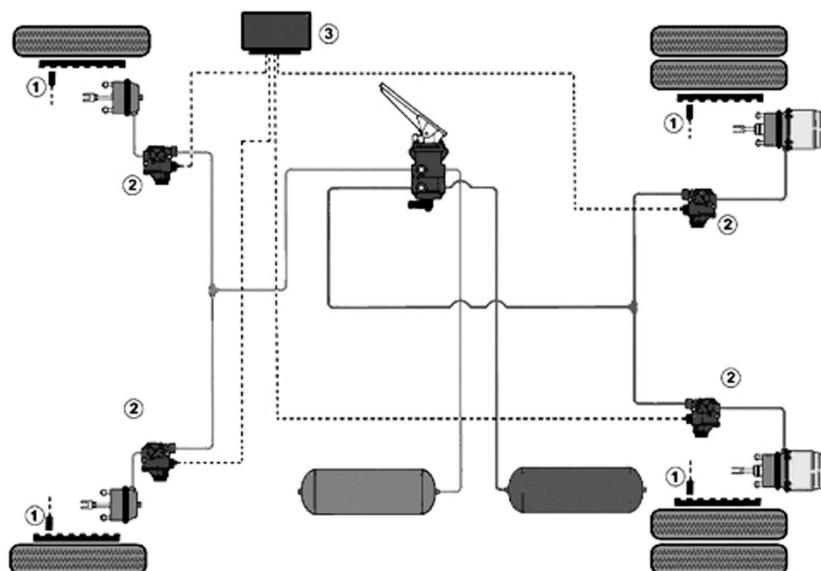
blokira i nadalje, kada je točak blokiran, nastaviće i dalje da prenosi visok procenat maksimalno dostupne sile kočenja. Međutim, u slučaju mokrog asfalta kada točak počinje da blokira, koeficijent prijanjanja značajno opada i točak će vrlo brzo doći u stanje potpune blokade. To se dešava jer je točak u stanju da prenese manju silu kočenja izazivajući povećano klizanje, što nadalje smanjuje nivo trenja i efikasnost procesa kočenja [121].



Slika 4.8. Krive klizanja privrednih vozila za različita stanja podlage

Kada točak započne da blokira onda on ne može više da prenese željeni moment kočenja, a osim toga nije ni u stanju da prenese bočne sile kojima se vrši upravljanje vozilom, odnosno kaže se da točak proklizava [123]. Slika 4.8 takođe pokazuje kako trenje koje je na raspolaganju u bočnom pravcu naglo opada kada točak počne da blokira usled kočenja. Nemogućnost točka na upravljačkoj osovini da prenese bočne sile pri kretanju u krivini znači da vozilo više neće biti pod potpunom kontrolom vozača, odnosno dolazi do gubitka upravljivosti vozila [121]. Zbog toga je važno da točkovi budu sprečeni da blokiraju tokom kočenja kako bi se ostvarila stabilnost upravljanja vozilom [121,122]. ABS sprečava blokiranje točkova pri kočenju vozila na različitim podlogama i obezbeđuje vozaču bezbedno upravljanje vozilom, bez odstupanja od željenog pravca kretanja. ABS predstavlja

elektronski sistem u okviru osnovnog kočnog sistema koji se koristi na privrednim vozilima ili autobusima i podrazumeva ugradnju Elektronske kontrolne jedinice (engl. ECU), modulatora pritiska, polarnih točkova, davača broja obrtaja točkova i prateće električne instalacije (slika 4.9).



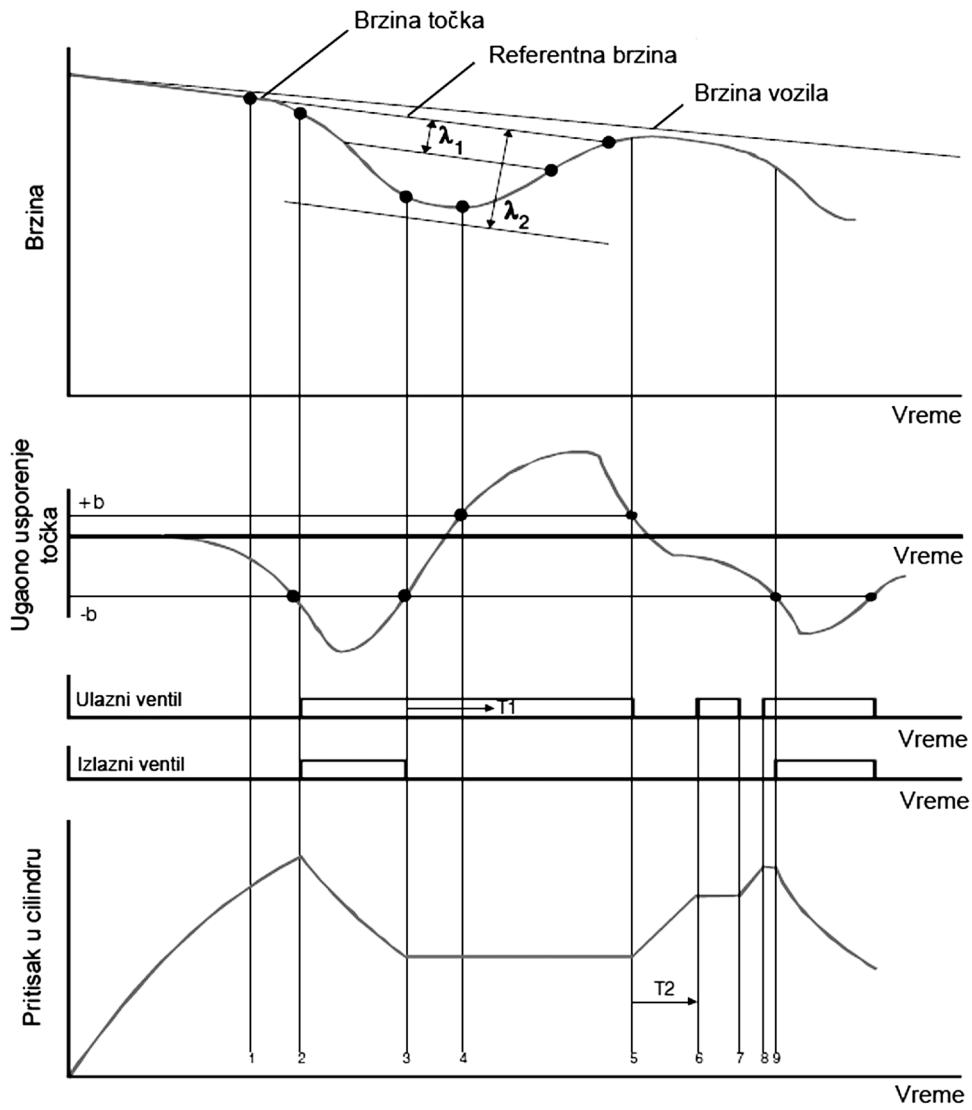
Slika 4.9. Šematski prikaz ABS sistema kod vozila konfiguracije 4x2 (4S/4M) [121]

ABS neprekidno prati broj obrtaja svih točkova i poredi ugaonu brzinu svakog od točkova sa prosečnom vrednošću ugaone brzine svih točkova (tzv. referentna ugaona brzina) koju izračunava Elektronska kontrolna jedinica – ECU (3), slika 4.9. Na taj način sistem može da identificuje kada jedan ili više točkova prekomerno usporavaju, odnosno pokazuju tendenciju ka blokiranju. Polarni točak i davač broja obrtaja točka (1) su instalirani na svakom točku i imaju zadatak da, kada se točak okreće, pošalju sinusni električni signal do elektronske kontrolne jedinice (ECU). Analizom frekvencije ovog signala ona može da prati broj obrtaja svakog točka i na osnovu toga da izračuna njegovo ubrzanje ili usporenje. Tokom procesa kočenja ECU u bilo kom vremenskom trenutku može da utvrdi da li ugaona brzina bilo kog točka odstupa od referentne brzine. Ukoliko je neki od točkova na klizavoj površini i ako tada nije u stanju da ostvari nivo traženih performansi u pogledu usporenja, tada će ugaona brzina tog točka pasti u odnosu na referentnu brzinu, tj. klizanje i usporenje tog točka će se naglo povećati. ECU će ovo normalno detektovati tokom kočenja i to pre nego što dođe do blokade točka. Onog trenutka kada ECU detektuje

odstupanje ugaone brzine točka od referentne, ona nadalje isključuje ugaonu brzinu tog točka pri izračunavanju referentne brzine. Kada ECU detektuje preveliko klizanje ili preterano naglu promenu usporenja točka (slika 4.10) ona šalje električni signal u odgovarajući modulator pritiska (2), slika 4.9, kako bi se pritisak u cilindru koji aktivira kočnicu na tom točku redukovao na odgovarajuću vrednost [121,125].

Prema [126], a u skladu sa slikom 4.10, u okviru tipičnog ciklusa upravljanja ABS sistema najvažnije kontrolne promenljive su prag ugaonog usporenja točka $-b$, prag ugaonog ubrzanja točka $+b$ i pragovi klizanja λ_1 i λ_2 . Kako pritisak u cilindru raste točak shodno tome proporcionalno usporava tokom vremena. U trenutku 1 ugaono usporene točke prekoračuje vrednost koja ne može fizički biti realizovana od strane vozila. Referentna brzina i brzina točka, koje su sve do ove tačke bile jednake, počinju da divergiraju sve dok u trenutku 2 točak ne dostigne veliko usporene (prekoračujući prag $-b$), koje u proseku iznosi oko 1,2g. Maksimalna vrednost je izvedena na osnovu referentnih brzina točkova upravljačke grupe i u opštem slučaju se ova vrednost koristi kao zajednička referentna brzina za dva točka. Klizanje točka se izračunava na osnovu trenutne brzine točka i odgovarajuće referentne brzine koja se elektronski izračunava na osnovu brzina svih točkova.

U tački 2 je prag ugaonog usporenja $-b$ prekoračen (slika 4.10). Točak tada prelazi u nestabilnu zonu u odnosu na krivu klizanja ($\mu-\lambda$ krivu), što znači da je točak dostigao maksimalnu vrednost raspoložive sile kočenja u kontaktu sa tlom pa svako dalje povećanje momenta kočenja povećava jedino vrednost usporenja točka. Zbog toga je pritisak u cilindru naglo smanjen što dovodi do smanjenja usporenja točka (slika 4.10). Vreme potrebno za usporenje točka je određeno histerezisom kočnice na datom točku i karakteristikom krive klizanja u oblasti nestabilne zone. Jedino kada histerezis kočnice bude neutralisan, kontinualno smanjenje pritiska dovodi do smanjenja usporenja točka [126].



Slika 4.10. Ilustracija rada ABS-a u skladu sa [126]

U trenutku 3 signal ugaonog usporenja točka $-b$ pada ispod praga i tada se pritisak u cilindru održava na konstantnom nivou u toku predefinisanog vremenskog intervala T_1 . Ugaono ubrzanje točka prekoračuje prag ubrzanja $+b$ tokom ovog perioda (tačka 4). Sve dok je ovaj prag prekoračen, pritisak se održava na istom (konstantnom) nivou. Ako $+b$ signal ne bude generisan tokom vremenskog intervala T_1 (na površinama sa niskim prijanjanjem na primer) pritisak u cilindru se dalje smanjuje na osnovu signala o klizanju λ_1 . Tokom ove faze upravljanja viši prag klizanja λ_2 nije dostignut. Posle pada ispod praga u trenutku 5 signal $+b$ opada. Točak je sada u stabilnoj zoni krive klizanja i ostvarena vrednost koeficijenta prijanjanja je negde u okolini maksimalne vrednosti koja je

raspoloživa za datu podlogu. Pritisak aktiviranja se tada naglo povećava u toku vremenskog intervala T2 da bi se neutralisao histerezis kočnice. Ovaj vremenski interval T2 je fiksног trajanja za prvi ciklus upravljanja, a tokom svake sledeće faze upravljanja izračunava se novo trajanje tog intervala. Nakon početnog naglog povećanja, pritisak u cilindru se dalje postepeno povećava preko cikličnog povećanja i zadržavanja pritiska koje obezbeđuju elektromagneti ventili (modulatori). Na kraju svakog stepenastog povećanja pritiska ECU će proveriti da li se ugaona brzina točka povećava u odnosu na brzine drugih točkova i ako je to ispunjeno ECU će signalizirati dalje stepenasto povećanje pritiska (slika 4.10). U trenutku kada ugaona brzina posmatranog točka postane bliska u odnosu na referentnu brzinu ECU će je ponovo uključiti kao ulaz za izračunavanje referentne brzine [91,93,121]. Ovakva postepena povećanja pritiska će se nastaviti sve dok pritisak u cilindru ne dostigne nivo koji vozač zahteva delovanjem na pedalu kočnice uz istovremeno zadovoljenje uslova da je klizanje točka na nivou koji garantuje odsustvo blokiranja. Ako u bilo kom trenutku ECU detektuje da se klizanje točka ponovo povećava i da postoji nagla promena usporenja ona će signalizirati modulatoru pritiska da ponovo redukuje pritisak putem ispuštanja vazduha u atmosferu. Ovaj ciklus redukovanja pritiska aktiviranja kočnice i ponovnog postepenog povećavanja (slika 4.10) će biti ponovljen nekoliko puta u sekundi da bi se ostvarila efikasnost kočenja, odnosno da bi se maksimalno iskoristilo raspoloživo prijanjanje uz istovremeno zadržavanje stabilnosti i upravljalivosti vozila [21,121,124,125,126].

Opisana logika upravljanja po kojoj funkcioniše ABS nije fiksna već adaptivna prema dinamičkom ponašanju točka u odnosu na različite vrednosti prijanjanja u kontaktu sa podlogom. Pragovi ubrzanja, usporenja ili klizanja točka manje više nisu konstantni i zavise od nekoliko parametara kao što je brzina vozila. Broj ciklusa upravljanja rezultira iz dinamičkog ponašanja čitavog lanca upravljanja u okviru ABS sistema (kočnice, točka i površine puta). Normalan broj ciklusa tokom kočenja se kreće od 3 do 5.

Prema [124,125], kada se vozilo kreće po podlozi sa različitim nivoima prijanjanja točkova na levoj i desnoj strani iste osovine onda postoji velika

verovatnoća da će kočeni točak koji se kotrlja po površini sa nižim nivoom prijanjanja pokazati tendenciju da blokira, a što kao posledicu implicira intervenciju ABS-a na tom točku. Ako se točak koji ne pokazuje tendenciju da blokira (na površini sa višim nivoom prijanjanja) aktivira sa pritiskom koji obezbeđuje normalno radno kočenje na tom točku, onda će se takva situacija, u odnosu na datu osovinu, svesti na kočenje gde se jedan od točkova koči u potpunosti, a drugi malo ili nimalo, zbog svoje tendencije ka blokiranju. Ova razlika u kočenju točkova iste osovine može izazvati proklizavanje i stvaranje tzv. "yaw" momenta koji teži da zaokrene vozilo oko vertikalne ose, a što je posebno opasno ako se radi o upravljačkoj osovinu jer u tom slučaju vozilo gubi upravljivost. Ne manje važan slučaj se odnosi na istovetnu situaciju na pogonskoj osoVINI, što može izazvati gubitak stabilnosti vozila.

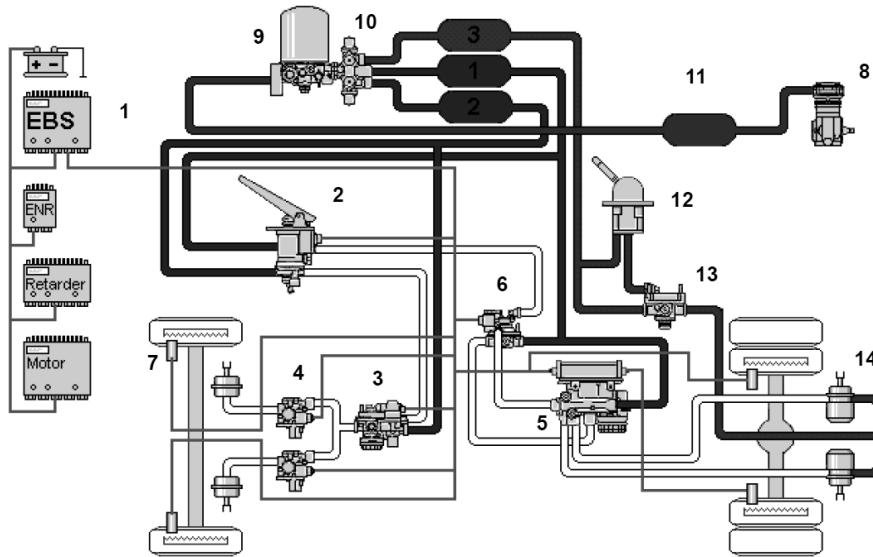
U cilju ublažavanja efekta momenta zakretanja vozila oko vertikalne ose na upravljačku osovinu vozila, ABS sistem koristi tzv. „modifikovanu individualnu regulaciju“ (engl. *Modified Individual Regulation - MIR*) na upravljačkoj osoVINI. Sa ovakvim načinom upravljanja, kada jedan točak pokazuje sklonost ka blokiranju i ABS interveniše da ograniči ili smanji pritisak u kočnom cilindru koji aktivira kočnicu na tom točku, to se takođe reflektuje i na drugi točak na isti način. Ovo ograničenje pritiska kontroliše ECU da bi neravnoteža u kočenju točkova na istoj osoVINI ostala u granicama koje omogućavaju vozaču da zadrži upravljivost vozila, odnosno da nije potrebno da vrši dodatne korekcije posredstvom točka upravljača. Pod ovim okolnostima teorijska maksimalna efikasnost kočenja koja bi mogla biti na raspolaganju nije postignuta na datoј osoVINI i zaustavni put će biti neznatno duži nego u slučaju da se kočnicama na toj osoVINI upravlja preko tzv. IR-a (individualna regulacija). Međutim, sposobnost vozača da zadrži upravljivost nad vozilom je poželjna u većini slučajeva da bi se ostvario što kraći zaustavni put [102,121,125]. Opisani procesi upravljanja se obavljaju od strane ABS-a sve dok postoje odgovarajući signali sa davača broja obrtaja o naglom smanjenju ugaone brzine točka, koji se obrađuju od strane ECU. ECU zahteva minimalan pik napona pre nego što prepozna takav signal sa davača broja obrtaja točka kao validan, a potom koristi frekvenciju signala da bi pratila ugaonu brzinu točka. Brzina pri kojoj

signal postaje validan zavisi od zazora između davača broja obrtaja i polarnog točka, ali je obično u rasponu od 5 do 8 km/h. Ovo je poznato kao „prag brzine“ i ispod ove brzine ECU postaje neaktivna i ABS nije u funkciji.

4.6.3. Elektronski upravljan kočni sistem (EBS)

Imajući u vidu da su današnji zahtevi koji se postavljaju pred kočne sisteme motornih i priključnih vozila sve veći, razvojem i uvođenjem elektronski upravljanog kočnog sistema (engl. *Electronically Controlled Braking System - EBS*) kočni sistemi privrednih vozila su značajno unapređeni [118]. Najvažnija karakteristika EBS-a je da povećava bezbednost vozila u saobraćaju putem bržeg odziva kočnog sistema zahvaljujući upravljanju njegovim komponentama pomoću elektronskih signala i poboljšanja stabilnosti vozila tokom kočenja [118,119]. Pored toga, prema [118,127], značajno je i smanjenje troškova održavanja, na primer optimizacijom istrošenja kočnih obloga. U pogledu bezbednosti, prema [118] najznačajnija su sledeća unapređenja EBS-a: manje vreme potrebno za dostizanje zahtevane vrednosti pritiska aktiviranja kočnica na prednjoj i zadnjoj osovini, poboljšana integrisana ABS funkcija, kao i to da se rad komponenata kočnog sistema na prednjoj/zadnjoj osovini i habanje kočnih obloga neprekidno nadgledaju.

Zbog toga što je u ovoj doktorskoj disertaciji istraživana mogućnost inteligenčnog upravljanja performansama kočnog sistema na primeru autobusa sa elektronski upravljanim kočnim sistemom, u daljem tekstu je data sumarna analiza osnovnih funkcionalnih karakteristika EBS-a. Na slici 4.11 je prikazana funkcionalna šema elektronski upravljanog kočnog sistema autobusa konfiguracije 4x2 u skladu sa [118].



Slika 4.11. EBS kod autobusa konfiguracije 4x2 (4S/4M sistem)

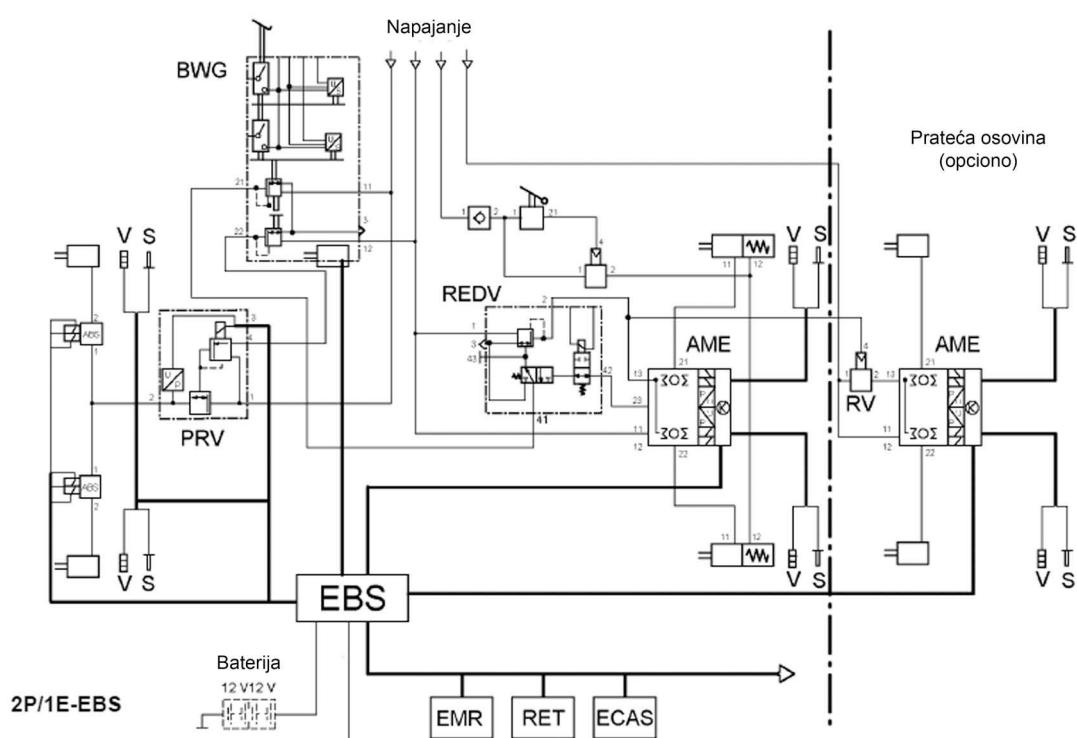
U tabeli 4.1 je dat spisak svih elektronski upravljenih komponenata bitnih za funkcijonisanje EBS-a koje su prikazane na slici 4.11, kao i ostalih komponenata konvencionalnog pneumatički aktiviranog kočnog sistema. Kao što je ilustrovano na slici 4.11, elektronski deo EBS sistema obuhvata elektronsku kontrolnu jedinicu (1), osovinski modulator sa integrisanim elektronskim jedinicama za zadnju osovinu (5), elektronski prenosnik signala (2) sa dva integrisana prekidača, proporcionalni rele ventil (3) i dva modulatora pritiska (ABS ventila) za prednju osovinu (4). Rele ventil 3/2 (6) se koristi u slučaju redundantnosti da brzo dovede ili ispusti vazduh iz kočnih cilindara zadnje osovine. U pogledu strukture, pneumatski deo EBS sistema sa dva kočna kruga u osnovi odgovara konvencijalnom kočnom sistemu sa pneumatičkim prenosnim mehanizmom. Ovaj deo EBS sistema ima redundantnu funkciju i postaje aktivan u slučaju otkaza elektro-pneumatičkog dela instalacije [118].

U skladu sa slikom 4.12, EBS sistem kod autobusa koji je ovde prikazan se sastoji od dva čisto pneumatička kočna kruga i posebnog elektronskog kočnog kruga. Ovakva konfiguracija EBS sistema se skraćeno naziva sistem 2P/1E i šematski je prikazana na slici 4.12. U skladu sa usvojenim oznakama na slici 4.11, elektro-pneumatički kočni krug obuhvata centralnu elektronsku kontrolnu jedinicu (tzv. centralni modul), označen sa EBS, osovinski modulator sa

integrисаном elektronиком за задњу осовину (AME), електронски читаč indeksa pritiska (BWG), као и proporcionalni rele ventil (PRV) i dva modulatora pritiska za prednju osovinu. Pored toga, on obuhvata i rele ventil (RV), davač broja obrtaja točka (S) i davač istrošenosti kočnih obloga (V).

Tabela 4.1. Komponente EBS-a

Pozicija	EBS komponente	Pozicija	Ostale komponente
1	Kontrolna jedinica EBS	8	Kompresor vazduha
2	Elektronska pedala kočnice	9	Isušivač vazduha
3	Proporcionalni rele ventil	10	Četvorokružni zaštitni ventil
4	Elektromagnetski ventil ABS (modulator)	11	Rezervoar vazduha
5	Osovinski modulator	12	Komandni ventil parkirne kočnice
6	3/2 rele ventil	13	Rele ventil
7	Davač broja obrtaja točka	14	Kočni cilindar



Slika 4.12. Primer izvođenja sistema 2P/1E

U pogledu strukture, pneumatički deo sa dva kočna kruga odgovara konvencionalnom kočnom sistemu sa pneumatičkim prenosnim mehanizmom. Ovaj čisto pneumatički deo kočnog sistema služi kao podrška u slučaju otkaza elektronskog kočnog kruga. Upravljanje kočnim sistemom privrednog vozila putem elektronskih signala EBS sistema omogućava komforno kočenje nezavisno od stanja opterećenosti vozila, kao i znatno skraćenje puta kočenja [119]. Ovi elektronski signali omogućavaju elektronskoj kontrolnoj jedinici EBS sistema da neprekidno komunicira sa sasvim ostalim elektronskim komponentama. To omogućava ventilima na kočnim cilindrima da generišu potreban pritisak aktiviranja kočnica u skladu sa odgovarajućim kontrolnim signalima.

Upravo ovakva infrastruktura postojećeg EBS sistema sa aktiviranjem komponenata u okviru elektronskog kočnog kruga pomoću elektronskih signala pruža mogućnost za intelijentno kočenje, odnosno za intelijentno upravljanje performansama kočnog sistema. To pre svega podrazumeva unapređenje upravljačkog softvera na osnovu intelijentnih rešenja baziranih na mogućnostima koje nude tehnike iz domena veštačke inteligencije, gde se posebno ističu veštačke neuronske mreže i fazi logika. Infrastruktura EBS-a dakle nudi mogućnost da se intelijentnim podešavanjem pritiska aktiviranja kočnica na prednjoj/zadnjoj osovini i njegovim pretvaranjem u odgovarajući napredni signal vrši intelijentno upravljanje performansama kočnog sistema, odnosno intelijentna raspodela sila kočenja na prednju i zadnju osovinu uz održavanje klizanja točkova na željenom/optimalnom nivou.

Nekoliko integrisanih funkcija u okviru EBS-a prepoznaju odstupanja od uobičajenih uslova pod kojima se izvodi kočenje i u skladu sa tim preduzimaju odgovarajuće akcije nezavisno od zahteva vozača. Prema [118,119], osnovne i najvažnije funkcije EBS sistema su:

1. Obezbeđenje kontrolisanog usporenenja vozila
2. Preraspodela sila kočenja između prednje i zadnje osovine
3. Kontrola istrošenja kočnih obloga
4. Sistem za pomoć vozaču pri kočenju (engl. Brake Assist – BAS)

5. Sistem za prevenciju prevrtanja vozila (engl. Anti Rolling Control – ARB)
6. Integrirana funkcija za sprečavanje blokiranja kočenih točkova (engl. Anti-lock Braking System – ABS)
7. Integrirana funkcija za sprečavanje proklizavanja pogonskih točkova (engl. Anti-Slip Regulation – ASR)

4.6.4. Elektronska kontrola stabilnosti (ESC/ESP) kod privrednih vozila

Vozači privrednih vozila su danas sve više podržani u vožnji pomoću aktivnih i pasivnih parametara bezbednosti [128]. Uvođenjem elektronskog sistema za upravljanje performansama kočnog sistema kao što je ESC (engl. *Electronic Stability Control*), koji se kod nekih proizvođača vozila naziva još i ESP (skraćeno od engl. *Electronic Stability Program*), funkcije EBS-a kao baznog sistema su proširene. ESC sistem ima slobodu automatskog intervenisanja u situacijama kada može doći do gubitka stabilnosti vozila, bilo da se radi o normalnoj vožnji ili o kočenju vozila. Ovaj sistem ima važan doprinos u povećanju bezbednosti privrednih vozila u sve većem intenzitetu saobraćaja. U granicama fizičkih mogućnosti, koje su diktirane pre svega trenutno važećim uslovima u kontaktu pneumatika i puta, ESC radi automatski i upravlja istovremeno pogonskim mostom i kočnicama kako bi pomogao vozaču da vrši bezbednije upravljanje i/ili kočenje vozila [129].

Prema [128], prvi koraci u razvoju sistema elektronske kontrole stabilnosti su napravljeni pre više od deset godina. U početnoj fazi, istraživanja su vršena na složenom modelu vozila, pomoću kompjuterskih simulacija. Model vozila je potom proširen na stvarni model i počele su faze ispitivanja na poligonu, praćene daljim razvojem sistema i sukcesivnim testiranjima. Kompleksnost zahteva koji se postavlja pred ovaj sistem dolazi do izražaja kod teških privrednih vozila sa širokim rasponom mogućih stanja opterećenosti i različitim izvođenjima pojedinih konstrukcionih rešenja, kao i visokim varijacijama položaja težišta. Kao dodatni problem se nameće potreba da se kočnim sistemom prikolice ili poluprikolice upravlja preko njima odgovarajućeg interfejsa.

Implementacija ESC sistema zahteva složeno inženjersko projektovanje sistema u kombinaciji sa odgovarajućim hardverskim komponentama koje podrazumevaju elektronske komponente visokih performansi i odgovarajuće davače. Elektronska kontrolna jedinica (ECU) je povezana sa kontrolnim jedinicama ostalih sistema kao što su pogonski agregat, menjački prenosnik ili retarder preko CAN magistrale. To između ostalog omogućava programu za upravljanje elektronskim kočnim sistemom integrисаном u elektronsku kontrolnu jedinicu da koordiniše rad sistema za radno kočenje i motorne kočnice [118,128,129].

Elektronska kontrolna jedinica ESC sistema komunicira sa elektronskom kontrolnom jedinicom EBS sistema posredstvom CAN magistrale visokih performansi. ESC kontrolna jedinica radi sa mikroprocesorima visokih performansi, davačem zakretanja vozila oko vertikalne ose i davačem ubrzanja/usporenja. U tu svrhu, svi ulazi sa odgovarajućih davača na vozilu se dovode do nje. ECS kontrolna jedinica tada upoređuje aktuelne uslove (parametre) kretanja vozila sa onima koji su teorijski uspostavljeni i interveniše ako je detektovano približenje parametara kritičnim vrednostima ili ako očitavanja davača prelaze preko maksimalne teorijske (reperne) vrednosti.

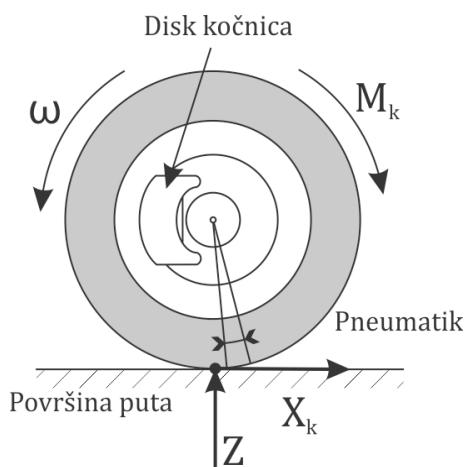
Davači na kojima se bazira rad ESC sistema obuhvataju:

- ✓ davače broja obrtaja točkova (koje koristi i ABS)
- ✓ davač ugla zakretanja točka upravljača
- ✓ davač bočnog ubrzanja koji ukazuje na skretanje vozila
- ✓ davač ugla zakretanja vozila oko vertikalne ose

Značaj ovog sistema dolazi do izražaja kada se vozilo kreće po podlozi sa različitim nivoom prijanjanja točkova i kada je ponašanje vozila uzrokovanu neadekvatnim reakcijama vozača u pogledu upravljanja vozilom. U takvим situacijama kada je stabilnost vozila narušena, ESC koristi EBS za upravljanje silama kočenja na svakom točku iz istovremeno regulisanje obrtnog momenta motora [128].

4.7. INTELIGENTNO UPRAVLJANJE PERFORMANSAMA KOČNOG SISTEMA

U opštem slučaju, izlazne performanse kočnog sistema zavise od performansi kočnica kao izvršnih elemenata i od trenutnih uslova koji vladaju u kontaktu pneumatika sa površinom puta, odnosno od mogućnosti prenošenja generisane sile kočenja na podlogu (slika 4.13). Složenost čitavog procesa, kao i veliki broj faktora na čiji uticaj treba обратити pažnju, doveli su do potrebe da se u ovoj disertaciji interakcija u kontaktu friкционog para kočnice i interakcija u kontaktu pneumatik-tlo razmatraju pojedinačno. U poglavlju 4.4 je već objašnjeno na koji način promena uslova u kontaktu frikcionih površina disk kočnice, izazvana promenom njenih radnih režima, utiče na njene izlazne performanse, odnosno na nivo i stabilnost tako generisanog momenta kočenja. Detaljna analiza fenomena u kontaktu pneumatik-tlo je data u poglavlju 5, gde je istraživan uticaj ostvarenog prijanjanja i klizanja točka u kontaktu sa podlogom na kočne performanse. Vrsta, stanje i nagib podloge po kojoj se vozilo kreće tokom kočenja ima takođe veliki uticaj na veličinu i stabilnost koeficijenta prijanjanja koji može biti ostvaren, odnosno na nivo klizanja u podužnom i bočnom pravcu. Prema slici 4.13, bitnu ulogu u vezi sa tim imaju i karakteristike pneumatika, u pogledu njegove konstrukcije, deformabilnosti, krutosti i elastičnosti materijala od koga je napravljen.



Slika 4.13. Faktori koji utiču na prenos momenta kočenja na podlogu

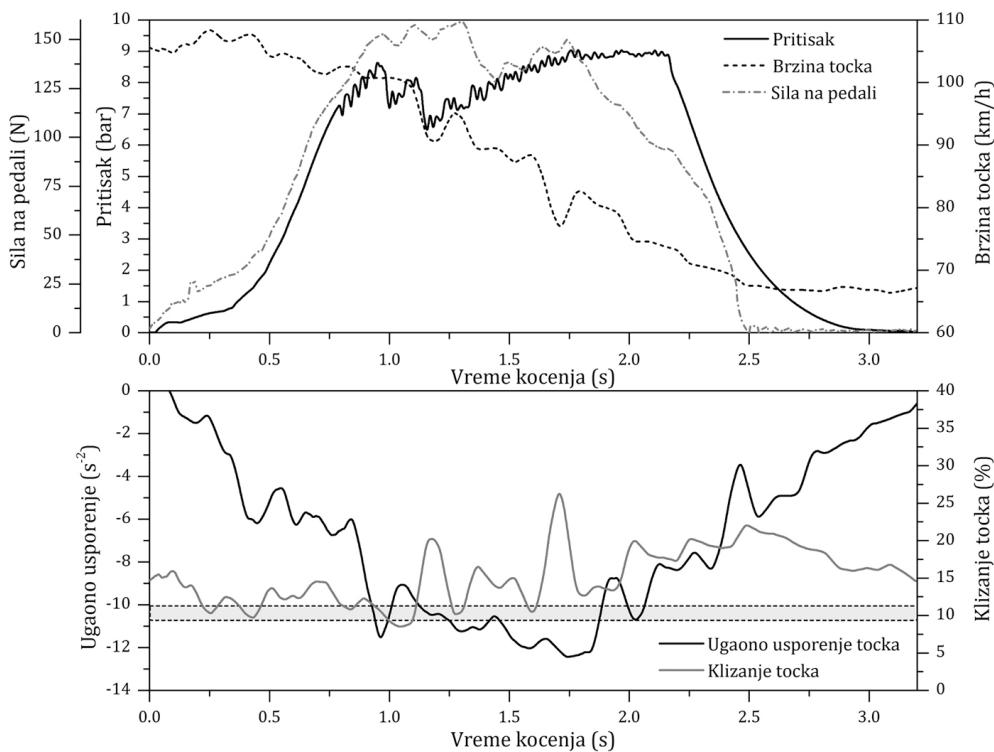
Imajući sve ovo u vidu, evidentno je da je upravljanje performansama kočnog sistema veoma složen i zahtevan proces, koji zahteva sagledavanje ne samo

karakteristika kočnog sistema i želja vozača, već i mogućnosti realizacije sile kočenja u kontaktu sa podlogom u cilju zadovoljenja zahteva u pogledu aktivne bezbednosti vozila tokom kočenja. To nameće potrebu za razvojem dinamičkog modela koji bi bio u stanju da obuhvati sve ove uticaje na performanse kočnog sistema. Na osnovu analize dosadašnjih koraka u ovom pravcu datog u poglavlju 2, može se uočiti da se nijedno istraživanje u ovoj oblasti ne odnosi na razvoj modela procesa kočenja koji objedinjuje uticaje i performansi kočnice i karakteristika pneumatika i interakcije pneumatik-tlo na performanse kočnog sistema. Nestabilnosti klizanja točka u kontaktu pneumatik-tlo, kao i njegove varijacije u toku ciklusa kočenja mogu imati veliki uticaj na proces kočenja, potencijalno izazivajući duži zaustavni put, kao i teškoće u održavanju stabilnosti i upravljivosti vozila. Imajući u vidu da i efikasnost analiziranih elektronskih sistema (ABS/EBS/ESC) zavisi od navedenih faktora, jasno je da se time može posredno unaprediti i njihova funkcija, posebno u pogledu boljeg upravljanja klizanjem točka u kontaktu sa podlogom tokom ciklusa kočenja. Tu se pre svega misli na to da bi integrisane upravljačke funkcije EBS-a, a naročito ABS funkcija, mogle biti bolje realizovane u smislu prepoznavanja trenutne vrednosti optimalnog klizanja točka i njegovog dovođenja na taj nivo putem upravljanja performansama kočnice na inteligentniji način. Upravljačke funkcije EBS sistema bi tako mogle biti unapredjene preventivnim delovanjem u smislu sprečavanja pojave visokih fluktuacija podužnog klizanja točka tokom kočenja i omogućavanjem njegovog neprekidnog dovođenja na željeni/optimalni nivo.

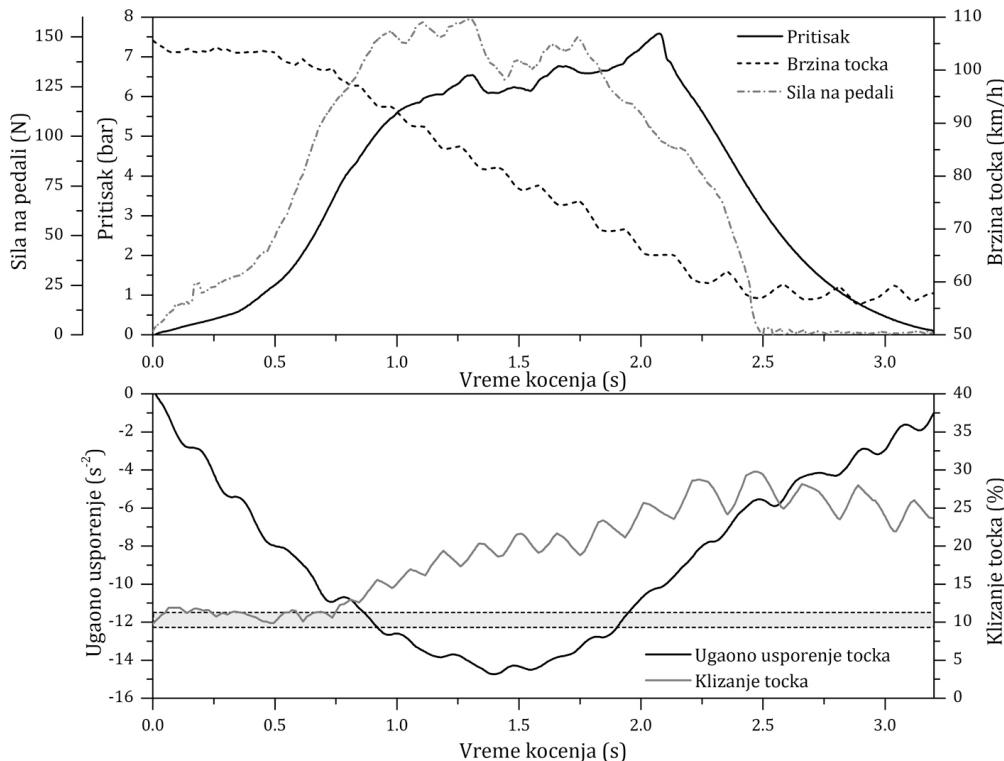
S obzirom na sve ovo, ovde su najpre identifikovane mogućnosti za unapređenje rada savremenih elektronskih sistema za upravljanje performansama kočnog sistema kako bi se jasno i precizno definisao prostor u kome je moguće uticati na poboljšanje njihove funkcije. U cilju ilustracije, izabrani su karakteristični ciklusi kočenja. Ovi ciklusi kočenja, prikazani na slikama 4.14-4.19, su realizovani na pravcu, na suvom i ravnom asfaltnom putu, i to u neopterećenom i opterećenom stanju vozila. Analiziran je takođe i karakter promene izmerenih funkcionalnih parametara EBS-a tokom ciklusa kočenja na prednjoj i zadnjoj osovini kako bi se analizirale i mogućnosti za uvođenje inteligentne raspodele sila kočenja između

prednje i zadnje osovine. Eksperimentalna istraživanja u vezi sa određivanjem funkcionalnih karakteristika EBS sistema, sprovedena u ovoj disertaciji, pokazuju da klizanje točka nije u optimalnim granicama tokom čitavog ciklusa kočenja, odnosno nije na nivou gde je dostupno maksimalno prijanjanje u podužnom pravcu. Vrednost maksimuma krive klizanja, odnosno vrednost klizanja točka pri kojoj se postiže maksimalni koeficijent prijanjanja između pneumatika i puta se dinamički menja u zavisnosti od velikog broja faktora i samim tim je različita za svaki ciklus kočenja. Najuticajniji faktori dinamičke promene uslova u kontaktu pneumatika i tla su dinamička promena vertikalnog opterećenja točka, dinamička promena sile kočenja, promena vrste/stanja/kvaliteta hraptavosti puta, itd. Detaljna analiza o načinu određivanja trenutnog maksimuma koeficijenta prijanjanja za date uslove kočenja, kao i vrednosti podužnog klizanja pri kome je on dostupan, data je u poglavlju 5.

Posmatrajmo najpre ciklus kočenja prikazan na slikama 4.14 (prednja osovina) i 4.15 (zadnja osovina) realizovan tokom ispitivanja vozila u neopterećenom stanju, pri čemu je došlo do intervencije ABS-a na prednjoj osovini počev od 0,75 s pa do 2,25 s vremena kočenja. Klizanje točkova na prednjoj osovini od 0,75 s vremena kočenja pa do kraja ciklusa ima relativno visoko odstupanje od zone između 9,5-11,5% podužnog klizanja, koja je identifikovana kao ona gde koeficijent prijanjanja dostiže maksimalnu vrednost za date uslove prijanjanja. Postupak dinamičkog određivanja opsega klizanja, pri kome je moguće ostvariti maksimalni koeficijent prijanjanja u kontaktu pneumatika i puta, biće detaljno objašnjen u poglavlju 5. Ako posmatramo samo deo ciklusa tokom koga je intervenisao ABS (slika 4.14) može se videti da u pojedinim zonama tokom ciklusa (1,2 i 1,7 s) klizanje ima vrednosti bliske onoj koja odgovara maksimalnom prijanjanju u kontaktu pneumatika i tla. Očigledno je da je ABS uspeo da korekcijom pritiska aktiviranja kočnice ublaži trend povećanja klizanja, ali njegova trenutna podešenost na datom vozilu za posledicu ima to da je klizanje održavano na nivou za oko 10% višem od onog gde je dostupno maksimalno prijanjanje (slika 4.14).



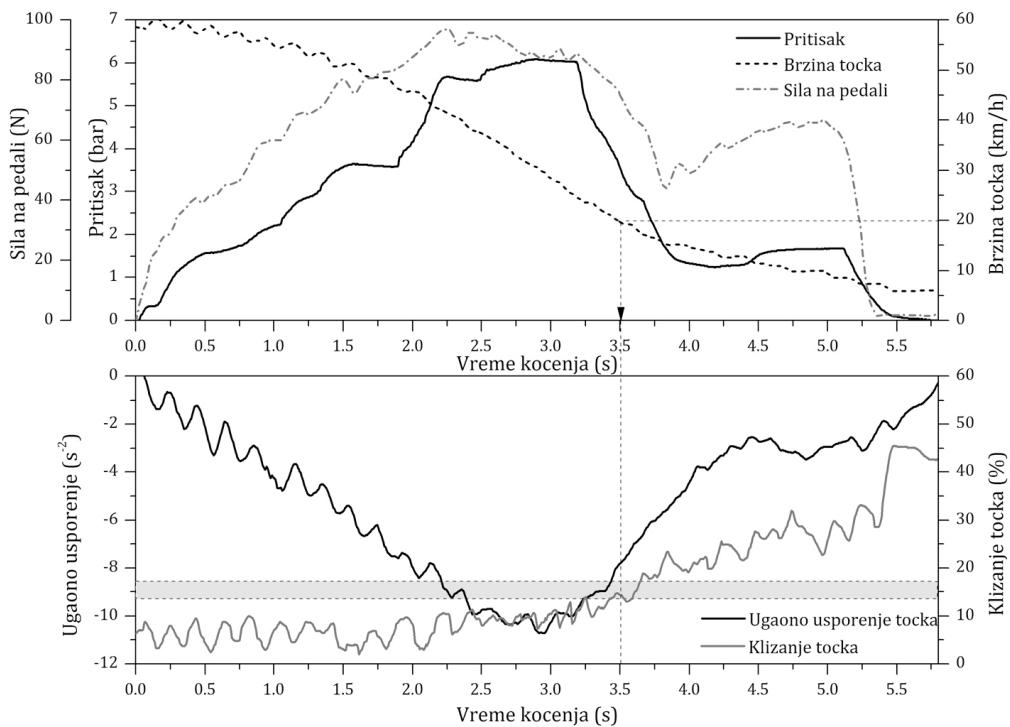
Slika 4.14. Promena funkcionalnih parametara na prednjoj osovini
(neopterećeno stanje vozila)



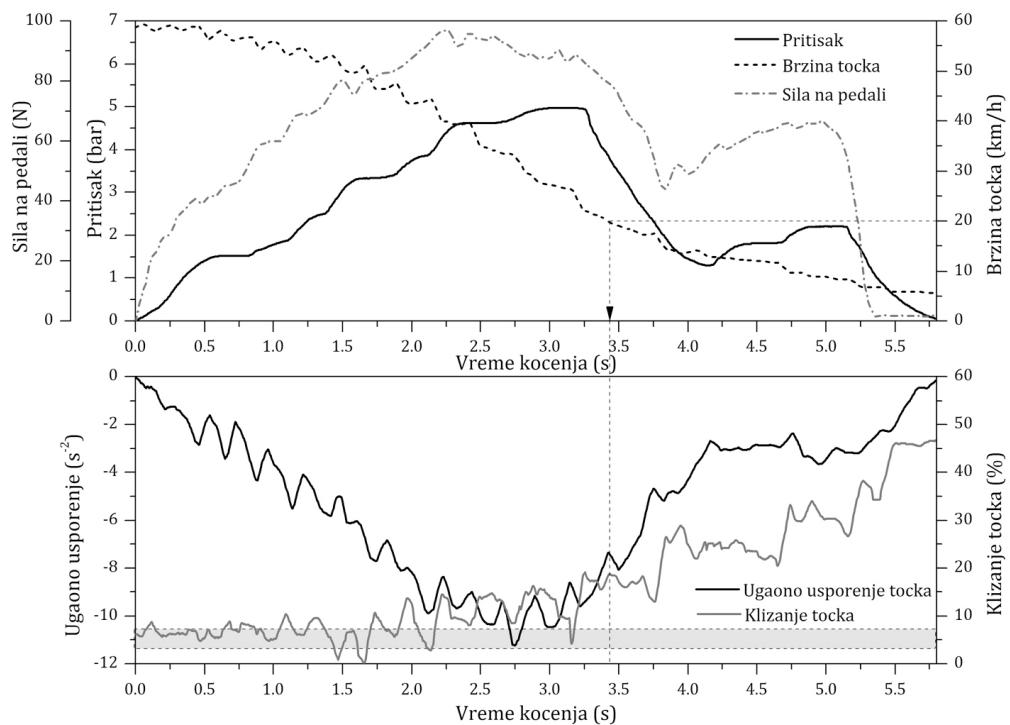
Slika 4.15. Promena funkcionalnih parametara na zadnjoj osovini
(neopterećeno stanje vozila)

U slučaju točka na zadnjoj osovini situacija je veoma slična, uz razliku što se ABS nije aktivirao. Počev od 0,75 s vremena kočenja, klizanje u podužnom pravcu ima trend neprekidnog povećanja do 30% na kraju ciklusa kočenja. Imajući u vidu da je u tom slučaju identifikovana zona klizanja gde je dostupno maksimalno prijanjanje između 9-11%, razlika između tog nivoa i nivoa klizanja koje je stvarno izračunato na kraju ciklusa kočenja dostiže vrednost od oko 20%.

Slike 4.16 i 4.17 pokazuju ciklus kočenja dobijen ispitivanjem autobusa u opterećenom stanju, pri čemu su kočnice aktivirane sa relativno visokim pritiskom. Nivoi klizanja na prednjoj i zadnjoj osovini koji odgovaraju maksimalnom prijanjanju se u ovom slučaju znatno razlikuju. U slučaju klizanja točka na prednjoj osovini ta zona se kreće između 13-17%, dok kod klizanja točka na zadnjoj osovini ona ima raspon 3,5-6%. Zbog smanjenja brzine vozila ispod 20 km/h ABS nije intervenisao da zaustavi naglo povećanje klizanja točka ispod te brzine. U skladu sa podešavanjima upravljačkog programa EBS sistema pri ovim brzinama vozila blokiranje kočenih točkova je dozvoljeno [118]. I pored toga, tokom preostalog dela ciklusa kočenja pritisak aktiviranja kočnice bi trebalo da bude dinamički prilagođen tako da se klizanje točka održava na nivou koji obezbeđuje postizanje maksimalnog prijanjanja u kontaktu pneumatik-tlo u podužnom pravcu. Sa slike 4.16 se može uočiti da bi funkcija EBS-a mogla da se unapredi ako bi se u delu ciklusa između 0-3,5 s omogućilo dinamičko podešavanje pritiska tako da se neprekidno vrši usklađivanje klizanja točka sa zonom koja odgovara maksimalnom prijanjanju. Time bi se stvorili uslovi za povećanje efikasnosti procesa kočenja, odnosno smanjenje zaustavnog puta vozila. To isto važi i za klizanje točka na zadnjoj osovini (slika 4.17), gde bi se smanjenjem nivoa klizanja za oko 13% mogle postići bolje performanse kočnog sistema.

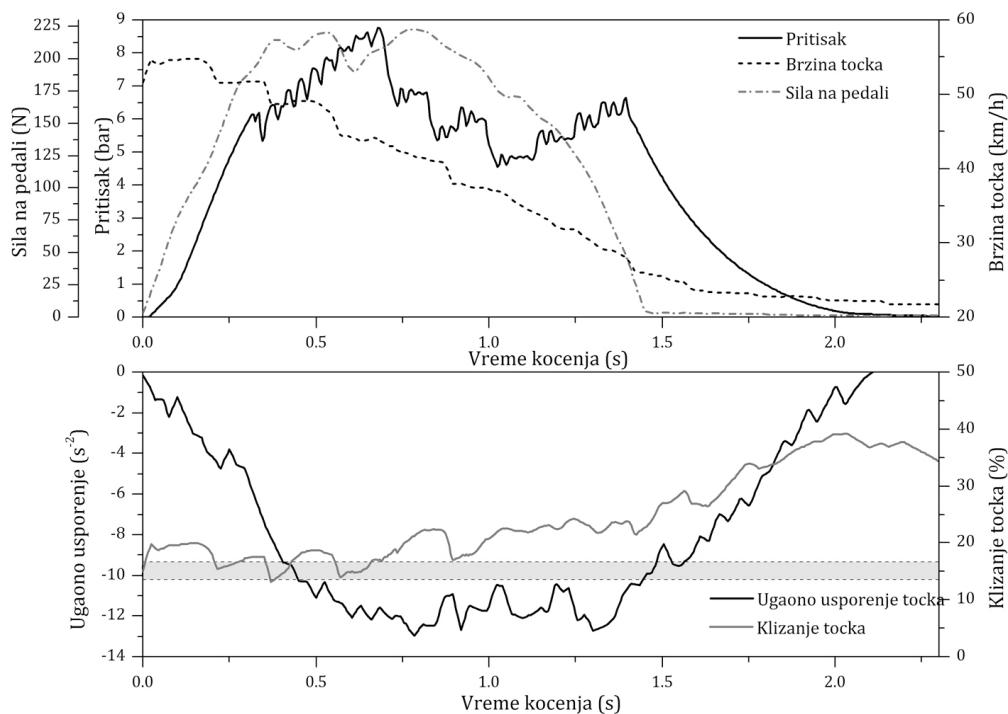


*Slika 4.16. Promena funkcionalnih parametara na prednjoj osovini
(opterećeno stanje vozila)*

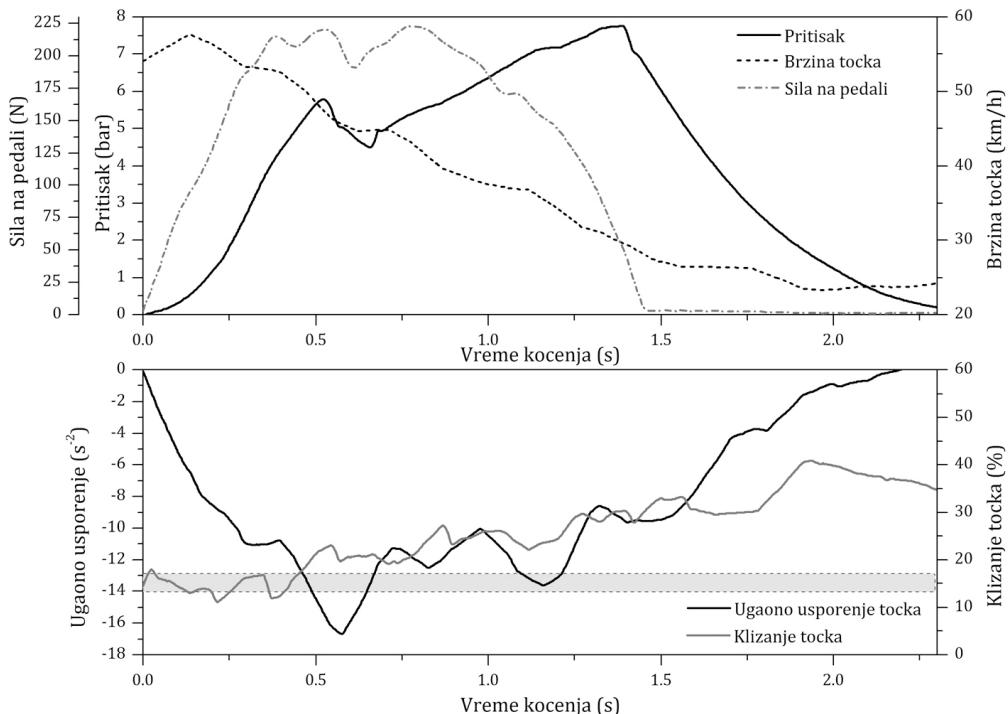


*Slika 4.17. Promena funkcionalnih parametara na zadnjoj osovini
(opterećeno stanje vozila)*

Na slikama 4.18 i 4.19 je dat primer ciklusa koji je realizovan u opterećenom stanju vozila, pri čemu je došlo do aktiviranja ABS-a i na prednjoj i na zadnjoj osovini. Zona klizanja gde je dostupan maksimalni koeficijent prijanjanja je u ovom slučaju bilo na približno istom nivou između 14-16% i za prednju i za zadnju osovinu. Od druge intervencije po redu u trenutku 0,7s, ABS je na prednjoj osovini održavao klizanje na nivou 10% većem od pomenute zone (slika 4.18). To znači da kočenje nije obavljeno sa iskorišćenjem maksimalno raspoloživog prijanjanja u podužnom pravcu između točkova prednje/zadnje osovine i puta tokom skoro celog ciklusa kočenja. To još jednom potvrđuje da sav raspoloživi potencijal za postizanje maksimalnog usporenenja vozila nije iskorišćen u ovoj situaciji.



*Slika 4.18. Promena funkcionalnih parametara na prednjoj osovini
(opterećeno stanje vozila)*



Slika 4.19. Promena funkcionalnih parametara na zadnjoj osovini (opterećeno stanje vozila)

Ovakva kompleksnost upravljanja performansama kočnog sistema uvedena sa ABS-om, koja se bazira na konvencionalnim tehnikama upravljanja sa povratnom spregom, stvara potrebu za razvojem novih rešenja koja bi bila korisna za unapređenje upravljanja radom kočnih sistema privrednih vozila, naročito u smislu boljeg upravljanja klizanjem točkova i performansama kočnog sistema u odnosu na zahteve vozača. Pošto ABS prvenstveno radi korektivno, trebalo bi obezbediti uvođenje prediktivnih, odnosno inteligentnih metoda za upravljanje performansama kočnih sistema privrednih vozila. Kočnice bi u tom slučaju trebalo inteligentno aktivirati u smislu uspostavljanja maksimalne efikasnosti procesa kočenja uz istovremeno održavanje stabilnosti vozila, bez obzira na uslove puta, stanje opterećenosti vozila i radnih režima kočenja. Pri tome je važno naglasiti da se upravljanje klizanjem na taj način može vršiti odvojeno u podužnom i bočnom pravcu, što dalje otvara mogućnosti da se izvrši optimizacija između podužnog i bočnog klizanja točka tokom kočenja.



INTERAKCIJA PNEUMATIKA I PUTA

5.1. UVOD

Kretanje, upravljanje i/ili zaustavljanje vozila realizuje se isključivo zahvaljujući trenju koje se javlja u kontaktu pneumatika i puta. Samim tim poznavanje karakteristika ovog procesa ima najveću važnost sa aspekta bezbednosti saobraćaja, ekonomičnosti, itd. [128]. Sa stanovišta procesa kočenja, stanje u kontaktu pneumatika i tla je od ključne važnosti da bi se sila kočenja, odnosno generisani moment kočenja mogao preneti na površinu puta (slika 4.13). Osim toga, funkcija novih elektronskih sistema za upravljanje performansama kočnog sistema u cilju povećanja bezbednosti vozila, kao što su sistem za sprečavanje blokiranja kočenih točkova (ABS), sistem za kontrolu proklizavanja pogonskih točkova (ASR), sistem za elektronsku raspodelu sile kočenja (EBD), sistem za pomoć vozaču pri kočenju (BAS) i veliki broj integrisanih funkcija u okviru EBS sistema, upravo najviše zavise od poznavanja karakteristika prijanjanja i klizanja u kontaktu pneumatik-tlo. U svim navedenim slučajevima, prenos sile kočenja sa točka na put se realizuje posredstvom frikcije (trenja). Kada klizanje u kontaktu pneumatika i puta nije u optimalnim granicama nije moguće u potpunosti realizovati prenos generisanog momenta kočenja na podlogu, što dalje može da uzrokuje gubitak upravljivosti i/ili stabilnosti vozila tokom kočenja. Maksimalna efikasnost procesa kočenja se postiže kada je klizanje u kontaktu pneumatika i puta na nivou koji odgovara maksimalnoj vrednosti koeficijenta prijanjanja, odnosno položaju maksimuma krive klizanja (poduzno klizanje). Očigledno je da zbog toga poznavanje karakteristika trenja između pneumatika i puta treba da ima važnu ulogu i prilikom razvoja i projektovanja budućih inteligentnih kočnih sistema. Inteligentno upravljanje performansama kočnog sistema predstavlja izazov, ali i težak zadatak imajući u vidu izrazito nelinearnu dinamiku procesa kočenja, praćenu stohastičkim i dinamičkim varijacijama uticajnih parametara poput

vertikalnog opterećenja točka, koeficijenta prijanjanja točka u kontaktu sa podlogom, kao i vrste, nagiba i stanja površine puta. Međutim, pošto taj izuzetno složeni proces za sada ne može da se opiše analitičkim putem, modeliranje trenja između pneumatika i puta poslednjih godina postalo je oblast intenzivnih istraživanja objavljenih u [17-57,130,132]. U tom pogledu veoma je važno što tačnije odrediti, ali i predvideti zavisnost između koeficijenta prijanjanja i klizanja u kontaktu pneumatik-tlo, naročito u realnim, dinamički promenljivim, radnim uslovima u kojima vozilo, a time i kočni sistem, vrši svoju funkciju.

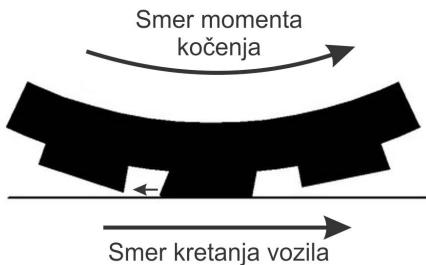
Zbog toga su u ovom poglavlju detaljno analizirani načini određivanja zavisnosti koeficijenta prijanjanja pneumatika u kontaktu sa podlogom od klizanja u podužnom pravcu (za slučaj kočenja), polazeći od kraćeg pregleda osnovnih karakteristika samih pneumatika koje mogu uticati na karakter promene uslova u njegovom kontaktu sa površinom puta. U pogledu karakteristika pneumatika, fokus istraživanja je bio usmeren na konstrukcione osobine i osobine elastičnosti pneumatika u cilju analize kako one mogu da utiču na interakciju pneumatik-tlo. Sa osvrtom na tzv. statičke modele kontakta pneumatik-tlo, analizirane su i mogućnosti određivanja tzv. dinamičkih krivih klizanja, odnosno određivanja zavisnosti koeficijenta prijanjanja od klizanja u podužnom pravcu u dinamičkim uslovima, tj. u realnom vremenu. Na osnovu toga kolika je trenutna vrednost koeficijenta prijanjanja i pri kojoj trenutnoj vrednosti klizanja točka se ona ostvaruje, analizirani su načini kako je moguće inteligentno upravljati pritiskom aktiviranja kočnice na datom točku, kako bi se klizanje točka u podužnom pravcu dovelo na optimalnu vrednost koja odgovara maksimalnoj vrednosti koeficijenta prijanjanja u kontaktu pneumatik-tlo.

5.2. UTICAJ KARAKTERISTIKA PNEUMATIKA NA INTERAKCIJU PNEUMATIKA I PUTA

U skladu sa analizom osnovnih karakteristika pneumatika prikazanom u [130,131], u pogledu ostvarivanja sila neophodnih za kretanje vozila pneumatik predstavlja najvažniju komponentu jer se posredstvom njega vrši interakcija vozila sa površinom puta. Dublje razumevanje dinamičkog ponašanja pneumatika predstavlja osnovni aspekt analize dinamike kretanja vozila. Sile i momenti koji se generišu u materijalu pneumatika su rezultat njegove interakcije sa podlogom. U određenoj meri, pneumatik se takođe može predstaviti i kao filter uskog prolaza u sistemu za oslanjanje, smanjujući vibracije visokih frekvencija od malih neravnina na putu [130]. Vibracije pneumatika se povećavaju sa većim brojem neravnina na putu, usled nelinearne dinamike kretanja vozila i različitih neravnomernosti u pogledu strukture i oblika pneumatika (npr. nejednaka istrošenost protektora pneumatika). Složena struktura pneumatika može u nekoj meri prigušiti izazvane oscilacije u određenim frekvencijskim opsezima, ali isto tako može doprineti njihovom pojačanju u drugim frekvencijskim opsezima [127,131].

U skladu sa slikom 4.13, ovde je pažnja posvećena identifikovanju osobina pneumatika čiji se uticaj na izlazne performanse kočnog sistema mora obuhvatiti putem inteligentnog podešavanja pritiska aktiviranja kočnice, kako bi se u kontaktu pneumatik-tlo postiglo željeno klizanje u podužnom pravcu, odnosno usporenje zahtevano od strane vozača. Istraživano je kakav uticaj imaju karakteristike pneumatika, pre svega elastičnost i konstrukcione osobine, na izlazne performanse kočnog sistema. Sa aspekta uvođenja inteligentnog upravljanja performansama kočnog sistema navedeni uticaji moraju biti uzeti u obzir, pogotovo imajući u vidu njihov izrazito dinamički karakter. Oscilacije ugaone brzine točka usled delovanja momenta kočenja u velikoj meri izazivaju promene u intenzitetu sile u podužnom pravcu. Dinamičko ponašanje pneumatika u velikoj meri zavisi od njegove složene konstrukcije. U opštem slučaju, pneumatik može biti predstavljen kao visko-elastični torus sačinjen od prednapregnutih čeličnih vlakana i gume. Pored konstrukcije samog pneumatika, bitnu ulogu na prenošenje sila i momenata koje deluju u njegovom kontaktu sa tlom ima i gazeća površina

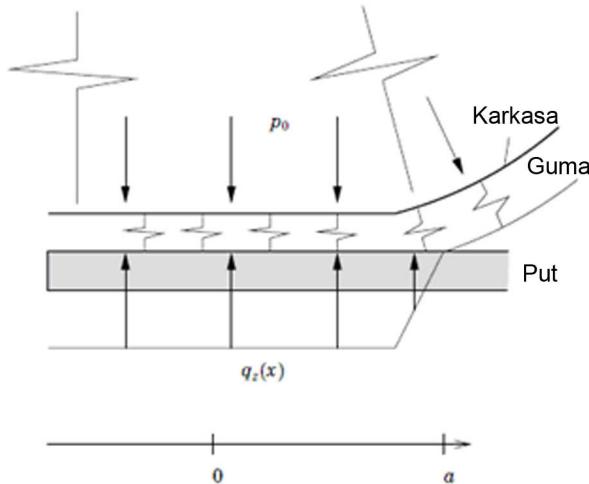
pneumatika (protektor), koja može u većoj ili manjoj meri da se deformiše (slika 5.1).



Slika 5.1. Deformacija gazeće površine pneumatika u poduznom pravcu

Sveobuhvatna analiza osobina pneumatika je od izuzetne važnosti za kvalitet projektovanja sistema i komponenata vozila poput sistema za oslanjanje, sistema za upravljanje i kočnog sistema. Do sada su razvijene različite metode, odnosno matematički modeli dinamičkog ponašanja pneumatika, koji se široko koriste prilikom simulacije dinamike kretanja vozila. Razlikuju se teorijski modeli bazirani na konstrukciji pneumatika i empirijski modeli koji se zasnivaju na eksperimentalnim podacima. Veliki broj modela koristi kombinaciju ova dva pristupa [127,132,133]. Da bi se razumelo generisanje i dejstvo sila u kontaktu pneumatik-tlo, veoma je korisno uvođenje koncepta klizanja pneumatika, koje se, kao što je već objašnjeno, definiše kao razlika trenutne brzine točka i brzine točka pri slobodnom kotrljanju. Odnos kojim se opisuje generisana horizontalna sila u kontaktu sa tlom, kao funkcija klizanja pod statičkim uslovima, naziva se karakteristika klizanja u statičkim uslovima ili stacionarna karakteristika klizanja [132]. Pri malim vrednostima klizanja, horizontalne sile uglavnom zavise od elastičnih deformacija pneumatika. Pri veoma malim vrednostima klizanja, generisana horizontalna sila je proporcionalna klizanju i takav koeficijent proporcionalnosti se naziva krutost pneumatika. To je još jedna od važnih osobina pneumatika koja utiče na prenos sile kočenja na površinu puta. Pri većim vrednostima klizanja horizontalne sile su ograničene nivoom trenja između pneumatika i puta. Izrazito nelinearne karakteristike klizanja u velikoj meri određuju ponašanje vozila prilikom upravljanja pri velikim vrednostima bočnog ubrzanja [133].

Elastične deformacije pneumatika tokom kočenja su takođe jedna od važnih njegovih osobina koje utiču na prenos sile kočenja na podlogu i njenu stabilnost. Prema [130,132], precizna analiza deformacija pneumatika zahteva dobre alate za proračun i tačne informacije o obliku pneumatika i trenutnim uslovima, kao što su opterećenje osovine, vrsta i stanje površine puta i temperatura. Šematski prikazano, deformacija pneumatika se može podeliti u dva dela (slika 5.2). Jedan deo se odnosi na promene oblika karkase i drugi koji se odnosi na sabijanje gumenih materijala. Ako je deformacija karkase umerena, zapremina vazduha u pneumatiku ostaće skoro konstantna i nije potrebno povećavati pritisak u pneumatiku. U statičkom slučaju, na primer, kada se vozilo ne kreće, maksimalni pritisak između pneumatika i puta obično ne može premašiti pritisak unutar pneumatika p_0 . Postoji oblast u centru kontaktne površine gde je pritisak jednak p_0 . U spoljašnjem delu gde se karkasa podiže od podloge sabijenost gume omogućava glatki prelaz pritiska sa vrednosti p_0 na 0, gde se kontaktna površina završava. Raspodela pritiska u podužnom preseku pneumatika može da izgleda kao primer prikazan na slici 5.2. U bočnom pravcu distribucija pritiska zavisi od oblika karkase. Lučna karkasa, koja odgovara dobro napumpanom pneumatiku, daje okruglu kontaktnu površinu. Nedovoljno naduvan pneumatik ima kao rezultat ravniju karkasu, što daje više pravougaoni profil kontakta [132].



Slika 5.2. Vertikalna raspodela pritiska duž preseka pneumatika

Prema [131,133], raspodela pritiska za dinamički slučaj je drugačija od one u statičkim uslovima. Pomeranje točka menja profil raspodele pritiska koji više neće biti simetričan. Kada točak rotira deformiše se kontinualno i dolazi do pojave momenta otpora kotrljanju. Pritisak se povećava u prednjoj polovini kontaktne zone posmatrajući smer kretanja vozila i smanjuje se u zadnjoj polovini [132,133]. Sve ovo značajno utiče na prenos sile kočenja sa pneumatika na podlogu na taj način što dolazi do pojave oscilacija, a samim tim i njene nestabilnosti.

U skladu sa [132,134] relativno veliki broj istraživanja je sproveden u području modeliranja pneumatika i pokriva sve od jednostavnih modela koji služe za razumevanje fizike kretanja do naprednijih modela sa konačnim elementima, koji precizno mogu predvideti ponašanje pneumatika. Osobine pneumatika se takođe menjaju sa povećanjem istrošenosti pneumatika, temperature, uslova puta, itd. Stoga su istraživači razvili empirijske modele uključujući nekoliko parametara, koji mogu biti određeni testiranjem pneumatika. Ovi modeli se mogu koristiti za izračunavanja tokom simulacija ili implementacija u realnom vremenu [132]. Mogućnost korišćenja ovih modela direktno na vozilu je veća, ali i dalje ograničavajuća pošto faktori iz okruženja utiču na karakteristike trenja u kontaktu pneumatika i puta [130].

5.3. PRIJANJANJE U KONTAKTU PNEUMATIKA I TLA

Tokom procesa kočenja uslovi u kontaktu pneumatika i tla se dinamički menjaju. Da bi kočni sistem uspešno izvršavao svoje zadatke, tj. da bi što efikasnije ispunjavao zadatu funkciju cilja, neophodno je da se karakteristike ovih dinamički promenljivih procesa, koji nastaju kao rezultat interakcije pneumatika sa površinom puta, što bolje upoznaju i jednoznačno odrede. To je takođe veoma važno i sa stanovišta uvođenja inteligentnog upravljanja performansama kočnog sistema. Tu se pre svega misli na određivanje trenutne vrednosti koeficijenta prijanjanja pneumatika u kontaktu sa podlogom u toku ciklusa kočenja, odnosno u dinamičkim radnim uslovima, kako bi u svakom trenutku bilo poznato gde je njegov trenutni maksimum za date uslove prijanjanja.

Kao što je već pokazano u literaturi [52,53,54,101] prilikom analize sila i momenata koji deluju u kontaktu pneumatika i tla tokom kočenja najprikladnije je krenuti od tzv. modela četvrtine vozila, koji podrazumeva da se tokom analize posmatra dinamičko ponašanje samo jednog točka. Ovakav model predstavlja uprošćeni pristup za opisivanje dinamičkog ponašanja točka. Njegova upotreba je moguća uz određene pretpostavke da se uticaj sila i momenata koji deluju u poprečnoj i vertikalnoj ravni tokom kočenja, uticaj dinamike elemenata sistema za oslanjanje, kao i postojanje uzajamnog dejstva između pojedinih točkova vozila mogu zanemariti. I pored toga, ovakav pristup proučavanju dinamičkog ponašanja kočenog točka sadrži fundamentalne karakteristike bitne sa stanovišta opisivanja njegovog dinamičkog ponašanja. U skladu sa [53,98,101], na slici 5.3 su prikazane sile i momenti koji deluju na kočeni točak, pri čemu su primenjene sledeće oznake:

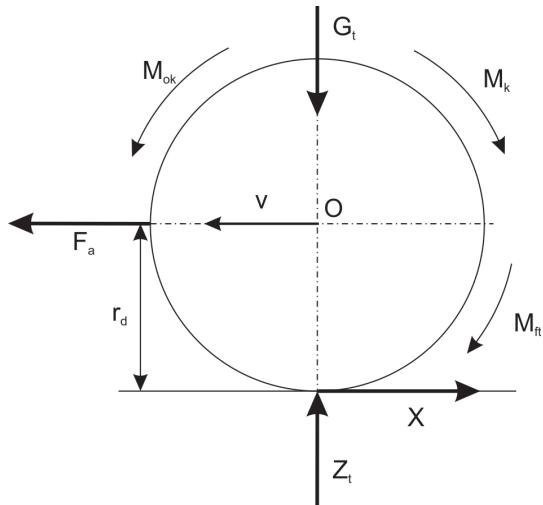
$G_t = gm_t$ - normalno opterećenje točka izazvano masom m_t ,

F_a - inerciona sila,

M_{ok} - propulzivni moment koji deluje u toku kočenja,

M_k - moment koji ostvaruje kočnica,

M_{ft} - moment otpora kotrljanju točka.



Slika 5.3. Sile i momenti koji deluju na kočeni točak

Na ravnom putu propulzivni moment deluje na točak u toku kočenja samo ako se ono vrši bez isključenja spojnice. Njegova vrednost se može izraziti u obliku:

$$M_{ok} = M_e i_u + J \frac{d\omega}{dt} \quad (5.1)$$

gde su:

M_e - efektivni moment motora,

i_u - ukupan prenosni odnos,

J - moment inercije obrtnih delova (sveden na točak),

ω - ugaona brzina točka.

Prema slici 5.3 momentna jednačina ravnoteže kočenog točka glasi:

$$X_k r_d + M_{ok} - M_{ft} - M_k = 0 \quad (5.2)$$

Odavde neposredno sledi da je tangentna reaktivna sila:

$$X_k = \frac{M_k + M_{ft} - M_{ok}}{r_d} \quad (5.3)$$

Tangentna reaktivna sila predstavlja ukupnu силу коčenja koja usporava točak. Propulzivni moment koji deluje na točak tokom kočenja se obično zanemaruje, tj. performanse kočnog sistema se posmatraju sa isključenom spojnicom. U tom slučaju tangentna reaktivna sila može da se prikaže u obliku:

$$X_k = F_k + R_{f\ddot{t}} \quad (5.4)$$

Gde je sa F_k obeležena sila kočenja izazvana kočnicama, odnosno:

$$F_k = \frac{M_k}{r_d} \quad (5.5)$$

Treba da se naglasi da kočnica razvija moment kočenja M_k , odnosno da je sila F_k u suštini zamišljena obimna sila, koja na točak ima isto dejstvo kao i moment M_k [96]. Prema tome ako je za date uslove kretanja, odnosno za datu vrednost otpora kotrljanju točka $R_{f\ddot{t}}$, potrebno da se ostvari sila kočenja X_k , kočnica kojom se točak koči treba da ostvari moment koji je jednak:

$$M_k = (X_k - R_{f\ddot{t}})r_d \quad (5.6)$$

Kod točka koji se koči na tvrdom putu, što se najčešće dešava i što je sa stanovišta bezbednosti saobraćaja najvažnije, otpor kotrljanju ima vrlo male, odnosno zanemarljive vrednosti [53,96], tako da se izraz 5.6 svodi na:

$$M_k = F_k r_d \cong X_k r_d \quad (5.7)$$

Pošto je sila kočenja tangentna reakcija koja se ostvaruje u spoju točka i puta, to je njena maksimalna vrednost ograničena uslovima ovog spoja, tj. uslovima prijanjanja. Drugim rečima, za shemu kočenog točka na slici 5.3, koji je opterećen masom koja izaziva normalno opterećenje m, g , odnosno normalnu reaktivnu силу Z_t , tangentna reakcija ima vrednosti:

$$X_{k \max} = \varphi_m Z_t \quad (5.8)$$

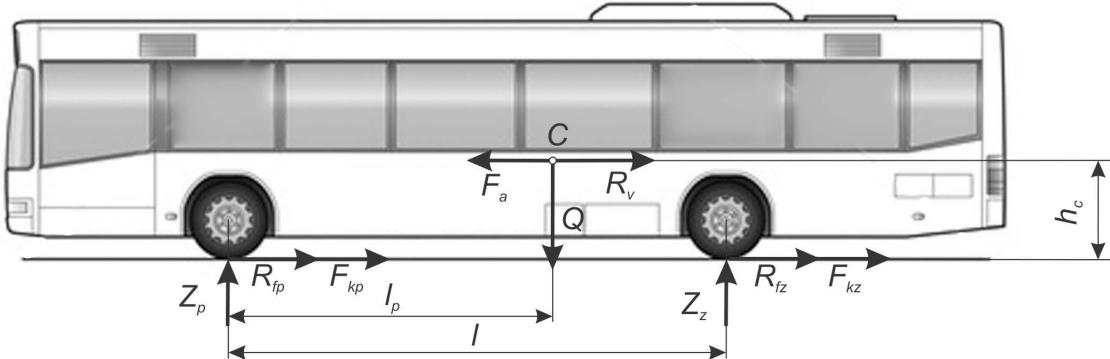
Gde je φ_m najveća vrednost prijanja između točka i puta. Ovako definisano prijanjanje predstavlja meru kvaliteta spoja točka i puta, odnosno srazmeru između normalne i maksimalne tangentne reaktivne sile na točku. Zbog toga se maksimalna vrednost prijanjanja naziva i „koeficijent“ prijanjanja, koji se često radi jednostavnosti označava samo sa φ , tj. $\varphi_m = \varphi$ [101].

Pošto sila kočenja zavisi i od dovedenog momenta kočenja (prema izrazu (5.7)), to za svaku njenu vrednost manju od maksimalne moguće, sa stanovišta najvećeg prijanjanja, tj. za svako $X_k < X_{k \max}$, važi odnos:

$$X_k = \varphi_s Z_t \quad (5.9)$$

gde φ_s označava tzv. iskorišćeno prijanjanje, s tim što uvek važi $\varphi_s < \varphi$ [96].

Prijanjanje između točka i puta predstavlja vrlo složen fenomen, koji se može interpretirati preko koeficijenta prijanjanja samo uz velika uprošćenja, tj. samo kao orijentacija. U stvarnosti prijanjanje nije konstanta ili koeficijent, već proces koji zavisi od mnogih činilaca, a pre svega od klizanja točka [99,96,107]. U dinamičkim radnim uslovima, međutim, situacija je nešto drugačija. Pošto je koeficijent prijanjanja definisan kao $\varphi = F_k/Z_t$, jasno je da su vrednosti sila F_k i Z_t neophodne da bi se izračunala njegova trenutna vrednost. S obzirom na model kočenog točka, tj. model četvrtine vozila prikazanog na slici 5.3, vrednost koeficijenta prijanjanja može biti određena pomoću ravnoteže momenata u odnosu na osu točka. Da bi se definisao izraz pomoću kojeg je moguće odrediti силу koja deluje na točak u vertikalnoj ravni, i to u dinamičkim uslovima, neophodno je uvesti nekoliko prepostavki. Ukoliko se zanemari veza između kotrljanja i bočnog nagiba točka u tom slučaju je moguće nezavisno odrediti uticaje sila koje deluju na točak na komponente usporena u podužnom i poprečnom pravcu. U slučaju da se zanemari i dinamika elemenata sistema za oslanjanje, vertikalna sila tzv. modela četvrtine vozila se može tada izjednačiti sa vertikalnom silom koja deluje na kočeni točak [117]. Prema tome, precizno dinamičko izračunavanje trenutne vrednosti koeficijenta prijanjanja u kontaktu pneumatika i puta u podužnom pravcu znatno zavisi od trenutne vrednosti vertikalnog opterećenja koje deluje na dati kočeni točak. Sila usled delovanja podužne komponente usporena vozila a u njegovom težištu izaziva pojavu dinamičke preraspodele opterećenja vozila sa zadnje na prednju osovinu (slika 5.4).



Slika 5.4. Položaj težišta vozila i sile u kontaktu pneumatik-tlo

Odgovarajuća trenutna vrednost koeficijenta prijanjanja u kontaktu između datog točka i puta se može tada izračunati pomoću jednačine (5.10), gde je Z_d odgovarajuća dinamička reakcija po točku na prednjoj/zadnjoj osovini.

$$\varphi = \frac{F_k}{Z_d} \quad (5.10)$$

Usporenje točka se može izračunati preko momentne jednačine postavljene u odnosu na centar rotacije točka (slika 5.3), odnosno na osu osovine, a u skladu sa drugim Njutnovim zakonom.

$$J\alpha = M_k - M_{ok} \quad \text{i} \quad m_t a_t = -F_k \quad (5.11)$$

gde M_k predstavlja moment kočenja koji uzrokuje smanjenje brzine točka, M_{ok} predstavlja pogonski moment, a_t usporenje točka, F_k silu kočenja, a m_t je opterećenje datog točka. Parametar J predstavlja moment inercije točka u odnosu na osu rotacije, dok parametar $\alpha (= \dot{\omega})$ predstavlja ugaono usporenje točka. Prema [117], ugaono usporenje točka može biti izračunato na osnovu razlike dve uzastopne vrednosti ugaone brzine točka:

$$\alpha(t) = \dot{\omega}(t) = \frac{\omega_n(t) - \omega_{n-1}(t)}{t} \quad (5.12)$$

gde t označava period uzorkovanja podataka. Potpuno analogno tome, translatorno usporenje točka a_t može biti izračunato na osnovu razlike dve uzastopne vrednosti translatorne brzine točka (v_t), dobijene kao $v_t = \omega r_d$:

$$a_t(t) = \dot{v}_t(t) = \frac{v_n(t) - v_{n-1}(t)}{t} \quad (5.13)$$

Prema preciznijoj definiciji u skladu sa [134,135,136,137,138], sila kočenja F_k koja se razvija u kontaktu pneumatika i puta data je preko izraza:

$$F_k = Z_t \varphi(\lambda, \varphi_m, \beta) \quad (5.14)$$

gde je koeficijent prianjanja φ nelinearna funkcija klizanja u kontaktu (λ), maksimalne vrednosti koeficijenta prianjanja (φ_m) i ugla klizanja točka (β). Koeficijent prianjanja može imati vrednosti u okviru veoma širokog opsega, ali je u opštem slučaju diferencijabilna funkcija u odnosu na sve argumente sa karakteristikama $\varphi(0, \varphi_m, \beta) = 0$ i $\varphi(\lambda, \varphi_m, \beta) > 0$ za $\lambda > 0$ [117,135-138]. Polazeći od jednačine (5.11), izračunavanjem prvog izvoda klizanja po vremenu može se izvesti izraz za dinamičku promenu klizanja točka za $v > 0$ i $\omega > 0$ (jednačina 5.15):

$$\begin{aligned} \dot{\lambda} &= \frac{d}{dt} \left(1 - \frac{\omega r}{v} \right) = -\frac{\dot{\omega}r}{v} + \frac{\omega r}{v} \frac{\dot{v}}{v} = -\frac{1}{v} \left(\frac{1}{m} (1 - \lambda) + \frac{r^2}{J} \right) F_z \varphi(\lambda, \varphi_m, \beta) + \frac{1}{v} \frac{r}{J} T_b, \\ \dot{v} &= -\frac{1}{m} F_z \varphi(\lambda, \varphi_m, \beta) \end{aligned} \quad (5.15)$$

Ova metoda se zasniva na pretpostavci da promene koeficijenta trenja (μ) u kontaktu friкционog para kočnice mogu da se zanemare i shodno tome usvoji da je C karakteristika disk kočnice nepromenljiva tokom kočenja i da je njena prosečna vrednost jednaka 0,7. U tom slučaju se moment kočenja može dobiti kao linearna funkcija pritiska aktiviranja kočnice, u skladu sa jednačinom 5.16.

$$M_k = p \cdot \mu \cdot K = p \cdot k_c \cdot i_p \cdot C \cdot r_{sr} \quad (5.16)$$

gde su p - pritisak aktiviranja kočnice, μ - koeficijent trenja u kontaktu friкционog para kočnice i K - konstanta koja obuhvata sve geometrijske karakteristike kočnice. Geometrijske karakteristike kočnice su: k_c - karakteristika kočnog cilindra (1222 N/bar za prednji, 1428 N/bar za zadnji), i_p - prenosni odnos poluge za aktiviranje ($i_p = 15,1$) i r_{sr} - srednji poluprečnik trenja ($r_{sr} = 0,173$ m). U skladu sa

jednačinama 5.11, 5.12 i 5.15, odgovarajuća trenutna vrednost koeficijenta prijanjanja tada može biti izračunata pomoću jednačine 5.17:

$$\varphi = \frac{J\dot{\omega} + M_k}{Z_t r_d} \quad (5.17)$$

Pri čemu trenutna vrednost odgovarajuće dinamičke reakcije na prednjem/zadnjem točku može biti određena pomoću jednačina 4.15 i 4.16.

Tabela 5.1. Podaci o vozilu

Veličina	Oznaka	Neopterećeno stanje vozila	Opterećeno stanje vozila
Međuosovinsko rastojanje (m)	l	5,92	5,92
Visina težišta (m)	h_c	0,9	1,1
Rastojanje težišta od prednje osovine (m)	l_p	3,46	3,92
Rastojanje težišta od zadnje osovine (m)	l_z	2,46	2
Ukupna masa	m	11730	17157
Masa na prednjoj osovini	m_p	4300	6560
Masa na zadnjoj osovini	m_z	7460	10620

5.4. KLIZANJE U STATIČKIM I DINAMIČKIM USLOVIMA

5.4.1. Uvod

U prethodnom poglavlju je objašnjeno da trenje (μ) koje se stvara između gazeće površine pneumatika i površine puta omogućava realizaciju sile kočenja u kontaktu pneumatik-tlo. Usled relativnog pomeranja ove dve površine, odnosno usled razlike u brzinama njihovog kretanja, dolazi do pojave klizanja točka (λ) u podužnom i/ili poprečnom pravcu. Predznak klizanja se obično usvaja tako da tokom kočenja ono bude negativno. To dakle znači da je pri potpunom blokiranju točka važi da je $\lambda = -1$. U tom slučaju podrazumeva se da je točak prestao da rotira i započeo da proklizava u kontaktu sa površinom puta, tj. upravljivost točka je narušena. Prilikom kretanja i/ili kočenja na klizavim površinama puta, klizanje može dostići veoma visoke vrednosti. Prema [95], klizanje točka nije moguće direktno izmeriti i obično se izračunava na osnovu izmerene vrednosti brzine vozila ili njegovog usporenja.

Klizanje kočenog točka je ozbiljniji i složeniji problem od ugaonog klizanja pogonskog točka, i to iz više razloga. Pre svega, translatorno klizanje kočenog točka može da se pojavi i na putevima sa najvišim prijanjanjem, posebno ako se radi o putničkim vozilima ili točkovima čije je normalno opterećenje relativno malo. Osim toga, mogućnost klizanja kočenog točka se značajno povećava ako se uslovi prijanjanja čak i relativno blago pogoršavaju (vlažan put). Nadalje, potpuno blokiranje točkova, odnosno potpuno zaustavljanje obrtanja i prelaženje na čisto translatorno klizanje točka najčešće u potpunosti onemogućava kontrolu kretanja vozila, što je sa stanovišta bezbednosti saobraćaja veoma opasno [96]. Zbog svega toga klizanju kočenog točka treba da se pokloni posebna pažnja.

Ovde će najpre biti predstavljene osnovne dinamičke karakteristike u vezi sa klizanjem kočenog točka. Klizanje kočenog točka može neposredno da se izrazi iz relativnog odnosa ugaonih brzina [117,140,141], odnosno:

$$\lambda = \frac{\omega_0 - \omega_k}{\omega_0} \quad (5.18)$$

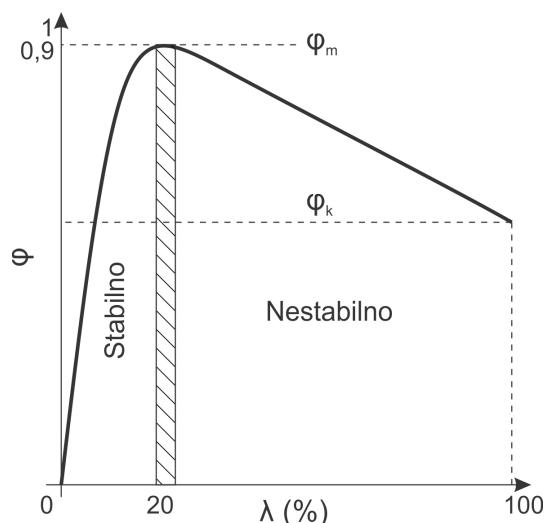
ω_0 - ugaona brzina točka bez klizanja,

ω_k - ugaona brzina kočenog točka.

To se može izraziti i u procentima, odnosno:

$$\lambda = \frac{\omega_0 - \omega_k}{\omega_0} \cdot 100\% \quad (5.19)$$

Iz ovog izraza sledi da je u slučaju kada je $\lambda = 0$ reč o neutralnom točku, koji se slobodno kotrlja bez klizanja ($\omega_0 = \omega_k$), dok je u slučaju $\lambda = 1$ ili 100% ($\omega_k = 0$) reč o potpuno ukočenom točku, koji se ne kotrlja već translatorno kliza po putu. U ovom slučaju govori se da je točak „blokirao“, odnosno da je „blokiran“. Od veličine klizanja zavisi i ostvareno prijanjanje, odnosno veličina sile kočenja [96]. Tipičan oblik ove zavisnosti, koja se naziva „kriva klizanja“, prikazan je na slici 5.5. Sa slike se vidi da prijanjanje u početku relativno brzo raste sa porastom klizanja, ostvarujući pri relativno malim vrednostima klizanja i svoj maksimum $\varphi_m = \varphi$. Ove vrednosti klizanja za privredna vozila obično iznose 10 do 20%, a vrlo retko i do 30% [96,117,121,140]. Posle maksimuma, prijanjanje sa daljim porastom klizanja blago opada, da bi pri klizanju od 100 %, odnosno pri blokiranju točka, dostiglo vrednost φ_k , koja je osetno niža od maksimalne, odnosno $\varphi_k < \varphi_m$, slika 5.5.



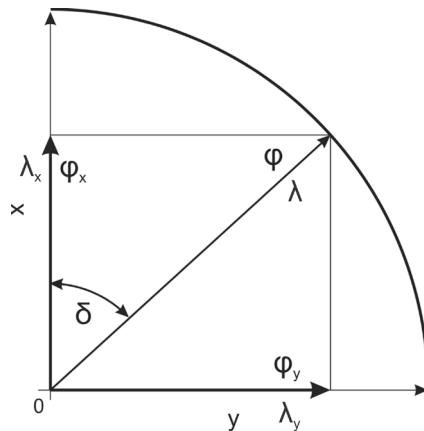
Slika 5.5. Tipičan oblik krive klizanja

Prema [96,117], prijanjanje pri punom blokiranju točka, tj. pri njegovom translatornom klizanju po putu, u osnovi je pojava koja je veoma slična trenju klizanja između pneumatika i puta. Na slici 5.5 je naznačeno da je proces klizanja točka do dostizanja maksimalne vrednosti prijanjanja stabilan, a u daljem toku nestabilan. Ovo je dokazano mnogim ispitivanjima. Detaljna ispitivanja su međutim pokazala da se i u stabilnom području prijanjanje menja relativno neravnomerno, sa većim ili manjim odstupanjima od krive prikazane na slici 5.5 [140,141]. Imajući sve to u vidu, dijagram na slici 5.5 predstavlja samo uprošćeni ili osrednjeni prikaz stvarnih promena prijanjanja pri promeni klizanja. Ovo se još više odnosi na nestabilno područje, u kome je prelaz sa jednog na drugo stanje izrazito stohastički.

Prikazana kriva klizanja na slici 5.5 odgovara tzv. stacionarnim uslovima, koji podrazumevaju da se tokom procesa kočenja, odnosno pri povećanju klizanja, ne menja ni vertikalno opterećenja točka, niti brzina translatornog kretanja točka. U dinamičkim radnim uslovima situacija se značajno menja. Kao što je već objašnjeno, zbog delovanja inercione sile prednji točkovi se tokom kočenja dopunski opterećuju, a zadnji rasterećuju, dok se brzine i jednih i drugih stalno smanjuju. To značajno utiče na karakter stvarnih, ili tzv. dinamičkih krivih klizanja [96,140]. Iz datih objašnjenja vidi se da je klizanje kočenog točka neposredno povezano sa parametrima režima kočenja, odnosno dovedenim momentom kočenja i osobinama spoja točka i puta.

Krive klizanja predstavljaju meru graničnih mogućnosti vozila u pogledu kočenja [140,141]. One su, međutim, značajne i za analize stabilnosti vozila pri kočenju, sa stanovišta sposobnosti kočenog točka da pored uravnoteženja sile inercije omogući i uravnoteženje različitih poremećajnih momenata ili sila, posebno bočnih sila [141]. Ove sile mogu biti različitog porekla (centrifugalna sila, bočni vetar, bočni nagib puta, itd.), ali u procesu kočenja one uvek teže da vozilo skrenu sa željene putanje, tj. da mu poremete stabilnost. U opštem slučaju, kada na točak deluju i vertikalna i bočna opterećenja, prijanjanje koje se javlja u spoju pneumatika i puta prilagođava se pravcu klizanja točka, tj. odnosu tangentne i bočne reakcije. U tom smislu, može da se govori o prijanjanju u podužnom i u bočnom pravcu, pa i o odgovarajućim komponentama koeficijenta prijanjanja φ_x .

(podužno) i φ_y (bočno), odnosno o komponentama klizanja u podužnom (λ_x) i poprečnom pravcu (λ_y). Odnos ove dve komponente koeficijenta prijanjanja, odnosno klizanja može biti veoma različit, a jedan uprošćen primer prikazan je na slici 5.6. Na ovoj slici sa δ je označen ugao povođenja pneumatika, odnosno ugao bočnog klizanja.



Slika 5.6. Ugao bočnog klizanja točka

Odnos između podužne i poprečne komponente klizanja mora biti optimalan kako bi se zadovoljili i kriterijumi u pogledu zaustavnog puta i oni koji se odnose na zadovoljenje uslova stabilnosti. U skladu sa slikom 4.8, to podrazumeva da između podužne i poprečne komponente klizanja treba da postoji kompromis tako da se što je moguće više iskoristi raspoloživo prijanjanje u poprečnom i podužnom pravcu. Pri većim vrednostima klizanja u podužnom pravcu dostupno prijanjanje u podužnom pravcu je na relativno visokom nivou, dok u poprečnom pravcu naglo opada. Upravo zbog toga je potrebno dovesti klizanje na nivo koji istovremeno omogućava i dobro iskorišćenje raspoloživog prijanjanja u poprečnom pravcu.

5.4.2. Teorijski (statički i dinamički) modeli kontakta pneumatik-tlo

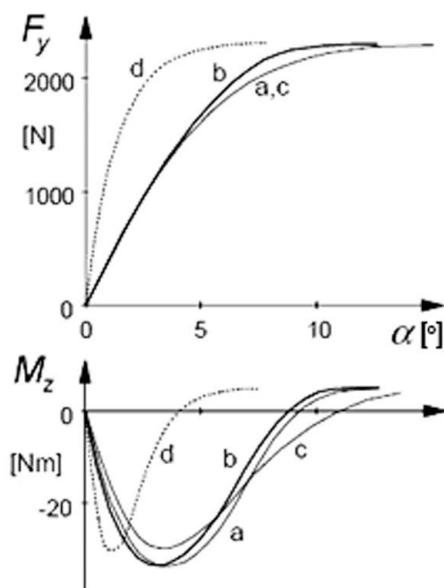
U ovom odeljku će biti posvećena pažnja analizi osobina teorijskih modela koji se koriste za opisivanje procesa koji se dešavaju u kontaktu pneumatik-tlo u cilju što boljeg njihovog razumevanja, ali i analize problema koji se tu javljaju, a u tesnoj su vezi sa uticajem klizanja točka na stabilnost vozila tokom kočenja. Matematičko modeliranje fizičkog modela interakcije pneumatika i tla bio je izazov za mnoge

istraživače pri čemu četiri ključna faktora igraju važnu ulogu: karakteristike trenja u kontaktu pneumatika i puta, raspodela kontaktnog pritiska, karakteristike gazećeg sloja pneumatika i karakteristike karkase [117,131,133,140]. Prema [133,140], Frank je 1965. izneo podrobno komparativno ispitivanje različitih jednodimenzionalnih modela. On je iskoristio opštu diferencijalnu jednačinu četvrtog reda sa kojom modeli pneumatika mogu biti predstavljeni kao rastegnuta žica, traka ili rastegnuta traka sa elastičnim elementima na gazećoj površini. Frank je pronašao rešenje za problem statičkog klizanja uz pomoć specijalnog analognog kompjuterskog kola [140]. Slika 5.7 predstavlja izračunate karakteristike nekoliko tipova modela pneumatika u odnosu na istu podlogu. Krive na dатој slici predstavljaju: a) model rastegljive žice, b) model trake, c) pretpostavka zasnovana na tzv. Fiala modelu, d) Fromov model (tzv. model četke). Krutost gazećeg sloja pneumatika je ista za svaki model. Parametri u slučajevima a, b i c su izabrani na takav način da ostvaruju što je moguće bolje poklapanje sa eksperimentalnim podacima za maksimalne vrednosti bočne sile pri malim uglovima klizanja [133,140]. Tada model c pokazuje usku povezanost sa krivom a za bočnu silu F_y .

Krive d pokazuju rezultat kada je elastičnost karkase zanemarena i kada se samo fleksibilnost gazećeg sloja uzima u razmatranje. Kada je krutost gazećeg sloja modela d prilagođena (tj. smanjena) na takav način da krutost u bočnom pravcu postaje jednak onoj kod ostala tri modela, ne pojavljuje se nikakva razlika između karakteristika bočne sile prema modelima Froma i Fiale. Prema pretpostavkama Fiale, koeficijenti u izrazu za bočnu silu u odnosu na ugao klizanja (ako je raspodela paraboličkog pritiska prilagođena) postaju jednakim onim koje je From odredio [132,133].

U proračunima na osnovu kojih su konstruisane krive sa slike 5.7, Frank je koristio konstantnu vrednost koeficijenta trenja i blago asimetričnu raspodelu vertikalnog pritiska, koji su dobijeni merenjima. Pozitivan moment uravnoveženja M_z , dobijen pri većim vrednostima ugla klizanja, povećava se kao rezultat ove asimetrije. Fenomen da moment uravnoveženja u praksi u potpunosti varira na ovaj način nastaje zahvaljujući kombinaciji nekoliko efekata. Glavni uzrok je najverovatnije povezan sa asimetričnom distribucijom pritiska pneumatika (usled

histerezisa materijala pneumatika), što kao rezultat ima mali pomak tačke dejstva normalnog opterećenja (izazivajući povećanje otpora kotrljanja) [142]. Pored toga, pri potpunom klizanju to je takođe i rezultat bočne sile. Drugi važan faktor koji uzrokuje da moment postane pozitivan je činjenica da koeficijent trenja nije konstantan i teži da se smanji sa povećanjem brzine klizanja. Brzina klizanja postiže svoju najvišu vrednost u zadnjem delu kontaktnog područja gde nagib pneumatika postaje najveći. Zbog toga se veće bočne sile očekuju u prednjoj polovini kontaktnog područja u uslovima potpunog klizanja pre nego u zadnjoj polovini. Otpor kotrljanja usled deformacije pneumatika deluje malo iza točka i može takođe doprineti promeni znaka momenta uravnoteženja. Imajući to u vidu, karakteristika podužne sile je da je maksimum krive obično naglašeniji nego kod bočne [140,142].

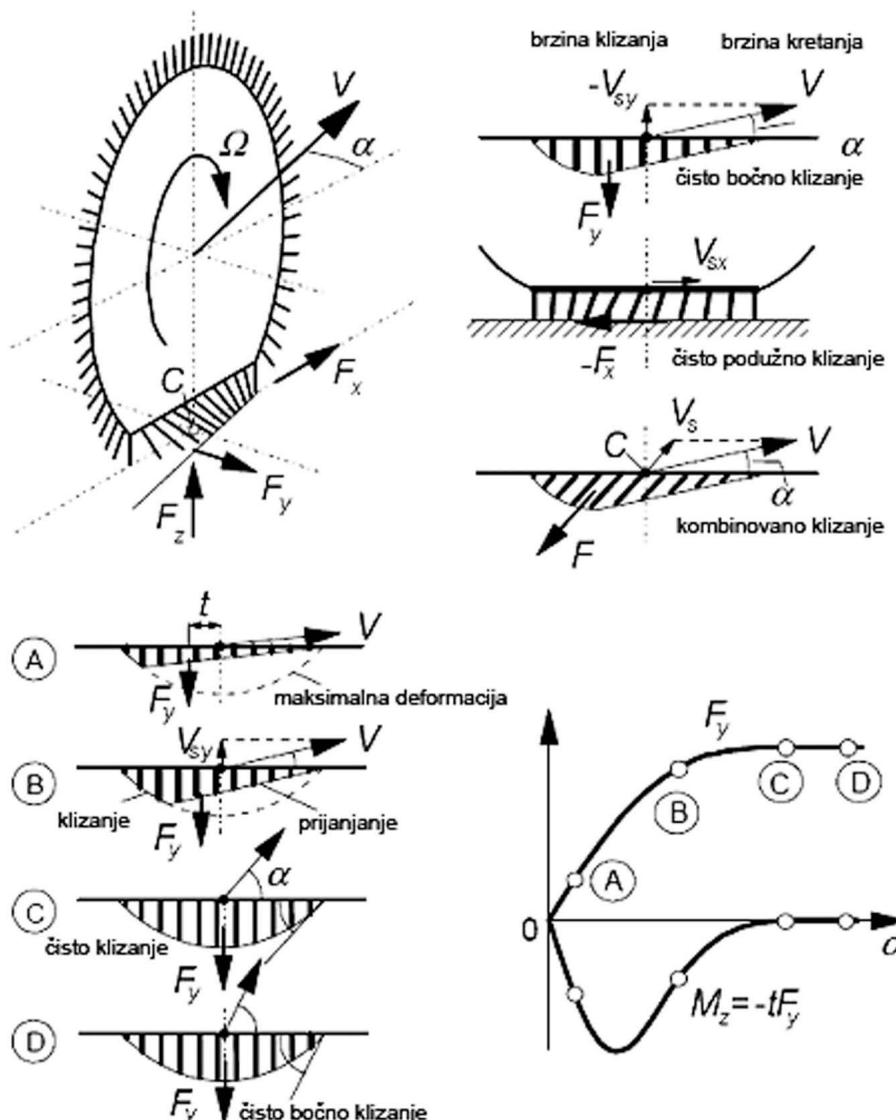


Slika 5.7. Poređenje karakteristika za četiri različita modela pneumatika [133]

Prema [133,143], uticaj različitih, ali simetričnih oblika za vertikalnu raspodelu sile duž z-ose teorijski je ispitana od strane Bergmana (1963). On je pronašao da je uticaj raspodele pritiska od velike važnosti, posebno kod pneumatika koji se suočavaju sa relativno velikom složenošću karkase. Nesimetrične i malo opštije raspodele su proučavane od strane Guo-a (1994). Mnogi autori su prilagodili za potrebe matematičke jednostavnosti paraboličku raspodelu (Fiala 1954, Freudenstein 1961, Bergman 1965, Pacejka 1958, Sakai (takođe parabola n-tog

stepena, 1989), Dugolf 1979 (uniformna, pravougaona distribucija) i Bernard 1977 (trapezasti oblik)). Uvođenje promenljivog koeficijenta trenja između ostalih ispitivali su: Bohm (1963), Borgman (1963), Dugolf (1970), Sakai (1981) i Bernard (1977) [144]. Slika 5.7 pokazuje da, kada se parametri modela dobro odaberu, izbor modela karkase pneumatika (traka ili žica) ima samo ograničen efekat.

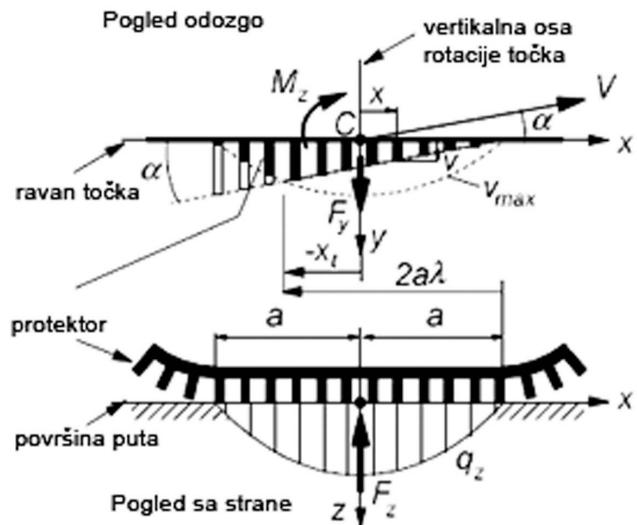
Kruti model karkase sa elastičnim kontaktnim elementima se obično naziva tzv. model četke (engl. "*brush tyre model*"). Zbog njegove jednostavnosti i kvalitativne saobraznosti sa eksperimentalno utvrđenim ponašanjem pneumatika u praksi [133] najpre će biti posvećena pažnja njegovim osobinama, uglavnom da bi se obezbedilo razumevanje osobina statičkog klizanja, koje takođe mogu biti od pomoći u razvijanju složenijih modela. Ovaj teorijski model je ujedno i najpoznatiji od svih modela iz grupacije statičkih modela. Model četke se sastoji od reda fiktivnih elastičnih čekinja koje dodiruju površinu puta i mogu se deformisati (povijati) u smeru paralelnom površini puta. Ove čekinje se mogu idealizovano posmatrati kao elementi gazećeg sloja pneumatika [143]. Njihova elastičnost predstavlja kombinaciju elastičnosti karkase, bočnih strana i gazeće površine realnog pneumatika. Dok se pneumatik okreće, pretpostavlja se da prvi element koji dolazi u zonu kontakta sa tlom stoji pod pravim uglom u odnosu na površinu puta. Kada se pneumatik slobodno okreće (bez delovanja pogonskog ili kočnog momenta) i kada nema klizanja u poprečnom pravcu, nagiba ili skretanja vozila, točak se kreće duž prave linije paralelno putu i u pravcu koji leži u njegovoј ravni. U toj situaciji, gazeći elementi ostaju vertikalni i pomeraju se od početne do krajnje ivice bez pojave horizontalne deformacije pa prema tome ne dolazi do stvaranja podužne ili bočne sile. Moguće prisustvo otpora kotrljanja se u ovom slučaju zanemaruje. Kada dođe do povećanja ugla između vektora brzine točka v u odnosu na ravan točka, tada se javlja bočno klizanje. Kada ugaona brzina točka (ω) pomnožena sa dinamičkim poluprečnikom točka nije jednaka podužnoj komponenti brzine točka $v_x = v \cos \alpha$ dolazi do pojave podužnog klizanja. Pod takvim uslovima, prikazanim na slici 5.8, nastaju horizontalna savijanja čekinja i odgovarajuće sile i momenti u kontaktu sa tlom se povećavaju [133,143].



Slika 5.8. Model četke u skladu sa [133]

Kao što je prikazano na slici 5.8, gazeći elementi (čekinje) se pomeraju od početne ivice kontakta do krajnje. Vrh elementa (čekinje) će dodirivati podlogu sve dok raspoloživo trenje dozvoljava, tj. neće klizati po površini puta [143]. U isto vreme, osnovna tačka elementa ostaje u ravni točka i pomera se unazad sa linearnom brzinom kotrljanja v_r u odnosu na osu točka, tj. u odnosu na kontaktni centar C. U odnosu na put, osnovna tačka elementa se pomera brzinom koja je označena kao brzina klizanja točka v_s .

Drugi karakterističan slučaj koji je analiziran u ovoj disertaciji odnosi se na čisto bočno klizanje, što je prikazano u donjem delu slike 5.8. Klizanje se menja od veoma malog do relativno velikog. Očigledno je da se savijanje elementa povećava dok se on pomera dalje kroz kontaktnu površinu. Rezultujuće savijanje varira linearno sa razdaljinom od početne ivice i vrhovi formiraju pravu liniju kontakta koja leži u pravcu paralelnom vektoru brzine točka v . Slika 5.9 takođe pokazuje maksimalno moguće savijanje koje može biti dostignuto od strane elementa u zavisnosti od njegovog položaja u kontaktnom području. Taj maksimum zavisi od (konstantnog) koeficijenta trenja (μ), raspodele vertikalne sile (F_z), i krutosti elementa (čekinje) C_{py} [133,140,144]. Pretpostavka je da raspodela pritiska i kao posledica toga maksimalno savijanje variraju po zakonu parabole [140]. U trenutku kada prava kontaktne linije preseče parabolu dolazi do pojave klizanja. Preostali deo kontaktne linije će se poklapati sa parabolom za maksimalno moguće savijanje elemenata. Pri povećanom uglu klizanja, bočna sila koja se generiše će se povećavati. Razdaljina njene linije dejstva od centra kontakta naziva se trag pneumatika (t). Moment uravnoveženja se povećava duž nesimetričnog profila rasporeda savijanja elemenata i može se izračunati kao proizvod bočne sile i traga pneumatika. Dok se klizanje povećava, deformisani oblik postaje simetričniji i, kao rezultat toga, trag pneumatika postaje manji. To je zato što se tačka preseka pomera napred time povećavajući opseg klizanja i smanjujući opseg prijenjanja. To se nastavlja sve dok se vektor brzine točka kreće paralelno tangentni paraboli na najudaljenijoj tački. Dalje, tačka preseka stiže do početne ivice i dolazi do pojave potpunog klizanja. Profil kontakta tada postaje potpuno simetričan. Bočna sila održava svoj maksimum i deluje u sredini kontakta tako da moment nestaje. Situacija ostaje nepromjenjena kada se ugao klizanja dalje povećava [140,142]. Rezultujuće karakteristike za bočnu silu i moment uravnoveženja su takođe prikazane na slici 5.9.



Slika 5.9. Model četke pri čisto bočnom klizanju [140]

Prema [134,140], kočenje vozila sa maksimalnom silom kočenja koju kočni sistem, odnosno kočnice mogu da ostvare može dovesti do potpunog blokiranja točkova, posebno na podlogama sa nižim vrednostima koeficijenta prijanjanja. Ukoliko se to još razmatra kao dinamički problem, onda uticaj gradijenta promene brzine u podužnom pravcu i efekata kombinovanog klizanja na poprečnu stabilnost ne može biti zanemaren. Zbog toga je ovde takođe istraživano na koji način se menjaju uslovi u kontaktu pneumatika i tla u slučaju kada kočeni točak delimično ili potpuno blokira i kako to dalje utiče na dinamičko ponašanje vozila. Imajući u vidu složenost takvog sistema, uticaj visine težišta vozila na njegovo kretanje se obično zanemaruje. Sa datom visinom težišta vozila, preraspodela mase vozila sa zadnje na prednju osovinu u podužnom pravcu može da se pojavi, ali takođe i u poprečnom, što može da uzrokuje nejednake sile kočenja na levim i desnim blokiranim točkovima. Slučaj se pojednostavljuje i time što se usvaja da je ugao zakretanja točkova u odnosu na podužnu ravan vozila jednak nuli. Primer ovakvog modela vozila sa dva točka i jednim tragom točka sa teorijskom visinom težišta jednakom nuli, u literaturi poznat kao model „bicikla“ [144], prikazan je na slici 5.10, gde se točak na osovinu 2 smatra blokiranim. Na osnovu toga se mogu formirati tri diferencijalne jednačine kretanja [133]:

$$\begin{aligned}
 m(\dot{u} - vr) &= F_{x1} + F_{x2} \\
 m(\dot{v} + ur) &= F_{y1} + F_{y2} \\
 mk^2\dot{r} &= aF_{y1} - bF_{y2}
 \end{aligned} \tag{5.20}$$

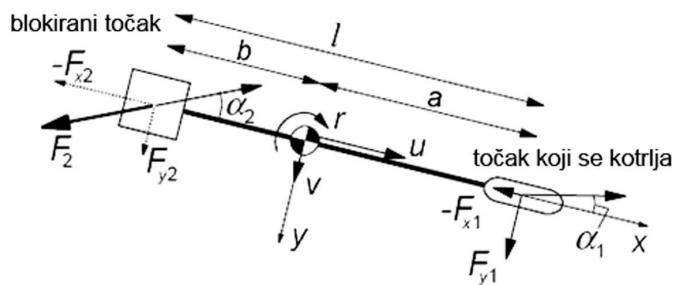
sa

$$\begin{aligned}
 \tan \alpha_1 &= -\frac{v + ar}{u} \\
 \tan \alpha_2 &= -\frac{v - br}{u}
 \end{aligned} \tag{5.21}$$

i

$$\begin{aligned}
 F_{y1} &= F_{y1}(\alpha_1, k_1, F_{z1}) \\
 F_{y2} &= F_{y2}(\alpha_2, k_2, F_{z2})
 \end{aligned} \tag{5.22}$$

Za odgovarajuću simulaciju kretanja, odgovarajući nivoi klizanja λ_i treba da rezultiraju iz ugaonih brzina točkova (ω_i), što prema [140] zahteva dodatni broj stepeni slobode. U ovom slučaju je iskorišćen alternativni pristup koji uključuje uvođenje funkcija za bočnu silu u kojima je uključena direktna zavisnost klizanja od veličine pritiska aktiviranja kočnica. To je moguće pod pretpostavkom da je između pneumatika i puta uspostavljen tzv. „suv“ trenje [140,143].



Slika 5.10. Tzv. model „bicikla“ sa jednim blokiranim točkom [140]

Kao što je prikazano na slici 5.10, pretpostavlja se da je točak na osovini 2 blokiran i da na točak na osovini 1 deluje moment kočenja. Najpre je razmatrana situacija bliska ravnomernom kretanju na pravcu. Pod pretpostavkom da su oba nivoa klizanja (u poprečnom i podužnom pravcu) mala dovodi do izraza za horizontalnu silu koja deluje na točak (u skladu sa slikom 5.10):

$$\begin{aligned}
F_{x1} &= -B_1 \\
F_{y1} &= F_{y1}(\alpha_1, B_1) \rightarrow C_1(B_1)\alpha_1 \\
F_{x2} &= -\mu F_{z2} \cos \alpha_2 \rightarrow -\mu F_{z2} \\
F_{y2} &= \mu F_{z2} \sin \alpha_2 \rightarrow \mu F_{z2} \alpha_2 = C_2 \alpha_2
\end{aligned} \tag{5.23}$$

U slučaju blokiranog točka figuriše i tzv. efektivna krutost zaokreta [140,143]:

$$C_2 = \mu F_{z2} = \mu \frac{a}{l} mg \tag{5.24}$$

Kao rezultat toga, jednačine (5.20 – 5.22) se svode na:

$$\begin{aligned}
m\ddot{u} &= -B_1 - \mu F_{z2} \\
m\dot{v} + \frac{1}{|u|}(C_1 + C_2)v + \left\{ mu + \frac{1}{|u|}(aC_1 - bC_2) \right\}r &= 0 \\
mk^2\dot{r} + \frac{1}{|u|}(a^2C_1 + b^2C_2)r + \frac{1}{|u|}(aC_1 - bC_2)v &= 0
\end{aligned} \tag{5.25}$$

Ako se uvede absolutna vrednost brzine u podužnom pravcu (u) u imenocima datih jednačina da bi se omogućilo razmatranje negativnih vrednosti te brzine, dok u isto vreme predznak α ostaje nepromenjen. Negativne vrednosti u odgovaraju slučaju blokiranih prednjih točkova [143].

Eliminacija brzine u poprečnom pravcu v iz jednačina (5.25) daje:

$$m^2 k^2 u^2 \ddot{r} + m \left\{ -k^2 B_1 + (a^2 + k^2)C_1 + b^2 C_2 \right\} u \dot{r} + \left\{ k^2 C_1 C_2 - mu |u| (aC_1 - bC_2) \right\} r = 0 \tag{5.26}$$

Primetno je da je u drugom koeficijentu (5.25) član $k^2 C_2$ nestao i da je dodat član $-k^2 B_1$. Uzrok tome je diferencijacija brzine u u procesu eliminacije brzine v . U drugom koeficijentu u jednačini (5.26) nalazi se član:

$$mk^2 \dot{u} \operatorname{sgn}(u) = -k^2 (\mu \frac{a}{l} mg + B_1) = -k^2 (C_2 + B_1) \tag{5.27}$$

koji objašnjava posmatrane promene. Takođe, može se formirati dodatna jednačina za brzinu u (ubacivanjem prve od jednačina iz izraza (5.25)) [133]:

$$u = u_o - \frac{1}{m} \left(\mu \frac{a}{l} mg + B_1 \right) \operatorname{sgn}(u) \cdot t \tag{5.28}$$

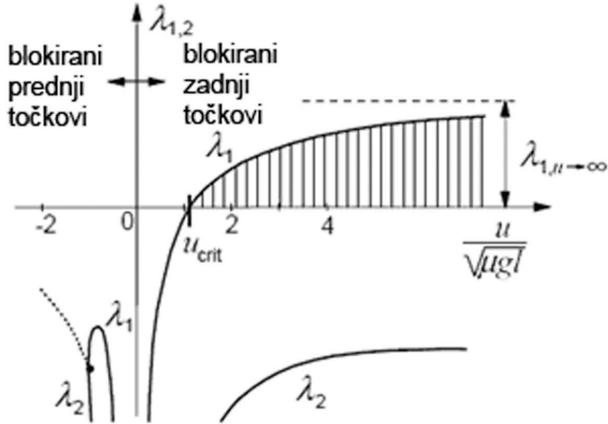
U situacijama kada je brzina u pozitivna točkovi zadnje osovine su blokirani. Blokiranje prednjih točkova, koje se javlja kada je u opisanom slučaju brzina $u < 0$ neće destabilizovati vozilo, ali će onemogućiti upravljanje vozilom. Do toga dolazi zbog činjenice da promena ugla upravljanja blokiranog točka ne može uticati na orijentaciju vektora odgovarajuće sile trenja u kontaktu sa podlogom. Vozilo sa blokiranim zadnjim točkovima odgovara po dinamičkom ponašanju slučaju preupravljanja, dok blokirani prednji točkovi mogu izazvati ekstremno povećanje podupravljanja [134,140]. Kritična brzina za slučaj blokiranih zadnjih točkova izvedena je izjednačavanjem trećeg koeficijenta jednačine (5.26) sa nulom. Korišćenjem jednačine (5.24) dobija se:

$$u_{crit} = \sqrt{\frac{\mu gl}{1 - \frac{\mu F_{Z1}}{C_1}}} \quad (5.29)$$

Iz ovog izraza može se videti da kada je u pitanju neelastični prednji pneumatik (tako da $C_1 \rightarrow \infty$) dobija se jednostavna formula: $u_{crit} = \sqrt{\mu gl}$. Uticaj elastičnog prednjeg pneumatika nije toliko veliki koliko krutost zaokreta prednjeg točka koja može da se kreće od 6 do 30 puta od normalnog opterećenja točka [133]. Razmatrajući suv put sa $\mu = 1$ dobija se kritična brzina od oko 20 km/h. U smislu ove veoma male brzine oko čije vrednosti vozilo sa blokiranim zadnjim točkovima postaje nestabilno i činjenicu da će brzina u normalnom slučaju biti dosta veća od kritične brzine u trenutku kada se aktiviraju kočnice, korisnije je razmatrati stepen nestabilnosti kao funkciju brzine. Zbog toga je neophodno prilagoditi koren λ_1 da bi se prikazao stepen nestabilnosti. Slika 5.11 prikazuje način na koji koreni variraju u zavisnosti od brzine kretanja. Dijagram uključuje slučaj blokiranih prednjih točkova ($u < 0$), pri čemu očigledno koreni ostaju negativni i postaju složeni pri većim brzinama kretanja (stvarni deo - isprekidana kriva). Kao praktični nagoveštaj stepena nestabilnosti može se iskoristiti visina horizontalne asimptote kojoj λ_1 teži kada $u \rightarrow 0$. U tom slučaju se dobija jednačina:

$$\lambda_1|_{u \rightarrow 0} = \sqrt{\frac{g}{l} \frac{ab}{k^2} \left(\frac{C_1}{F_{z1}} - \mu \right)} \quad (5.30)$$

kojom se dokazuje da nestabilnost raste kada je krutost zaokreta prednjeg pneumatika manja. Takođe postaje jasno da kada su prednji točkovi takođe blokirani dolazi do smanjenja stepena nestabilnosti na nultu vrednost [133,140].



Slika 5.11. Promena stepena stabilnosti u zavisnosti od brzine kretanja

Prema [57,133], postoji nekoliko poznatih empirijskih ili polu-empirijskih modela za opisivanje kontakta pneumatik-tlo u statičkim uslovima poput tzv. magične formule, modela izračunavanja prema tzv. NIRA dinamici, Burchardt-ovog modela, itd. Široko korišćen (prema nekim autorima polu-empirijski) model kontakta pneumatika i tla za izračunavanje sile trenja u statičkim uslovima zasniva se na takozvanoj „Magičnoj formuli“. Razvoj modela počeo je sredinom osamdesetih godina prošlog veka pri čemu je od tada razvijeno nekoliko verzija (Bakker 1987, 1989, Pacejka 1993). Kod ovih modela situacija kombinovanog klizanja modelirana je sa fizičkog aspekta [133]. Godine 1993. Michelin je uveo čisto empirijski model koristeći funkcije na osnovu tzv. Magične formule da bi opisao generisanje horizontalne sile koja deluje u kontaktu pneumatika i puta pri kombinovanom klizanju. Opšti oblik magične formule koji važi za date vrednosti vertikalnog opterećenja i položaja točka u odnosu na podužnu ravan vozila glasi:

$$y = D \sin[C \arctan\{B_x - E(B_x - \arctan B_x)\}] \quad (5.31)$$

sa dodatnim članovima:

$$Y(X) = y(x) + S_v \quad (5.32)$$

$$x = X + S_H \quad (5.33)$$

gde su:

Y : izlazne veličine (F_x , F_y ili M_z)

X : ulazne veličine ($\operatorname{tg}\beta$ ili λ)

i

B - faktor krutosti

C - faktor nagiba krive klizanja od 0 do maksimalne vrednosti koeficijenta prianjanja

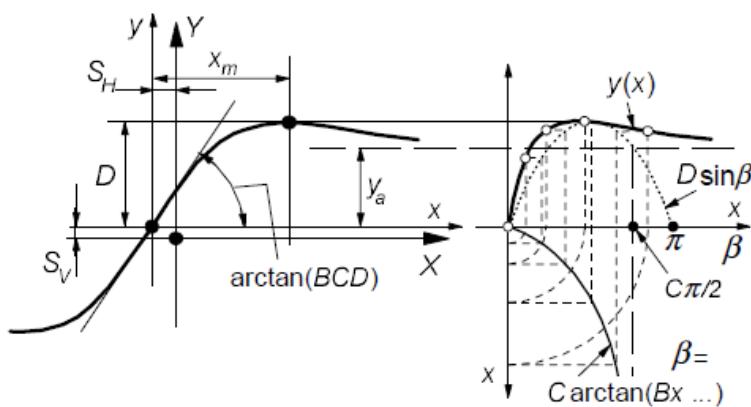
D - položaj maksimuma krive klizanja (maksimum koeficijenta prianjanja)

E - faktor zakrivljenosti krive klizanja

S_H - horizontalno odstupanje

S_V - vertikalno odstupanje

Magična formula $y(x)$ obično generiše (formira) krivu koja prolazi kroz koordinatni početak $x = y = 0$, dostiže maksimum, a zatim teži ka horizontalnoj asymptoti [133,140]. Za date vrednosti koeficijenata B , C , D i E kriva ima nesimetričan oblik u odnosu na osnovni. Da bi se omogućilo da kriva ima dozvoljeno odstupanje u odnosu na osnovni oblik, uvedene su dve vrednosti odstupanja S_H i S_V . Tada je neophodno uvesti novi set koordinata $Y(X)$ kao što je prikazano na slici 5.12.



Slika 5.12. Kriva formirana pomoću originalne sinusne verzije Magične formule

Formula poseduje mogućnost generisanja krivih klizanja koje su približnih osobina kao i merene krive za bočnu silu F_y i za silu u podužnom pravcu F_x kao funkcije njima odgovarajućih vrednosti klizanja: ugao klizanja β i podužno klizanje λ sa uključenim uticajem vertikalnog opterećenja F_z i ugla nagiba točka γ [140]. Slika 5.12 prikazuje pojašnjenje nekih faktora pod dejstvom bočne sile. Očigledno, koeficijent D predstavlja maksimalnu vrednost, odnosno maksimum krive klizanja (u odnosu na centralnu x-osu i za $C \geq 1$) i proizvod BCD koji odgovara nagibu krive na delu kod koordinatnog početka ($x = y = 0$). Faktor oblika C kontrolisce granice opsega sinusne funkcije pojavljujući se u formuli (5.31) i stoga određujući oblik rezultujuće krive. Faktor B ima zadatak da odredi nagib početnog dela krive i naziva se faktor krutosti. Faktor E je uveden da bi kontrolisao krivinu na maksimumu krive i u isto vreme horizontalnu poziciju vrha [133,140].

Faktor oblika C može biti izračunat na osnovu visine vrha i horizontalne asimptote:

$$C = 1 \pm \left(1 - \frac{2}{\pi} \arcsin \frac{y_a}{D} \right) \quad (5.34)$$

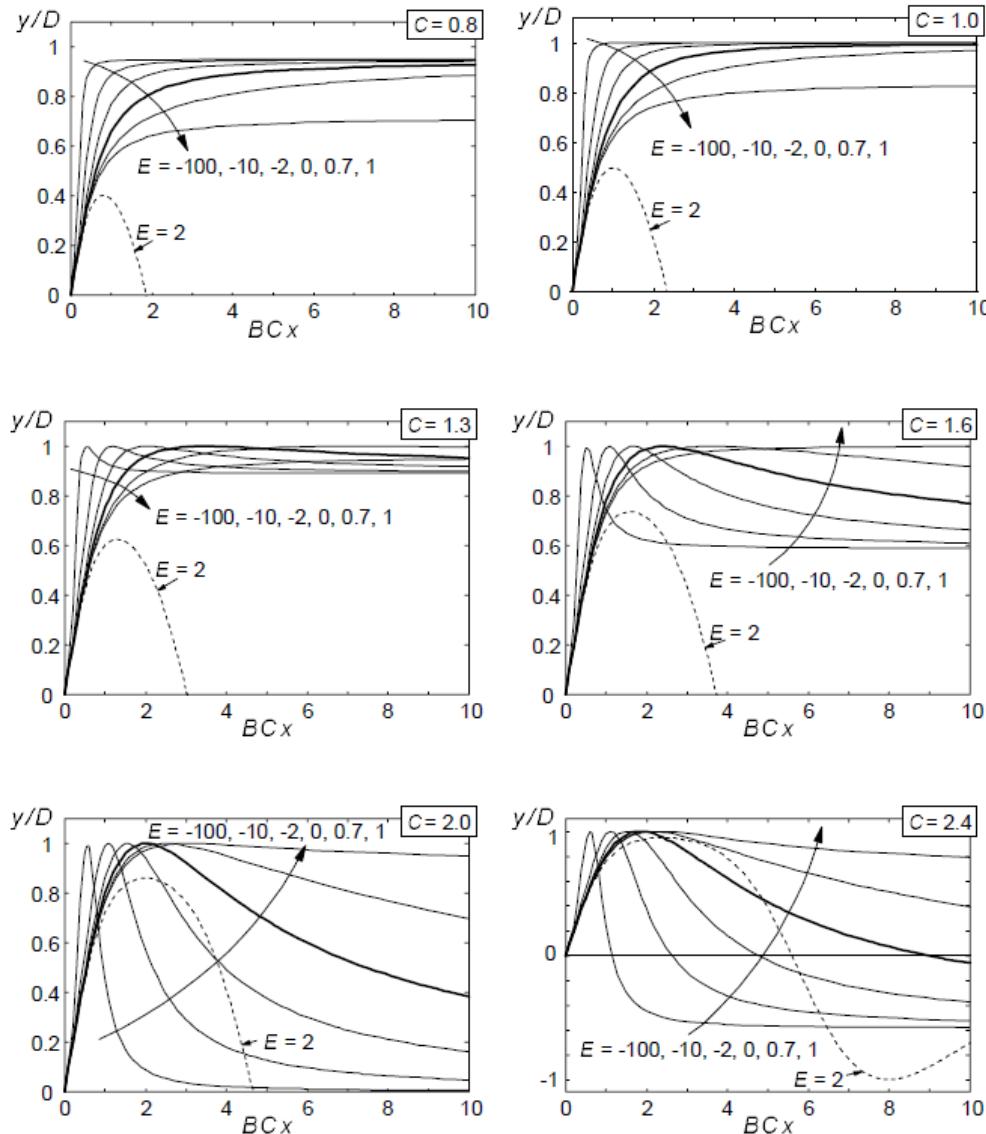
Vrednost faktora E može biti procenjena na osnovu faktora B i C i položaja vrha krive X_m :

$$E = \frac{Bx_m - \tan\{\pi/(2C)\}}{Bx_m - \arctan(Bx_m)} \quad \text{ako je } C > 1 \quad (5.35)$$

Odstupanja S_H i S_V se pojavljuju kao efekti uticaja varijacija elastičnosti pneumatika iz više razloga, kao i mogućeg postojanja otpora kotrljanja, što prouzrokuje da kriva ne prolazi kroz koordinatni početak. Bočni nagib točka u određenoj meri može povećati to odstupanje. Takva promena može biti ispraćena značajnom devijacijom od čisto nesimetričnog oblika originalne krive. Da bi se prilagodila takva asimetrija, faktor krive E napravljen je zavisnim od znaka apscise (x).

$$E = E_o + \Delta E \cdot \text{sgn}(x) \quad (5.36)$$

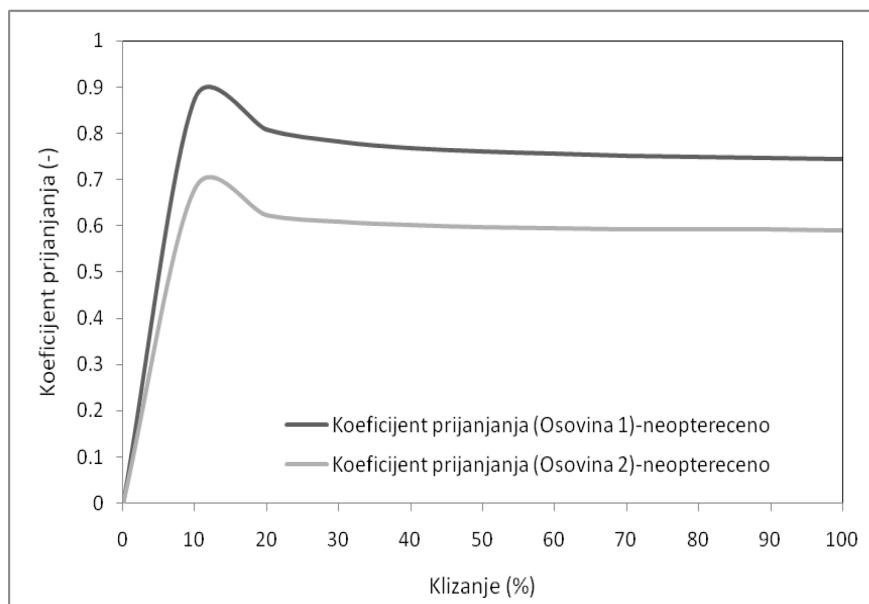
Na slici 5.13 prikazan je uticaj dva faktora oblika C i E pri formiranju krivih klizanja. Dijagrami su normalizovani deljenjem koordinate y sa D i množenjem koordinate x sa CB praveći nivo vrha krive i početni nagib nezavisnim od parametara C i E.



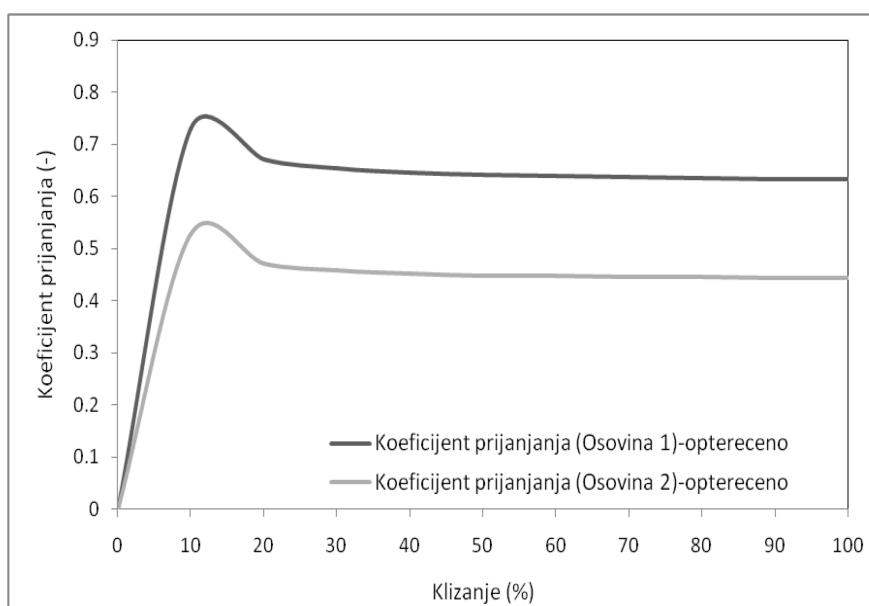
Slika 5.13. Uticaj faktora oblika C i E na oblik krive

Da bi se ilustrovali nedostaci primene ovakvog statičkog modela u dinamički promenljivim uslovima, na slikama 5.14 i 5.15 su prikazane odgovarajuće statičke krive klizanja točkova na prednjoj i zadnjoj osovini (za neopterećeno i opterećeno stanje vozila), koje su formirane primenom Pacejkine „magične formule“.

Parametri na osnovu kojih su formirane krive klizanja su izračunati pomoću izraza 5.32-5.35, a njihove vrednosti su date u tabeli 5.2. Kao što se vidi sa slike 5.14 i 5.15, formirane krive klizanja su previše idealizovane, odnosno predstavljaju osrednjeni prikaz stvarnih promena prijanjanja pri promeni klizanja. Međutim, u dinamičkim uslovima to nije slučaj, imajući u vidu ponekad izrazito dinamičke promene klizanja/koeficijenta prijanjanja u toku ciklusa kočenja.



Slika 5.14. Statičke krive klizanja (neopterećeno stanje vozila)



Slika 5.15. Statičke krive klizanja (opterećeno stanje vozila)

Tabela 5.2. Parametri „magične formule“

Stanje opterećenosti	Osovina	Parametar		
		B	C	D
Neopterećeno	1	0,232404	1,4	19372,58
	2	0,156505	1,4	26949,62
Opterećeno	1	0,178099	1,4	25366,21
	2	0,296253	1,4	28884,81

Pored Pacejkinog modela, u ovoj disertaciji je analiziran i statički model koji se zasniva na tzv. NIRA dinamici, detaljno objašnjen u [132,133,140]. Prema tom modelu, pretpostavka je da je za male vrednosti klizanja veza između sile i klizanja linearna:

$$F = k\lambda \quad (5.37)$$

Dalje se tvrdi da k ne zavisi samo od pneumatika nego i od trenja u kontaktu pneumatik-tlo. Koristeći Kalmanov filter, k može da se izračunava tokom vožnje. Ako se promena vrednosti k uoči algoritam će to osetiti kao promenu u trenju. Najteži deo u ovom pristupu je kalibracija. Klizanje ponekad ima odstupanje, zaviseći od malih promena dinamičkog poluprečnika točka. Da bi se kompenzovalo ovo odstupanje, izračunavanje se vrši preko izraza [140]:

$$\lambda = [F \quad 1] \begin{bmatrix} \frac{1}{\lambda} \\ \delta \end{bmatrix} + e(t) \quad (5.38)$$

Značajna odlika ovog pristupa je da izračunavanje trenja radi zajedno sa kalkulatorom varijansi. Varijansa dinamičkog poluprečnika pneumatika se izračunava i pokazuje značajnu razliku između različitih vrsta podloga.

Model kontakta pneumatik-tlo predstavljen od strane Burchardt-a 1993. godine je izведен putem slične metodologije kao kod „magične formule“, gde je koeficijent prijanjanja φ izražen kao funkcija klizanja točka u podužnom pravcu λ i brzine vozila v [57,133]. Vertikalna sila koja deluje na točak se smatra konstantnom, što daje izraz:

$$\varphi_x(\lambda, v) = (C_1(1 - e^{-C_2\lambda}) - C_3\lambda)e^{-C_4\lambda v} \quad (5.39)$$

Gde su C_1 , C_2 , C_3 i C_4 parametri koji zavise od vrste i stanja podloge. Pojedinačno, ovi parametri se odnose na:

C_1 – maksimalna vrednost krive klizanja

C_2 – parametar oblika krive klizanja

C_3 – razlika između maksimalne vrednosti na krivoj i vrednosti pri $\lambda = 1$

C_4 – parametar zakrivljenosti koji se nalazi u opsegu 0,02-0,04 s/m

Kiencke i Daib su 1996. godine predstavili uprošćeni Burchardt-ov model sa linearnim parametrima a i b [57]:

$$\varphi(\lambda) = \frac{k\lambda}{a\lambda^2 + b\lambda + 1} \quad (5.40)$$

gde je k početni faktor oblika (pri $\lambda = 0$).

U skladu sa [57,140,143], dinamički modeli se uglavnom koriste za opisivanje specijalnih slučajeva stanja u kontaktu pneumatik-tlo. Uvedeni su pri modeliranju kontakta pneumatika i tla za opisivanje dinamičkih procesa kada na točak deluje moment kočenja. Oni takođe razmatraju zavisnost brzine od trenja. Prema [57], dinamički modeli kontakta pneumatik-tlo se baziraju se na dva pristupa: grupnom (Canudas de Wit, Olsson, Astrom i Lischinsky, 1995.) i distributivnom (Canudas de Wit, Horowitz i P. Tsotras). Grupni model podrazumeva kontakt pneumatika i puta u jednoj tački, dok distributivni podrazumeva postojanje površine po kojoj se ostvaruje kontakt između pneumatika i puta. Grupni pristup je opisan preko:

$$\dot{z} = v_r - \frac{\sigma_0 |v_r|}{g(v_r)} z \quad (5.41)$$

$$F_x = (\sigma_0 z + \sigma_1 \dot{z} + \sigma_2 v_r) F_z \quad (5.42)$$

$$g(v_r) = \mu_c + (\mu_s - \mu_c) e^{-\sqrt{|v_r/v_s|}} \quad (5.43)$$

Gde su:

F_x - sila trenja

F_z - vertikalna sila

σ_0 - ukupna krutost pneumatika u podužnom pravcu

σ_1 - koeficijent apsorpcije vibracija u podužnom pravcu

σ_2 - koeficijent relativne viskoznosti materijala pneumatika

μ_C - normalizovano Kulonovo trenje

μ_S - normalizovano statičko trenje

v_S - Štribekova relativna brzina

v_r - relativna brzina ($= r\omega - v$)

z - tzv. unutrašnje trenje (prosečna vrednost deformacije)

Kod ovog modela postoji dinamička veza između brzine klizanja i deformacije pneumatika [57]. U distributivnom pristupu, z zavisi od pozicije u kontaktnom području, ali u grupnoj realizaciji z označava prosečnu vrednost deformacije u celom kontaktnom području. Grupni oblik mora biti korišćen za potrebe kontrole i izračunavanje, ali da bi smo bili u stanju da uspostavimo vezu sa σ -parametrima u jednačinama sa eksperimentalnim podacima, mora biti korišćena statička verzija distributivnog pristupa. Takva procedura prema [57] kao krajnji rezultat ima sledeći izraz:

$$F_x(s) = \text{sign}(v_{sx}) F_z g(v_{sx}) \left(1 + \left(1 - \frac{\sigma_1 |v_{sx}|}{g(v_{sx})} \right) \frac{g(v_{sx})}{\sigma_0 2a |\lambda|} \left(e^{\frac{\sigma_0 2a |\lambda|}{g(v_{sx})}} - 1 \right) \right) + F_z \sigma_2 v_{sx} \quad (5.44)$$

gde je $2a$ dužina kontaktne zone. Postoji šest parametara koji moraju biti identifikovani u ovoj formuli. U [131,132] je dokazano da se može napraviti izgled krive vrlo sličan obliku dobijenom pomoću „magične formule“.

5.5. DINAMIČKO ODREĐIVANJE POLOŽAJA TRENUTNOG MAKSIMUMA KRIVE KLIZANJA

Krive klizanja datog vozila (autobusa) u neopterećenom i opterećenom stanju mogu biti određene na osnovu eksperimentalno dobijenih podataka. Analize dinamičkog ponašanja točka prikazane u [117,133,140], koje se odnose na točak koji se slobodno kotrlja, polaze od pretpostavke da se komponenta brzine točka u podužnom pravcu v_x (podužna komponenta vektora ukupne brzine centra točka v) i ugaona brzina točka ω_0 mogu dobiti merenjem. Deljenjem ove dve veličine može se odrediti tzv. efektivni radijus obrtanja r_e :

$$r_e = \frac{v_x}{\omega_0} \quad (5.45)$$

Kao što je već objašnjeno u poglavlju 4, dinamičko određivanje trenutne vrednosti klizanja točka u cilju stvaranja preduslova za precizno upravljanje klizanjem, odnosno održavanje njegove vrednosti na željenom nivou je veoma važno. U [135] je pokazano da izračunavanje vrednosti klizanja u realnom vremenu koje odgovara maksimumu krive klizanja može obezbediti pouzdane informacije o njegovoj trenutnoj vrednosti sistemu za upravljanje klizanjem u kontaktu pneumatika i puta. Pošto dinamička kriva zavisnosti koeficijenta prianjanja od klizanja tokom kočenja može biti predstavljena u obliku $\varphi(\lambda) = \varphi(\lambda, \varphi_m, \beta)$, to predstavlja osnovu za prikupljanje podataka koji su pogodni za dinamičko izračunavanje koeficijenta prianjanja i identifikaciju trenutnog položaja maksimuma krive klizanja, tj. $\varphi - \lambda$ krive. Na taj način je moguće odrediti krivu klizanja u realnom vremenu, a na osnovu izmerenih vrednosti broja obrtaja točka (na osnovu koga se izračunava njegova ugaona, odnosno translatorna brzina v_t), brzine kretanja vozila (v), usporenja vozila u podužnom pravcu (a), kao i izračunatog translatornog usporenja točka (a_t), odnosno ugaonog usporenja točka (α). Trenutna vrednost klizanja može biti određena u skladu sa jednačinom 5.18 na osnovu brzine vozila i ugaone brzine točka (translatorne brzine točka), znajući vrednost dinamičkog poluprečnika točka:

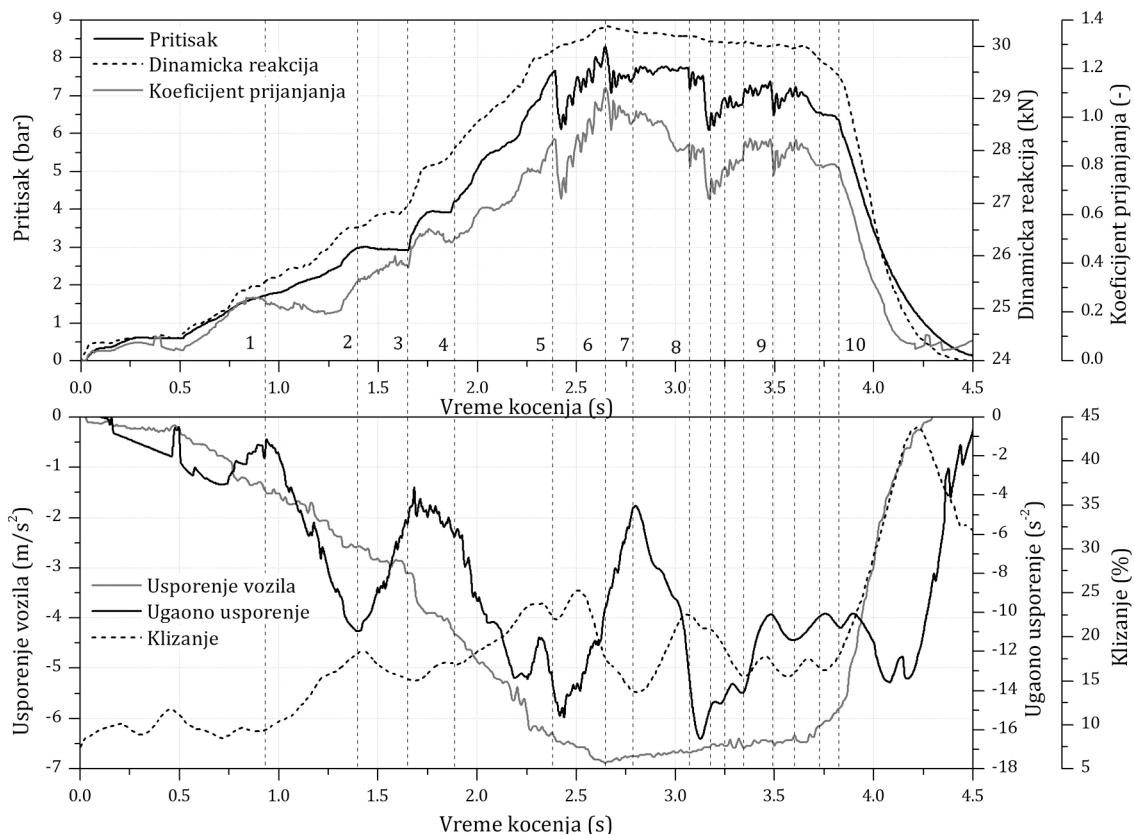
$$\lambda = \frac{(v - \omega r_d)}{v} \quad (5.46)$$

Vrednost translatornog usporenja točka u datom trenutku može biti određena u skladu sa jednačinom 5.16. Na osnovu te vrednosti, koeficijent prijanjanja u datom trenutku se može izračunati u skladu sa jednačinom 5.17. Na taj način moguće je jednostavnije dinamički odrediti krivu klizanja za dato stanje opterećenosti vozila, odnosno identifikovati pri kojoj vrednosti klizanja točka koeficijent prijanjanja dostiže maksimalnu vrednost tokom ciklusa kočenja.

Dinamičko određivanje stanja u kontaktu pneumatika i puta, odnosno određivanje dinamičke krive klizanja, je izvršeno u ovoj doktorskoj disertaciji pomoću postupka opisanog u poglavlju 5.3 u cilju obezbeđivanja preduslova za upravljanje performansama kočnog sistema tokom ciklusa kočenja. To je izuzetno važno za poboljšanje performansi kočnih sistema privrednih vozila tokom procesa kočenja. Pri tome treba imati u vidu da je u pitanju računski dobijena vrednost koeficijenta prijanjanja, koja predstavlja približenje, ali nije apsolutno tačna. Na primeru dva ciklusa kočenja prikazanih na slikama 5.16 i 5.18 uporedno su prikazane dinamičke promene koeficijenta prijanjanja i klizanja u kontaktu pneumatik-tlo u toku ciklusa kočenja. Uporedno su prikazane i dinamičke promene merenih/izračunatih veličina u toku ciklusa kočenja i na osnovu toga je izvršena analiza kakav uticaj imaju te promene na promenu koeficijenta prijanjanja i/ili klizanja točka u kontaktu sa površinom puta. Na slici 5.16 je prikazan ciklus kočenja koji se odnosi na neopterećeno stanje vozila, dok se ciklus na slici 5.18 odnosi na opterećeno stanje vozila. Oba izabrana ciklusa se odnose na točak prednje osovine. U gornjem delu slika 5.16 i 5.18 su prikazane dinamičke promene pritiska aktiviranja kočnice na prednjoj osovini, odgovarajuće dinamičke reakcije i koeficijenta prijanjanja (određenog pomoću izraza 5.17). U donjem delu slika su prikazane odgovarajuće promene klizanja u podužnom pravcu, usporenja vozila i ugaonog usporenja točka (izračunatog pomoću jednačine 5.12). Odgovarajuće dinamičke krive klizanja su prikazane na slikama 5.17 i 5.19, respektivno.

Na osnovu dinamičke promene pritiska aktiviranja kočnice (slika 5.16) uočljivo je da je između 2,4-3,8 s kočenja došlo do aktiviranja ABS sistema. Na toj slici je

obeleženo deset najinteresantnijih vremenskih trenutaka u kojima su identifikovane karakteristične promene posmatranih veličina. Pored toga što su promene klizanja i ugaonog usporenja točka u toku ciklusa kočenja veoma kompleksne, evidentno je da one dešavaju naglo i u veoma kratkom vremenskom periodu, što ukazuje na to da njihovo dinamičko praćenje tokom ciklusa kočenja nije ni malo lak zadatak. Kao što se može videti sa slike 5.16, porast pritiska aktiviranja za 1,5 bar od početka kočenja pa do trenutka obeleženog sa 1 izaziva skoro konstantno povećanje ugaonog usporenja točka tokom prvih 0,7 s, a zatim ono opada do trenutka 1 za 3 s^{-2} . U tom kratkom intervalu ciklusa dinamička reakcija na prednjem točku ima veći gradijent porasta, što je uticalo na blago povećanje koeficijenta prijanjanja, odnosno na smanjenje klizanja točka. Dalje povećanje pritiska na 3 bar do trenutka 2 je uslovilo povećanje ugaonog usporenja točka sa 1,5 na 11 s^{-2} , što je uticalo na to da se klizanje u tom intervalu poveća za 9% (slika 5.16). Za to vreme, odgovarajuća vrednost koeficijenta prijanjanja blago opada. Između trenutaka 2 i 3, pritisak ima vrlo blag opadajući trend što izaziva pad klizanja i ugaonog usporenja točka na 4 s^{-2} i veoma blago povećanje koeficijenta prijanjanja.

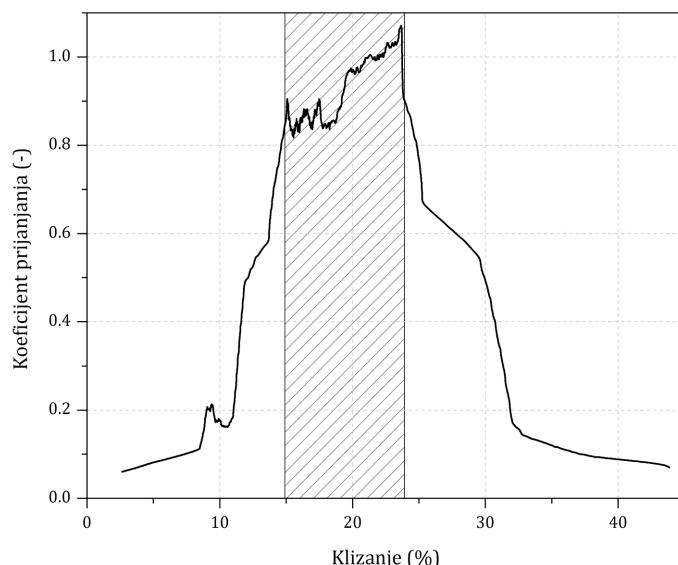


Slika 5.16. Dinamička promena merenih/izračunatih veličina (neopterećeno stanje)

Od trenutka 3 do trenutka 5, veliki gradijent porasta pritiska je izazvao situaciju da zajedno sa njim naglo rastu i ugaono usporenje i klizanje točka (slika 5.16), pri čemu je njihov gradijent porasta izrazito veći od trenutka 4. Do tog trenutka koeficijent prijanjanja takođe raste. U trenutku 5 ugaono usporenje točka je dostiglo vrednost $15,2 \text{ s}^{-2}$ pa je u skladu sa tim i klizanje naglo poraslo na 25%, što je ABS sistem prepoznao kao pretendovanje točka da blokira i smanjio pritisak za 1,5 bar. Posledica toga je prvo manje smanjenje ugaonog usporenja/klizanja, odnosno kratko smanjenje a zatim povećanje koeficijenta prijanjanja do trenutka 6. U tom trenutku je usledila još jedna intervencija ABS-a (smanjenje pritiska za 1 bar) do trenutka 7, što za posledicu ima još veće smanjenje ugaonog usporenja i klizanja (slika 5.16). U tom trenutku je dostignut lokalni maksimum koeficijenta prijanjanja, a takođe i maksimum intenziteta dinamičke reakcije, dok je ugaono usporenje točka palo na vrednost od 5 s^{-2} . Do trenutka 8, EBS sistem je održavao pritisak na približno konstantnoj vrednosti, ali koeficijent prijanjanja ima opadajući trend pa je to dovelo do naglog povećanja klizanja i ugaonog usporenja

točka, koje je u tom delu ciklusa dostiglo maksimum od $16,5 \text{ s}^{-2}$. Da bi sprečio blokiranje točka, ABS je još dva puta korigovao (smanjio) vrednost pritiska neposredno posle trenutka 8 i u trenutku 9. To je dovelo do zaustavljanja trenda opadanja koeficijenta prijanjanja, a samim tim i do održavanja ugaonog usporenja/klizanja točka u uskim granicama i na nižim vrednostima sve do trenutka 10, kada je pritisak počeo da se smanjuje do nule usled prestanka dejstva vozača na komandu sistema za radno kočenje (slika 5.16).

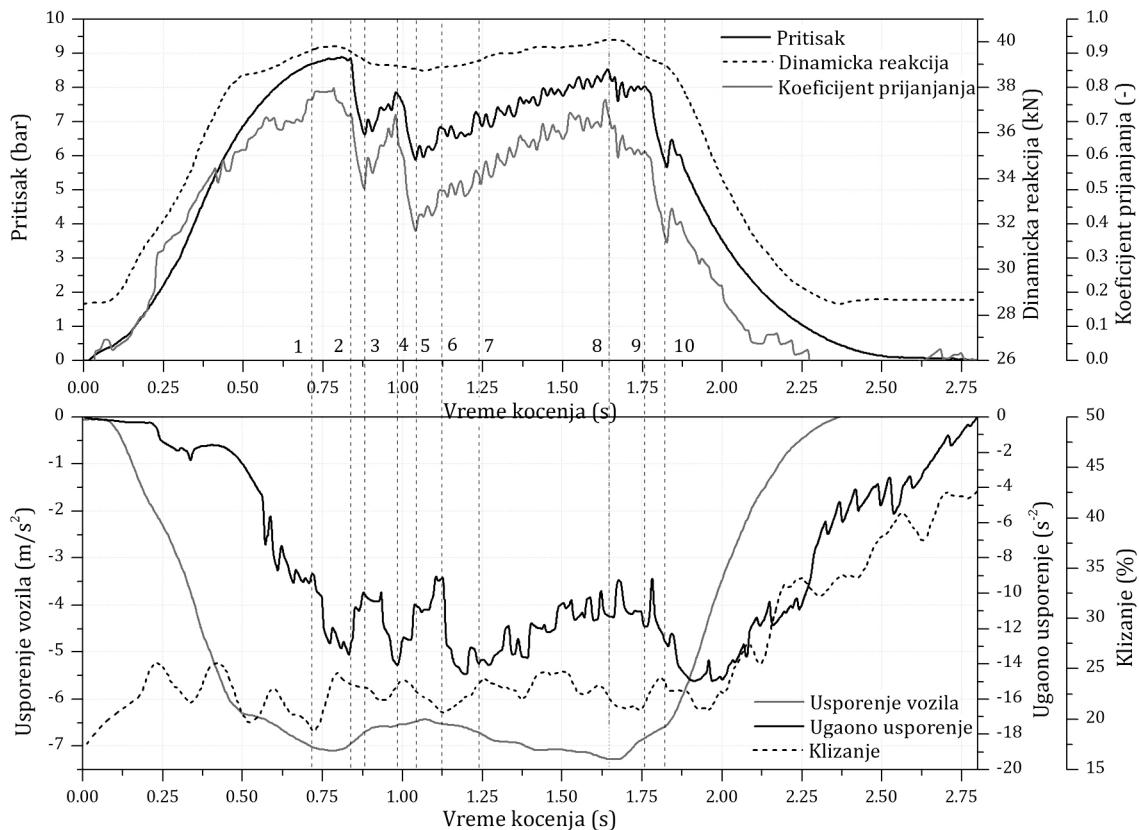
Na slici 5.17, koja prikazuje odgovarajuću krivu klizanja za ovaj ciklus, može da se preglednije isprati zavisnost između promene koeficijenta prijanjanja i klizanja koja je prikazana u toku ciklusa kočenja na slici 5.16. Na osnovu formirane dinamičke krive klizanja, u zoni između 15-24% klizanja koeficijent prijanjanja ima maksimalne vrednosti, što je u skladu sa dinamičkim promenama prijanjanja i klizanja prikazanim na slici 5.16.



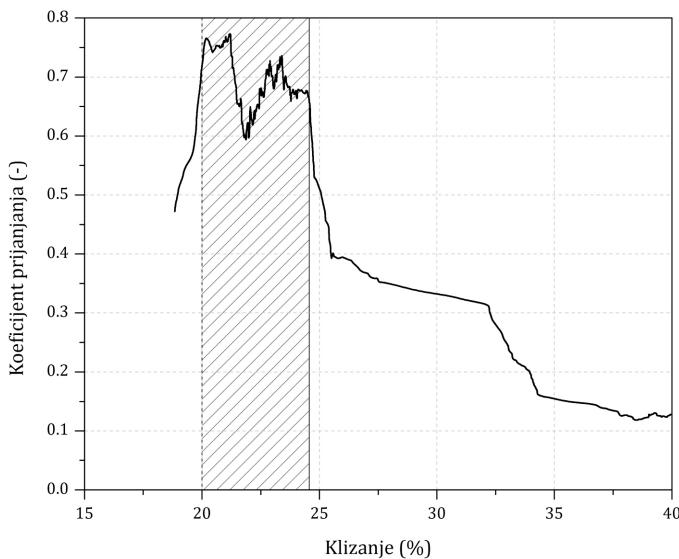
Slika 5.17. Dinamička kriva klizanja za ciklus kočenja sa slike 5.16

U slučaju ciklusa kočenja prikazanog na slici 5.18, koji se odnosi na opterećeno stanje vozila, dinamička promena koeficijenta prijanjanja tokom ciklusa kočenja u zavisnosti od promene pritiska, dinamičke reakcije, ugaonog usporenja točka i klizanja ima veoma sličan karakter. Vidna razlika u odnosu na prethodno analizirani slučaj (slika 5.16) odnosi se na to da je nivo klizanja točka u kontaktu sa podlogom veći u proseku za 10% tokom čitavog ciklusa kočenja. Karakteristične

vrednosti pritiska/ugaonog usporenja/klizanja su u trenucima obeleženim sa 2, 4, 8 i 9 (slika 5.18). U ta četiri karakteristična trenutka ABS je intervenisao i naglo smanjivao pritisak kako bi sprečio blokiranje točka jer je ugaono usporene točka, odnosno klizanje počelo naglo da se povećava. Sa slike 5.18 se vidi da je maksimum prijanjanja u toku ciklusa postignut između trenutaka 1 i 2. U tom intervalu, klizanje se kretalo u zoni 20-24%. ABS je dalje sve do trenutka 10 vršio korekcije pritiska tako da se u tom intervalu klizanje približno kretalo unutar ove zone. Navedene zaključke potvrđuje i odgovarajuća dinamička kriva klizanja koja je formirana za ovaj ciklus (slika 5.19). Maksimalne vrednosti koeficijenta prijanjanja se nalaze upravo u ovoj zoni između 20-24% podužnog klizanja.



Slika 5.18. Dinamička promena merenih/izračunatih veličina (opterećeno stanje)

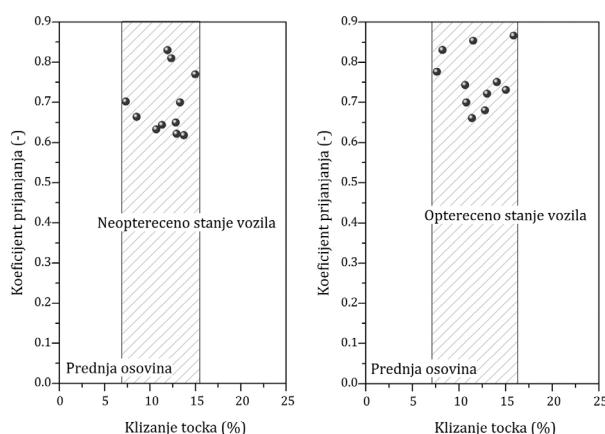


Slika 5.19. Dinamička kriva klizanja za ciklus kočenja sa slike 5.18

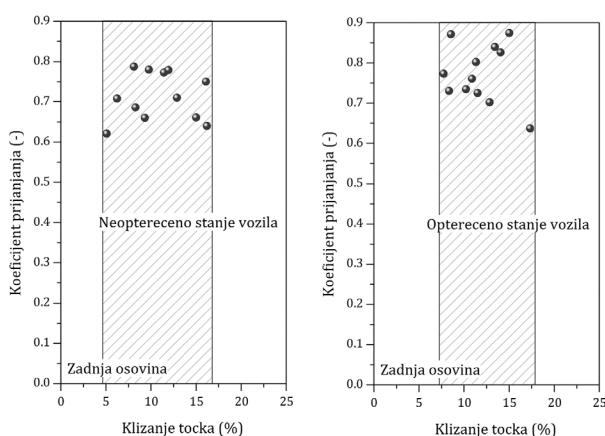
Važno je da se napomene da ovako dobijena dinamička kriva klizanja važi samo za posmatrani ciklus kočenja, trenutni režim kočenja, dato stanje opterećenosti vozila i date uslove u kontaktu pneumatik-tlo. U nekim drugim uslovima (promena vrste/stanja podloge, promena pneumatika i/ili nagiba puta na primer) doći će do pomeranja trenutnog maksimuma krive klizanja na levo ili na desno, tj. klizanje pri kome je raspoloživo maksimalno prijanjanje neće biti isto.

Slika 5.20 prikazuje položaje maksimuma krivih klizanja određenih za točak prednje osovine, tj. maksimalne vrednosti koeficijenta prijanjanja u kontaktu pneumatika prednjeg točka i tla u zavisnosti od podužnog klizanja točka i to za neopterećeno i opterećeno stanje vozila. Krive klizanja su određene tokom kočenja na pravcu, na suvoj asfaltnoj podlozi i sa uključenom spojnicom. Rezultati prikazani na slici 5.20 su dobijeni na osnovu izabranih po 12 ciklusa kočenja za oba stanja opterećenosti vozila. Evidentno je da vrednost podužnog klizanja pri kojoj je dostupna maksimalna vrednost koeficijenta prijanjanja varira u opsegu između 6-16% za neopterećeno stanje vozila i između 6-17% za opterećeno stanje vozila. Na slici 5.21 su prikazani položaji maksimuma krivih klizanja određenih za točak zadnje osovine u slučaju neopterećenog i opterećenog vozila. Kao i u prethodnom slučaju, izabran je uzorak od po 12 ciklusa kočenja za oba stanja opterećenosti vozila. I u jednom i u drugom slučaju (slike 5.20 i 5.21), analizom nisu obuhvaćeni ciklusi pri kojima je došlo do aktiviranja ABS-a. Vrednost podužnog klizanja pri

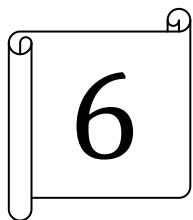
kojoj je dostupna maksimalna vrednost koeficijenta prijanjanja varira u opsegu između 4-17% za neopterećeno stanje vozila i između 7-18% za opterećeno stanje vozila. Treba napomenuti da to važi za date radne režime kočnice, trenutno važeće uslove u kontaktu pneumatik-tlo, karakteristike ugrađenog EBS-a, kao i karakteristike pneumatika i puta. Ovakva divergentnost maksimalno dostupnog prijanjanja u odnosu na različite uslove kočenja ukazuje na to zbog čega je suštinski važno da sistem za inteligentno upravljanje performansama kočnog sistema ima sposobnost da prepozna trenutni položaj maksimuma krive klizanja, koji se dinamički menja u toku datog ciklusa kočenja. Sa takvim mogućnostima, sistem bi bio u stanju da omogući postizanje vrednosti podužnog klizanja točka koja odgovara maksimumu koeficijenta prijanjanja tokom čitavog ciklusa kočenja.



Slika 5.20. Položaji maksimuma krivih klizanja za različite režime kočenja (prednja osovina)



Slika 5.21. Položaji maksimuma krivih klizanja za različite režime kočenja (zadnja osovina)



VEŠTAČKA INTELIGENCIJA

6.1. POJAM VEŠTAČKE INTELIGENCIJE

6.1.1. Uvod

Prema [145-153], veštačka inteligencija predstavlja mešavinu konvencionalne nauke, fiziologije i psihologije, sve u cilju da se napravi mašina koja bi se, po ljudskim merilima, mogla smatrati „intelligentnom“. U širem smislu, mogućnost stvaranja intelligentnih uređaja zaokuplja ljudsku maštu još od drevnih vremena, ali tek sada, sa brzim tempom razvoja računara i već pedesetogodišnjim iskustvom na polju istraživanja tehnika programiranja, san o pametnim mašinama počeo je da postaje stvarnost. Naučnici su konačno sposobni da stvore sisteme koji razumeju govor i mogu da pobede najbolje igrače šaha, dok je hardver sa elementima veštačke inteligencije već isprobani u oružanim sukobima (sistemi krstarećih projektila) [145,147]. Međutim i pored svog napretka, naučnici se još uvek nisu uhvatili u koštac sa osnovnim izazovom u razvoju intelligentne mašine – pravljenjem sistema koji oponašaju ljudski mozak. Ljudski mozak sa više milijardi neurona predstavlja možda i najsloženiju tvorevinu u univerzumu [145].

Za pojam inteligencije suštinska su dva pitanja: pitanje znanja i pitanje zaključivanja, koja, kada se govori o računarima, odgovaraju pojmovima baze znanja i komponente zaključivanja. Komponenta zaključivanja (izvođenja) predstavlja takođe neku vrstu znanja - to je znanje o procesu izvođenja novih informacija iz date baze znanja i o pravilima po kojima se to izvođenje vrši. Znanje ovog tipa se može nazvati meta-znanjem. Sam pojam znanja, takođe ima više aspekata. Po mnogim filozofskim koncepcijama znanje predstavlja tvrđenje za koje je utvrđeno ili može biti utvrđeno da je tačno. Ipak, često postoji potreba za radom i sa informacijama koje ne moraju da budu tačne, pa je bolje prihvatići širi pojam

znanja i pod njim podrazumevati i istinite, potvrđene činjenice, ali i hipoteze, nepotpune informacije i informacije date sa određenim verovatnoćama. Izbor reprezentacije znanja je jedan od ključnih problema i on je u direktnoj vezi i sa prirodom određenog znanja, ali i sa prirodom mehanizama za zaključivanje [147]. Mehanizmi za zaključivanje moraju biti prilagođeni reprezentaciji znanja i njegovoj prirodi, pa će u jednom slučaju biti zasnovani na klasičnoj logici, a u drugom na teoriji verovatnoće, fazi logici, itd. Zaključivanjem se može smatrati proces po kojem se na osnovu baze znanja može izvesti informacija koja u njoj nije eksplicitno sadržana [145,148,149]. Veoma čest slučaj predstavlja susretanje sa problemima kod kojih je teško precizno zasnovati proces zaključivanja koji odgovara čovekovom. To dovodi do potrebe traganja za sofisticiranim tehnikama koje odgovaraju tim zahtevima [145].

Savremena teorija predstavlja veštačku inteligenciju u modernijem svetu [147,149,151]. Prema toj teoriji veštačka inteligencija je podoblast informatike. Cilj istraživanja veštačke inteligencije je razvijanje programa (softvera), koji bi omogućio računarima da se ponašaju na način koji bi se mogao okarakterisati intelligentnim. Prva istraživanja se vežu za same korene računarstva. Ideja o stvaranju mašina koje će biti sposobne da obavljaju različite zadatke intelligentno, bila je centralna preokupacija naučnika računarstva koji su se opredelili za istraživanje veštačke inteligencije tokom cele druge polovine XX veka. Danas, istraživanja u veštačkoj inteligenciji su konstantno orijentisana na stvaranje generalno intelligentnih, autonomnih sistema upravljanja [151]. Veštačka inteligencija kao pojam u širem smislu, označava kapacitet jedne veštačke tvorevine za realizovanje funkcija koje su karakteristika ljudskog razmišljanja. Mogućnost razvoja slične tvorevine je budila interesovanje ljudi još od antičkog doba. Ipak, tek u drugoj polovini XX veka takva mogućnost je dobila prva oruđa (računare), koja otvaraju put za taj poduhvat.

Napretkom moderne nauke, istraživanje veštačke inteligencije se odvija u dva pravca: psihološka i fiziološka istraživanja prirode ljudskog uma i tehnološki razvoj sve složenijih informatičkih sistema [151,152]. Istraživanja u vezi sa veštačkom inteligencijom su fokusirana na sledeće komponente inteligencije:

učenje, razmišljanje, rešavanje problema, percepciju i korišćenje jezika [150,151,152].

6.1.2. Učenje

U skladu sa [151,152], postoji više različitih oblika učenja koji su primjenjeni u oblasti veštačke inteligencije. Najjednostavniji se odnosi na učenje na greškama, preko pokušaja. Prilikom pokušaja implementacije, odnosno tzv. uopštavanja, javljaju se veći problemi i zahtevi. Uopštavanje se sastoji od primene prošlih iskustava na analogne nove situacije.

Deduktivno zaključivanje, vođeno zakonima logike, može se smatrati osnovnom karakteristikom intelligentnog ponašanja. Ovakvo zaključivanje jedan je od osnovnih načina zaključivanja kod ljudi. Druga karakteristika intelligentnog ponašanja koja se može primetiti i kod životinja je prilagođavanje ponašanja jedinke okolini u kojoj se ona nalazi. Kroz evolutivne procese, prilagodljivost se postiže i kod nižih organizama, ali je ova sposobnost sa tačke gledišta veštačke inteligencije posebno zanimljiva kod životinja i ljudi kod kojih se manifestuje u toku života jedinke. Kod njih se prilagođavanje postiže učenjem na osnovu primera iz iskustva i primenom naučnog znanja u sličnim situacijama u budućnosti. Primera radi, za živi organizam je značajno da uoči ključne karakteristike neke situacije ili skupa situacija u kojima preduzimanje neke akcije dovodi do poželjnih odnosno nepoželjnih posledica po organizmu. Prepoznavanje sličnih situacija u budućnosti omogućava organizmu da preduzimanjem adekvatne akcije u situaciji u kojoj se nalazi predupredi ishode nepovoljne po njega ili dovede do ishoda koji su za njega povoljni. Apstraktnije razmatrano, moguće je govoriti o donošenju zaključaka o nepoznatim slučajevima, na osnovu znanja o nekim drugim, poznatim, slučajevima. Proces u kome se znanje koje važi za neki skup slučajeva prenosi na neki njegov nadskup, naziva se generalizacijom ili induktivnim zaključivanjem. Koncept generalizacije je direktno povezan sa konceptom apstrakcije [145,150].

Za jednostavan primer generalizacije može se uzeti sledeća situacija. Sistem koji prepozna rukom pisani tekst bi na osnovu nekoliko primera mogao da zaključi da se broj 0 piše kao elipsa ili krug koji prilikom pisanja mogu eventualno biti malo

otvoreni. U ovom slučaju, generalizacija je korektna. Za razliku od deduktivnog zaključivanja, proces generalizacije ne pruža garancije da su zaključci ispravni. Iako zaključci dobijeni generalizacijom ne moraju biti tačni, induktivno zaključivanje je i dalje veoma značajno. To je jedan od osnovnih načina za formiranje predstava o okruženju, situacijama ili uzročno posledičnim odnosima ili u formalnim okvirima, odnosno za pravljenje modela podataka iz iskustva. Ukoliko su u nekom domenu greške u zaključivanju prihvatljive, algoritmi induktivnog zaključivanja omogućavaju zaključivanje i bez temeljnog poznavanja i kompletног formalnog opisivanja domena na koji se primenjuju. Takođe, mogu biti efikasniji od algoritama deduktivnog zaključivanja [153].

U skladu sa [145,147], postoje dve glavne formulacije problema učenja:

- ✓ Nadgledano učenje je pristup problemu učenja koji se odnosi na situacije u kojima se algoritmu zajedno sa podacima iz kojih uči daju i željeni izlazi. Algoritam treba da nauči da za date podatke (ne nužno trening podatke) pruži odgovarajuće izlaze.
- ✓ Nenadgledano učenje je pristup problemu učenja koji se odnosi na situacije u kojima se algoritmu koji uči pružaju samo podaci bez izlaza. Od algoritma koji uči očekuje se da sam uoči neke zakonitosti u podacima koji su mu dati.

Naravno, ovi drastično različiti pristupi se ne odnose na iste vrste problema. Primer nadgledanog učenja je već pomenuta klasifikacija kod koje su unapred poznati primeri za različite klase. Takav je slučaj sa prepoznavanjem računarskih članaka. Primer nenadgledanog učenja je tzv. *klasterovanje* - uočavanje grupa na neki način sličnih objekata kada ne postoji prethodno znanje o tome koliko grupe postoji ili koje su njihove karakteristike.

6.1.3. Podaci

Prirodno je da svako učenje polazi od nekih podataka. Podaci na osnovu kojih se vrši generalizacija, nazivaju se *podacima za obuku (trening)*, a njihov skup *trening skup*. Testiranje naučenog znanja na podacima na osnovu kojih je učeno obično dovodi do značajno boljih rezultata od onih koji se mogu kasnije dobiti u

primenama. Stoga je pre upotrebe potrebno proceniti kvalitet naučenog znanja. To se obično radi tako što se razmatra koliko je naučeno znanje u skladu sa nekim unapred datim *podacima za testiranje*. Podaci za testiranje čine *test skup*. Test skup treba da bude disjunktan sa trening skupom. Često se prilikom konstrukcije sistema koji uključuje učenje raspolaže ograničenom količinom podataka koja se mora upotrebiti u obe svrhe. Jedan od standardnih načina je da se jedna trećina ili neki manji procenat izdvoji unapred za testiranje, a da se trening vrši na ostaku [145,153]. Naravno, u ovakvom slučaju se postavlja pitanje kako odrediti koji podaci će biti korišćeni kao test skup. Obično se ovaj skup određuje slučajnim izborom. Međutim, ovakav izbor može dovesti do značajnih oscilacija u vrednostima mera kvaliteta u zavisnosti od toga koji je podskup izabran. Pouzdaniji način procene naučenog znanja je takozvana *unakrsna validacija*. Ceo skup podataka kojim se raspolaže se deli na n približno jednakih podskupova. Jeden podskup se izdvaja i obuka se vrši na ostalih $n-1$ podskupova. Posle obuke, kvalitet naučenog znanja se ocenjuje na izdvojenom podskupu. Ovaj postupak se ponavlja za sve ostale izdvojene podskupove i kao finalna ocena kvaliteta se uzima prosek dobijenih ocena za svaki od podskupova. Ovakav postupak daje stabilniju ocenu kvaliteta.

6.1.4. Rešavanje problema

Rešavanje problema, naročito u veštačkoj inteligenciji, karakteriše se po sistematskom traženju u rangu mogućih akcija s ciljem iznalaženja nekog ranije definisanog rešenja. Ono predstavlja niz stanja koji započinje početnim, a završava se završnim stanjem, pri čemu je prelazak iz jednog u naredno stanje u nizu izveden primenom neke operacije. Metode rešavanja problema se dele na metode posebne i metode opšte namene [151]. Metoda posebne namene je traženje adaptiranog rešenja za određeni problem i sadrži vrlo specifične osobine situacija od kojih se on sastoji. Kao kontrast, metod opšte namene se može primeniti na širi spektar problema.

6.2. VEŠTAČKE NEURONSKE MREŽE

6.2.1. Uvod

Opšte gledano, veštačke neuronske mreže predstavljaju jednu od metoda veštačke inteligencije. Umesto da konceptualizuju problem u matematičkoj formi, veštačke neuronske mreže koriste principe rada ljudskog mozga i njegove strukture, kako bi razvile strategiju procesiranja podataka. Veštačke neuronske mreže su relativno nov koncept u analizi podataka imajući u vidu da počeci razvoja veštačkih neuronskih mreža ne sežu daleko u prošlost [153]. Međutim, metode izgrađene na njima nalaze široku primenu, kako u tehničkim naukama, tako i u društvenim. Primena u tehnici je uglavnom vezana za predviđanje budućih stanja procesa koje se posmatraju ili modeliranje rada određenih sistema. Što tačnije predviđanje vrednosti relevantnih primenljivih je od esencijalnog značaja za dalju upotrebu razvijenog neuronskog modela u eksploataciji datog sistema. Pored upotrebe veštačkih neuronskih mreža za potrebe predviđanja, značajna je i upotreba u svrhu klasifikacije [154].

Upravo zbog toga su ovde najpre razmatrane mogućnosti veštačkih neuronskih mreža u pogledu modeliranja složenih dinamičkih uticaja radnih režima kočnice na njene performanse u cilju uvođenja inteligenčnog upravljanja performansama kočnog sistema u dinamičkim radnim uslovima. U vezi sa tim, istraživane su osnovne karakteristike veštačkih neuronskih mreža sa naglaskom na dinamičke neuronske mreže, a posebno je pažnja posvećena analizi rekurentnih neuronskih mreža, kao podvrsti dinamičkih mreža. Analizirano je na koji način je moguće razviti dinamički neuronski model koji bi bio u stanju da funkcionalno aproksimira dinamički promenljive uticaje različitih radnih uslova kočnice u toku ciklusa kočenja na njene performanse, kao i dinamiku procesa koji se dešavaju u kontaktu pneumatika i tla. Istraživane su i mogućnosti za dinamičko obučavanje neuronskog modela u toku ciklusa kočenja, kako bi se omogućilo prilagođavanje predviđanja modela novim uslovima u toku njegovog rada.

Na samom početku biće objašnjeni neki od glavnih pojmoveva, istorijat razvoja, kao i suštinski principi vezani za veštačke neuronske mreže. Pošto su veštačke

neuronske mreže razvijene po ugledu na mozak čoveka, najadekvatnije je njihovo razmatranje početi od biološke osnove razvoja neuronskih mreža.

6.2.2. Pregled razvoja veštačkih neuronskih mreža

Početak neuro-računarstva obično se vezuje za 1943. godinu i članak Warrena McCullocha i Waltera Pittsa „Logički račun ideja svojstvenih nervnoj aktivnosti“. Ovaj članak je često citiran. Kibernetičar Norbert Winer i matematičar John von Neumann su smatrali da bi istraživanja na polju računarstva, inspirisana radom ljudskog mozga, mogla biti izuzetno zanimljiva. Knjiga Donalda Hebb-a iz 1949. godine pod naslovom „The Organization of behavior“ (Organizacija ponašanja) iskazuje ideju da je klasično psihološki uslovljeno ponašanje prisutno kod svih životinja, jer je ono svojstvo neurona. Ova ideja nije bila nova, ali ju je Hebb više razradio od prethodnika, predlažući određeni zakon učenja za sinapse, a pomoću njega je izveo kvalitativno objašnjenje nekih eksperimentalnih rezultata iz psihologije [46,154].

Početkom pedesetih godina, najviše uticaja na dalji razvoj veštačkih neuronskih mreža je imao rad Marvin Minsky-a koji je u tom periodu konstruisao neuroračunar pod imenom Snark (1951). Frank Rosenblatt je zaslužan za otkriće jednoslojne veštačke neuronske mreže, zvane perceptron. Ovaj računar je mogao uspešno da podešava težinske koeficijente, međutim, nije postigao značajnije praktične rezultate. Tek krajem pedesetih godina (1957-1958), Frank Rosenblatt i Charles Wightman sa svojim saradnicima su uspeli da razviju računar pod nazivom Mark I koji predstavlja prvi neuroračunar. Nešto posle Rosenblatta, Bernard Widrow je sa svojim studentima (najpoznatiji je Ted Hoff, kasnije tvorac mikroprocesora) razradio novi tip „neurona“, tzv. ADALINE (ADaptivni LINearni Element, funkcija prenosa $f(x) = x$) i njemu odgovarajući zakon učenja [154].

U periodu od 1950-tih do ranih 1960-tih godina napisano je nekoliko knjiga i osnovano nekoliko kompanija koje se bave neuroračunarima. Međutim, sredinom 1960-tih godina došlo je do zastoja zbog dva očigledna problema. Prvo, većina istraživača je prišla problemu sa kvalitativne i eksperimentalne strane, zanemarujući analitički pristup. Drugo, početni entuzijazam je bio toliko jak da su

uvetko publikovana predviđanja da nas od veštačkog mozga deli samo nekoliko godina istraživanja. Ovakav zanos je dalje diskreditovao ovu oblast i odbio veliki broj istraživača. Mnogi od istraživača su napustili neuroračunarstvo i prešli u srodnna polja. Sredinom 1960-ih godina je pristup rešavanja problema veštačkih neuronskih mreža okarakterisan kao pogrešan, nakon što Marvin Minsky i Seymour Papert u knjizi „Perceptrons“ objavljaju matematički dokaz da jednoslojna veštačka neuronska mreža „Perceptron“ ne može da nauči funkciju XOR, uz pretpostavku da dodavanjem više slojeva neurona taj problem neće biti prevaziđen. Tačno je da neuron nije u stanju da izvede pomenutu funkciju, ali za iole složeniju mrežu od nekoliko neurona to predstavlja veoma jednostavan zadatak. Njihov dokaz je diskreditovao istraživanja u oblasti veštačkih neuronskih mreža, a finansiranja su preusmerena na druge oblasti veštačke inteligencije [46].

U periodu između 1967. do 1982. godine pojavljuju se istraživači koji daju značajan doprinos razvoju ove oblasti kao što su Teuvo Kohonen, Kunihiko Fukushima i Stephnen Grossberg. Naročito se istakao Teuvo Kohonen, koji je razvio nekoliko tipova veštačkih neuronskih mreža koje su po njemu dobile naziv. U ovom periodu se pojavio i tzv. *backpropagation* algoritam. U radu na ovom algoritmu su se posebno istakli sledeći naučnici: Amari (1967) dodaje unutrašnje slojeve perceptronskoj mreži, Bryson i Ho (1969) razvijaju algoritam sličan backpropagation algoritmu, Werbos (1974) nezavisno od prethodnika razvija backpropagation algoritam, a Parker (1982) unapređuje backpropagation algoritam. Početkom 1980-ih godina, američka vojna agencija DARPA (Agencija za odbrambene istraživačke projekte) postala je zainteresovana za veštačke neuronske mreže i finansiranja su ponovo započela. Sredinom 1980-tih, poznati fizičar John Hopfield dao je veliki doprinos popularizaciji veštačkih neuronskih mreža, objavljajući rad u kome je napravio paralelu između njih i određenih fizičkih sistema. Početkom devedesetih godina, Bart Kosko u knjizi „Neural Networks and Fuzzy Systems“ dokazuje da veštačke neuronske mreže i fazi logika opisuju isti skup problema i samim tim otvara novu oblast koja je nazvana „soft computing“. Rumenel, Hinton i Williams (1986) dokazuju veliku promenljivost i potencijal backpropagation algoritma. Krajem 1980-tih i početkom 1990-tih

godina, veštačke neuronske mreže i neuro računarstvo se uvode kao predmet na nekoliko elitnih univerziteta u SAD, dok se danas veštačke neuronske mreže znatno šire koriste. Iako su veštačke neuronske mreže imale neobičnu istoriju, one su još uvek u ranoj fazi razvoja[155].

6.2.3. Osnovne karakteristike veštačkih neuronskih mreža

Kao što je istaknuto u [154,155], postoje dve kategorije neuronskih mreža: veštačke i biološke neuronske mreže. Predstavnik bioloških neuronskih mreža je nervni sistem živih bića. Veštačke neuronske mreže su po strukturi, funkciji i obradi informacija slične biološkim neuronskim mrežama, ali se radi o veštačkim tvorevinama. Neuronska mreža u računarskim naukama predstavlja povezanu mrežu elemenata koji obrađuju podatke. One su sposobne da izađu na kraj sa problemima koji se tradicionalnim pristupom teško rešavaju, kao što su govor i prepoznavanje oblika. Jedna od najvažnijih osobina veštačkih neuronskih mreža je njihova sposobnost da uče na ograničenom skupu primera.

U ovom radu, kada se govori o neuronskim mrežama, misli se prvenstveno na „veštačke neuronske mreže” (engleski termin *Artificial Neural Networks*, skraćeno ANN), zbog toga što se uglavnom govori o modelima neuronskih mreža (skraćeno NM), realizovanim na računarima. U stručnoj literaturi, nije redak slučaj da se izostavlja reč „veštačke” iako se misli na njih. Biološke neuronske mreže su daleko komplikovanije od svojih matematičkih modela koji se koriste za veštačke neuronske mreže. ANN predstavljaju sistem sastavljen od veoma velikog broja jednostavnih elemenata za obradu podataka. Ovakvi sistemi su sposobni za prikupljanje, memorisanje i korišćenje eksperimentalnog znanja. Ne postoji jedinstvena definicija neuronskih mreža. Prema [33,34] veštačka neuronska mreža bi se mogla definisati na sledeći način:

Veštačka neuronska mreža je sistem sastavljen od više jednostavnih procesora (jedinica, neurona), svaki od njih ima lokalnu memoriju u kojoj pamti podatke koje obrađuje. Te jedinice su povezane komunikacionim kanalima (vezama). Podaci koji se ovim kanalima razmenjuju su obično numerički. Jedinice obrađuju samo svoje

lokalne podatke i ulaze koje primaju preko konekcije. Ograničenja lokalnih operatora se mogu otkloniti tokom treninga.

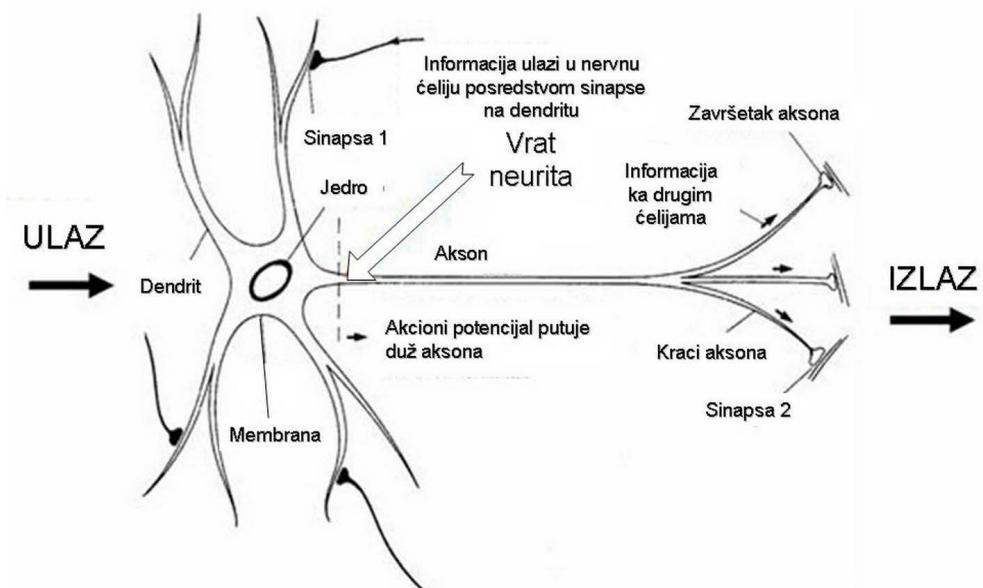
Veliki broj veštačkih neuronskih mreža su nastale kao modeli bioloških neuronskih mreža. Istoriski gledano, inspiracija za razvoj veštačkih neuronskih mreža proizilazi iz želje da se konstruiše veštački sistem sposoban za prefinjeno, možda „inteligentno”, izračunavanje na sličan način kao što to ljudski mozak rutinski izvodi. Potencijalno, veštačke neuronske mreže nam pružaju mogućnost za razumevanje rada ljudskog mozga. Veštačke neuronske mreže su kolekcija matematičkih modela koji simuliraju neke od posmatranih osobina bioloških nervnih sistema i povlače sličnosti sa prilagodljivim biološkim učenjem. Sačinjene su od velikog broja međusobno povezanih neurona (obrađujućih elemenata) koji su, slično biološkim neuronima, povezani svojim vezama koje sadrže propusne (težinske) koeficijente, koje su po ulozi slične sinapsama [34].

Učenje se kod bioloških sistema obavlja putem regulisanja sinaptičkih veza koje povezuju aksone i dendrite neurona. Učenje tipičnih događaja putem primera se ostvaruje preko treninga ili otkrića do tačnih setova podataka ulaza-izlaza koji treniraju algoritam ponavljanjem podešavajući propusne (težinske) koeficijente veza (sinapse). Ove veze memorišu znanje neophodno za rešavanje specifičnog problema. Većina veštačkih neuronskih mreža ima neku vrstu pravila za „obučavanje”, čime se koeficijenti veza između neurona podešavaju na osnovu ulaznih podataka. Drugim rečima, veštačke neuronske mreže „uče” preko primera (kao što deca uče da prepoznaju konkretan predmet, objekat, proces ili pojavu preko odgovarajućih primera) i poseduju sposobnost za generalizaciju posle podataka za obuku. Veliki potencijal veštačkih neuronskih mreža se nalazi u mogućnosti paralelne obrade podataka, tokom izračunavanja komponenti koje su nezavisne jedne od drugih. Kao što je rečeno, veštačke neuronske mreže su sistemi sastavljeni od više jednostavnih elemenata (neurona) koji obrađuju podatke paralelno. Funkcije koje su veštačke neuronske mreže u stanju da obrađuju određene su struktukom mreže i jačinom konekcije, a obrada podataka se izvodi u neuronima. Svaki element operiše samo lokalnim informacijama i radi nezavisno od drugih [35,157].

Iako veštačke neuronske mreže postoje od 1940-tih godina, one nisu imale značajniju praktičnu primenu sve do 1980-tih, kada su algoritmi postali dovoljno prefinjeni za opštu primenu. Danas se veštačke neuronske mreže primenjuju za rešavanje sve većeg broja svakodnevnih problema sa značajnom kompleksnošću. U programiranju se mogu koristiti kao „generator“ (engleski *engine*) koji je u stanju da vrši različita prepoznanja i klasifikacije i koji ima sposobnost da izvrši generalizaciju prilikom odlučivanja pri nepreciznim ulaznim podacima. Veštačke neuronske mreže nude idealno rešenje za raznovrsno klasifikovanje problema, kao što je prevodenje teksta u govor, prepoznavanje slova, rešavanje problema za koje ne postoji algoritamsko rešenje. Pokazuju dobre rezultate prilikom predviđanja i modeliranja rada sistema gde fizički procesi nisu jasni ili su veoma kompleksni. Prednost veštačkih neuronskih mreža leži u visokoj „elastičnosti“ prema poremećajima u ulaznim podacima i u sposobnosti da uči. Veštačka neuronska mreža često uspešno rešava probleme koji su previše kompleksni za konvencionalne tehnologije (na primer, problem koji nema algoritamsko rešenje ili za koji je algoritam previše komplikovan da bi bio pronađen) i one su često dobra pratnja problemima koje ljudi rešavaju [35].

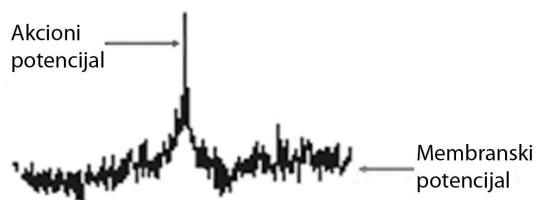
6.2.4. Biološke osnove

Prema [15,33,35,157] ljudski mozak i celokupni nervni sistem je sačinjen od nervnih ćelija kojih ima oko 10^{11} , i koje ukupno ostvaruju oko 10^{15} konekcija. Nervne ćelije u mozgu nazivaju se neuroni. Svaki od neurona može ostvariti kontakt sa nekoliko hiljada drugih neurona. Neuron ima četiri osnovna dela: ulazni deo ćelije, telo ćelije (tzv. soma), izlazni deo ćelije i sinapse. Neuron predstavlja jedinicu koju mozak koristi za obradu informacija. Neuron se sastoji od ćelijskog tela sa produžecima različitih dužina. Najveći deo produžetaka su kraći nastavci koji se nazivaju dendriti. Duži nastavci nervne ćelije (neurona) se nazivaju neuriti, čijim međusobnim spajanjem u snopove nastaje nerv ili akson. Isprekidana linija na slici 6.2 pokazuje početak aksona, gde počinje prenos signala.



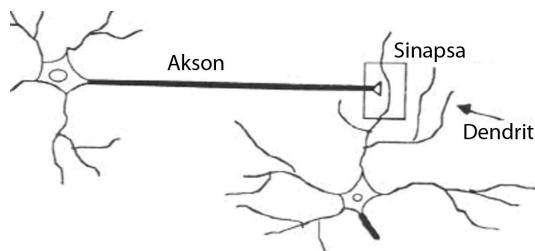
Slika 6.2. Struktura biološkog neurona

Spoljašnja granica neurona je poznata kao ćelijska membrana. Dokazano je da postoji naponska razlika (membranski potencijal) između unutrašnje i spoljašnje strane membrane. Ukoliko je ulazni impuls dovoljno veliki dolazi do generisanja akcionog potencijala. Akcioni potencijal (nervni impuls) u tom slučaju putuje duž nerva (aksona) udaljavajući se od tela ćelije. Na slici 6.3 prikazan je trenutak generisanja nervnog impulsa.



Slika 6.3. Nervni impuls

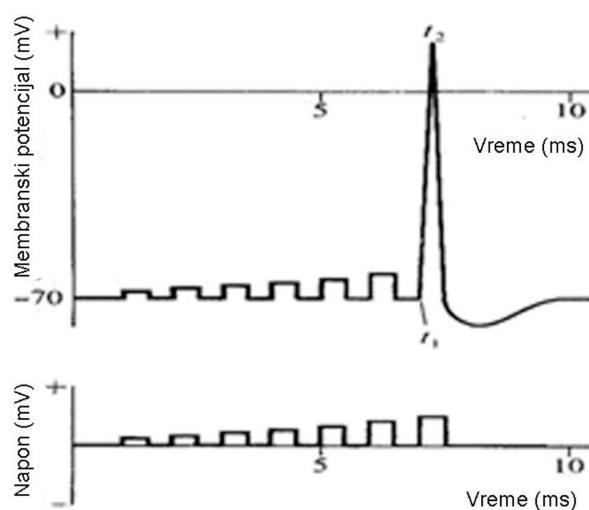
Konekcije između pojedinačnih neurona se nazivaju sinapse. To su mesta gde se impulsi prenose od jedne do druge nervne ćelije (tzv. celularna transdukcija). Informacija (nervni nadražaj) uvek napušta neuron preko njegovog aksona (videti slike 6.2. i 6.4.), a zatim biva prenešen dalje preko sinapse ka neuronu koji prima signal i prosleđuje ga dalje.



Slika 6.4. Sinapsa

Neuroni generišu impulse jedino u slučaju kada je ulazni potencijal veći od određenog praga potencijala (slika 6.5). Treba napomenuti da generisanje impulsa ne postaje jače sa povećanjem stimulansa, jednostavno – impuls nastaje ili ne.

Impulsi (signali) su veoma važni zbog toga što ih ostali neuroni primaju i na taj način međusobno ostvaruju komunikaciju. Informacija koja se prenosi kodirana je nervnim impulsima. Sinapse mogu biti prenosne (transportne) ili blokirajuće (inhibitorske). Impulsi (signali) koji dolaze do prenosne sinapse nastoje da uzrokuju generisanje impulsa u neuronu koji ih prima. Signali koji pristižu na inhibitorsku sinapsu nastoje da spreče generisanje impulsa u neuronu koji prima signal. Telo ćelije i sinapse u suštini izračunavaju (putem veoma komplikovanog elektro-hemijskog procesa) razliku između ulaznih prenosnih i blokirajućih signala. Kada je razlika dovoljno velika (u poređenju sa pragom neurona), neuron će generisati električni impuls. Grubo rečeno, što brže prenosni impuls priстиžu na sinapse brže će se generisati impuls (analogno i za blokirajući signal) [157].



Slika 6.5. Generisanje nervnog impulsa

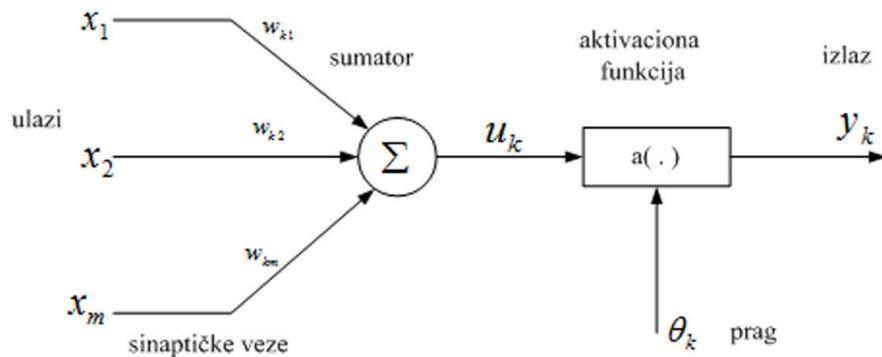
6.2.5. Veštački neuron

Po analogiji sa biološkim neuronom, formiran je model veštačkog neurona. U teoriji veštačkih neuronskih mreža neuron je nelinearna, parametrizovana i ograničena funkcija [158,159]. Zbog praktičnosti, linearna parametrizovana funkcija se često naziva linearni neuron. Promenljive neurona se često nazivaju ulazi neurona, a njegova vrednost se naziva izlaz. Veštački neuron predstavlja nelinearnu ograničenu funkciju $y = f(x_1, x_2, \dots, x_n; w_1, w_2, \dots, w_p)$, gde su $\{x_i\}$ promenljive, a $\{w_j\}$ parametri (težine, težinski koeficijenti) neurona. Za predstavljanje veštačkog neurona na dalje će se koristiti sledeće oznake:

- x_i ($i = 1, \dots, m$) – ulazne veze, vrednosti uzlaza koje neuron prima (signali ili potencijali ulaza kod biološkog neurona),
- w_{ki} ($i = 1, \dots, m$) – tzv. težinski odnosi, odnosno koeficijenti (sinapse kod biološkog neurona),
- u_k – zbirna vrednost, koja se dobija sabiranjem ponderisanih ulaza (telo prirodnog neurona),
- $a(\cdot)$ – aktivaciona funkcija (akson kod biološkog neurona),
- θ_k – prag aktivacije ;
- y_i – vrednost izlaza (potencijal izlaza kod biološkog neurona).

Šematski prikaz veštačkog neurona u skladu sa [151], uz upotrebu navedenih oznaka, predstavljen je na slici 6.6. Svaka od ulaznih veza, koje su označene sa x_i , i kojih ima m , množi se odgovarajućim težinskim koeficijentom w_{ki} . Ovako pomnožene vrednosti se potom sabiraju, i dobija se vrednost u_k (tzv. težinska suma), što je predstavljeno jednačinom (6.1):

$$u_k = \sum_{i=1}^m w_{ki} x_i \quad (6.1)$$



Slika 6.6. Šematski prikaz veštačkog neurona prema [151]

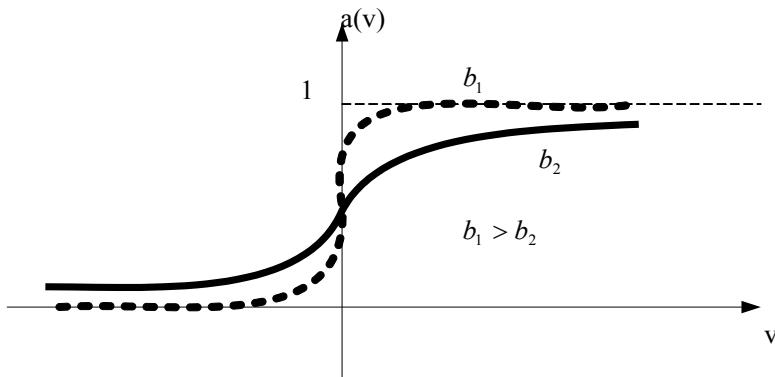
Zatim se vrednost u_k koristi kao ulaz u aktivacionu funkciju, koja je generalno nelinearna, a najčešće je u pitanju tzv. sigmoidna (logistička) funkcija (slika 6.7). Povezanost između praga aktivacije θ_k i aktivacione funkcije je najčešće takva da se vrednost θ_k oduzima od vrednosti u_k , pa se ta razlika koristi kao ulaz u aktivacionu funkciju. Na taj način se dobija vrednost izlaza y_i .

Funkcija f može biti parametrizovana na nekoliko odgovarajućih načina. Prema [159,160] dva tipa parametrizacije se trenutno koriste:

- ✓ Parametri su usaglašeni sa ulazima neurona. Izlaz neurona je nelinearna kombinacija ulaza $\{x_i\}$, ponderisana parametrima $\{w_i\}$ koji se često nazivaju težine (težinski odnosi), ili, da bi podsećali na biološku inspiraciju neuronskih mreža, sinaptički težinski odnosi.
- ✓ Parametri su usaglašeni sa nelinearnostima neurona, tj. oni pripadaju oblasti definisanosti aktivacione funkcije kao što je na primer slučaj kada je funkcija f radijalna. Na primer, Gausov izlaz te funkcije je dat kao:

$$y = \exp \left[- \sum_{i=1}^n (x_i - w_i)^2 / 2w_{n+1}^2 \right] \quad (6.2)$$

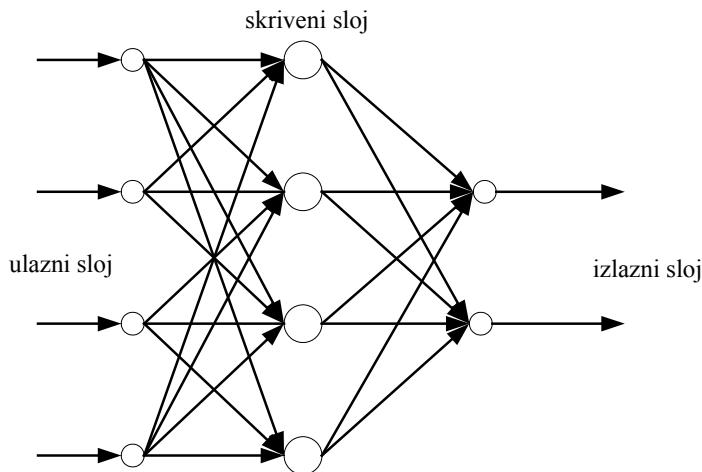
gde su parametri w_i ($i=1$ do n) pozicija centra Gausijana, a w_{n+1} njegova standardna devijacija.



Slika 6.7. Sigmoidna (logistička) funkcija

6.2.6. Arhitektura neuronske mreže

Arhitekturu ili topologiju veštačke neuronske mreže predstavlja specifično uređenje i povezivanje neurona u obliku mreže. Po arhitekturi, neuronske mreže se razlikuju prema broju slojeva neurona. Najpoznatija neuronska mreža sa jednim slojem je *jednoslojni perceptron* [34]. Kod mreža sa više slojeva, obično svaki sloj prima ulaze iz prethodnog sloja, a svoje izlaze šalje narednom sloju. Prvi sloj se naziva ulazni, poslednji je izlazni, ostali slojevi se obično nazivaju skrivenim slojevima. Jedna od najčešćih arhitektura neuronskih mreža je mreža sa tri sloja. Prvi sloj (ulazni) je jedini sloj koji prima signale iz okruženja. Prvi sloj prenosi signale sledećem sloju (skriveni sloj) koji obrađuje ove podatke i izdvaja osobine i šeme iz primljenih signala. Podaci koji se smatraju važnim se upućuju izlaznom sloju, poslednjem sloju mreže. Na izlazima neurona trećeg sloja se dobijaju konačni rezultati obrade. Složenije neuronske mreže mogu imati više skrivenih slojeva, povratne petlje i elemente za odlaganje vremena, koji su dizajnirani da omoguće što efikasnije odvajanje važnih osobina ili šema sa ulaznog nivoa. Danas se uglavnom izučavaju i primenjuju višeslojne neuronske mreže koje pored ulaznih i izlaznih slojeva sadrže neurone na srednjim (skrivenim) slojevima [159,161]. Na slici 6.8 je dat prikaz mreže sa tri sloja.



Slika 6.8. Šematski prikaz neuronske mreža sa tri sloja

6.2.7. Podela veštačkih neuronskih mreža

Prema [34,35,157,160,161], postoji veliki broj različitih realizacija neuronskih mreža, a samim tim postoji i mnogo podela.

Veštačke neuronske mreže se mogu podeliti prema *vrstama veza*, tj. arhitekturi na:

- ✓ Slojevite - neuroni su raspoređeni tako da formiraju slojeve. Na ulaz jednog neurona se dovode izlazi svih neurona sa prethodnog sloja, a njegov izlaz se vodi na ulaze svih neurona na narednom sloju. Neuroni sa prvog (ulaznog) sloja imaju samo po jedan ulaz. Izlazi neurona sa zadnjeg (izlaznog) sloja predstavljaju izlaze mreže. Tipičan predstavnik je backpropagation algoritam.
- ✓ Potpuno povezane - izlaz jednog neurona vodi ka ulazu svih neurona u mreži. Predstavnik je Hopfieldova mreža.
- ✓ Celularne - međusobno su povezani samo susedni neuroni. Bez obzira na lokalnu povezanost, signali se prostiru i na neurone i van susedstva zbog indirektnog prostiranja informacija. Predstavnik je tzv. CNN – Cellular Neural Network.

Veštačke neuronske mreže se prema *smeru prostiranja informacija* kroz mrežu mogu podeliti na:

- ✓ Feedforward (nerekurzivne, nerekurentne ili nepovratne) - Viši slojevi ne vraćaju informaciju u niže slojeve. Vrše prostiranje (propagaciju) signala samo u jednom smeru (od ulaza prema izlazu). Kao predstavnik ove vrste neuronske mreže može se navesti višeslojni perceptron, odnosno mreža sa više slojeva.
- ✓ Feedback (rekurzivne, rekurentne ili povratne) - Viši slojevi vraćaju informacije nazad u niže slojeve. Izlaz iz neurona se vraća u niže slojeve ili u isti sloj. Predstavnici ove vrste mreža su: Hopfieldova, Celularna Neuronska Mreža (CNN), Kohonenova neuronska mreža, dvostruko asocijativna, i sl. Feedback mreže imaju mnogo veće procesne sposobnosti od Feedforward mreža.

Feedforward (statičke) mreže nemaju povratnu spregu za tok informacija i ne sadrže odlaganja (tzv. privremenu memoriju) - izlaz se direktno proračunava na osnovu ulaza putem prostiranja signala unapred. Dinamičke neuronske mreže su generalno moćnije od statičkih (mada su nešto teže za obučavanje) i imaju memoriju koja može da zapamti prošle vrednosti ulaza ili izlaza i stanja mreže [155]. Tradicionalna istraživanja u ovoj oblasti koriste mrežu sa sekvenčijalnim iterativnim procesom učenja, baziranim na osnovu feedforward, backpropagation pristupa. Izlaz dinamičke neuronske mreže ne zavisi samo od trenutne vrednosti ulaza, već i od prethodnih vrednosti ulaza, izlaza ili stanja mreže [46,35,154]. Pošto dinamičke neuronske mreže mogu da se obučavaju koristeći iste (gradijentno orijentisane) algoritme za obuku koji se koriste i za statičke mreže, performanse algoritama kod dinamičkih mreža mogu biti prilično različite i gradijent mora biti proračunavan na složeniji način.

U principu, dinamičke neuronske mreže se mogu podeliti u dve vrste: (i) Feed-forward Time-Delay mreže i (ii) Feedback ili rekurentne mreže [155,159,160]. Funkcija mreže u velikoj meri zavisi od veze između neurona, odnosno težinskih odnosa. Prema [46], izlaz dinamičke mreže je pod uticajem težinskih odnosa na različite načine. Pri tom, dva različita efekta se mogu razmatrati: (i) neposredno dejstvo (promena težinskog odnosa izaziva momentalnu promenu izlaza u tom vremenskom trenutku), i (ii) indirektni efekat (podrazumeva korišćenje

dinamičkog backpropagation algoritma za izračunavanje gradijenata, što je računski zahtevnije). Rekurentne mreže su formirane na takav način da su izlazi određenih neurona vraćaju nazad na ulaz istih tih neurona ili neurona u prethodnim slojevima. One imaju unutrašnju dinamičku memoriju: njihovi izlazi u datom trenutku uvažavaju trenutni ulaz, kao i prethodne vrednosti ulaza i izlaza koje se postepeno smenjuju u narednim vremenskim koracima. Ova funkcija čini rekurentne mreže posebno pogodnim za primenu kod dinamičkih sistema [39,160].

Značajna karakteristika veštačkih neuronskih mreža, koja ih suštinski razdvaja od ostalih multivarijacionih tehnika je njihova sposobnost da uče. Prema tipu učenja u mreži, algoritmi neuronskih mreža se dele na:

- ✓ Nagledano (supervised) učenje – poznate su vrednosti izlaznih promenljivih skupa za učenje mreže (Backpropagation, Radial Basis Function, Probabilistička mreža), i
- ✓ Nenagledano (unsupervised) učenje – nisu poznate vrednosti izlaznih promenljivih skupa za učenje mreže (Kohonenova samoorganizujuća mreža, ART mreža).

Treba naglasiti da se najviše koristi upravo učenje sa nadgledanjem. U tom slučaju, porede se aktuelne vrednosti sa stvarnim vrednostima izlaza. Ako postoji razlika između ove dve vrednosti, možemo pristupiti tzv. *obučavanju* sistema. Najčešća forma obučavanja je *backpropagation*, odnosno algoritam povratnog prostiranja, kod kojeg se greška u vrednosti izlaza izračunava i šalje unazad kroz sistem neurona, pri čemu dolazi do proporcionalnih promena vrednosti težinskih koeficijenata, koje se povećavaju ili smanjuju u zavisnosti od pravca greške [34,157,158]. Kada su ove vrednosti izmenjene, ulaz vezan za drugi slučaj ulazi u sistem i proces se ponavlja. Cilj je da se procesuira veliki broj slučajeva kroz veštačku neuronsku mrežu u fazi obučavanja, kako bi se obezbedio najviši kvalitet izlaza u odnosu na postojeće ulaze.

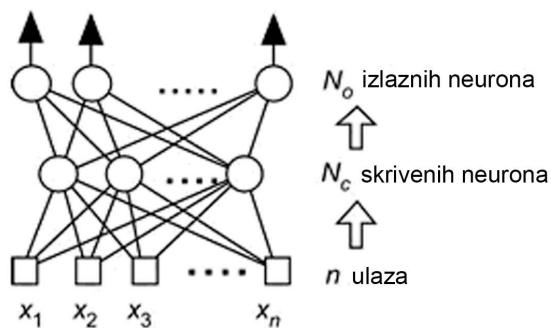
Fleksibilnost veštačkih neuronskih mreža omogućava njihovu primenu na širokom dijapazonu problema, počev od predviđanja do klasifikacije, pa i analize vremenskih serija. Ipak, primenljivost zavisi od konkretnih karakteristika

problema. U opštem slučaju, problemi na koje se mogu uspešno primeniti veštačke neuronske mreže su oni kod kojih:

- ✓ postoji mnogo prošlih reprezentativnih,
- ✓ nisu poznata pravila dolaženja do odluke (tzv. „black box“ sistem), tj. eksperata nema ili nisu dostupni,
- ✓ se promenljive mogu kvantitativno izraziti (što je u većini slučajeva moguće),
- ✓ standardne statističke metode nisu pokazale uspeh, tj. pojava se ne može predstaviti nekim linearnim modelom,
- ✓ je ponašanje sistema često neizvesno, podaci nepotpuni, te je potreban robustan alat.

6.2.8. Veštačke neuronske mreže sa prostiranjem signala unapred

Prema [35,161], veštačka neuronska mreža sa prostiranjem signala unapred je nelinearna funkcija svojih izlaza, koji su kompozicija funkcija svojih neurona. Prema tome, veštačka neuronska mreža sa prostiranjem signala unapred se može grafički predstaviti kao skup međusobno povezanih neurona, u kojoj informacije teku samo u smeru napred, od ulaza ka izlazu. Neuroni koji vrše krajnje procesiranje signala, tj. neuroni čiji izlazi su ujedno i izlazi iz veštačke neuronske mreže nazivaju se izlazni neuroni, dok se ostali neuroni, koji vrše posredno procesiranje signala, nazivaju skrivenim neuronima (slika 6.9).



Slika 6.9. Veštačka neuronska mreža [35]

Višeslojna veštačka neuronska mreža vrši procesiranje N_o funkcija ulaznih promenljivih. Svaki izlaz je nelinearna funkcija (procesirana odgovarajućim izlaznim neuronom) nelinearnih funkcija procesiranih od strane skrivenih neurona. Mreža sa prostiranjem signala unapred sa n ulaza, N_c skrivenih neurona i N_o izlaznih neurona procesira N_o nelinearnih funkcija svojih n ulaznih promenljivih, kao kombinacije N_c funkcija procesiranih od strane skrivenih neurona. Treba napomenuti da su mreže sa prostiranjem signala unapred statičke - ako su ulazi konstantni, onda su i izlazi konstantni takođe. Vreme potrebno za izračunavanje funkcije od strane svakog neurona je obično veoma kratko. Zbog toga se veštačke neuronske mreže sa prostiranjem signala unapred obično nazivaju statičke mreže, nasuprot dinamičkim ili rekurentnim mrežama. Višeslojne mreže sa prostiranjem signala unapred sa sigmoidnim nelinearnostima se obično nazivaju višeslojni perceptroni.

6.2.9. Radijalne funkcije i vejl mreže

Parametri ovakvih veštačkih neuronskih mreža su usaglašeni sa nelinearnom aktivacionom funkcijom, umesto da su usaglašeni sa konekcijama kao u višeslojnog perceptronu. Izlaz predstavlja linearu kombinaciju izlaza skrivenih radijalnih funkcija [35]. Dakle, prema [34,35] izlazi mreže se mogu definisati pomoću jednačine:

$$g(x, w) = \sum_{i=1}^{N_c} \left[w N_{c+1,i} \exp\left(-\frac{\sum_{j=1}^n (x_j - w_{ij})^2}{2w_i^2}\right) \right] \quad (6.3)$$

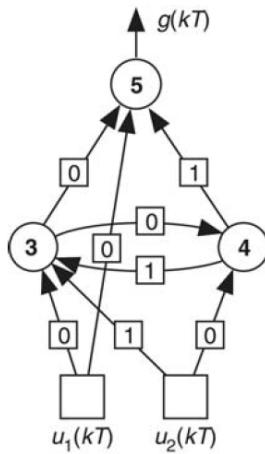
gde x predstavlja n -ti vektor ulaza, a w je vektor $((n+2) N_c)$ težinskih odnosa. Skriveni neuroni su numerisani od 1 do N_c , a izlazni neuron je numerisan sa N_c+1 . Parametri ovakve mreže se dele u dve kategorije: parametri poslednjeg sloja, koji prenose informaciju od N_c radijalnih funkcija i parametri radijalne funkcije. Konekcije prvog sloja (od ulaza do radijalne funkcije) su jednaki 1. U takvim mrežama, izlaz je linearu funkciju težinskih odnosa poslednjeg sloja i to je u stvari nelinearna funkcija težinskih odnosa Gausijana. „Wavelet“ veštačke neuronske mreže imaju potpuno istu strukturu, osim činjenice da su nelinearnosti neurona talasaste umesto da su oblika Gausove krive [35].

6.2.10. Rekurentne veštačke neuronske mreže (mreže sa povratnom spregom)

Arhitektura rekurentne veštačke neuronske mreže se može predstaviti pomoću grafikona koji sadrži cikluse [35,160]. U okviru tog grafikona postoji najmanje jedna putanja signala kojom se, prateći konekciju, može vratiti nazad do početnog neurona. Takva putanja u okviru veštačke neuronske mreže se naziva ciklus [35]. Pošto izlaz neurona ne može biti sopstvena funkcija, takva arhitektura mreže zahteva da vreme bude eksplisitno uzeto u obzir. Razlog za to leži u činjenici da izlaz iz neurona ne može biti sopstvena funkcija u datom vremenskom trenutku, ali može biti funkcija svoje ranije (prethodne) vrednosti. Veštačke neuronske mreže se mogu implementirati u većini slučajeva kao deo digitalnih sistema (bilo standardnih kompjutera ili digitalnih kola za specijalne potrebe ili za obradu signala). Prema tome, diskretni vremenski sistemi su prirodni okvir za ispitivanje rekurentnih mreža. Oni su matematički opisani rekurentnim (povratnim) jednačinama pa otuda potiče i ime ovih mreža. Diskretno-vremenske (ili rekurentne) jednačine su diskretno-vremenske jednačine kontinualnih diferencijalnih jednačina. To dakle znači da je svakoj konekciji neuronske mreže sa povratnom spregom pridruženo kašnjenje (engl. *delay*), koje može biti i jednak nuli, pored toga što joj je već pridružen parametar kao kod veštačke neuronske mreže sa prostiranjem signala unapred. Svako kašnjenje je celobrojni umnožak elementarnog vremenskog trenutka koji se smatra vremenskom jedinicom. Zbog toga što izlaz neurona u datom trenutku ne može biti svoja sopstvena funkcija, suma zakašnjenja na krajevima ciklusa na grafikonu mora biti različita od nule. Diskretno-vremenska veštačka neuronska mreža sa povratnom spregom ispunjava set nelinearnih diskretno-vremenskih povratnih jednačina, kroz kompoziciju funkcija svojih neurona, i kroz vremensko zakašnjenje povezano sa njegovim konekcijama [34,35,161].

Slika 6.10 pokazuje primer veštačke neuronske mreže sa povratnom spregom. Brojevi u kvadratićima predstavljaju kašnjenja povezana sa konekcijama, izražena kao celobrojni umnožitelji vremenskih jedinica (ili perioda uzorkovanja) T . Mrežu karakteriše ciklus, odnosno krug od neurona 3 ka neuronu 4 i nazad. Pošto

konekcija od 4 do 3 ima kašnjenje od jedne vremenske jedinice, mreža je rekurentna.



Slika 6.10. Rekurentna veštačka neuronska mreža sa dva ulaza

U vremenskom trenutku kT , ulazi neurona 3 su $u_1(kT), u_2[(k-1)T], y_4[(k-1)T]$ (k je pozitivan celobrojni broj, a $y_4(kT)$ je izlaz neurona 4 u vremenskom trenutku kT) i on na izlazu daje $y_3(kT)$. Ulazi neurona 4 su $u_2(kT)$ i $y_3(kT)$, a odgovarajući izlaz $y_4(kT)$. Ulazi neurona 5 su $y_3(kT), u_1(kT)$ i $y_4[(k-1)T]$, što na izlazu daje $g(kT)$, a što je ujedno i izlaz iz mreže. Zbog toga što su veštačke neuronske mreže sa povratnom spregom obezbeđene povratnim diskretno – vremenskim jednačinama, prirodno je da se ispitaju veze između takvih nelinearnih modela i konvencionalnih dinamičkih linearnih modela, načinom koji se koristi kod linearog modeliranja i upravljanja. U skladu sa [35], opšti matematički opis linearog sistema je jednačina stanja u obliku:

$$x(k) = Ax(k-1) + Bu(k-1) \quad (6.4)$$

$$g(k) = Cx(k-1) + Du(k-1) \quad (6.5)$$

gde je $x(k)$ vektor stanja u vremenskom trenutku kT , $u(k)$ je ulazni vektor u vremenskom trenutku kT , $g(k)$ je izlazni vektor u vremenskom trenutku kT , dok su A, B, C i D matrice. Promenljive stanja su minimalan set promenljivih tako da njihove vrednosti u vremenu $(k+1)T$ može biti izračunato ako su: (i) njihove

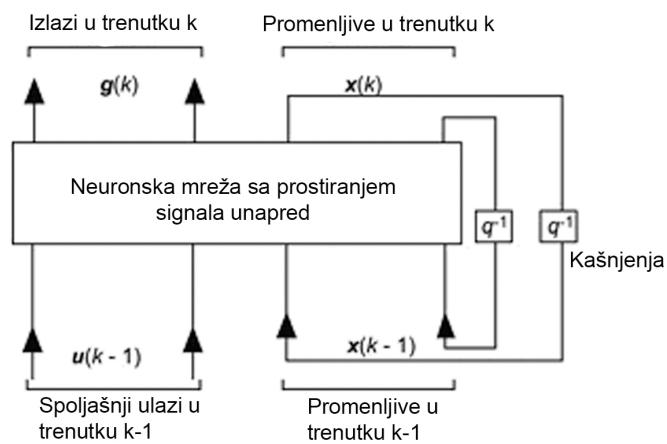
početne vrednosti poznate, i (ii) vrednosti njihovih ulaza poznate sve vreme od 0 do kT . Broj promenljivih stanja predstavlja red sistema jednačina.

Slično tome, pravilna (kanonska) forma nelinearnih sistema je definisana kao:

$$x(k) = \Phi[x(k-1), u(k-1)] \quad (6.6)$$

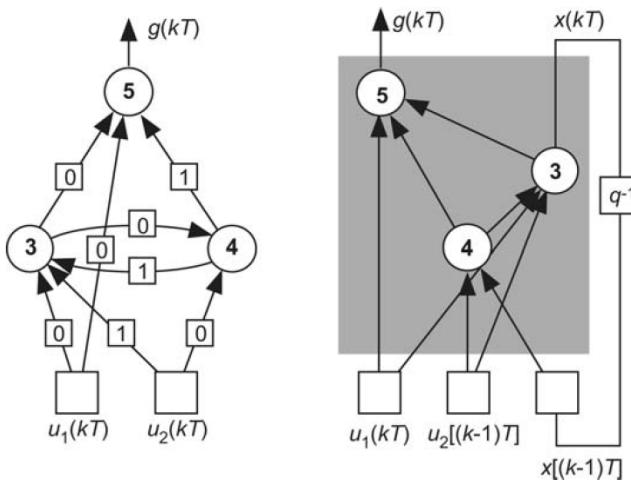
$$g(k) = \Psi[x(k-1), u(k-1)] \quad (6.7)$$

gde su Φ i Ψ nelinearne vektorske funkcije, na primer, neuronske mreže, a x je vektor stanja. Kao i u slučaju linearne funkcije i promenljive stanja su elementi minimalnog seta promenljivih tako da model može biti potpuno opisan u vremenu $k+1$ imajući početne vrednosti promenljivih stanja, a ulazi od vremenskog trenutka 0 do vremenskog trenutka k (slika 6.11).



Slika 6.11. Kanonski oblik rekurentne veštačke neuronske mreže

Bilo koja veštačka neuronska mreža sa povratnom spregom, ma koliko bila složena, može biti prebačena u kanonski oblik formiran od veštačke neuronske mreže sa prostiranjem signala unapred na taj način što se neki izlazi (nazivaju se izlazi stanja) povratnom spregom vraćaju na ulaz sa zakašnjnjem. Na primer, neuronska mreža sa slike 6.11 može da se pretvori u kanonski oblik koji je prikazan na slici 6.12. Ta mreža poseduje promenljivu prvog reda (stoga je i mreža prvog reda), a to je izlaz neurona 3. U tom primeru, neuron 3 je skriveni neuron.



Slika 6.12. Kanonski oblik rekurentne mreže formirane na osnovu feedforward neuronske mreže

6.2.11. Obučavanje veštačkih neuronskih mreža

Obučavanje veštačke neuronske mreže je algoritamska procedura gde se parametri neurona mreže proračunavaju (ažuriraju) u cilju da neuronska mreža ispuni, koliko god je moguće precizno, zadatak koji joj je dodeljen. U okviru toga, moguće su dve kategorije obučavanja: obučavanje pod nadzorom i obučavanje bez nadzora [34,159].

Kao što je objašnjeno u [160,161], veštačka neuronska mreža sa prostiranjem signala unapred izračunava nelinearnu funkciju svojih ulaza. Zbog toga takvoj mreži može biti dodeljen zadatak izračunavanja specifične nelinearne funkcije. U skladu sa tim mogu se pojaviti dve situacije :

1. Nelinearna funkcija je poznata analitički - mreža u tom slučaju izvodi funkcionalnu aproksimaciju
2. Nelinearna funkcija nije poznata analitički, ali je poznat konačan broj numeričkih vrednosti funkcije - u većini aplikacija, ove vrednosti nisu tačno poznate zato što se dobijaju putem merenja obavljenih na fizičkim, hemijskim, finansijskim, ekonomskim, biološkim i drugim procesima. U takvom slučaju, zadatak koji se postavlja pred mrežu je da ona aproksimira regresionu funkciju dostupnih podataka, zbog toga što je u pitanju statički model procesa.

U većini slučajeva njihove primene, veštačke neuronske mreže sa prostiranjem signala unapred obučavane pod nadzorom se koriste u situacijama drugog prioriteta. Obučavanje može biti smatrano da se izvodi „pod nadzorom“ ako je funkcija koju mreža treba da aproksimira poznata u nekim ili u svim tačkama [35].

Veštačkoj neuronskoj mreži sa prostiranjem signala unapred takođe može biti dat zadatak analize ili vizualizacije. Na primer, neka je dostupan set podataka opisan vektorom sa velikim brojem komponenti. Od mreže može biti traženo da se grupišu ovi podaci, prema kriterijumima sličnosti koji nisu poznati *a priori*. Metode za grupisanje su dobro poznate u statistici. Veštačkim neuronskim mrežama sa prostiranjem signala unapred može biti dodeljen zadatak koji je približan grupisanju podataka, od visoko dimenzionalnog predstavljanja podataka pa do nalaženja prikaza manjih dimenzija (obično dvodimenzionalnih) koji čuvaju sličnosti ili okruženja. Tako, „učitelj“ nije prisutan u ovom zadatku, pošto obučavanje neuronske mreže treba da otkrije sličnosti između elemenata baze podataka i da ih prevede u novi prikaz podatka ili tzv. „mape“ [35]. Prema [35,157,158,160], najpopularnije veštačke neuronske mreže sa prostiranjem signala unapred obučavane bez nadzora su „samoorganizujuće mape“ ili „Kohonenove mape“.

6.2.12. Primena veštačkih neuronskih mreža

U skladu sa [162] veštačke neuronske mreže mogu imati prednost u bilo kojoj oblasti primene koja zahteva pronalaženje nelinearne veze između promenljivih koje opisuju dati proces ili skup podataka. S obzirom na to, neophodno je razmotriti sve činjenice koje argumentuju u kojim uslovima se takav pristup preporučuje.

- ✓ Prvi uslov je potreban ali ne i dovoljan. Pošto je projektovanje veštačke neuronske mreže u suštini problem u statistici, set primera koji prikladno uzorkuju prostor ulaza i koji su u odgovarajućem broju, mora biti dostupan.
- ✓ Posle prikupljanja podataka, treba proceniti da je nelinearni model neophodan, pošto je razvoj linearног modela mnogo jednostavnije i brže nego razvoj neuronskog modela. Stoga, ako ne postoji prethodno znanje o

obimu onoga što treba modelirati, treba prvo probati linearni model. Ako se ispostavi da je linearni model previše neprecizan, uprkos činjenici da su svi relevantni faktori prisutni na ulazu, onda se projektant modela može okrenuti nelinearnim modelima kao što su veštačke neuronske mreže.

- ✓ Ako su odgovarajući primeri dostupni i ako je nelinearni model neophodan onda treba odlučiti da li je korišćenje veštačkih neuronskih mreža poželjno, umesto polinoma na primer. Broj težinskih odnosa prvog sloja konekcija (konekcije između ulaza i skrivenih neurona) se povećava linearno sa brojem promenljivih, dok se kod aproksimacije polinomima povećava eksponencijalno (tu postoji, međutim, statistički test koji može do određenog obima ograničiti kombinatornu ekspanziju težinskih odnosa kod modeliranja pomoću polinoma). Imajući to u vidu, veštačke neuronske mreže su u prednosti kada je broj promenljivih veliki, na primer veći ili jednak 3.

Iz svega prethodnog se može izvesti zaključak da ako je odgovarajući skup podataka dostupan veštačke neuronske mreže se mogu koristiti prioritetno u odnosu na ostale metode u svim aplikacijama koje zahtevaju proračunavanje težinskih odnosa regresione funkcije sa tri ili više promenljivih [34]. Ako je broj promenljivih manji, nelinearni modeli, koji su linearni u odnosu na njihove parametre kao što su polinomi, radikalno bazirane funkcije sa nepokretnim centrima i standardnom devijacijom, ili vejfleti sa fiksnim translacijama i dilatacijama mogu biti podjednako tačni i u skladu sa tim mogu zahtevati jednostavniju implementaciju [35,162]. Ako dostupni podaci nisu numerički (na primer simboli), ne mogu se direktno obrađivati veštačkim neuronskim mrežama. Potrebno je odgovarajuće predprocesiranje tih podataka da bi oni postali numerički (tehnike evoluirale iz teorije fazi skupova mogu biti prikladne u tu svrhu).

6.2.13. Projektovanje strukture veštačke neuronske mreže

Veštačke neuronske mreže su nelinearne parametrizovane funkcije koje mogu aproksimirati bilo koju nelinearnu funkciju [34,35,159,160]. Zbog toga

približavanje regresionoj funkciji pomoću primera zahteva pronalaženje arhitekture veštačke neuronske mreže za koju je suma kvadrata greške modeliranja minimalna, za sve podatke iz seta za obuku. Kao posledica toga, projektovanje strukture veštačke neuronske mreže obuhvata ispunjenje sledećih zahteva:

- ✓ Identifikovanje relevantnih ulaza, tj. faktora koji imaju značajan uticaj na veličinu koja se modelira (na primer, uticaj šuma pri merenju),
- ✓ Prikupljanje podataka koji su neophodni za obuku i testiranje veštačkih neuronskih mreža,
- ✓ Pronalaženje odgovarajuće strukture neuronskog modela, odnosno odgovarajućeg broja skrivenih slojeva i neurona u okviru tih slojeva,
- ✓ Proračunavanje težinskih odnosa mreže za koje je greška predviđanja modela minimalna, odnosno obuka neuronske mreže, i
- ✓ Testiranje stepena obučenosti, odnosno sposobnosti generalizacije veštačke neuronske mreže nakon procesa obuke.

Izbor relevantnih ulaza može obuhvatati različite zahteve u zavisnosti od oblasti primene veštačkih neuronskih mreža. Ako je proces čiji se rad modelira industrijski problem koji je pažljivo projektovan, relevantni faktori i uzročne veze između njih su obično poznati. Nasuprot tome, ako je proces od interesa složen prirodni proces (na primer iz oblasti biologije ili ekologije) ili pak ako je ekonomski, finansijski ili društveni proces, izbor relevantnih ulaza može biti znatno teži. Pitanja u vezi selekcije ulaza, a takođe i selekcije neuronskog modela, su bez sumnje specifična za veštačku neuronsku mrežu. Ona su od velike važnosti za sve tehnike modeliranja, bilo da su one linearne ili nelinearne [35,161].

Pre obučavanja, putem merenja, odnosno prikupljanja podataka o ponašanju sistema ili procesa koji se modelira moraju se prikupiti podaci sa ciljem formiranja seta podataka za obuku, kao i seta za validaciju i testiranje koji će biti naknadno definisani. Kada broj faktora (ulaza u model) pređe dva ili tri, uzorkovanje ulaznog opsega na regularan i sistematizovan način generalno nije izvodljivo zato što dolazi do veće ekspanzije mogućih kombinacija. Zbog toga je obično važno projektovati

eksperimente što je moguće efikasnije. Projektovanje eksperimenta je veoma važan deo projektovanja neuronskog modela i generalno je teže za nelinearne nego za linearne neuronske modele [35].

Nesklad između neuronske aproksimacije i funkcije koju treba aproksimirati je obrnuto proporcionalan broju skrivenih neurona. Sve do današnjeg dana, nijedan rezultat ne dozvoljava projektantu neuronskog modela da nađe odgovarajući broj neurona u okviru skrivenih slojeva imajući dostupne podatke i željene performanse modela [34,158,160]. Upravo zbog toga je neophodno koristiti specifičnu metodologiju.

Pošto se preciznost aproksimacije date funkcije od strane veštačke neuronske mreže povećava sa povećanjem broja skrivenih neurona, tradicionalna metodologija projektovanja modela bi se sastojala u formiranju veštačke neuronske mreže sa što je moguće više neurona. Međutim, kao što je već pomenuto, u stvarnim inženjerskim problemima od mreže se ne zahteva da podjednako aproksimira poznatu funkciju, već da aproksimira nepoznatu funkciju (regresionu funkciju) sastavljenu od konačnog broja eksperimentalno dobijenih tačaka (set podataka za obuku). Stoga, mreža ne treba samo da ostvari predviđanja što približnija eksperimentalno dobijenim tačkama (u smislu minimiziranja srednje kvadratne greške), već takođe treba da pokaže sposobnost generalizacije, tj. da pokaže zadovoljavajuće predviđanje u situacijama koje se ne nalaze u okviru seta podataka za obuku [157]. Prema tome, problem formiranja neuronskog modela je sledeći:

- ✓ Ako veštačka neuronska mreža ima previše težinskih odnosa, odnosno ako je previše parametrizovana, biće previše „fleksibilna“ tako da će njen izlaz veoma precizno odgovarati svim tačkama u okviru trening seta (uključujući i šum koji se nalazi u koordinatama tih tačaka), ali će ostvariti nezadovoljavajuća predviđanja u situacijama koje nisu prisutne u trening setu podataka. Ovaj fenomen je poznat kao *pretreniranost* veštačke neuronske mreže.
- ✓ U suprotnom, veštačke neuronske mreže sa premalo težinskih odnosa neće biti dovoljno složene da bi uspešno odgovorile na kompleksnost

nepoznate regresione funkcije, tako da neće biti u mogućnosti da nauči funkcionalne zavisnosti između podataka u okviru seta za obuku.

Kada je složenost modela, tj. broj skrivenih neurona veštačke neuronske mreže sa prostiranjem signala unapred jednom izabrana, proces obuke može da počne. Potrebno je proceniti parametre neuronske mreže koji, s obzirom na broj težinskih odnosa koji su dati, ima minimalnu srednju kvadratnu grešku u odnosu na trening set podataka. Prema tome, obučavanje veštačke neuronske mreže je numerički optimizacioni problem.

Zbog jednostavnosti, može se posmatrati model sa jednim izlazom $g(x, w)$. Trening set sadrži N primera. Prema [35,159], funkcija najmanjih kvadrata je definisana jednačinom (6.8):

$$J(w) = \frac{1}{2} \sum_{k=1}^N [y_p(x^k) - g(x^k, w)]^2 \quad (6.8)$$

gde je x^k vektor sa vrednostima promenljive (na primer k), $y_p(x^k)$ odgovarajuća izmerena vrednost veličine koja će biti modelirana, w je vektor težinskih odnosa (ili težine) modela, a $g(x^k, w)$ je izlazna vrednost modela sa parametrima (težinskim odnosima) w za vektor promenljivih x^k . Dakle, funkcija najmanjih kvadrata je funkcija svih podesivih težinskih odnosa w modela. Obuka se sastoji u pronalaženju vektora težinskih odnosa w za koji je funkcija $J(w)$ minimalna.

- ✓ Za model koji je linearan u odnosu na njegove težinske odnose funkcija $J(w)$ je kvadratna u odnosu na njih. Tada se može koristiti običan metod najmanjih kvadrata. On je jednostavan i efikasan, ali su rezultati ipak skromni.
- ✓ Za model koji nije linearan u odnosu na njegove parametre (na primer feedforward veštačke neuronske mreže), optimizacioni problem je višeparametarski nelinearan, što običan metod najmanjih kvadrata čini neprimenljivim. Tehnike koje rešavaju takve probleme su iterativne

tehnike koje vrše sekvencijalno proračunavanje težinskih odnosa sve dok se ne dostigne minimum ili zadovoljenje postavljenog kriterijuma.

Optimizacione tehnike u okviru procesa obuke veštačke neuronske mreže su prvenstveno gradijentne metode [154,159]. One su zasnovane na proračunavaju gradijenta funkcije cilja u odnosu na težinske odnose modela pri svakoj iteraciji. Gradijent izračunat na takav način se zatim koristi za ažuriranje vrednosti težinskih odnosa uspostavljenih u prethodnoj iteraciji. Prema [162], backpropagation je popularan, računski ekonomičan način izračunavanja gradijenta funkcije cilja. Prema tome, backpropagation nije algoritam za obuku. To je jednostavno tehniku za izračunavanje gradijenta funkcije cilja, koja je jako često sadržana u okviru postupka obuke veštačke neuronske mreže [34,35,162]. Često se navodi da je pronalazak backpropagation postupka omogućio obučavanje veštačke neuronske mreže sa prostiranjem signala unapred, što definitivno nije tačno. Metode izračunavanja gradijenta funkcije cilja su korišćene u obradi signala dosta pre uvođenja veštačkih neuronskih mreža. Takve metode se mogu koristiti za obučavanje veštačkih neuronskih mreža sa prostiranjem signala unapred. Bez sumnje, veštačke neuronske mreže su korisne kad god se traži nelinearna veza između numeričkih podataka. Zbog toga se veštačke neuronske mreže mogu karakterisati i kao statističke alatke za nelinearnu regresiju.

6.2.14. Modeliranje pomoću veštačkih neuronskih mreža

Model je najkraće rečeno reprezentacija, odnosno opservacija vidljivog sveta. U [35,163,164,165,166] su razmatrani matematički modeli formirani od algebarske ili diferencijalne jednačine, koji uspostavljaju relacije između uzroka (zvanih promenljive, faktori ili ulazi modela) i posledica (zvanih veličine koje se modeliraju, veličine od interesa ili izlazi modela), sa posebnim naglaskom na njihovu primenu za modeliranje rada različitih sistema. U [164] su posebno analizirane mogućnosti međusobnog kombinovanja različitih tipova veštačkih neuronskih mreža, kao i mogućnost njihovog kombinovanja sa ostalim tehnikama veštačke inteligencije.

Najjednostavniji oblik matematičkog modela predstavlja tzv. „model crne kutije“ (engl. *black box model*). On je zasnovan samo na opservacijama i može dati

određena predviđanja, ali ne obezbeđuje nikakva objašnjenja u vezi njih. Nasuprot tome, model zasnovan na znanju (ili tzv. „model bele kutije“) rezultira iz analize fizičkih, hemijskih, bioloških ili nekih drugih fenomena koji generišu veličinu koju treba modelirati. Ti fenomeni su opisani jednačinama koje se oslanjaju na teoretsko znanje dostupno prilikom razvoja modela. Takav model ima i sposobnost predviđanja i sposobnost objašnjenja. Naučno istraživanje teži da izgradi model zasnovan na znanju kad god je to moguće, dok razvoj modela crne kutije zahteva da budu dostupni izmereni podaci [34,160,161].

Polufizički ili tzv. „modeli sive kutije“ predstavljaju nešto između modela crne kutije i modela zasnovanog na znanju. Oni objedinjuju primenu obe vrste jednačina: i onih koje su rezultat primene teorijskih znanja i onih koje poseduju empirijske rezultate iz modela crne kutije. Za sada većina oblasti primene veštačkih neuronskih mreža se oslanja na model crne kutije.

U pogledu analiza datih u [34,35,156,159] da li je model statički ili dinamički, sumarni zaključak koji se može izvesti odnosi se na to da se statički model jedino sastoji od algebarskih jednačina, na primer veštačke neuronske mreže sa prostiranjem signala unapred. Suprotno tome, dinamički model zahteva diferencijalnu (ili parcijalnu diferencijalnu) jednačinu gde je vreme promenljiva, a ponekad čak i dodatnu algebarsku jednačinu.

Da bi se obezbedilo da model performansi kočnog sistema uči na osnovu novih situacija, odnosno ciklusa kočenja, istraživane su metode za obuku veštačkih neuronskih mreža u realnom vremenu. U [35,161] su analizirane metode koje optimizuju funkciju najmanjih kvadrata koristeći sve dostupne podatke na početku procesa obuke, pri čemu ukupan gradijent funkcije cilja može biti izračunat kao suma parcijalnih gradijenata. Kod adaptivne (on-line) obuke, težinski koeficijenti se ažuriraju koristeći parcijalni gradijent za svaki primer, tako da obuka može početi čak i pre nego što su dostupni svi podaci iz seta za obuku. Varijanta algoritama adaptivne obuke sastoji se u ažuriranju težinskih odnosa posle obrade bloka podataka (tzv. „blok trening“) [34]. U tom slučaju parcijalni inkrement nije povezan sa jednim ulazno/izlaznim parom nego sa blokom ulazno/izlaznih parova.

Najpopularnija tehnika adaptivne obuke se naziva stohastički gradijent [35], gde su ažuriranja težinskih odnosa proporcionalna gradijentu parcijalnog inkrementa:

$$w^{k+1} = w^k - \mu^k \nabla J^k(w^k) \quad (6.9)$$

gde je w^k vrednost vektora težinskih odnosa posle iteracije k , tj. posle ažuriranja težinskih odnosa iz uzorka k . Pojedini empirijski rezultati sugerisu da metod stohastičkog gradijenta izbegava zarobljavanje u lokalnom minimumu efikasnije od jednostavnog stepenastog gradijenta tokom obučavanja. Alternativna tehnika, koja je proizašla iz adaptivnog filtriranja, može se koristiti za obuku veštačkih neuronskih mreža. Efikasnija je od stohastičkog gradijenta u pogledu brzine konvergencije, ali je broj operacija po iteraciji znatno veći.

Cilj modeliranja uz pomoć tzv. modela crne kutije je razvoj modela koji je dovoljno složen da nauči podatke iz trening seta, ali da pri tom ne ispoljava pretreniranost, tj. da se ne prilagođava šumu signala [35,159]. U tom slučaju se prema [35] mogu koristiti dve kategorije strategija:

- ✓ Pasivne tehnike - nekoliko modela različite složenosti se obučavaju i selekcija između tih modela se izvodi nakon obuke sa ciljem da se eliminišu modeli koji pokazuju pretreniranost.
- ✓ Aktivne tehnike - obuka se izvodi sa ciljem da se izbegne razvoj modela koji pokazuju pretreniranost putem ograničavanja magnitude promene težinskih odnosa.

Aktivne tehnike su od posebnog značaja kada treba projektovati velike mreže i to je obično slučaj kod klasifikacije prilikom vizualnog prepoznavanja oblika, odnosno kada se koriste reprezentacije niskog nivoa. U takvim situacijama, pretreniranost se ne može izbeći limitiranjem broja težinskih odnosa, pošto je broj ulaza donja granica broja težinskih odnosa. Jedini način da se izbegne pretreniranost ogleda se u ograničavanju amplitude promene težinskih odnosa [162].

Ako se razvija velika mreža i ako algoritam obuke nađe malo srednje kvadratno odstupanje sa težinskim odnosima malih amplituda, onda performanse

generalizovanja zavise od reda vektora težinskih odnosa i nezavisne su od broja težinskih odnosa.

U suštini, postoje dve grupe metoda regularizacije:

- ✓ Rano stopiranje (sastoji se u zaustavljanju procesa obuke pre nego što je dostignut minimum funkcije cilja), i
 - ✓ Korektivna metoda (sastoji se u dodavanju korektivnog člana u funkciju cilja da bi se favorizovali regularni modeli. Funkcija cilja tada ima sledeću formu: $J' = J + \alpha\Omega$, gde je J funkcija najmanjih kvadrata, a Ω je funkcija težinskih odnosa. Najpopularnija korektivna funkcija glasi:
- $$\Omega = \sum_i \|w_i\|^2 [35].$$

Regularizacija stupa na scenu preko kriterijuma zaustavljanja. Obuka je prekinuta pre nego što je dostignut minimum funkcije cilja tako da model ne aproksimira podatke iz trening seta tako dobro kao što bi mogao, a znajući broj težinskih odnosa koji su mu dostupni. Na taj način se pretreniranost ograničava. Problem koji se javlja se odnosi na to kada bi trebalo zaustaviti obuku. Najpopularniji metod se sastoji u nadgledanju variranja greške predviđanja validacionog seta podataka i u prekidanju obuke kada greška predviđanja u odnosu na taj set podataka počinje da se povećava [34,35,157,160].

Još jedan važan zadatak na koji treba obratiti pažnju predstavlja kontrola ažuriranja težinskih odnosa kako bi se izbeglo da oni budu bolje podešeni prema određenom broju radnih režima kočnice, pa da onda u slučaju ostalih radnih režima model ima lošije performanse predviđanja. To je posebno važno u slučaju obuke neuronskog modela u realnom vremenu u dinamičkim radnim uslovima. Prema [34,35] regularizacija preko korektivne metode sprečava prekomerno ažuriranje težinskih odnosa, na taj način što vrši minimizaciju funkcije cilja J' tokom obuke, koja je suma funkcije najmanjih kvadrata J i regularizacionog člana, proporcionalnog kvadratnom redu vektora težinskih odnosa $J^* = J + \frac{\alpha}{2} \sum_{i=1}^q w_i^2$, gde je q broj težinskih odnosa modela, a α je hiperparametar čija vrednost mora biti nađena podešavanjem. Ako je α preveliko, minimizacija smanjuje vrednosti

težinskih odnosa bez obzira na grešku predviđanja, dok u suprotnom slučaju kada je α previše malo regularizacioni član nema uticaj na proces obuke, što može dovesti do pretreniranosti. Rad metode je veoma jednostavan: gradijent funkcije J se izračunava preko backpropagation postupka, a zatim se naknadno dodaje regularizacioni član:

$$\nabla J^* = \nabla J + \alpha w \quad (6.10)$$

6.2.15. Izbor modela

Nakon izbora promenljivih i procesa obuke, izbor modela je treći važan element metodologije projektovanja neuronskog modela. Model treba da bude dovoljno složen da pronađe determinističke relacije između veličina koje treba modelirati i faktora koji imaju značajan uticaj na njih, ali ne i da bude previše složen što bi dovelo do pretreniranosti. Drugim rečima, izabrani model treba da ostvari najbolji balans između kapaciteta učenja i kapaciteta generalizacije. Ako model uči kako dobro on se više prilagođava šumu signala pa onda slabo generalizuje [155].

Modeli obučavani na osnovu istog trening seta među kojima se pravi izbor, razlikuju se prema dve glavne karakteristike:

- ✓ Njihovoj složenosti - složenost modela može biti definisana kao broj njegovih elemenata (broj monoma u polinomnom modelu, odnosno broj skrivenih neurona u veštačkoj neuronskoj mreži), pa otuda potiče broj njegovih podesivih težinskih odnosa.
- ✓ Vektoru težinskih odnosa za datu složenost - za modele koji su nelinearni u odnosu na težinske odnose, funkcija cilja ima nekoliko lokalnih minimuma. Prema tome, za datu složenost i za dati set podataka za obuku, različite obuke (sa različitim početnim vrednostima težinskih odnosa) mogu kao rezultat imati različite modele koji odgovaraju različitim minimumima funkcije cilja.

Imajući u vidu analizirane načine razvoja neuronskih modela može se zaključiti da projektovanje dobrog modela zahteva sistematsku, principijelu metodologiju. Koriste se sledeći principi projektovanja:

- ✓ Veštačke neuronske mreže su relativno dobri aproksimatori, koji mogu biti korisno upotrebljeni za modele koji imaju više od dve promenljive. Za modele sa manje od dve promenljive modeli koji su linearni u odnosu na njihove težinske odnose, poput polinoma, daju odlične rezultate i lakše se obučavaju.
- ✓ Bilo da je model linearan ili nelinearan u odnosu na svoje težinske odnose, prvi korak se sastoji u analizi ulaznih podataka u cilju nalaženja funkcije stanja podataka, koja je što je moguće više kompaktna, da bi se u narednoj selekciji ulaza izabrale samo one promenljive koje su zaista relevantne.
- ✓ Izbor arhitekture neuronskog modela je sledeći korak (broj monoma za polinomni model, broj skrivenih neurona za neuronski model, itd.), a zatim sledi ažuriranje težinskih odnosa modela (proces obuke).
- ✓ Za svaku arhitekturu bira se najbolji model i „najbolji“ modeli različitih struktura se međusobno upoređuju sve dok se ne izvrši finalni izbor neuronskog modela.

6.2.16. Dinamički „model crne kutije“

Ulazi i izlazi dinamičkih modela su povezani posredstvom diferencijalnih jednačina ili, za diskretno-vremenske sisteme, preko rekurentnih jednačina [35]. Ovde će u nastavku biti razmatrani jedino diskretno-vremenski sistemi zato što velika većina realnih aplikacija veštačkih neuronskih mreža uključuje računare ili digitalno integrisana kola, koja su predstavnici uzorkovanih sistema (veličine od interesa su merene u realnom vremenu i predstavljaju celobrojne umnoške perioda uzorkovanja T . Zbog pojednostavljenja, veličina T biće izostavljena u sledećim jednačinama (vrednost promenljive x u vremenskom trenutku kT , gde je k pozitivni ceo broj, biće označen sa $x(k)$). Imajući u vidu izrazito dinamički karakter procesa kočenja, ovde je takođe od primarnog značaja istražiti načine za razvoj dinamičkih neuronskih modela.

6.2.17. Prostorni i ulazno-izlazni oblik modela

Dinamičko modeliranje ima nekoliko specifičnih odlika, koje nisu karakteristične za staticki model [35,154]. Prva specifična odlika je postojanje nekoliko funkcija stanja dinamičkog modela u datom procesu. Kaže se da je model u slobodnom (prostornom) obliku ako su njegove jednačine formulisane kao:

$$x(k) = f(x(k-1), u(k-1), b_1(k-1)) \text{ - jednačina stanja} \quad (6.11)$$

$$y(k) = g(x(k), b_2(k)) \text{ - izlazna jednačina} \quad (6.12)$$

gde je $x(k)$ vektor stanja (čije su komponente promenljive stanja), vektor $u(k)$ je kontrolni vektor ulaza, $b_1(k)$ i $b_2(k)$ su vektori poremećaja, a skalar $y(k)$ predstavlja izlaz iz modela. Funkcija f je nelinearna vektorska funkcija, a funkcija g je nelinearna skalarna funkcija. Dimenzija vektora stanja, tj. broj promenljivih stanja naziva se „red“ modela. Promenljive stanja mogu biti izmerene ili ne [35].

Za proces sa samo jednim ulazom $u(k)$, komponente vektora $u(k)$ mogu biti $u(k)$ i prošle vrednosti ulaznog kontrolnog signala: $u(k) = [u(k), u(k-1), \dots, u(k-m)]^T$. Prema [34,35], model je u normalnom (ulazno-izlaznom) obliku ako njegove jednačine oblika:

$$y(k) = h(y(k-1), \dots, y(k-n), u(k-1), \dots, u(k-m), b(k-1), \dots, b(k-p)) \quad (6.13)$$

gde je h nelinearna funkcija, n je red modela, m i p su dve pozitivne celobrojne konstante, $u(k)$ je vektor kontrolnog ulaza, $b(k)$ je vektor poremećaja. Normalni oblik modela je u stvari specifična forma prostornog oblika, gde su komponente vektora stanja $[y(k-1), y(k-2), \dots, y(k-n)]$.

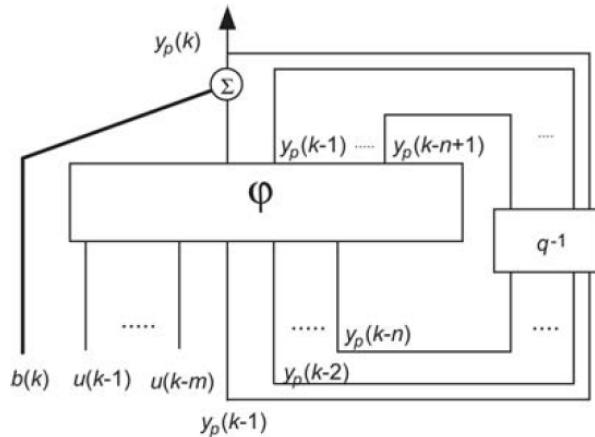
Kod linearног modeliranja, prostorni i normalni oblik su ekvivalentni: bira se oblik koji je najprikladniji za cilj koji taj model treba da ispuni. Suprotno tome, kod nelinearnog modeliranja, prostorni oblik je opštiji i dosta skromnijih performansi od normalnog oblika modela [35].

6.2.18. Normalni oblik modela

Prepostavljamo da se model može opisati na odgovarajući način, prikazom u obliku:

$$y_p(k) = \psi(y_p(k-1), \dots, y_p(k-n), u(k-1), \dots, u(k-m)) + b(k) \quad (6.14)$$

gde je $y_p(k)$ izmereni izlaz procesa. Prepostavljamo takođe da dolazi do povećanja poremećaja izlaza (videti sliku 6.13) i da u vremenu k poremećaj utiče na trenutni izlaz, a takođe i na n prošlih izlaza. U nelinearnom modeliranju ta pretpostavka je poznata kao NARX (Nelinearna auto-regresivna mreža sa egzogenim ulazima) [35,160,161]. Prepostavljamo i da poremećaj utiče na izlaz, ne samo direktno u vremenskom trenutku k , već i kroz izlaze u n prošlih vremenskih koraka. Pošto traženi model treba da bude takav da je greška modeliranja u vremenskom trenutku k jednaka poremećaju u istom vremenskom koraku, treba uzeti u obzir procese izlaza u n prethodnih vremenskih koraka.



Slika 6.13. Normalni oblik modela u skladu sa [35]

Veštačka neuronska mreža sa prostiranjem signala unapred predstavlja savršeni neuronski model pošto je obučavana pomoću tehnika koje su diskutovane u delu posvećenom treniranju statičkih modela. Takav način obuke se zove usmereno ili nadgledano obučavanje veštačke neuronske mreže. Pošto su ulazi dinamičkog neuronskog modela (pored kontrolnih ulaza) izmereni izlazi procesa, izlaz iz modela može biti izračunat vremenski samo jedan korak unapred. Ako se od modela očekuje da se koristi kao simulator, tj. za predviđanje izlaza procesa u

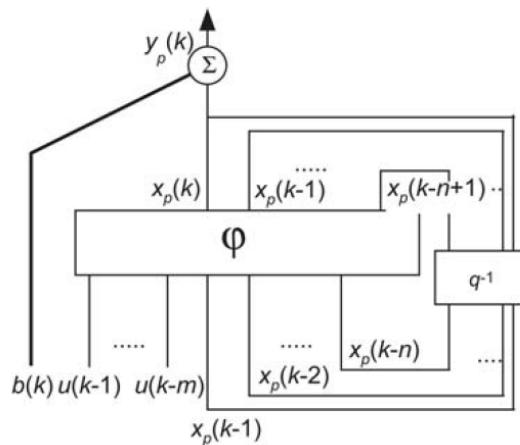
vremenskom domenu koji prevazilazi okvire vremenskog perioda uzorkovanja podataka, ulazi su obavezno prethodni izlazi tog modela. Posledica toga je rad van optimalnih uslova za taj posmatrani neuronski model.

Sada se može napraviti drugačija pretpostavka da proces može biti odgovarajuće opisan predstavljanjem u obliku:

$$x_p(k) = \varphi(x_p(k-1), \dots, x_p(k-n), u(k-1), \dots, u(k-m)) \quad (6.15)$$

$$y_p(k) = x_p(k) + b(k) \quad (6.16)$$

Prema tome, a u skladu sa [35], ovakva pretpostavka podrazumeva da je šum signala u stvari samo dodatak na izlaz (videti sliku 6.14).



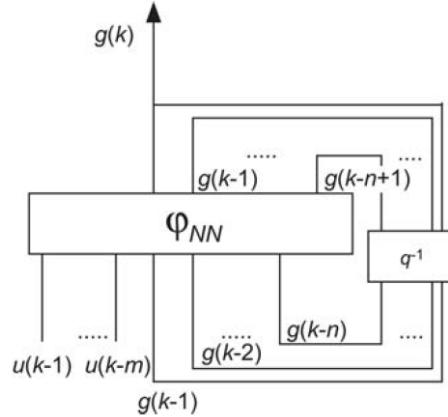
Slika 6.14. Pretpostavka o šumu izlaza u skladu sa [35]

On se dakle pojavljuje izvan povratne petlje jer ima uticaj na izlaz jedino u tom istom vremenskom koraku. Ta pretpostavka je poznata u linearном adaptivnom modeliranju kao „izlazna greška“ ili „paralela“. Pošto je izlaz u vremenskom trenutku k funkcija šuma samo u istom vremenskom koraku, traženi model ne bi trebalo da uključuje i prethodne izlaze procesa. Stoga, razmatraćemo rekurentnu neuronsku mrežu prikazanu na slici 6.15 koja zadovoljava jednačinu:

$$g(k) = \varphi_{NN}(g(k-1), \dots, g(k-n), u(k-1), \dots, u(k-m), w) \quad (6.17)$$

gde je w vektor težinskih odnosa, a funkcija φ_{NN} je izračunata od strane veštačke neuronske mreže sa prostiranjem signala unapred. Uvođenjem još nekih pretpostavki može se doći do zaključka da je greška predviđanja modela jednaka

poremećaju. Model je prema tome idealan, pošto on računa za sve što je determinističko u funkciji stanja, a ne modelira šum. Treba imati na umu da je u tom slučaju idealni model rekurentan [35,159].



Slika 6.15. Idealan model u normalnom obliku sa pretpostavljenim poremećajima izlaza

Obuka rekurentnog modela može biti svedena na obuku veštačke neuronske mreže sa prostiranjem signala unapred, kao što će biti pokazano u odeljku posvećenom obuci rekurentnih veštačkih neuronskih mreža (tzv. „polunadgledano obučavanje“). Suprotno prethodnom slučaju, model može da radi kao simulator u optimalnim uslovima. Osim toga, model takođe može služiti i za predviđanje jedan korak unapred [35,155,156].

Razmatrajmo kompjuterski simuliran proces koji zadovoljava sledeću jednačinu:

$$y_p(k) = \left[1 - \frac{T}{a + b y_p(k-1)} \right] y_p(k-1) + \left[T \frac{c + d y_p(k-1)}{a + b y_p(k-1)} \right] u(k-1) + b(k) \quad (6.18)$$

Na osnovu jednačine 6.13 i analize sprovedene u [35], u slignalu je prisutan šum. Kao što je već zaključeno u prethodnom izlaganju, idealan model je neuronska mreža sa prostiranjem signala unapred.

6.2.19. Metodologija modeliranja

Na samom početku izlaganja o metodologiji modeliranja neophodno je napomenuti da bi prema [35] projektovanje neuronskog modela, osim izbora broja skrivenih neurona i algoritma obuke, trebalo da obuhvata i sledeće korake:

- ✓ Pre korišćenja veštačke neuronske mreže ili bilo kog statističkog modela, može biti potrebno da se generišu nove ulazne promenljive kako bi se smanjio njihov broj, a da se pri tom ne izgube informacije u pogledu njihovog rasporeda.
- ✓ Posle izračunavanja težinskih odnosa modela (tj. obuke ako je model veštačka neuronska mreža), korisnik treba da proceni rizik korišćenja tako razvijenog modela. Taj rizik je usko povezan sa greškom generalizacije, koja ne može biti izračunata, pa otuda mora biti procenjena.

Dakle, aspekti metodologije koja će biti predstavljena u narednom izlagaju odnose se na:

- ✓ predprocesiranje podataka,
- ✓ tehnike za smanjenje broja ulaza, i
- ✓ procenu greške generalizacije koristeći statističke tehnike uzorkovanja

Raspodela ulazno/izlaznih obučavajućih parova, kao i njihov broj, trebalo bi da bude tako određen da se može uspešno reprezentovati problem koji se modelira. Ukupan broj potrebnih podataka koji je neophodan zavisi od stepena nelinearnosti problema koji se modelira, tj. visoko nelinearan problem zahteva više podataka. Tačna veza između broja obučavajućih parova i problema koji se modelira danas je veoma interesantna oblast za sveobuhvatna istraživanja. Za slučajnu raspodelu, na primer, ukupan broj obučavajućih parova se bira tako da verovatnoća realnog predstavljanja problema koji se modelira iznosi 90% [157].

Kako je objašnjeno u [157], nasuprot tipičnoj binarnoj situaciji, gde su odgovarajuće vrednosti predstavljene brojevima 0 i 1, intenzitet uticaja ulazno/izlaznih parametara često može da se značajno razlikuje jedan u odnosu na

drugi. U takvim situacijama rangiranje pojedinačnih uticajnih podataka, koji čine skup parova za trening neuronskih mreža, je izuzetno važno. Skaliranje podataka može biti izvršeno u odnosu na ulazne parametre, u odnosu na izlazne parametre ili u odnosu na oba skupa podataka. Postoje različiti načini na koji se mogu skalirati podaci: linearno, log-aritmetičko, obostrano log-aritmetičko, itd. Jedan od najčešćih načina skaliranja podataka je linearno skaliranje prema izrazu (6.19).

$$\bar{x} = \bar{x}_{\min} + \frac{x - x_{\min}}{x_{\max} - x_{\min}} \cdot (\bar{x}_{\max} - \bar{x}_{\min}) \quad (6.19)$$

a odgovarajući izraz za njegovo deskaliranje je dat u nastavku preko (6.20),

$$x = x_{\min} + \frac{\bar{x} - \bar{x}_{\min}}{\bar{x}_{\max} - \bar{x}_{\min}} (x_{\max} - x_{\min}) \quad (6.20)$$

Linearno skaliranje ulaznih parametara poboljšava uslove obučavanja mreža u smislu postizanja optimalnog seta težinskih odnosa u mreži i balansa između različitih ulaza. Linearno skaliranje izlaznih parametara može uspostaviti balans između izlaza čiji su intenziteti vrlo različiti. U slučaju kada nema skaliranja originalni podaci se koriste za obučavanje mreža. Ovakav način saopštavanja podataka mreži se koristi za obuku tzv. *knowledge-based* neuronskih mreža kada je potrebno očuvati fizičko značenje ulaznih promenljivih.

Projektovanje modela $g(x,w)$ može zahtevati redukciju dimenzija ulaza vektora x . To je naročito važno kada je broj promenljivih prevelik da bi se sa njim rukovalo zgodno, ili kada se pretpostavlja da nisu međusobno nezavisni. U drugom slučaju, njihova redukcija pojednostavljuje projektovanje modela. Drugi slučaj je zato robusniji s obzirom na promenljivost podataka i manje je osetljiv na pretreniranost zahvaljujući parametrizovanosti. Da bi se smanjio broj faktora (komponenti) moguće je konstruisati podprostor prostora ulaza (takođe zvanom prostor funkcije stanja), čije su dimenzije stoga manje od broja faktora, u kom je distribucija u funkciji stanja opservacija (tački) što je moguće sličnija njihovoj distribuciji u prostoru funkcije stanja [35].

6.2.20. „Offline“ i „online“ obuka

Prema tome kada se vrši ažuriranje težinskih odnosa i biasa tokom obuke, neuronska mreža se može obučavati na dva načina. Kod tzv. „online“ ili adaptivnog obučavanja modela težinski odnosi i biasi se ažuriraju svaki put kada se ulaz prezentuje mreži. Kod „offline“ obuke težinski odnosi i biasi se ažuriraju tek nakon što se prezentuju svi ulazi. Oba navedena načina obuke mogu biti primenjeni i kod statičkih i kod dinamičkih mreža. „Online“ obuka se najčešće koristi kod dinamičkih neuronskih mreža, naročito kod onih adaptivnog tipa [35,158], a imajući u vidu da je ovde od primarne važnosti obezbediti da se neuronski model obučava u toku ciklusa kočenja najveća pažnja je posvećena ovom načinu obučavanja.

6.2.21. Neuronsko modeliranje dinamičkih sistema pomoću rekurentnih mreža

Modeliranje upravljanih dinamičkih sistema ili „identifikacija procesa“ predstavlja glavnu oblast primene veštačkih neuronskih mreža. Neuronsko modeliranje nelinearnih procesa je u suštini generalizacija vrlo dobro poznate linearne regresije. U većini aplikacija, stanje sistema ne može biti u potpunosti poznato zato što neke promenljive stanja ne mogu biti izmerene i zato što se ne može izbeći greška u merenju. Stoga, tehnike filtriranja se obično koriste da rekonstruišu stanje dinamičkih procesa na osnovu dostupnih rezultata merenja. Jedna od veoma popularnih tehnika je i Kalmanovo filtriranje. Ona se koristi za projektovanje neuronskih algoritama učenja koji se mogu koristiti za identifikaciju dinamičkih procesa [160].

Matematički model dinamičkog sistema je definisan setom E , nazvanim parametarski prostor sistema, i jednačinom evolucije koja u potpunosti opisuje evoluciju stanja sistema u parametarski prostor od početnih uslova stanja. U većini problema, kaže se da je evolucija autonomna jer zakon evolucije ne zavisi od vremena. Kod problema upravljanja, stanje sistema u vremenskom trenutku $t + \Delta t$ ne zavisi jedino od stanja sistema u vremenskom trenutku t . Ono takođe zavisi od spoljašnjeg signala u vremenskom trenutku t , koji se naziva ulaz ili kontrola

sistema. U tom slučaju, sistem se naziva kontrolisanim, što je suprotno od autonomnog [35,160]. Set kontrola će se, prema tome, označavati drugačije, na primer sa F . Koristeći klasične načine obeležavanja, mogu se napisati relacije:

- $x(t) \in E$ za stanje sistema u vremenskom trenutku t ,
- $u(t) \in F$ za vrednost kontrole u vremenskom trenutku t .

Prema tome, da bi se definisala čitava putanja promene stanja kontrolisanog sistema od vremenskog trenutka 0 do vremenskog trenutka τ , potrebno je početno stanje sistema $x(0)$ i kontrolna putanja $[u(t)]_{t \in [0, \tau]}$. Kontrolni sistem je projektovan sa ciljem formiranja kontrolne putanje koja treba da bude što je bliže moguće referentnoj putanji stanja ili da minimizira ciljnu trajektoriju poštujući datu funkciju cilja.

Treba posebno obratiti pažnju na to da ako je primenjen mehanizam upravljanja sa zatvorenom petljom, tj. ako kontrolni sistem podešava upravljanje procesom kao funkciju trenutnog stanja, prošlog stanja sistema ili prošlih rezultata merenja u sistemu, tada se celi sistem (kontrolisani dinamički sistem + kontrola sistema) naziva autonomican dinamički sistem. Dinamički sistem u realnom vremenu može biti izведен iz neprekidnog dinamičkog sistema uzorkovanjem trajektorije stanja sistema. Period uzorkovanja se označava sa T , pa je onda vreme uzorkovanja za broj od k uzorkovanja definisano kao $t = kT$. Vreme evolucije kontrolisanih dinamičkih sistema je opisano sledećom jednačinom:

$$x(k+1) = f[x(k), u(k)] \quad (6.21)$$

gde funkcija f vrši mapiranje iz skupa $E \times F$ u skup E , što nam omogućava izvođenje zaključka o stanju sistema u vremenskom trenutku $(k+1)T$ na osnovu stanja u vremenskom trenutku kT .

Linearni model je još više klasičan. U tom slučaju, parametarski prostor sistema i kontrolni prostor su vektorski prostori. A predstavlja linearno mapiranje iz E u E , B je linearne mapiranje iz F u E , pa jednačina evolucije ima sledeću formu:

$$x(k+1) = Ax(k) + Bu(k) \quad (6.22)$$

Zato što su matematički modeli samo procene realne evolucije fizičkih procesa, greška modeliranja je uopšteno predstavljena slučajnim dodatnim članom. Taj član se često naziva šum (poremećaj stanja).

Inženjeri se obično suočavaju sa poremećajem stanja u kontinuiranim dinamičkim sistemima. U tom slučaju, proračun verovatnoće je mnogo složeniji i ne može se rešiti analitički osim u slučaju linearnih modela sa dodatnim Gausovim poremećajem. Ovde je opisan taj model zato što se on često koristi kod Kalmanovog filtriranja.

Prepostavimo da je linearan kontrolisani dinamički sistem definisan preko jednačine stanja:

$$x(k+1) = Ax(k) + Bu(k) + Cv(k+1) \quad (6.23)$$

gde je $v(k)$ srednja vrednost Gausovog poremećaja, tj. sekvenca slučajnih nezavisnih ravnomerno raspoređenih vektora koji prate Gausovu raspodelu. Ako je $x(k)$ Gausov vektor sa očekivanjem jednakim $m(k)$ i matricom kovarijanse koja je jednaka $P(k)$, onda iz uslova stabilnosti Gausovog zakona pod linearom transformacijom, $x(k+1)$ je Gausov vektor jednak:

$$m(k+1) = Am(k) + Bu(k) \quad (6.24)$$

i sa matricom kovarijanse jednakom:

$$P(k+1) = AP(k)A^T + CC^T \quad (6.25)$$

gde su A^T i C^T transponovane matrice matrica A i C .

Ako je matrica A stabilna, Gausov proces konvergira kada vreme ode do beskonačnosti u odnosu na Gausov zakon sa nultom srednjom vrednošću i sa matricom kovarijanse P_∞ što je rešenje sledeće jednačine:

$$P_\infty = AP_\infty A^T + CC^T \quad (6.26)$$

Obrnuto, ako matrica A nije stabilna, onda tu ne postoji nepromenljiv (stacionaran) režim i proces divergira u dužem vremenskom periodu. Linearni model se tada naziva nestabilnim.

Auto regresivni (AR) model je definisan sledećom regresivnom jednačinom:

$$x(k+1) = a_1 x(k) + \dots + a_p x(k-p+1) + v(k+1) \quad (6.27)$$

gde je $v(k)$ Gausov poremećaj. Treba obratiti pažnju na to da relevantni signal može biti interpretiran kao odziv na linearni filter. Filter beskonačnog odziva impulsa (IIR filter ili „rekurzivni filter“) se karakteriše činjenicom da njegov odziv u vremenskom trenutku $k+1$ zavisi od njegovog ulaza u vremenskom trenutku k i od odziva u prethodnom periodu. Sa druge strane, filter konačnog odziva impulsa (FIR filter ili „dijagonalni filter“) se karakteriše činjenicom da njegov odziv u vremenskom trenutku $k+1$ ne zavisi od njegovih odziva u prošlim trenucima već jedino od ulaznog signala u tom trenutku i u prošlim trenucima. Pored toga, model odziva FIR filtera na ulazni poremećaj, kao što je na primer:

$$x(k+1) = b_0 v(k+1) + b_1 v(k) + \dots + b_q v(k-q+1) \quad (6.28)$$

se obično naziva dinamički osrednjeni proces $MA(q)$. Prirodna generalizacija ova dva modela je autoregresivni dinamički osrednjeni model reda (p,q) , ili $ARMA(p,q)$ model [34,35]. Iako $ARMA$ modeli koriste pravilo univerzalne aproksimacije, efikasnije je da se izgrade nelinearne evolutivne jednačine. Dakle, $NARMA$ modeli su uvedeni pomoću sledeće regresivne jednačine:

$$x(k+1) = f[x(k), \dots, x(k-p+1), v(k), \dots, v(k-q+1)] \quad (6.29)$$

Na primer, za $NARMA$ model reda (p,q) stanje sistema u trenutku k je vektor $x(k)$, koji ima $p+q$ komponenata, odnosno

$$[x_1(k) = x(k), \dots, X_p(k) = x(k-p+1), x_{p+1}(k) = v(k), \dots, x_{p+q}(k) = v(k-q+1)] \quad (6.30)$$

pa tada jednačina stanja glasi:

$$x_2(k+1) = x_1(k) \quad (6.31)$$

.....

$$x_p(k+1) = x_{p-1}(k) \quad (6.32)$$

$$x_{p+1}(k+1) = v(k+1) \quad (6.33)$$

$$x_{p+2}(k+1) = x_{p+1}(k) \quad (6.34)$$

.....

$$x_{p+q}(k+1) = x_{p+q-1}(k) \quad (6.35)$$

$$x_1(k+1) = f[x_1(k), \dots, x_p(k), v(k+1), x_{p+1}(k), \dots, x_{p+q}(k)] \quad (6.36)$$

Na isti način je moguće razmatrati kontrolisane dinamičke sisteme koji su zasnovani na autonomnim dinamičkim sistemima preko uvođenja novih ulaza. U skladu sa tim teorija vremenski zavisnih parametara razmatra autoregresivne modele sa spoljašnjim (egzogenim) ulazima koji se nazivaju ARMAX (ili NARMAX) modeli [35,155]. Kod ovih modela, evoluciona jednačina uzima u obzir spoljašnje promenljive u trenutku koji se posmatra ili u prošlom. Ove spoljašnje promenljive su poznate i predstavljaju ekvivalent kontrolnog signala. Na taj način se dobija ARMAX (p,q,r) model kao:

$$\begin{aligned} x(k+1) = & a_1 x(k) + \dots + a_p x(k-p+1) + b_0 v(k+1) + b_1 v(k) + \dots + \\ & + b_q v(k-q+1) + c_1 u(k) + \dots + c_r u(k-r+1) \end{aligned} \quad (6.37)$$

Pa je NARMAX (p,q,r) model:

$$\begin{aligned} x(k+1) = & f[x(k), \dots, x(k-p+1), v(k+1), v(k), \dots, \\ & v(k-q+1), u(k), \dots, u(k-r+1)] \end{aligned} \quad (6.38)$$

6.2.22. Regresiono modeliranje dinamičkih sistema

Linearna regresija je definisana u skladu sa [35] kao algoritam za pronalaženje ($n, 1$) vektora kolone $w = (w_1; \dots; w_n)$ koji minimizira sumu kvadrata greške (SSE):

$$J = \sum_{k=1}^N (y_k - x_k w)^2 \quad (6.39)$$

Od $N(1,n)$ vektora ulaza $(x_1, \dots, x_k, \dots, x_N)$ i N skalara na izlazu $(y_1, \dots, y_k, \dots, y_N)$, ili ekvivalentno, koji minimizira srednju vrednost kvadrata greške (MSE):

$$\phi_N(w) = \frac{1}{2N} \sum_{k=1}^N (y_k - x_k w)^2 \quad (6.40)$$

Poznato je da kvadratna funkcija ima jedan minimum, koji može biti izведен pomoću sledeće matrične formule:

$$\hat{w} = (X^T X)^{-1} X^T Y \quad (6.41)$$

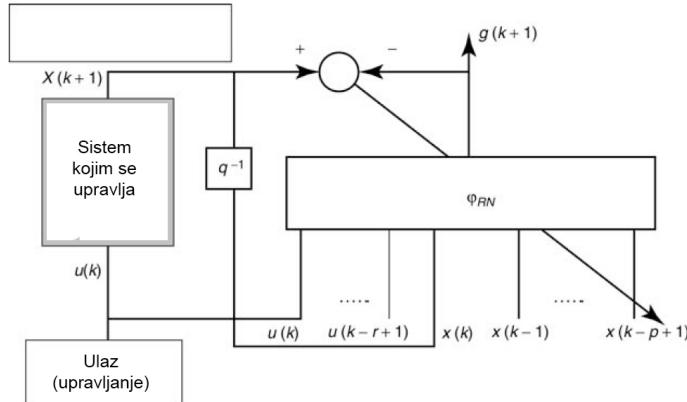
gde su (N,n) matrica $X = (x_1; \dots; x_k; \dots; x_N)$ i $(N,1)$ vektor kolona $y = (y_1; \dots; y_k; \dots; y_N)$ formirani od ulaznih i izlaznih podataka. Takav algoritam može biti korišćen za identifikaciju autoregresivnog modela datog u jednačini (6.37). Treba napomenuti da postoji korelacija između ulaza i izlaza. Prema tome je vektor regresionih koeficijenata $w = [a_1, \dots, a_p, b_0, c_1, \dots, c_r]^T$. Kada su ulazna trajektorija $[u(1), \dots, u(k), \dots, u(N)]$ i izlazna trajektorija $[x(1), \dots, x(k), \dots, x(N)]$ dostupne, $(1,p+r)$ ulaznih regresionih vektora je formirano kao: $x_k = [x(k); \dots; x(k-p+1); u(k); \dots; u(k-r+1)]$ gde k varira od $\max(p,r)+1$ do $(N-1)$, a odgovarajući izlaz je $y_k = x(k+1)$ [35].

6.2.23. Nelinearno modeliranje pomoću mreža sa prostiranjem signala unapred

Kada prepostavka o linearnosti jednačine stanja nije ispoštovana, modeliranje bazirano na linearnoj regresiji kontrolisanih dinamičkih sistema je vrlo neprecizno i koristi veoma kompleksne modele sa previše parametara. Najjednostavniji primer neuronskog modeliranja kontrolisanog dinamičkog sistema se zasniva na regresionim algoritmima. Model je tada autoregresivni sa spoljašnjim ulazima (tzv. NARX model) [35,158,160]. Stohastička jednačina NARX (p,r) modela glasi:

$$X(k+1) = f[X(k), \dots, X(k-p+1), V(k+1), u(k), \dots, u(k-r+1)] \quad (6.42)$$

Regresioni koeficijenti su p za stanje i r za kontrolu. Dijagram takve mreže je prikazan na slici 6.16.



Slika 6.16. Dijagram obuke NARX neuronskog modela

Uz pomoć neuronske mreže sa prostiranjem signala unapred moguće je implementirati funkciju φ_{RN} . Ulaz u mrežu je formiran od signala sa vrednostima od trenutka k do k-p+1 (izlaz procesa f koji se posmatra) i kontrolnih vrednosti od trenutka k do k-r+1 (ulaz procesa koji se posmatra). U tom slučaju, p je koeficijent modela u odnosu na stanje, a r koeficijent modela u pogledu na upravljanje. Izračunavanje se zasniva na minimizaciji greške modeliranja, odnosno, razlike između izlaza procesa $x(k+1)$ i predviđanja $g(k+1)$ koji model predviđa.

Obuka modela je skup ulaznih vektora tipa $x_k = [x(k); \dots; x(k-p+1); u(k); \dots; u(k-r+1)]$ i odgovarajućih izlaznih skalara tipa $g_k = x(k+1)$. Dve strategije se mogu koristiti za formiranje seta podataka za obuku:

- ✓ Ukoliko je dostupan simulator podataka, on će se iskoristiti za formiranje seta za obuku. U tom slučaju, postoji sloboda u izboru reprezentativnog uzorka izlaza mreže. U tom smislu, može se izabrati bilo klasično uzorkovanje ulaznog prostora, ili se mogu izabrati uzorci ulaza u skladu sa zakonima verovatnoće, koji favorizuju uobičajeni operativni region ulaznog prostora. Ponekad, naprotiv, granične tačke i granice bezbednosti domena su favorizovane sa ciljem da se obezbedi sigurnost i tačnost zastupljenosti u celom operativnom domenu. Takva situacija, gde je simulator dostupan, je uobičajena kada se radi o potrazi za polu-fizičkom reprezentacijom ili tzv. „modelom sive kutije“.

- ✓ Nasuprot tome, ako se obuka vrši sa stvarnim eksperimentalnim podacima, uzorkovanje ulaznog prostora ne može biti izabrano svojevoljno. Tada se set podataka za obuku dobija uzorkovanjem ulazno-izlazne eksperimentalne putanje. U tom slučaju, važno je koristiti eksperimentalne uređaje sa odgovarajućom inicijalizacijom i za dovoljno dugo vreme da bi se uzorkovanje ulaznog prostora mreže izvršilo sa dovoljnom frekvencijom (što je u osnovi posledica prostora stanja od strane kontrolnog prostora). Da bi se identifikovao kontrolisan dinamički sistem, potrebno je generalno pobuđivanje sistema u tzv. otvorenoj petlji. Izbor odgovarajuće kontrolne trajektorije je pomalo intrigantan. U slučaju linearnih sistema, harmonijska pobuda je dovoljna da se identificuje sistem pomoću funkcije prenosa. U slučaju nelinearnih sistema, potrebno je da se kombinuje korišćenje generatora slučajnih brojeva i fizičko znanje o sistemu.

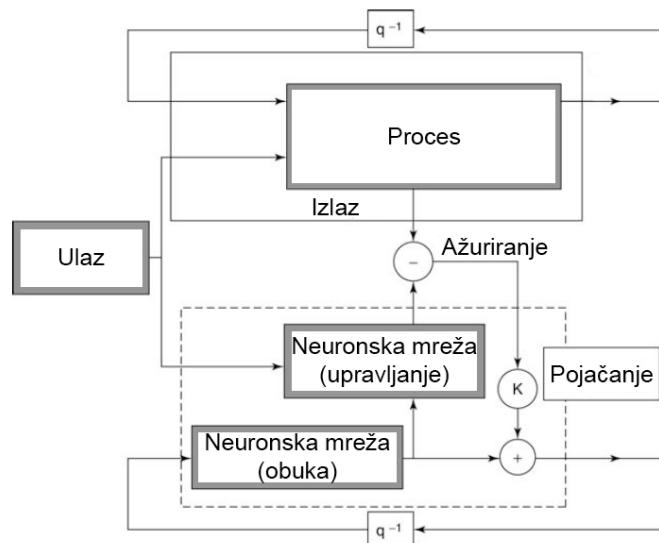
Algoritmi koji se koriste za ekstrahovanje glavnog signala tokom merenja se nazivaju filtri. Zapravo, takvi algoritmi neutrališu šum u cilju dobijanja prave vrednosti trenutnog signala. U narednom izlaganju će biti objašnjeno obučavanje NARX veštačke neuronske mreže tako što se set ulaznih podataka filtrira pomoću tzv. Kalmanovog filtra, kako bi se šum u signalu neutralisao u određenoj meri. Princip Kalmanovog filtriranja se sastoji u korišćenju modela verovatnoće i nesigurnosti modela i merne nesigurnosti za izračunavanje poboljšanja [34]. Prema [35], rekonstrukcija signala iz merenja predstavlja u suštini Bajesov problem izračunavanja: prošli zakon verovatnoća se računa na osnovu dostupnih merenja, a odluka se vrši korišćenjem metode najmanjih kvadrata ili procenom maksimalne verodostojnosti (tzv. MAP procena). Međutim, takav proračun može biti veoma težak u opštem slučaju. U okviru linearног modela sa dodatnim Gausovim šumom, rešenje predstavlja rekurzivni filter, koji je u stvari optimalni filter. Problem filtriranja se u suštini sastoji u rekonstrukciji trenutnog signala u vremenskom trenutku $k+1$, pod uticajem prošlih ili sadašnjih merenja. Dostupne informacije su sadržane u vektoru $y(k+1) = [y(1), \dots, y(k+1)]$. Kriterijum

predstavlja kvadrat razlike između izračunate vrednosti $\hat{X}(k+1)$ i stvarne vrednosti signala $X(k+1)$.

U skladu sa [35,160], osnovne osobine Kalmanovog filtriranja se mogu sumirati na sledeći način:

- ✓ Kada se uporede rezultati filtriranja u varijacionom okviru i u okviru verovatnoće, Kalmanov filter je optimalni filter u domenu varijacionog okvira.
- ✓ Kalmanov filter je bezuslovno stabilan i predstavlja doslednu procenu signala. Dinamika greške konvergira ka optimalnom stabilnom režimu čak i kada je dinamički sistem i sam nestabilan.
- ✓ Sekvencijalno poboljšanje je rezultat uzastopnih linearnih regresija. Zbog toga je nezavisno od Gausovog modela.

Na slici 6.17 je prikazan dijagram algoritma obuke veštačke neuronske mreže pomoću proširenog Kalmanovog filtra. Sistem koji se razmatra je sama neuronska mreža. Pretpostavljeno je da postoji model procesa kojim je generisan set podataka za obuku. U stvari, njegovo stanje je opisano konfiguracijom mreže, tj. skupom svih parametara mreže.



Slika 6.17. Obuka neuronske mreže pomoću proširenog Kalmanovog filtra

Ulazno-izlazni podaci mreže su bazirani na merenju parametara procesa, što daje informaciju o evoluciji konfiguracije. Prema tome, takav adaptivni algoritam je pogodan za praćenje sporih varijacija u okruženju, što predstavlja tipičan zadatak jednog adaptivnog algoritma. Linearna jednačina stanja $X(k+1) = AX(k) + Bu(k) + V(k+1)$ dobija oblik:

$$W(k+1) = W(k) + V(k+1) \quad (6.43)$$

gde je $W(k)$ vektor konfiguracije mreže (težinski odnosi + biasi) u vremenskom trenutku k . Nelinearna jednačina merenja $Y(k) = h[X(k)] + W(k)$ postaje:

$$y(k) = g[x(k), w(k)] + W(k) \quad (6.44)$$

Prema tome, greška modela u pogledu poboljšanja iznosi $\vartheta(k+1) = y(k+1) - g[x(k+1), w(k)]$. Jednačina filtara je forma neadaptivnog optimizacionog algoritma. Kod takvog algoritma, silazna putanja nije gradijent kvadrata greške koji je jednak $H(k+1)^T \vartheta(k+1)$ [35]. Gradijent može biti izračunavan pomoću backpropagation algoritma. Algoritam obuke Kalmanovog filtara je metod drugog reda, ali je u suštini adaptivni metod. Ovaj algoritam obuke nije široko zastupljen zbog svoje kompleksnosti kod implementacije. Ipak, može biti interesantan kao metod adaptacije drugog reda [161].

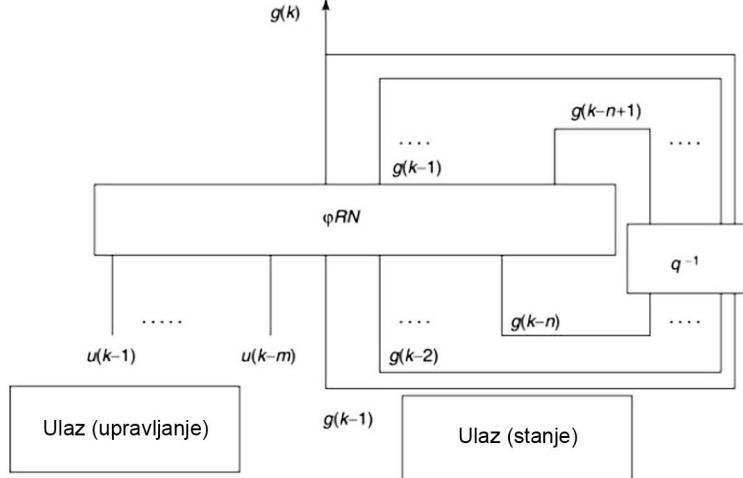
6.2.24. Karakteristike rekurentnih neuronskih mreža

U odeljku koji je bio posvećen neuronskom modeliranju kontrolisanog dinamičkog sistema, feedforward neuronske mreže su bile projektovane kao modeli sa predviđanjem jedan korak unapred. Na slici 6.16 je predstavljen dijagram procesa obučavanja modela prema NARX hipotezi. Pokazano je takođe da je takav pristup relevantan kada je prisutan šum signala. Izlaz iz modela u vremenskom trenutku k može se rekonstruisati na osnovu prošlih vrednosti izlaza procesa koji se posmatra i prošlih vrednosti kontrolnog signala. Nakon završene obuke, izlaz iz mreže može biti priključen na ulaz, u obliku povratne sprege sa određenim zakašnjnjem. Na takav način se formira rekurentna neuronska mreža. Zapravo, dijagram pokazuje mrežu zatvorenog kruga. Takva rekurentna mreža,

koja modelira funkciju ψ_{RN} , se može iskoristiti za predviđanje izlaza procesa u konačnom vremenskom periodu.

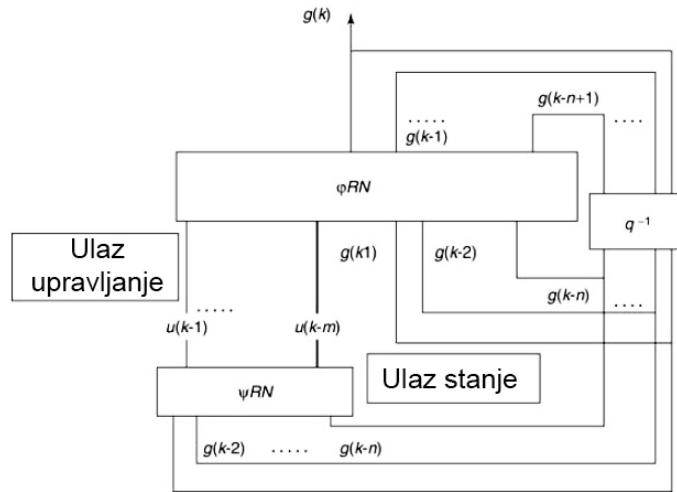
Slika 6.18 pokazuje dijagram tipične rekurentne neuronske mreže. Kod rekurentnih mreža stanje ulaza sastoji se od prošlih vrednosti izlaza [34,35,156,158]. Ako su parametri mreže izračunavani koristeći obučavanje u tzv. otvorenom kolu, kao na slici 6.13, i ako se mreža koristi za predviđanje izlaza procesa jedan korak unapred, takav pristup nije optimalan (predviđanje je pod uticajem šuma signala). Nasuprot tome, što je i teorijski prikazano i ilustrovano kroz primere, predviđanje je optimalno ako je izmereni šum u stvari šum izlaza, ako je obuka sprovedena pomoću polunadgledanog algoritma obuke, i ako su, u toku učenja, izlazi iz modela korišćeni kao ulazi stanja. U tom kontekstu, pretpostavlja se da kontrolni signal $u(k)$ ne zavisi od stanja (zapravo izlaza mreže).

Prema tome, radi se o dinamičkom sistemu kontrolisanom u otvorenom kolu [35].



Slika 6.18. Rekurentna neuronska mreža za modeliranje dinamičkog sistema u otvorenom kolu

Kao što se feedforward neuronska mreža čiji su ulazi (stanje + kontrola) signali, i čiji izlaz je izlaz stanja, koristi za modeliranje kontrolisanog dinamičkog sistema, kontroler može biti modeliran kao posledica uticaja prostora stanja na kontrolni prostor, čime se vrši usklađivanje odgovarajućeg upravljanja sa trenutnim stanjem [35]. Dijagram na slici 6.19 prikazuje vezu između njih.

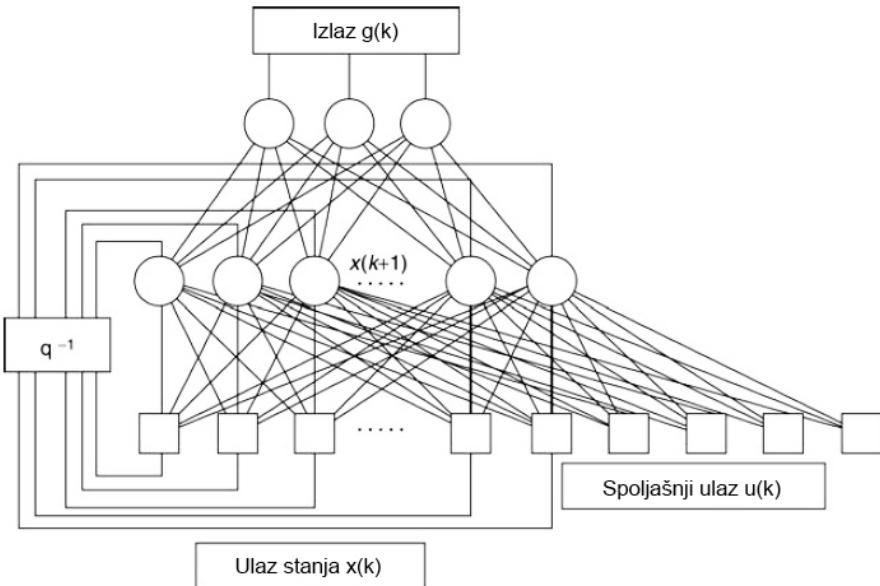


Slika 6.19. Rekurentna neuronska mreža za modeliranje dinamičkog sistema u zatvorenom kolu

Na dijagramu sa slike 6.19 stanje ulaza je povezano i sa modelom procesa i sa kontrolerom koji proračunava kontrolni signal. Taj kontrolni signal je sekundarni ulaz modela [35]. Na taj način je moguće formirati upravljački sistem sa zatvorenim kolom, odnosno sa povratnom spregom. Ako se stanje izlaza priključi na stanje ulaza, dobija se neuronski simulator kontrolisanog dinamičkog sistema u zatvorenom kolu. Kao što je već objašnjeno, takva arhitektura mreže može biti korišćena za predviđanje ponašanja sistema više koraka unapred (u konačnom vremenskom intervalu).

Treba imati na umu da kod rekurentnih neuronskih mreža kašnjenja moraju biti definisana u potpunosti da bi se izbegle nedoumice u dinamici mreže [34,161]. U skladu sa tim, neophodno je da bude ispoštovano sledeće pravilo: Da bi rekurentna neuronska mreža bila dinamička, svaki ciklus grafika mreže mora imati kašnjenje različito od nule [34,35].

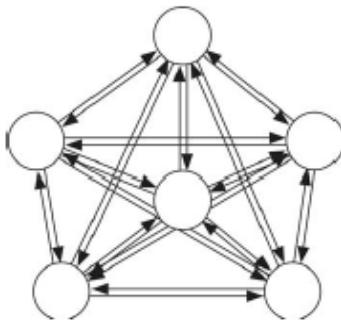
U cilju istraživanja koji tip rekurentne neuronske mreže bi najbolje odgovarao za potrebe modeliranja izrazito nelinearnih dinamičkih procesa, analizirane su i tzv. Elmanova i Hopfieldova mreža. Prema [160], Elmanova mreža je slojevita neuronska mreža, čiji dijagram je prikazan na slici 6.20.



Slika 6.20. Primena Elmanove mreže za modeliranje dinamičkog sistema

Elmanova mreža je mreža sa jednim skrivenim slojem. Izlazi iz neurona u okviru tog sloja se povratnom spregom vraćaju na ulaz sa određenim zakašnjnjem. Prema tome, red modela je jednak broju skrivenih neurona. Elman naziva skrivene neurone kontekstualne jedinice. Izlaz iz mreže u datom trenutku je nelinearna funkcija spoljašnjeg ulaza u istom tom vremenskom trenutku i izlaza skrivenih neurona u prethodnom vremenskom koraku. Treba napomenuti da su osnovne komponente posmatranog dinamičkog sistema jasno obuhvaćene Elmanovim modelom: ulazni sloj mreže se odnosi na upravljanje sistemom, a izlazni sloj na ono što je izmereno. Veza ulaznog sloja ka skrivenom sloju se odnosi na uticaj upravljanja na promenu stanja [35,160].

Prema [34,35,161], Hopfieldove mreže su igrale veoma važnu ulogu još od 1982. godine. One su bile inspirisane napretkom statističke fizike i njene primene na kompleksne sisteme. Te 1982. godine Hopfield je predstavio neuronski model koji je predstavljao značajan pomak u odnosu na tada popularan perceptron (slika 6.21). On je naglašavao dinamičke karakteristike bioloških mreža koje nemaju rekurentne veze.



Slika 6.21. Hopfieldova mreža

Hopfieldova mreža je sastavljena od binarnih neurona sa koračnom funkcijom kao aktivacionom funkcijom. Izlaz y iz neurona je definisan kao:

$$y = H\left(\sum_j w_{ij}x_j\right) \text{ gde je } H(x) = 1 \text{ ako je } \sum_j w_{ij}x_j \geq 0 \text{ i } H(x) = 0 \quad (6.45)$$

gde su x_j vrednosti ulaza i-tog neurona, a ostale vrednosti su izlazi svih ostalih neurona. Na taj način svaki neuron kodira binarnu informaciju i stanje mreže tada predstavlja vektor izlaza neurona. To je binarni vektor koji kodira informacije.

Hopfieldova mreža nema eksternih ulaza. Njeno ponašanje je autonomno i zavisi jedino od njene sopstvene dinamike. Da bi se garantovala opšta stabilnost jedne takve mreže, tj. da bi se garantovalo da stanje mreže konvergira ka stabilnom bez obzira na početno stanje i da bi bilo moguće da se izračuna ta stabilnost, Hopfield je uveo simetriju u povezivanju. Težinski odnosi od neurona i ka neuronom j su jednaki težinskim odnosima od neurona j ka neuronom i . Pored toga, svaka konekcija sadrži zakašnjenje (ove pretpostavke nisu u skladu sa biološkim pristupom). Na slici 6.21 je prikazana Hopfieldova mreža sa šest binarnih neurona. Oznake zakašnjenja u okviru pojedinih konekcija su izostavljene. Proces obučavanja ovakve mreže se sastoji u proračunavanju parametara mreže na taj način da se oni parametri koje treba sačuvati kodiraju putem ravnotežnog stanja dinamike mreže. Iz Hopfieldove teorije se može izvesti zaključak: sa biološke tačke gledišta na modeliranje, prednost Hopfieldovog modela je u naglašavanju uloge dinamike u kognitivnim funkcijama bioloških neuronskih mreža, kao i prikaz veze između učenja i korelacije predstavljenim Hebovim učenjem [167].

6.2.25. Obuka rekurentnih neuronskih mreža

Eduardo Sontag u [168] je dokazao da su rekurentne neuronske mreže univerzalni aproksimatori kontrolisanih, determinističkih dinamičkih sistema. Baš kao i univerzalna Hornikova teorema za aproksimaciju funkcije (objašnjena u [35]), ni ova teorema nije konstruktivna i ne daje nikakvu indikaciju bilo o arhitekturi mreže ili o algoritmu obuke. Osnovni problem kod obučavanja rekurentnih mreža *gradient descent* metodom (gradijentna metoda prvog ili drugog reda) je uzrokovan vremenskim domenom kao posledice promene težinskih odnosa [34,35]. Uticaj vrednosti težinskih odnosa na posmatranu funkciju nije ograničen trenutnim vremenom, on se prenosi kroz domen proračunavanja, koji je teoretski neograničen. Prema striktnom matematičkom razmatranju, izračunavanje gradijenta posmatrane funkcije zahteva prenošenje izračunavanja za svaki primer u okviru čitavog opsega računanja, računanje korekcije težinskih odnosa i nove iteracije ako je to potrebno. Proces obuke rekurentnih mreža bi tada bio veoma dug za veoma velike sekvene podataka. To bi posebno otežavalo implementaciju kod procesa koji se prate u realnom vremenu. Prema tome, kada se za modeliranje i upravljanje dinamičkim sistemom predlaže rekurentna arhitektura neuronske mreže, koriste se aproksimativna rešenja.

Kada je stanje sistema poznato u potpunosti jer je mereno u svakom od vremenskih trenutaka ne postoji poseban problem. Tada veoma lako može biti primjenjen algoritam nadgledanog obučavanja jer je ta tehnika pogodna jedino u slučajevima gde je odgovarajuća nepredvidivost modelirana sa postojanjem šuma. Ovakav pristup se pokazao kao loš kada šum merenja mora biti uzet u obzir, što je veoma česta situacija u industrijskoj primeni. U opštem slučaju, gde je znanje o stanju procesa ometeno šumom merenja ili nije izmereno u potpunosti, neophodno je napraviti izbor između dve aproksimacije [35,160]:

- ✓ Računanje stvarnog gradijenta u odnosu na trenutne vrednosti težinskih odnosa, ali sa promenom funkcije koja se posmatra putem skraćenja perioda računanja pomoću tzv. kliznog prozora, što se naziva backpropagation kroz vreme, ili

- ✓ Aproksimacija gradijenta prethodnih stanja sistema u odnosu na trenutne vrednosti težinskih odnosa putem vrednosti gradijenata u odnosu na prethodne vrednosti težinskih odnosa, što se naziva rekurentna obuka u realnom vremenu.

Kod metode nadgledanog obučavanja svi ulazi kanonskog oblika mreže su poznati tokom procesa obuke [35]. Dakle, treba uzeti u obzir činjenicu da su eksperimentalni podaci za podešavanje modela dostupni u bilo kom vremenskom trenutku. Proces obuke mreže se tada može posmatrati kao nelinearna regresija mreže na njene ulaze.

Ulagano stanje, odnosno zakašnjenje (set od N ulaznih podataka) se u tom slučaju koristi kao baza podataka procesa obuke. Međustanja (u trenutku k) se koriste i kao izlazi (da bi se sagledala evolucija računanja u mreži od trenutka $k-1$ do trenutka k) i kao ulazi u mrežu (da se omogući sagledavanje evolucije računanja od trenutka k do $k+1$). Naravno, da bi se ovaj jednostavan metod primenio, celokupan ulaz u proces mora biti poznat u svakom vremenskom koraku. On ne može biti implementiran u opštem slučaju [35,158].

Prema [35], kod kanonskog oblika mreže i primene backpropagation metode, rekurentne karakteristike mreže se mogu razmatrati putem formiranja mreže sa prostiranjem signala unapred čiji izlazi su identični sa sekvencom izlaza rekurentne mreže. Takva mreža se dobija kopiranjem feedforward dela kanonskog oblika N puta (ako je sekvenca za obuku dužine N). Trajektorija stanja procesa nije merena pošto ne može biti iskorišćena kao stanje ulaza tokom obuke. Stanje mreže je inicijalno podešeno kao stanje procesa ukoliko je ono dostupno (polunadgledano obučavanje). Ukoliko to nije slučaj, stanje ulaza mreže se inicijalizuje na proizvoljnu vrednost (a priori inicijalizacija).

Razvijanje kanonskog oblika mreže podrazumeva formiranje feedforward mreže [35]. Bilo koji algoritam obuke može biti korišćen, pod uslovom da su svi težinski odnosi kopija identični [34]. Prema tome, tehnika deljenja težinskih odnosa mora biti korišćena. Ukoliko su sekvene podataka za obuku preduge, ili ako je neophodna adaptivna (on-line) obuka, sekvene za obuku moraju biti

odsečene tako da traju konačno vreme jer se tada omogućava korišćenje ograničene količine informacija o prošlom stanju sistema za svaki korak obuke.

Ako se uzme da je p trajanje tog perioda, u trenutku n su jedino informacije koje se odnose na vremenski trenutak $n-p+1$ do n uzete u obzir. To dalje vodi prema novom označavanju: od sada će sa k biti označavan broj kopije u odnosu na korak n , gde k varira od 1 do p .

Komponenta gradijenta kvadratne greške u odnosu na težinski odnos rekurentne neuronske mreže je suma izračunatih komponenata gradijenta u odnosu na sve konekcije razvijene mreže, koje dele istu vrednost težinskog odnosa. Metod za obuku rekurentnih neuronskih mreža u realnom vremenu počiva na drugoj aproksimaciji, različitoj od odsecanja vremena. Najbolje je ponovo poći od evolucionu jednačinu rekurentne mreže od trenutka n do trenutka $n+1$ u kanonskom obliku:

$$x(n+1) = g[u(n), x(n), w(n)] \quad (6.46)$$

$$y(n+1) = h[u(n), x(n), w(n)] \quad (6.47)$$

Potrebno je dakle izračunati, sa težinskim odnosima $w(n)$, gradijent funkcije ψ_1^{n+1} koja uzima ulaz w i daje $y = \psi_1^{n+1}$ na izlazu. Računanje će biti sprovedeno od početnog stanja $x(0)$ korišćenjem sledećih jednačina. Za $k = 0, \dots, n$ tada važi $x(k+1) = g[u(k), x(k), w]$ i $y(k+1) = h[u(n), x(n), w]$. Diferenciranjem ovih jednačina dobija se:

$$\nabla_w \psi_1^{n+1}[w(n)] = \nabla_w h[u(n), x(n), w(n)] + \nabla_x h[u(n), x(n), w(n)] \cdot \nabla_w \Phi_1^n[w(n)] \quad (6.48)$$

gde je Φ_1^n definisano kao funkcija koja uzima ulaz w i daje $x = \Phi_1^n$ pomoću sledeće rekurzivne formule, gde za $k = 0, \dots, n-1$ važi $x(k+1) = g[u(k), x(k), w]$ i $x = x(n)$. Nasuprot backpropagation algoritmu, ukupan gradijent se mora računati eksplicitno. Računanje mora biti sprovedeno od ulaza ka izlazu, umesto da bude sprovedeno unazad. Na osnovu ovih i ranije navedenih zaključaka, veštačke neuronske mreže se mogu koristiti za projektovanje kontrolera [35,155,156].

6.3. FAZI LOGIKA

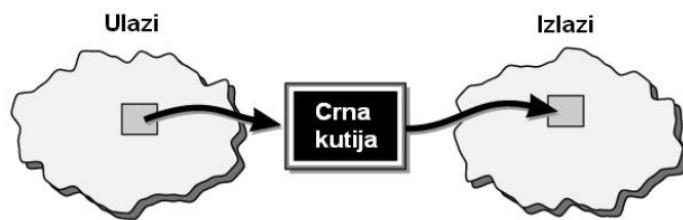
6.3.1. Uvod

Još jedna od tehnika iz domena veštačke inteligencije koja je analizirana u ovoj doktorskoj disertaciji je fazi logika. Istraživane su mogućnosti ove tehnike u pogledu razvoja intelligentnih osobina kočnog sistema, a posebno je posvećena pažnja analizi mogućnosti njenog kombinovanja sa metodom veštačkih neuronskih mreža. Istraživano je takođe na koji način je moguće iskoristiti i ugraditi ekspertska znanja koja se mogu definisati pomoću fazi logičkih pravila kako bi se ostvarila stabilnost upravljanja performansama kočnog sistema u neodređenim situacijama u kojima on može da se nađe. Pod neodređenim situacijama se mogu podrazumevati eventualne pojave grešaka u predviđanju dinamičkog neuronskog modela.

Da bi se dao adekvatan odgovor na pitanje šta je to fazi logika, neophodno je uporediti ovaj pristup sa konvencijalnom logikom. Osnove klasične logike je učvrstio još u antičkoj Grčkoj poznati filozof Aristotel. Ova logika se zasniva na jasnim i precizno utvđenim pravilima, a počiva na teoriji skupova. Neki element može da pripada nekom skupu ili da ne pripada. Skupovi imaju jasno određene granice. Tako su ovakvi skupovi, pa sa njima i logika, nazvani engleskom reči *crisp*, koja ima značenje – jasan, bistar. Fazi (engl. *fuzzy*) je engleska reč koja bi mogla da se prevede kao maglovito, nejasno, mutno [169,170].

U fazi logici nije precizno definisana pripadnost jednog elementa određenom skupu, već se pripadnost meri u procentima na primer. Ove mere pripadnosti, skalirane, mogu da uzimaju vrednosti od 0 do 1 [170]. Fazi logiku je predstavio *Lotfi Zadeh* 1965. godine, a u upravljanje sistemima ju je uveo *E. Mamdani* 1976. godine [171]. Još tada je ovaj pristup privukao zavidnu pažnju. Iako se za jednostavnije sisteme fazi pristup pokazao kao veoma efikasan i jasno prilagođen ljudskom poimanju stvari, za komplikovanije sisteme se pokazao kao veoma zahtevan. Za realizaciju kontrolera u tom slučaju je potrebno mnogo resursa, i vremenskih i intelektualnih. U godinama koje su usledile razvijene su različite metode za projektovanje kontrolera koje bi olakšale ovaj proces. Jedna od tih

metoda je projektovanje fazi PID kontrolera, odnosno zadržavanje koncepta PID kontrolera i kombinovanje sa fazi logikom zaključivanja. Za ulaze kontrolera se usvajaju proporcionalno, integralno i diferencijalno dejstvo, kao do tад pozne i prihvачene promenljive o čijem se ponašanju poseduje dovoljno iskustvenog znanja. Sam fazi deo kontrolera je zamišljen tako da odgovara ponašanju konkretnog sistema [169,171]. Prema [172,173], fazi kontroler je kontroler koji vrši preslikavanje ulaza u izlaze korišćenjem fazi logike (slika 6.22).



Slika 6.22. Preslikavanje ulaza u izlaze

Fazi logika kao koncept je puno prirodniji nego što se to u prvom približenju misli. Postoje situacije u kojima nije moguće znanje o sistemu reprezentovati na apsolutno precizan način. Čak je više situacija u kojima moraju da se koriste neprecizne konstatacije [172,174]. Da bismo bili u stanju reprezentovati znanje o ovakvim sistemima (a ima ih jako puno) potrebno je se odreći klasične (binarne) logike u kojoj je nešto ili tačno ili netačno (crno ili belo) i koristiti fazi logiku (sve je nijansa sive boje) [173].

U poslednjih nekoliko godina svedoci smo naglog rasta broja i raznolikosti primene fazi logike (FL). Kao jedna od tehnika veštačke inteligencije, fazi logika poseduje sposobnost da oponaša ljudski um i da efikasno iskoristi način razmišljanja koji je više približan nego tačan [174]. U tradicionalnom računarstvu, odluke ili aktivnosti se zasnivaju na preciznosti, sigurnosti i efikasnosti. Kod tzv. *soft computing* tehnika u donošenju odluka je izražena fleksibilnost. Mogućnost tolerisanja nepreciznosti i neizvesnosti ističe ljudsku sposobnost da razume nerazumljivi govor, dešifruje rukopis, razume dijalekte maternjeg jezika, sažeti tekst, da prepozna i klasifikuje slike. Sa fazi logikom se mogu odrediti pravila mapiranja u obliku reči, ali ne i brojeva [173]. Još jedan osnovni koncept u fazi logici predstavljaju fazi ako-onda (engl. *if-then*) pravila. Iako sistemi zasnovani na

pravilima imaju dugu tradiciju upotrebe u veštačkoj inteligenciji, ono što nedostaje u takvim sistemima je mašina za bavljenje fazi posledicama ili fazi uzrocima. U većini aplikacija, fazi logičko rešenje je prevod ljudskog rešenja. Fazi logika može da modelira nelinearne funkcije proizvoljne složenosti do željenog stepena preciznosti. Ona predstavlja pogodan način za mapiranje ulaznog prostora u izlazni prostor. Ova tehnika je jedan od alata koji se koriste za modeliranje sistema sa više ulaza i više izlaza [174].

6.3.2. Fazi logika i upravljanje

Do danas su razvijane mnoge tehnike projektovanja kontrolera koje bi trebalo da omoguće jasnu metodologiju za ostvarivanje željenih performansi i specifikacija koje kontroler treba da ispuni. Ove tehnike se razlikuju i u pristupu, pa se tako izdvajaju različiti kontroleri: linearni, robusni, nelinearni, adaptivni, zasnovani na prostoru stanja itd. Najveći broj kontrolera u upotrebi danas su PID kontroleri koji se često smatraju kao adekvatno rešenje koje je jednostavno, pouzdano i u velikoj meri lako razumljivo [175,176]. Svi ovi pristupi se oslanjaju na diferencijalne jednačine kojima se dovoljno dobro opisuje dinamičko ponašanje sistema. Matematičke predstave fizičkih zakonitosti po kojima se proces ponaša, dovode do određenih zaključaka kako da se procesom valjano upravlja. Ove jednačine, naravno, opisuju proces sa određenim stepenom zanemarivanja, a sve u cilju da se dobije što jednostavniji model procesa koji zadovoljavajuće predstavlja sistem i njegovu dinamiku. Da bi se dobili kontroleri dobrih performansi razvijene su razne metode podešavanja kontrolera. Ove metode se zasnivaju na heurističkom predznanju o procesu koji treba kontrolisati, kao npr. najčešće korišćena metoda Zigler – Nikols (Ziegler – Nichols) [177].

Iako je postojao veliki entuzijazam u vezi sa primenom fazi logičkog pristupa za upravljanje složenim sistemima tokom 1970-ih i 1980-ih godina, došlo se do zaključka da čovek kao operater u tim slučajevima ne može biti lako zamenjen pa su istraživanja orijentisana ka tome da se fazi logika iskoristi za nadgledanje operatera koji upravlja sistemom, a ne da se on zameni [178]. Ovakva ideja da se fazi logički pristup iskoristi za nadgledanje i eventualno korigovanje pritiska

aktiviranja kočnice koji predlaže neuronski model može biti iskorišćena i za projektovanje sistema za inteligentno upravljanje performansama kočnog sistema. Prema [188], fazi upravljanje obezbeđuje formalnu metodologiju za predstavljanje, manipulaciju i implementaciju ljudskog heurističkog predznanja o tome kako kontrolisati jedan određeni sistem. Ovo ne isključuje razvoj modela procesa jer je taj model u svakom slučaju potreban za detaljnu simulaciju ponašanja kontrolera u cilju ispitivanja zadovoljenja performansi, stabilnosti sistema kao i za ispitivanje krajnih ograničenja samog projektovanja. Cilj fazi pristupa je da, umesto da jezikom matematike pokuša da što bolje reši problem upravljanja sistemom, omogući implementaciju inženjerskog iskustva o procesu u sam algoritam kontrolera [188]. Ovde će biti predstavljena uopštena filozofija ovakvog pristupa projektovanju fazi kontrolera, nakon uvodne analize fazi logike i načina funkcionisanja ove metode veštačke inteligencije.

6.3.3. F0azi skupovi i funkcije pripadanja

Prema [174,176] fazi skupovi su osnovni elementi kojima se opisuje nepreciznost. Diskretan (klasičan) skup sadrži elemente sa istim svojstvima dok fazi skupovi sadrže elemente sa sličnim svojstvima. Kod diskretnih skupova, element ili pripada ili ne pripada određenom skupu, a ako se to predstavi matematički, može se reći da je stepen pripadnosti skupu 1 (ako pripada) ili 0 (ako ne pripada). Sa druge strane, elementi u fazi skupovima mogu delimično da pripadaju, a matematički se to može predstaviti na sledeći način 1 (100% pripada), 0 (uopšte ne pripada skupu), ili 0,7 (70% pripada skupu). Ovim pristupom se mogu preciznije reprezentovati neprecizni iskazi [188].

Osnovne osobine jednog fazi skupa su:

- ✓ normalnost (maksimalna vrednost funkcije pripadnosti je 1),
- ✓ konveksnost, i
- ✓ broj elemenata.

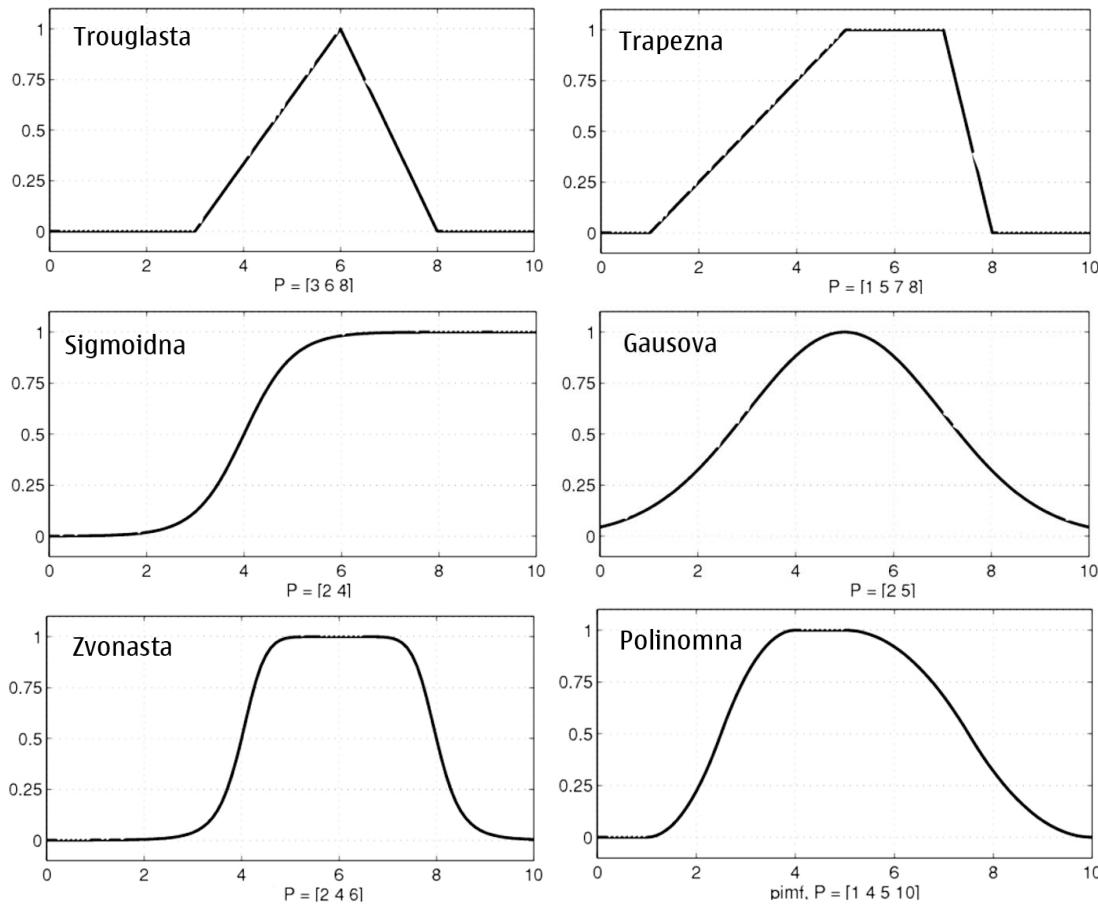
Broj elemenata skupa računa sa kao zbir vrednosti funkcije pripadnosti svakog elementa. Kao i kod diskretnih skupova i ovde se definišu osnovne operacije (unija, presek, negacija i komplement).

Fazi tehnike u obliku približnog rezonovanja pružaju podršku u odlučivanju i ekspertnim sistemima sa dobim mogućnostima rasuđivanja . Popustljivosti u fazifikaciji procesa ljudskog razmišljanja ukazuju na to da veći deo te logike nije tradicionalna dvoveličinska logika, već logika sa fazi istinama, fazi konekcijama i fazi pravilima zaključivanja. Fazi skup je produžetak tzv. krisp skupa [174,175]. Krisp skup dozvoljava samo punopravno članstvo ili ono ne postoji uopšte, dok fazi skup dozvoljava delimična članstvo. Prema [169], u krisp skupu, pripadnost ili nepripadnost elementa x u skupu A je opisana funkcijom $\mu_A(x)$, gde je $\mu_A(x)=1$ ako $x \in A$ i $\mu_A(x)=0$ ako $x \notin A$. Teorija fazi skupova proširuje ovaj koncept definisanjem parcijalne pripadnosti. Fazi skup A u domenu prostora U je okarakterisan funkcijom pripadanja $\mu_A(x)$ koja uzima vrednosti iz intervala $[0,1]$. Fazi skupovi predstavljaju zdravorazumske lingvističke pojmove kao što su spor, brz, mali, veliki, težak, nizak, srednji, visok, visoko, itd. Dati element može biti član više od jednog fazi skupa u isto vreme. Fazi skup A u U može biti predstavljen kao skup uređenih parova. Svaki par se sastoji od generičkih elemenata x i njegove ocene funkcije pripadnosti, tj. i $A = \{(x, \mu_A(x)) | x \in U\}$, x se naziva pomoćna vrednost ako $\mu_A(x) > 0$. Lingvistička promenljiva x u domenu prostora U može biti predstavljena kao $T(x) = \{T_x^1, T_x^2, \dots, T_x^k\}$ i $\mu(x) = \{\mu_x^1, \mu_x^2, \dots, \mu_x^k\}$, gde je $T(x)$ odgovarajuća vrednost člana x . Na primer, ako x ukazuje na visinu, onda se T može odnositi na skupove kao što su kratko, srednje ili visoko. Funkcija pripadanja je u suštini kriva koja definiše kako se svaka tačka u ulaznom prostoru mapira u odgovarajuću vrednost pripadanja (ili stepen pripadanja) između 0 i 1 [174,176,179].

U skladu sa [179], u fazi logici se koriste različite vrste funkcije pripadanja kao što su trouglaste, trapezoidne, generalizovan oblik zvona, Gausove krive, polinom krive, i sigmoidne funkcije (slika 6.23). Trouglaste krive se najčešće koriste za opisivanje stepena pripadnosti određene promenljive fazi skupu i zavise od tri

parametra, a, b i c (jednačina 6.49), pri čemu ovi parametri predstavljaju temena trougla.

$$f(x; a, b, c) = \begin{cases} 0 & x < a \\ \frac{x-a}{b-a} & a \leq x < b \\ \frac{c-x}{c-b} & b \leq x \leq c \\ 0 & x > c \end{cases} \quad (6.49)$$



Slika 6.23. Tipovi funkcija pripadanja

6.3.4. Logičke operacije i *ako-onda* pravila

Operacije sa fazi skupovima su analogne operacijama sa krisp skupovima [174]. Važna stvar u definisanju logičkih operatora fazi skupova se odnosi na to da ako zadržimo fazi vrednosti na ekstremumu koji je jednak 1 (tačno) ili 0 (netačno), trebalo bi da se standardne logičke operacije održe. U cilju definisanja fazi skupa logičkih operatora, prvo treba razmotriti operatore krisp skupa. Najelementarnije

operacije krisp skupa su unija, presek i komplementarnost, i koje u suštini odgovaraju *ILI*, *I* i *NE* operatorima, respektivno [169,172,173,174]. Ako su A i B dva podskupa domena U njihova unija, označena sa $A \cup B$, sadrži sve elemente ova dva skupa, tako da važi $\mu_{A \cup B}(x) = 1$ ako $x \in A$ ili $x \in B$. Presek skupova A i B , označen sa $A \cap B$, sadrži sve elemente koji su istovremeno sadržani i u A i u B , tako da važi $\mu_{A \cap B}(x) = 1$ ako $x \in A$ i $x \in B$. Komplement skupa A se označava sa \bar{A} i sadrži sve elemente koji ne pripadaju skupu A , tako da važi $\mu_{\bar{A}}(x) = 1$ ako $x \notin A$ i $\mu_{\bar{A}}(x) = 0$ ako $x \in A$. Logičke tablice ovih operatora u skladu sa [178] prikazane su u tabeli 6.1.

Tabela 6.1. Logičke tablice fazi operatora

I (AND)			ILI (OR)			NE (NOT)	
A	B	$A \cup B$	A	B	$A \cap B$	A	\bar{A}
0	0	0	0	0	0	0	1
0	1	0	0	1	1	1	0
1	0	0	1	0	1		
1	1	1	1	1	1		

U fazi logici, istinitost bilo kog tvrđenja je stvar stepena [174]. U cilju definisanja operatora fazi logike, neophodno je naći odgovarajuće operatore koji čuvaju rezultat korišćenja *I*, *ILI* i *NE* operatora. Odgovor su *min*, *max*, i *complement* operacije. Ovi operatori su definisani, respektivno, kao:

$$\begin{aligned}\mu_{A \cup B}(x) &= \max[\mu_A(x), \mu_B(x)] \\ \mu_{A \cap B}(x) &= \min[\mu_A(x), \mu_B(x)] \\ \mu_{\bar{A}}(x) &= 1 - \mu_A(x)\end{aligned}\tag{6.50}$$

Formule za *I*, *ILI* i *NE* operatore iz jednačine 6.50 su korisne za dokazivanje ostalih matematičkih osobina skupova, međutim, *min* i *max* nisu jedini način za opisivanje preseka i unije dva skupa. Lotfi Zadeh je 1965. godine definisao fazi uniju i fazi presek kao:

$$\begin{aligned}\mu_{A \cup B}(x) &= \mu_A(x) + \mu_B(x) - \mu_A(x)\mu_B(x) \\ \mu_{A \cap B}(x) &= \mu_A(x)\mu_B(x)\end{aligned}\tag{6.51}$$

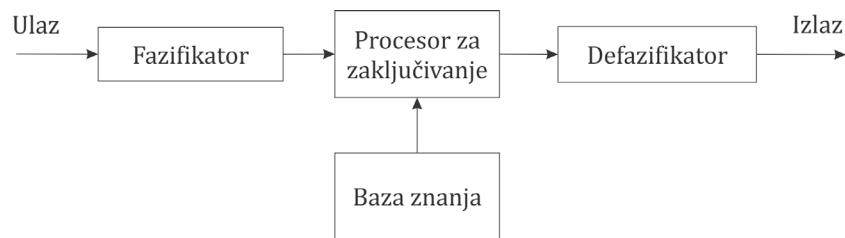
U opštijem smislu, presek dva skupa A i B je predstavljen binarnim mapiranjem T koji spaja dve funkcije pripadanja kao:

$$\mu_{A \cap B}(x) = T(\mu_A(x)\mu_B(x)) \quad (6.52)$$

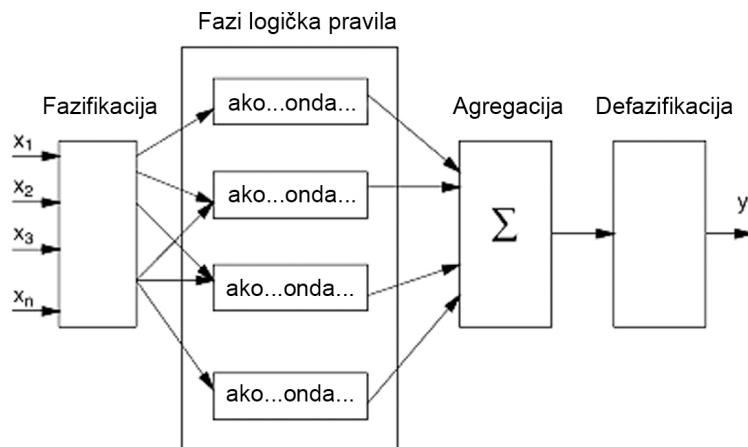
6.3.5. Sistem fazi upravljanja

Prema [176], fazi sistem zaključivanja (engl. fuzzy inference system - FIS) u suštini definiše nelinearno mapiranje vektora ulaznih podataka u skalarni izlaz koristeći fazi pravila . Proces mapiranja obuhvata ulazno/izlazne funkcije pripadanja, fazi logičke operatore, fazi ako-onda pravila, agregaciju izlaznih skupova i defazifikaciju. FIS sa više izlaza može se smatrati kao sistem sa više nezavisnih ulaza i jednim izlazom. Opšti model sistema fazi zaključivanja (FIS) je prikazan na slici 6.24. FIS mapira krisp ulaze u krisp izlaze. Sa slike 6.24 se može videti da FIS sadrži četiri komponente: fazifikator, procesor za zaključivanje, bazu pravila i defazifikator. Baza pravila sadrži jezička pravila obezbeđena od strane eksperata. Takođe je moguće izvući pravila iz numeričkih podataka. Kada su pravila uspostavljena, FIS se može posmatrati kao sistem koji mapira ulaz vektor u izlazni vektor. Fazifikator mapira ulazne brojeve u odgovarajuće fazi članove. To je potrebno da bi se aktivirala pravila u smislu jezičkih promenljivih. Fazifikator prihvata ulazne vrednosti i određuje njihov stepen pripadnosti svakom od fazi skupova pomoću funkcije pripadanja. Procesor zaključivanja definiše mapiranje iz ulaznog fazi skupa u izlazni fazi skup. On određuje stepen zadovoljenja zadatog kriterijuma. Ako prethodno pravilo ima više od jedne klauzule, fazi operateri se primenjuju za dobijanje jednog broja koji predstavlja rezultat prethodnog pravila. Moguće je da jedno ili više pravila deluje u isto vreme. Izlazi za sva pravila se tada udružuju. Tokom agregacije, fazi skupovi koji predstavljaju izlaz svakog pravila se kombinuju u jedan fazi skup. Fazi pravila se primenjuju paralelno, što je jedan od važnih aspekata FIS-a. U FIS-u, redosled kojim se pravila primenjuju ne utiče na izlaz. Defazifikator mapira izlaz fazi skupa u krisp broj. S obzirom na fazi skup koji obuhvata opseg izlaznih vrednosti, defazifikator vraća jedan broj , čime se prelazi od fazi skupa na krisp broj. Nekoliko metoda za defazifikaciju se koriste u praksi , uključujući centroid, maksimum, osrednjeni maksimum, itd. Najpopularniji metod za defazifikaciju je centroid, koji izračunava, tj. određuje težište agregatnog fazi skupa [174,175]. FIS sistemi koriste pravila. Međutim, za razliku od

konvencionalnih pravila kod ekspertskega sistema, fazi pravilo lokalizuje region prostora uz površ funkcije, umesto da izoluje točke na površi. Za dati ulaz, večje od jednog pravila može biti veljano. Takođe, u FIS-u se više regiona kombinuje u izlazni prostor za formiranje kompozitnog regiona [173]. Generalni šematski prikaz FIS-a je dat na sliki 6.25. Sve ove osobine će biti detaljnije objašnjene na realnom primeru primene fazi logike za projektovanje fazi kontrolera, odnosno fazi sistema upravljanja u narednom izlaganju.



Slika 6.24. Blok dijagram fazi sistema zaključivanja



Slika 6.25. Šematski prikaz FIS-a

6.3.6. Struktura fazi kontrolera

U osnovi, na fazi kontroler treba gledati kao na veštačkog donosioca odluke koji radi u sistemu sa zatvorenim spregom u realnom vremenu. On „sakuplja“ podatke izlaza procesa, upoređuje ih sa referencom i onda na način svojstven fazi logici „odlučuje“ šta u tom trenutku treba da bude ulaz procesa, i to tako da se zadovolje željene performanse i zadati ciljevi specifikacije [170,171].

U skladu sa [173], da bi se projektovao jedan fazi kontroler potrebno je pre svega određeno predznanje o ponašanju procesa. Heurističke informacije o tome

kako najbolje upravljati nekim procesom mogu da se prikupe na dva načina. Informacije se najčešće dobijaju od operatera koji ima dovoljno iskustvenih podataka o tome kako na najbolji način upravljati procesom. Ređe zaključke o upravljanju procesa donose specijalno angažovani inženjeri koji, shvatajući dinamiku procesa, mogu da odrede pravila po kojima bi se procesom moglo upravljati [168,169]. Ova pravila govore kakav bi trebalo da bude ulaz procesa ako se njegov izlaz ponaša na određeni način. Prema [172], količina informacija ne bi trebalo da bude manja od informacija potrebnih za projektovanje nekog od konvencionalnih kontrolera. Projektovanje fazi kontrolera po definiciji ne isključuje odsustvo potrebe za nalaženjem modela procesa. Prednost fazi načina se ne ogleda u tome. Pri konvencionalnom projektovanju, za opisivanje dinamike sistema se koriste diferencijalne jednačine, koje se kasnije pokušavaju pojednostaviti i tako učine što „razumljivije“ mašinama. Time one postaju ujedno manje razumljive ljudima. Fazi pristup je drugačiji. On ljudski način rezonovanja unosi u računarsku logiku – računarski algoritam postaje bliži ljudskom zaključivanju i samim tim jednostavniji ljudima za shvatanje [175,176]. Pošto se prvenstveno zasniva na FIS-u, rad fazi logičkog kontrolera se vrši pomoću sledećih komponenata/operacija:

- ✓ Baza pravila sadrži znanje o tome kako najbolje kontrolisati sistem, i to u formi skupa logičkih (ako – onda) pravila.
- ✓ Interfejs je mehanizam za procenjivanje koja kontrolna pravila su relevantna za trenutno stanje sistema i odlučuje logičkim sklopom kakav će biti upravljački signal, tj. ulaz u proces.
- ✓ Fazifikacija modificuje signale ulaza tako da mogu biti pravilno protumačeni i upoređeni sa pravilima u bazi pravila. Realan signal se pretvara u adekvatan fazi oblik.
- ✓ Defazifikacija transformiše zaključak interfejsa u takav oblik signala da ovaj može biti signal koji predstavlja ulaz u proces. Ovo je transformacija fazi oblika u realni oblik signala, koji je „razumljiv“ procesu.

Prvi korak u projektovanju fazi logičkog kontrolera predstavlja izbor ulaza i izlaza kontrolera. Promenljive koje nose informaciju o ponašanju sistema treba da budu ulazi kontrolera. Proučavanjem sistema se može uvideti da je moguće uzeti različite informacije [175]. Postoje mnoga intuitivna rešenja za izbor promenljivih koje nose dovoljno informacija o trenutnom stanju sistema i na kojima će se zasnovati odluka kontrolera. Sledeći korak je izbor kontrolne promenljive, odnosno ulaza u proces [175,189]. Za kompleksnije sisteme izbor ulaza i izlaza kontrolera može biti teži. Da bi kontroler mogao da doneše odluku o vrednosti upravljačke promenljive, mora da prima dovoljno informacija kroz signale ulaza. Ako se ispostavi da kontroler ne radi dobro, problem je možda upravo u izboru ulaznih signala ili u nedovoljnem broju relevantnih parametara koji su uzeti u obzir. Takođe, kontroler mora imati izlaz koji će upravljati sistemom tako da ga dovede u zahtevano stanje sa željenim performansama. U laboratorijskim uslovima i uslovima simulacije, sistemi i njihovo ponašanje su relativno poznati. Sistemi sa kojima se inženjeri sreću u praksi su obično višeslojno komplikovani i izbor ovih promenljivih se ne sme uzeti olako [176]. Ulazi i izlazi mogu imati različite lingvističke nazive [176]. Uobičajeno se promenljive nazivaju opisnim imenima, poput: veličina pritiska, mala razlika, velike zarade, brzi automobili, mala rastojanja, veliko klizanje, itd. Ovo je dobar pristup, ali treba biti obazriv da se zarad što boljeg opisa promenljive i njenog uticaja na sistem ne napravi previše komplikovan i dug naziv. Transformaciju ovakvih izraza u oblik matematičke predstave omogućava teorija fazi skupova [174].

Lingvističke promenljive bi trebalo da imaju i lingvističke vrednosti. To mogu biti: „negativno veliko“, „negativno srednje“, „negativno malo“, „blisko nuli“, „pozitivno veliko“, „dobro“ i sl. Ovim vrednostima je moguće dodeliti i numeričku predstavu u cilju lakšeg i kraćeg obeležavanja [172,174]. Sve ovo koristi da se što bolje objasni dinamika sistema kroz lingvističku predstavu znanja o procesu. Što je proces više razumljiv, lingvistička predstava njegovog ponašanja će biti preciznija i samim tim dovesti do razvoja boljeg kontrolera. Slučaj da neka lingvistička promenjiva uzima određenu lingvističku vrednost mora da predstavlja jasno određeno stanje sistema i da se distancira od drugih slučajeva [174]. Kao što je već

objašnjeno, funkcije pripadanja određuju koju vrednost imaju lingvističke vrednosti. Funkcija pripadanja predstavlja kontinualno merilo sigurnosti da li je data promenjiva klasifikovana kao ta lingvistička vrednost. Ova funkcija određuje stepen pripadanja nekog objekta datom fazi skupu [175,176]. Jedino što funkcija pripadanja mora da ispuni jeste da bude skalirana i da uzima vrednosti od 0 do 1, kao stvarne reprezentante stepena pripadanja promenljive toj funkciji. Kakva će biti funkcija pripadnosti zavisi od uslova i ponašanja sistema.

Fazifikacija predstavlja samo vrstu predstave krisp veličina u takav oblik da bude primenjiv u fazi logici. Često se ovaj postupak naziva i kodiranje. Ovo omogućavaju upravo funkcije pripadnosti, koje u stvari mapiraju stepen istinitosti neke tvrdnje [176]. Fazifikacija predstavlja preslikavanje numeričkih vrednosti ulaza x u fazi skup. Poseban oblik fazifikacije predstavlja tzv. „singleton“ fazifikacija. Proizvod ovog preslikavanja je skup čija funkcija pripadanja uzima samo jednu, diskretnu vrednost. Ovakva singleton funkcija se predstavlja diskretnom impulsnom funkcijom. Ona se često koristi u procesu određivanja fazi skupa izlaznih promenljivih fazi kontrolera. Izlazi tada uzimaju konačan broj diskretnih i određenih vrednosti. Ovo je pogodnost u automatskom upravljanju, jer se često vrednosti upravljačkih signala moraju kretati u ograničenom opsegu, da bi se zadržala stabilnost sistema. Ovakvi kontroleri se nazivaju *sugeno* tip kontrolera [169,170,173].

U narednom koraku, potrebno je pronaći način kako lingvističko znanje o procesu uneti u fazi kontroler. Cilj fazi kontrolera je da fazi logikom mapira preslikavanje ulaza u izlaze kontrolera. Primarni mehanizam za to je lista *ako-onda* tvrdjenja koja se nazivaju pravilima. Sva pravila se izvršavaju paralelno i njihov redosled nije bitan. Ovakva lista pravila se naziva baza pravila. Pravila se odnose na lingvističke promenljive i na njihove osobine [176]. Pravila imaju oblik:

ako (situacija) onda (akcija)

Na isti način kao što teorija krisp skupova služi kao osnova za klasičnu logiku, teorija fazi skupova služi kao osnova za fazi logiku. Osnovni pojam fazi logike, kao i logike krisp skupova, je tvrdjenje (iskaz) koje ima oblik x je A . Operacije preseka, unije i komplementa imaju svoje korespondente u fazi logici u veznicima „i“, „ili“ i

„ne“, tako da se pomoću njih mogu graditi složena tvrđenja. Maksimalno moguć broj pravila je određen brojem ulaznih veličina i brojem lingvističkih vrednosti. Ako je broj ulaza n , a broj vrednosti za svaku veličinu ponaosob m , onda je maksimalan broj pravila mn . Ovo važi u slučaju svih kombinacija, mada se dešava da ako jedna promenjiva ima određenu vrednost, druga ulazna promenjiva nema nikakav uticaj. Ako broj ulaza u kontroler nije prevelik, zgodan način predstavljanja svih slučajeva je u formi tabele. Pravila ne mogu da budu sasvim precizna. To je zato što promenljive uzimaju lingvističke vrednosti i to iz ograničenog skupa pa samim tim imamo i ograničeni skup pravila. Ona su samo apstraktne predstave o tome kako bi trebalo upravljati procesom. Cilj i nije da budemo precizni već da predstavimo stvari koje imaju važnost, koje su od značaja za dati problem upravljanja procesom [174]. Funkcionalan fazi sistem mora da sadrži više od jednog fazi lingvističkog pravila. Kombinovanjem ovih pravila (poznato kao agregacija), dobija se kompaktna matematička predstava celokupne baze znanja. U zavisnosti od tipa implikacije koja je korišćena, agregacija se svodi na neku od osnovnih logičkih operacija (konjunkciju ili disjunkciju, odnosno T- ili S-normu) [173,174].

Defazifikacija predstavlja u suštini proces suprotan procesu fazifikacije pa se naziva i dekodiranje. Ovo je u stvari proces koji treba da pretvori rezultat agregacije, koji u osnovi predstavlja presek površi, u signal koji je razumljiv procesu. Izlaz kontrolera mora da ima jednu jedinstvenu vrednost, najčešće predstavljenu realnim brojem. Metode koje se najčešće koriste za defazifikaciju su: centar površi (gravitacije), centar suma, centar najveće površi, prvog maksimuma, sredine maksimuma i visinska defazifikacija [176,179].

Defazifikacija metodom centra površi je najpoznatiji defazifikacioni metod [178]. Ovaj metod glasi:

$$u^{Crisp} = \frac{\sum_{i=1}^R b_i \int_u \mu_B(u) du}{\sum_{i=1}^R \int_u \mu_B(u) du} \quad (6.53)$$

gde je R broj pravila, a b_i - centar površi funkcije pripadanja skupa B , koja predstavlja posledicu i - tog pravila i uzima odgovarajuću lingvističku vrednost. Ovaj metod određuje centar površi ispod kombinovane funkcije pripadnosti, koja se dobija posle agregacije. U obzir se uzima površina ispod funkcija pripadnosti kao jedinstvena, pa stoga ako se površi preklapaju, to se ne reflektuje u formuli [174,179].

6.4. GENETSKI ALGORITMI

6.4.1. Uvod

Imajući u vidu da su genetski algoritmi, kao jedna od metoda veštačke inteligencije, široko korišćeni bilo samostalno za optimizaciju parametara procesa i optimizaciju strukture sistema [180,181,182,183] ili u kombinaciji sa ostalim metodama veštačke inteligencije [51,52,53,54], ovde su istraživane njihove mogućnosti u pogledu moguće primene u oblasti razvoja intelligentnih osobina kočnog sistema. Posebno je istraživana mogućnost kombinovanja genetskih algoritama sa metodom veštačkih neuronskih mreža u cilju formiranja hibridnog sistema pomoću koga bi se moglo intelligentno upravljati performansama kočnog sistema, a u cilju ostvarivanja optimalnog klizanja točka u kontaktu sa tlom. Polazeći od osnovnih karakteristika ove optimizacione metode, analizirano je da li je moguće i pod kojim uslovima implementirati genetske algoritme u cilju realizacije dinamičkog podešavanja pritiska aktiviranja kočnica na prednjoj i zadnjoj osovini. S obzirom na visoku nelinearnost i dinamičnost procesa kočenja, nema sumnje da takva, tzv. *online* optimizacija, mora biti realizovana brzo i to najčešće u vremenskom periodu od nekoliko milisekundi do nekoliko delova sekunde. Zbog toga je ovde takođe u fokusu bila i analiza tačnosti optimalnog rešenja u odnosu na brzinu njegovog pronalaženja.

6.4.2. Globalna optimizacija

Prema [180], globalna optimizacija je grana primjenjenih matematičkih i numeričkih analiza koje se fokusiraju na optimizaciju. Cilj opšte optimizacije je pronalazak najboljih mogućih elemenata x iz seta X prema skupu kriterijuma $F = \{f_1, f_2, \dots, f_n\}$. Ovi kriterijumi se predstavljaju kao matematičke funkcije, odnosno tzv. funkcije cilja [180]. Funkcija cilja se definiše kao matematička funkcija koja je predmet optimizacije, tj. kao funkcija $f : X \rightarrow Y$, gde je $Y \subseteq \mathbb{R}$. Kodomen Y funkcije cilja kao i njen opseg moraju biti podređeni realnim brojevima ($Y \subseteq \mathbb{R}$). Domen X od f zove se prostor problema i može biti predstavljen pomoću bilo kojeg tipa elemenata kao što su brojevi, liste, planovi konstrukcije, itd. Bira se

na osnovu problema koji se rešava sa procesom optimizacije. Funkcije cilja nisu obavezno samo puki matematički izrazi, već mogu biti složeni algoritmi koji, na primer, uključuju više simulacija. Globalna optimizacija obuhvata sve tehnike koje mogu biti korišćene za pronalaženje najboljih elemenata x u X poštujući kriterijum $f \in F$ [180]. Termin „najbolje rešenje“ podrazumeva da postoji više od jednog rešenja i da rešenja nisu jednake vrednosti. Definicija najboljeg je relativna za dati problem, njegov način rešavanja i dozvoljene tolerancije [181,182].

Optimizacija je proces prilagođavanja ulaza karakteristikama uređaja, matematičkog procesa ili eksperimenta zbog pronalaženja minimuma ili maksimuma izlaza ili rezultata. Ulaz se sastoji od promenljivih: proces ili funkcija je poznata kao funkcija cilja, a izlaz je optimalna vrednost. Ako je proces eksperiment, onda su promenljive fizički ulazi eksperimenta [180,181,183,184].

Prema [180], optimizacioni algoritmi se mogu podeliti na šest kategorija. Nijedan od ovih šest pristupa ili njihovih grana nisu nužno međusobno isključivi. Kategorije optimizacionih algoritama se mogu definisati kao:

1. „Trial and error“ optimizacija se odnosi na proces prilagođavanja promenljivih koje utiču na izlaz bez mnogo znanja o procesu koji ga proizvodi.
2. Ako postoji samo jedna promenljiva, optimizacija je jednodimenzionalna. Problem postojanja više od jedne promenljive zahteva višedimenzionalnu optimizaciju. Optimizacija postaje značajno teža sa povećanjem broja dimenzija. Mnogi pristupi višedimenzionalnih optimizacija se odnose na serije jednodimenzionalnih pristupa.
3. Dinamička optimizacija znači da je izlaz funkcija vremena, dok statička znači da je izlaz nezavisan od vremena. Statički problem je teško rešiti ako je u pitanju pronalaženje najboljeg rešenja, ali dodatna vremenska dimenzija translira postupak ka rešavanju dinamičkog problema.
4. Optimizacija se takođe može razlikovati po ili diskretnim ili kontinualnim promenljivama. Diskrete promenljive imaju jedino konačan broj mogućih vrednosti, dok kontinualne promenljive imaju beskonačan broj mogućih

vrednosti. Ako je potrebno odlučiti kojim redom rešavati serije zadataka na listi, koristiće se diskretna optimizacija. Optimizacija diskretnih promenljivih je takođe poznata kao kombinatorička optimizacija, zato što se optimalno rešenje sastoji od izvesnih kombinacija promenljivih iz konačnog skupa svih mogućih promenljivih. Međutim, ako pokušavamo da pronađemo minimalnu vrednost funkcije $f(x)$, prikladnije je sagledati problem kao kontinuirani.

5. Promenljive često imaju ograničenja ili zabrane. Ograničena optimizacija uključuje i dodatne promenljive, a to su linearne jednakosti i linearne nejednakosti funkcije cilja. Optimizacija bez ograničenja dozvoljava promenljivama da imaju bilo koju vrednost. Ograničena promenljiva se često pretvara u neograničenu putem transformacije promenljivih. Većina rutina numeričke optimizacije najbolje radi sa neograničenim promenljivama. Kada ograničena optimizacija formuliše promenljive u smislu linearne jednačine i linearog ograničenja, tada se ona naziva linearni program. Kada su takve jednačine ili ograničenja nelinearni, problem postaje nelinearni problem programiranja.

Prema opštoj podeli datoј u [181,185], optimizacioni algoritmi se mogu podeliti u dve osnovne klase: determinističke i probabilističke. Deterministički algoritmi se najčešće koriste ako postoji jasan odnos između karakteristika mogućih rešenja i njihovih primena za dati problem. Ako veza između kandidata rešenja i njegove „pogodnosti“ nije očigledna ili je previše komplikovana ili su pak dimenzije prostora pretrage veoma velike, postaje teže rešiti problem deterministički. U tom slučaju, treba koristiti probabilističke algoritme. Početna istraživanja u ovoj oblasti, koja je sada postala jedan od najvažnijih oblasti istraživanja u optimizaciji, započela su pre oko 55 godina. Naročito relevantna familija probabilističkih algoritama su „Monte Carlo“ zasnovani pristupi. Oni garantuju konvergenciju ka optimalnom rešenju za kraće vreme. Ovo ne znači da rezultati dobijeni pomoću njih nisu tačni – oni jedino ne moraju biti opšti (globalni) optimum. Sa druge strane, rešenje koje je samo malo lošije od najbolje mogućeg je bolje od onog kome treba 10^{100} godina da bude pronađeno [185].

U pogledu brzine optimizacionog algoritma, prema [181] razlikuju se dva glavna tipa optimizacije:

1. Online optimizacija (optimizacija u realnom vremenu) – problemi optimizacije u realnom vremenu su zadaci koji se moraju rešiti brzo u vremenskom periodu između deset milisekundi do nekoliko minuta. U cilju pronalaženja rešenja u tako kratkom vremenu, optimalnost je obično zamenjena za dobit u brzini. Zadaci online optimizacije se obično izvode u ponavljanjima.
2. Offline optimizacija – u problemima offline optimizacije, vreme nije toliko bitno i korisnik je voljan da sačeka možda i danima ako ona može da mu obezbedi optimalno ili rešenje blizu optimalnog. Ovakvi optimizacioni procesi se obično izvode jednom u dužem vremenskom periodu.

Ako su u pitanju funkcije sa jednim ciljem – u slučaju optimizacije jednog kriterijuma f , optimum je ili njegov maksimum ili minimum, u zavisnosti od toga što se traži. U opštoj (globalnoj) optimizaciji, uobičajeno je da su optimizacioni problemi najčešće definisani kao minimizacije i ako je kriterijum f subjekat maksimizacije, mi prosto minimiziramo njegovu negativnu vrednost ($-f$) [180,181]. Slika 6.26 ilustruje takvu funkciju f koja je definisana preko dvodimenzionalnog prostora $X = (X_1, X_2)$. Kao što je prikazano na dijagramu, razlikuju se lokalni i globalni optimum. Globalni optimum je optimum čitavog domena X dok je lokalni optimum - optimum samo podskupa X .

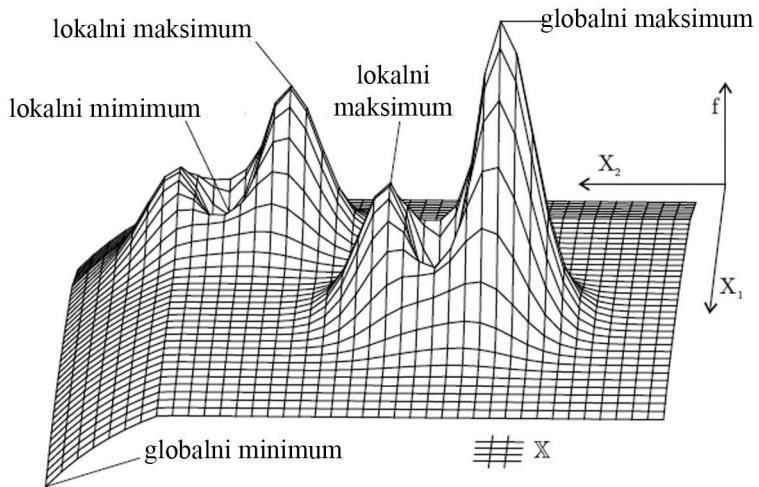
Prema [180], lokalni maksimum $\hat{x}_l \in X$ funkcije cilja $f : X \rightarrow R$ je ulazni element sa $f(\hat{x}_l) \geq f(x)$ za svako x u blizini \hat{x}_l . Ako je $X \subseteq R^n$ može se napisati:

$$\forall \hat{x}_l \exists \varepsilon > 0 : f(\hat{x}_l) \geq f(x) \forall x \in X, |x - \hat{x}_l| < \varepsilon \quad (6.49)$$

Lokalni minimum $\hat{x}_l \in X$ funkcije cilja $f : X \rightarrow R$ je ulazni element sa $f(\hat{x}_l) \leq f(x)$ za svako x u blizini \hat{x}_l . Ako je $X \subseteq R^n$ može se napisati:

$$\forall \hat{x}_l \exists \varepsilon > 0 : f(\hat{x}_l) \leq f(x) \forall x \in X, |x - \hat{x}_l| < \varepsilon \quad (6.50)$$

Slično tome, lokalni optimum $x_l^* \in X$ funkcije cilja $f : X \rightarrow R$ se definiše ili kao lokalni maksimum ili kao lokalni minimum. Globalni maksimum $\hat{x} \in X$ funkcije cilja $f : X \rightarrow R$ je ulazni element sa $f(\hat{x}) \geq f(x), \forall x \in X$. Globalni minimum $\check{x} \in X$ funkcije cilja $f : X \rightarrow R$ je ulazni element sa $f(\check{x}) \leq f(x), \forall x \in X$. Globalni optimum $x_l^* \in X$ funkcije cilja $f : X \rightarrow R$ se definiše ili kao globalni maksimum ili kao globalni minimum.



Slika 6.26. Globalni i lokalni optimum dvodimenzionalne funkcije

Čak i jednodimenzionalna funkcija $f : X = R \mapsto R$ može imati više od jednog globalnog maksimuma, više globalnih minimuma ili čak oba u svom domenu X . Ispravno rešenje takvog problema optimizacije bio bi skup X^* svih optimalnih ulaza u X pre nego samo jednog maksimuma ili minimuma. Osim toga, tačno značenje termina *optimalno* je zavisno od problema. Kod optimizacije sa jednim ciljem to znači minimum ili maksimum. Kod optimizacije sa više ciljeva, postoji varijacija pristupa da bi se definisao optimum.

Skup optimalnih rešenja X^* se definiše kao skup koji sadrži sva optimalna rešenja. Obično ih ima više, čak ponekad i beskonačno mnogo optimalnih mogućnosti. Pošto je memorija računara ograničena, moguće je naći samo njihov konačan (pod)skup. Tako razlikujemo globalni optimalni skup X^* i skup X^* elemenata (koji deluju optimalno) koje optimizator pronađe. Zadaci globalnih optimizacionih algoritama su:

1. Da pronađu rešenja koja su najbolja moguća, i
2. Ona koja su takođe puno različita jedno od drugog.

U slučaju funkcije sa više ciljeva kao što je projektovanje realnih sistema ili problema donošenja odluka, češće se primenjuju skupovi F koji se sastoje od $n = |F|$ funkcija cilja f_i , od kojih svaka predstavlja jedan kriterijum koji se optimizuje.

$$F = \{f_i : X \mapsto Y_i : 0 < i \leq n, Y_i \subseteq R\} \quad (6.54)$$

Algoritmi projektovani da optimiziraju takav set funkcija cilja se obično označavaju prefiksom više-ciljni, poput više-ciljnih evolucionih (genetskih) algoritama [181].

6.4.3. Evolucioni algoritmi

Evolucioni algoritmi (EA) su metaheuristički optimizacioni algoritmi zasnovani na populaciji koji koriste biološki inspirisane mehanizme kao što su mutacija, ukrštanje, prirodna selekcija i opstanak najjačeg u cilju iterativnog filtriranja kandidata rešenja. Prednost evolucionih algoritama u poređenju sa ostalim optimizacionim metodama je njihov karakter tzv. „crne kutije”, koji pravi samo nekoliko prepostavki o njima odgovarajućim funkcijama cilja. Osim toga, definicija funkcija cilja obično zahteva manji uvid u strukturu problema prostora nego manuelna konstrukcija prihvatljive heuristike [181]. Na slici 6.27 prikazan je osnovni ciklus evolucionih algoritama. Pored toga, razlikuju se i evolucioni algoritmi sa jednim i algoritmi sa više ciljeva, pri čemu ovi drugi znače da je moguće pokušati da se optimizuju višestruki, moguće konfliktni kriterijumi. Višeciljni evolucioni algoritam može izvesti optimizaciju više kriterijuma na osnovu veštacke evolucije [181,185].



Slika 6.27. Osnovni ciklus evolucionih algoritama

Familija evolucionih algoritama obuhvata pet članova od kojih su najpoznatiji genetski algoritmi. Budući da su genetski algoritmi u nauci najčešće korišćena tehnika za optimizaciju [181], u ovom radu su analizirane njihove karakteristike kako bi se istražile mogućnosti optimizacije pritiska aktiviranja kočnice u cilju postizanja željenih performansi kočnica, a time i kočnog sistema, odnosno željenog nivoa klizanja u kontaktu pneumatik-tlo.

6.4.4. Osnovne karakteristike genetskih algoritama

Prema [180], genetski algoritmi (GA) su tehnika optimizacije i pretrage zasnovana na principima genetike i prirodne selekcije. Oni predstavljaju jedan od najboljih načina za rešavanje problema o kojima se vrlo malo zna i spadaju u veoma opšte algoritme što im omogućava dobar rad u bilo kojoj oblasti istraživanja. Genetski algoritmi koriste principe selekcije i evolucije za određivanje nekoliko rešenja datog problema. GA dozvoljava populaciji sastavljenoj od određenog broja jedinki da evoluira pod određenim uslovima selekcije u stanje u kome je maksimizirana „pogodnost“, tj. minimizirana funkciju cilja. Metod je prvo bitno razvijen od strane Džona Holanda tokom 1960-ih i 1970-ih, a objavio ga je njegov student Dejvid Goldberg.

Danas postoji mnogo primera primene u nauci, ekonomiji, istraživanju i razvoju koji mogu biti rešavani uz pomoć genetskih algoritama. Dalje treba napomenuti da, zbog uske povezanosti sa biologijom i pošto su genetski algoritmi bili originalno primenjivani na jednokriterijumske optimizacije, funkcije cilja f se obično odnose na funkciju pogodnosti.

Prostori pretrage G genetskih algoritama se odnose na genome i njihovi elementi se zovu genotipi. Genotipi u prirodi obuhvataju sve nasledne informacije organizma zapisanih u DNK. DNK je veza osnovnih parova koji kodiraju fenotipske karakteristike bića kome pripadaju. Kao i njihovi prirodni prototipovi, genomi u genetskim algoritmima su veze, linearne sekvene određenih tipova podataka. Zbog linearne strukture, ti genotipovi se takođe nazivaju hromozomi. U genetskim algoritmima, najčešće se koriste hromozomi koji su veze jednog i istog tipa podataka, na primer nizovi ili realni brojevi [180,181,182].

Genetski algoritmi nastoje da napreduju u oblastima u kojima postoji veoma širok spektar mogućih rešenja i u kojima je prostor za pretragu rešenja neujednačen i ima dosta lokalnih minimuma i maksimuma. Genetski algoritmi se ponašaju dobro u svim okruženjima, ali veoma lako mogu biti nadmašeni od strane algoritama koji su preciznije prilagođeni datoj situaciji u jednostavnijim okruženjima za traženje rešenja [186]. Treba dakle imati u vidu da genetski algoritmi nisu uvek najbolji izbor. Dešava se u nekim situacijama da zakasne sa obradom rezultata, pa stoga nisu uvek pogodni za upotrebu u realnom vremenu. Kako god, genetski algoritmi predstavljaju jedan od najmoćnijih metoda kojim se (relativno) kratko dolazi do visoko kvalitetnih rešenja različitih problema [180,187].

Genetski algoritmi (GA) su adaptivni metod koji se najuspešnije primenjuje za rešavanje problema pretrage i optimizacije. Bazirani su prvenstveno na genetičkim procesima bioloških organizama. Tokom dugog perioda smene generacija, prirodne populacije su evoluirale u skladu sa principima prirodne selekcije i „opstanka najjačeg“. Oponašanjem ovog procesa, genetski algoritmi su u stanju da vrše „evoluciju“ rešenja svakidašnjih realnih problema, ukoliko su oni kodirani na odgovarajući način. GA rade sa *populacijom „pojedinaca“*, od kojih svaki reprezentuje moguće rešenje datog problema. Svaki takav član se usaglašava sa tzv. „rezultatom sposobnosti“ u skladu sa time koliko je dobro rešenje problema. Visokokvalifikovanim članovima date su mogućnosti „reprodukције“ putem „naslednog ukrštanja“ sa ostalim članovima unutar populacije. Rezultat toga je formiranje novih članova, tzv. „izdanaka“, odn. „potomaka“, koji nose genetski

materijal svakog „roditelja“. Najmanje podesni članovi populacije su manje interesantni za izbor za reprodukciju i dakle „umiru“ [188].

Celokupna nova populacija mogućih rešenja je tako proizvedena putem selekcije najboljih članova iz tekuće „generacije“, a daljom njihovom kombinacijom proizvodi se novi skup članova. Takva nova generacija sadrži veću razmeru karakteristika procesuiranih preko dobrih članova prethodne generacije. Na ovaj način, tokom više generacija, dobre karakteristike se razlivaju kroz čitavu populaciju. Favorizovanjem (podsticanjem) kombinovanja najvažnijih članova, ispitane su oblasti prostora za istraživanje koje najviše obećavaju. Ako su genetski algoritmi dobro formirani populacija će konvergirati optimalnom rešenju problema [186,187].

U skladu sa [180,187], prednosti genetskih algoritama u odnosu na druge optimizacione metode su sledeće:

- ✓ Vrše optimizaciju sa kontinualnim ili diskretnim promenljivama
- ✓ Ne zahtevaju informaciju o izvodu promenljive
- ✓ Istovremena pretraga široke površi funkcije
- ✓ Uspešno izlaze na kraj sa velikim brojem promenljivih
- ✓ Pogodni su za paralelno procesiranje
- ✓ Optimiziraju promenljive sa ekstremno složenim površima funkcije cilja (mogu da se oslobole iz lokalnog minimuma)
- ✓ Obezbeđuju nekoliko optimalnih promenljivih, ne samo jedno jedino rešenje
- ✓ Rade sa numerički generisanim podacima, eksperimentalno dobijenim podacima ili analitičkim funkcijama

Kao što je već rečeno, genetski algoritam nije najbolji način da se reši svaki problem. Na primer, tradicionalne metode su podešene tako da brzo pronađu rešenje konveksne analitičke funkcije od samo nekoliko promenljivih. U [181] je pokazano da u takvim slučajevima računski bazirane metode nadigravaju genetski

algoritam brzo pronalazeći rešenje, dok GA i dalje analizira pogodnost inicijalne populacije.

Genetski algoritam koristi tri glavna tipa pravila pri svakom koraku za formiranje naredne generacije od tekuće populacije:

- ✓ Pravila selekcije biraju jedinke, zvane roditelji, a to doprinosi populaciji u sledećoj generaciji.
- ✓ Pravila ukrštanja kombinuju dva roditelja sa ciljem da se formiraju potomci za sledeću generaciju.
- ✓ Pravila mutacije primenjuju nasumične promene kod svakog od roditelja prilikom formiranja potomaka.

Prema [180,181,186,188], način funkcionisanja genetskog algoritma se može sumirati u nekoliko važnih stavki:

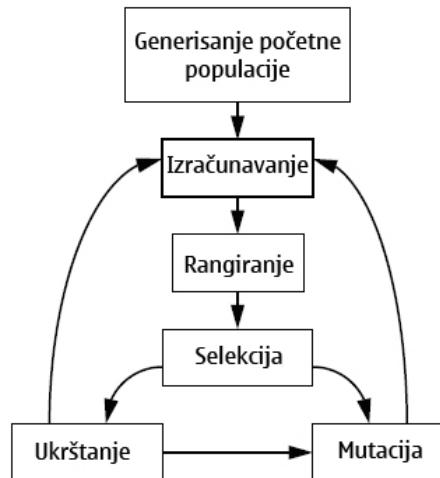
1. Genetski algoritam počinje kreiranjem nasumične početne populacije.
2. Genetski algoritam zatim kreira sekvence novih populacija. Pri svakom koraku, algoritam koristi jedinke iz trenutne generacije za kreiranje sledeće populacije. Da bi se napravila nova populacija, algoritam izvršava sledeće korake:
 - Rangira svakog člana trenutne populacije izračunavanjem njegove pogodnosti.
 - Skalira rangirane pogodnosti pojedinaca da bi ih konvertovao u korisniji opseg vrednosti.
 - Bira članove, zvane roditelji, u zavisnosti od njihov pogodnosti.
 - Neki od pojedinaca u trenutnoj populaciji koji imaju manje vrednosti funkcije cilja se biraju kao elitni. Ovi elitni pojedinci se prenose u sledeću populaciju.
 - Od roditelja proizvodi potomke. Potomci se proizvode ili pravljenjem nasumičnih promena na jednom roditelju (mutacija) ili

kombinovanjem vektora unošenjem delova pojedinih roditelja (ukrštanje).

- Zamenjuje trenutnu populaciju sa potomcima da bi formirao sledeću generaciju.

3. Algoritam se zaustavlja kada je jedan od navedenih kriterijuma ispunjen.

Funkcionisanje genetskog algoritma je proces koji se sastoji iz dve faze [181]. On počinje sa inicijalnom (početnom) populacijom. Selekcija se primenjuje na tekuću populaciju da bi se kreirala među-populacija. Zatim se primenjuju rekombinacija (ukrštanje) i mutacija na tu među-populaciju u cilju formiranja naredne populacije. Proces kretanja od tekuće do naredne populacije konstituiše jednu generaciju prilikom rada genetskog algoritma. Uobičajena forma genetskog algoritma može biti šematski predstavljena kao na slici 6.28.



Slika 6.28. Uobičajena forma genetskog algoritma

6.4.5. Analiza karakteristika genetskih algoritama

Snaga genetskog algoritama leži u činjenici da je ta tehnika robustna i da se može veoma uspešno nositi sa širokim spektrom različitih problema. Genetski algoritmi nisu garancija za pronalaženje globalnog optimalnog rešenja problema, međutim, generalno su dobri u pronalaženju „prihvatljivo dobrih“ rešenja problema i to „prihvatljivo brzo“. Kada postoje specijalizovane tehnike za rešavanje određenih problema, one pretenduju da odbace (nadmaše) genetske algoritme i u brzini i u

preciznosti pronalaženja konačnog rezultata. Čak i gde postojeće tehnike rade zadovoljavajuće, napredak se oseti tek onda kada se one hibridizuju (udruže) sa genetskim algoritmima. Osnovni mehanizam funkcionisanja genetskih algoritama je toliko robusan da, unutar prilično širokih granica, podešenost parametara nije kritična [181,188].

Nedostaci genetskih algoritama se ogledaju u činjenici da geni sa nekoliko članova komparativno visokih sposobnosti (ali ne optimalnih) mogu rapidno da stupe na scenu pretendujući na dominaciju nad populacijom, uzrokujući da ona konvergira ka lokalnom maksimumu. Kada je populacija jednom konvergirala, sposobnost genetskog algoritma da nastavi pretragu za boljim rešenjima je efektivno eliminisana: ukrštanje gotovo identičnih hromozoma proizvodi mali broj onih koji su novi. Jedino preostaje mutacija da istraži neku novu oblast, a to jednostavno funkcioniše kao spora, nasumična pretraga [186,187].

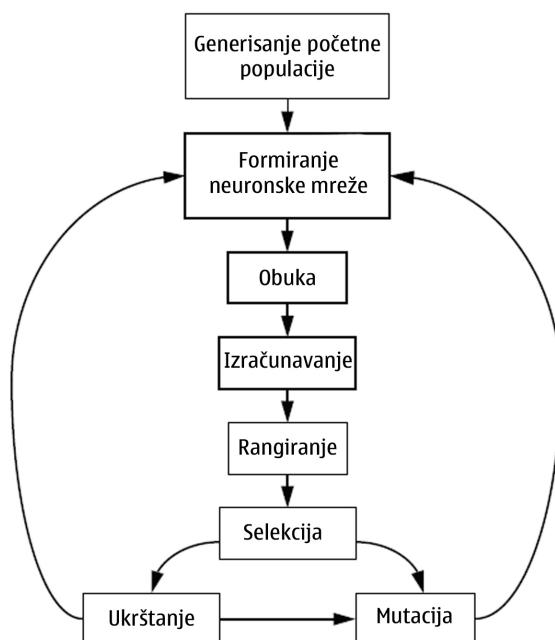
Bilo koji delotvoran optimizacioni algoritam mora da koristi dve tehnike za pronalaženje globalnog maksimuma: *istraživanje* za ispitivanje novih i nepoznatih oblasti u prostoru za istraživanje i *eksploataciju* da omogući korisnim znanje pronađeno u prethodno presečenim tačkama da bi doprinelo u nalaženju boljih tačaka. Te dve odrednice su kontradiktorne i dobar algoritam za pretragu mora pronaći neki kompromis između njih [186].

Prema [189], u poređenju sa tehnikom veštačkih neuronskih mreža i genetski algoritmi i veštačke neuronske mreže su adaptivne metode, imaju sposobnost učenja, mogu da izađu na kraj sa visoko nelinearnim modelima i komplikovanim podacima i spadaju u robusne, tzv. „slabe“ metode u pogledu nasumične pretrage. One ne zahtevaju informacije o gradijentu ili glatkoći funkcija. U oba slučaja njihova fleksibilnost je takođe još jedna prednost, iako moraju biti pažljivo strukturirane i kodirane po čemu su na neki način i specifične. U praktičnoj primeni najbolje rezultate postižu u međusobnoj kombinaciji: veštačke neuronske mreže mogu biti iskorišćene kao primarni alat za modeliranje sa genetskim algoritmima koji se mogu koristiti za optimizaciju parametara mreže.

Prema analizi metoda kombinovanja veštačkih neuronskih mreža i genetskih algoritama datoј u [190,191], ove dve tehnike veštačke inteligencije se mogu lako

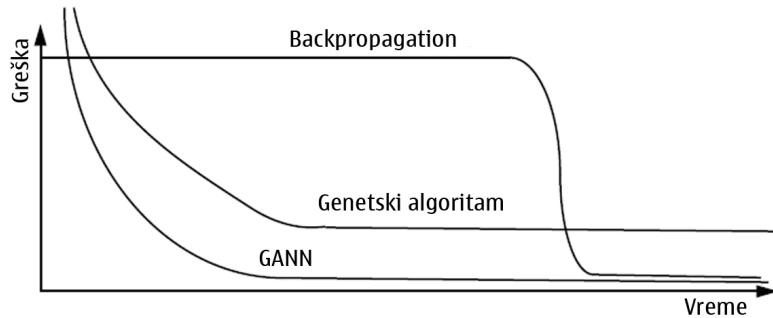
kombinovati ako se najpre izvrši tzv. kodiranje mreže. Kodiranje mreže se odnosi pre svega na formiranje zajedničkog GANN sistema [191]. Prvi pokušaji da se kombinuju metoda GA i metoda ANN počeli su 1980. godine o čemu svedoči veliki broj radova objavljenih na tu temu sve do danas [189,190]. Takođe, varijetet različitih strategija kodiranja je implementiran sa fokusom na feedforward mreže sa backpropagation algoritmom [191]. U skladu sa [190], osnovna ideja kombinovanja genetskih algoritama i veštačkih neuronskih mreža u GANN sistem prikazana je na slici 6.25.

Informacija o veštačkoj neuronskoj mreži je kodirana u genomu genetskog algoritma. Na početku, generiše se broj proizvoljno izabranih pojedinaca. Moraju se proračunati parametri niza, što podrazumeva da veštačka neuronska mreža mora biti projektovana u skladu sa informacijom o genomu. Njene performanse mogu biti određene putem obučavanja backpropagation algoritmom. Zatim se novi kandidati optimalnih rešenja izračunavaju i rangiraju, a onda se primenjuju genetski operatori (selekcija, ukrštanje i mutacija). Ukrštanje i mutacija formiraju nove pojedince koji zamenjuju najgore ili sve članove populacije [191].



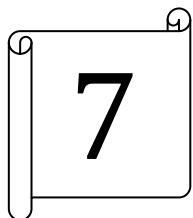
Slika 6.29. Struktura GANN sistema

Mada GA i ANN imaju zajedničku osobinu da su generalno strategije za istraživanje, empirijske studije pokazuju da one variraju u svom opsegu. Genetski algoritmi ostvaruju globalniju pretragu u odnosu na veštačke neuronske mreže sa backpropagation algoritmom [191]. Slika 6.30 ilustruje konvergenciju ove dve metode. Backpropagation algoritmu treba više vremena da locira okruženje optimalnog rešenja, ali sa druge strane obrađuje problem mnogo preciznije.



Slika 6.30. Brzina pretraživanja

Nasuprot tome, genetski algoritmi proučavaju (istražuju) tekući prostor za istraživanje. Dakle, oni pronalaze brže region sa optimalnim rešenjem, ali imaju poteškoća oko lokalizacije prave tačke. To se dešava zbog тога што коначно „фино подешавање“ решења зависи потпуно од мутације [189,190]. Управо је брзина проналаžења оптималног решења пресудна за генетске алгоритме у њиховој примени код динамичких система, на пример за одређивање оптималне вредности притиска активирања коčnice како би се остварило жељено klizanje u kontaktu pneumatika i tla.



INTELIGENTNO UPRAVLJANJE PERFORMANSAMA KOČNOG SISTEMA PRIVREDNOG VOZILA

7.1. UVOD

Kao što je već rečeno u prethodnom izlaganju, predmet ove doktorske disertacije su teorijska i eksperimentalna istraživanja u cilju modeliranja složenih dinamičkih uticaja radnih režima kočnica motornih vozila i predviđanja ovih uticaja na performanse kočnica u toku ciklusa kočenja, a time i na performanse kočnog sistema. U ovom delu doktorske disertacije je data analiza na koji način je moguće inteligentno upravljati performansama kočnog sistema pomoću metoda čiji se rad bazira na paralelnom procesiranju eksperimentalno dobijenih podataka tokom procesa kočenja. To se konkretno odnosi na istraživanja mogućnosti primene tri tehnike iz oblasti veštačke inteligencije - dinamičkih veštačkih neuronskih mreža, fazi logike i genetskih algoritama u razvoju dinamičkog modela performansi kočnica, odnosno u razvoju inteligentno upravljanog kočnog sistema motornog vozila.

U skladu sa tim, fokus istraživanja je bio usmeren na razvoj metode intelligentnog upravljanja performansama kočnog sistema privrednog vozila opremljenog elektronski upravljanim kočnim sistemom (EBS-om), kako bi se u kontaktu pneumatika i tla ostvarila željena/optimalna dinamička promena klizanja u podužnom pravcu. Posebna pažnja je posvećena tome na koji način je moguće obezbediti intelligentne osobine takve metode upravljanja performansama kočnog sistema. U tom smeru su vršena istraživanja da li je to moguće ostvariti pre svega razvojem dinamičkog neuronskog modela performansi kočnice koji objedinjuje i interakciju pneumatika i tla, a na osnovu koga bi bilo moguće projektovati

neuronski kontroler, koji bi bio u stanju da vrši dinamičko podešavanje pritiska aktiviranja kočnice u toku ciklusa kočenja na vrednost koja obezbeđuje željeni nivo klizanja u kontaktu pneumatika i puta. Sve to je potrebno obezbediti u odnosu na zahteve vozača, različito stanje opterećenosti vozila, trenutne radne režime kočnice i trenutno stanje u kontaktu pneumatik/tlo (stvarno klizanje točka). Istraživano je takođe da li je primenom fazi logičkog pristupa moguće dodatno iskorisnijati vrednost pritiska aktiviranja kočnice koji predlaže neuronski model, ukoliko postoji jasno odstupanje pritiska aktiviranja kočnice od vrednosti koja može da dovede klizanje točka na željeni nivo. Razlog za uvođenje fazi logičkog pristupa u sinergiji sa dinamičkim neuronskim mrežama leži u činjenici da je izuzetno važno obezbediti dovoljno visok nivo kvaliteta predviđanja u jednom dinamičkom i izrazito nelinearnom procesu, kao što je to proces kočenja koji se zasniva na trenju između elemenata tzv. friкционог para.

Imajući sve ovo u vidu, kao i kompleksnost promene stvarnog klizanja točka tokom rada EBS-a (ABS-a) u toku ciklusa kočenja (što je pokazano u poglavlju 4), može se doći do zaključka da je istraživanje u pravcu razvoja intelligentno upravljanog kočnog sistema od izuzetnog značaja, a posebno u funkciji unapređenja postojećih rešenja kao što je EBS, odnosno sistema za sprečavanje blokiranjia kočenih točkova (ABS) i za upravljanje klizanjem točkova na prednjoj/zadnjoj osovini (DSC), čiji rad prvenstveno zavisi od nivoa klizanja u kontaktu pneumatika i tla. Zbog toga su u ovom radu na osnovu modela četvrtine vozila razvijeni posebni dinamički modeli koji funkcionalno aproksimiraju proces kočenja, odnosno rad kočnice zajedno sa interakcijom pneumatik-tlo na prednjoj i zadnjoj osovini vozila u opterećenom i neopterećenom stanju. Razvoj pomenutih modela realizovan je pomoću podataka prikupljenih tokom eksperimentalnog dela istraživanja. Sprovodenje eksperimentalnog dela istraživanja, odnosno postupak merenja potrebnih veličina (kasnije korišćenih u procesu modeliranja) i naknadne obrade tako izmerenih signala u cilju dinamičkog eliminisanja šuma, objašnjeni su u poglavlju 7.2.

7.2. EKSPERIMENTALNA ISTRAŽIVANJA

U cilju analize i identifikovanja mogućnosti za dalje unapređenje rada EBS-a, a time i integrisanog ABS-a u smislu boljeg upravljanja klizanjem u kontaktu pneumatika i puta, sprovedena su eksperimentalna istraživanja načina funkcionisanja EBS-a kod privrednih vozila. U tu svrhu izabran je autobus proizvođača VDL Berkhof, tip Axial 70 (slika 7.1), koncepcije pogona 4x2 sa integrisanim EBS sistemom tipa 4S/4M, proizvođača Wabco. Detaljan opis karakteristika vozila je dat u Tabeli 7.1. Ugrađeni EBS sistem sadrži integrisane ABS/ASR funkcije, kao i funkciju pomoći vozaču koja omogućava vozaču rano upozorenje o potencijalno kritičnoj situaciji tokom vožnje. Elektronska kontrola stabilnosti vozila (ESC) nije instalirana na ispitivanom vozilu. Odnos preraspodele sila kočenja između prednje i zadnje osovine vozila pri intenzitetu usporenenja vozila u podužnom pravcu od $0,15g$ iznosi 1, što podrazumeva da je elektronska raspodela sila kočenja u tom slučaju deaktivirana. Razlog za to leži u činjenici da izračunavanje usporenenja vozila pri veoma malim brzinama kretanja uključuje veliki broj grešaka jer davači broja obrtaja točkova pri malim vrednostima ugaonih brzina ne očitavaju signale sa zadovoljavajućom tačnošću [192]. Parametar AV/AV1 (tabela 1) se takođe koristi za koordinisanje raspodele sile kočenja na prednju/zadnju osovinu. Pored toga, EBS ugrađen na datom vozilu uključuje redundantnu funkciju na zadnjoj osovini. U skladu sa [118], pneumatički kočni krugovi za prednju i za zadnju osovinu rade sa drugačijim podešavanjima redundantnosti. Pneumatički kočni krug za prednju osovinu radi u skladu sa principom dopunske redundantnosti, koji se ugrađuje kao standardna funkcija. Pneumatički kočni krug za zadnju osovinu je opremljen redundantnom jedinicom koja može biti aktivirana/deaktivirana pomoću posebnog ventila. Ukoliko dođe do otkaza u elektronskom delu kočnog sistema, odgovarajuća osovina se koči pomoću pritiska vazduha obezbeđenog od strane pneumatičkog dela instalacije koji ima redundantnu funkciju.



Slika 7.1. Ispitivano vozilo – VDL Berkhof, Axial 70

Osnovni preduslov za uvođenje inteligentnog upravljanja performansama kočnog sistema jeste modeliranje dinamički promenljive funkcionalne korelacije između pritiska aktiviranja kočnice i klizanja točka, ugaone brzine točka i temperature u kontaktu friкционog para kočnice u toku ciklusa kočenja. Imajući u vidu da klizanje točka ne može biti direktno izmereno [117,131], njegova vrednost je izračunata na osnovu vrednosti merene brzine vozila i izračunate brzine točka u podužnoj ravni. Brzina točka u podužnoj ravni je izračunata na osnovu vrednosti dinamičkog poluprečnika točka i izračunate vrednosti njegove ugaone brzine, dobijene na osnovu izmerenog broja obrtaja točka. U skladu sa tim, veličine koje su merene pomoću sistema za akviziciju podataka i odgovarajućih davača su brzina vozila, pritisci aktiviranja kočnica na prednjoj i zadnjoj osovini, temperature kočnica na prednjoj i zadnjoj osovini (temperature u kontaktu frikcionih parova), broj obrtaja točkova na prednjoj/zadnjoj osovini, sila na komandi sistema za radno kočenje i usporenje vozila u podužnom i poprečnom pravcu.

Tabela 7.1. Podaci o opterećenju vozila, kočnicama, kočnom sistemu i pneumaticima

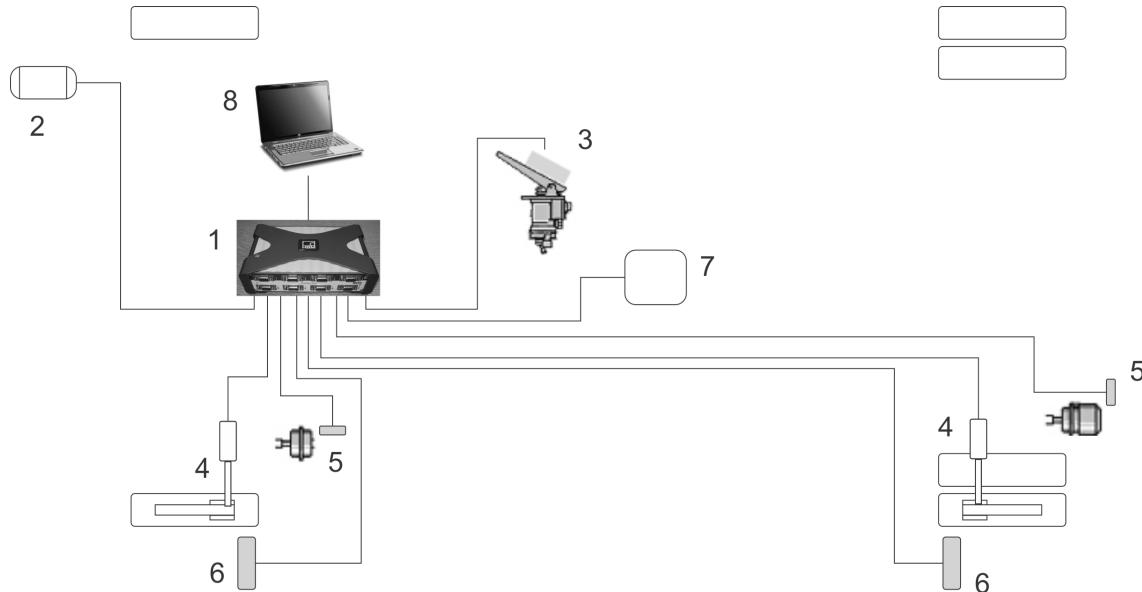
Podaci o vozilu			
Tip vozila	Autobus (4 x 2)		
	Prednja osovina	Zadnja osovina	Ukupno
Neopterećeno stanje	4300	7460	11760
Opterećeno stanje	6560	10620	17180
Dužina/Osno rastojanje	12.1 m/5.92 m		
	Visina		neopterećeno - 0,9 m opterećeno - 1,1 m
Položaj težišta vozila	Rastojanje od prednje osovine		neopterećeno - 3,46 m opterećeno - 3,92 m
	Rastojanje od zadnje osovine		neopterećeno - 2,46 m opterećeno - 2 m
Karakteristike ugrađenog EBS-a			
Tip EBS sistema	EBS Bus Standard (4S/4M)		
ABS/ASR funkcije	Integrисane u okviru EBS-a		
ESC funkcija	Nije podržana		
Integrисана funkcija pomoći vozaču	Da		
Odnos raspodele sila kočenja pri usporenu 0.15 g	1		
Parametar raspodele sila kočenja AV/AV1	1		
Obim pneumatika (prednja/zadnja osovina)	3200/3200 mm, respektivno		
Ugrađena funkcija redundantnosti za zadnju osovinu	Da		
Karakteristike pneumatika			
Prednji/zadnji pneumatici	Pneumatik za upravljačku/pogonsku osovinu (letnji dezen) Proizvođač: prednji – Yokohama, zadnji - Goodyear Dimenzije 295/80R 22.5 Dinamički poluprečnik: prednji 495 mm, zadnji 487 mm		
Karakteristike kočnica			
Prednja/zadnja kočnica	Pneumatički aktivirana disk kočnica proizvođača Knorr-Bremse sa samoventilirajućim diskom (unutrašnji/spoljašnji prečnik diska 170/460 mm) Proizvođač: Allied Nippon		
Prednje/zadnje disk pločice	Dužina/širina 247/109.3 mm WVA broj 29108		

Za potrebe izrade ove doktorske disertacije, sva merenja su obavljena tokom ispitivanja vozila u stvarnim eksplotacionim, odnosno tzv. putnim uslovima. To podrazumeva da su eksperimentalna istraživanja sprovedena u realnim uslovima

vožnje u kojima vozilo izvršava svoju funkciju. Tako dobijeni podaci oslikavaju stvarno ponašanje vozila prilikom kočenja u odnosu na podatke dobijene pri ispitivanju u laboratorijskim uslovima [134]. Sprovodenje eksperimentalnih istraživanja uključuje nekoliko preduslova, kao što su izbor vozila koje će biti ispitivano i izbor odgovarajuće opreme za ispitivanje. Izbor odgovarajuće deonice puta za obavljanje eksperimenta, kao i obezbeđivanje uslova za testiranje vozila u opterećenom i neopterećenom stanju su samo neki od dodatnih zahteva koje je trebalo realizovati.

S obzirom na prethodno nabrojane veličine koje su merene, oprema pomoću koje su realizovana eksperimentalna istraživanja, odnosno izvršena merenja, uključuje sledeće komponente (slika 7.2):

1. merni most QuantumX,
2. davač brzine vozila (1 kanal),
3. davač sile na komandi sistema za radno kočenje (1 kanal), i
4. davače temperature u kontaktu frikcionih parova kočnica na prednjoj/zadnjoj osovini (2 kanala),
5. davače pritiska aktiviranja kočnica na prednjoj/zadnjoj osovini vozila (2 kanala),
6. davače broja obrtaja točkova na prednjoj/zadnjoj osovini (2 kanala),
7. davač ubrzanja/usporenja u podužnoj i poprečnoj ravni (2 kanala), i
8. laptop računar opremljen softverskim paketom za akviziciju podataka (QuantumX Assistant).



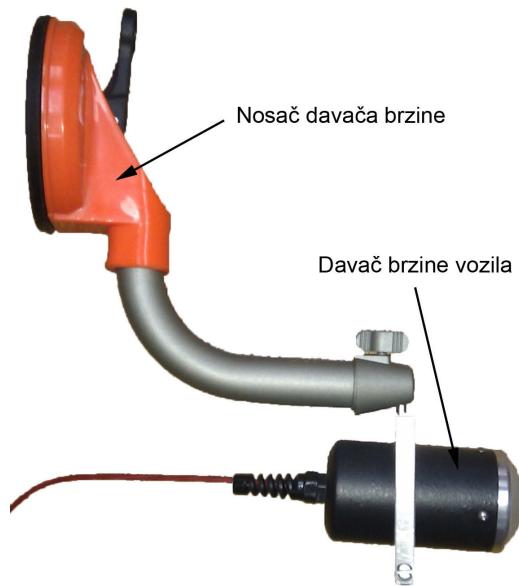
Slika 7.2. Shema postavljanja davača i njihovo povezivanje u merni most

Višekanalni univerzalni merni most sa pojačavačem QuantumX MX840, proizvođača HBM, je korišćen za istovremenu akviziciju podataka dobijenih od davača (slika 7.3). Podržava širok spektar davača (induktivne, otporne, kapacitivne, piezorezistivne, termoparove, potenciometre, itd.) vezanih u pun ili polumost. Najvažnije osobine ovog mernog mosta su brz prenos podataka do računara i tzv. TEDS funkcija (engl. Transducer Electronic Data Sheet). Ova funkcija podrazumeva čuvanje podataka o tipu davača, položaju/nazivu, mernim jedinicama i opsegu merenja i njegovo automatsko prepoznavanje od strane mernog mosta prilikom priključenja davača.



Slika 7.3. Višekanalni merni most QuantumX

Svi davači su postavljeni u skladu sa preporukama proizvođača na mesta koja obezbeđuju zahtevanu tačnost merenja. Merenje svih veličina je ponovljivo, pri čemu određene specifičnosti merenja pojedinih veličina ne utiču značajno na rezultate merenja. Davač brzine kretanja vozila je radarskog tipa i koristi princip Doplerovog efekta (slika 7.4). Opseg merenja ovog davača je od 0,8 – 480 km/h, pri ambijentalnim temperaturama između -17...60 °C. Davač generiše izlaz u obliku talasa kvadratnog profila između 0 – 5 V pri radnoj frekvenciji od $35,5 \pm 0,1$ GHz, odnosno 100 impulsa za 1 mph, tj. 62,1 impulsa za 1 km/h. Greška merenja ovog davača iznosi $\pm 0,54\%$ za 1 km/h i povećava se za $0,0037\%$ za svaki km/h. Davač brzine vozila je postavljen na prednjem delu vozila i to pod uglom od 30° u odnosu na podlogu. Prema specifikaciji proizvođača (GMN Engineering), uglovi između 25 - 36° su najpogodniji sa stanovišta tačnosti dobijenih rezultata merenja. Davač je pričvršćen na vozilo uz pomoć specijalnog vakuumskog držača (takođe prikazanog na slici 7.4).



Slika 7.4. Davač brzine vozila sa nosačem

Davač sile na pedali je postavljen direktno na komandu sistema za radno kočenje tako da vozač nogom deluje direktno na davač, a on dalje prenosi tu силу aktiviranja na pedalu kočnice. Davač je sa linearnom karakteristikom i meri силу на команди система за радно коčenje (pedali) у нјутнима (N), slika 7.5. Opseg меренja овог давача је 0 – 1500 N, а просечна вредност грешке меренja износи 3%.

Izlazna karakteristika davača je 1 mV/N. Mesto postavljanja ovog davača na komandi je od velike važnosti za tačnost dobijenih podataka. Imajući u vidu da se komanda sistema za radno kočenje kod autobusa izvodi kao tzv. „stojeća“ pedala, kao što je prikazano na slici 7.5, davač sile je postavljen na gornjoj polovini komande, kako bi se sila kojom vozač deluje na komandu prenela u punom iznosu preko davača na komandu. Osim toga, prema preporukama proizvođača važno je i da nogu vozača naleže na čitavu površinu davača kako bi tačnost merenja bila što veća.



Slika 7.5. Davač sile na komandi sistema za radno kočenje

Davači temperature u kontaktu frikcionih parova, koji funkcionišu na principu termoparova (slika 7.6), su postavljeni na kočnicu desnog točka na prednjoj i kočnicu desnog točka na zadnjoj osovini. U pitanju su davači tipa K (termopar nikl hrom – nikl, NiCr – Ni) sa sondom prečnika 3 mm i opsega merenja od -40 do 1200 °C prema DIN EN 60584. Prema specifikaciji proizvođača, u pogledu greške merenja ovi davači spadaju u klasu 2, pri čemu se greška merenja kreće u granicama $\pm 2,5$ °C (-40...333 °C) i $\pm 0,75$ °C (333...1200 °C).



Slika 7.6. Davač temperature u kontaktu frikcionog para

Davači temperature su postavljeni u prethodno izbušene rupe (slika 7.7) u kočnim oblogama disk pločica, na dubini od 1 mm od frikcione površine kočne obloge (slika 7.8). Osim toga, dodatno su osigurane od aksijalnog pomeranja i ispadanja iz ležišta. Odgovarajući provodnici signala od davača su pažljivo osigurani od kontakta sa tlom ili pokretnim delovima sistema za oslanjanje i upravljanje. Pretpostavka je da su temperature u kontaktu frikcionih površina kočnica na istoj osovini jednake.



Slika 7.7. Mesto bušenja rupe za sondu davača temperature



Slika 7.8. Mesto postavljanja davača temperature

Da bi se izmerila vrednost pritiska vazduha u kočnim cilindrima, tj. pritiska sa kojim su aktivirane kočnice na prednjoj/zadnjoj osovini, potrebno je postaviti davače pritiska aktiviranja na kontrolne priključke za merenje pritiska vazduha na odgovarajućim kočnim cilindrima na prednjoj i zadnjoj osovini. Pri tome je uvedena pretpostavka da su pritisci aktiviranja na levom i desnom točku iste osovine jednaki. Za merenje pritiska aktiviranja kočnice korišćeni su davači pritiska proizvođača HBM, tip P8AP sa opsegom merenja od 0 do 10 bar, slika 7.9. Klasa tačnosti ovih davača je 0,3, a osetljivost $2\pm2\%$ mV/V (uticaj temperature na osetljivost je $\pm0,3\%$). Opseg radne temperature davača je -40...80 °C. Veza davača sa kontrolnim priključcima na vozilu je ostvarena posredstvom specijalno napravljenih adaptera.



Slika 7.9. Davač pritiska aktiviranja kočnice

Davači broja obrtaja točkova su optički, proizvođača Omron, tip E3F2 (slika 7.10). Domet snopa se kreće između 0,1-4 m, a ugao postavljanja u odnosu na osu upravnu na ravan reflektujuće površine se toleriše u granicama od 3-20°. Opseg ambijentalne temperature u kojoj rade se kreće između -25...55 °C. Svetlosni izvor emituje infracrvene zrake od 950 nm. Postavljeni su u visećem položaju sa bočne strane vozila, odnosno upravno na bočnu površinu pneumatika na prednjoj/zadnjoj osovini i na propisanom rastojanju od nje (slika 7.11). Za vozilo su pričvršćeni pomoću stezača, koji su dodatno osigurani od pada i eventualnog oštećenja. Na bočnoj strani pneumatika je obeleženo nekoliko repernih linija u beloj boji sa dobrim reflektujućim karakteristikama.



Slika 7.10. Davač broja obrtaja točka



Slika 7.11. Postavljanje davača broja obrtaja točka

Davač usporenja je kapacitivnog tipa (proizvođač ASC GmbH, tip ASC 5631), sa mogućnošću merenja u tri pravca (tri ose), a za potrebe eksperimenta merene su komponente vektora usporenja u podužnoj i u poprečnoj ravni vozila. Napon izlaznog signala se kreće u granicama 0,5-4,5 V. Otporan je na udare intenziteta do 2g, a radna temperatura davača je u opsegu -40...85 °C. Osetljivost davača je 1000 mV/g, a radna frekvencija 50 Hz ±5%. Radi preciznosti merenja, veoma je važno postaviti davač usporenja tako da se podužna i poprečna osa (označene na kućištu davača) poklapaju sa podužnom i poprečnom ravni vozila. Davač usporenja je postavljen na ravnu horizontalnu površinu pomoću specijalne metalne ploče za koju je kruto vezan (slika 7.11). Ploča je osigurana od pomeranja i kruto pričvršćena za pod vozila. Da bi se preciznost merenja dodatno osigurala, davač je prema preporukama proizvođača postavljen na mestu na kome se nalazi položaj težišta vozila. Ukoliko se ovaj davač ne postavi u težištu vozila, naginjanje vozila usled preraspodele mase sa zadnje na prednju osovinu može da utiče na preciznost merenja komponenata usporenja u podužnom i poprečnom pravcu. Visina na kojoj je postavljen davač u vozilu treba takođe da odgovara visini težišta vozila imajući u vidu da izračunavanje dinamičkih reakcija točkova na prednjoj i zadnjoj osovini zavisi od vrednosti usporenja u podužnom pravcu [104,117].



Slika 7.11. Troosni davač usporenja

Podaci prikupljeni od strane svakog davača su mereni sa rezolucijom od 200 Hz. Opsezi promene svih veličina merenih tokom eksperimentalnog istraživanja je dat u Tabeli 7.2. Eksperiment je projektovan sa ciljem da se prikupi dovoljan broj podataka potrebnih da se uspostavi funkcionalna zavisnost između pritiska aktiviranja kočnice, brzine točka, temperature u kontaktu friкционog para kočnice i klizanja točkova. U skladu sa tim, obavljeno je ukupno 199 kočenja sa različitim pritiscima aktiviranja, različitim početnim brzinama kočenja i sve to pri različitim vrednostima temperature u kontaktu friкционog para. Ukupno vreme kočenja na kome se baziraju eksperimentalni rezultati iznosi 1414 s. Od ukupnog broja kočenja, 128 ciklusa je obavljeno ispitivanjem vozila u neopterećenom stanju, dok je preostali broj ciklusa kočenja obavljen pri opterećenom stanju vozila. Imajući to u vidu, prikupljeno je 282713 podataka koji su dalje iskorišćeni za razvoj dinamičkog neuronskog modela, odnosno obučavanje i testiranje dinamičkih neuronskih mreža.

Tabela 7.2. Opsezi promene merenih veličina

	Prednja osovina	Zadnja osovina
Pritisak (bar)	0 - 9,1	0 - 8,2
Brzina vozila (km/h)		0 - 105
Temperatura kočnice (°C)	40 - 450	43 - 495
Usporenje vozila (m/s ²)		0 - 8,4
Broj obrtaja točka (min ⁻¹)	0 - 564	0 - 560
Sila na komandi kočnog sistema (N)		0 - 275

7.3. OBRADA IZMERENIH PODATAKA

Po završetku eksperimentalnog dela istraživanja, izvršena je analiza metoda koje se koriste za obradu izmerenih podataka u cilju dinamičkog uklanjanja šuma u signalu. Proces kočenja vozila je izrazito dinamičke prirode pa je stoga prisutan i šum kao prateća pojava merenja sprovedenih tokom eksperimenta. Uklanjanje (eliminacija) šuma, odnosno rekonstrukcija „realnog“ signala na bazi podataka koji u sebi sadrže neodređenost u vidu šuma, predstavlja jedan od ključnih problema u mnogim oblastima nauke i tehnike [193]. Pri tome signali mogu biti jednodimenzionalni (kada predstavljaju funkcije vremena) ili dvodimenzionalni (kada se radi o slici) [193]. Pod šumom se podrazumevaju i potpisi u signalu visoko dinamičkih i stohastičkih pojava kao što su na primer dinamika trenja, elastične deformacije, udari, vibracije i slično [194]. Tokom realizacije eksperimentalnih istraživanja je upravo ovome posvećena velika pažnja u cilju uklanjanja negativnih uticaja na kvalitet izmerenog signala u pogledu nivoa šuma. To je posebno važno kod postavljanja merne opreme, a posebno davača broja obrtaja točka i davača brzine vozila koji se nalaze na odgovarajućim nosačima. Nosači u vidu konzole imaju znatan uticaj na generisanje šuma tokom merenja sa pomenutim davačima zbog toga što tokom kretanja vozila dolazi do pojave njihovih vibracija.

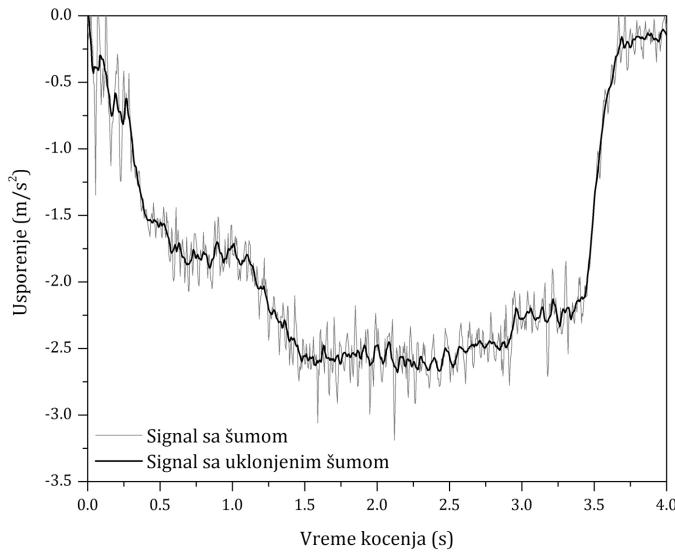
Prema [193,195,196], postojeće metodologije uklanjanja šuma su veoma raznolike. One obuhvataju inženjerske pristupe zasnovane na klasičnim metodama projektovanja digitalnih filtara, optimalne filtre proizišle iz Wiener-ove i Kalman-ove teorije, metode zasnovane na razvoju u ortogonalne funkcije kao što su Fourierova transformacija i transformacija pomoću tzv. talasa (vejvleta). Prilikom eliminacije šuma neophodno je da izmereni signal pretrpi što manje fazno izobličenje i da zadrži sve svoje detalje uključujući i one na visokim frekvencijama [194]. Prema [197,198], Fourierova transformacija, odnosno njena savremena računarska realizacija FFT, je korisna u slučaju signala koji u svom trajanju imaju konstantnu frekvenciju. Međutim, u slučaju signala koji imaju izvesne anomalije i singularitete vejvleti su rešenje koje se nameće kao najpogodnije za uklanjanje

šuma iz realnog signala. Vejvleti su sposobni da pronađu ove singularitete i da pruže istovremeno informaciju o njihovoj lokaciji, frekvenciji i obliku [197].

U poslednje vreme su postignuti veoma dobri rezultati u eliminaciji šuma primenom diskretnе transformacije pomoću talasa, odnosno vejvleta (DWT – *Discrete Wavelet Transform*) [193]. To podrazumeva da se na bazi pogodno izabranog praga može doći do reprezentacije signala koja ima željeni stepen glatkosti [193]. Vejvet je mali talas ograničenog trajanja srednje vrednosti nula, a pod ograničenim trajanjem se podrazumeva da je reč o oscilaciji koja ima svoj jasno određen početak i kraj [197]. Osnovna ideja je da se vejvet skalira i translira sve dok se ne poklopi sa singularitetom, kada će njegovi koeficijenti biti najveći [199]. Signal se kod vejvlet transformacije predstavlja kao sklop svih vejvleta nastalih skaliranjem i transliranjem jednog matičnog vejvleta [193,194,197]. Koeficijent vejvleta predstavlja merilo koliko je i kako neki vejvet poklopljen sa nekim događajem i direktno je zavistan od translacije i skaliranja. Prema [196,197,199], realna vejvet transformacija ima dva oblika: kontinualni i diskretni. Kontinualna vejvet transformacija podrazumeva da se svako skaliranje i transliranje vejvleta vrši za celobrojni korak. Diskretna vejvet transformacija (DWT) razlaže signal na frekvencijske komponente koje je potom moguće obrađivati i to u određenom trenutku. Proces se svodi na sukcesivno razlaganje na visokofrekvenčne komponente, tzv. „detalje“ i niskofrekvenčne komponente, odnosno „aproksimacije“. U načelu, DWT može imati više nivoa, gde se na svakom novom nivou vrši razlaganje aproksimacija sa prethodnog nivoa na detalje i aproksimacije višeg nivoa [195,199].

Prilikom izbora vejvleta za dinamičko uklanjanje šuma iz signala koji opisuju veličine koje su merene, u ovoj disertaciji su iz tog signala generisana obeležja pomoću talasa iz Daubechies familije. Kod svih merenih veličina osim stvarnog pritiska aktiviranja kočnice (brzina vozila, temperatura kočnice, sila na komandi sistema za radno kočenje, usporenje vozila), kao i izračunatih veličina (klizanje točka, brzina točka) korišćeni su vejvleti reda DB2. Izmereni stvarni pritisak aktiviranja nije dodatno filtriran zbog toga što EBS sistem već vrši filtriranje elektronskog signala kojim upravlja proporcionalnim rele ventilom i osovinskim

modulatorom. Posledica toga su glatke promene pritiska aktiviranja u toku ciklusa kočenja, a odgovarajući signali pritiska sadrže zanemarljivi nivo šuma. Prema [194], vevlet za uklanjanje šuma mora biti višeg reda od 1. Da bi se ilustrovala primena DWT tehnike za eliminaciju šuma iz signala u realnom vremenu (tokom simulacije u programskom paketu Simulink), na slikama 7.12-7.15 su uporedno prikazani realno izmereni signali i obrađeni signali sa uklonjenim šumom pomoću DWT. Iako je najveći deo šuma uklonjen i dalje postoji određena količina šuma. Za uklanjanje ovog preostalog šuma u realnom vremenu (tokom samog procesa obuke neuronskih modela) korišćen je IIR filter (engl. *Infinite Impulse Response*), integrisan u okviru samog neuronskog modela. Karakteristike ovog filtera su objašnjene u delu koji se odnosi na obuku dinamičkih neuronskih modela.

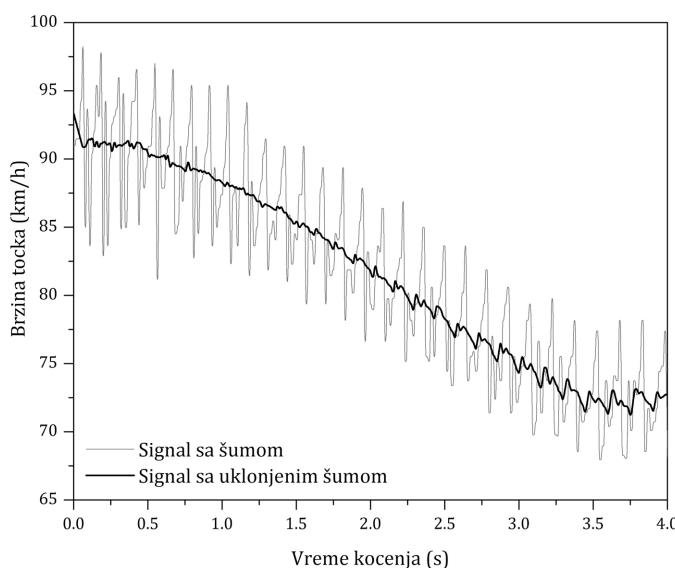


Slika 7.12. Uklanjanje šuma pomoću DWT – podužno usporenje vozila

Na slici 7.12 su prikazani signali pre i posle uklanjanja šuma, koji se odnose na usporenje vozila u podužnoj ravni. Imajući u vidu da je davač usporenja bio postavljen na podu vozila, evidentno je da na nivo realno izmerenog signala veliki uticaj imaju vibracije nosećeg sistema vozila izazvane stohastičkim promenama uslova u kontaktu pneumatik-tlo, promenama vrste i stanja površine puta (hrapavost, promena nagiba, neravnine i slično) i/ili promenom režima rada pogonskog agregata. Primena DB2 vevleta sa transformacijom na tri nivoa je

omogućila malo fazno izobličenje realnog signala kako bi se zadržali svi njegovi detalji, slika 7.12.

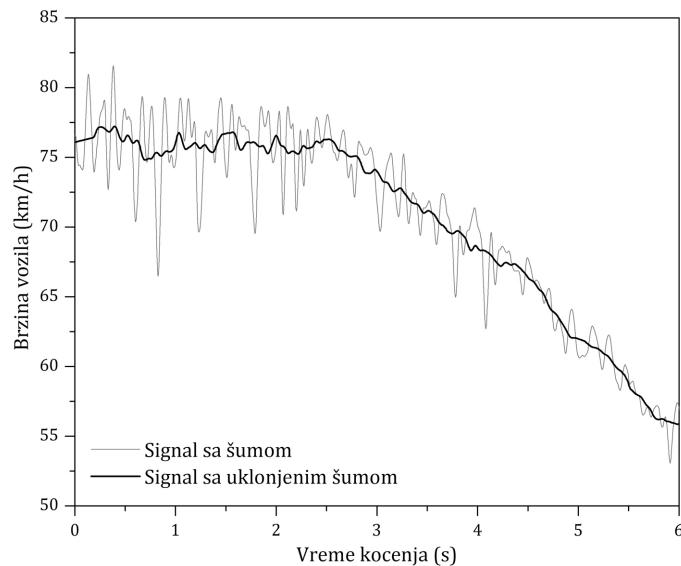
Modeliranje procesa kočenja zahteva da se posebna pažnja posveti preciznom izračunavanju klizanja točka u podužnoj ravni na osnovu izmerenih vrednosti brzine vozila i broja obrtaja točka (pomoću koga se izračunava brzina točka). To upravo zavisi od nivoa šuma u okviru pomenuta dva signala, što ukazuje na to da je njegovo uklanjanje neophodno kako bi se izbeglo modeliranje šuma zajedno sa realnim vrednostima signala. Na slici 7.13 je prikazana realna promena izračunate brzine točka na osnovu signala o broju obrtaja točka zajedno sa signalom posle uklanjanja šuma. Primenjeni su DB2 vevleti sa transformacijom na pet nivoa. U poređenju sa usporenjem vozila (slika 7.12) kompleksnost promene realnog signala brzine točka je malo veća (slika 7.13). Nivo šuma u ovom signalu potiče od vibracija nosača optičkog davača usled kretanja vozila, kao i od elastičnih deformacija pneumatika pri njegovom kotrljanju. Elastične deformacije pneumatika utiču na promenljivost ugla pod kojim se snop infracrvenih zraka koje emituje optički davač odbija od bočne površine pneumatika.



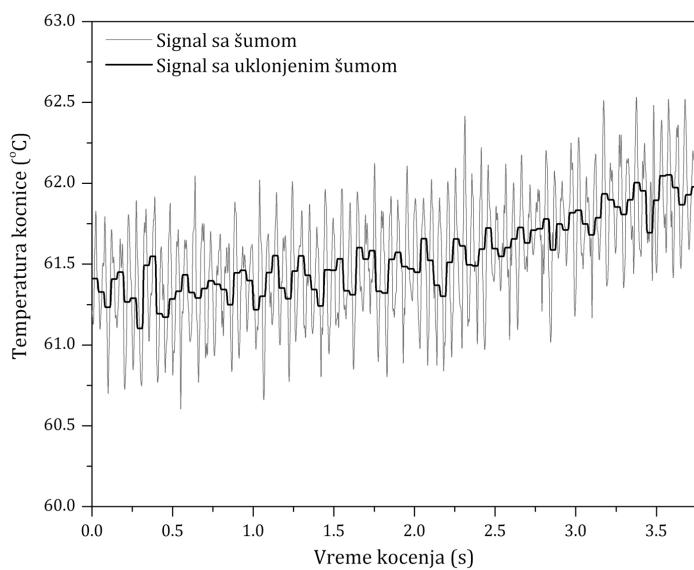
Slika 7.13. Uklanjanje šuma pomoću DWT – brzina točka

Veoma slična situacija je i sa brzinom vozila (slika 7.14) gde na nivo šuma mogu da utiču, pored oscilacija nosača davača i udara usled neravnina na kolovozu, stanje površine puta (hrapavost, neravnine, nagib) i naginjanje vozila u podužnoj

ravni usled preraspodele opterećenja sa zadnje na prednju osovINU. U ovom slučaju su korišćeni DB2 vejvleti sa transformacijom na tri nivoa. Na slici 7.15 su prikazani signali temperature u kontaktu frikcionih parova kočnice na prednjoj osovini pre i posle uklanjanja šuma pomoću DWT metode. Iskorišćeni su takođe DB2 vejvleti sa transformacijom na tri nivoa.



Slika 7.14. Uklanjanje šuma pomoću DWT – brzina vozila



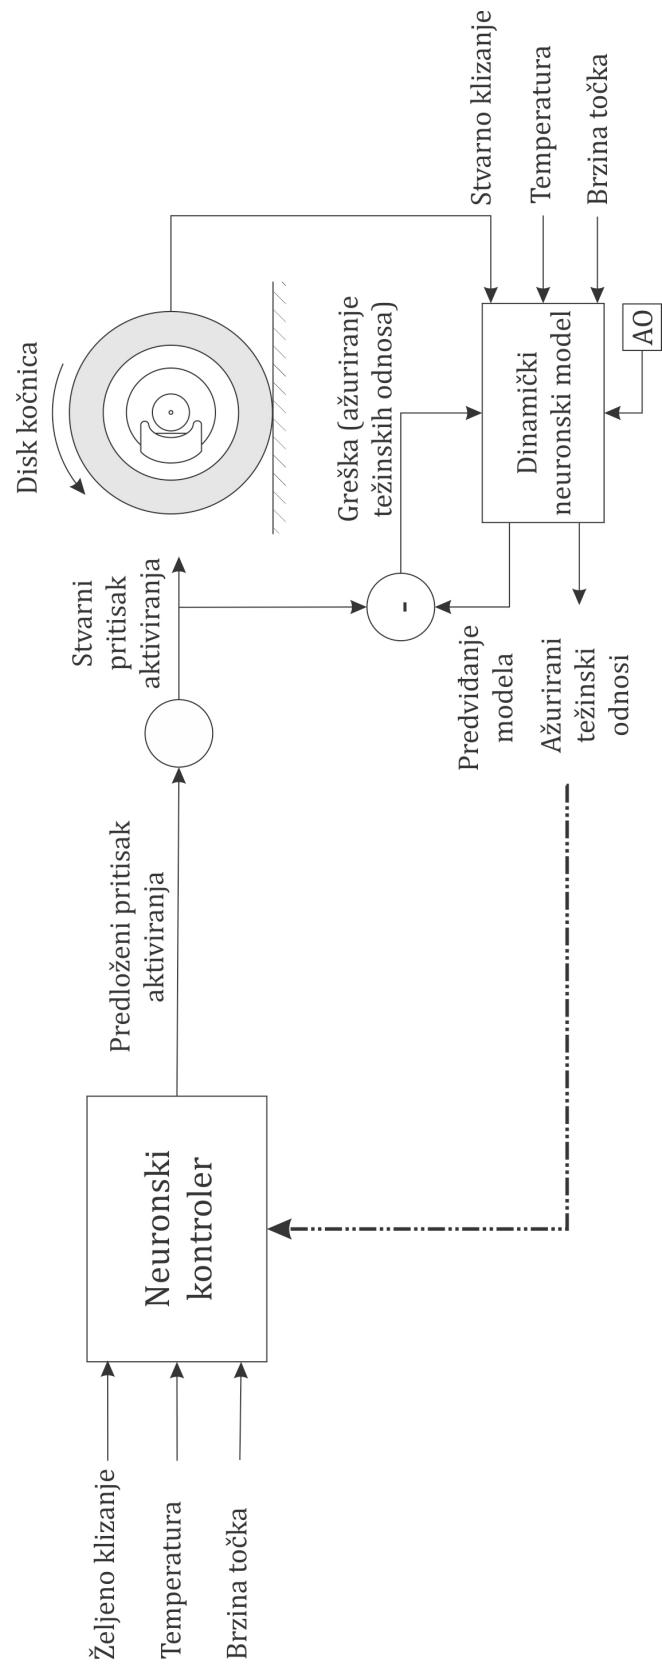
Slika 7.15. Uklanjanje šuma pomoću DWT – temperaturna kočnica

7.4. INTELIGENTNO UPRAVLJANJE PERFORMANSAMA KOČNICE POMOĆU METODE VEŠTAČKIH NEURONSKIH MREŽA

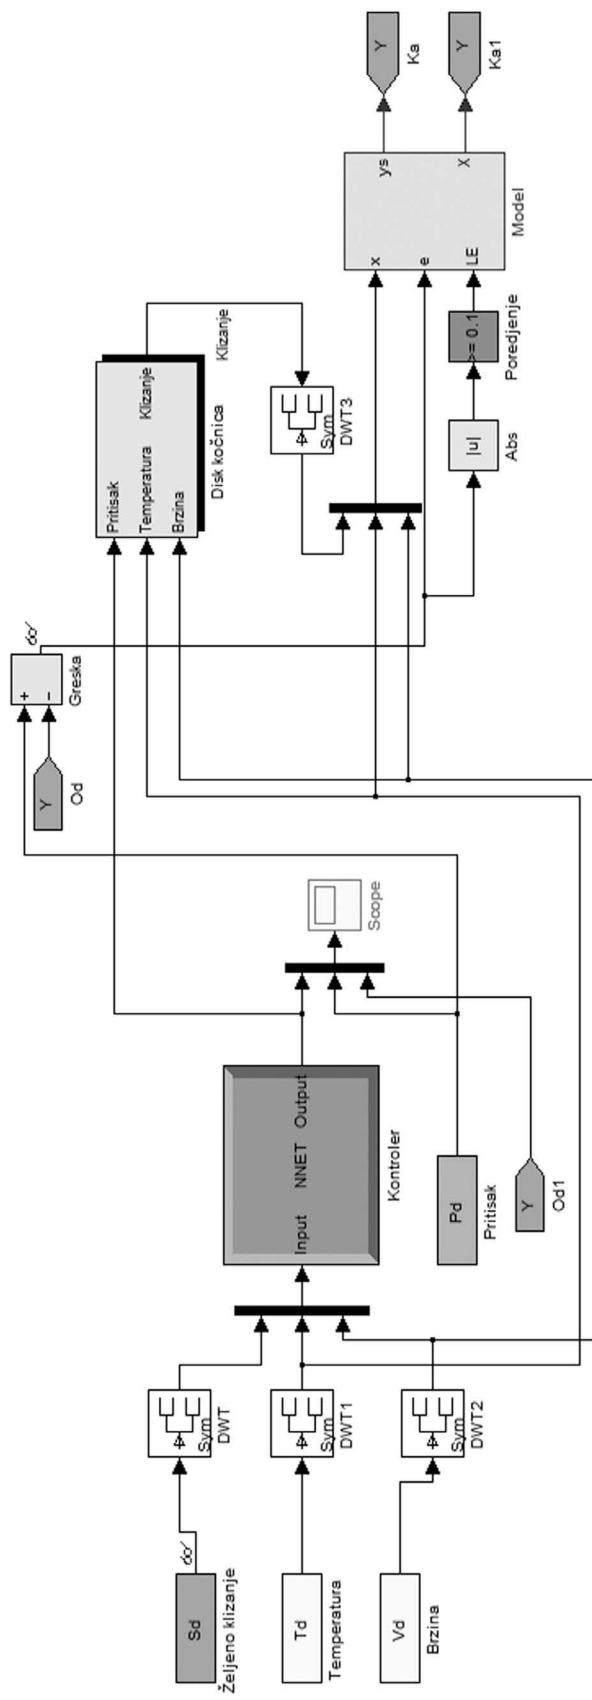
Opšti koncept sistema inteligentnog upravljanja klizanjem u kontaktu pneumatika i tla putem podešavanja pritiska aktiviranja kočnice primenom metode dinamičkih veštačkih neuronskih mreža, može se predstaviti pomoću blok dijagrama na slici 7.16. Imajući u vidu da postoji veliki broj metoda upravljanja zasnovanih na tehnici veštačkih neuronskih mreža, što je detaljno analizirano u [70], u ovom radu su za primenu izdvojene dve metode. Prva se odnosi na nadgledano upravljanje pomoću veštačkih neuronskih mreža, a druga na tzv. direktno inverzno upravljanje. Opšti koncepti pomenutih metoda su kombinovani u sistemu sa povratnom spregom prilikom razvoja sistema intelligentnog upravljanja klizanjem u kontaktu pneumatik-tlo u ovoj doktorskoj disertaciji. To podrazumeva da se konfiguracija za upravljanje klizanjem u kontaktu pneumatika i tla prikazana na slici 7.16 zasniva na nadgledanom upravljanju modifikovanom na taj način što je dodatno razvijen inverzni dinamički model procesa kočenja koji objedinjuje uticaje i performansi kočnice i interakcije pneumatik-tlo i dovodi ih u vezu sa pritiskom aktiviranja kočnice. Kao što je već napomenuto u poglavlju 4.7, dosadašnja istraživanja u ovoj oblasti nisu vršena u pravcu razvoja modela procesa kočenja koji bi obuhvatio navedene uticaje. U ovoj doktorskoj disertaciji je upravo to bio glavni cilj sprovedenih istraživanja. Da bi se on i realizovao, sistem intelligentnog upravljanja koja se zasniva na primeni dinamičkih neuronskih mreža bi trebalo da sadrži sledeće komponente (slika 7.16):

1. Inverzne dinamičke modele procesa kočenja za prednju i zadnju osovinu.
2. Dinamički neuronski kontroler procesa kočenja za prednju i zadnju osovinu.
3. Model točka (model četvrтine vozila) sa pneumatički aktiviranom disk kočnicom privrednih vozila.
4. Mehanizam za ažuriranje težinskih odnosa model-kontroler.

Shematski prikaz odgovarajuće konfiguracije sistema upravljanja klizanjem u programskom paketu Matlab/Simulink je dat na slici 7.17.



Slika 7.16. Konfiguracija sistema za inteligentno upravljanje poduznim klizanjem točka pomoću veštačkih neuronskih mreža



Slika 7.17. Konfiguracija sistema u radnom okruženju Simulink-a

Funkcija inverznog dinamičkog neuronskog modela je da funkcionalno aproksimira rad kočnice u inverznom smislu, tj. da predviđa dinamičku promenu pritiska aktiviranja kočnice za datu vrednost podužnog klizanja točka, kao rezultat trenutne vrednosti pritiska aktiviranja kočnice, temperature u kontaktu friкционog para, brzine točka i trenutnih uslova prijanjanja u kontaktu pneumatika i tla. Osim toga, obezbeđeno je da se inverzni dinamički neuronski model obučava tokom rada, u toku svakog ciklusa kočenja, tj. da obavlja dinamičko ažuriranje težinskih odnosa kao reprezenata posmatrane funkcionalne veze. Obuka modela u realnom vremenu se vrši na osnovu greške između pritiska koji model predviđa na izlazu i trenutne vrednosti pritiska aktiviranja kočnice. Za njeno izračunavanje tokom rada sistema je potrebno vreme od 0,001 s. Dinamički neuronski kontroler ima zadatak da na osnovu dinamički ažuriranih težinskih odnosa dobijenih od neuronskog modela, vrši predviđanje potrebnog pritiska aktiviranja kočnice u toku ciklusa kočenja kako bi se ostvarilo željeno podužno klizanje u kontaktu pneumatik-tlo, u zavisnosti od trenutne vrednosti brzine točka i temperature u kontaktu friкционog para kočnice. Istraživanje u ovoj disertaciji se odnosilo na softverske karakteristike kontrolera tj. obezbeđenje „znanja“ koja su potrebna kontroleru za dinamičko upravljanje pritiskom aktiviranja kočnice. Znanje o tome je upravo obezbeđeno od strane inverznog dinamičkog neuronskog modela koji opisuje funkcionalnu vezu između pritiska aktiviranja disk kočnice i podužnog klizanja točka.

Sa slike 7.16 se vidi da dinamički neuronski kontroler ima tri ulaza (trenutna željena/optimalna vrednost klizanja, trenutna temperatura u kontaktu friкционog para kočnice i trenutna brzina točka). Na osnovu datog vektora ulaza i ažurirane matrice težinskih odnosa koja se automatski prenosi sa inverznog dinamičkog neuronskog modela sa zakašnjnjem od 0,005 s, dinamički neuronski kontroler predviđa trenutnu vrednost pritiska sa kojim bi trebalo aktivirati kočnicu kako bi se stvarna vrednost klizanja u kontaktu pneumatik-tlo dovela na željeni nivo za date uslove prijanjanja i režim rada kočnice. Aktiviranje kočnice sa tim pritiskom dovodi do generisanja sile kočenja, odnosno momenta kočenja koji, uz odgovarajuće gubitke, u spoju pneumatika i tla izaziva klizanje, obeleženo na slici 7.16 kao stvarno klizanje. Ta vrednost stvarnog klizanja je sada, zajedno sa

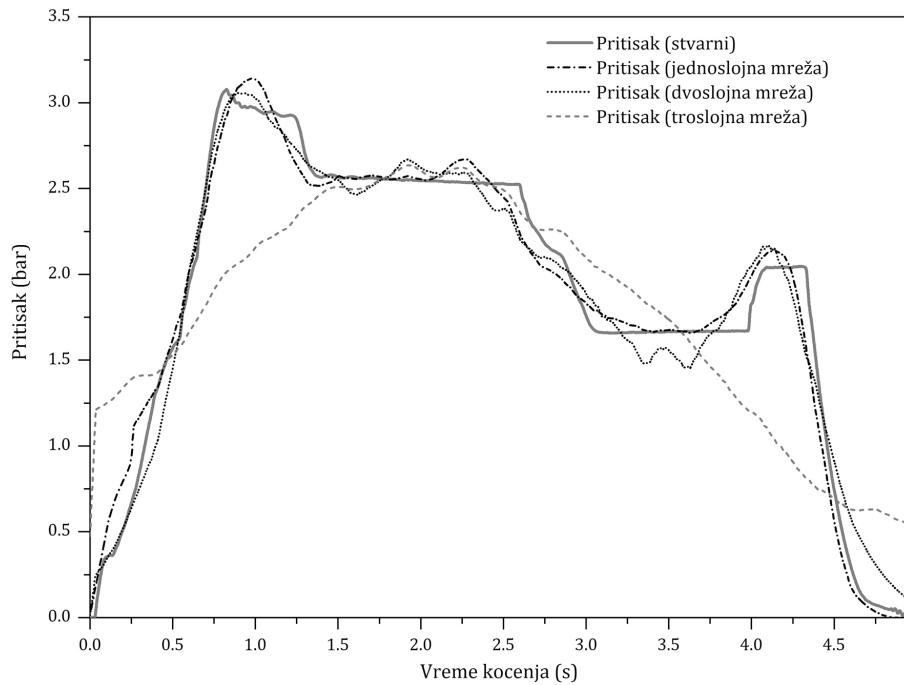
temperaturom kočnice i brzinom točka, na ulazu u inverzni dinamički neuronski model, koji na osnovu tog vektora ulaza sa zakašnjenjem od 0,01 s predviđa vrednost pritiska kojim bi trebalo aktivirati kočnicu. Pritisak koji predviđa inverzni dinamički model se neprekidno upoređuje sa vrednošću pritiska sa kojim je kočnica stvarno aktivirana kako bi se izračunalo odstupanje (greška) jedne vrednosti u odnosu na drugu. Ta vrednost odstupanja između pomenute dve vrednosti pritiska je iskorišćena za dinamičko ažuriranje težinskih odnosa u toku samog rada modela, što ima za cilj osposobljavanje modela, a time i kontrolera, da vrši dinamičko podešavanje pritiska u skladu sa promenama uticajnih veličina tokom ciklusa kočenja, odnosno ulaznih veličina (trenutnih vrednosti željenog/optimalnog klizanja, temperature kočnice i brzine točka). Osim toga, to omogućava i dodatno obučavanje za nove situacije kočenja, odnosno prilagođavanje u odnosu na nove uslove koji vladaju u kontaktu pneumatika i tla (na primer, prelazak na drugačiju vrstu podloge i/ili promena stanja podloge). Dinamičko obučavanje modela u toku ciklusa kočenja je veoma važno zbog toga što se na taj način proširuju inteligentne mogućnosti sistema da se dodatno prilagođava promenama i novim uslovima tokom kočenja, koji mogu biti rezultat promene stanja površine puta, vrste podloge po kojoj se vozilo kreće i/ili stanja opterećenosti vozila, odnosno stanja same kočnice. Nakon inicijalne obuke dinamičkog neuronskog modela u tzv. „offline“ režimu na osnovu izabranih 114 ciklusa kočenja, koji pokrivaju celokupan opseg promene ulaznih/izlaznih parametara, tako dobijeni težinski odnosi se dodatno ažuriraju, tj. prilagođavaju novim radnim režimima kočnice/uslovima prijanjanja, a da pri tome ne dođe do gubitka prethodno stečenog znanja o procesu kočenja. Ovo poslednje je takođe izuzetno važno za realnu primenu na vozilu pa je zbog toga prilikom razvoja date konfiguracije za inteligentno adaptivno upravljanje performansama kočnice u cilju postizanja željenog klizanja točka omogućeno kontrolisanje odnosno aktiviranje/deaktiviranje procesa dinamičkog obučavanja inverznog dinamičkog modela sa svakim novim ciklusom kočenja.

7.4.1. Inverzni dinamički modeli klizanja za prednju i zadnju osovinu

Posebni inverzni dinamički neuronski modeli klizanja za prednju i zadnju osovinu su razvijeni sa ciljem da se aproksimira rad prednje/zadnje kočnice zajedno sa procesima koji nastaju kao rezultat interakcije pneumatik-tlo. Da bi se obezbedilo što bolje podešavanje težinskih odnosa i bias-a mreže, inverzni dinamički modeli su podešeni tako da rade pet puta brže od odgovarajućeg dinamičkog neuronskog kontrolera. To znači da za jedan vremenski korak od 0,005 s, čije trajanje je uspostavljeno na nivou rada čitavog sistema, inverzni dinamički model izvrši podešavanje težinskih odnosa pet puta i tek onda se tako ažurirana matrica težinskih odnosa prenosi do neuronskog kontrolera. Dakle, inverzni dinamički neuronski model ima zadatku da vrši neprekidno obučavanje u realnom vremenu, tj. da se adaptira svakoj novoj situaciji prilikom kočenja vozila putem kontinualnog podešavanja težinskih odnosa mreže, koji, kako je to objašnjeno u poglavlju 6, određuju jačinu veza između neurona. Kako je već rečeno, to podrazumeva izračunavanje greške između pritiska koji model predviđa i pritiska sa kojim je kočnica stvarno aktivirana. Kao što je prikazano na slici 7.16, taj signal se ponovo vraća na ulaz u inverzni dinamički model i od njegovog intenziteta zavisi gradijent podešavanja težinskih odnosa. Ukoliko dođe do velikog poremećaja, odnosno iznenadnih promena ulaznih parametara tokom procesa kočenja, signal o povećanoj vrednosti greške se vraća povratnom spregom u model i na osnovu toga se težinski odnosi koriguju kako bi model zadržao stabilne performanse predviđanja. Na osnovu podešenih vrednosti težinskih odnosa između neurona, razvijeni inverzni dinamički model za prednju/zadnju osovinu čuva znanje o modeliranom procesu, tj. pamti kakav uticaj dinamičke promene klizanja točka, temperature kočnice i brzine točka imaju na dinamičku promenu pritiska aktiviranja kočnice. Usled izrazito nelinearne prirode procesa kočenja veoma je važno da dinamički neuronski kontroler ima u svakom trenutku ažurne vrednosti težinskih odnosa i bias-a.

Inverzni dinamički modeli za prednju i zadnju osovinu su razvijeni na osnovu dinamičke neuronske mreže sa prostiranjem signala unapred i jednim skrivenim

slojem sa 10 neurona. Do ovakve arhitekture neuronske mreže se došlo poređenjem performansi predviđanja ukupno 42 različite neuronske mreže. Istraživano je po 14 arhitektura mreža sa jednim, dva i tri skrivena sloja sa različitim kombinacijama broja neurona u okviru njih. Da bi se ilustrovale razlike i mogućnosti njihovog predviđanja pritiska u toku ciklusa kočenja, na slici 7.18 je dat uporedni prikaz predviđanja za izabrane tri mreže sa jednim (10 neurona), dva (10+5 neurona) i tri (5+3+2 neurona) skrivena sloja. Sve tri mreže su obučavane sa Bayesian Regularization algoritmom obuke, sa istim brojem podataka (33013), u trajanju od 1000 iteracija i sa stepenom obučavanja od 0,2. Kao što se vidi sa slike 7.18, jednoslojna mreža sa 10 neurona ima najbolju sposobnost generalizacije u odnosu na dati set ulazno/izlaznih podataka.



Slika 7.18. Poređenje predviđanja mreža u zavisnosti od njihove arhitekture

Prema strukturi, izabrana jednoslojna neuronska mreža odgovara adaptivnom generalizovanom višeslojnom perceptronu (engl. *Generalized Multi Layer Perceptron - GMLP*) u skladu sa [71]. To je veštačka neuronska mreža sa sigmoidnom funkcijom prenosa, koja se može opisati jednačinom (7.3):

$$f(s) = \frac{L + (U - L)}{1 + \exp(-s/T)} \quad (7.3)$$

gde je s ulaz funkcije, L je donja granica, U je gornja granica, a T predstavlja nagib krive. U slučaju da je $L = 0$, $U = 1$ i $T = 1$ funkcija se svodi na uobičajen oblik sigmoidne funkcije. Prošireno gradijentno pravilo, sa strukturom u skladu sa backpropagation algoritmom je korišćeno za ažuriranje parametara mreže (težinskih odnosa i bias-a). U bilo kom proizvoljnom vremenskom trenutku t , ako je $x(t)$ vektor ulaza/izlaza, tada se i -ti element izlaznog vektora iz skrivenog/izlaznog sloja mreže može predstaviti jednačinom (7.4):

$$z(i,t) = Lh(i,t) + \frac{Uh(i,t) - Lh(i,t)}{1 + \exp(-(V(i,t)x(t) + Pv(i,t)/Th(i,t)))} \quad (7.4)$$

gde su $Lh(i,t)$, $Uh(i,t)$ i $Th(i,t)$ i -ti elementi vektora donje granice, gornje granice i nagiba krive, respektivno. $V(i,t)$ predstavlja i -ti red matrice težinskih odnosa, a $Pv(i,t)$ je i -ti element vektora izlaza.

U skladu sa slikom 7.16, inverzni dinamički model ima tri ulaza (ulazni vektor u mrežu, signal o grešci između predviđanja modela i stvarnog pritiska aktiviranja i signal za aktiviranje/deaktiviranje procesa obuke mreže). Prvi ulaz je najvažniji i odnosi se na glavni vektor ulaza u inverzni dinamički model koji ima tri elementa (stvarno klizanje u kontaktu pneumatik-tlo, temperatura u kontaktu friкционog para i translatorna brzina točka). Kašnjenje (engl. *delay*) ulaznih vrednosti u odnosu na trenutnu vrednost tokom procesa obuke mreže iznosilo je 0,01 s. Na taj način je obuhvaćen uticaj istorije dinamičke promene ulaznih veličina na njihove trenutne vrednosti, što dalje olakšava posao neuronskom modelu da isprati tako kompleksne promene. Na ovo kašnjenje modela se mora dodati i kašnjenje usled filtriranja ulaznih signala (klizanja točka, brzine točka i temperature kočnice) pomoću diskretne vejvlet transformacije, koje iznosi 0,025 s.

Drugi ulaz predstavlja signal greške između trenutnih vrednosti pritiska koji predviđa inverzni dinamički model na izlazu i pritiska sa kojim je kočnica stvarno aktivirana. Na osnovu slika 7.16 i 7.17 se vidi da se taj izračunati signal povratnom spregom vraća na ulaz u model kako bi se na osnovu njegovog intenziteta izvršilo dinamičko ažuriranje težinskih odnosa. Težinski odnosi se ažuriraju pomoću

algoritma sa stepenastim opadanjem gradijenta, koji minimizira srednje kvadratno odstupanje između stvarnih i predviđenih vrednosti izlaza.

Treći ulaz je logički (Bulov) signal (na slici 7.16 obeležen sa AO – aktiviranje obuke) kojim se vrši aktiviranje/deaktiviranje procesa obuke mreže modela. Ukoliko je $A_0=1$ tada je obuka mreže aktivna, dok je u obrnutom slučaju kada je $A_0=0$ obuka mreže deaktivirana, tj. mreža tada vrši samo predviđanje, bez obuke u realnom vremenu. Rezultati koji su dobijeni se zasnivaju na tome da je ovaj signal bio podešen tako da kada je signal greške manji ili jednak 0,1 bar obuka modela se ne obavlja, tj. težinski odnosi se u tom slučaju ne ažuriraju. To podrazumeva da obuka modela u realnom vremenu nastupa jedino kada signal greške prekorači predefinisanu granicu od 0,1 bar, čime se obezbeđuje da model, odnosno kontroler radi sa minimalnim opterećenjem. Ukoliko pak signal greške koji se koristi za aktivaciju obuke prekorači predefinisanu granicu, težinski odnosi se tada ponovo dinamički podešavaju kako bi se model, odnosno kontroler što bolje prilagodio novoj situaciji tokom kočenja.

Kao što je već napomenuto u poglavljju 7.3, svi navedeni ulazni i izlazni signali iz neuronskog modela su dodatno filtrirani u cilju uklanjanja preostalog šuma. U neuronski model je zato implementiran IIR filter (engl. *Infinite Impulse Response*). IIR bazirani sistemi poseduju tzv. impulsnu funkciju odziva koja je različita od nule tokom vremena. Tipični primeri digitalnih filtara koji rade po ovom principu su Chebyshev, Butterworth i Bessel filtri. Funkcija ovog filtra se prema [200] opisuje pomoću diferencijalne jednačine (7.5) koja definiše promenu izlaznog signala u zavisnosti od promene ulaznog signala.

$$y(n) = \frac{1}{a_0} (b_0 x[n] + b_1 x[n-1] + \dots + b_p x[n-P] - a_1 y[n-1] - a_2 y[n-2] - \dots - a_Q y[n-Q]) \quad (7.5)$$

Gde su P – red filtra pri prostiranju signala unapred, b_i – koeficijenti filtra pri prostiranju signala unapred, Q – red filtra pri prostiranju signala unazad, a_i – koeficijenti filtra pri prostiranju signala unazad, $x[n]$ – ulazni signal i $y[n]$ – izlazni

signal. Sređivanjem diferencijalne jednačine (7.6) može se dobiti njen kompaktniji oblik:

$$y[n] = \frac{1}{a_0} \left(\sum_{i=0}^P b_i x[n-i] - \sum_{j=1}^Q a_j y[n-j] \right) \quad (7.6)$$

Odgovarajuće podešavanje stepena učenja mreže je takođe od presudnog značaja. Njegove prevelike vrednosti obezbeđuju bolje performanse učenja mreže, ali takođe i veći korak promene trenutnih vrednosti težinskih koeficijenata. To podrazumeva stalnu adaptaciju mreže novim radnim uslovima i može dovesti do toga da mreža postane bolje prilagođena za određene radne režime kočnice, odnosno uslove prijanjanja nego za druge. Izbor nižih vrednosti stepena učenja za ovu vrstu mreže, onda kada postane dobro obučena da može da pokrije ceo radni opseg, tj. opseg promene ulaznih/izlaznih veličina, obezbeđuje promenu težinskih odnosa sa manjim korakom. Mreža će biti tada manje osetljiva na nove radne uslove, ali prethodno stečeno znanje neće biti izgubljeno jer mreža uči samo onda kada postoji veliko odstupanje u predviđanju modela. Međutim, glavna prednost leži u činjenici da svaki novi ciklus kočenja sada može da se iskoristi za adaptivnu obuku inverznog dinamičkog neuronskog modela, razvijenog radi uspostavljanja funkcionalnog odnosa između klizanja točka, njegove brzine i temperature kočnice sa jedne, i pritiska aktiviranja kočnice sa druge strane.

7.4.2. Dinamičko upravljanje procesom kočenja za prednju i zadnju osovINU

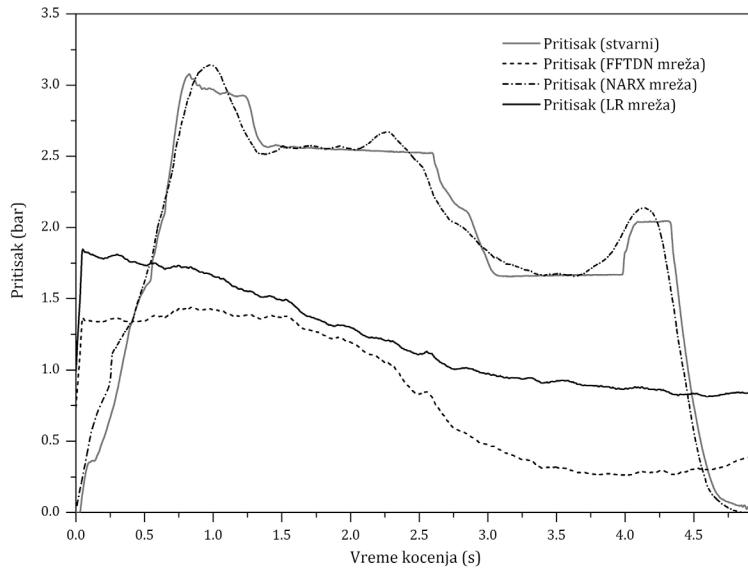
Dinamički neuronski kontroler procesa kočenja za prednju/zadnju osovinu, prikazan na slici 7.16, je razvijen na osnovu inverznog dinamičkog neuronskog modela procesa kočenja sa ciljem da se omogući inteligentno podešavanje pritiska aktiviranja kočnice kako bi se u kontaktu pneumatika i tla ostvario željeni nivo podužnog klizanja točka. Njegova funkcija u sistemu je upravljanje pritiskom aktiviranja kočnice sa kojim bi se ostvarilo željeno klizanje, za date uslove prijanjanja, radne režime kočnice i stanje opterećenosti vozila. Neuronska mreža ovog kontrolera ima istu strukturu kao i mreža inverznog dinamičkog modela. To

omogućava da se neprekidno ažuriraju vrednosti matrice težinskih odnosa od inverznog dinamičkog modela do neuronskog kontrolera. Time se trenutna, ažurna, funkcionalna veza, koja aproksimira rad kočnice i stepen iskorišćenja uslova prijanjanja u kontaktu pneumatik-tlo, neprekidno tokom svakog ciklusa kočenja preslikava u kontroler. Na ovaj način se obezbeđuje da predikcija potrebnog pritiska aktiviranja kočnice bude usaglašena sa trenutnim performansama kočnice i uslovima u kontaktu pneumatika i tla, naravno, sa određenim, dovoljno malim, zakašnjenjem u odnosu na realan proces kočenja.

Prema [73,85], primena dinamičkih veštačkih neuronskih mreža se pokazala kao veoma efikasan metod za modeliranje i predviđanje kompleksnih dinamičkih procesa. Na osnovu toga u ovoj doktorskoj disertaciji je tokom razvoja dinamičkog neuronskog modela najpre istraživano koji od postojećih tipova dinamičkih neuronskih mreža analiziranih u poglavljju 6 ima najbolje mogućnosti za primenu u procesu modeliranja, a zatim i upravljanja performansama kočnice u cilju ostvarivanja željenog klizanja u kontaktu pneumatika i tla. Na slici 7.19 su uporedno prikazane performanse predviđanja pritiska aktiviranja kočnice pomoću tzv. „Feedforward Distributed Time Delay“ mreže (FFTDN), „NARX“ rekurentne mreže (NARX) i „Layer-Recurrent“ (LR) mreže. Mreže su jednoslojne sa 10 neurona u skrivenom sloju i obučavane su pod istim uslovima sa Bayesian Regularization algoritmom. U poređenju sa stvarnim pritiskom aktiviranja kočnice tokom izabranog ciklusa kočenja, sa slike 7.19 je evidentno da je NARX rekurentna mreža predvidela pritisak sa najmanjom greškom u odnosu na ostale dve mreže. Osim toga, ova mreža je najbolje generalizovala funkcionalnu zavisnost između ulaza i izlaza u odnosu na dati set podataka.

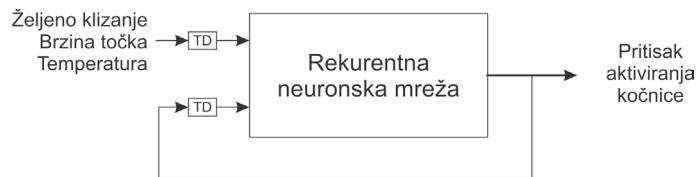
Imajući u vidu prethodno poređenje za razvoj kontrolera je izabrana rekurentna dinamička neuronska mreža i to tzv. nelinearna autoregresivna veštačka neuronska mreža sa spoljašnjim ulazima (NARX dinamička neuronska mreža, detaljno analizirana u poglavljju 6) za modeliranje i predviđanje pritiska aktiviranja kočnice u zavisnosti od dinamičke promene uticajnih faktora na ulazu (klizanje točka, temperatura u kontaktu friкционog para i translatorna brzina točka). Najpre je razvijen dinamički neuronski model obučavanjem NARX rekurentne mreže u tzv.

offline režimu kako bi se dobile inicijalne vrednosti težinskih odnosa, a zatim je na osnovu tog modela razvijen dinamički neuronski kontroler kao jedan od osnovnih elemenata sistema za inteligentno upravljanje performansama kočnice da bi se ostvarilo željeno klizanje točka.



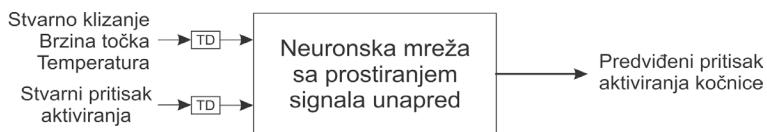
Slika 7.19. Poređenje predviđanja različitih tipova dinamičkih mreža

Kao što je prikazano na slici 7.20, NARX neuronska mreža iskorišćena za razvoj neuronskog modela, a potom kontrolera, pripada rekurentnim dinamičkim neuronskim mrežama sa povratnom spregom koja obuhvata sve slojeve mreže. Shematski prikaz takve mrežne arhitekture prikazan na slici 7.20 predstavlja tzv. originalni (naziva se još i zatvoreni ili paralelni) oblik NARX mreže. Kao što je detaljno pokazano u poglavlju 6, ovakav model mreže je baziran na linearном ARX modelu, koji se široko koristi kod modeliranja procesa koji se menjaju tokom vremena. Trenutna vrednost izlaznog signala se vraća nazad na ulaz zajedno sa prethodnim vrednostima izlaza i prethodnim vrednostima spoljašnjeg ulaza u mrežu, sadržanih u okviru vektora TD, slika 7.20.



Slika 7.20. NARX neuronska mreža u tzv. zatvorenoj (paralelnoj) formi

Prema [82,83,85,87-89], NARX mreža se široko koristi u mnogim oblastima, a posebno za modeliranje nelinearnih dinamičkih sistema. Još jedan razlog zbog koga je ona iskorišćena za razvoj dinamičkog modela procesa kočenja leži u činjenici da je moguće formirati tzv. serijsko-paralelnu ili redno-paralelnu arhitekturu mreže, koja je veoma korisna prilikom obučavanja ovako kompleksne mreže (slika 7.21). Serijsko-paralelna arhitektura mreže ima dve važne prednosti: (i) vektor ulaza u mrežu je jednostavniji, i (ii) rezultujuća mrežna arhitektura je feedforward tipa, odnosno kompleksna arhitektura rekurentne mreže se svodi na jednostavnu mrežnu arhitekturu sa prostiranjem signala unapred, što dalje omogućava primenu statičkog backpropagation algoritma za obuku. U skladu sa slikom 7.21, stvarne vrednosti pritiska aktiviranja kočnice su korišćene za obuku NARX mreže u serijsko-paralelnoj formi (kao sekundarni ulaz u mrežu) umesto da se na ulaz vraća vrednost pritiska koji ona predviđa. Stvarno klizanje točka, njegova brzina i temperatura u kontaktu friкционog para kočnice su iskorišćeni za formiranje vektora primarnog ulaza u mrežu, slika 7.21.



Slika 7.21. Serijsko-paralelna forma NARX rekurentne mreže

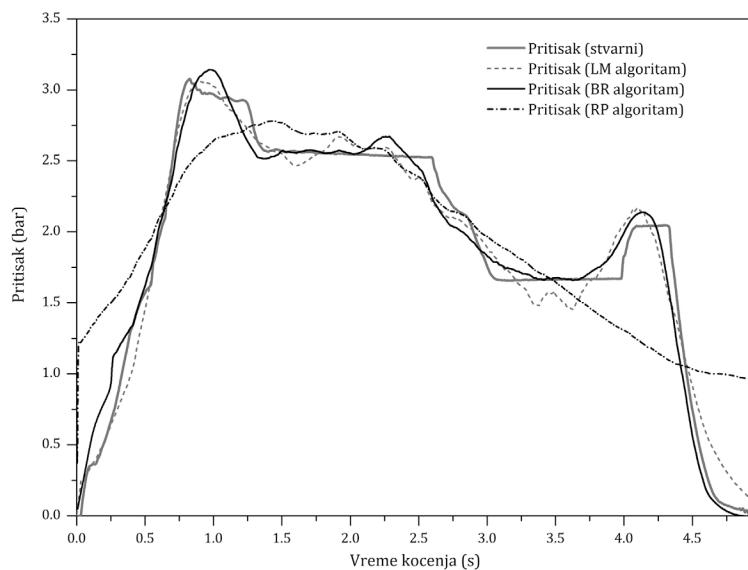
Obuka NARX rekurentne mreže u offline režimu je obavljena pomoću podataka eksperimentalno dobijenih tokom ispitivanja autobusa na poligonu. Ukupan broj od 194 raspoloživa ciklusa kočenja (228327 podataka) je podeljen u setove za obuku i testiranje u cilju obuke i daljeg testiranja, odnosno validacije rekurentnih neuronskih modela. Pošto dinamičke neuronske mreže sadrže kašnjenja (delays), ulaz u mrežu mora biti niz ulaznih vektora koji se pojavljuju u određenom vremenskom rasporedu. Poredak po kome se vektori pojavljuju je izuzetno važan. Obuka neuronskih mreža je obavljena sa početnom vrednošću ulaznog kašnjenja od 0,1 sekundi. Izmerena (stvarna) vrednost pritiska aktiviranja kočnice takođe kasni 0,1 s kao sekundarni ulaz u serijsko-paralelnu formu NARX mreže (slika 7.21). Na taj način, prošle vrednosti ulazno/izlaznih parametara, koje nose informacije o istoriji njihovih dinamičkih promena, su prezentovane mreži preko

ulaznih i izlaznih kašnjenja. Važno je napomenuti da su ne samo prethodne vrednosti izlaza vraćane nazad, već takođe i prošle vrednosti brzine točka, temperature i klizanja točka. Mreža je dakle prvo obučavana u otvorenom (serijsko-paralelnom) obliku koristeći stvarne vrednosti pritiska aktiviranja kočnice, umesto vraćanja nazad njegovih predviđenih vrednosti. Vremensko trajanje ulaznih i izlaznih kašnjenja je pravilno podešeno tako da omogućava dobre i stabilne mogućnosti za predviđanje pritiska aktiviranja kočnice.

Različite vrednosti ulaznog/izlaznog kašnjenja imaju shodno tome i drugačiji uticaj na performanse predviđanja neuronskog modela. Ulazna i izlazna kašnjenja zavise od dinamičke promene stvarnog pritiska aktiviranja u toku ciklusa kočenja. Previše malo kašnjenje može da dovede do nedovoljnih performansi predviđanja modela u smislu njegovog prilagođavanja realnoj dinamičkoj promeni parametra koji se modelira, a u skladu sa tim i gubitka kvaliteta predviđanja i njegove stabilnosti. Rezultati predviđanja dobijeni sa više podataka koji se odnose na prošle vrednosti su uglavnom precizniji. Previše prošlih vrednosti, tj. preveliko kašnjenje bi takođe moglo da ima negativan uticaj na sposobnost mreže da isprati složene i iznenadne promene parametara procesa. Obično su najveći razlozi za to povećani intenzitet izračunavanja unutar mreže i produženo vreme potrebno za obradu velike količine podataka. Osim toga, u znatnoj meri utiču i kompleksna promena parametara procesa, kao i veličina mreže (veliki broj skrivenih slojeva i/ili neurona u njima) i vreme trajanja modeliranog procesa. Pored toga, može doći do smanjenja osetljivosti modela na dinamičke promene izlazne veličine.

Pošto najbolja kombinacija arhitekture neuronske mreže i algoritma obuke nije unapred poznata, potrebno je kroz više pokušaja (eng. *trial and error* metod) obučiti i izabrati neuronski model sa najboljim karakteristikama. Zbog toga je razvijeno 42 rekurentna neuronska modela sa jednim, dva i tri skrivena sloja. Za svaku od ovih mrežnih arhitektura broj neurona u skrivenim slojevima je postepeno povećavan. Veći broj neurona u skrivenom sloju daje mreži veću fleksibilnost, jer ona tada ima više parametara koje može da optimizira. Sa druge strane, mreže sa jednim skrivenim slojem i odgovarajućim brojem neurona u njemu imaju prednost sa stanovišta veće stabilnosti i otpornosti na iznenadne

dinamičke promene ulaza, a posebno u pogledu bržeg vremena odziva, što ih čini posebno pogodnim za razvoj modela kao preduslova za projektovanje kontrolera na bazi veštačkih neuronskih mreža. Razmatrane dinamičke neuronske mreže su obučavane pomoću tri algoritma obuke: Levenberg-Marquardt (LM), Bayesian Regularization (BR), i Resilient Backpropagation (RP), respektivno. Primena svakog od navedena tri algoritma obuke ima različite konačne efekte na obuku složenih dinamičkih neuronskih mreža, što je ilustrovano na slici 7.22. Prema [150], najbrža funkcija obuke je uglavnom LM algoritam, mada je manje efikasan u slučaju velikih mreža, jer one zahtevaju više memorije i duže vreme računanja za ove slučajeve. Dobre osobine uopštavanja (generalizacije) BR algoritma su takođe istraživane u ovom radu. RP algoritam je dobar izbor u slučaju obuke velikih mreža, naročito kada su one dinamičke. Njegovi memorijski zahtevi su relativno mali, a ipak je mnogo brži od ostalih gradijentnih metoda. Razmatrane različite arhitekture dinamičkih neuronskih mreža su obučavane i testirane pomoću programskog paketa Matlab/Simulink 7.12 (R2011a). Između skrivenog i izlaznog sloja, kao i na izlazu iz mreže korišćena je ista sigmoidna funkcija prenosa kao u slučaju inverznog dinamičkog modela definisana pomoću jednačine (7.3).



Slika 7.22. Uticaj algoritama za obuku na predviđanje mreže

Pre početka procesa obuke neuronskih mreža, izvršeno je predprocesiranje ulaznih i izlaznih parametara u okviru setova za obuku i testiranje. Ovo je

postignuto kroz skaliranje ulaznih i izlaznih podataka u opseg između [-1, 1] kako bi značaj svakog ulaznog podatka u odnosu na promenu izlaza bio više evidentan. Dakle, uticaj razlike u opsegu podataka na ulazu je na taj način eliminisan, odnosno ulazni i izlazni podaci su predprocesirani kako bi se održali u malom, predvidljivom opsegu. Podaci su normalizovani prema izrazu (7.7). Vrednosti parametra x označene sa s u izrazu (7.7) predstavljaju skalirane vrednosti, dok vrednosti označene sa r predstavljaju realne (stvarne) vrednosti odgovarajućeg parametra.

$$x_{(s)} = x_{(s)\min} + \frac{x_{(r)} - x_{(r)\min}}{x_{(r)\max} - x_{(r)\min}} (x_{(s)\max} - x_{(s)\min}) \quad (7.7)$$

Da bi se obezbedila što bolja i efikasnija obuka dinamičkih neuronskih mreža u offline režimu, u tu svrhu je iskorišćeno 78 ciklusa kočenja, od toga je 40 kočenja obavljen u neopterećenom stanju vozila, a preostalih 38 kočenja se odnosi na opterećeno stanje vozila. Za testiranje neuronskih mreža u pogledu njihove sposobnosti generalizacije iskorišćeno je ukupno 58 ciklusa (31 u neopterećenom i 27 u opterećenom stanju vozila). Ova dva skupa podataka su pažljivo formirana sa ciljem da se uspostavi relativno ravnomerna raspodela radnih režima kočnice. Nakon obuke mreža u serijsko-paralelnoj formi, one su prekomponovane u originalnu (paralelnu) formu kako bi se omogućilo predviđanje tokom više vremenskih koraka. Najbolje performanse predviđanja su ostvarene pomoću NARX rekurentne neuronske mreže sa jednim skrivenim slojem koji sadrži deset neurona. Relativno visok nivo generalizacije je postignut obučavanjem pomoću Bayesian Regularization algoritma.

U narednom poglavlju će biti analizirano na koji način ovakav koncept inteligenčnog upravljanja performansama kočnice može da se iskoristi za unapređenje rada kočnih sistema privrednih vozila sa ciljem da se u kontaktu pneumatika i tla realizuje željena vrednost klizanja točka, za date uslove prijanjanja, zahteve vozača, stanja opterećenosti vozila i performansi posmatranih kočnica na prednjoj i zadnjoj osovini. Imajući u vidu da se najvažniji pravac istraživanja u ovoj doktorskoj disertaciji odnosi na mogućnosti unapređenja rada

elektronski upravljanog kočnog sistema (EBS-a) kod privrednih vozila, posebna pažnja je posvećena unapređenju njegovih integrisanih funkcija koje svoj rad prvenstveno zasnivaju na što efikasnijem upravljanju klizanjem u kontaktu pneumatik-tlo, a to su pre svega ABS i DSC (engl. *Differential Slip Control*). Upravo zbog toga, paralelno su razvijeni posebni neuronski modeli koji funkcionalno aproksimiraju rad kočnice i uslove prijanjanja na prednjoj, odnosno zadnjoj osovini, što je dalje dovelo do razvoja odgovarajućih kontrolera za upravljanje pritiskom aktiviranja kočnica na prednjoj i zadnjoj osovini.

7.4.3. Verifikacija „performansi“ predviđanja neuronskih modela za prednju i zadnju osovinu

U okviru ovog poglavlja su prikazani rezultati testiranja kvaliteta predviđanja neuronskih modela u cilju njihovog kasnijeg korišćenja kao osnove budućeg sistema za inteligentno upravljanje performansama kočnice. Simuliranje rada, tj. predviđanja pritisaka aktiviranja disk kočnica od strane neuronskih modela, kao deo inteligentnog kočnog sistema, je izvršeno u programskom paketu Matlab/Simulink. Osnovni cilj testiranja je bila verifikacija performansi neuronskih modela, a time i neuronskih kontrolera, za prednju i zadnju osovinu, u smislu ocene mogućnosti za predviđanje pritiska aktiviranja kočnica u cilju održanja podužnog klizanja u kontaktu pneumatika i tla tokom ciklusa kočenja na željenom nivou.

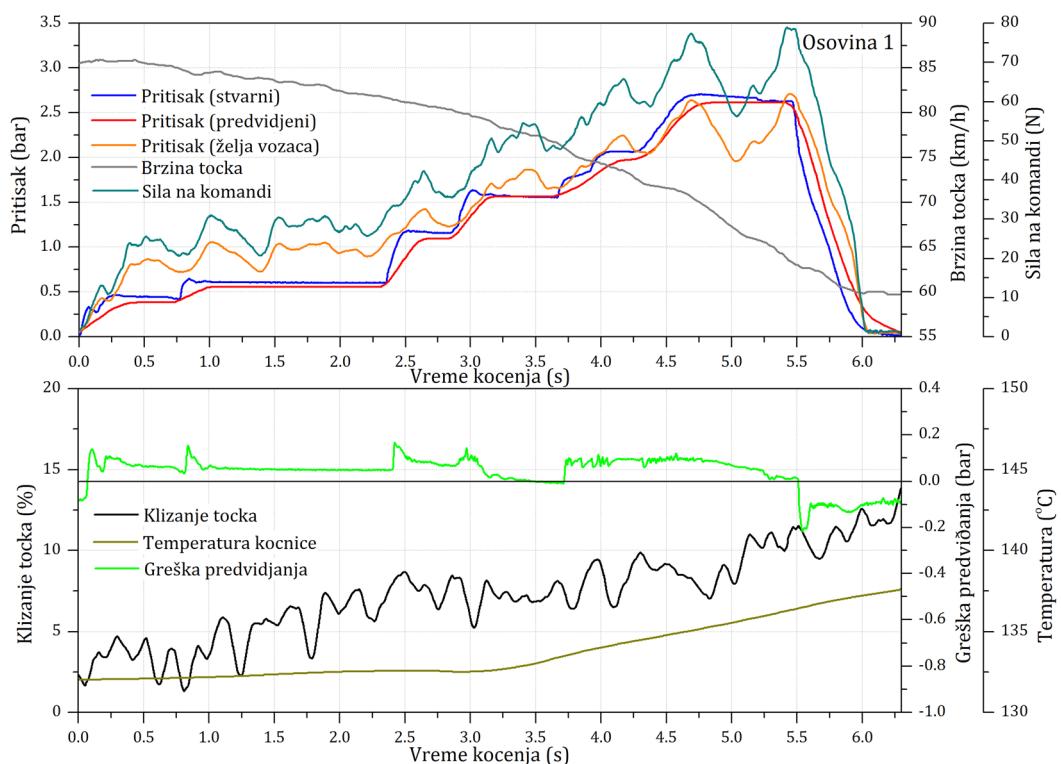
Kako je pokazano u poglavlju 4, realizacija gore pomenutih zadataka nije jednostavna imajući u vidu izrazite oscilacije u promeni stvarnog klizanja točka tokom ciklusa kočenja, koje može znatno da se razlikuje u odnosu na različite režime kočenja točkova na prednjoj i zadnjoj osoVINI u okviru istog ciklusa kočenja (slike 4.16-4.21). Pošto je fokus u okviru istraživanja u ovom radu usmeren na unapređenje rada kočnog sistema u pogledu boljeg i efikasnijeg upravljanja kočnim performansama vozila, odnosno usporenju vozila i skraćenju puta kočenja uz održavanje stabilnosti vozila na pravcu, posebna pažnja tokom analize rezultata je posvećena unapređenju rada protivblokirajućeg uređaja (ABS) i sistema za diferencijalno upravljanje klizanjem točkova na prednjoj/zadnjoj osoVINI (DSC).

Zbog toga je ovo poglavlje koncipirano tako da je omogućeno paralelno upoređivanje performansi intelligentnog upravljanja u slučaju kočnice na prednjoj i kočnice na zadnjoj osovini. To je posebno važno zbog analize mogućnosti primene ove metode u cilju intelligentne raspodele sila kočenja između kočnica na prednjoj i zadnjoj osovini, tako da se u kontaktu odgovarajućih točkova i puta ostvari željeni nivo klizanja u podužnom pravcu.

Rezultati prikazani na sledećim slikama ilustruju na koji način je moguće poboljšati upravljanje performansama kočnice u okviru EBS sistema privrednih vozila da bi se unapredio njihov rad i preventivno delovalo u cilju sprečavanja posledica fenomena koji se javljaju u kontaktu pneumatika i tla tokom kočenja. Najpre je izvršeno testiranje sistema intelligentnog upravljanja koji se zasniva na tehnici veštačkih neuronskih mreža u cilju verifikacije njegovih mogućnosti, odnosno mogućnosti dinamičkih neuronskih modela klizanja za prednju i zadnju osovinu da izvrše predviđanje pritiska aktiviranja kočnice u toku ciklusa kočenja, kako bi se ostvarilo željeno klizanje točka. Predviđena vrednost pritiska aktiviranja kočnice od strane dinamičkih neuronskih modela klizanja za prednju i zadnju osovinu, u odnosu na dinamički promenljive vrednosti klizanja točka, temperature kočnice i brzine točka, je verifikovana na osnovu karakterističnih ciklusa kočenja. Ti ciklusi kočenja su bili nepoznati modelima tokom procesa obuke, odnosno nalaze se u setu podataka za testiranje. Prva četiri analizirana ciklusa kočenja su obavljena tokom ispitivanja vozila u neopterećenom stanju (slike 7.23-7.26), dok se druga četiri ciklusa odnose na opterećeno stanje vozila (slike 7.27-7.30). Na svakom od pomenutih dijagrama su prikazane dinamičke promene sile na komandi sistema za radno kočenje i tako generisanog pritiska aktiviranja kočnice koji zahteva vozač. Da bi se ilustrovalo proces dinamičke obuke modela, dijagrami prikazani na slikama 7.23-7.30 sadrže i dinamičku promenu greške na osnovu koje se model dodatno obučava u toku samog ciklusa kočenja. Ko što je već objašnjeno, pod pojmom greške obuke ovde se podrazumeva razlika između vrednosti pritiska koju dinamički neuronski model predviđa na izlazu i stvarne vrednosti pritiska u tom trenutku. Radi pojednostavljenja, u objašnjenjima ispod slika su, umesto punih naziva „srednji maksimalni pritisak“ i „početna brzina kočenja“, korišćeni skraćeni

nazivi, odnosno samo „pritisak“ i „brzina“, respektivno. Osim toga, u svim objašnjenjima rezultata testiranja, kao i na odgovarajućim dijagramima, korišćena translatorna brzina točka (izračunata na osnovu merenog broja obrtaja točka) je kraće označavana samo sa „brzina točka“.

Na slikama 7.23 i 7.24 je prikazana verifikacija „performansi“ predviđanja dinamičkih neuronskih modela za prednju i zadnju osovini, na primeru ciklusa kočenja koji su karakteristični po dugotrajnom postepenom povećanju pritiska do maksimalne vrednosti, a zatim po naglom opadanju stvarnog pritiska aktiviranja do nule usled prestanka dejstva vozača na komandu sistema za radno kočenje. Izmerena temperatura kočnice na prednjoj osovini tokom ciklusa kočenja se menjala u opsegu 132-138 °C (slika 7.23), a na zadnjoj osovini između 158-164°C (slika 7.24).



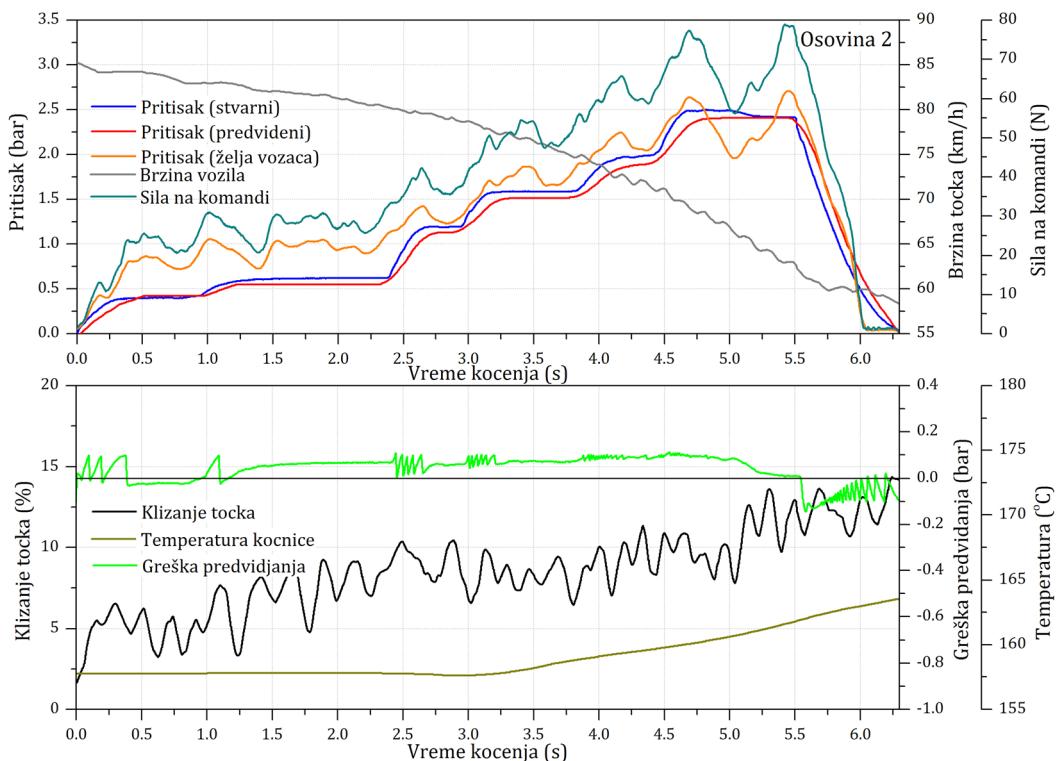
Slika 7.23. Verifikacija predviđanja neuronskog modela – prednja osovina (pritisak 2,5 bar, brzina 85 km/h)

Za date cikluse kočenja karakterističan je blago rastući trend promene stvarnog klizanja prednjeg/zadnjeg točka, koja kod točka na zadnjoj osovini ima izraženije oscilacije na kraju ciklusa kočenja. Zbog relativno blagog kočenja i samim tim male

preraspodele vertikalnog opterećenja sa zadnje na prednju osovinu, EBS sistem je podesio pritiske aktiviranja kočnica na prednjoj i zadnjoj osovini tako da je razlika između srednjih maksimalnih vrednosti tih pritisaka aktiviranja mala (oko 0,1 bar). Sa slike 7.23 i 7.24 se vidi da se stvarno klizanje točkova na prednjoj/zadnjoj osovini menja u opsegu između 2-14%.

Performanse predviđanja dinamičkih neuronskih modela za prednju i zadnju osovinu su verifikovane tako što su im saopšteni isti uslovi, odnosno stvarne promene ulaznih veličina (klizanje točka, brzina točka i temperatura kočnice) koje su izmerene/izračunate tokom eksperimentalnog istraživanja, a zatim su njihova predviđanja pritisaka aktiviranja prednje/zadnje kočnice upoređena sa odgovarajućim stvarnim promenama pritisaka aktiviranja kočnica na prednjoj i zadnjoj osovini. Dakle, za potrebe verifikacije modela željena promena klizanja je identična kao stvarna dinamička promena klizanja točka ostvarena u toku ciklusa kočenja. To znači da su modelima za prednju i zadnju osovinu na ulazu saopštene poznate stvarne vrednosti klizanja, brzine točka i temperature kočnice u odnosu na koje oni treba da izvrše dinamičko predviđanje pritisaka aktiviranja kočnica na prednjoj/zadnjoj osovini vozila. Na osnovu prethodno uspostavljene funkcionalne međuzavisnosti između ulaznih i izlaznih podataka, dinamički neuronski modeli za prednju i zadnju osovinu su trebali da predvide dinamičke promene pritisaka aktiviranja prednjih i zadnjih kočnica u toku ciklusa kočenja. Ocena, odnosno verifikacija kvaliteta predviđanja neuronski modela je izvršena upoređenjem stvarnih (izmerenih) pritisaka aktiviranja kočnica sa predviđenim vrednostima pritisaka tokom ciklusa kočenja za različite radne režime kočnica. Na osnovu poređenja predviđenih promena pritisaka sa pritiscima sa kojim su kočnice na prednjoj/zadnjoj osovini stvarno aktivirane (slike 7.23 i 7.24) može se uočiti da postoje mala odstupanja predviđenih vrednosti pritisaka u odnosu na stvarne. Na osnovu prikazanih dinamičkih promena grešaka predviđanja modela za prednju/zadnju osovinu, mogu se uočiti trenuci tokom ciklusa kočenja u kojima su se modeli dodatno obučavali, kako bi se predviđeni pritisci aktiviranja prednje/zadnje kočnice doveli na nivo koji odgovara njima odgovarajućim promenama stvarnog pritiska. Na primer, ako se posmatra ciklus kočenja prikazan

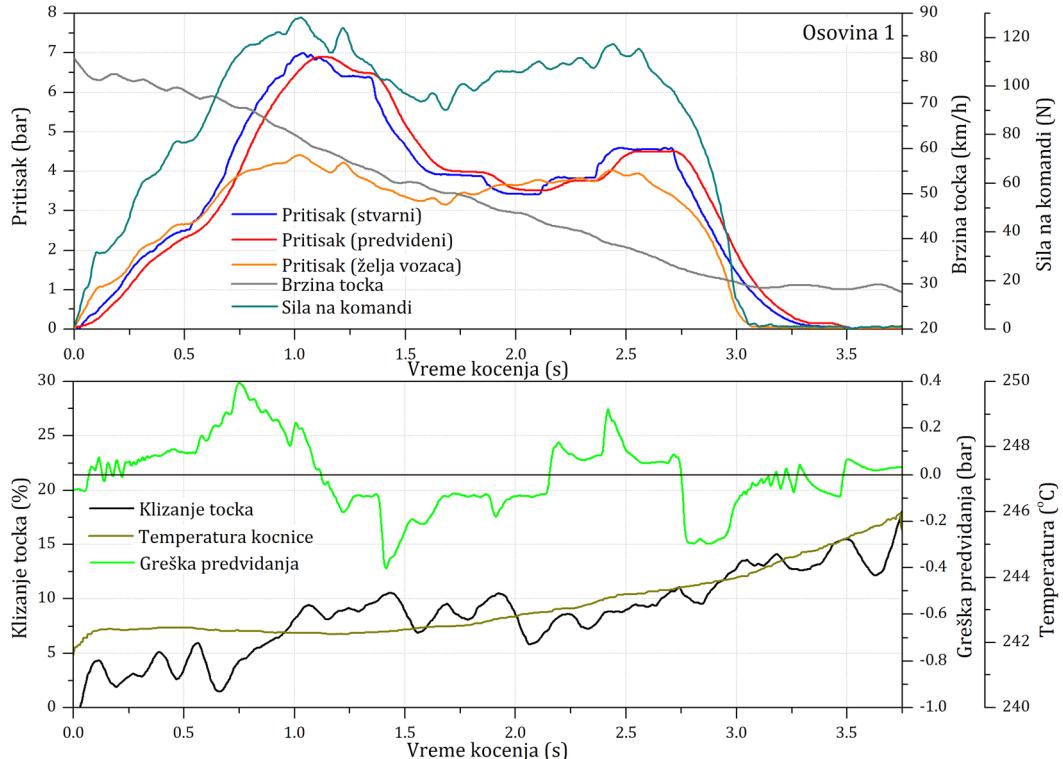
na slici 7.23, u trenucima 0,1 s, 0,8 s i 2,4 s, a posebno trenutku 5,5 s od početka procesa kočenja, greška predviđanja modela za prednju osovinu prekoračuje vrednost od 0,1 bar, koja je postavljena kao granična za aktiviranje/deaktiviranje procesa dinamičke obuke modela. U tim trenucima je inverzni dinamički model ažurirao vrednosti težinskih odnosa i u skladu sa tim korigovao predviđanje pritiska sa zakašnjnjem od 0,046 s u cilju postizanja željene promene klizanja. U slučaju ciklusa kočenja koji se odnosi na zadnju osovinu (slika 7.24), karakterističan je deo od 5,5 s do završetka ciklusa kočenja, tokom koga je model dodatno korigovao težinske odnose. U delovima ciklusa gde je ova greška u intervalu između -0,1 do 0,1 bar, modeli za prednju i zadnju osovinu su vršili predviđanje pritisaka aktiviranja kočnice na prednjoj/zadnjoj osovini na osnovu trenutno važeće matrice težinskih odnosa.



Slika 7.24. Verifikacija predviđanja neuronskog modela – zadnja osovina (pritisak 2,4 bar, brzina 85 km/h)

Na izabranom primeru iz grupe ciklusa kočenja kod kojih je potrebno realizovati brz odziv sistema, odnosno ostvariti visok gradijent povećanja pritiska aktiviranja kočnice u relativno kratkom vremenskom periodu, proverene su mogućnosti

razvijenih dinamičkih neuronskih modela za kočnice na prednjoj/zadnjoj osovini da predvide pritisak aktiviranja kočnica kako bi se ostvarile stvarno izračunate promene klizanja na prednjoj/zadnjoj osovini (slike 7.25 i 7.26).

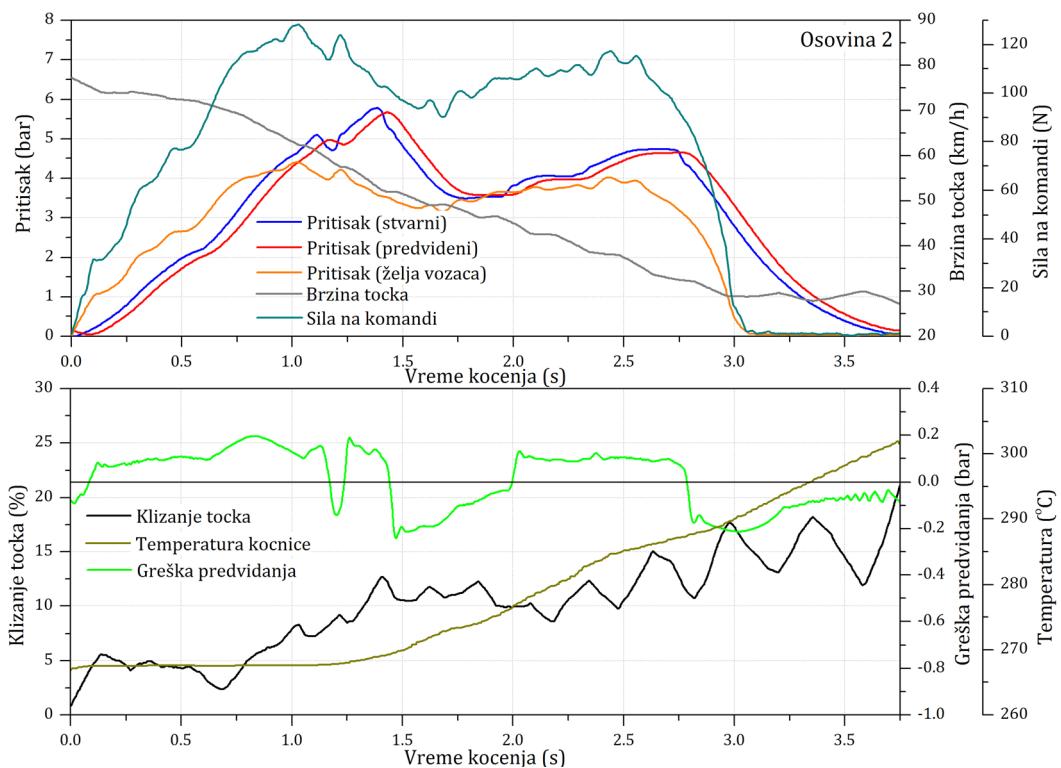


Slika 7.25. Verifikacija predviđanja neuronskog modela – prednja osovina (pritisak 6,5 bar, brzina 80 km/h)

Kao što se vidi sa ovih slika, izabrani su ciklusi kočenja koje karakteriše visok gradijent porasta pritiska aktiviranja u početnom delu ciklusa kočenja, a zatim se pritisak naglo smanjivao i ponovo povećavao do kraja ciklusa. Dati ciklusi kočenja su takođe karakteristični i po relativno visokoj temperaturi kočnica na prednjoj (245°C) i zadnjoj osovini (290°C). Ako se posmatra slika 7.25, stvarni pritisak aktiviranja kočnice na prednjoj osovini naglo raste do 7 bar tokom prve sekunde kočenja. Posledica toga je porast klizanja točka u podužnom pravcu u proseku za oko 10%. Do druge sekunde kočenja pritisak aktiviranja kočnice se smanjuje do polovine prvobitne vrednosti (a takođe i klizanje), dok se posle toga povećava za oko 1 bar do 2,75 s. Sa slike 7.26 se može uočiti da promena pritiska aktiviranja kočnice na zadnjoj osovini ima sličan karakter, ali je srednja maksimalna vrednost pritiska manja. Imajući u vidu da se ovakav režim kočenja može svrstati u nagla

(panična) kočenja, usled preraspodele opterećenja između osovina, EBS sistem je podesio manji pritisak na zadnjoj osovinu da ne bi došlo do prekoračenja maksimalno raspoložive sile u kontaktu pneumatika i tla u podužnom pravcu.

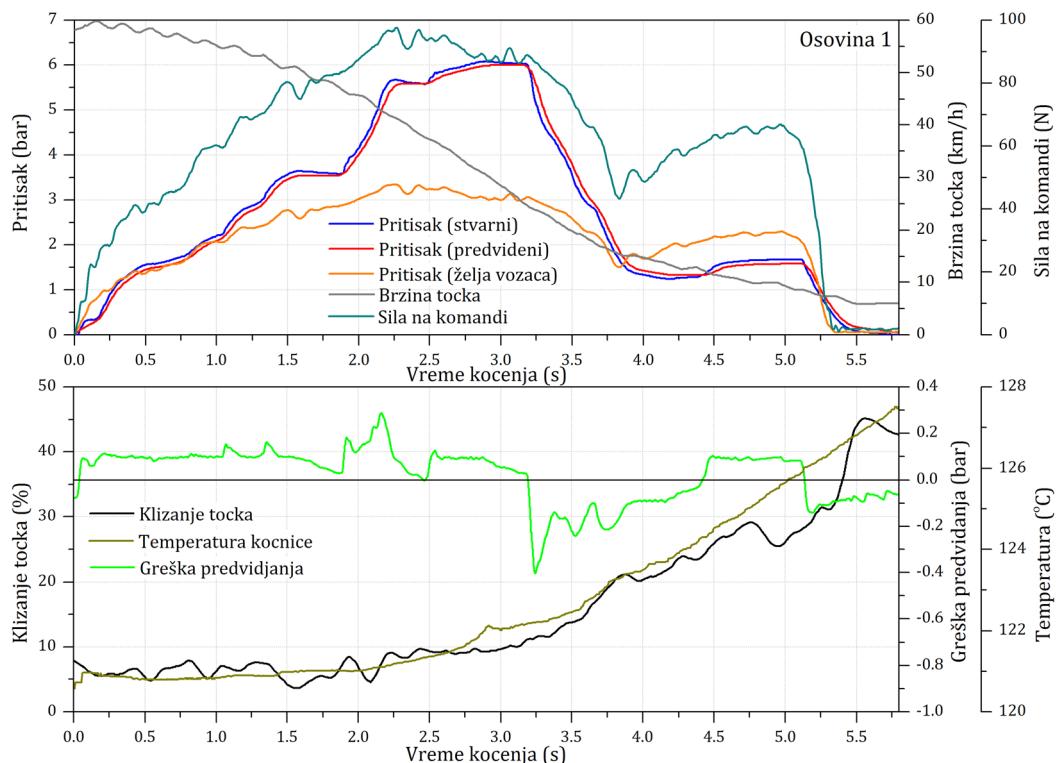
Dinamički neuronski model klizanja za prednju osovinu je sa zakašnjnjem od 0,1 s predvideo potrebnu promenu pritiska aktiviranja tokom ovog ciklusa kočenja kako bi se klizanje točka održavalo na željenom nivou. To se može zaključiti sa slike 7.25, na kojoj se vidi da je model za prednju osovinu na osnovu datih promena ulaznih veličina predvideo nagli porast pritiska od 0 do 7 bar u periodu od samo jedne sekunde. Ako se posmatra greška predviđanja (slika 7.25), vidi se da su predviđanja modela najviše odstupala od vrednosti stvarnog pritiska u trenucima 0,75 s, 1,4 s, 2,3 s i između 2,8-3 s od početka kočenja, što je uticalo na aktiviranje on-line obuke modela. To su upravo trenuci u kojima dolazi do naglih promena u veličini klizanja točka, a u skladu je sa promenom stvarnog pritiska aktiviranja kočnice.



Slika 7.26. Verifikacija predviđanja neuronskog modela – zadnja osovina (pritisak 5,2 bar, brzina 80 km/h)

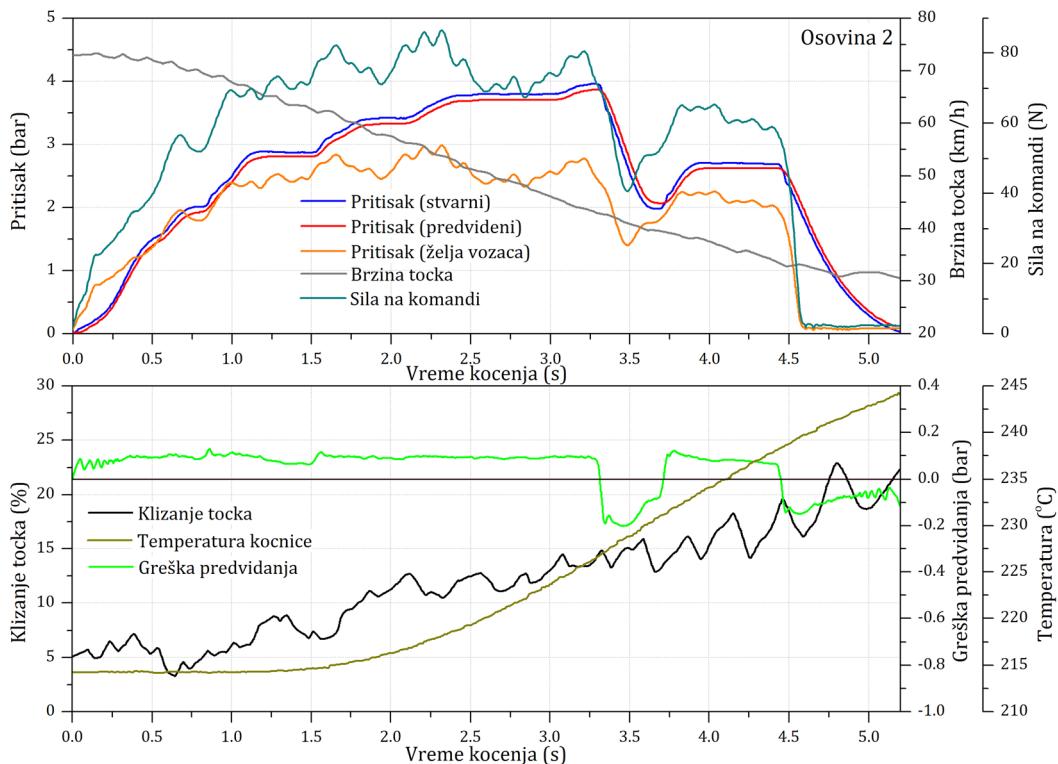
U slučaju modela za podešavanje pritiska aktiviranja na zadnjoj osovini, nagle promene klizanja točka, u sinergiji sa dinamičkim promenama brzine i temperature, takođe znatno utiču na predviđanje pritiska od strane modela (slika 7.26). Na primer, u trenutku 1,4 s (slika 7.26) greška predviđanja modela naglo dostiže vrednost od -0,25 bar. Obuka modela se aktivirala i u skladu sa tim model je započeo ažuriranje težinskih odnosa tako da se predviđeni pritisak korigovao, što je dovelo do daljeg smanjenja greške predviđanja, koja do trenutka 2 s konvergira ka nuli.

U slučaju ciklusa kočenja prikazanih na slikama 7.27 i 7.28, koji se odnose na opterećeno stanje vozila, srednja vrednost temperature kočnice na prednjoj osovini je bila 125°C , a na zadnjoj 230°C . U pitanju su kočenja za koje je karakteristično postepeno povećanje pritisaka aktiviranja, kao i njihova promenljivost tokom ciklusa kočenja. Odgovarajuće dinamičke promene stvarnog klizanja se kreću u opsegu 5-45% za točak na prednjoj i 5-23% za točak na zadnjoj osovini (slike 7.27 i 7.28).



*Slika 7.27. Verifikacija predviđanja neuronskog modela – prednja osovina
(pritisak 6 bar, brzina 59 km/h)*

Sličnost sa prethodnim ciklusima (slike 7.25 i 7.26) se ogleda u tome što postoje nagla opadanja stvarnih pritisaka u veoma kratkom vremenskom intervalu, što je posledica naglog prestanka dejstva vozača na komandu sistema za radno kočenje. U slučaju točka na prednjoj osovini, stvarni pritisak naglo opada za 4,5 bar za samo pola sekunde. U tom intervalu podužno klizanje počinje naglo da raste, a zbog pada brzine točka ispod 20 km/h nije došlo do intervencije ABS-a. Imajući u vidu da se okviru seta podataka za obuku mreže modela nalazio određeni broj ciklusa kočenja sa sličnim karakterom promene ulaznih/izlaznih veličina, model je u ovom slučaju uspešno predvideo ovako naglu promenu pritiska na osnovu promene klizanja, temperature i brzine točka (slika 7.27). Greška predviđanja modela u odnosu na stvarni pritisak aktiviranja kočnice dostiže veće vrednosti tokom ciklusa kočenja u trenucima 2,2 s i 3,2 s od početka kočenja, tj. u trenucima gde dolazi do nagle promene ulaznih veličina.

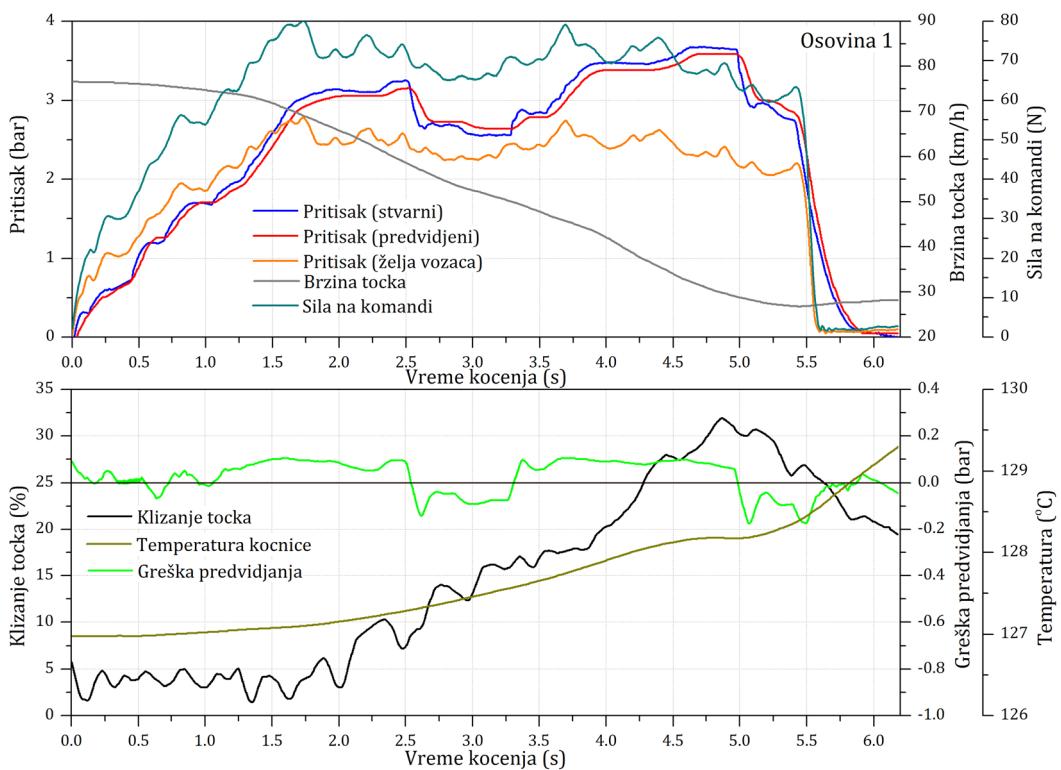


Slika 7.28. Verifikacija predviđanja neuronskog modela – zadnja osovina (pritisak 3,5 bar, brzina 70 km/h)

U slučaju ciklusa sa slike 7.28, koji se odnosi na zadnju osovINU, karakterističan je nagli pad pritiska od 2 bar koji se događa, kao i u prethodnom slučaju, između

3,25-3,75 s vremena kočenja. U ovom slučaju u pitanju je prikočivanje od početne brzine koja iznosi 70 km/h do brzine od 30 km/h. Kao što se vidi sa slike 7.28, maksimalno odstupanje predviđene vrednosti pritiska od stvarne iznosi 0,2 bar u trenutku 3,5 s od početka kočenja. Tokom preostalog dela ciklusa odstupanja predviđenog pritiska su u prihvatljivim granicama.

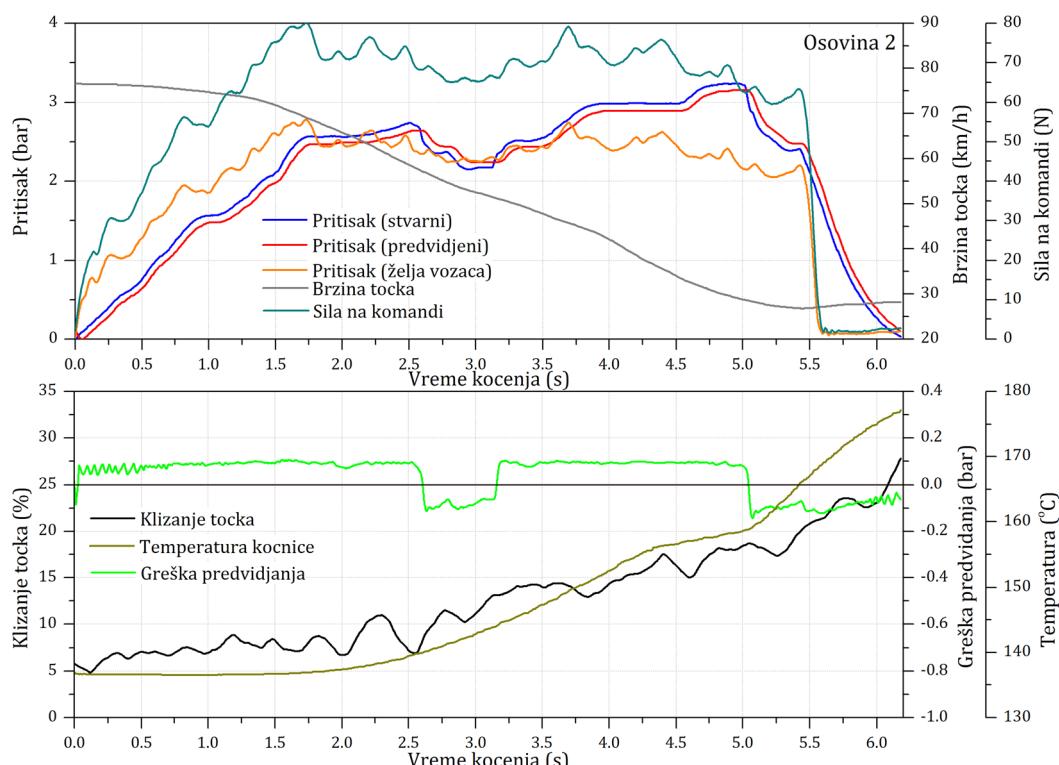
Na slikama 7.29 i 7.30 je ilustrovana verifikacija performansi neuronskih modela za prednju/zadnju osovinu u slučajevima kada su stvarne promene pritisaka aktiviranja kočnica imale nagle (skokovite) promene. U oba slučaja stvarno klizanje se menjalo u intervalu između 0-29%. Srednja vrednost temperature kočnice je iznosila 129°C na prednjoj i 160°C na zadnjoj osovini.



Slika 7.29. Verifikacija predviđanja neuronskog modela – prednja osovina (pritisak 3,2 bar, brzina 75 km/h)

Sa slikama 7.29 i 7.30 se može videti da su odgovarajući modeli predvideli kakva treba da bude promena pritiska aktiviranja kočnice u zavisnosti od promene uslova u kontaktu pneumatik-tlo (stvarnog klizanja), temperature i brzine točka, ali je ipak evidentno da u određenim vremenskim trenucima tokom ciklusa postoje određena odstupanja predviđenih vrednosti pritiska u odnosu na stvarne. To je

posebno uočljivo u intervalu 5-5,5 s kod ciklusa koji se odnosi na prednju kočnicu (slika 7.29) i između 2,6-3,2 s u slučaju ciklusa prikazanog na slici 7.30. U oba slučaja, modeli za prednju/zadnju osovinu su tokom većeg dela ciklusa vršili predviđanje sa trenutno važećom matricom težinskih odnosa, što se vidi na osnovu prikazane greške predviđanja koja ne prelazi granicu od 0,1 bar po absolutnoj vrednosti. To potvrđuje da je model zapamtio zavisnost između ulaznih/izlaznih veličina tokom procesa obuke.



Slika 7.30. Verifikacija predviđanja neuronskog modela – prednja osovina (pritisak 2,7 bar, brzina 75 km/h)

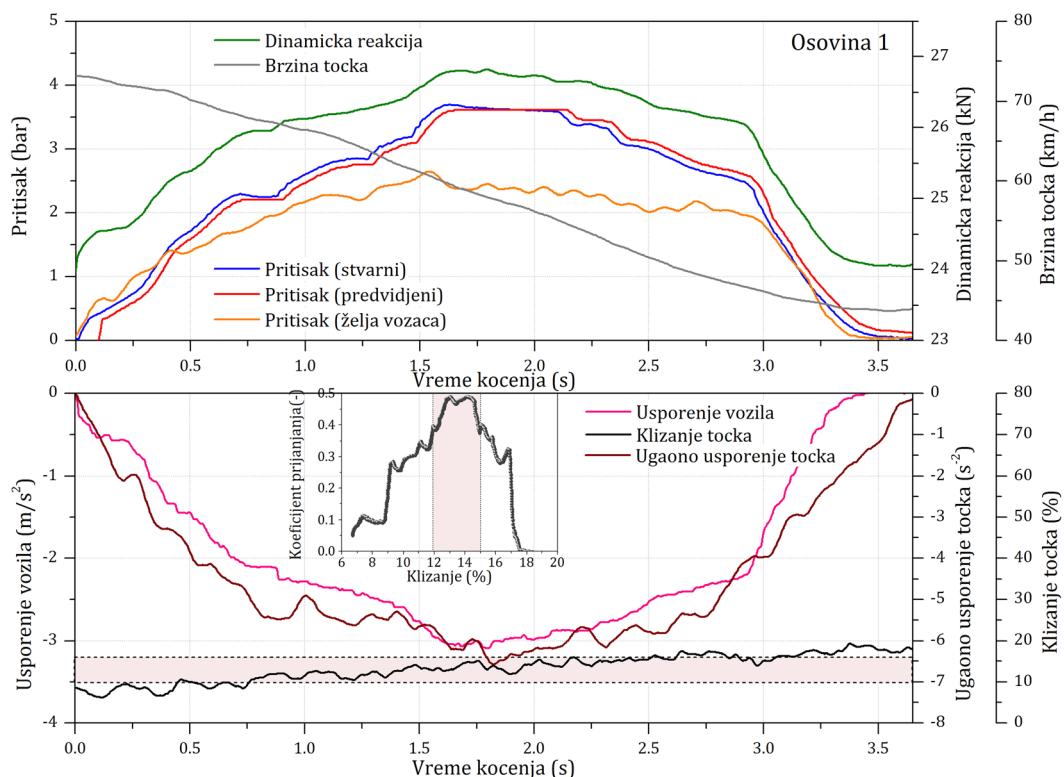
7.4.4. Upravljanje performansama kočnog sistema pomoću neuronskih modela za prednju i zadnju osovinu

Posle verifikacije „performansi“, odnosno kvaliteta predviđanja neuronskih modela, izvršena je analiza mogućnosti da se znanje o modeliranoj funkcionalnoj vezi, koje se nalazi u neuronskim modelima za prednju i zadnju osovinu, iskoristi za upravljanje klizanjem točka u toku ciklusa kočenja. Cilj je „držanje“ klizanja točka u podužnoj ravni na nivou koji odgovara trenutno maksimalnom koeficijentu

prijanjanja (u podužnom pravcu) u kontaktu pneumatika i puta. Izabrano je 12 karakterističnih ciklusa kočenja (šest koji se odnose na neopterećeno i šest koji se odnose na opterećeno stanje vozila), tokom kojih je identifikovana vrednost podužnog klizanja točka pri kojoj se ostvaruje maksimum prijanjanja u podužnom pravcu. Na osnovu toga, razvijeni simulacioni model inteligentnog sistema za kočenje je testiran tako da dinamički podešava pritiske aktiviranja prednjih i zadnjih kočnica na način da se podužno klizanje točkova na prednjoj i zadnjoj osovini upravo održi na nivou koji obezbeđuje maksimalno podužno prijanjanje (kočenje na pravcu). Kvalitet upravljanja pritiskom aktiviranja kočnica je verifikovan na osnovu stvarnog pritiska koji je postignut tokom ispitivanja vozila. Treba napomenuti da je samo u okviru ovih ciklusa kočenja nivo klizanja točkova (pri kočenju na pravcu) održan na nivou koji obezbeđuje maksimalno prijanjanje.

Slike 7.31-7.36 ilustruju rezultate testiranja sistema za intelligentno upravljanje klizanjem točkova na prednjoj i zadnjoj osovini pri neopterećenom stanju vozila. U skladu sa odgovarajućom krivom klizanja, maksimalni koeficijent prijanjanja u podužnom pravcu (ciklus kočenja prikazanog na slici 7.31) je dostupan za vrednosti podužnog klizanja koje se dinamički menjalo u intervalu 12-15%. Dinamički neuronski model, odnosno tako formiran kontroler je testiran da podesi pritisak aktiviranja prednje kočnice kako bi se klizanje održavalo na tom nivou tokom datog ciklusa kočenja. Brzina točka se smanjuje od početne vrednosti od 72 km/h do 43 km/h, dok je srednja maksimalna vrednost temperature prednje kočnice tokom ovog ciklusa iznosila 67°C. Na osnovu rezultata prikazanih na slici 7.31 može se zaključiti da je kontroler dinamički podesio pritisak aktiviranja kočnice na nivo koji obezbeđuje da se klizanje točka drži na željenom nivou. Na osnovu stečenog znanja o funkcionalnoj vezi između pritiska, brzine, temperature i klizanja točka u toku ciklusa kočenja tokom procesa obuke kao i njihovom trenutnom uticaju, model je prvo predvideo dinamičku promenu pritiska kojim bi trebalo aktivirati kočnicu uz istovremeno dodatno obučavanje na osnovu greške predviđanja. Kao što se vidi sa slike 7.31, kontroler je pokazao zadovoljavajući kvalitet predviđanja u zavisnosti od istovremene dinamičke promene pritiska i brzine točka tokom ovog ciklusa kočenja. Na primer, pritisak aktiviranja prednje

kočnice je povećan na 3,8 bar za 1,75 s od početka kočenja gde je prema krivoj klizanja dostignuta maksimalna vrednost koeficijenta prijanjanja. U tom trenutku je takođe dostignuta i maksimalna vrednost usporenja točka. Od trenutka 0,75 s usporenje točka se povećavalo sa manjim gradijentom (brzina točka se smanjivala takođe sa manjim gradijentom) pa je i kontroler tokom sledeće sekunde smanjio gradijent povećanja pritiska aktiviranja kočnice (slika 7.31). Imajući u vidu da je ovde proces dinamičke obuke uključen, promena predviđenog pritiska aktiviranja kočnice je u skladu sa promenom pritiska sa kojim je kočnica stvarno aktivirana.

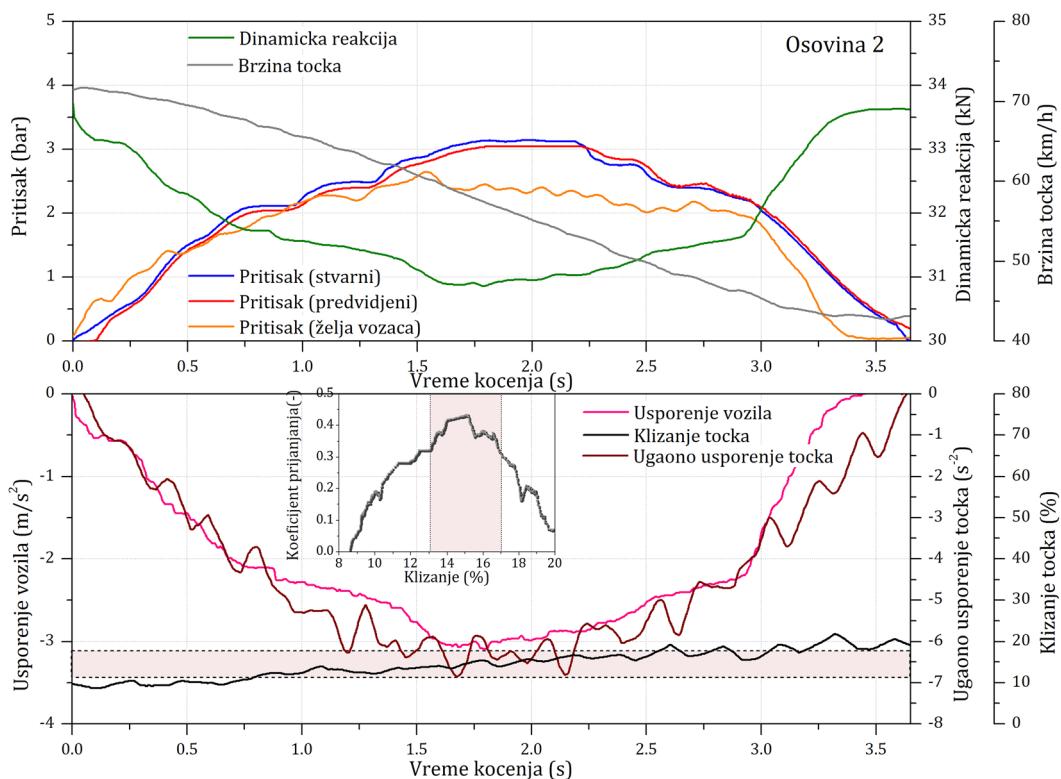


Slika 7.31. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=12-15\%$

Nakon toga, kontroler je tokom sledeće sekunde (do 2,75 s) započeo da smanjuje pritisak aktiviranja sa blažim gradijentom do 2,5 bar jer se ugaono usporenje točka smanjuje, odnosno brzina točka se smanjuje sa manjim gradijentom (slika 7.31). U poređenju sa promenom stvarnog pritiska aktiviranja tokom datog ciklusa, sposobnost kontrolera da inteligentno podesi pritisak aktiviranja u ciklusu kočenja (sa zakašnjnjem) u zavisnosti od toga pri kom

klizanju točka se ostvaruje maksimum koeficijenta prijanjanja, kao i u zavisnosti od željene dinamičke promene klizanja u kontaktu pneumatik-tlo, je zadovoljavajuća.

U slučaju ciklusa kočenja prikazanog na slici 7.32, koji se odnosi na zadnju osovinu, klizanje točka se dinamički menja u intervalu 8-22%, dok se brzina točka smanjuje od 72-43 km/h. Srednja maksimalna vrednost temperature kočnice na zadnjoj osovini tokom ovog ciklusa kočenja je iznosila 79°C. Odgovarajuća kriva klizanja pokazuje da je opseg klizanja u kome je ostvarivo maksimalno prijanjanje u kontaktu pneumatika i tla između 13-17%.

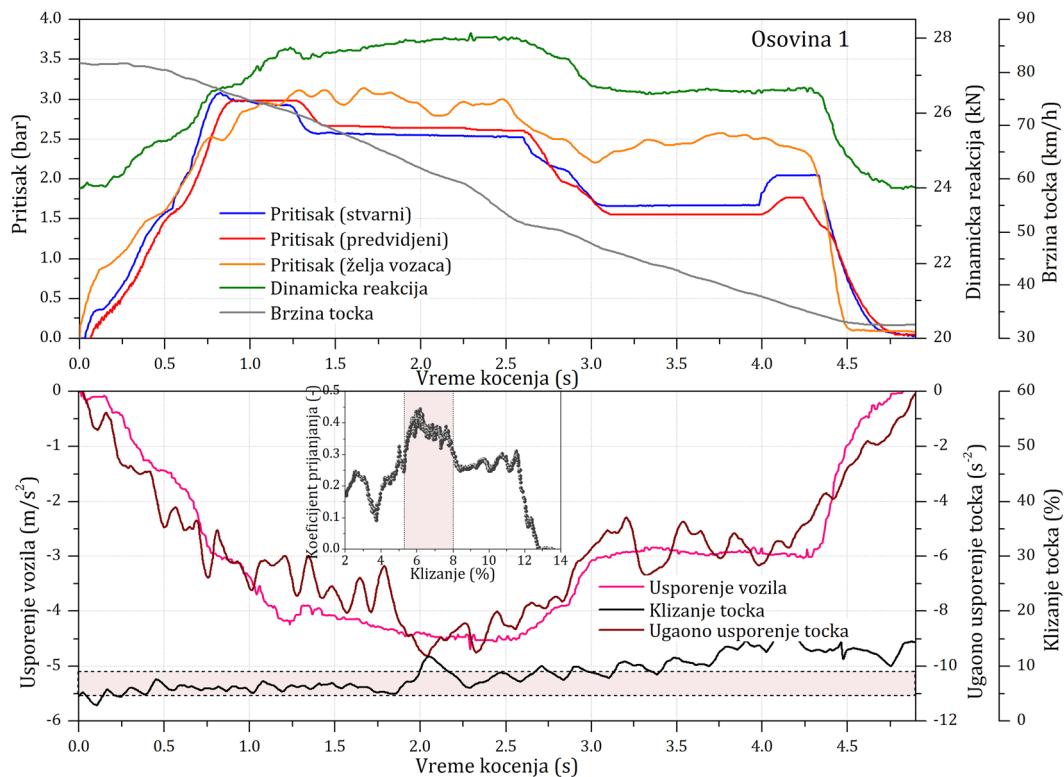


Slika 7.32. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=13-17\%$

Na osnovu ugaonog usporenja točka (slika 7.32) vidi se da je maksimalan potencijal prijanjanja dostignut između 1,5 i 2,25 sekunde od početka kočenja. U prvoj polovini ciklusa kočenja do 1,75 s prijanjanje se blago povećavalo sve do dostizanja maksimuma, pa je kontroler za upravljanje klizanjem točka na zadnjoj osovinu postepeno povećavao pritisak (predviđeni) do maksimalne vrednosti od 3 bar kako bi se što bolje iskoristilo optimalno prijanjanje u kontaktu pneumatika i tla. Imajući u vidu stvarne vrednosti poduznog klizanja, brzine točka i temperature

kočnice model je predvideo ovaj potencijal (u smislu ostvarivanja maksimalnog prijanjanja) i omogućio da kontroler dinamički podesi (poveća) pritisak u ovom delu ciklusa kočenja kako bi klizanje točka bilo zadržano na željenom nivou.

Ako se posmatra ciklus kočenja na slici 7.33, koji se odnosi na točak prednje osovine, klizanje točka se menjalo u intervalu 2-14%. U ovom ciklusu kočenja maksimalno prijanjanje je ostvarivo pri vrednostima klizanja između 5-8%. Brzina točka se menja u intervalu 82-32 km/h, a srednja maksimalna vrednost temperature prednje kočnice je bila 96°C.

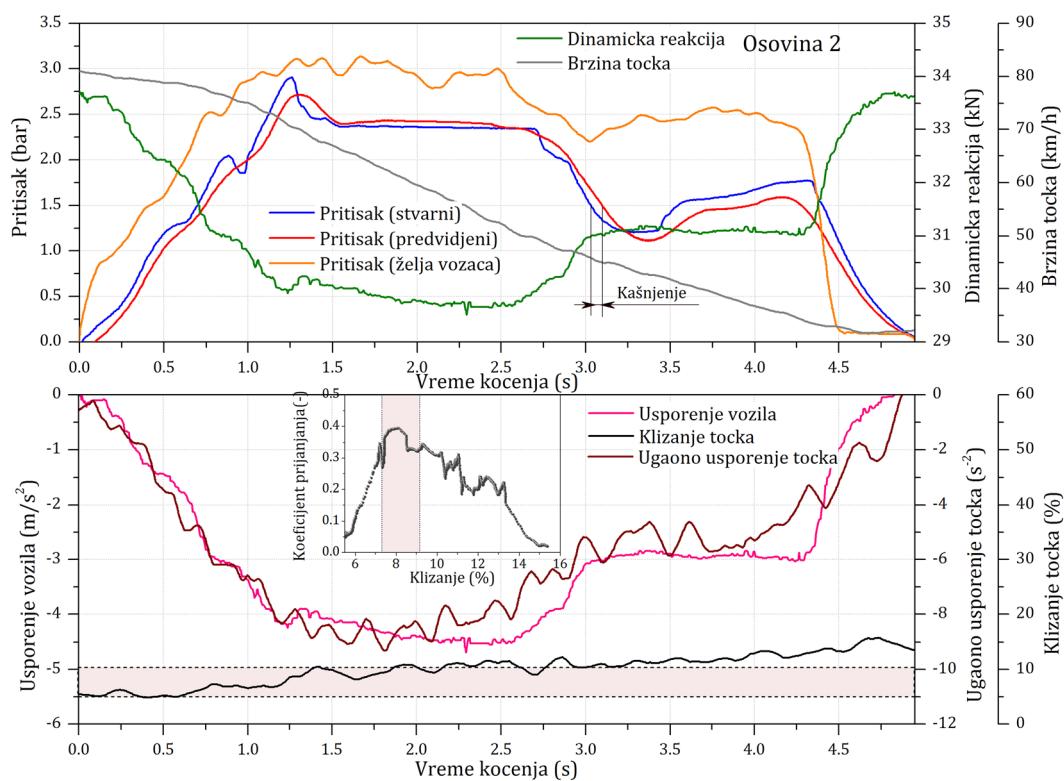


Slika 7.33. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=5-8\%$

Rezultati dinamičkog podešavanja pritiska pomoću modela klizanja za prednju osovinu su prikazani na slici 7.33, gde se vidi da je kvalitet predviđanja modela u zavisnosti od dinamičke promene pritiska i brzine točka na zadovoljavajućem nivou. Dinamički kontroler je predvideo potrebu povećanja pritiska aktiviranja prednje kočnice do 3 bar tokom prve sekunde od početka ciklusa kočenja gde je moguće ostvariti maksimalnu vrednost koeficijenta prijanjanja. Posle tog trenutka, kontroler je predvideo potrebu smanjivanja pritiska na 2,7 bar i uz veoma blagi

pad u toku sledećih 1,5 s smanjio pritisak na 2,6 bar. Od zone maksimalnog ugaonog usporenja točka (između 2-2.5 s) brzina točka počinje da opada sa manjim gradijentom, a u skladu sa tim i ugaono usporenje točka počinje da opada do 3,2 s, pa je kontroler smanjio pritisak na vrednost od 1,7 bar. Posle 3,4 s stvarno klizanje nije više u optimalnoj zoni, pa je kontroler, na osnovu dinamičkog modela, korigovao (smanjio) pritisak u tom intervalu ciklusa da bi se klizanje točka vratilo u zonu gde je moguće postići maksimalno prijanjanje.

Što se tiče podešavanja pritiska aktiviranja kočnice na zadnjoj osovini (slika 7.34) u cilju ostvarenja maksimalnog usporenja po točku, situacija je veoma slična kao u prethodnom ciklusu koji se odnosi na prednju osovINU.

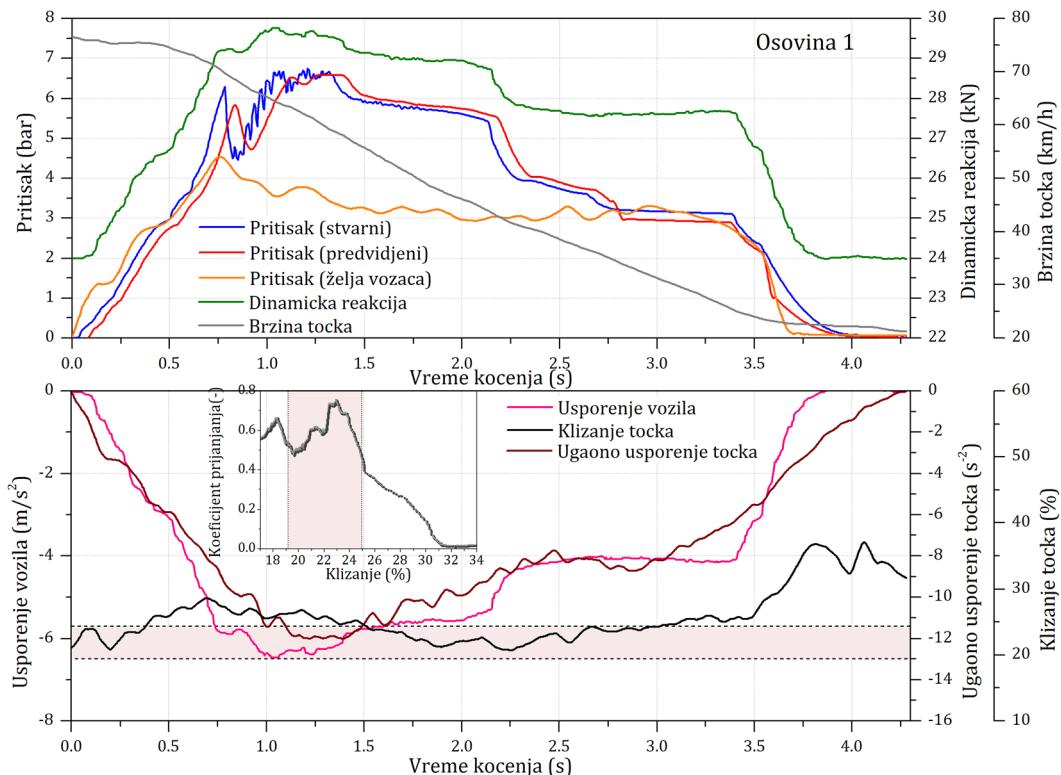


Slika 7.34. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=7-9\%$

U ovom ciklusu dinamička promena klizanja je u okviru intervala 6-16%, pa je opseg klizanja u kome je moguće postići maksimalni koeficijent prijanjanja na nešto višem nivou u odnosu na prethodni slučaj (7-9%, slika 7.34). Brzina točka se smanjuje od 72-43 km/h, a srednja maksimalna vrednost temperature kočnice je 112°C. Model je relativno dobro generalizovao uticaj dinamičkih promena klizanja,

brzine točka i temperature na promenu vrednosti pritiska aktiviranja tokom ovog ciklusa kočenja. U skladu sa razlikama u uslovima prijanjanja u podužnom pravcu na prednjoj i zadnjoj osovini, kontroler je izvršio dinamičko podešavanje pritiska čija je srednja maksimalna vrednost u toku ciklusa manja za 0,5 bar na zadnjoj osovini (slika 7.34). U delu ciklusa kočenja posle 3,2 s kontroler je uskladio (blago smanjio) pritisak aktiviranja kočnice kako bi se klizanje točka vratio u optimalnu zonu. Na osnovu rezultata prikazanih na slikama 7.33 i 7.34, performanse kontrolera za prednju i zadnju osovinu, u smislu inteligentnog podešavanja pritiska aktiviranja u ciklusu kočenja u zavisnosti od željene dinamičke promene klizanja u kontaktu pneumatik-tlo, su na prihvatljivom nivou.

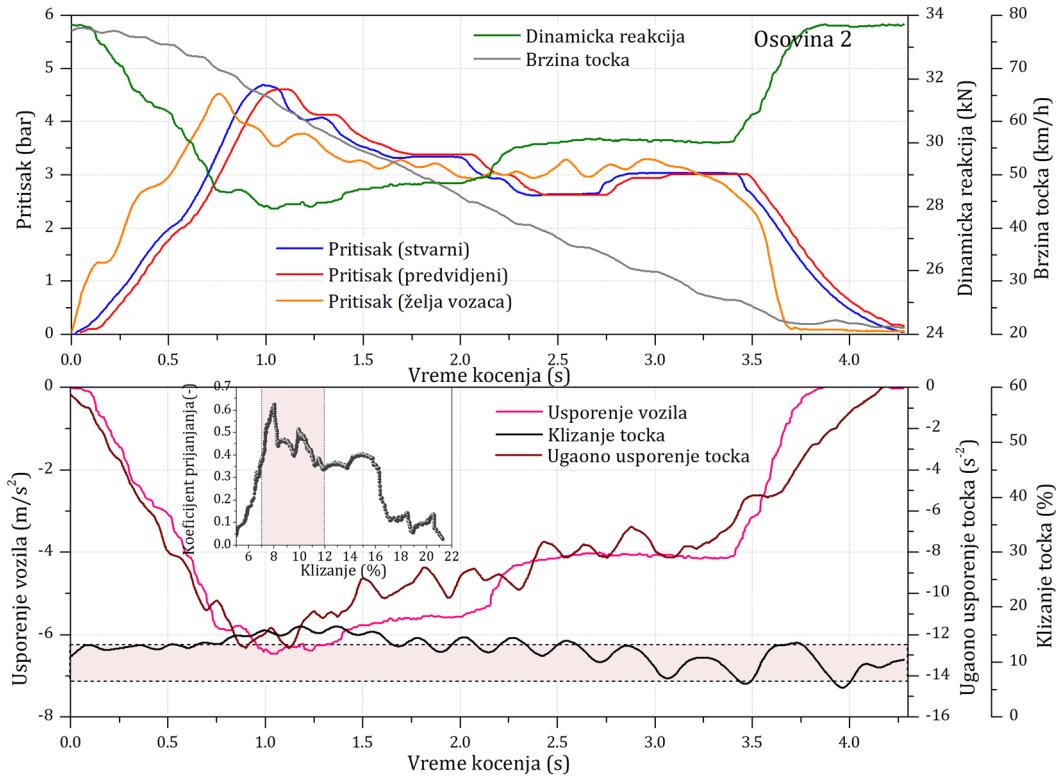
Ciklus prikazan na slici 7.35 se odnosi na prednju osovinu i karakterističan je po tome što je u stvarnim uslovima kočenja došlo do aktiviranja ABS-a između 0,75-1,3 s. Kontroler je testiran da izvrši podešavanje pritiska aktiviranja kočnice tokom ciklusa kočenja u skladu sa datim dinamičkim promenama klizanja točka, temperature kočnice i brzine točka.



Slika 7.35. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=19-25\%$

Na osnovu krive klizanja (slika 7.35), maksimalno prijanjanje u kontaktu prednjeg točka i površine puta je moguće ostvariti pri vrednostima klizanja u opsegu između 19-25%. Srednja maksimalna vrednost temperature tokom ciklusa je viša nego u prethodno analiziranim slučajevima i iznosi 285°C . U toku prvih 0,7 s kočenja, kontroler je predvideo povećanje pritiska od nule na vrednost 5,8 bar. Ako se ova vrednost pritiska uporedi sa vrednošću stvarnog pritiska aktiviranja kočnice (slika 7.35), koja iznosi 6,2 bar, može se uočiti da je kontroler podesio pritisak koji je manji za 0,4 bar. Od tog trenutka (0,7 s) kontroler je započeo da smanjuje pritisak jer je dobio informaciju da je klizanje izašlo iz optimalnog opsega u kome je moguće ostvariti maksimalno prijanjanje. Kontroler je smanjio pritisak tokom narednih 0,2 s do 4,6 bar, a onda je započeo da povećava pritisak da bi se klizanje vratio u optimalnu zonu. Pritisak je zatim povećavan do trenutka 1,1 s na 6,5 bar i dalje održavan na tom nivou trenutka 1,4 s od početka kočenja, imajući u vidu da se klizanje još nalazi u optimalnoj zoni. Kontroler je podesio veći pritisak u tom intervalu ciklusa u skladu sa tom promenom klizanja, ali i sa promenom brzine točka, odnosno njoj analognom promenom intenziteta dinamičke reakcije na prednjem točku (slika 7.35). U tom intervalu brzina točka opada sa manjim gradijentom (povremeno se on povećava) u odnosu na približno konstantno klizanje točka, na osnovu čega je kontroler korigovao pritisak za vrednost koja odgovara toj promeni brzine točka, a u skladu sa zahtevima vozača. Između 3-3,5 s kočenja klizanje je ponovo u optimalnoj zoni pa je kontroler podesio pritisak tako što ga je privremeno zadržao na vrednosti od 3,2 bar, kako bi se iskoristio raspoloživi potencijal za ostvarivanje maksimalne efikasnosti procesa kočenja. Posle 3,5 s od početka kočenja, kontroler je počeo postepeno da smanjuje pritisak aktiviranja kočnice u skladu sa konstantno opadajućom promenom ugaonog usporenja točka, tj. nižim gradijentom smanjenja brzine točka (slika 7.35). Imajući u vidu da se radi o desnom točku vozila, naglo povećanje stvarnog/željenog klizanja (iako se pritisak aktiviranja smanjuje) u ovom intervalu je rezultat prelaska na podlogu sa nižim prijanjanjem tokom kočenja, odnosno prelazak sa suve asfaltne podlove kolovoza na deo kolovoza koji ima dosta prašine i šljunka. Na osnovu informacije o trenutnoj vrednosti tog klizanja, dinamički model je

predvideo da postoji potreba da se pritisak dodatno koriguje u smislu smanjenja u odnosu na stvarni i prema tome uskladio predviđanje kontrolera, slika 7.35.

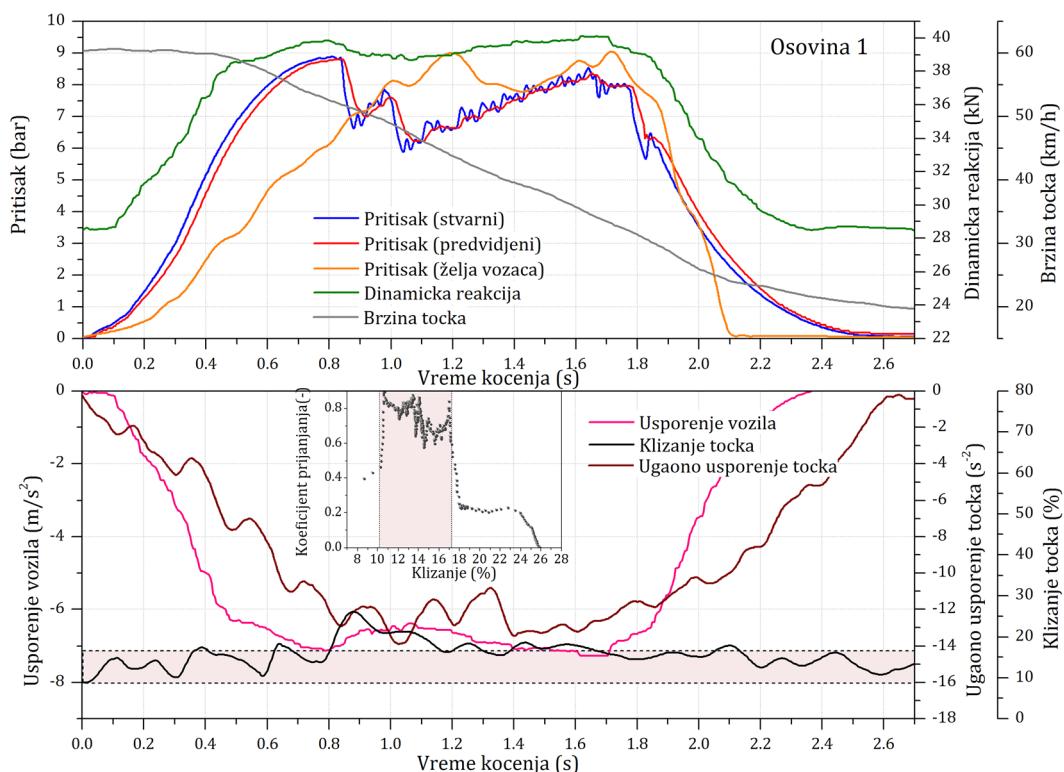


Slika 7.36. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=7-11\%$

Na slici 7.36 je prikazan ciklus kočenja koji se odnosi na zadnju osovinu vozila. Maksimalno prijanjanje u odnosu na dati ciklus se ostvaruje pri vrednostima podužnog klizanja točka između 7-11%. Srednja maksimalna vrednost temperature tokom ciklusa kočenja je 322°C . Kao što se može videti sa slike 7.36, dinamički kontroler je podesio pritisak u skladu sa dinamičkim promenama brzine točka, klizanja i temperature kako bi se ostvarilo željeno klizanje točka, koje svuda osim u segmentu ciklusa između 0,75-1,75 s pripada zoni koja odgovara maksimumu koeficijenta prijanjanja. Maksimalna vrednost pritiska koji zahteva vozač iznosi 4,5 bar. EBS sistem je blaže povećavao pritisak u odnosu na tu promenu i u trenutku 1 s od početka kočenja dostignuta je vrednost stvarnog pritiska aktiviranja kočnice od 4,7 bar. Neuronski kontroler je sa zakašnjnjem od 0,1 s predvideo pritisak koji je u tom trenutku manji za 0,2 bar od stvarnog. Od trenutka 1,75 s pa sve do kraja ciklusa kočenja, predviđeni pritisak je na bliskom

nivou kao i stvarni pritisak aktiviranja kočnice, pri čemu je njegovo maksimalno odstupanje od stvarnog pritiska 0,15 bar u trenutku 2,8 s), slika 7.36.

Na slikama 7.37-7.42 su prikazani rezultati inteligentnog upravljanja performansama kočnica na prednjoj i zadnjoj osovini u cilju postizanja maksimalnog usporenja, odnosno održanja klizanja točkova na nivou koji obezbeđuje maksimalno prijanjanje pri opterećenom stanju vozila. U ciklusu sa slike 7.37 zona optimalnog klizanja je između 10-17%. Srednja maksimalna vrednost temperature u toku ciklusa kočenja je 136°C . Maksimalna vrednost pritiska od 9 bar koju zahteva vozač je dostignuta u trenutku 1,2 s.

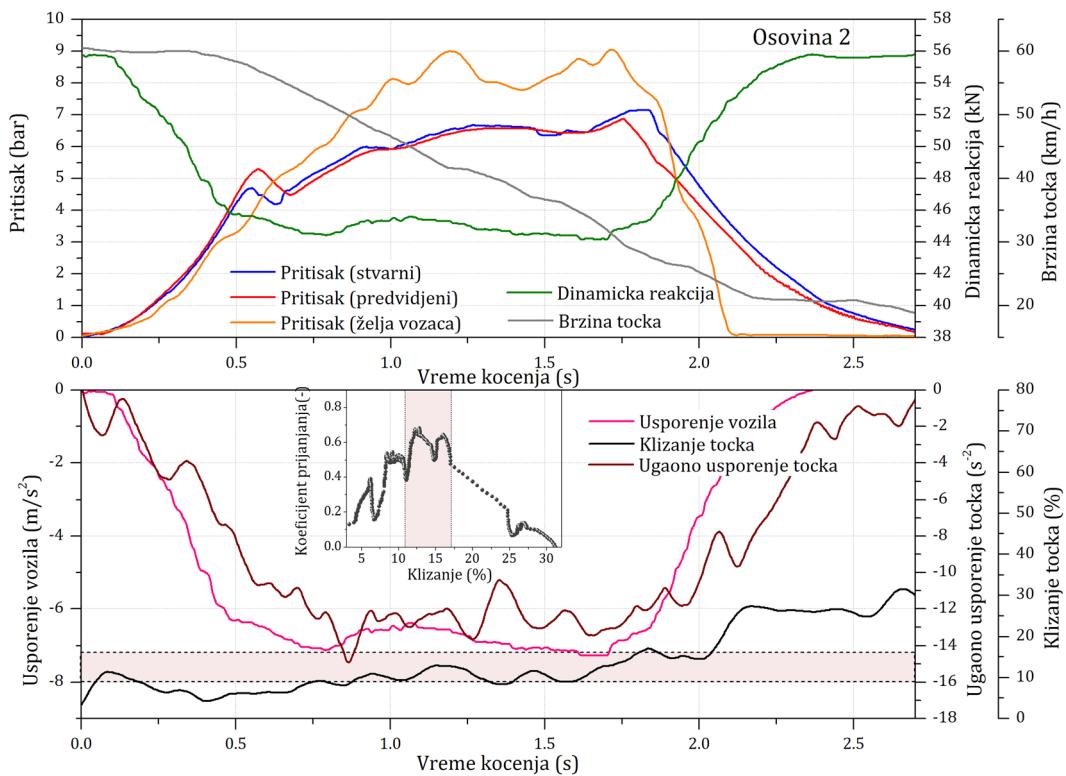


Slika 7.37. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=10-17\%$

EBS sistem je povećao pritisak od nule sa većim gradijentom porasta do maksimalne vrednosti u toku ciklusa od 8,9 bar za 0,8 s. Posledica toga je i povećanje klizanja prednjeg točka do maksimalne vrednosti od 27%, što je izazvalo aktiviranje ABS-a. Kontroler je sa zakašnjenjem od 0,1 s, u skladu sa promenama stvarnog klizanja (koje je ujedno i željeno) i ugaonog usporenja/brzine točka, predvideo da pritisak aktiviranja kočnice treba da ima ovakvo povećanje tokom

prvih 0,8 s ciklusa kočenja, slika 7.37. Zbog smanjenja ugaonog usporenja točka, odnosno opadanja brzine točka sa manjim gradijentom, kontroler je nadalje smanjio pritisak, prvo na 7, a zatim na 6,2 bar, a onda ga je zatim ponovo povećao na 8,2 bar imajući u vidu da se ugaono usporenje točka između 1,3-1,7 s ponovo povećalo, a sve u cilju zadržavanja klizanja na željenom nivou. Pritisak koji zahteva vozač do kraja ciklusa počinje da se smanjuje, a takođe i stvarni pritisak aktiviranja kočnice. U skladu sa tim klizanje točka blago opada, a ugaono usporenje se smanjuje pa je kontroler izvršio postepeno smanjenje pritiska do nule, koji veoma malo odstupa u odnosu na stvarni pritisak (slika 7.37).

U ciklusu koji se odnosi na zadnju osovinu (slika 7.38) klizanje pri kome je moguće ostvariti maksimalno prijanjanje se kreće u opsegu 10-16%. Srednja maksimalna vrednost temperature tokom ciklusa iznosi 158°C.



Slika 7.38. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=10-16\%$

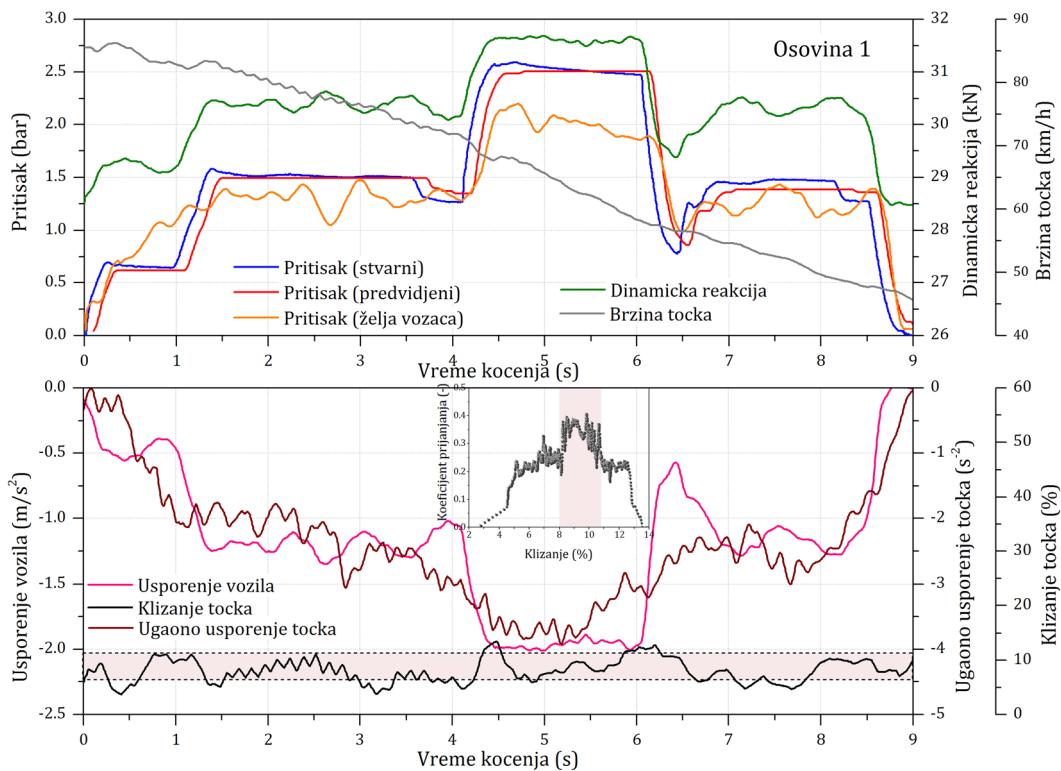
Ciklusi prikazani na slikama 7.37 i 7.38 predstavljaju dobru ilustraciju različito moguće zone optimalnog klizanja u kontaktu točkova prednje i zadnje osovine tokom kočenja. Pored uticaja vrste i stanja istrošenosti pneumatika, kao i vrste i

stanja podloge na kojoj vozilo koči, značajan uticaj na to ima i preraspodela vertikalnog opterećenja između osovina. To se može utvrditi i analizom krivih klizanja sa slika 7.37 i 7.38. Zbog toga je bilo potrebno razviti sistem intelligentnog upravljanja koji će istovremeno upravljati klizanjem i na prednjoj i na zadnjoj osovini, što bi trebalo dalje da stvori uslove za optimizaciju raspodele sila kočenja na prednjoj i zadnjoj osovini.

Sa slike 7.38 se vidi da je model prepoznao da je klizanje u kontaktu zadnjeg točka i puta u intervalu 0,2-0,8 s kočenja manje od optimalnog gde prijanjanje ima maksimum. U skladu sa tim dinamički kontroler je predvideo blago povećanje pritiska u odnosu na stvarni pritisak aktiviranja kočnice na zadnjoj osovini za isti taj interval kočenja. Od 0,8-1,8 s kočenja kontroler je podešavao pritisak u skladu sa uspostavljenom funkcionalnom zavisnošću između pritiska, klizanja, brzine i temperature u toku ciklusa kočenja. U tom intervalu klizanje je u optimalnim granicama pa je kontroler postepeno povećao pritisak da bi se iskoristilo maksimalno prijanjanje u kontaktu pneumatika i puta, a sve to u skladu sa promenom pritiska koji zahteva vozač i ugaonog usporenja zadnjeg točka, odnosno brzine točka koja mu je saopštена na ulazu. Klizanje točka do kraja ciklusa raste, a ugaono usporenje počinje naglo da opada pa je kontroler posle 1,8 s (sa zakašnjenjem od 0,1 s) postepeno smanjio pritisak do nule u poređenju sa stvarnim pritiskom (slika 7.38), a sve to u cilju da se klizanje vrati u optimalan opseg.

U slučaju ciklusa kočenja prikazanog na slici 7.39, obavljenog pri opterećenom stanju vozila, klizanje točka se dinamički menja u granicama 2-14%, dok se brzina točka smanjila za 38 km/h od početka do kraja kočenja. Prema odgovarajućoj krivoj klizanja (slika 7.39) klizanje točka pri kome je prijanjanje maksimizirano je u granicama 8-11%. Maksimalno prijanjanje je dostignuto između 4,3-6 s od početka ciklusa kočenja. U trenutku 4,3 s kočenja, posledica naglog povećanja sile na komandi sistema za radno kočenje (pritisaka koji zahteva vozač), a samim tim i povećanja stvarnog pritiska aktiviranja kočnice, je i povećanje klizanja za 5%. Zbog toga je sistem za intelligentno upravljanje povećao pritisak sa 1,3 bar na 2,5 bar kako bi se dosegla gornja granica optimalnog prijanjanja u kontaktu pneumatik-tlo

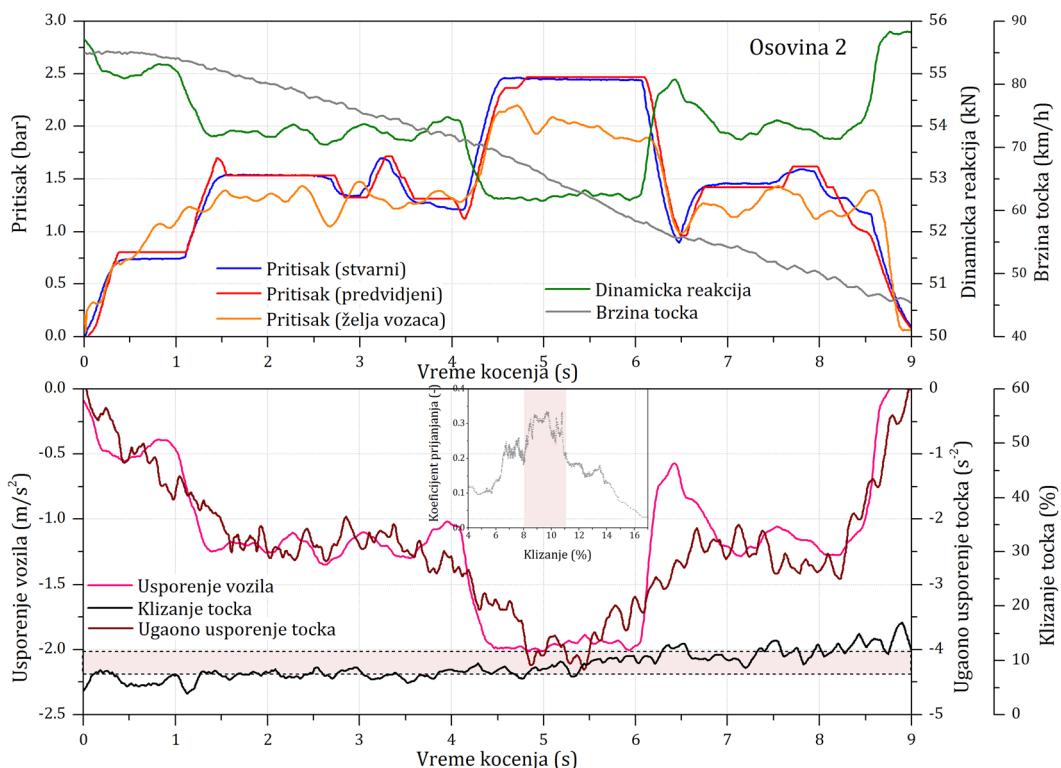
(slika 7.39). U trenutku 6,2 s pritisak koji zahteva vozač je naglo opao na 1 bar pa je i predikcija kontrolera bila usklađena sa time. Nakon toga, ugaono usporenje točka počinje da se povećava što je rezultat povećanja pritiska koji zahteva vozač/stvarnog pritiska aktiviranja kočnice. U skladu sa tim, došlo je do povećanja pritiska aktiviranja kočnice, u vremenu kočenja između 6,6-8,6 s, na 1,3 bar (slika 7.39) jer je predviđena vrednost pritiska aktiviranja kočnice usklađena sa željenim opsegom podužnog klizanja točka. Srednja maksimalna vrednost temperature u toku ovog ciklusa iznosi 343°C .



Slika 7.39. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=8-11\%$

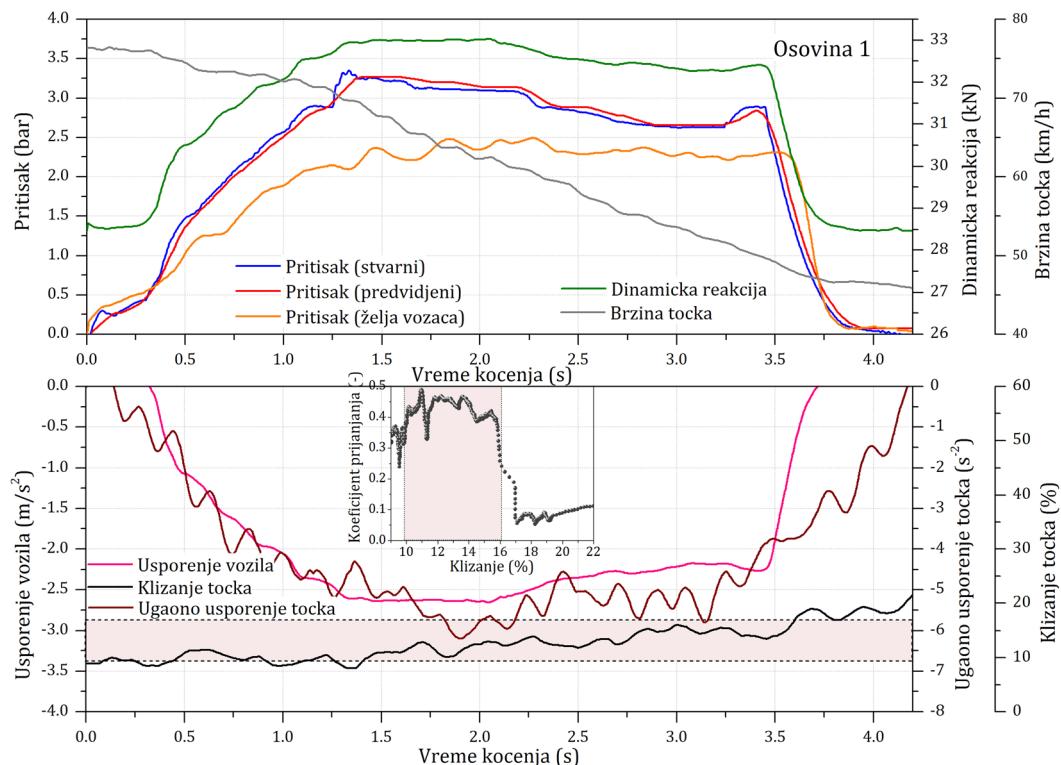
Podešavanje pritiska od strane kontrolera za zadnju osovINU tokom ciklusa prikazanog na slici 7.40 je veoma slično, imajući u vidu da su i promene brzina točkova, odnosno ugaonihs usporenja točkova na prednjoj i zadnjoj osovinii takođe slične. Kao što se vidi sa slike 7.40 i ovaj ciklus karakterišu nagle (skokovite) promene pritiska koji zahteva vozač, odnosno stvarnog pritiska aktiviranja kočnice. Osim toga, optimalna zona klizanja, odnosno opseg klizanja u kome je prijanjanje maksimalno je isti kao u prethodno razmatranom ciklusu (8-11%). Srednja

maksimalna vrednost temperature kočnice u ovom slučaju je viša nego kod kočnice na prednjoj osovini i iznosi 387°C . Povećanje pritiska koji zahteva vozač, odnosno povećanje stvarnog pritiska aktiviranja kočnice u trenutku 4,3 s je u ovom slučaju dovelo do povećanja klizanja za 4%. U skladu sa tim je i kontroler povećao pritisak sa 1,1 bar na 2,25 bar kako bi se postiglo optimalno prijanjanje u kontaktu pneumatik-tlo. Tokom naredne 2 s pritisak koji zahteva vozač je blago opadao, a zatim je u trenutku 6,2 s naglo opao na 0,8 bar. Dinamički kontroler je prepoznao odgovarajuću promenu klizanja, odnosno brzine/usporenja točka i uskladio predviđanje pritiska da bi se ostvarilo željeno klizanje. Posle 6,5 s, kao posledica povećanja pritiska koji zahteva vozač, odnosno stvarnog pritiska aktiviranja kočnice, ugaono usporenje točka počinje da se povećava do 8,1 s. Shodno tome, pritisak aktiviranja kočnice se povećao u intervalu ciklusa kočenja između 6,6-8,6 s na 1,2 bar. Na slici 7.40 se vidi da je ta predviđena vrednost pritiska aktiviranja kočnice manja u odnosu na stvarni pritisak jer je usklađena sa opsegom klizanja točka u kome je moguće ostvariti maksimalno prijanjanje.



Slika 7.40. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=8-11\%$

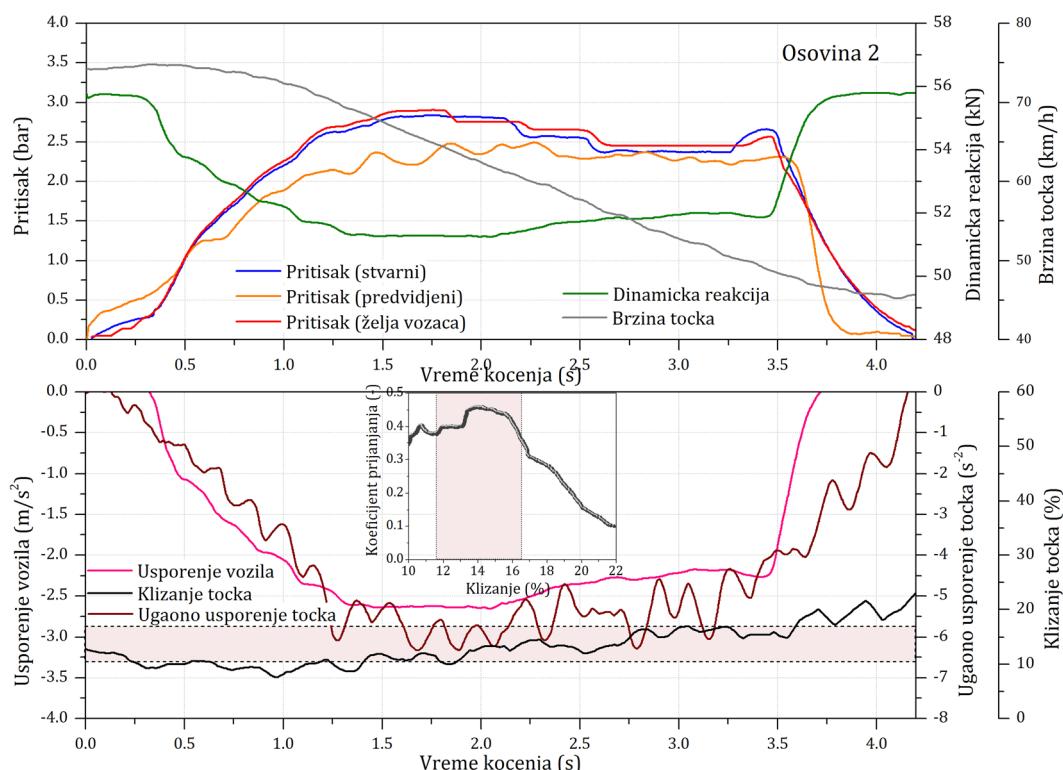
Neuronski modeli za upravljanje performansama kočnica na prednjoj i zadnjoj osovini su pokazali slične „performanse“ predviđanja tokom testiranja sa ciklusima kočenja prikazanim na slikama 7.41 i 7.42. U slučaju ciklusa kočenja prikazanog na slici 7.41, klizanje pri kome prijanjanje dostiže maksimum je u granicama 10-16%, dok se u slučaju ciklusa sa slike 7.42 ovaj optimalni opseg skoro poklapa, odnosno iznosi 11-16%. U slučaju prednje kočnice (slika 7.41), srednja maksimalna temperatura iznosi 382°C , dok temperatura zadnje kočnice (slika 7.42) iznosi 403°C . Kao i u prethodno analiziranim slučajevima i rezultati dinamičkog podešavanja pritiska prikazani na slikama 7.41 i 7.42 pokazuju da je kvalitet predviđanja modela klizanja prednje/zadnje osovine, u zavisnosti od dinamičkih promena klizanja i brzine točka, na zadovoljavajućem nivou.



Slika 7.41. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=10-16\%$

Kao što se vidi sa slikama 7.41 i 7.42, najveću grešku predviđanja dinamički kontroler je imao u trenucima nagle promene pritiska koji zahteva vozač/stvarnog pritiska, odnosno promene ugaonog usporenja točka i klizanja u kontaktu pneumatik-tlo. U slučaju točka na prednjoj osovini, kontroler je sa zakašnjnjem od

0,1 s u trenutku 1,25 s predvideo pritisak veći za 0,2 bar u odnosu na stvarni da bio se dosegao opseg klizanja u kome je prijanjanje maksimalno. Posle 3,5 s pa do kraja ciklusa kontroler je blago smanjio pritisak u odnosu na stvarni u proseku za 0,1 bar. Ako se posmatra predviđeni pritisak u slučaju ciklusa koji se odnosi na zadnju osovinu (slika 7.42), to je takođe slučaj sa delom ciklusa kočenja posle 3,6 s pa sve do kraja pri čemu je kontroler dodatno smanjio pritisak za 0,1 bar da bi se klizanje dovelo u željeni opseg.



Slika 7.42. Uporedni prikaz predviđenog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=11,5-16,5\%$

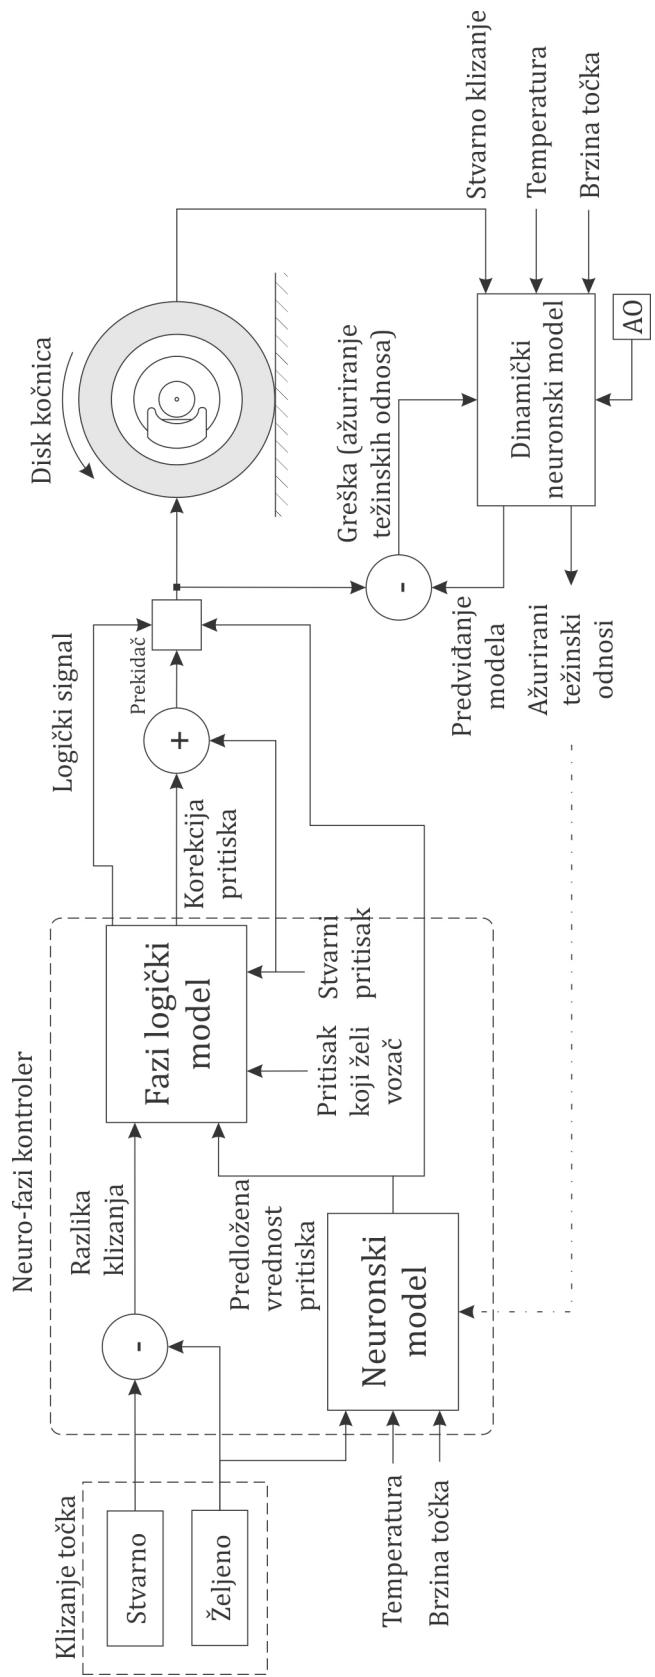
7.5. INTELIGENTNO UPRAVLJANJE PERFORMANSAMA KOČNICE POMOĆU KOMBINOVANOG NEURO-FAZI PRISTUPA

Uvođenje fazi logičkog pristupa kao podrške upravljanju klizanjem točka pomoću dinamičkih veštačkih neuronskih mreža izvršeno je radi unapređenja rada budućeg intelligentnog kočnog sistema u slučajevima kada dođe do grešaka u predviđanju inverznog neuronskog modela, odnosno do potrebe dodatnog korigovanja trenutnog (stvarnog) pritiska aktiviranja kočnica. U skladu sa tim, kao dodatna komponenta sistema za upravljanje klizanjem uveden je hibridni model, odnosno neuro-fazi kontroler. Fazi logički kontroler (FLC), kao deo intelligentnog sistema za upravljanje performansama kočnog sistema, ima funkciju praćenja razlike između stvarnog pritiska aktiviranja kočnica, željenog pritiska određenog od strane vozača i predviđenog pritiska pomoću inverznog neuronskog modela performansi kočnice. Na osnovu poznavanja ove razlike budući intelligentni kočni sistem će moći da odlučuje o potrebi dodatne korekcije predviđenog pritiska od strane dinamičkog inverznog neuronskog modela kako bi se klizanje u kontaktu pneumatik-tlo dovelo na željeni nivo. Odluku o tome donosi na osnovu trenutnih vrednosti ulaznih parametara (razlike između željenog i stvarnog klizanja, trenutnih vrednosti stvarnog pritiska aktiviranja, pritiska koji zahteva vozač i vrednosti pritiska koju predlaže neuronski model). Uvođenje fazi logike ima za cilj da se pruži ekspertska podrška radu dinamičkog neuronskog modela, odnosno obezbedi redundantna funkcija intelligentnog sistema za upravljanje performansama kočnog sistema. Ovo je važno u trenucima kada sistem radi sa neprihvatljivo visokom greškom predviđanja, tj. kada je predviđena vrednost pritiska aktiviranja kočnice od strane inverznog dinamičkog neuronskog modela nerealna i/ili neodgovarajuća u odnosu na želju vozača i/ili stvarnu vrednost pritiska aktiviranja kočnice u tom trenutku. S obzirom da vozila, pa time i kočni sistem radi u vrlo širokom opsegu promene ne samo radnih režima kočnica, već i uslova prijanjanja između točka i puta (različite vrste puta, promenljivi vremenski uslovi, različiti tipovi i stanja pneumatika, različita stanja i performanse disk kočnica, itd.), nije realno očekivati da će neuronski model moći da nauči u kratkom vremenskom periodu ovako različita stanja u kojima se može naći kočni sistem i da

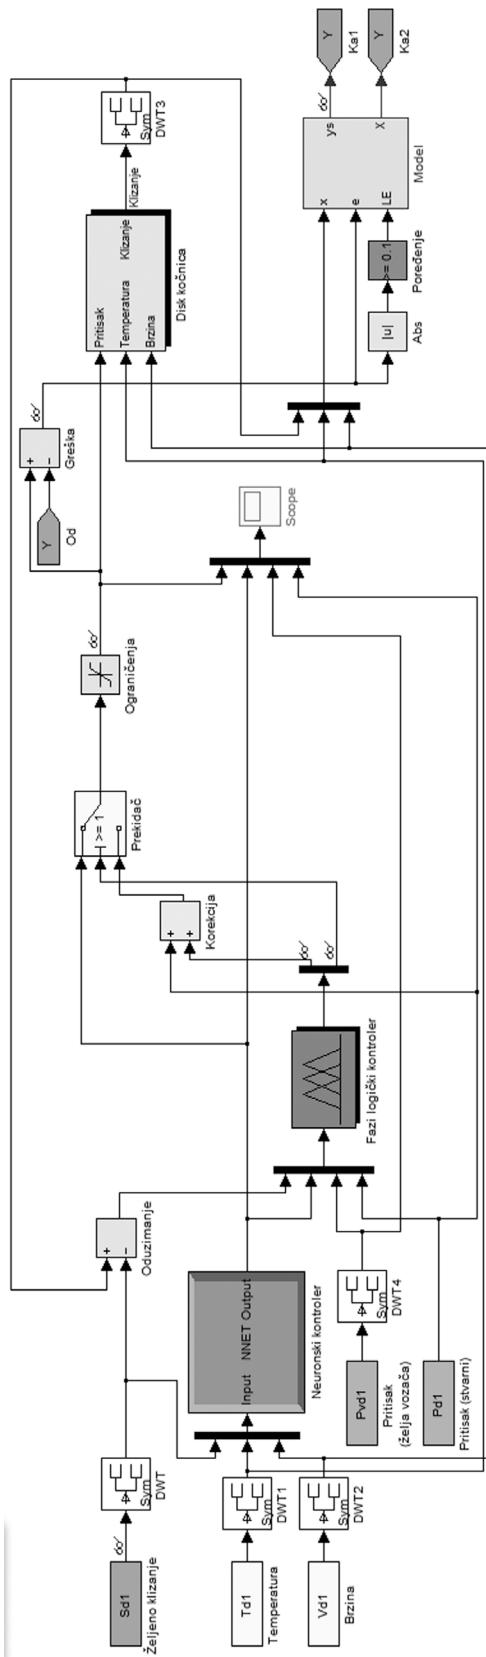
može dovoljno kvalitetno da prilagodi performanse kočnog sistema novim, različitim, stanjima puta/režimima kočenja. Koncept sistema intelligentnog upravljanja, zasnovan na upravljanju klizanjem u kontaktu pneumatika i tla pomoću kombinovanog neuro-fazi pristupa, je predstavljen pomoću blok dijagrama na slici 7.43. Osnovne komponente sistema za upravljanje klizanjem točka su u tom slučaju:

1. Inverzni dinamički model procesa kočenja za prednju i zadnju osovinu.
2. Dinamički neuronski kontroler za prednju i zadnju osovinu dobijen na bazi inverznog neuronskog modela performansi kočnica.
3. Fazi logički model (integriran u neuro-fazi kontroler).
4. Model točka (model četvrtine vozila) sa pneumatički aktiviranom disk kočnicom privrednih vozila.
5. Mehanizam za ažuriranje težinskih odnosa model-kontroler.

U skladu sa time, na slici 7.44 je prikazan odgovarajući dijagram sistema za upravljanje formiran u radnom okruženju programskog paketa Matlab/Simulink.



Slika 7.43. Konfiguracija za upravljanje klizanjem točka pomoću neuro-fazi pristupa



Slika 7.44. Konfiguracija sistema u radnom okruženju Simulink-a

Kao što se može zaključiti sa slike 7.43, konfiguracija sistema intelligentnog upravljanja klizanjem točka u pogledu komponenata sistema, koje zasnivaju rad na veštačkim neuronским mrežama, je ista kao konfiguracija razmatrana u poglavljiju 7.4 (slika 7.16). Zbog toga u ovom delu rada neće biti ponavljana analiza funkcionisanja dinamičkog neuronskog modela za prednju i zadnju osovinu, pa će celokupna pažnja biti usmerena na integriranu funkciju neuro-fazi kontrolera. Pomoću pomoćnih elemenata za procesiranje signala u okviru Simulink paketa, na osnovu željene vrednosti klizanja u kontaktu pneumatik-tlo vrši se izračunavanje koliko ta vrednost odstupa od trenutne vrednosti stvarnog klizanja (razlika između klizanja). Istovremeno, neuronski model, u okviru neuronskog dela neuro-fazi kontrolera, na osnovu vrednosti željenog klizanja, temperature kočnice i brzine točka na ulazu, predviđa vrednost pritiska kojim bi trebalo aktivirati kočnicu da bi se ostvarilo to željeno klizanje. Paralelno sa time, neuronski model u okviru kontrolera dobija ažurne vrednosti težinskih odnosa od inverznog neuronskog modela koji se obučava u realnom vremenu na osnovu trenutnih i prošlih vrednosti stvarnog klizanja, temperature kočnice, translatorne brzine točka i greške između pritiska koji on predviđa na izlazu i trenutne vrednosti pritiska aktiviranja kočnice. Fazi logički deo kontrolera za trenutne vrednosti razlike između željenog i stvarnog klizanja, trenutne razlike između vrednosti stvarnog pritiska aktiviranja, pritiska koji zahteva vozač i predviđenog pritiska od strane neuronskog dela neuro-fazi kontrolera na ulazu, donosi odluku o tome sa kojim pritiskom će kočnica biti aktivirana. U zavisnosti od toga kakav je odnos između stvarnog pritiska, pritiska koji zahteva vozač i pritiska koji predviđa neuronski deo kontrolera, fazi deo kontrolera, u skladu sa definisanim fazi logičkim pravilima, odlučuje o tome sa kojim pritiskom će biti aktivirana kočnica. Kočnica može biti aktivirana pritiskom koji zahteva vozač ili će se dozvoliti da se aktivira trenutnom stvarnom vrednošću pritiska ili će biti aktivirana predviđenim pritiskom od strane neuronskog kontrolera. Ukoliko ni jedan od ova tri pritiska ne obezbeđuju željeno klizanje u kontaktu pneumatik-tlo, fazi logički deo neuro-fazi kontrolera će omogućiti korekciju trenutne stvarne vrednosti pritiska aktiviranja kočnice (smanjenje ili povećanje stvarnog trenutnog pritiska aktiviranja kočnice, u skladu

sa uspostavljenim „ako-onda“ pravilima). Treba napomenuti da se u ovakvoj konfiguraciji (neuro-fazi) sistema ukupno kašnjenje trenutne vrednosti korigovanog pritiska u odnosu na trenutnu vrednost stvarnog pritiska dobija kao zbir kašnjenja neuronskog modela (0,015 s), filtriranja signala pomoću diskretne vejljet transformacije (0,025 s), fazi logičkog modela (0,02 s) i rada prekidača (0,001 s), pa prema tome iznosi 0,061 s.

U skladu sa konfiguracijom inteligentnog upravljanja sa slike 7.43, fazi logički deo kontrolera ima četiri ulaza i dva izlaza. Prvi ulaz se odnosi na razliku između željene i stvarne vrednosti klizanja točka, dok se ostala tri ulaza odnose na pritiske (pritisak predložen od strane neuronskog kontrolera, pritisak koji zahteva vozač dejstvom na komandu sistema za radno kočenje i pritisak sa kojim je kočnica stvarno aktivirana u prethodno posmatranom trenutku, tj. trenutna vrednost pritiska u kočnim cilindrima na prednjoj/zadnjoj osovini). Prvi izlaz iz fazi logičkog dela kontrolera se odnosi na eventualnu korekciju stvarnog pritiska aktiviranja kočnice. Drugi izlaz predstavlja logički (Bulov) signal, koji može biti jednak 0 ili 1 i služi za upravljanje prekidačem koji ima funkciju selekcije da li će se kočnica aktivirati pritiskom koji predlaže neuronski deo kontrolera ili sa korigovanim stvarnim pritiskom. Prema utvrđenim fazi logičkim pravilima, ukoliko je potrebno da se kočnica aktivira direktno sa pritiskom koji je predložio neuronski deo kontrolera (u slučaju da je on odgovarajući), FLC na izlaz šalje logički signal jednak 1, što dakle signalizira prekidaču da dalje propusti signal o pritisku koji predlaže neuronski deo kontrolera. U obrnutom slučaju, ako su aktivirana pravila na osnovu kojih će fazi logički deo kontrolera „zaključiti“ da je vrednost pritiska koji predlaže neuronski deo kontrolera neodgovarajuća (previše velika, previše mala), logički signal je tada jednak 0 pa prekidač dalje propušta korigovanu vrednost stvarnog pritiska. Fazi logički deo kontrolera neprekidno nadgleda ulazne veličine i donosi odluku o vrednosti korekcije stvarnog pritiska (koliki treba da bude njen intenzitet i da li treba da bude pozitivna ili negativna). U opštem slučaju, razlika između vrednosti klizanja određuje da li treba povećati ili smanjiti pritisak aktiviranja kočnice, dok sve četiri ulazne veličine zajedno (i pritisci i razlika klizanja) definišu kolika treba da bude vrednost korekcije pritiska na izlazu, ako je to potrebno.

Ukoliko je razlika između željenog i stvarnog klizanja točka jednaka nuli, u tom slučaju je i korekcija pritiska na izlazu jednaka nuli. To znači da je željeno klizanje jednakost stvarnom pa je dakle kočnicu potrebno aktivirati sa vrednošću trenutnog (stvarnog) pritiska, tj. nije potrebno vršiti nikakvu korekciju.

Na osnovu prikazane konfiguracije sistema inteligentnog upravljanja može se zaključiti da su njegove inteligentne sposobnosti obezbeđene pomoću dinamičkog neuronskog dela kontrolera, a da fazi deo kontrolera vrši neophodne korekcije u situacijama kada je to potrebno. To znači da sistem može da vrši inteligentnu selekciju između pritisaka koje predlaže neuronski deo kontrolera (dinamički neuronski model), pritiska koji zahteva vozač i trenutne (stvarne) vrednosti pritiska, odnosno može da koriguje stvarni pritisak u toku ciklusa kočenja. Sa dobro obučenim dinamičkim neuronskim modelom u celokupnom radnom opsegu, kočnica bi tada mogla biti aktivirana sa pritiskom koji obezbeđuje željenu vrednost klizanja točka, umesto čisto adaptivne konvergencije koju vrši fazi logički kontroler kada radi sam u sistemu.

7.5.1. Razvoj fazi logičke podrške

Fazi logički kontroler, koji je kombinovan sa dinamičkim neuronskim kontrolerom obrazujući hibridni, neuro-fazi, sistem za inteligenntno upravljanje performansama kočnice je razvijen na osnovu Mamdanijeve metode zaključivanja i odgovarajućih fazi logičkih „ako-onda“ pravila. Funkcije pripadanja i „ako-onda“ pravila, koja se odnose na razvijeni fazi logički kontroler, su formirani na osnovu karakteristika ulaznih/izlaznih promenljivih. Kako je to objašnjeno u poglavljju 6, funkcija pripadanja određuje stepen pripadnosti nekog elementa u okviru fazi skupa na taj način što vrši mapiranje elemenata iz svog domena u numeričke vrednosti koje pripadaju intervalu [0,1]. Taj postupak je poznat kao fazifikacija. Fazifikovana vrednost 0, odnosno funkcija pripadanja sa vrednošću 0 označava da odgovarajući element definitivno nije član datog fazi skupa, dok vrednost 1 označava da element u potpunosti pripada fazi skupu.

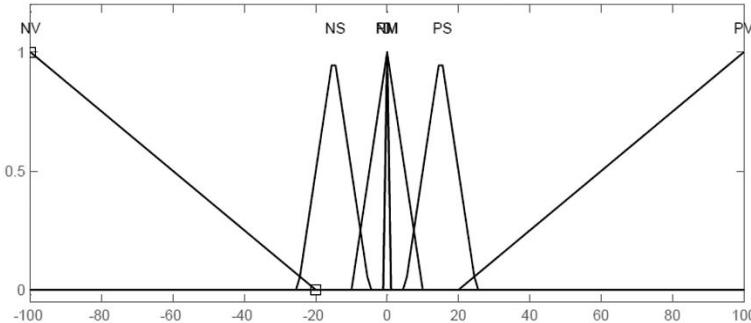
Slike 7.45 i 7.46 prikazuju dva seta funkcija pripadanja za ulazne promenljive – prvi se odnosi na razliku klizanja (slika 7.45), a drugi na vrednosti pritisaka (predviđenih od strane neuronskog dela kontrolera, stvarni pritisak i pritisak koji zahteva vozač delujući na komandu sistema za radno kočenje, slika 7.46). Prvi set sadrži sedam lingvističkih promenljivih, odnosno funkcija pripadanja koje pokrivaju opseg mogućih vrednosti koji može da ima razlika željenog i stvarnog klizanja. Ta razlika može da bude pozitivna ili negativna u zavisnosti od toga da li treba smanjiti ili povećati klizanje u kontaktu pneumatik-tlo. Teoretski, ona može imati bilo koju vrednost u intervalu između [-100,100], mada treba napomenuti da su šanse da dođe do ostvarivanja ekstremnih vrednosti razlike od 100% skoro bliske nuli. Značaj upotrebe razlike između pomenute dve vrednosti klizanja točka, a ne direktno njihovih stvarnih vrednosti ponaosob, ogleda se u smanjenju broja ulaznih veličina u fazi logički kontroler, što dalje utiče na smanjenje broja fazi logičkih pravila potrebnih za opisivanje svih stanja u kojima sistem može da se nađe. Osetljivost fazi sistema u velikoj meri zavisi od broja i rasporeda funkcija pripadanja ulaznih i izlaznih veličina. Što je broj funkcija pripadanja veći, veća je i osetljivost izlaza iz fazi sistema na promenu ulazne/ulaznih veličina. Funkcije pripadanja za razliku klizanja su date u tabeli 7.3.

Tabela 7.3. Funkcije pripadanja za ulaznu promenljivu razlika klizanja (slika 7.45)

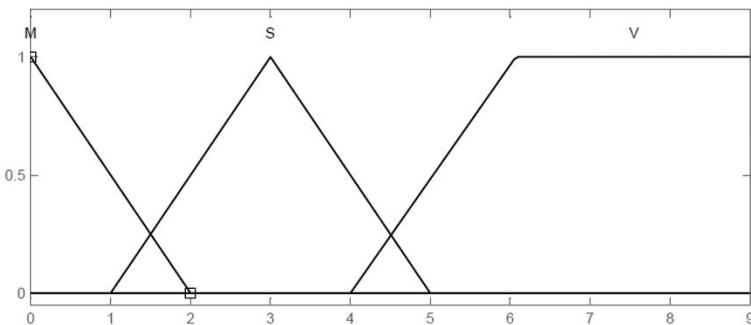
Red. br.	Oznaka	Naziv	Oblik profila	Koordinate temena
1.	0	Nula	Trouglasta	[0;0;0]
2.	PM	Pozitivno malo	Trouglasta	[0;0;10]
3.	PS	Pozitivno srednje	Trouglasta	[5;15;25]
4.	PV	Pozitivno veliko	Trouglasta	[15;100;100]
5.	NM	Negativno malo	Trouglasta	[-10;0;0]
6.	NS	Negativno srednje	Trouglasta	[-25;-15;-5]
7.	NV	Negativno veliko	Trouglasta	[-100;-100;-15]

Drugi set funkcija pripadanja ima tri lingvističke promenljive koje se odnose na nivo tri pritiska na ulazu, a koji se menjaju u opsegu između 0 i 9 bar, slika 7.46. Najčešće se primenjuju funkcije pripadanja oblika trougla, trapeza, Gausova i zvonasta jer mogu najlakše da se implementiraju u fazi logičke kontrolere. Kao što

se vidi sa slike 7.46, dve funkcije pripadanja su trouglaste, dok je treća trapeznog oblika. Da bi se omogućio blagi prelaz iz jednog stanja u drugo, funkcije pripadanja se preklapaju, a njihove karakteristike su date u tabeli 7.4.



Slika 7.45. Funkcije pripadanja za promenljivu „razlika klizanja“



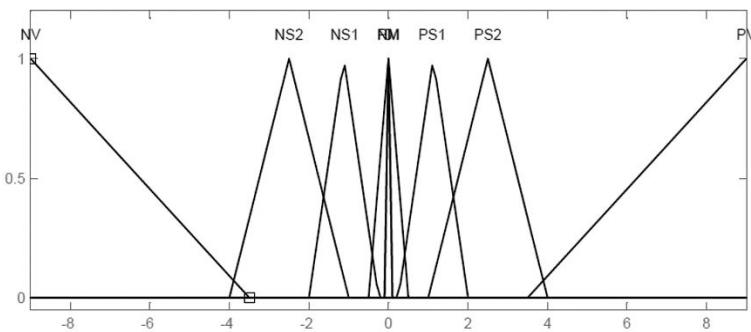
Slika 7.46. Funkcije pripadanja za pritiske

Tabela 7.4. Funkcije pripadanja za pritiske (prema slici 7.46)

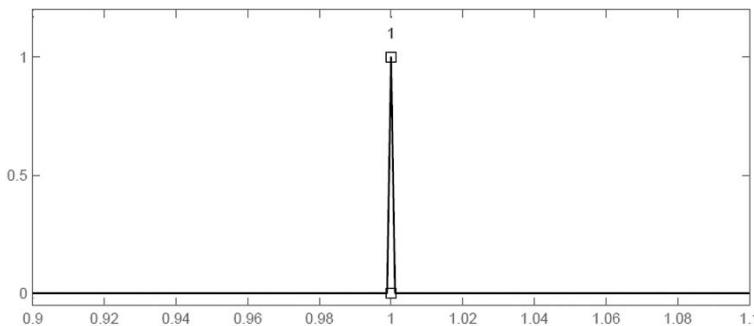
Red. br.	Oznaka	Naziv	Oblik profila	Koordinate temena
1.	M	Mali	Trouglasta	[0;0;2]
2.	S	Srednji	Trouglasta	[1;3;5]
3.	V	Veliki	Trapezna	[4;6;9;9]

Funkcije pripadanja, pomoću kojih su predstavljene uzlazne promenljive su prikazane na slikama 7.47 i 7.48. Što se tiče korekcije pritiska, ukupan opseg mogućih vrednosti korekcije se nalazi između -9 i 9 bar pa je shodno tome izabrano 9 funkcija pripadanja (slika 7.47), datih u tabeli 7.5. Način njihovog definisanja je analogan sa načinom definisanja funkcija pripadanja razlike klizanja na ulazu. Jedina razlika se odnosi na dodatno razdvajanje pozitivnog/negativnog fazi skupa srednje na dva manja fazi skupa (PM1 i PM2/NM1 i NM2) sa ciljem da se omogući korigovanje pritiska sa manjim korakom. Fazi skupovi su u ovom slučaju

predstavljeni pomoću trouglastih funkcija pripadanja. Kao i kod ulaznih promenljivih i ove funkcije pripadanja se preklapaju čime se obezbeđuje da izlaz bude sa blagim promenama. Logički signal koji služi za upravljanje prekidačem može biti predstavljen samo jednom, tzv. *singleton* funkcijom pripadanja sa koordinatama [1;1;1], slika 7.48.



Slika 7.47. Funkcije pripadanja za korekciju pritiska



Slika 7.48. Funkcija pripadanja za logički signal

Da bi se opisala sva moguća stanja fazi sistema tokom njegovog rada, definisano je ukupno 194 ($27 \times 7 = 194$) fazi logičkih („ako-onda“) pravila. Ova pravila su bazirana na međusobnim kombinacijama fazi skupova koji opisuju stepen pripadanja odgovarajuće ulazne/izlazne promenljive. Međusobni odnos pritisaka na ulazu može u opštem slučaju da se razvrsta na četiri posebna slučaja, vidi tabelu 7.6. U skladu sa tim, definisana je strategija formiranja pravila koja je prikazana u tabeli 7.7. Odgovarajuće oznake se odnose na Δp – razlika između željenog i stvarnog klizanja, p_p – pritisak koji predlaže neuronski kontroler, p_v – pritisak koji zahteva vozač i p_{stv} – stvarni pritisak aktiviranja kočnice.

Tabela 7.5. Funkcije pripadanja za izlaznu promenljivu korekcija pritiska (prema slici 7.47)

Red. br.	Oznaka	Naziv	Oblik profila	Koordinate temena
1.	0	Nula	Trouglasta	[0;0;0]
2.	PM	Pozitivno mala	Trouglasta	[0;0;0,5]
3.	PS1	Pozitivno srednja 1	Trouglasta	[0;1;2]
4.	PS2	Pozitivno srednja 2	Trouglasta	[1;2,5;4]
5.	PV	Pozitivno velika	Trouglasta	[3,5;9;9]
6.	NM	Negativno mala	Trouglasta	[-0,5;0;0]
7.	NS1	Negativno srednja 1	Trouglasta	[-2;-1;0]
8.	NS2	Negativno srednja 2	Trouglasta	[-4;-2,5;-1]
9.	NV	Negativno velika	Trouglasta	[-9;-9;-3,5]

Tabela 7.6. Odnos pritisaka na ulazu

Red. br.	Odnos pritisaka
1.	$p_p \geq p_v \geq p_{stv}$
2.	$p_p \geq p_v \leq p_{stv}$
3.	$p_p \leq p_v \geq p_{stv}$
4.	$p_p \leq p_v \leq p_{stv}$

Tabela 7.7. Definisana fazi logička pravila

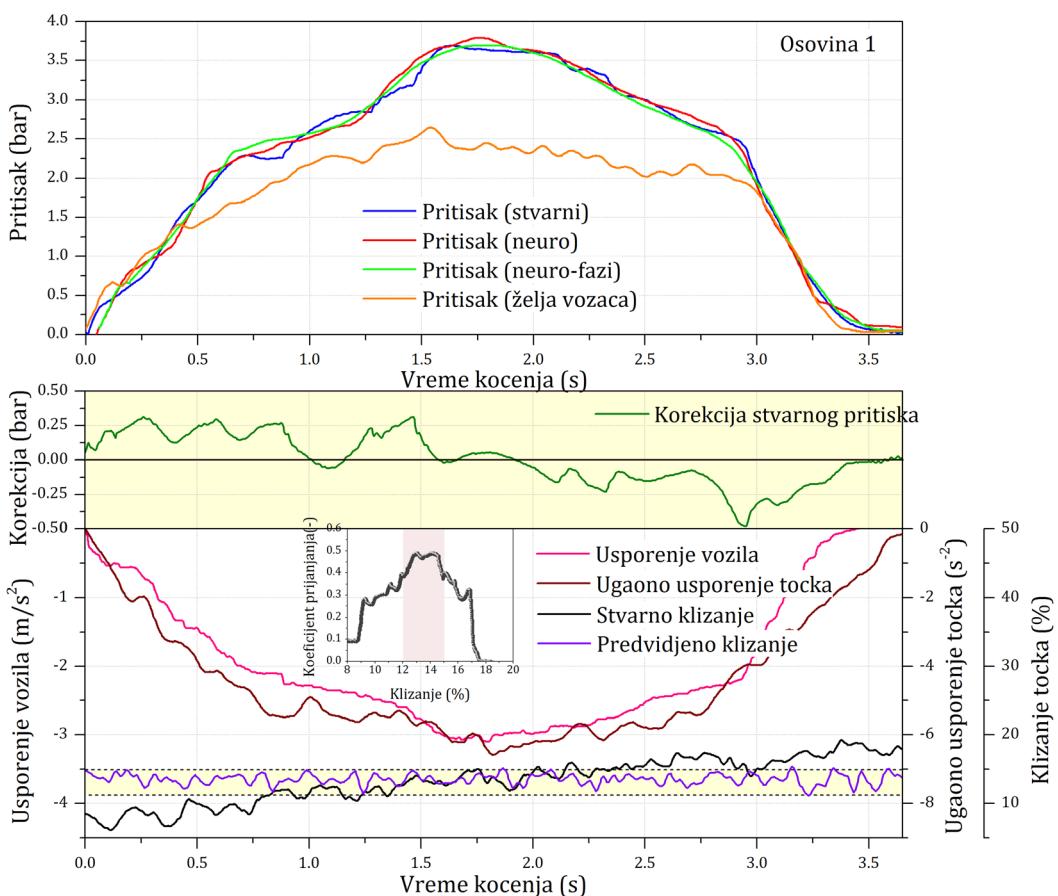
Slučaj (Tabela 7.6)	Red. br.	p_p	Ulazne veličine					$i_{\Delta\lambda}$	Izlazne veličine						
			i/ili	p_v	i/ili	p_{stv}	0		PM	PS	PV	NM	NS	NV	
1	1	V	i	i	V	NV, NS, NM, 0, PM, PS, PV	V	p_{stv}	p_p	p_p	p_p	NM	NS1	NS2	
1	2	V			V		S	p_{stv}	p_p	p_p	p_p	NS1	NS2	NS2	
1	3	V			V		M	p_{stv}	PS1	p_p	p_p	NM	NM	NM	
2	4	V			S		V	p_{stv}	pp	p_p	p_p	NM	NS1	NS2	
1	5	V			S		S	p_{stv}	pp	p_p	p_p	NM	NS1	NS2	
1	6	V			S		M	p_{stv}	PS1	p_p	p_p	NM	NM	NM	
2	7	V			M		V	p_{stv}	p _p	p_p	p_p	NM	NS1	NS2	
2	8	V			M		S	p_{stv}	p_p	p_p	p_p	NM	NS1	NS2	
1	9	V			M		M	p_{stv}	PS1	p_p	p_p	NM	NM	NM	
3	10	S			V		V	p_{stv}	PM	PS1	PS2	p_p	p_p	NV	
3	11	S			V		S	p_{stv}	p_p	PS1	PS2	p_p	NS1	NS2	
3	12	S			V		M	p_{stv}	p_p	p_p	PV	NM	NM	NM	
4	13	S			S		V	p_{stv}	PM	PS1	PS2	p_p	p_p	p_p	
1	14	S			S		S	p_{stv}	p_p	PS1	PS2	p_p	NS1	NS2	
1	15	S			S		M	p_{stv}	p_p	p_p	p_p	NM	NM	NM	
2	16	S			M		V	p_{stv}	PM	PS1	PV	p_p	p_p	p_p	
2	17	S			M		S	p_{stv}	p_p	p_p	p_p	NM	NS1	NS2	
1	18	S			M		M	p_{stv}	p_p	p_p	p_p	NM	NM	NM	
3	19	M			V		V	p_{stv}	PM	PS1	PS2	p_p	p_p	p_p	
3	20	M			V		S	p_{stv}	PM	PS1	PV	NM	p_p	p_p	
3	21	M			V		M	p_{stv}	p_p	PS1	PV	NM	NM	NM	
4	22	M			S		V	p_{stv}	PM	PS1	PS2	NS1	p_p	p_p	
4	23	M			S		S	p_{stv}	PM	PS2	PV	p_p	p_p	p_p	
3	24	M			S		M	p_{stv}	p_p	PS1	PS2	NM	NM	NM	
4	25	M			M		V	p_{stv}	PM	PS1	PS2	NS1	p_p	p_p	
4	26	M			M		S	p_{stv}	PM	PS2	PV	p_p	p_p	p_p	
1	27	M			M		M	p_{stv}	p_p	PS1	PS2	NM	NM	NM	

7.5.2. Upravljanje performansama kočnog sistema pomoću neuro-fazi modela za prednju i zadnju osovinu

Da bi se u potpunosti sagledale prednosti kombinovanja neuronskog i fazi pristupa za inteligentno upravljanje performansama kočnice u cilju ostvarivanja željenog/optimalnog nivoa klizanja u kontaktu pneumatik-tlo analizirano je 11 različitih ciklusa kočenja. Prvih šest ciklusa se odnose na neopterećeno, dok se ostalih pet odnose na opterećeno stanje vozila. U skladu sa time, slike 7.49-7.54 se odnose na neopterećeno, a sve ostale na opterećeno stanje vozila. U objašnjenjima koja slede je, pored analize ciklusa kočenja sa stanovišta opisivanja promena posmatranih ulaznih veličina (klizanje, brzina i temperatura), na primer, maksimalne/minimalne vrednosti, opseg promene, trend promene, itd., pažnja bila usmerena na uporednu analizu podešavanja pritiska aktiviranja kočnice pomoću čisto neuro i kombinovanog neuro-fazi pristupa. U odnosu na dijagrame rezultata prikazane u prethodnom poglavljiju koji se odnose na čisto neuronski pristup, na svakom od dijagrama su uporedno prikazani stvarni pritisak aktiviranja kočnice (izmeren tokom datog ciklusa kočenja), pritisak koji je zahtevaо vozač dejstvom na komandu sistema za radno kočenje u toku ciklusa kočenja, pritisak koji predviđa neuronski model u sastavu budućeg kontrolera i predviđeni pritisak aktiviranja kočnice kao rezultat rada hibridnog neuro-fazi modela. Uporedo sa tim je dodatno prikazana i dinamička promena korekcije stvarnog pritiska, kao razlika pritiska predviđenog od strane neuro-fazi modela i stvarnog pritiska kojim je kočnica aktivirana tokom rada EBS sistema posmatranog vozila. Da bi se proverilo da li je klizanje, kao rezultat uvedene korekcije pritiska aktiviranja kočnice u željenom opsegu (u kome je ostvarivo maksimalno prijanjanje u podužnom pravcu), na dijagramu je takođe prikazana i promena predviđenog klizanja. To klizanje je rezultat simulacije datih uslova kočenja za vrednost pritiska aktiviranja kočnice korigovanog pomoću neuro-fazi modela, odnosno budućeg kontrolera čiji će se rad zasnivati na ovom hibridnom modelu. Pored toga, na nekim dijogramima je dodatno prikazana i promena logičkog signala, kojim se upravlja prekidačem (selekcija između predviđenog i stvarnog pritiska), kako bi se bolje objasnilo kako sistem intelligentnog upravljanja radi, odnosno u kojim trenucima tokom ciklusa

kočenja dolazi do korekcija pritisaka, odnosno prelaza sa predviđenog na stvarni pritisak i obrnuto.

U slučaju ciklusa kočenja prikazanog na slici 7.49, da bi se klizanje u kontaktu pneumatika i tla dovelo na nivo koji odgovara maksimalnom prijanjanju točka u kontaktu sa podlogom, kočnica na prednjoj osovini bi, prema odlukama koje donosi neuro-fazi model, trebalo da bude aktivirana pritiskom koji je u određenoj meri korigovan (sa zakašnjnjem od 0,061 s) u odnosu na stvarni pritisak. Prema krivoj klizanja prikazanoj na slici 7.49, maksimalni koeficijent prijanjanja u podužnom pravcu je dostupan za vrednosti klizanja između 12-15%.



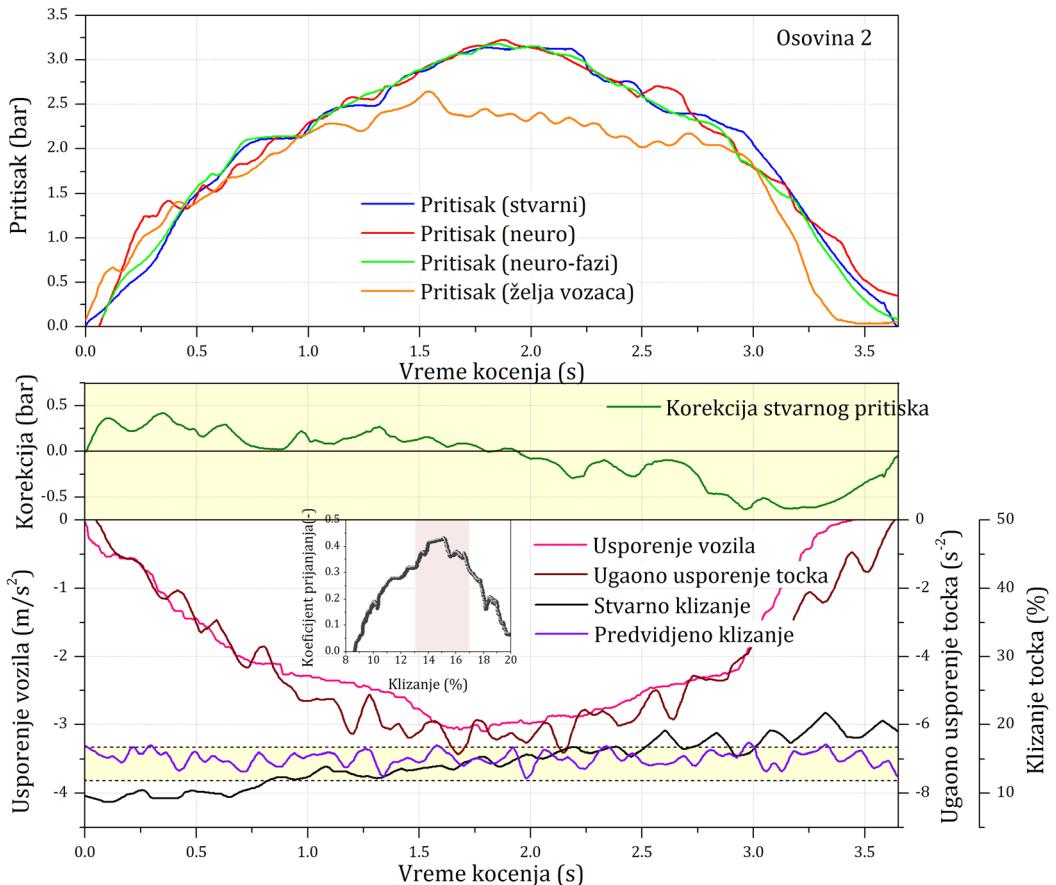
Slika 7.49. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=12-15\%$

Neuro-fazi model je testiran sa ciljem da se pritisak aktiviranja prednje kočnice uskladi sa trenutnim uslovima kočenja, kako bi se klizanje održavalo u okviru pomenutog opsega tokom datog ciklusa kočenja. Na osnovu rezultata prikazanih

na slici 7.49 može se zaključiti da je neuro-fazi model, odnosno budući kontroler zasnovan na ovakovom modelu, korigovao (povećao) pritisak aktiviranja prednje kočnice u toku prve sekunde vremena kočenja u proseku za 0,2 bar, što je izazvalo dovođenje (povećanje) podužnog klizanja u kontaktu pneumatik-tlo na nivo blizu gornje granice željenog opsega klizanja. Tokom narednih 0,2 s kontroler je smanjio pritisak za 0,05 bar jer se stvarna vrednost klizanja u tom intervalu nalazi u okviru zone gde je moguće ostvariti maksimalno prijanjanje. Tu je predviđena vrednost pritiska bila odgovarajuća pa je i vrednost korigovanog pritiska koji određuje neuro-fazi kontroler jednaka toj vrednosti. Između 1,2-1,5 s kontroler je povećao pritisak za 0,3 bar da bi se stvarno klizanje dovelo sa donje na gornju granicu željenog opsega. Iz istog razloga, između 1,6 -1,8 s stvarni pritisak je korigovan (blago uvećan) za 0,08 bar (slika 7.49). Posle 1,8 s pa do kraja ciklusa kočenja, stvarno klizanje je van željenog opsega pa je kontroler uskladio, tj. smanjio pritisak u odnosu na stvarnu vrednost da bi se klizanje dovelo u zonu između 12-15%, što potvrđuje prikazana promena predviđenog klizanja u tom delu ciklusa.

Što se tiče ciklusa kočenja koji se odnosi na zadnju osovinu (slika 7.50), razlike u odnosu na ciklus koji se odnosi na prednju osovinu su veoma male. Uvažavajući želju vozača (koji zahteva povećanje pritiska za 1,5 bar) i stvarnu vrednost pritiska (koja je povećana za 1,2 bar), tokom 0,5 s neuro-fazi kontroler je sa zakašnjnjem povećao pritisak aktiviranja u proseku za 0,4 bar u odnosu na stvarni pritisak, da bi se klizanje točka povećalo i dovelo u opseg 13-17% (slika 7.50). Sa druge strane, od 2,8-3,3 s kočenja neuro-fazi kontroler je korigovao (smanjio) pritisak aktiviranja kočnice za 0,2 bar da bi se ostvarilo željeno klizanje u kontaktu pneumatika i puta. Slično kao i u prethodnom slučaju, kontroler je do trenutka 1,7 s u većoj ili manjoj meri povećavao pritisak u odnosu na stvarni, prvo da bi doveo klizanje točka u željenu zonu (interval 0-0,7 s), a onda do 1,7 s da bi se klizanje dovelo na gornju granicu tog opsega, što se potvrđuje na osnovu promene predviđenog klizanja (slika 7.50). Nakon 1,75 s do kraja ciklusa je usledilo smanjenje korigovanog pritiska u odnosu na stvarni (maksimalno za 0,6 bar) jer stvarno klizanje u proseku za 5-8% odstupa od zone klizanja gde je moguće postići maksimalnu efikasnost kočenja. Karakteristična su odstupanja pritiska koji

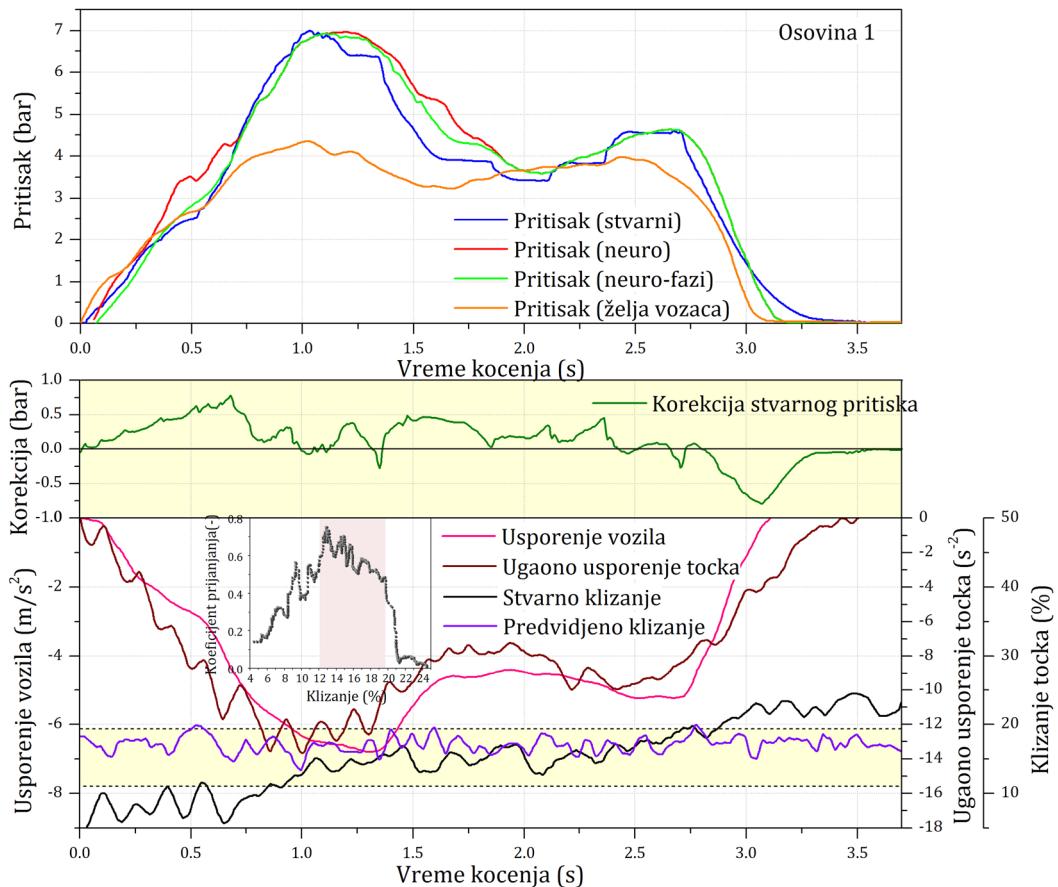
predviđa neuronski deo kontrolera između 2,5-2,7 s i posle 3,3 s do kraja ciklusa gde je neuro-fazi kontroler korigovao pritisak tako što je smanjio neodgovarajuća povećanja u tim intervalima.



Slika 7.50. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=13-17\%$

U slučaju ciklusa kočenja sa slike 7.51, neuro-fazi kontroler je od početka kočenja do 0,7 s povećao pritisak za 0,75 bar i doveo klizanje na gornju granicu optimalne zone (predviđeno klizanje između 0-0,7 s), a zatim je do 1,1 s postepeno smanjivao razliku u odnosu na stvarni pritisak kako bi se klizanje zadržalo u željenom opsegu. Pri tome treba imati u vidu da stvarno klizanje u tom delu konvergira ka sredini optimalnog opsega koji se nalazi u granicama između 12-20% za dati ciklus. To je takođe u skladu sa promenom ugaonog usporenja točka, koje je u tom intervalu prekinulo trend naglog povećanja i počelo veoma blago da se smanjuje. Sve do 2,8 s stvarno klizanje je u optimalnom opsegu pa je kontroler usklađivao pritisak uz minorne korekcije u odnosu na promenu stvarnog pritiska,

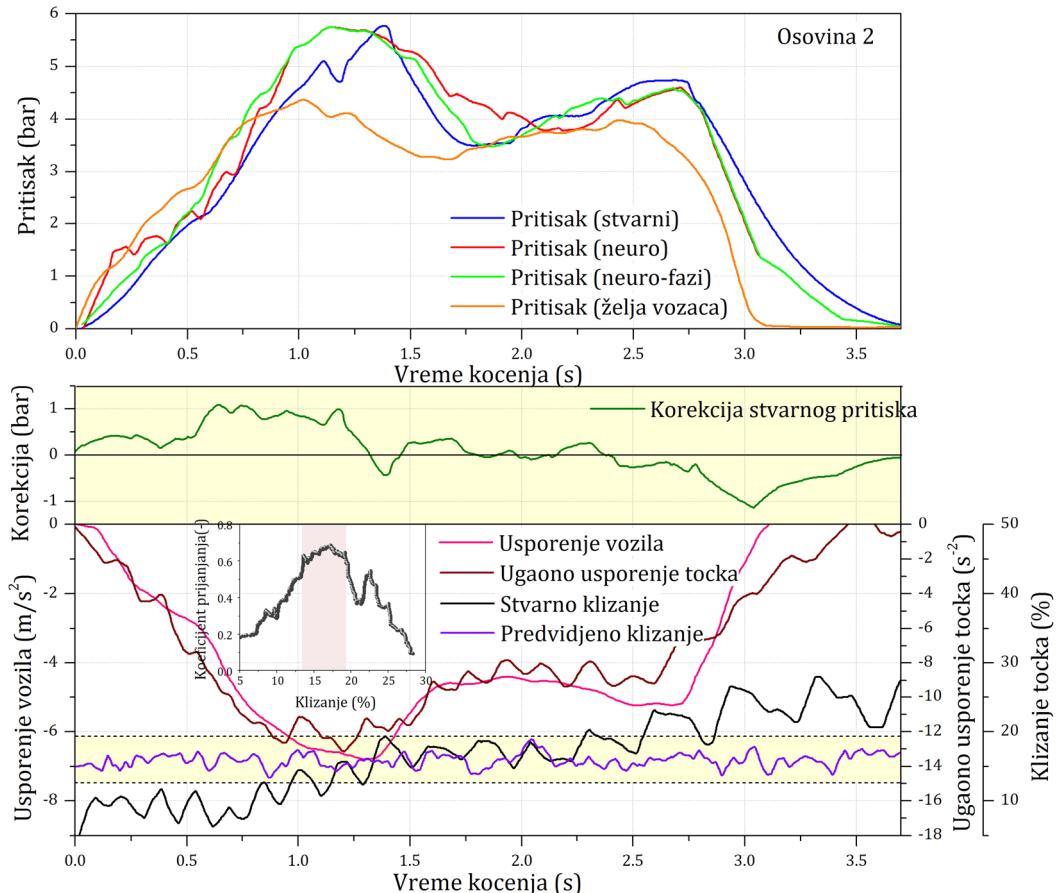
što je dovelo do toga da se predviđeno klizanje nađe na nivou u blizini gornje granice zone optimalnog klizanja. Posle tog trenutka, kontroler je smanjio pritisak do kraja ciklusa da bi se i klizanje točka smanjilo za 8-10% i na taj način dovelo na nivo koji se dinamički menja u okviru željene/optimalne zone. Kao što se vidi sa slikama 7.50, u delovima ciklusa između 0,7-1,1 s i posle 1,8 s do kraja ciklusa, kontroler je prepoznao da je promena predviđenog pritiska odgovarajuća, odnosno usklađena sa trenutno važećim uslovima prijanjanja i u skladu sa tim doneo odluku da kočnica treba da se aktivira sa tom predviđenom vrednošću pritiska, što je prevashodno bio jedan od glavnih ciljeva razvoja ovakvog sistema inteligentnog upravljanja, baziranog na uvođenju hibridnog neuro-fazi modela.



Slika 7.51. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=12-20\%$

Tokom ciklusa kočenja koji se odnosi na zadnju osovinu (slika 7.52) neuro-fazi kontroler je u delu ciklusa 0,95-1,3 s i posle 2,4 s pa do kraja ciklusa uvažio predviđanje neuronskog modela i doneo odluku da se kočnica aktivira

predviđenim pritiskom. To za posledicu ima povećanje klizanja (u prvom pomenutom intervalu) i smanjenje (u drugom intervalu), što potvrđuje dinamička promena klizanja koja je rezultat simulacije trenutnih uslova kočenja (predviđeno klizanje).

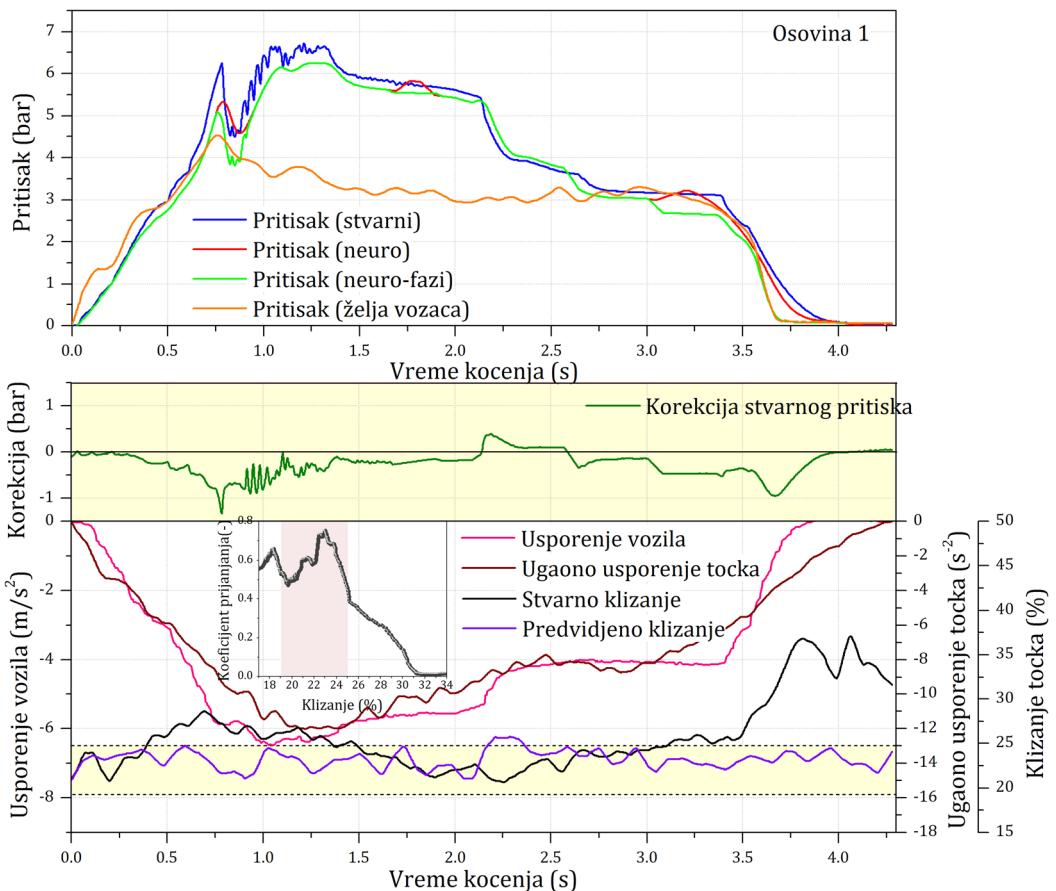


Slika 7.52. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=13-19\%$

Od početka ciklusa do 1,3 s neuro-fazi kontroler je povećao pritisak u odnosu na stvarni, prvo za 0,5 bar, a zatim posle trenutka 0,5 s na 1 bar, jer je stvarno klizanje u tom delu dalje od željenog/optimalnog opsega, koji se kreće u granicama 13-19% (slika 7.52). Taj korigovani pritisak je manji od onog koji predviđa neuronski deo kontrolera, a u isto vreme i veći od stvarnog, što je u skladu sa zahtevima vozača koji želi veći pritisak. Slučaj promene korekcije (povećanja) pritiska sa 0,5 na 1 bar se čini kao pogodan primer za detaljniju analizu rada neuro-fazi kontrolera. Do trenutka 0,4 s dominantan uticaj na vrednost korekcije pritiska na izlazu iz fazi logičkog dela kontrolera ima pravilo iz skupa pod brojem 14, gde stvarni,

predviđeni i pritisak koji zahteva vozač pripadaju oblasti funkcije pripadanja „srednji“, a razlika klizanja pripada opsegu funkcije „pozitivno srednje“. To je dovelo do toga da fazi deo kontrolera doneše odluku da treba povećati stvarni pritisak za vrednost koja pripada domenu funkcije pripadanja „pozitivno srednje“. Dalja promena pritisaka, s obzirom na to da je pritisak koji zahteva vozač najveći (slučaj 3 u skladu sa tabelom 7.7), je dovela do toga da se postepeno aktivira pravilo iz skupa pod brojem 11, što za posledicu ima povećanje pritiska za još 0,5 bar, pri čemu i ta korekcija pripada domenu funkcije pripadanja „pozitivno srednje“. Posebno je uočljiva korekcija, odnosno smanjenje pritiska u delu ciklusa kočenja između 2,5 s do kraja, gde je evidentan uticaj promene klizanja točka u tom segmentu ciklusa, što je uslovilo da neuro-fazi kontroler smanji pritisak aktiviranja za čak 1,3 bar da bi se ostvarila promena klizanja koja se nalazi u optimalnom opsegu.

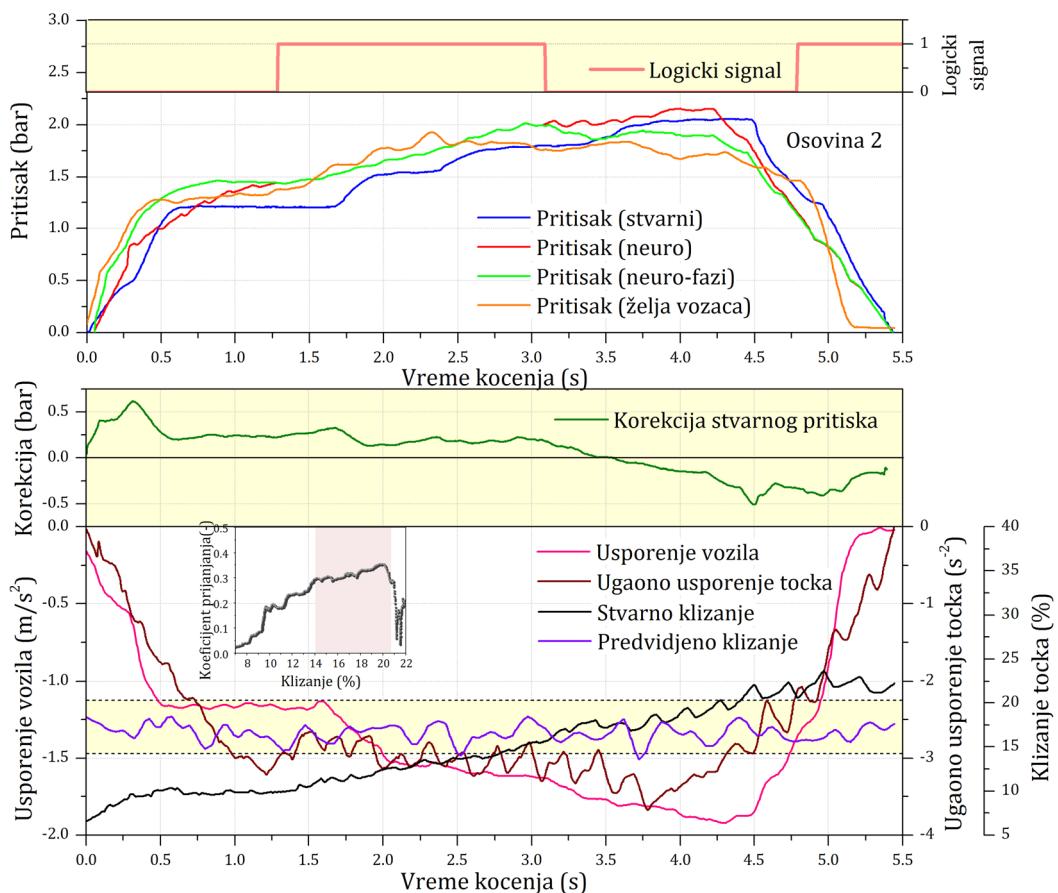
Slika 7.53 prikazuje rezultate podešavanja pritiska aktiviranja kočnice na prednjoj osovini pomoću neuro-fazi pristupa u slučaju kada je došlo do aktiviranja ABS-a. Do 0,75 s kočenja neuro-fazi kontroler je na izlaz sa zakašnjenjem od 0,061 s propustio pritisak koji predviđa neuronski deo kontrolera. To je takođe slučaj u segmentima ciklusa između 0,9-1,7 s i od 1,9-3 s (slika 7.53). Uvažavajući promenu pritiska koji zahteva vozač i promenu pritiska koji je predvideo neuronski deo kontrolera, u kratkom intervalu posle 0,75 s neuro-fazi kontroler je prvo dodatno smanjio pritisak u poređenju sa predviđenim, pri čemu maksimalna razlika u odnosu na stvarni pritisak iznosi 1,4 bar. Posle toga, kontroler je korigovao, tj. smanjivao pritisak za manju vrednost, uvažavajući i predviđanje dinamičkog neuronskog modela (između 0,9-1,7 s), a imajući u vidu da je u tom intervalu stvarno klizanje sve bliže gornjoj granici zone optimalnog klizanja. U delu ciklusa između 1,7-1,9 s ciklusa kočenja, fazi deo kontrolera je dodatno smanjio pritisak za 0,3 bar jer je stvarno klizanje još uvek na gornjoj granici optimalne zone. Kratko povećanje pritiska (bazirane na promeni predviđenog pritiska) u intervalu između 2,1-2,3 s je dovelo do toga da predviđeno klizanje, kao rezultat simulacije uslova kočenja aktiviranjem kočnice sa tim korigovanim pritiskom, izađe, tj. prekorači gornju granicu optimalnog opsega u tom intervalu ciklusa (slika 7.53).



Slika 7.53. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=19-25\%$

Na slici 7.54 je prikazan ciklus kočenja koji se odnosi na zadnju osovINU, pri čemu je dijagram u gornjem delu dopunjen sa prikazom promene logičkog signala, koji ima funkciju upravljanja prekidačem pomoću koga se vrši izbor između predviđenog i stvarnog pritiska, koji je korigovan za određenu vrednost (na dijagramima označenu sa korekcija stvarnog pritiska). Pri tome treba napomenuti da se pod stvarnim pritiskom aktiviranja kočnice podrazumeva pritisak koji je izmeren tokom eksperimentalnog dela istraživanja i reprezentuje stanje kako sistem trenutno radi. Na osnovu logičkog signala se jasnije vidi kada je neuro-fazi kontroler na izlaz propustio pritisak koji predviđa neuronski deo kontrolera, a to se u ovom slučaju desilo u intervalima između 1,3-3,1 s i posle 4,75 s do kraja ciklusa kočenja. Međutim, greške u predviđanju neuronskog modela su korigovane od strane neuro-fazi kontrolera u preostalom delu ciklusa (0-1,3 s i 3,1-4,75 s), slika 7.54. Na taj način je sprečeno da kočnica bude aktivirana sa vrednošću

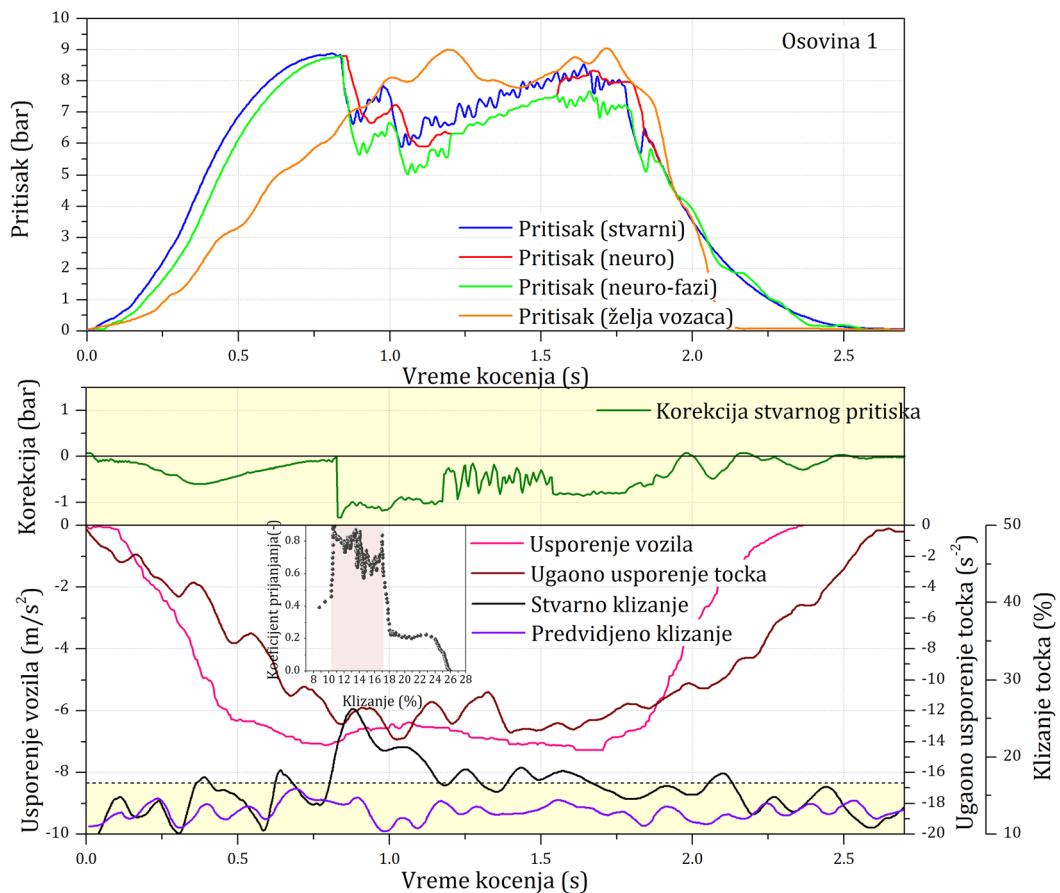
pritisaka koja nije usklađena sa trenutnim uslovima kočenja, što bi moglo da dovede do neželjenih posledica poput narušavanja stabilnosti vozila (imajući u vidu da se radi o zadnjoj osovini vozila). U ovom slučaju zona klizanja gde je moguće ostvariti maksimalno prijanjanje se kreće u granicama između 14-21%. Da bi se klizanje točka u kontaktu sa podlogom dovelo u pomenutu zonu, kontroler je povećao pritisak za 0,6 bar tokom prvih 0,5 s kočenja (gde je stvarno klizanje maksimalno odstupalo od optimalnog opsega), a zatim je smanjio povećanje na vrednost koja u proseku iznosi 0,3 bar sve do 3,5 s. U preostalom delu ciklusa kontroler je smanjio pritisak u odnosu na stvarni da bi se klizanje dovelo u optimalnu zonu, slika 7.54.



Slika 7.54. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=14-21\%$

Rezultati testiranja neuro-fazi pristupa pomoću ciklusa kočenja obavljenih pri opterećenom stanju vozila su prikazani na slikama 7.55-7.60. Sa slike 7.55 se vidi da je u ovom slučaju došlo do aktiviranja ABS-a na prednjoj osovini u intervalu 0,75-1,8 s, pri čemu je ABS četiri puta uzastopno vršio naglo smanjenje stvarnog

pritiska. Neuro-fazi kontroler je u intervalima 0-0,8 s, 1,2-1,6 s i 1,8 s pa do kraja ciklusa uvažio predviđanje neuronskog modela i shodno tome doneo odluku da dalje propusti predviđenu vrednost pritiska jer je u skladu sa trenutnim uslovima kočenja (prijanjanja). Na primer, tokom prvih 0,8 s pritisak koji zahteva vozač je najmanji i pripada domenu funkcije pripadanja „srednji“ (slučaj broj 2 prema tabeli 7.6), dok su predviđeni i stvarni pritisak u domenu funkcije pripadanja „veliki“. Imajući u vidu da je razlika klizanja u domenu funkcije „pozitivno malo“, aktiviralo se pravilo iz grupacije pod rednim brojem 6 (tabela 7.7), prema kome na izlaz treba propustiti predviđeni pritisak.



Slika 7.55. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=10-17\%$

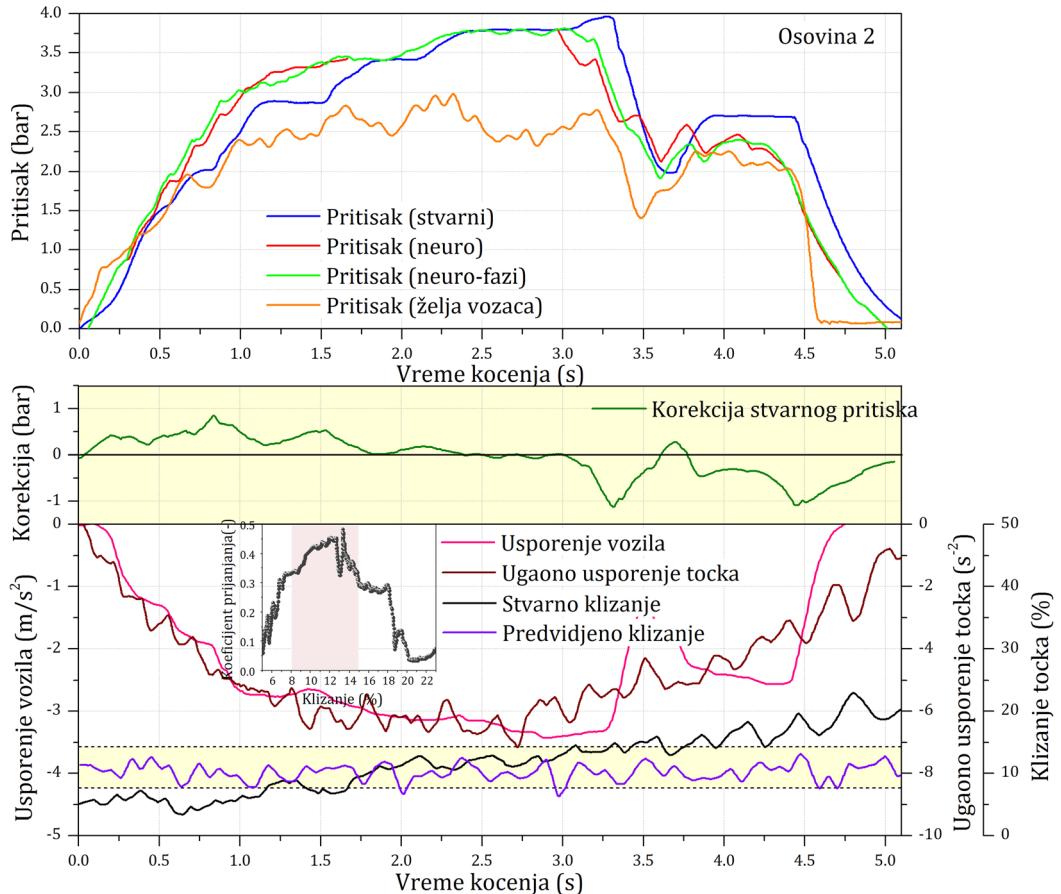
U delu ciklusa između pomenutih intervala, neuro-fazi kontroler je izvršio odgovarajuće korekcije stvarnog pritiska kako bi se u kontaktu pneumatika i tla ostvarila dinamička promena klizanja, koja u ovom slučaju treba da se nalazi u opsegu između 10-17%. Na primer, u intervalu 0,8-1,2 s dominantan uticaj na

vrednost korekcije pritiska na izlazu iz fazi logičkog dela kontrolera ima pravilo iz skupa pod brojem 1, gde stvarni, predviđeni i pritisak koji zahteva vozač pripadaju domenu funkcije pripadanja „veliki“, a razlika klizanja pripada opsegu funkcije „negativno srednje“. To je dovelo do toga da fazi deo kontrolera doneše odluku da treba smanjiti stvarni pritisak za vrednost koja pripada domenu funkcije pripadanja „negativno srednje 1“. U segmentu ciklusa između 0,75-1,2 s, gde stvarno klizanje najviše prekoračuje gornju granicu pomenutog opsega klizanja, kontroler je, upoređivanjem trenutnih vrednosti pritisaka i razlike između željenog i stvarnog klizanja, procenio da je smanjenje pritiska koje predviđa neuronski model u tom intervalu nedovoljno, i shodno tome dodatno uskladio (smanjio) pritisak (u proseku za 1,3 bar u odnosu na stvarni pritisak). To je takođe slučaj i u delu ciklusa između 1,6-1,8 s. Od 2,2 s do kraja ciklusa, stvarno klizanje se nalazi u optimalnoj zoni pa je kontroler uskladio pritisak (propustio predviđeni) tako da se u tom delu ciklusa klizanje održi u željenom opsegu.

U slučaju ciklusa sa slike 7.56, tokom prvih 0,25 s kočenja kontroler je dao signal prekidaču da propusti predviđeni pritisak. Do 1,1 s neuronski model je nedovoljno povećao pritisak aktiviranja kočnice, pa je u tom intervalu kontroler dodatno korigovao (povećao) pritisak za 0,6 bar u odnosu na stvarni, što je dovelo do povećanja klizanja i njegovog održavanja u optimalnoj zoni. Od 1,6 do 3,5 s stvarno klizanje je u optimalnom opsegu, pa je kontroler u delu tog intervala do 3 s doneo odluku da se kočnica aktivira sa predviđenim pritiskom, dok je u preostalom delu intervala vršio korekciju stvarnog pritiska, tako da je ta korigovana vrednost veća od one koju predviđa neuronski model. Posle 3,5 s do kraja ciklusa, razlika između stvarnog klizanja i opsega u kome treba da se nađe klizanje koje odgovara korigovanoj vrednosti pritiska se povećava, pa je kontroler u krajnjem delu tog intervala propustio predviđeni pritisak, a između 3,5-4,4 je korigovao, tj. umanjio stvarni pritisak za 0,6 bar (slika 7.56).

Kod ciklusa kočenja prikazanog na slici 7.57, gde je maksimalno prijanjanje u kontaktu pneumatika i puta moguće ostvariti pri vrednostima podužnog klizanja između 7-14%, karakteristična je korekcija pritiska aktiviranja kočnice između 1,4-1,8 s. Na osnovu razlike klizanja, neuro-fazi kontroler je dodatno povećao pritisak

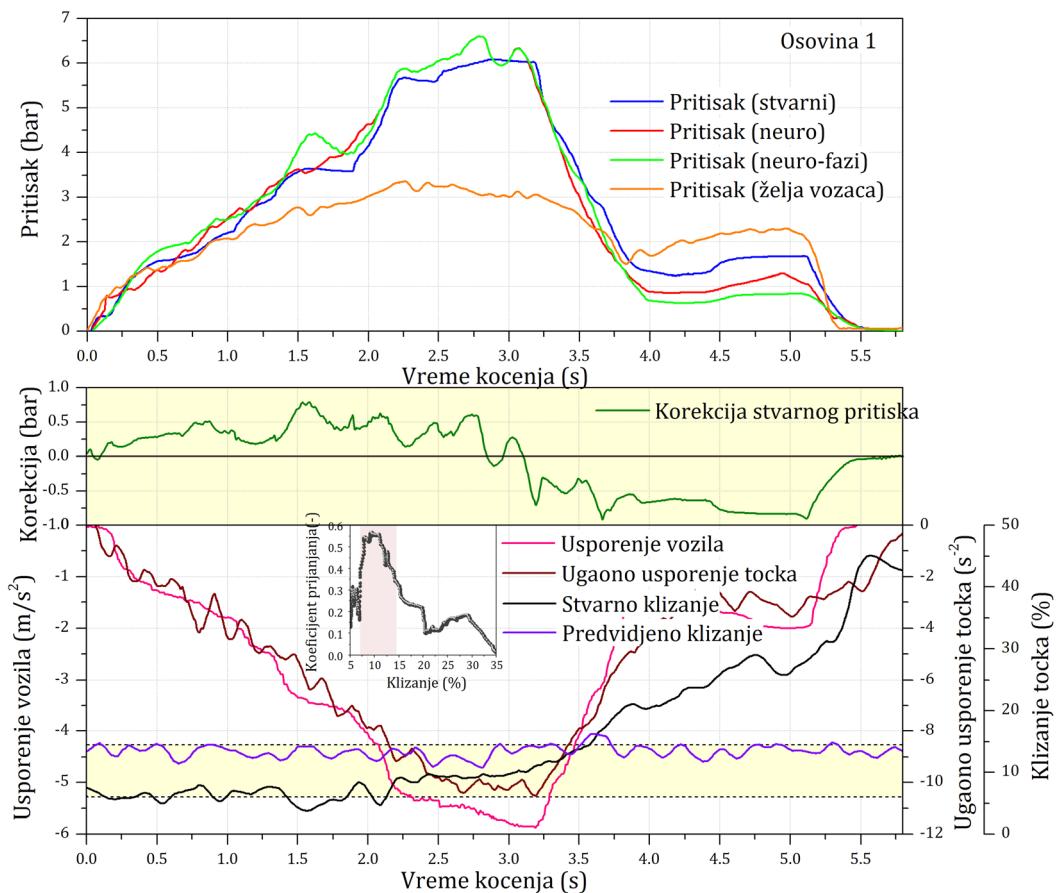
u odnosu na stvarni da bi se klizanje, koje je na nižoj vrednosti od željenog/optimalnog opsega, povećalo i ponovo vratilo na optimalni nivo.



Slika 7.56. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=8-15\%$

Imajući u vidu da stvarno klizanje varira oko donje granice opsega, kontroler je do 2 s povećao pritisak u proseku za 0,3 bar, da bi se dosegla gornja granica opsega optimalnog klizanja (slika 7.57). U delu ciklusa između 2-3,1 s kontroler je propustio predviđeni pritisak, čija promena blago varira oko vrednosti stvarnog pritiska, što je u skladu sa nivoom stvarnog klizanja, koje se nalazi na sredini optimalne zone. Ako se posmatra predviđeno klizanje u tom intervalu (dobijeno simulacijom uslova kočenja), vidi se da je ono blisko gornjoj granici optimalnog opsega klizanja zbog toga što je i korigovani pritisak u tom delu veći od stvarnog. Ovaj ciklus kočenja je, osim po izrazito naglim promenama stvarnog pritiska aktiviranja kočnice, takođe karakterističan po tome što posle 3,5 s stvarno klizanje naglo raste, uprkos tome što je vrednost stvarnog pritiska pala za čak 4,5 bar, što je

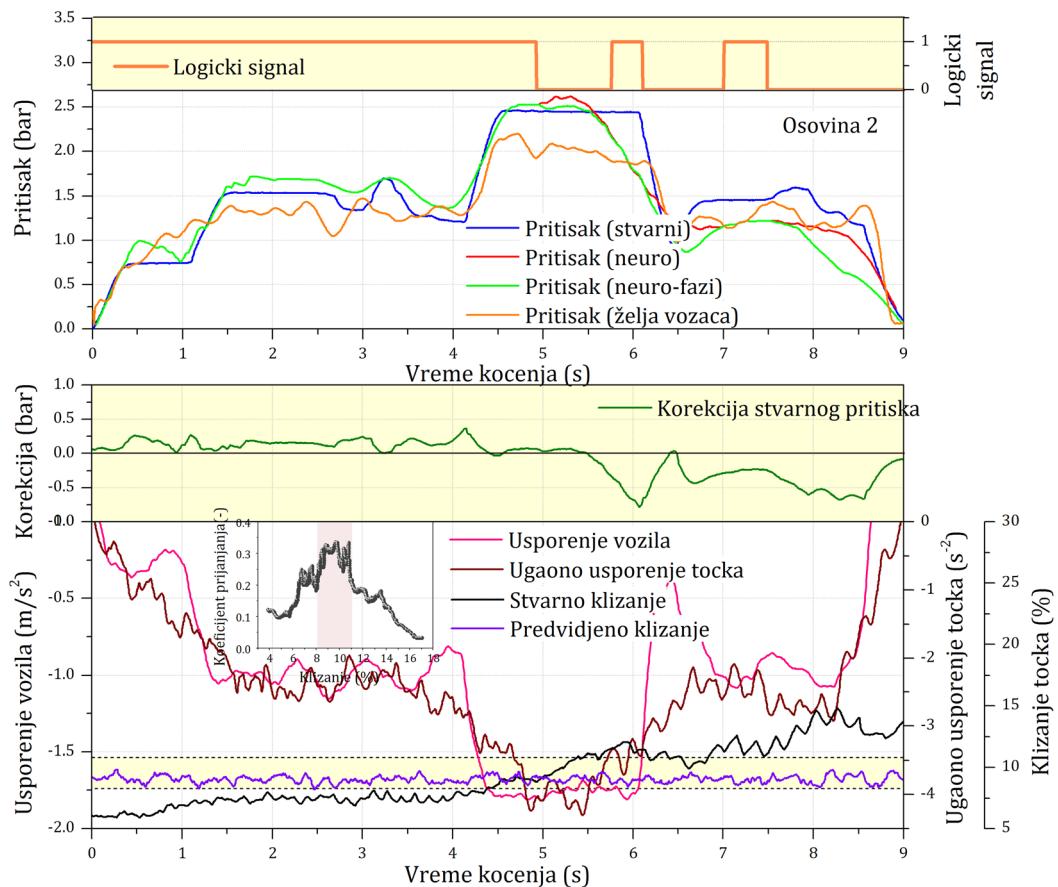
posledica prelaska kočenog točka na podlogu sa nižim koeficijentom prijanjanja (o čemu je već bilo reči u prethodnom poglavlju). Na osnovu informacije o promeni brzine točka, odnosno njegovog ugaonog usporenja, neuronski model je predvideo potrebu da se pritisak aktiviranja kočnice smanji u ovom, krajnjem, intervalu ciklusa kočenja, slika 7.57. Na osnovu predviđanja modela, kao i promene stvarnog pritiska i pritiska koji zahteva vozač, fazi deo kontrolera je dodatno korigovao, odnosno smanjio pritisak aktiviranja u odnosu na predviđenu vrednost, a rezultati simulacije uslova kočenja za tako podešeni pritisak aktiviranja kočnice pokazuju da je predviđeno klizanje na gornjoj granici optimalne zone.



Slika 7.57. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=7-14\%$

Stvarni pritisak tokom ciklusa prikazanog na slici 7.58 ima skokovite promene, što se u drugom delu trajanja ciklusa vidno odrazilo na promenu ugaonog usporenja, a dalje i na klizanje točka u kontaktu sa podlogom (stvarno klizanje). Da bi se jasnije uočilo gde se događao prelazak sa predviđenog pritiska na korigovanu

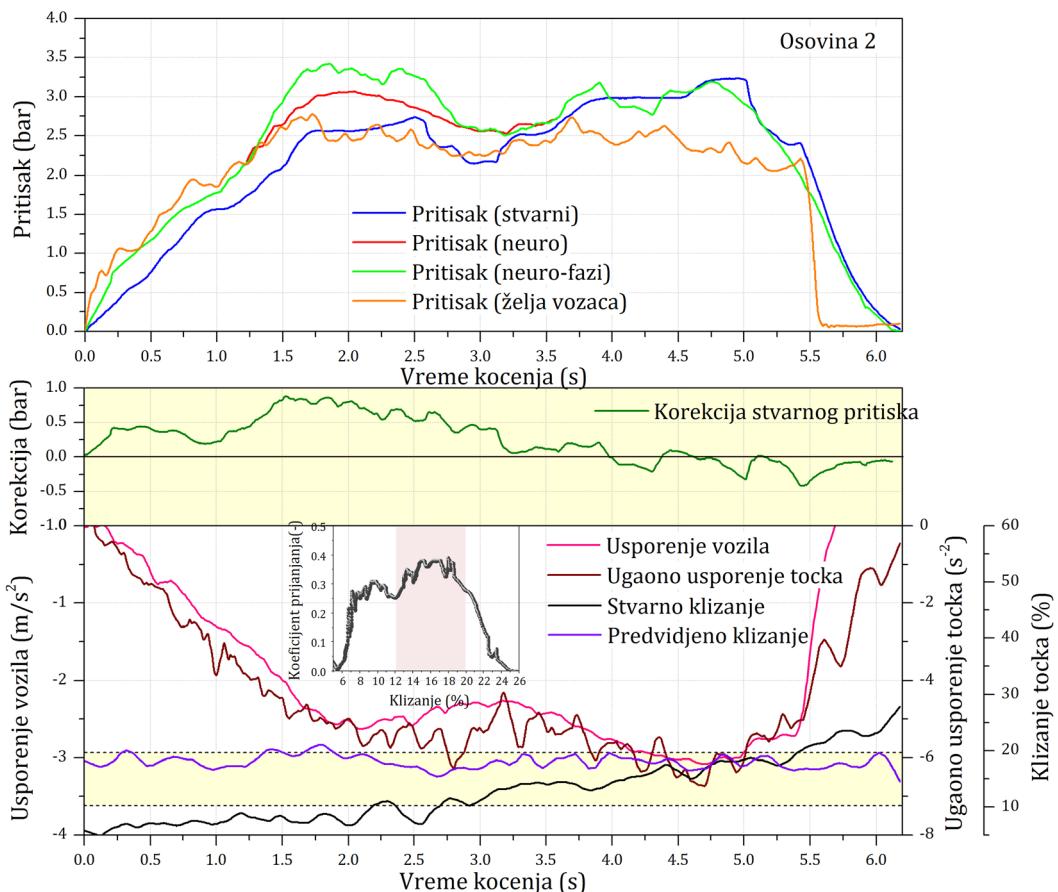
vrednost stvarnog pritiska i obrnuto, u gornjem delu dijagrama je prikazan logički signal koji se koristi za aktiviranje prekidača. Kao što se vidi sa slike 7.58, a takođe i na osnovu promene vrednosti logičkog signala, od početka ciklusa pa sve do 4,9 s kontroler je doneo odluku da kočnicu treba aktivirati sa predviđenom vrednošću pritiska.



Slika 7.58. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=8-11\%$

Predviđena vrednost pritiska je u proseku za 0,2 bar veća od stvarnog pritiska u tom intervalu, čime je obezbeđeno da se klizanje poveća u proseku za 3% i na taj način dovede u zonu koja odgovara maksimalnom prijanjanju (8-11%). Tokom sledećih 0,8 s kontroler je na svom drugom izlazu propustio vrednost logičkog signala koja je jednaka 0, čime je dao signal prekidaču da propusti blago korigovanu vrednost stvarnog pritiska jer je pritisak koji je predviđeo neuronski model preveliki, a imajući u vidu da je stvarno klizanje na gornjoj granici zone optimalnog klizanja. Od 5,5-6,6 s stvarno klizanje je van te zone pa je kontroler

smanjio pritisak za 0,6 bar u odnosu na stvarnu vrednost (logički signal je 0), pri čemu je između 5,7-6,1 s na izlaz propušten predviđeni pritisak (gde je logički signal jednak 1). Nakon toga, stvarno klizanje do kraja ciklusa je povećano, pa je kontroler negativnom korekcijom smanjio pritisak u proseku za 0,6 bar (slika 7.58).



Slika 7.59. Uporedni prikaz korigovanog i stvarnog pritiska aktiviranja kočnice – maksimum prijanjanja pri $\lambda=12-20\%$

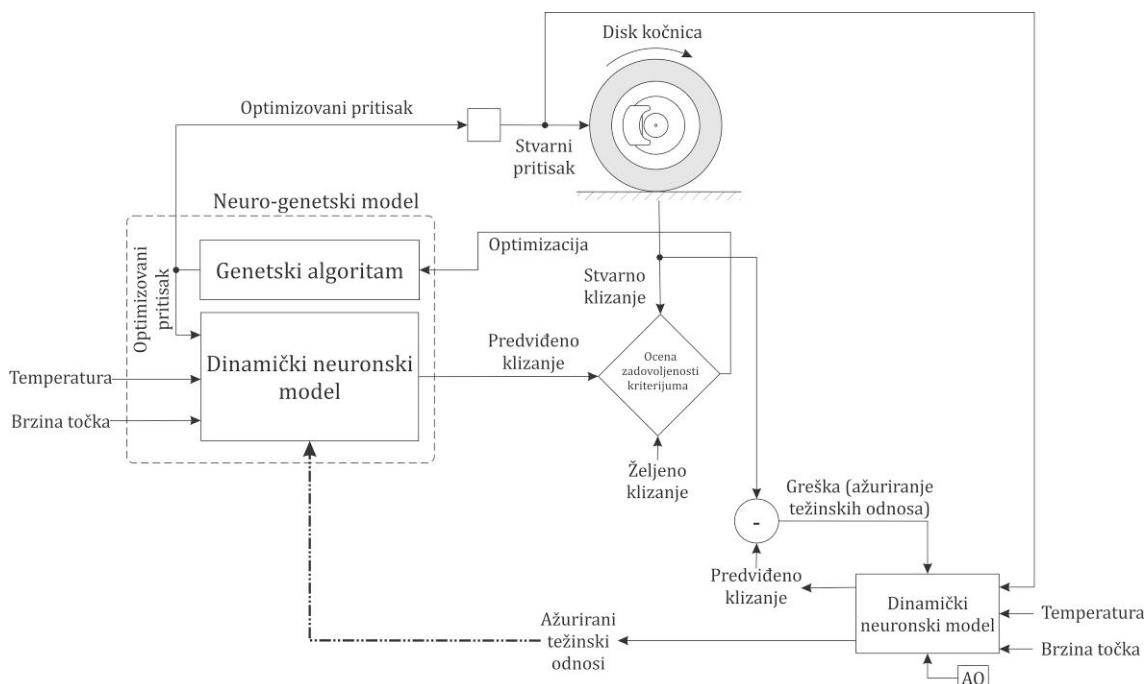
U slučaju ciklusa kočenja prikazanog na slici 7.59, neuro-fazi kontroler je propustio predviđenu vrednost pritiska tokom čitavog ciklusa, osim u intervalu između 1,3-3,5 s. U tom intervalu kontroler je dodatno povećao pritisak aktiviranja u odnosu na stvarni, čime je dosegnuta gornja granica optimalnog opsega klizanja. Posle 2 s kontroler je smanjio pritisak da bi se klizanje vratio u optimalnu zonu, a zatim je dalje propustio predviđeni pritisak, koji posle 4,5 s ima trend stalnog smanjenja, što je rezultiralo dovođenjem podužnog klizanja točka u optimalnu zonu klizanja (12-20%) na kraju datog ciklusa kočenja, slika 7.59.

7.6. INTELIGENTNO UPRAVLJANJE PERFORMANSAMA KOČNICE POMOĆU KOMBINOVANOG NEURO-GENETSKOG PRISTUPA

Prilikom analize karakteristika genetskih algoritama kao jedne od metoda veštačke inteligencije, koja se primenjuje za optimizaciju, u poglavlju 6.4.5 je istaknuto da je brzina pronalaženja optimalnog rešenja veoma važna. U ovom poglavlju su prikazani rezultati istraživanja da li je i na koji način moguće koristiti genetske algoritme za dinamičko podešavanje pritiska aktiviranja kočnice, odnosno određivanje optimalne vrednosti pritiska aktiviranja kočnice, kako bi se ostvarilo željeno klizanje u kontaktu pneumatika i tla. Fokus istraživanja je bio usmeren na razvoj hibridne, neuro-genetske metode, u cilju intelligentnog upravljanja klizanjem u kontaktu pneumatik-tlo. Razlog za kombinovanje ove dve metode se nalazi u činjenici da primena genetskih algoritama, kao pre svega optimizacione metode, zahteva postojanje modela, u ovom slučaju dinamičkog neuronskog modela performansi kočnice, kako bi na osnovu tako uspostavljene funkcionalne veze bilo moguće sprovesti proces optimizacije. Prema [93], u slučaju kombinovanja pomenute dve metode veštačke inteligencije, genetski algoritmi mogu imati tri različite uloge u takvom hibridnom sistemu: (i) pronalaženje optimalne matrice težinskih odnosa veštačke neuronske mreže (obučavanje veštačke neuronske mreže), (ii) pronalaženje optimalne strukture veštačke neuronske mreže i (iii) pronalaženje optimalnih vrednosti ulaza u veštačku neuronsku mrežu. Za primenu kombinovanog neuro-genetskog pristupa u cilju optimizacije pritiska aktiviranja kočnice je najinteresantniji ovaj poslednji način kombinovanja pomenutih metoda. On podrazumeva da postoji obučen dinamički neuronski model koji se može iskoristiti kao funkcija cilja genetskog algoritma, čime se formira hibridni, neuro-genetski model. Razvojem neuro-genetskog modela se stvaraju preduslovi za razvoj neuro-genetskog kontrolera, koji bi koristio znanje o modeliranom dinamičkom procesu [201].

Da bi se realizovali svi prethodno navedeni zahtevi, odnosno da bi se pronašla vrednost pritiska aktiviranja kočnice koja, za dati režim rada kočnice, karakteristike pneumatika i tla i trenutne uslove prijanjanja u kontaktu

pneumatik-tlo, dovodi do željene promene klizanja točka, razvijena je konfiguracija sistema za inteligentno upravljanje klizanjem točka koja izgleda kao na slici 7.61. U tom slučaju, sistem za inteligentno upravljanje klizanjem točka pomoću neurogenetskog pristupa bi trebalo da uključuje sledeće komponente: (i) dinamički neuronski model procesa kočenja, (ii) neuro-genetski kontroler procesa kočenja, (iii) model točka sa pneumatički aktiviranom disk kočnicom privrednih vozila i (iv) dodatne elemente za prenos, filtriranje i usmeravanje signala, koji na slici 7.61 nisu prikazani da bi se obezbedila bolja preglednost blok-dijagrama sistema upravljanja.



Slika 7.61. Konfiguracija sistema za inteligentno upravljanje klizanjem točka pomoću neuro-genetskog pristupa

Imajući u vidu da genetski algoritmi, kada koriste veštačku neuronsku mrežu kao funkciju cilja, vrše optimizaciju jednog ili više ulaza u neuronsku mrežu, za potrebe daljeg istraživanja u ovom pravcu razvijen je poseban dinamički neuronski model procesa kočenja, koji je detaljno analiziran u poglavljju 7.6.1. Pomoću tog modela je uspostavljena dinamička funkcionalna zavisnost između pritiska aktiviranja kočnice, brzine točka i temperature kočnice, sa jedne strane, i klizanja u kontaktu pneumatik-tlo, sa druge strane. Dakle, dinamički neuronski model procesa kočenja ima funkciju da, za trenutne vrednosti stvarnog pritiska aktiviranja kočnice, temperature kočnice i brzine točka, sa ukupnim zakašnjenjem

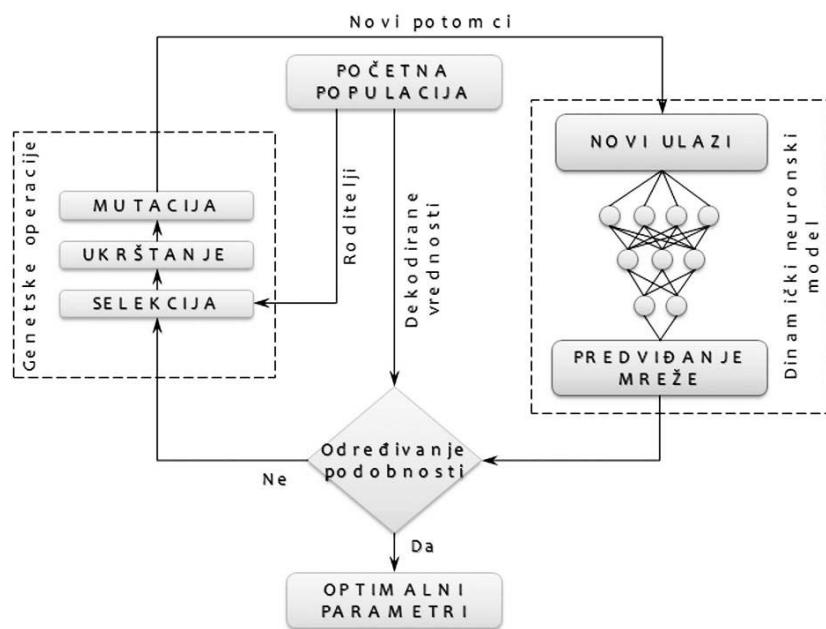
od 0,05 s predvidi kolika će biti odgovarajuća vrednost klizanja točka u kontaktu sa podlogom. Ovaj model se koncepcijски razlikuje od prethodno analiziranih inverznih modela procesa kočenja, jer predviđa klizanje, kao posledicu kočenja točka, za date režime kočenja, u kontaktu sa podlogom. Kada govorimo o kašnjenju, treba imati u vidu da se na ovo kašnjenje modela mora dodati i kašnjenje usled filtriranja ulaznih signala (pritiska, brzine točka i temperature kočnice) pomoću diskretne vejljet transformacije, koje iznosi 0,1 s. U isto vreme, dinamički neuronski model neprekidno inovira prethodno stečeno znanje o procesu kočenja putem dinamičkog ažuriranja težinskih odnosa između neurona mreže, čime se usklađuje njegovo predviđanje sa novim uslovima kočenja. Ovakva dinamička obuka neuronskog modela u realnom vremenu, odnosno u toku ciklusa kočenja se vrši na osnovu greške između trenutnih vrednosti klizanja koje model predviđa na izlazu i trenutne vrednosti stvarnog klizanja točka. Postupak aktiviranja/deaktiviranja obuke i način na koji veličina ove greške (odnosno razlike između vrednosti klizanja u datom trenutku) utiče na promenu težinskih odnosa mreže su već objašnjeni u poglavljiju 7.4.1, pa zbog toga ovde nisu detaljno razmatrani.

U skladu sa slikom 7.61, ažurirana matrica težinskih odnosa se sa zakašnjnjem od 0,005 s prenosi do neuronskog modela, koji se nalazi u okviru neuro-genetskog modela (budućeg neuro-genetskog kontrolera), i koji sa zakašnjnjem od 0,05 s predviđa klizanje u kontaktu pneumatik-tlo za date vrednosti veličina na ulazu. Neuronski model u sastavu neuro-genetskog modela ima tri ulaza i to su optimizirana vrednost pritiska aktiviranja kočnice, stvarna temperatura kočnice i stvarna brzina točka (slika 7.61). Trenutne vrednosti stvarnog, predviđenog i željenog klizanja se zatim upoređuju u cilju ocene zadovoljenosti postavljenog kriterijuma, koji je definisan kao razlika između stvarnog i željenog klizanja. Na taj način sistem treba da pronađe pritisak koji će, na osnovu predviđanja modela, dovesti do toga da se stvarno i željeno klizanje izjednače. Osnovni cilj je da ta razlika između stvarnog i željenog klizanja konvergira ka nuli, a kao dodatni uslov se postavlja da klizanje koje predviđa dinamički neuronski model u sklopu neuro-genetskog kontrolera bude jednako željenom klizanju. To omogućava da se ubrza

proces konvergencije jer sistem prvo treba da pronađe koja trenutna vrednost pritiska obezbeđuje željeno klizanje, a zatim da proveri koje efekte to izaziva na stvarno klizanje uz pomenuti uslov da razlika stvarnog i željenog klizanja bude jednak nuli. Na osnovu te predikcije, kočnica se aktivira tim pritiskom, a zatim se izračuna (sa zakašnjnjem) stvarno klizanje i uporedi sa željenim. Ako stvarno klizanje konvergira željenom, tj. razlika se bliži nuli, kočnica se i dalje aktivira tim pritiskom. Taj pritisak se istovremeno može promeniti od strane modela ako je u međuvremenu bilo greške u predviđanju modela pa je model dodatno obučavan. Tu treba da postoji dozvoljena greška jer ta razlika ne može idealno da bude nula. Ukoliko se razlika stvarnog i željenog klizanja povećava to znači da prethodno optimizovan pritisak nije dobro usklađen jer nije doveo do smanjenja razlike između klizanja već na primer do povećanja ili je u međuvremenu došlo do promene uslova kočenja. Tada nastupa drugi nivo optimizacije, jer je u tom slučaju evidentno da model greši, kada je potrebno naći vrednost pritiska koja dovodi do smanjenja razlike klizanja (stvarno-željeno), a ne povećanja. To se može takođe videti i na osnovu konfiguracije sistema sa slike 7.61. Na osnovu upoređenja navedenih trenutnih vrednosti klizanja u trajanju od 0,01 s, sledeći nivo optimizacije podrazumeva da se optimizovana vrednost pritiska aktiviranja kočnice se u sledećoj iteraciji rada sistema, zajedno sa temperaturom kočnice i brzinom točka, dovodi na ulaz u neuronski model u okviru neuro-genetskog kontrolera, na osnovu čega on dalje predviđa vrednost klizanja točka, koja odgovara datom setu ulaza (slika 7.61). Upravo je pomenuto zakašnjenje sa kojim genetski algoritam pronalazi optimalnu vrednost pritiska ograničavajući faktor za njegovu primenu u modeliranju dinamičkih procesa, a o čemu će biti reči u poglavljju 7.6.2. Pre toga je neophodno detaljnije objasniti suštinu rada neuro-genetskog kontrolera (algoritam funkcionisanja neuro-genetskog modela), kao i razvoj samog neuronskog modela procesa kočenja, koji ima sposobnost da se kontinualno dinamički obučava u toku ciklusa kočenja.

7.6.1. Algoritam funkcionisanja neuro-genetskog modela

Algoritam funkcionisanja razvijenog hibridnog neuro-genetskog modela je prikazan na slici 7.62. Ovakav pristup može biti sažet u pet osnovnih koraka: (1) Genetski algoritam formira početnu populaciju pojedinaca za pritisak aktiviranja; (2) Posle toga, određuje se podobnost svakog hromozoma. Istovremeno, podobnost svakog hromozoma se uskladjuje od strane dinamičkog neuronskog modela; (3) Generiše se populacija za sledeću generaciju primenom genetskih operacija (selekcija, ukrštanje i mutacija) sa verovatnoćom koja se bazira na podobnosti svakog hromozoma; (4) Genetski algoritam zatim šalje novu generaciju potomaka ka dinamičkom neuronskom modelu kao novi ulazni parametar; (5) Na kraju, dinamički neuronski model izračunava podobnost ulaznog parametra i generiše odgovarajući izlaz. Poslednja četiri koraka se ponavljaju sve dok se ne ispunи postavljeni kriterijum za zaustavljanje procesa optimizacije.



Slika 7.62. Algoritam funkcionisanja hibridnog, neuro-genetskog, modela

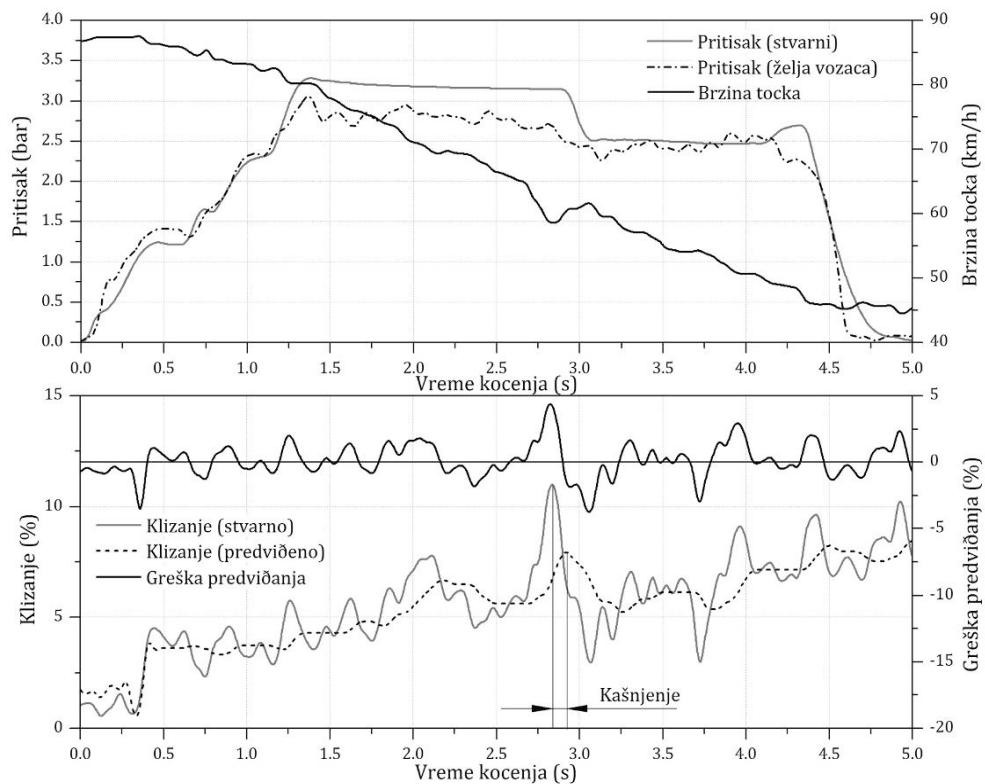
Sa slike 7.62 se može videti da se podobnost svakog pojedinca izračunava pomoću dinamičkog neuronskog modela tokom svakog evolucionog koraka. Simuliranjem neuronskog modela za različite vrednosti brzine točka i temperature kočnice tokom ciklusa kočenja, pritisak aktiviranja kočnice se dinamički optimizira

uzimajući u obzir dinamičke promene stvarnog i željenog klizanja točka, kao i njima odgovarajućih nelinearnih ograničenja. Ograničenja funkcije cilja su formirana na osnovu simulacije modela i željene vrednosti klizanja i predstavljaju linearne jednakosti koje se izjednačavaju sa nulom. Definisana su dakle kao razlika klizanja, koje predviđa neuronski model u zavisnosti od trenutnih uslova kočenja, i odgovarajuće željene vrednosti klizanja. U cilju minimiziranja razlike između ove dve vrednosti klizanja točka, genetski algoritam vrši pretragu za optimalnom vrednošću pritiska u toku ciklusa kočenja. Osnovni cilj procesa optimizacije je da stvarna vrednost klizanja i vrednost klizanja definisana kao željena u odnosu na date uslove kočenja postanu jednake, pošto njihova razlika konvergira ka nuli tokom serije uzastopnih generacija pojedinaca. Kako se vrednost funkcije cilja tokom uzastopnih smena generacija približava onoj koja je definisana prema zadatom kriterijumu, pritisak aktiviranja konvergira ka optimalnoj vrednosti. Drugim rečima, kočnicu bi trebalo aktivirati sa pritiskom jednakim toj optimalnoj vrednosti da bi se ostvario moment kočenja koji će dovesti do promene klizanja definisane preko nelinearne funkcije ograničenja.

7.6.2. Razvoj neuronskog modela procesa kočenja

Performanse neuro-genetskog modela prvenstveno zavise od kvaliteta dinamičkog neuronskog modela procesa kočenja pa se njegovom razvoju mora posvetiti najveća pažnja. Razvijeni dinamički neuronski model procesa kočenja se zasniva na dinamičkoj neuronskoj mreži sa prostiranjem signala unapred i tri skrivena sloja sa 6 neurona u prvom, 4 neurona u drugom i 2 neurona u trećem skrivenom sloju. Izabrano je kašnjenje ulaznih vrednosti (pritiska, temperature i brzine) koje iznosi 0,05 s. Struktura ove neuronske mreže je dobijena na osnovu poređenja performansi predviđanja 12 različitih dinamičkih neuronskih mreža sa jednim, dva i tri skrivena sloja, pri čemu su takođe istraživane i različite kombinacije broja neurona u okviru njih. Između slojeva mreže je korišćena sigmoidna funkcija prenosa, a za njenu obuku je korišćeno prošireno gradijentno pravilo, koje je već objašnjeno u poglavljju 7.4.1.

Na slikama 7.63 i 7.64 su prikazani rezultati verifikacije modela u smislu kvaliteta predviđanja klizanja točka (za prednju osovinu). Zbog pojednostavljenja, u potpisima ispod slika su korišćeni skraćeni nazivi veličina („pritisak“ i „brzina“), što odgovara srednjem maksimalnom pritisku tokom ciklusa kočenja i početnoj brzini kočenja. U skladu sa tim, na slici 7.63 je prikazan ciklus kočenja gde srednja maksimalna vrednost pritiska iznosi 3 bar, a početna brzina 86 km/h. Srednja maksimalna vrednost temperature tokom datog ciklusa iznosi 125 °C. Uporedo sa promenom tih veličina, na slici 7.63 su prikazane i dinamičke promene stvarnog klizanja u toku datog ciklusa kočenja i klizanja koje je predvideo dinamički neuronski model procesa kočenja. Pored toga, da bi se dodatno pojasnio proces dinamičke obuke neuronskog modela, odnosno na koji način funkcioniše uključivanje/isključivanje procesa obuke, prikazana je i greška predviđanja, tj. razlika između vrednosti stvarnog i predviđenog klizanja.

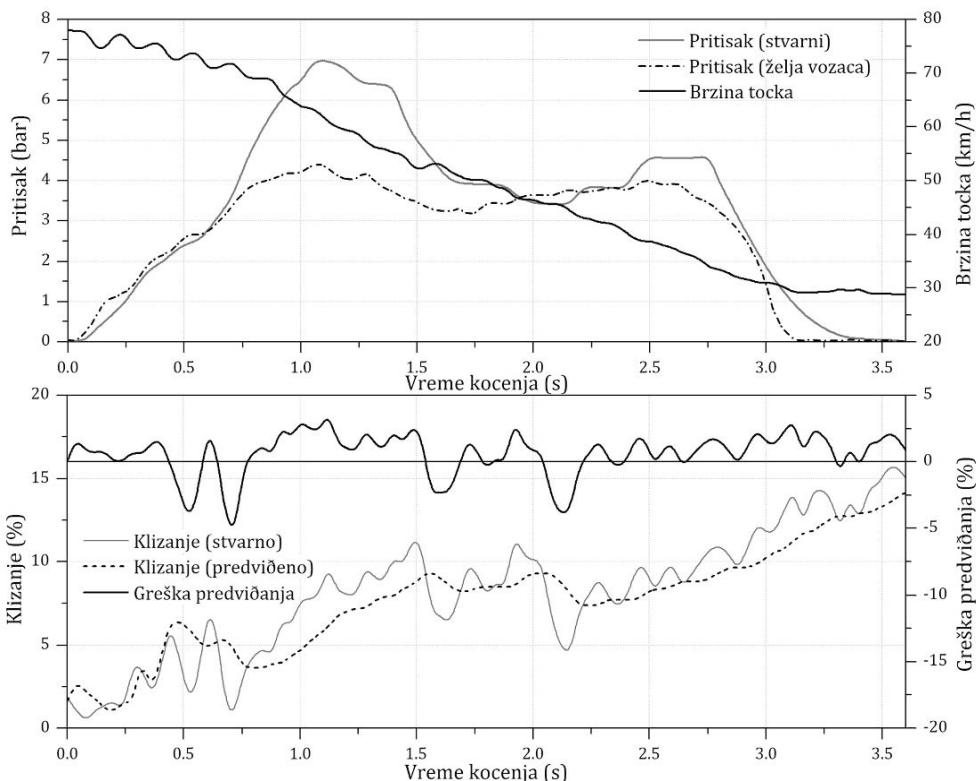


*Slika 7.63. Verifikacija performansi predviđanja dinamičkog neuronskog modela
(pritisak 3 bar, brzina 86 km/h)*

U ovom slučaju, sistem je podešen tako da se obuka dinamičkog neuronskog modela vrši kada razlika između stvarnog i predviđenog klizanja po absolutnoj

vrednosti prekorači vrednost od 1%. Na primer, ako posmatramo trenutak 2,6 s vremena kočenja (slika 7.63) vidi se da od tog trenutka pa na dalje razlika između stvarnog klizanja i onog koje predviđa neuronski model počinje da se povećava i u trenutku 2,8 s dostiže maksimum od 4 %. Do trenutka 2,7 s greška predviđanja je bila unutar tolerancije od $\pm 1 \%$, jer promena predviđenog klizanja vrlo malo odstupa od stvarnog klizanja. Dalje povećanje greške je izazvalo aktiviranje procesa dinamičke obuke neuronskog modela, što je uslovilo da model poveća predviđenu vrednost klizanja kako bi se razlika između klizanja smanjila, ali tek od trenutka 2,8 s pošto radi sa zakašnjnjem od 0,1 s (ovo kašnjenje je obeleženo na slici 7.63). U delovima ciklusa kočenja gde je razlika između vrednosti stvarnog i predviđenog klizanja bila manja od $\pm 1\%$ po absolutnoj vrednosti (4-4,4 s na primer), neuronski model nije obučavan.

Na slici 7.64 je prikazan ciklus kočenja gde je srednja maksimalna vrednost pritiska bila veća i iznosila je 6,3 bar, a početna brzina je bila 78 km/h. Srednja maksimalna vrednost temperature tokom ovog ciklusa je takođe bila veća i iznosila je 364°C . Da bi se ilustrovalo kako na predviđanje modela utiče različita vrednost greške predviđanja pri kojoj se aktivira obuka, u ovom slučaju je vrednost razlike od 2% izabrana kao ona pri kojoj se obuka modela uključuje. Karakterističan je segment ciklusa kočenja između 0,7-1,5 s, slika 7.64. Od trenutka 0,7 do 1,1 s vremena kočenja stvarni pritisak aktiviranja kočnice konstantno raste, što je indukovalo povećanje stvarnog klizanja u tom intervalu. U trenutku 0,8 s obuka neuronskog modela je aktivirana pa je i predviđeno klizanje počelo da se povećava. U trenutku 1,2 s vrednost razlike klizanja je pala ispod 2% pa je model nakratko prekinuo da se obučava. Nadalje do 1,5 s vremena kočenja, vrednost razlike je vrlo bliska graničnoj vrednosti od 2% pa je obuka modela bila povremeno aktivirana, što se može videti po promeni predviđenog klizanja, koje je model korigovao sa ukupnim zakašnjnjem od 0,1 s.



Slika 7.64. Verifikacija performansi predviđanja dinamičkog neuronskog modela (pritisak 6,3 bar, brzina 78 km/h)

7.6.3. Mogućnosti primene neuro-genetskog pristupa za optimizaciju pritiska aktiviranja kočnice

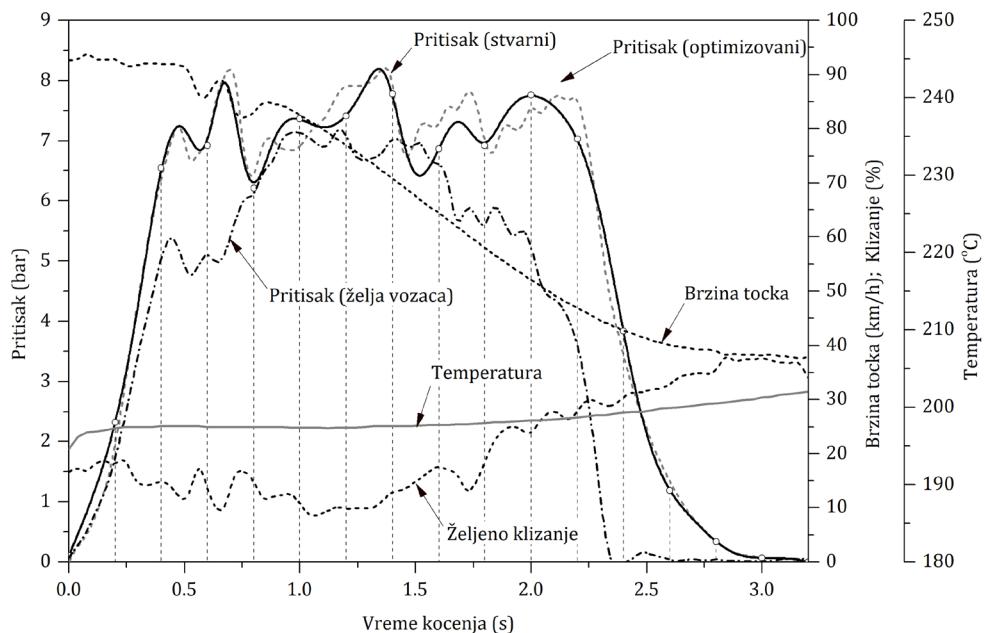
Istraživanja u pogledu mogućnosti upotrebe kombinovanog neuro-genetskog pristupa za dinamičko podešavanje pritiska aktiviranja kočnice su izvršena uz pomoć solvera za rad sa genetskim algoritmima, raspoloživog u okviru programskog paketa Matlab 7.11. Izabrani su ciklusi kočenja obavljeni u neopterećenom i opterećenom stanju vozila, koji se odnose na kočnicu na prednjoj osovini (slike 7.65-7.67). U slučaju ciklusa kočenja koji je prvo analiziran (slika 7.65), u cilju verifikacije optimizovanog pritiska za željenu dinamičku promenu klizanja je izabrana poznata dinamička promena klizanja u toku ciklusa (za date promene stvarnog pritiska, brzine točka i temperature kočnice), a to je stvarno klizanje. U tom slučaju je stvarno klizanje isto što i željeno. Treba napomenuti da se uloga stvarnog pritiska, čiji rezultat je stvarno klizanje u kontaktu pneumatika i puta, u svim analiziranim slučajevima svodi na to da se optimizovani pritisak

uporedi sa njim, kako bi se proverio kvalitet optimizacije pritiska. Svi prikazani rezultati (slike 7.65-7.67) su dobijeni pomoću testiranja neuro-genetskog modela pod istim uslovima. Ti uslovi podrazumevaju da je korišćena početna populacija od 10 pojedinaca, funkcija selekcije hromozoma je ravnomerna nasumična, dok je stepen ukrštanja jednak 0,8. Izabran je koeficijent mutacije od 0,75, dok je tzv. „broj elitnih pojedinaca“ bio podešen na 2.

Kao što je već istaknuto u poglavlju 7.6, osnovni problem kod primene neuro-genetskog pristupa za modeliranje rada sistema u dinamičkim uslovima predstavlja previše dugo vreme potrebno da genetski algoritam pronađe optimalno rešenje, odnosno u ovom slučaju optimalnu vrednost pritiska aktiviranja kočnice. Zbog toga je ovde najpre istraživano koliko vreme je potrebno da se obavi jedna smena generacija, na osnovu koje će genetski algoritam da pronađe optimalnu vrednost pritiska aktiviranja kočnice u datom trenutku. Pri tome treba napomenuti da se može smatrati da računar na kome je vršeno testiranje poseduje prosečne mogućnosti u pogledu performansi. U slučaju računara sa drugačijim performansama, vreme potrebno za pronalaženje optimalne vrednosti pritiska aktiviranja kočnice neće biti isto. Takođe treba imati u vidu da genetski algoritam uvek nasumično bira početnu populaciju pojedinaca (osim ako se to ne onemogući), odnosno da ona nikad nije ista, što takođe ima veliki uticaj na trajanje procesa optimizacije do prve smene generacija. Na brzinu pronalaženja optimalnog pritiska mogu značajno da utiču i neki drugi parametri (na primer stepen ukrštanja, koeficijent mutacije, broj „elitnih“ pojedinaca, itd.). Njihov uticaj nije posebno analiziran u ovom radu pa su korišćeni isti parametri u svim primerima, kao što je navedeno u prethodnom paragrafu.

Na slici 7.65 su prikazane promene pritiska aktiviranja kočnice dobijenog pomoću neuro-genetskog modela i ostalih veličina koje karakterišu radni režim kočnice i stanje u kontaktu pneumatik-tlo (temperatura kočnice, translatorna brzina točka i klizanje točka). U ovom slučaju, pokazani su rezultati istraživanja gde je genetski algoritam podešen da vrši samo jednu smenu generacija prilikom određivanja jedne vrednosti pritiska aktiviranja kočnice. Pošto je u pitanju samo jedna smena generacija, optimizovani pritisak u pojedinim delovima ciklusa

kočenja odstupa i do 1 bar u odnosu na stvarni pritisak aktiviranja kočnice, slika 7.65. Imajući u vidu veliki broj podataka u okviru jednog ciklusa kočenja, promena optimizovanog pritiska je formirana na osnovu tačaka koje predstavljaju srednju vrednost pritiska za deset uzastopnih podataka o klizanju, temperaturi i brzini točka.



Slika 7.65. Uporedni prikaz stvarnog i optimizovanog pritiska pomoću neurogenetskog modela (neopterećeno stanje vozila)

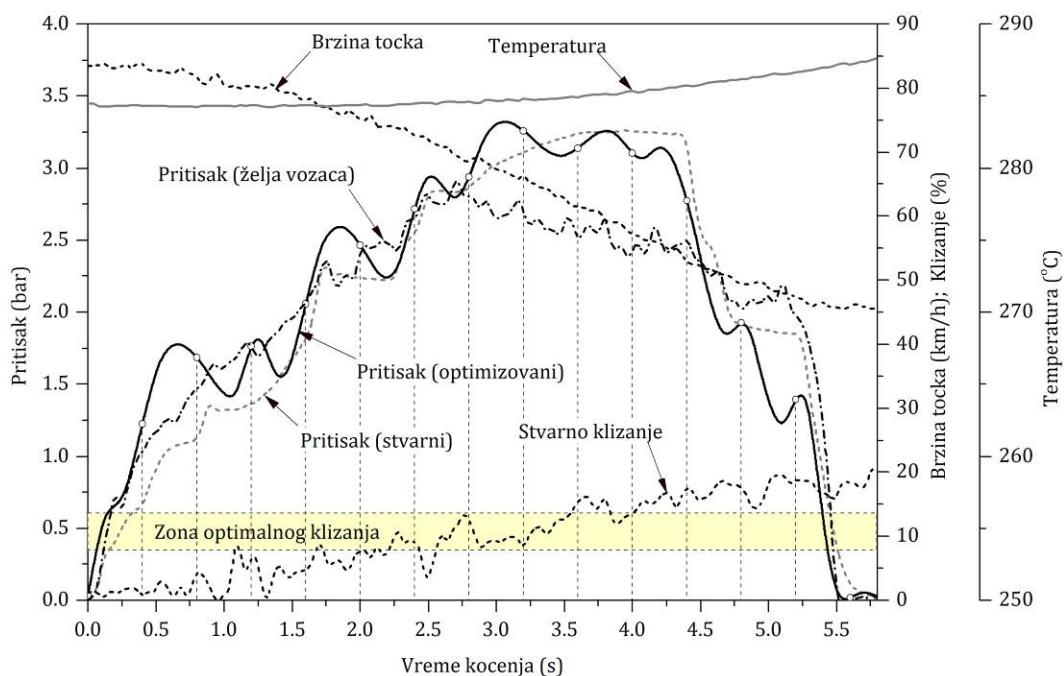
Od početka procesa optimizacije sa početnom populacijom od deset hromozoma pa do prve smene generacija izmereno je vreme od 19 s. Pri tome je posebno važno uzeti u obzir činjenicu da jedna smena generacija može vremenski da traje i do nekoliko puta duže od trajanja samog ciklusa kočenja. Već na osnovu ovog najjednostavnijeg slučaja (samo jedna smena generacija u trajanju od 19 s), evidentno je da je kašnjenje neuro-genetskog modela preveliko i da takvo predstavlja glavnu prepreku ovoj metodi za aktivnu primenu u dinamički promenljivim radnim uslovima tokom procesa kočenja. Ako bi svaka od 17 vrednosti optimizovanog pritiska u toku ovog ciklusa kočenja bila određena tokom jedne smene generacija, iz toga proizilazi da bi za sve bilo potrebno ukupno vreme od 323 s, što je nešto više od 5,5 minuta. Da bi se to i pokazalo, na primeru ovog i još dva ciklusa kočenja su izvršene analize uticaja promene pojedinih parametara

genetskog algoritma na vreme koje je potrebno da genetski algoritam pronađe optimalnu vrednost pritiska aktiviranja kočnice u statičkim, tzv. „offline“ uslovima. Pored toga, na dijagramima prikazanim na slikama 7.66 i 7.67 su istovremeno prikazana poređenja kako EBS sistem trenutno radi (stvarni pritisak aktiviranja koji za date promene brzine točka i temperature kočnice dovodi do promene stvarnog klizanja točka u podužnom pravcu) i kako bi radio u slučaju unapređenja putem uvođenja inteligentnog upravljanja. To pre svega podrazumeva dovođenje klizanja točka na željeni (optimalni) nivo pri kome je moguće ostvariti maksimalno prijanjanje u kontaktu pneumatik-tlo.

U skladu sa tim, na primeru ciklusa kočenja sa slike 7.66, koji se odnosi na opterećeno stanje vozila, istraživano je kako će se neuro-genetski model ponašati u slučaju kada se optimizacija vrši pod istim uslovima (isti parametri rada genetskog algoritma, isti računar, itd.), ali kada dođe do promene uslova pod kojima se vrši kočenje. To dakle znači da je u tom slučaju istraživano na koji način promena radnih režima kočnice i uslova u kontaktu pneumatik-tlo utiče na trajanje procesa optimizacije do prve smene generacija. Pri tome je veoma važno napomenuti da je zadržana i početna populacija od 10 pojedinaca, kako bi rezultati mogli da se uporede sa rezultatima iz prethodnog slučaja (prikazanih na slici 7.65). Kao i u prethodnom slučaju, genetski algoritam je podešen da vrši samo jednu smenu generacija, a promena optimizovanog pritiska je takođe formirana na osnovu tačaka koje predstavljaju srednju vrednost pritiska za deset uzastopnih podataka o klizanju, temperaturi i brzini točka. Vreme do prve smene generacija je duže nego u prethodnom slučaju i iznosilo je 22 s.

Ako posmatramo rezultate optimizacije pritiska aktiviranja kočnice u ovom slučaju (slika 7.66), može se videti da je stvarno klizanje (koje odgovara stvarnom pritisku aktiviranja kočnice) u delovima ciklusa između 0-2 s i od 3,6 s pa do kraja ciklusa van opsega u kome je moguće ostvariti maksimalno prijanjanje. Pri tome treba imati u vidu da se pod stvarnim pritiskom podrazumeva pritisak koji je izmeren tokom datog ciklusa kočenja, a ne korigovana vrednost pritiska kojom je trenutno aktivirana kočnica. Maksimalno prijanjanje u slučaju ovog ciklusa kočenja se postiže za vrednosti klizanja između 8-14%, pri čemu je taj opseg proglašen kao

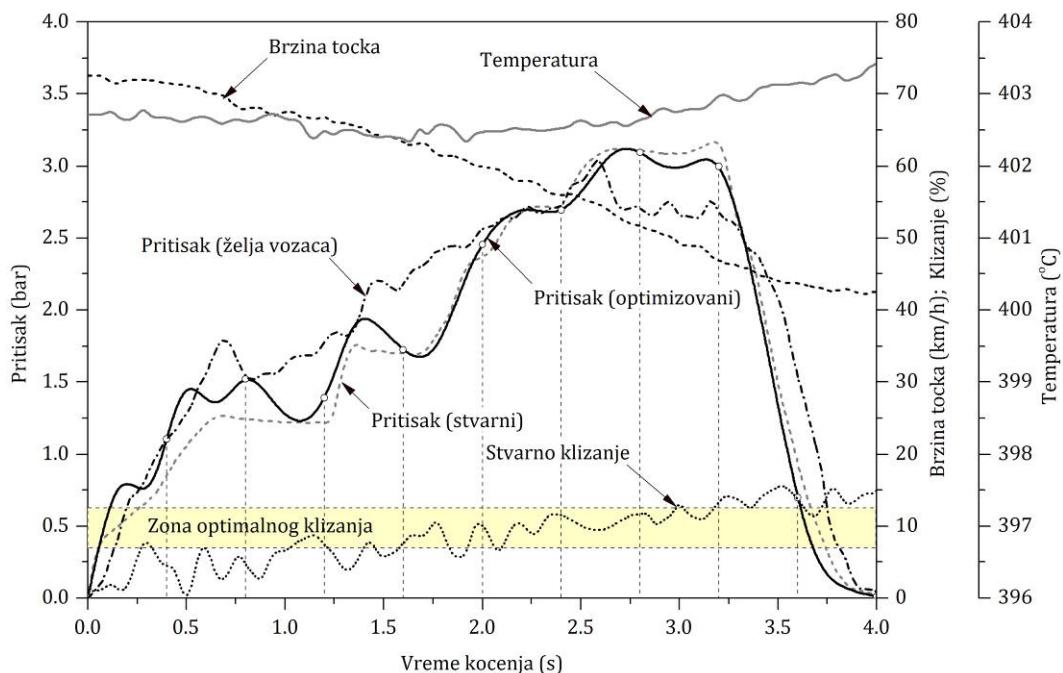
zona optimalnog klizanja (slika 7.66). Tokom prvih 0,7 s ciklusa kočenja neurogenetski kontroler je povećao pritisak na 1,8 bar, što je više za 0,8 bar od stvarnog pritiska u trenutku 0,7 s, da bi se klizanje točka dovelo u optimalnu zonu. U trenucima gde je stvarno klizanje u okviru optimalne zone (na primer 1,2 s, 2-2,4 s, 3,9 s, 4,8 s), vrednosti optimizovanog pritiska su bliske sa vrednostima stvarnog pritiska, slika 7.66. Na osnovu dinamičkog modela neuro-genetski kontroler je predvideo da treba smanjiti klizanje u odnosu na stvarno u krajnjem delu ciklusa posle 3,6 s pa je i vrednost optimizovanog pritiska usklađena sa time, odnosno smanjena u odnosu na stvarni pritisak aktiviranja kočnice. Kao što se može videti sa slike 7.66, karakteristično je smanjenje optimizovanog pritiska od 0,6 bar u trenutku 5,1 s, kako bi se doseglo maksimalno prijanjanje točka.



Slika 7.66. Primer optimizacije pritiska pomoću neuro-genetskog modela (opterećeno vozilo)

Dalja istraživanja su sprovedena u pravcu analize uticaja većeg broja smene generacija tokom procesa optimizacije. U tu svrhu je izabran ciklus kočenja koji se odnosi na neopterećeno stanje vozila, prikazan na slici 7.67. Razlika u odnosu na prethodno analizirane slučajevе je u tome što je kriterijum za zaustavljanje procesa optimizacije bila realizacija 10 uzastopnih smena generacija. Vreme trajanja jedne smene generacija je u ovom slučaju iznosilo 20 s. S obzirom na

ukupno vreme trajanja procesa optimizacije pritiska aktiviranja kočnice, koje je posledica pomenutih deset uzastopnih smena generacija, dobija se ukupno kašnjenje neuro-genetskog modela u sistemu (u odnosu na samo jednu vrednost optimizovanog pritiska), koje iznosi 110 s, odnosno nešto manje od 2 minuta. Sve ovo važi pod pretpostavkom da tokom procesa optimizacije ne dođe do zarobljavanja genetskog algoritma u nekom od lokalnih ili globalnih minimuma. U skladu sa tim, da bi se optimizovao pritisak tokom celog ciklusa kočenja, ukupno kašnjenje genetskog algoritma bi iznosilo 21 minut. Imajući u vidu veći broj smena generacija, genetski algoritam je u ovom slučaju imao na raspolaganju više vremena da konvergira ka optimalnoj vrednosti pritiska aktiviranja kočnice.

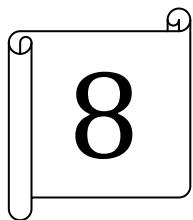


Slika 7.67. Primer optimizacije pritiska pomoću neuro-genetskog modela (neopterećeno vozilo)

Sa slike 7.67 se vidi da je u ovom slučaju zona optimalnog klizanja između 7-13%, pri čemu stvarno klizanje pripada ovoj zoni u delu ciklusa između 1,5-3,2 s. Tokom prvih 0,25 s kočenja kontroler je povećao optimizovani pritisak za 0,2 bar u odnosu na stvarni. U trenutku 0,3 s stvarno klizanje je na donjoj granici optimalne zone pa je kontroler uskladio pritisak u tom trenutku i povećao ga na 0,7 bar. To se takođe dogodilo i u trenucima 0,6 s i 1,2 s (slika 7.67). Nasuprot tome, u trenucima gde je stvarno klizanje daleko od optimalne zone (0,5 s, 0,8 s i 1,3 s), kontroler je

povećao pritisak da bi se podužno klizanje dovelo u optimalnu zonu. U delu ciklusa gde stvarno klizanje pripada optimalnoj zoni neuro-genetski kontroler je optimizovao pritisak aktiviranja kočnice, čija promena vrlo malo odstupa od promene stvarnog pritiska. Od 3,2 s pa sve do kraja ciklusa kontroler je smanjio optimizovani pritisak u odnosu na stvarni imajući u vidu da je stvarno klizanje izašlo iz opsega u kome je ostvarivo maksimalno prijanjanje (slika 7.67).

Prikazani rezultati istraživanja pokazuju da ovakav kombinovani, neurogenetski, pristup ima potencijal za realizaciju ovako važnih zadataka kao što je inteligentno upravljanje klizanjem u kontaktu pneumatik-tlo. Međutim, pošto je kočenje izrazito dinamički i nelinearan proces, na osnovu istraživanja sprovedenih u ovom radu i analiza različitih rešenja za optimizaciju parametara dinamičkih sistema pomoću genetskih algoritama [90,91,92,93], može se doći do zaključka da genetski algoritmi ne daju očekivane rezultate u pogledu brzine pronalaženja optimalnog rešenja koja se zahteva od sistema za dinamičko upravljanje performansama kočnice u toku ciklusa kočenja. Kao što je pokazano pomoću rezultata prikazanih na slikama 7.65-7.67, genetski algoritmi u kombinaciji sa veštačkim neuronskim mrežama predstavljaju veoma koristan alat za potrebe optimizacije statičkih i kvazi-statičkih sistema. Sa druge strane, njihova sporost, delimično uzrokovana i time što su u principu tehnika globalnog pretraživanja, predstavlja ograničavajući faktor za primenu kod izrazito dinamičkih sistema. To potvrđuje i činjenica da jedna smena generacija tokom simulacije rada neurogenetskog modela može da traje i do nekoliko minuta. Upotreba takvog sistema za upravljanje klizanjem točka tokom procesa kočenja, gde se traži brz odziv u desetim delovima sekunde, prema tome nije moguća. Osim nemogućnosti primene genetskih algoritama kod upravljanja dinamičkim sistemom u realnom vremenu, u [90] je pokazano da su veštačke neuronske mreže kao metoda znatno preciznije u pronalaženju traženog rešenja, pa je u ovoj doktorskoj disertaciji više pažnje tokom istraživanja posvećeno ostalim metodama iz oblasti veštačke inteligencije.



ZAKLJUČAK

Unapređenje aktivne bezbednosti motornih vozila nameće potrebu da se performanse motornih vozila, a time i kočnog sistema, neprekidno unapređuju kroz uvođenje inovativnih i inteligentnih rešenja u oblasti rada kočnih sistema. Razvoj inteligentnih kočnih sistema motornih, a posebno privrednih vozila, u cilju obezbeđenja uslova za tzv. intelligentno kočenje, dovodi do potrebe razvoja motornih vozila koja trebaju da ponude budućem korisniku viši nivo aktivne bezbednosti. Uvođenje intelligentnog upravljanja performansama kočnog sistema motornog vozila, naročito u različitim, dinamički promenljivim, radnim uslovima, nametnulo je potrebu da se u ovoj doktorskoj disertaciji sprovedu istraživanja različitih problema u vezi sa funkcijom kočnog sistema, mogućnostima intelligentnog upravljanja njegovim performansama, a time i performansama kočnica, kao i problema koji su vezani za složenu interakciju pneumatik-tlo. Posebno su u fokusu bili problemi u vezi sa mogućnostima realizacije dinamičkog modeliranja, predviđanja i upravljanja performansama kočnica, a time i kočnog sistema, odnosno intelligentnog upravljanja podužnim klizanjem u kontaktu pneumatika i tla u toku ciklusa kočenja. Zbog svega toga, analizirane su mogućnosti primene tehnika iz oblasti veštačke inteligencije, kao što su veštačke neuronske mreže, fazi logika i genetski algoritmi.

Polazne prepostavke na osnovu kojih su sprovedena istraživanja u ovoj doktorskoj disertaciji se odnose na to da se intelligentnim upravljanjem pritiskom aktiviranja kočnice mogu uskladiti performanse kočnica sa trenutno važećim uslovima prijanjanja između pneumatika i tla. Pored toga, polazi se od toga da se intelligentnim upravljanjem pritiskom aktiviranja kočnica može postići maksimum prijanjanja pneumatika u podužnom pravcu, odnosno intelligentno upravljanje klizanjem točkova pri kočenju vozila na pravcu. Dinamičko modeliranje, predviđanje i upravljanje performansama kočnica a time i kočnog sistema, za date

radne uslove kočnica, odnosno inteligentno upravljanje podužnim klizanjem točka može biti izvršeno ukoliko postoje modeli kojima se uspostavlja kompleksna, dinamički promenljiva, funkcionalna korelacija između pritiska aktiviranja kočnice i podužnog klizanja točka. Pored uticaja pritiska aktiviranja kočnice, kao jednog od najvažnijih uticaja na ostvareni moment kočenja, potrebno je uzeti u obzir i značajan uticaj translatorne brzine točka i temperature u kontaktu friкционog para kočnice u toku ciklusa kočenja. U tesnoj vezi sa tim je i pretpostavka da je modeliranje, odnosno razvoj dinamičkog modela procesa kočenja, moguće realizovati pomoću metoda čiji se rad bazira na paralelnom procesiranju eksperimentalno dobijenih podataka tokom procesa kočenja, odnosno koje obezbeđuju učenje i intelligentno prilagođavanje promenama velikog broja parametara koji utiču na performanse kočnice, tj. vrednost klizanja u kontaktu pneumatika i tla.

U skladu sa navedenim polaznim pretpostavkama, da bi se uspešno realizovali ciljevi istraživanja u okviru ove doktorske disertacije najpre se pošlo od analize osnovnih karakteristika kočnih sistema privrednih vozila i zahteva koji se postavljaju pred savremene kočne sisteme motornih vozila. Osnovni problem koji je vezan za rad današnjih kočnica motornih vozila, koje svoju funkciju realizuju na principima trenja, je nepredvidivost, odnosno stohastičnost procesa kočenja kao rezultat vrlo složene interakcije između elemenata friкционog para kočnice, tj. kočnog diska i friкционog materijala (disk pločice). Funkcionalne karakteristike kočnica motornih vozila su zato teško predvidive i vrlo često izrazito nestabilne tokom složenih radnih režima kojima su one izložene, a to se javlja kao posledica uticaja velikog broja fenomena u kontaktu friкционog para kočnice koji su analizirani u ovoj disertaciji. U okviru daljih istraživanja su analizirane karakteristike postojećih elektronski upravljenih sistema koji svoju funkciju relaizuju preko kočnog sistema i to pre svega ABS-a, ESC-a i EBS-a i kako njihov rad utiče na performanse kočnog sistema. Na osnovu toga i izvršenih eksperimentalnih istraživanja, identifikovane su mogućnosti za dalje unapređenje rada postojećih elektronskih sistema za upravljanje performansama kočnog sistema. Na osnovu prikazanih rezultata rada postojećeg EBS sistema u ovoj disertaciji, posebno u

odnosu na način upravljanja promenom podužnog klizanja u kontaktu pneumatik-tlo u zavisnosti od promene uslova u kojima se kočenje obavlja, identifikovan je značajan prostor za dalje unapređenje EBS sistema, odnosno uvođenje intelligentnih rešenja u njegovom radu. Na osnovu prikazanih rezultata evidentno je da podužno klizanje točka često nije u optimalnim granicama tokom celog ciklusa kočenja ili dela ciklusa kočenja, odnosno klizanje točka nije na nivou koje odgovara maksimalnom prijanjanju u podužnom pravcu. Zbog toga je razvijena nova metoda intelligentnog upravljanja performansama kočnog sistema privrednog vozila opremljenog elektronski upravljanim kočnim sistemom (EBS), kako bi se u kontaktu pneumatika i tla ostvarila željena/optimalna dinamička promena klizanja u podužnom pravcu i time maksimizirale kočne performanse vozila pri kočenju na pravcu.

U skladu sa postavljenim ciljevima disertacije, kao i polaznom pretpostavkom da je modeliranje procesa kočenja moguće realizovati pomoću metoda čiji se rad bazira na paralelnom procesiranju eksperimentalno dobijenih podataka, u disertaciji su prikazani rezultati koji pokazuju da je moguće razviti dinamički model procesa kočenja i obezbediti intelligentno upravljanje performansama kočnog sistema. Pokazano je takođe da je moguće razviti takve osobine dinamičkog modela koji može da uči, kada se pojave greške u njegovom radu, odnosno da uči iz novih situacija koje su mu do tog trenutka bile nepoznate. Dakle, razvijena je jako važna osobina dinamičkog modela, a to je intelligentno prilagođavanje promenama parametara (pritiska aktiviranja kočnice, translatorne brzine točka, temperature kočnice i promene stvarnog klizanja u kontaktu pneumatik-tlo) koji utiču na performanse kočnice, odnosno na vrednost podužnog klizanja u kontaktu pneumatik-tlo.

U cilju analize više mogućih rešenja za razvoj dinamičkog modela procesa kočenja, sposobnog da izvrši dinamičko modeliranje i predviđanje, kao i da omogući kasnije upravljanje performansama kočnog sistema, u ovoj disertaciji je razvijeno i analizirano više različitih neuronskih, neuro-fazi i neuro-genetskih dinamičkih modela zasnovanih na tzv. modelu četvrtine vozila. Prikazani rezultati u disertaciji se odnose na uslove prijanjanja na suvoj asfaltnoj podlozi, sa

razrađenim kočnim oblogama i srednje pohabanim pneumaticima namenjenim za letnje uslove eksploracije. Na osnovu rezultata istraživanja dobijenih korišćenjem modela četvrtine vozila, pokazano je da je moguće razviti dinamički neuronski i neuro-fazi model koji može uspešno da modelira i predviđa posmatrane uticaje na performanse kočnice, odnosno na interakciju pneumatika i tla tokom procesa kočenja, što dalje omogućava dinamičko inteligentno podešavanje pritiska aktiviranja kočnice u toku ciklusa kočenja na vrednost koja obezbeđuje željeni nivo podužnog klizanja u kontaktu pneumatika i puta, uzimajući u obzir zahteve vozača. Važno je napomenuti da razvijeni dinamički modeli omogućuju prilagođavanje promenama karakteristika kočnice, stanja opterećenja vozila, pneumatika i podloge, što pokazuje njihovu značajnu mogućnost prilagođavanja promeni velikog broja parametara koji utiču na izlazne performanse kočnog sistema. Uvođenje dinamičkih veštačkih neuronskih mreža u postupak razvoja inteligentno upravljanog kočnog sistema je u ovoj disertaciji omogućilo modeliranje dinamički promenljive funkcionalne korelacije između pritiska aktiviranja kočnice i podužnog klizanja točka, translatorne brzine točka i temperature u kontaktu friкционog para kočnice u toku ciklusa kočenja, i to kroz razvoj inverzne veze između ovih veličina, odnosno razvoj inverznog dinamičkog modela procesa kočenja. Inverzni dinamički model je razvijen na osnovu dinamičke neuronske mreže sa prostiranjem signala unapred i jednim skrivenim slojem sa 10 neurona, koja je izabrana na osnovu poređenja performansi predviđanja ukupno 42 različita dinamička neuronska modela. Istraživano je po 14 arhitektura mreža sa jednim, dva i tri skrivena sloja i različitim kombinacijama broja neurona u okviru njih. Dinamičke neuronske mreže su obučavane pomoću tri algoritma obuke: Levenberg-Marquardt (LM), Bayesian Regularization (BR) i Resilient Backpropagation (RP), respektivno. Da bi se obezbedila što bolja i efikasnija obuka dinamičkih neuronskih mreža u „offline“ režimu, od ukupno 194 izabrano je 78 ciklusa kočenja. Od toga se 40 kočenja odnosi na neopterećeno stanje vozila, a preostalih 38 kočenja se odnosi na opterećeno stanje vozila. Za testiranje neuronskih mreža u pogledu njihove sposobnosti generalizacije iskorišćeno je ukupno 60631 podataka (33013 u neopterećenom i 27618 u opterećenom stanju vozila). Ova dva skupa podataka su pažljivo formirana sa ciljem da se uspostavi

relativno ravnomerna raspodela radnih režima kočnice. Za razvoj dinamičkog modela, kao upravljačkog (softverskog) dela budućeg kontrolera, je izabrana NARX rekurentna dinamička neuronska mreža. Shodno tome je najpre razvijen dinamički neuronski model, obučavanjem NARX rekurentne mreže u tzv. „offline“ režimu, kako bi se dobole inicijalne vrednosti težinskih odnosa i za to je bilo raspoloživo ukupno 228327 podataka (194 ciklusa kočenja). Obuka dinamičkih neuronskih mreža je obavljena sa početnom vrednošću ulaznog kašnjenja od 0,01 sekundi. Izmerena (stvarna) vrednost pritiska aktiviranja kočnice takođe kasni 0,01 s kao sekundarni ulaz u serijsko-paralelnu formu NARX mreže. Značaj toga se ogleda u činjenici da su na taj način prošle vrednosti ulazno/izlaznih parametara, koje nose informacije o istoriji njihovih dinamičkih promena, prezentovane mreži preko ulaznih i izlaznih kašnjenja. U oba slučaja (model za prednju i model za zadnju osovinu) najbolje performanse predviđanja su ostvarene pomoću NARX rekurentnih neuronskih mreža sa jednim skrivenim slojem koji sadrži deset neurona, pri čemu je relativno visok nivo generalizacije postignut obučavanjem pomoću Bayesian Regularization algoritma. Inverzni dinamički model ima tri ulaza. To su ulazni vektor u mrežu, signal o grešci između predviđanja modela i stvarnog pritiska aktiviranja i signal za aktiviranje/deaktiviranje procesa obuke mreže. Kašnjenje ulaznih vrednosti u odnosu na trenutnu vrednost tokom procesa obuke mreže, na osnovu kojih je obuhvaćen uticaj istorije dinamičke promene ulaznih veličina na njihove trenutne vrednosti, iznosilo je 0,01 s. Značaj razvoja inverznog dinamičkog modela procesa kočenja, koji predviđa pritisak aktiviranja kočnice, u zavisnosti od stvarne promene podužnog klizanja pneumatika, translatorne brzine točka i temperature kočnice, je u tome što se na taj način omogućilo istovremeno učenje o funkcionalnoj vezi između pomenutih veličina sa svakim novim kočenjem, a u skladu sa tim i usklađivanje predviđanja modela sa novonastalim promenama. Na osnovu podešenih vrednosti težinskih odnosa između neurona, razvijeni inverzni dinamički model čuva znanje o modeliranom procesu, tj. pamti kakav je prošli i sadašnji uticaj dinamičke promene klizanja točka, temperature kočnice i brzine točka imaju na dinamičku promenu pritiska aktiviranja kočnice. Ovako razvijeni dinamički model procesa kočenja pruža mogućnosti da se budući inteligentni kočni sistem dodatno prilagodi novim uslovima kočenja (promena

podloge po kojoj se koči, zamena pneumatika, zamena kočnih obloga i/ili diska, itd.), pri čemu ne dolazi do gubitka prethodno stečenog znanja o tom procesu.

Pored razvijenog inverznog dinamičkog modela procesa kočenja korišćenjem dinamičkih neuronskih mreža, u ovoj disertaciji su prikazani rezultati istraživanja koja se odnose na razvoj dodatne, redundantne, funkcije budućeg intelligentnog kočnog sistema, bazirane na fazi logici, koja je integrisana sa neuronskim modelima procesa kočenja na prednjoj i zadnjoj osovini. Kako bi se dodatno unapredio rad inverznog dinamičkog modela procesa kočenja, razvijen pomoću veštačkih neuronskih mreža, u smislu eliminacije, odnosno smanjenja moguće greške, kada treba izvršiti modeliranje i predviđanje pritiska aktiviranja kočnice u uslovima rada kočnog sistema koji su nepoznati neuronskom modelu, razvijena je integrisana fazi podrška inverznom dinamičkom modelu procesa kočenja. Značaj razvoja novog, hibridnog, neuro-fazi modela procesa kočenja se ogleda u tome što je na taj način omogućeno da se trenutni pritisak aktiviranja kočnice, koji predviđa inverzni dinamički neuronski model dodato koriguje ukoliko za to postoji potreba, odnosno ukoliko postoji određeno odstupanje tog pritiska od vrednosti koja bi dovela točak na željeni nivo podužnog klizanja. Uvođenjem fazi logičkog pristupa kao ekspertske podrške upravljanju klizanjem točka pomoću dinamičkih veštačkih neuronskih mreža je obezbeđena redundantna funkcija budućeg intelligentnog kočnog sistema u gore navedenim slučajevima. To je pre svega važno u trenucima kada sistem radi sa neprihvatljivo visokom greškom predviđanja, tj. kada je predviđena vrednost pritiska aktiviranja kočnice od strane inverznog dinamičkog neuronskog modela nerealna i/ili neodgovarajuća u odnosu na želju vozača i/ili stvarnu vrednost pritiska aktiviranja kočnice u tom trenutku. S tim u vezi je pokazano da je moguće uspešno integrisati fazi logiku sa dinamičkim neuronskim mrežama u razvoju kočnog sistema sa intelligentnim osobinama, odnosno implementirati ekspertsко znanje u budući intelligentni kočni sistem za upravljanje performansama kočnog sistema. To je u ovoj doktorskoj disertaciji pre svega podrazumevalo kombinovanje fazi logike sa metodom dinamičkih veštačkih neuronskih mreža u cilju razvoja hibridnog, neuro-fazi modela (kao osnove za razvoj neuro-fazi kontrolera) za upravljanje performansama disk kočnice

privrednih vozila, odnosno upravljanje podužnim klizanjem točka u kontaktu sa površinom puta. Razvoj hibridnog neuro-fazi dinamičkog modela je omogućio da se upravlja podužnim klizanjem točka tokom kočenja na inteligentniji način, čime su stvoreni uslovi za implementaciju neuro-fazi kontrolera za upravljanje pritiskom aktiviranja kočnica. Razvijeni neuro-fazi sistem za intelligentno upravljanje pritiskom aktiviranja kočnice svoju funkciju bazira na praćenju razlike između stvarnog pritiska aktiviranja kočnica, pritiska koji zahteva vozač i predviđenog pritiska pomoću inverznog neuronskog modela procesa kočenja. Na osnovu poznavanja ove razlike budući intelligentni kočni sistem ima mogućnost da odlučuje o potrebi korekcije predviđenog pritiska od strane dinamičkog inverznog neuronskog modela kako bi se klizanje u kontaktu pneumatik-tlo dovelo na željeni/optimalni nivo. Odluku o tome donosi na osnovu trenutnih vrednosti ulaznih parametara (razlike između željenog i stvarnog klizanja, trenutnih vrednosti stvarnog pritiska aktiviranja, pritiska koji zahteva vozač i vrednosti pritiska koju predlaže neuronski model). Fazi logički deo neuro-fazi modela procesa kočenja, koji služi za intelligentnu selekciju pritiska aktiviranja kočnica, je razvijen na osnovu Mamdanijeve metode zaključivanja i odgovarajućih fazi logičkih „ako-onda“ pravila. Da bi se opisala sva moguća stanja neuro-fazi sistema intelligentnog upravljanja tokom njegovog rada, definisano je ukupno 194 fazi logičkih („ako-onda“) pravila, čime je obezbeđeno upravljanje performansama kočnog sistema u neodređenim situacijama u kojima on može da se nađe. Rezultati testiranja rada sistema intelligentnog upravljanja, zasnovanog na neuro-fazi pristupu, pokazuju da neuro-fazi sistem za upravljanje pritiskom aktiviranja kočnica može da uspešno predviđi i/ili dodatno podeši pritisak aktiviranja kočnice u toku ciklusa kočenja u različitim situacijama, odnosno uslovima kočenja kada god vrednost predviđenog pritiska nije bila usklađena sa željenim nivoom podužnog klizanja točka.

U disertaciji je pokazano, kroz testiranje performansi razvijenih neuronskih i neuro-fazi modela, da je moguće modelirati i predvideti vrednost pritiska aktiviranja kočnice u toku ciklusa kočenja, koji omogućuje postizanje optimalne vrednosti podužnog klizanja u kontaktu pneumatika i tla. Na osnovu rezultata

testiranja dinamičkih modela, tj. na osnovu poređenja predviđenih promena pritisaka aktiviranja kočnice sa pritiscima aktiviranja koji su izmereni tokom eksperimentalnih istraživanja, na prednjoj i zadnjoj osovini, pokazano je da je moguće razviti dinamički neuronski i neuro-fazi model koji funkcionalno aproksimira posmatrane uticaje, sa dovoljnom tačnošću, u toku ciklusa kočenja. Dalje je pokazano da se uvođenjem ove nove metode modeliranja, predviđanja i upravljanja pritiscima aktiviranja kočnica na prednjoj i zadnjoj osovini, može postići optimalni nivo klizanja u kontaktu pneumatik tlo i time maksimizirati kočne performanse vozila, što je od presudnog značaja za unapređenje aktivne bezbednosti vozila. Pored toga, otvorena je mogućnost da se razvijeni dinamički model procesa kočenja iskoristi, osim za dinamičko predviđanje pritiska aktiviranja kočnice i/ili klizanja u kontaktu pneumatik-tlo, i za izračunavanje dinamičke promene koeficijenta prijanjanja u toku ciklusa kočenja.

U skladu sa naučnim ciljevima disertacije, istraživanja u pogledu mogućnosti primene metoda veštačke inteligencije u ovoj disertaciji su vršena i u pravcu da li je i kako moguće koristiti genetske algoritme za dinamičko određivanje optimalne vrednosti pritiska aktiviranja kočnice kako bi se ostvarilo željeno klizanje u kontaktu pneumatika i tla. Kao i u slučaju fazi logike, fokus istraživanja je bio usmeren na razvoj nove metode za intelligentno upravljanje performansama kočnice kombinovanjem mogućnosti veštačkih neuronskih mreža i genetskih algoritama. Da bi se pronašla vrednost pritiska aktiviranja kočnice koja za dati režim rada kočnice, karakteristike pneumatika i tla i trenutne uslove prijanjanja u kontaktu pneumatik-tlo dovodi do željene promene klizanja točka, u disertaciji je razvijen nov neuronski model procesa kočenja koji nije inverzan. Razvijen je i istraživan nov dinamički neuronski model procesa kočenja, pomoću koga je uspostavljena dinamička funkcionalna zavisnost između pritiska aktiviranja kočnice, brzine točka i temperature kočnice, sa jedne strane, i klizanja u kontaktu pneumatik-tlo, sa druge strane. Razvijeni dinamički neuronski model se zasniva na dinamičkoj NARX rekurentnoj neuronskoj mreži obučavanoj pomoću Bayesian Regularization algoritma, koja ima jedan skriveni sloj sa deset neurona. Na osnovu rezultata testiranja ovog modela, koji su prikazani u disertaciji, je pokazano da

ovakav kombinovani neuro-genetski pristup ima potencijala za realizaciju važnih zadataka kao što je inteligentno upravljanje pritiskom aktiviranja kočnice. Imajući u vidu da je kočenje izrazito dinamički i nelinearan proces, na osnovu istraživanja sprovedenih u ovoj disertaciji i analiza različitih rešenja za optimizaciju parametara dinamičkih sistema pomoću genetskih algoritama, došlo se do zaključka da genetski algoritmi ne daju očekivane rezultate u pogledu brzine pronalaženja optimalnog rešenja koja se zahteva od sistema za dinamičko upravljanje performansama kočnice u toku ciklusa kočenja. To znači da sporost genetskih algoritama u pronalaženju optimalnog rešenja, delimično uzrokovana i time što su u principu tehnika globalnog pretraživanja, predstavlja ograničavajući faktor za primenu kod izrazito dinamičkih sistema kao što je kočni sistem motornih vozila. Na osnovu dobijenih rezultata optimizacije pritiska aktiviranja kočnice pomoću neuro-genetskog pristupa, u disertaciji je pokazano da upotreba takvog neuro-genetskog pristupa za upravljanje pritiskom tokom procesa kočenja, gde se traži izuzetno brz odziv sistema, prema tome nije moguća. Pri tome je veoma važno napomenuti pod kojim uslovima sve navedeno važi. U vezi sa istraživanjima sprovedenim u ovoj disertaciji, može se smatrati da računar na kome je vršeno testiranje poseduje prosečne mogućnosti u pogledu performansi. U slučaju računara sa različitim performansama, vreme potrebno za pronalaženje optimalne vrednosti pritiska aktiviranja kočnice nije isto. Takođe treba imati u vidu da genetski algoritam uvek nasumično bira početnu populaciju pojedinaca (osim ako se to ne onemogući), odnosno da ona nikad nije ista, što takođe ima veliki uticaj na trajanje procesa optimizacije do prve smene generacija. Na brzinu pronalaženja optimalnog pritiska mogu značajno da utiču i neki drugi parametri (na primer stepen ukrštanja, koeficijent mutacije, broj „elitnih“ pojedinaca, itd.).

Razvojem dinamičkog modela procesa kočenja, koji omogućuje predviđanje performansi kočenja i predstavlja osnovu za inteligentno upravljanje performansama kočnog sistema, stvoreni su uslovi za dalja istraživanja u ovoj oblasti. Pre svega razvojem „softverskog“ dela sistema za inteligentno upravljanje performansama kočnog sistema, stvorili su se važni preduslovi za razvoj kontrolera za upravljanje performansama kočnog sistema baziranog na veštačkoj

inteligenciji, kao i njegovu praktičnu implementaciju u okviru kočnih sistema privrednih vozila. Osim toga, postignuti rezultati su takođe od velikog značaja na polju unapređenja rada postojećih elektronski upravljenih kočnih sistema motornih vozila uvođenjem inteligenčnih osobina u upravljanju performansama kočnog sistema u skladu sa promenom posmatranih uticajnih veličina i izabranom strategijom kočenja. Razvoj dinamičkih modela za prednju i zadnju osovinu je otvorio mogućnost za dalja istraživanja na polju uvođenja inteligenčne raspodele sile kočenja između prednje i zadnje osovine. Pored toga, pomenuti dinamički modeli klizanja mogu poslužiti kao osnova za dalja istraživanja na polju optimizacije između nivoa klizanja točka u podužnom i poprečnom pravcu, čime bi se mogućnosti sistema inteligenčnog upravljanja dodatno proširile na polju obezbeđenja stabilnosti/upravljivosti vozila. Eksperimentalno verifikovani dinamički neuronski i neuro-fazi modeli procesa kočenja za prednju i zadnju osovinu takođe mogu poslužiti za dalja istraživanja u cilju unapređenja algoritama njihove obuke u toku svakog ciklusa kočenja i obezbeđenja stabilnog i preciznog predviđanja performansi kočnog sistema u zavisnosti od trenutnih uslova prijanjanja u kontaktu pneumatika i tla. Otvaranjem mogućnosti za preciznije iskorišćavanje uslova prijanjanja u kontaktu pneumatik-tlo tokom procesa kočenja, stvoreni su takođe uslovi za dalja istraživanja na polju unapređenja aktivne bezbednosti vozila.

Razvojem inteligenčnog neuro-fazi dinamičkog modela procesa kočenja za svaki točak, odnosno kočnicu, obezbeđeni su uslovi za razvoj inteligenčno upravljanog kočnog sistema privrednih vozila. Ovim se otvaraju značajne mogućnosti za dalja unapređenja postojećih rešenja za upravljanje performansama kočnog sistema privrednih vozila i posebno sistema za sprečavanje blokiranja kočenih točkova (ABS), odnosno za upravljanje klizanjem točkova na prednjoj/zadnjoj osovini (DSC). Analiza dosadašnjih istraživanja u ovoj oblasti je pokazala da u savremenoj literaturi ne postoje rešenja problema dinamičkog modeliranja, predviđanja i upravljanja performansama kočnog sistema motornih vozila u toku ciklusa kočenja, koja istovremeno obuhvataju uticaje na performanse kočnog sistema analizirane tokom istraživanja sprovedenih u ovoj disertaciji. Time se u velikoj meri ističe njen

naučni i stručni doprinos, posebno imajući u vidu da je omogućeno da se razvijeni neuro fazi dinamički model procesa kočenja u isto vreme neprekidno dodatno prilagođava dinamičkim promenama uticajnih veličina tokom kočenja, pa se shodno tome očekuje značajna praktična primena rezultata i metoda razvijenih u ovoj disertaciji. Primenom rezultata prikazanih u ovoj disertaciji je moguće znatno unaprediti proces projektovanja inteligentno upravljenih kočnih sistema privrednih vozila. Pored toga, time se omogućava i provera dinamičkog ponašanja i performansi inteligentno upravljenih kočnih sistema, ali i skraćuje vreme njihovog razvoja, a to dalje dovodi do znatnih ušteda u fazi projektovanja, ispitivanja i eksploatacije budućeg intelligentnijeg kočnog sistema privrednih vozila.

LITERATURA

- [1] Eriksson, M., Jacobson, S., (2000) Tribological surfaces of organic brake pads. *Tribology International* 33 (12), pp. 817-827.
- [2] Eriksson, M., Bergman, F., Jacobson S., (2002) On the nature of tribological contact in automotive brakes. *Wear* 252 (1-2), pp. 26-36.
- [3] Aleksendrić, D., Barton, D., Vasić, B., (2010) Prediction of brake friction materials recovery performance using artificial neural networks. *Tribology International* 43 (11), pp. 2092-2099.
- [4] Aleksendrić, D., Barton, D., (2009) Neural network prediction of disc brake performance. *Tribology International* 42 (7), pp. 1074-1080.
- [5] Aleksendrić, D., Duboka, Č., (2006) Prediction of automotive friction material characteristics using artificial neural networks-cold performance. *Wear* 261 (3-4), pp. 269-282.
- [6] Aleksendrić, D., Duboka, Č., (2007) Fade performance prediction of automotive friction materials by means of artificial neural networks. *Wear* 262 (7-8), pp. 778-790.
- [7] Xiao, G., Zhu Z., (2010) Friction materials development by using DOE/RSM and artificial neural network. *Tribology International* 43, pp. 218-227.
- [8] Nasir, T., Yousif, B.F., McWilliam, S., Salih, N.D., Hui, L.T., (2010) An artificial neural network for prediction of the friction coefficient of multi-layer polymeric composites in three different orientations. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science* 224, pp. 419-429.
- [9] Rukiye, E., Nurettin, Y., (2010) An experimental study of the effects of manufacturing parameters on the tribological properties of brake lining. *Wear* 268, pp. 1524-1532.

- [10] Aleksendrić, D., (2007) Veštačke neuronske mreže u razvoju friкционog materijala kočnica motornih vozila. Doktorska disertacija, Mašinski fakultet Univerziteta u Beogradu.
- [11] Mutlu, I., (2009) Artificial neural network modelling of non-asbestos brake lining performance boric acid in brake pad. *Information Technology Journal* 8, pp. 389-402.
- [12] Aleksendrić, D., (2010) Neural network prediction of brake friction materials wear. *Wear* 268 (1-2), pp. 117-125.
- [13] Ostermeyer, G.P., (2003) On the dynamics of the friction coefficient. *Wear* 254 (9), pp. 852-858.
- [14] Muller, M., Ostermeyer, G.P., (2007) A Cellular Automaton model to describe the three-dimensional friction and wear mechanism of brake systems. *Wear* 263, pp. 1175-1188.
- [15] Zhang, S.Y., Qu, S.G., Li, Y.Y., Chen, W.P. (2010) Two-body abrasive behavior of brake pad dry sliding against interpenetrating network ceramics/Al-alloy composites. *Wear* 268, pp. 939-945.
- [16] Cetinel, H., Ozturk, H., Celik, E., Karlik, B., (2006) Artificial neural network-based prediction technique for wear loss quantities in Mo coatings. *Wear* 261, pp. 1064-1068.
- [17] Muro, T., Shigematsu, T., (1998) Automatic control system of a rear-wheel drive vehicle moving on a sloped weak sandy terrain. *Journal of Terramechanics* 35 (4), pp. 239-263.
- [18] Amodeo, M., Ferrara, A., Terzaghi, R., Vecchio, C., (2010) Wheel Slip Control via Second-Order Sliding-Mode Generation. *Intelligent Transportation Systems, IEEE Transactions* 11 (1), pp. 122-131.
- [19] Gissinger, G.L., Menard, C., Constans, A., (2003) A mechatronic conception of a new intelligent braking system. *Control Engineering Practice* 11 (2), pp. 163-170.
- [20] Ćirović, V., Aleksendrić, D., (2008) Intelligent control of automotive braking system. *FISITA 2008 World Automotive Congress*, F2008-SC-046, Munich, Germany.

- [21] Austin, L., Morrey, D., (2000) Recent advances in antilock braking systems and traction control systems. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 214 (6), pp. 625-638.
- [22] Choi, C.B., Cho, M.S., Wereley, N.M., (2006) Wheel-Slip Control of a Passenger Vehicle Using an Electrorheological Valve Pressure Modulator. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 220, pp. 519-529.
- [23] Choi, S.B., Bang, J.H., Cho, M.S., Lee, Y.S., (2002) Sliding mode control for anti-lock brake system of passenger vehicles featuring electro rheological valves. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 216, pp. 897-908.
- [24] Ivanov, V., Shyrokau, B., Augsburg, K., Algin, V., (2010) Fuzzy evaluation of tyre-surface interaction parameters. *Journal of Terramechanics* 47 (2), pp. 113-130.
- [25] Margolis, D., Shim, T., (2001) A bond graph model incorporating sensors, actuators, and vehicle dynamics for developing controllers for vehicle safety. *Journal of the Franklin Institute* 338 (1), pp. 21-34.
- [26] Topalov, A.V., Oniz, Y., Kayacan, E., Kaynak, O., (2011) Neuro-fuzzy control of antilock braking system using sliding mode incremental learning algorithm. *Neurocomputing* 74 (11), pp. 1883-1893.
- [27] Sharkawy, A.B., (2010) Genetic fuzzy self-tuning PID controllers for antilock braking systems. *Eng. Appl. Artif. Intell.* 23 (7), pp. 1041-1052.
- [28] Cheli, F., Concas, A., Giangulio, E., Sabbioni, E., (2008) A simplified ABS numerical model: Comparison with HIL and full scale experimental tests. *Computers & Structures* 86 (13-14), pp. 1494-1502.
- [29] Wu, M., Shih, M., (2003) Simulated and experimental study of hydraulic anti-lock braking system using sliding-mode PWM control. *Mechatronics* 13 (4), pp. 331-351.
- [30] Papelis, Y.E., Watson, G.S., Brown, T.L., (2010) An empirical study of the effectiveness of electronic stability control system in reducing loss of vehicle control. *Accident Analysis & Prevention* 42 (3), pp. 929-934.

- [31] Zheng, S., Tang, H., Han, Z., Zhang, Y., (2006) Controller design for vehicle stability enhancement. *Control Engineering Practice* 14 (12), pp. 1413-1421.
- [32] Bang, M.S., Lee, S.H., Han, C.S., Maciuca, D.B., Hedrick, J.K., (2001) Performance enhancement of a sliding mode wheel slip controller by the yaw moment control. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 215, pp. 455-468.
- [33] Chun, K., Sunwoo, M., (2005) Wheel slip tracking using moving sliding surface. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 219, pp. 31-41.
- [34] Pauwelussen, J.P., Gootjes, L., Schroder, C., Kohne, K.U., Jansen, S., Schmeitz, A., (2003) Full vehicle ABS braking using the SWIFT rigid ring tyre model. *Control Engineering Practice* 11 (2), pp. 199-207.
- [35] Straky, H., Kochem, M., Schmitt, J., Isermann, R., (2003) Influences of braking system faults on vehicle dynamics. *Control Engineering Practice* 11 (3), pp. 337-343.
- [36] Song, J., Che, W.S., (2009) Comparison between braking and steering yaw moment controllers considering ABS control aspects. *Mechatronics* 19 (7), Special Issue on Hardware-in-the-loop simulation, pp. 1126-1133.
- [37] Buchner, T., Hofflinger, B., Schwederski, T., Maretzke, J., (1991) WSP - A Processor for Real-Time Wheel Slip Measurement in Vehicles. *Vehicular Technology Conference, Gateway to the Future Technology in Motion, 41st IEEE Conference*, pp. 860–865.
- [38] Nouillant, C., Assadian, F., Moreau, X., Oustaloup, A., (2001) Hybrid control architecture for automobile ABS. *Robot and Human Interactive Communication Proceedings. 10th IEEE International Workshop*, pp. 493-498.
- [39] Chikhi, R., El Hadri, A., Cadiou, J.C., (2005) Optimal Control for Anti-Braking System. *Intelligent Control, Proceedings of the 2005 IEEE International Symposium, Mediterranean Conference on Control and Automation*, pp. 581-585.
- [40] Mirzaei, A., Moallem, M., Mirzaeian, B., (2005) Designing a Genetic-Fuzzy Anti-Lock Brake System Controller. *Intelligent Control, Proceedings of the*

- 2005 IEEE International Symposium, Mediterrean Conference on Control and Automation, pp. 1246–1250.
- [41] Mirzaei, A., Moallem, M., Mirzaeian, B., (2005) Optimal design of a hybrid controller for antilock braking systems. Advanced Intelligent Mechatronics. Proceedings, IEEE/ASME International Conference, pp. 905–910.
 - [42] Ebrahimirad, H., Yazdanpanah, M.J., Kazemi, R., (2004) Sliding mode four wheel slip-ratio control of anti-lock braking systems. Industrial Technology, IEEE ICIT '04 International Conference (3), pp. 1602–1606.
 - [43] Topalov, A.V., Kayacan, E., Oniz, Y., Kaynak, O., (2009) Neuro-Fuzzy Control of Antilock Braking System Using Variable-Structure-Systems-Based Learning Algorithm. Adaptive and Intelligent Systems, ICAIS '09. International Conference, pp. 166–171.
 - [44] Li, F., Hu, R., Yao, H., (2010) The Performance of Automobile Antilock Brake System Based on Fuzzy Robust Control. Intelligent Computation Technology and Automation (ICICTA), International Conference (3), pp. 870–873.
 - [45] Aly, A.A., (2010) Intelligent fuzzy control for antilock brake system with road-surfaces identifier. Mechatronics and Automation (ICMA), International Conference, pp. 699–705.
 - [46] Precup, R., Spătaru S.V., Petriu, E.M., Preitl, S., Rădaç M.B., Dragoş, C.A., (2010) Stable and optimal fuzzy control of a laboratory Antilock Braking System. Advanced Intelligent Mechatronics (AIM), IEEE/ASME International Conference, pp. 593–598.
 - [47] Zhang, J., Song, B., Sun, G., (2008) An Advanced Control Method for ABS Fuzzy Control System. Intelligent Computation Technology and Automation (ICICTA), International Conference (1), pp. 845–849.
 - [48] Tanelli, M., Savaresi, S.M., (2006) Friction-curve peak detection by wheel-deceleration measurements, Intelligent Transportation Systems Conference ITSC '06 IEEE, pp. 1592–1597.
 - [49] Tanelli, M., Astolfi, A., Savaresi, S.M., (2006) Non-local extremum seeking control for active braking control systems. Computer Aided Control System Design, 2006 IEEE International Conference on Control Applications, 2006 IEEE International Symposium on Intelligent Control, pp. 891–896.

- [50] Fujimoto, H., Fujii, K., Takahashi, N., (2007) Vehicle stability control of electric vehicle with slip-ratio and cornering stiffness estimation. Advanced intelligent mechatronics, 2007 IEEE/ASME international conference, pp. 1-6.
- [51] Tanelli, M., Savaresi, S.M., Cantoni, C., (2006) Longitudinal vehicle speed estimation for traction and braking control systems. Computer Aided Control System Design, 2006 IEEE International Conference on Control Applications, 2006 IEEE International Symposium on Intelligent Control, pp. 2790-2795.
- [52] Villagra, J., d'Andrea-Novel, B., Fliess, M., Mounier, H., (2010) A diagnosis-based approach for tire-road forces and maximum friction estimation. Control Engineering Practice 19 (2), pp. 219, 31-41.
- [53] Matusko, J., Petrović, I., Perić, N., (2008) Neural network based tire/road friction force estimation. Engineering Applications of Artificial Intelligence 21 (3), pp. 442-456.
- [54] Gustafsson, F., (1997) Slip-based tire-road friction estimation. Automatica 33 (6), pp. 1087-1099.
- [55] Rudd, R., (2008) Estimating the Mu Slip Curve via Extended Kalman Filtering, Mathematica 11 (1).
- [56] Kececi, F., Tao, G., (2006) Adaptive vehicle skid control, Mechatronics 16 (5), pp. 291-301.
- [57] Canudas-de-wit, C., Tsiotras, P., Velenis, E., Basset, M., Gissinger, G., (2002) Dynamic Friction Models for Road/Tire Longitudinal Interaction. at URL: <http://soliton.ae.gatech.edu/labs/dcsl/papers/vsd02.pdf>
- [58] Tiwari, S., Naresh, R., Jha R., (2011) Neural network predictive control of UPFC for improving transient stability performance of power system. Applied Soft Computing 11 (8), pp. 4581-4590.
- [59] Dennis, J.E., Schnabel, R.B., (1983) Numerical Methods for Unconstrained Optimization and Nonlinear Equations. Englewood, NJ: Prentice-Hall.
- [60] Shrivastava, P., Trivedi, A., (2011) Control of nonlinear process using neural network based model predictive control. International Journal of Engineering Science and Technology 3 (4), pp. 2573-2581.

- [61] Lazar, M., Pastravanu, O., (2002) A neural predictive controller for non-linear systems. *Mathematics and Computers in Simulation* 60 (3-5), pp. 315-324.
- [62] Hagan, M.T., Demuth, H.B., De Jesús, O., (2002) An introduction to the use of neural networks in control systems. *Int. J. Robust Nonlinear Control* 12, pp. 959–985.
- [63] Gil, P., Henriques J., Dourado, A., Duarte-Ramos, H., (1999) Non-linear predictive control based on a recurrent neural network. *Intelligent Control, ConferenceESIT\99.*
- [64] Venayagamoorthy, G.K., Harley, R.G., (1998) Simulation studies with a continuously online trained artificial neural network controller for a micro-turbogenerator. *International Conference Simulation '98.*, pp. 405 – 412.
- [65] Nikolaou, M., (2001) Model predictive controllers: A critical synthesis of theory and industrial needs. *Advances in Chemical Engineering* 26, pp. 131-204.
- [66] Burton, B., Kamran, F., Harley, R.G., Habetler, T.G., Brooke, M., Poddar, R., (1995) Identification and control of induction motor stator currents using fast on-line random training of a neural network. *Industry Applications Conference IAS '95.*, pp. 1781 – 1787.
- [67] Kamran, F., Harley, R.G., Burton, B., Habetler, T.G., Brooke, M., (1995) A fast on-line neural network training algorithm for a rectifier regulator. *Industrial Electronics, Proceedings of the 1995 IEEE IECON*, pp. 1462 – 1467.
- [68] Grino, R., Cembrano, G., Torras, C., Nonlinear system identification using additive dynamic neural networks-two on-line approaches. *Circuits and Systems I: Fundamental Theory and Applications* 47 (2), pp. 150 – 165.
- [69] Schiller, U.D., (2003) Analysis and Comparison of Algorithms for Training Recurrent Neural Networks. Diploma Thesis, Faculty of Technology, University of Bielefeld.
- [70] Callinan, T., (2003) Artificial Neural Network identification and control of the inverted pendulum. At URL:
http://elm.eeng.dcu.ie/~brutonj/Reports/TCallinan_MEng_03.pdf

- [71] Campa, G., (2008) Adaptive Neural Networks. West Virginia University.
- [72] Hagan, M.T., Demuth, H.B., Beale, M., (1995) Neural networks design. PWS Pub. Co., Pages 736.
- [73] Gurney, K., (2009) An Introduction to Neural Networks. University College London (UCL) Press, Pages 148.
- [74] Dreyfus, G., (2005) Neural networks: Methodology and applications. Springer, Pages 515.
- [75] Poursamad, A., (2009) Adaptive feedback linearization control of antilock braking systems using neural networks. Mechatronics 19, pp. 767-773.
- [76] Ricalde, L.J., Sanchez, E.N., (2008) Output tracking with constrained inputs via inverse optimal adaptive recurrent neural control. Engineering Applications of Artificial Intelligence 21, pp. 591-603.
- [77] Yu, S., Zhu, K., Diao, F., (2008) A dynamic all parameters adaptive BP neural networks model and its application on oil reservoir prediction. Applied Mathematics and Computation 195, pp. 66-75.
- [78] Benitez, V.H., Sanchez, E.N., Loukianov, A.G., (2007) Decentralized adaptive recurrent neural control structure. Engineering Applications of Artificial Intelligence 20, pp. 1125-1132.
- [79] Canelon, J.I., Shieh, L., Karayiannis, N.B., (2005) A new approach for neural control of nonlinear discrete dynamic systems. Information Sciences 174, pp. 177-196.
- [80] Ćirović, V., Aleksendrić, D., (2010) Development of neural network model of disc brake operation, FME Transactions 38 (1), pp. 29-38.
- [81] Ito, M., Noda, K., Hoshino, Y., Tani, J., (2006) Dynamic and interactive generation of object handling behaviors by a small humanoid robot using a dynamic neural network model. Neural Networks 19, pp. 323-337.
- [82] Becerikli, Y., Oysal, Y., (2007) Modeling and prediction with a class of time delay dynamic neural networks. Applied Soft Computing 7, pp. 1164-1169.
- [83] Becerikli, Y., Konar, A.F., Samad, T., (2003) Intelligent optimal control with dynamic neural networks. Neural Networks 16, pp. 251-259.

- [84] Terzic, E., Nagarajah, C.R., Alamgir, M., (2010) Capacitive sensor-based fluid level measurement in a dynamic environment using neural network. *Engineering Applications of Artificial Intelligence* 23 (4), pp. 614-619.
- [85] Pearlmutter, B.A., (1990) Dynamic recurrent neural networks. Technical report CMU-CS-90-196, 1990, Carnegie Mellon University, School of Computer Science.
- [86] Zhou, S.M., (1999) Combining dynamic neural networks and image sequences in a dynamic model for complex industrial production processes. *Expert Systems with Applications* 16, pp. 13-19.
- [87] Anh, H.P.H., Ahn, K.K., (2011) Hybrid control of a pneumatic artificial muscle (PAM) robot arm using an inverse NARX fuzzy model. *Engineering Applications of Artificial Intelligence* 24, pp. 697-716.
- [88] Ćirović, V., Aleksendrić, D., (2011) Dynamic modelling of disc brake contact phenomena, *FME Transactions* 39 (4), pp. 177-183.
- [89] Ćirović, V., Aleksendrić, D. Mladenović, D., (2012) Braking torque control using recurrent neural networks. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, Published online before print, doi: 10.1177/0954407011428720.
- [90] Blanco, A., Delgado, M., Pegalajar, M.C., (2001) A real-coded genetic algorithm for training recurrent neural networks. *Neural Networks* 14 (1), pp. 93-105.
- [91] Sexton, R.S., Dorsey, R.E., Johnson, J.D., (1999) Optimization of neural networks: A comparative analysis of the genetic algorithm and simulated annealing. *European Journal of Operational Research* 114 (3), pp. 589-601.
- [92] Sexton, R.S., Dorsey R.E., Johnson J.D., (1998) Toward global optimization of neural networks: A comparison of the genetic algorithm and backpropagation. *Decision Support Systems* 22 (2), pp. 171-185.
- [93] Kuo, R.J., Hong, S.M., Lin, Y., Huang, Y.C., (2008) Continuous genetic algorithm-based fuzzy neural network for learning fuzzy IF-THEN rules. *Neurocomputing* 71 (13-15), pp. 2893-2907.
- [94] Remling, J., (2007) Brakes, Wiley, 328 pages.

- [95] Barton, D.C., Haigh, M.J., (1998) The Second International Seminar on Automotive Braking: recent developments and future trends. Professional Engineering Publishing, 293 pages.
- [96] The History of American Standard, (1999) Write Stuff Enterprises Inc.
- [97] Norman, A., Bennett, S., Corinchock, J.A., (2000) Heavy-Duty Truck Systems. Delmar Thomson Learning, 1086 pages.
- [98] Todorović, J., (1988) Kočenje motornih vozila. Zavod za udžbenike i nastavna sredstva, Beograd.
- [99] Nunney, M.J., (1998) Automotive Technology. SAE, 654 pages.
- [100] Puhn, F., (1987) Brake Handbook. HP Trade.
- [101] Baker, A.K., (1986) Vehicle braking, Pentech Press, 347 pages.
- [102] Buckman, L.C. (1998) Commercial Vehicle Braking Systems: Air Brakes, ABS and Beyond. Society of Automotive Engineers Incorporated, 172 pages.
- [103] Limpert, R., (1999) Brake Design and Safety. Second Edition, Society of Automotive Engineers Inc.
- [104] ECE Regulation No. 13, (2011) Uniform provisions concerning the approval of vehicles of categories M, N and O with regard to braking, Revision 7.
- [105] Heisler, H., (2002) Advanced Vehicle Technology. Elsevier, 654 pages.
- [106] Eriksson, M., (2000) Friction and contact phenomena of disc brakes related to squeal. Doctoral Thesis, Faculty of Science and Technology, University Uppsala.
- [107] Cho, M.H., Kim, S.J., Basch, R.H., Fash, J.W., Jang, H., (2003) Tribological study of gray cast iron with automotive brake linings: The effect of rotor microstructure. *Tribology International* 36, pp. 537-545.
- [108] Lu, Y., (2006) A combinatorial approach for automotive friction materials: Effects of ingredients on friction performance. *Composites Science and Technology* 66 (3–4), pp. 591-598.
- [109] Kumar, M., Bijwe, J., (2010) Studies on reduced scale tribometer to investigate the effects of metal additives on friction coefficient – Temperature sensitivity in brake materials. *Wear* 269 (11–12), pp. 838-846.

- [110] Eriksson, M., Bergman, F., Jacobson, S., (1999) Surface characterisation of brake pads after running under silent and squealing conditions. Wear 232, pp. 163-167.
- [111] Österle, W., Urban, I., (2006) Third body formation on brake pads and rotors. Tribology International 39 (5), pp. 401-408.
- [112] Sinou, J.J., (2010) Transient non-linear dynamic analysis of automotive disc brake squeal – On the need to consider both stability and non-linear analysis. Mechanics Research Communications 37 (1), pp. 96-105.
- [113] Eriksson, M., Lord, J., Jacobson, S., (2000) Wear and contact conditions of brake pads - dynamical in-situ studies of pad on glass. Accepted for publication in proceedings of Nordtrib 2000, Porvoo, Finland.
- [114] Zaidi, H., Senouci, A., (1999) Thermal tribological behaviour of composite carbon metal/steel brake. Applied Surface Science 144–145, pp. 265-271.
- [115] Qi, H.S., Day, A.J., (2007) Investigation of disc/pad interface temperatures in friction braking. Wear 262 (5–6), pp. 505-513.
- [116] Institution of Mechanical Engineers (Great Britain), (1996) Advances in Automotive Braking Technology: Design Analysis and Materials Development, Mechanical Engineering Pub., 158 pages.
- [117] Petersen, I., (2003) Wheel Slip Control in ABS Brakes using Gain Scheduled Optimal Control with Constraints, Doctor Thesis, Norwegian University of Science and Technology, Trondheim, Norway.
- [118] EBS Electronically Controlled Brake System, (2007) System and functional description, Second edition, Wabco.
- [119] Ribbens, W.B., Mansour, N.P., (2003) Understanding Automotive Electronics, Newnes, 470 pages.
- [120] Miller, F.P., Vandome, A.F., McBrewster, J., (2010) Anti-Lock Braking System. VDM Verlag Dr. Mueller e.K., 76 pages.
- [121] ABS 6 Standard Anti-lock Braking System, (2010) Product Manual, Knorr-Bremse GmbH.
- [122] A review of antilock braking and traction control systems, at URL: http://www.astm.org/BOOKSTORE/PREVIEWM4/Chapter4_Mono4.pdf

- [123] Society Of Automotive Engineers, (1995) Advancements in Abs/Tcs and Brake Technology. Society of Automotive Engineers, 83 pages.
- [124] Erjavec, J., (1996) A Technician's Guide to Anti-Lock Brake Systems. Delmar Publishers, 170 pages.
- [125] Anti-Lock Brake System (ABS), (2010) System and functional description, Wabco.
- [126] ABS Control Theory, (2009) ABS Training course, Wabco Inc.
- [127] Owen, C., (2010) Automotive Brake Systems, Cengage Learning, 832 pages.
- [128] Society of Automotive Engineers, (2005) Brakes and electronic stability control, SAE International, 178 pages.
- [129] Rajamani R., (2011) Vehicle Dynamics and Control, Springer, 496 pages.
- [130] Stamenković, D., Đurđanović, M., Nikolić, M., (2007) Prilog istraživanju problema kontakta pneumatika i kolovoza. 10th International Conference on Tribology, SERBIATRIB '07.
- [131] Zegelaar, P.W.A., (1998) The Dynamic Response of Tyres to Brake Torque Variations and Road Unevennesses. Doctoral Dissertation, Delft University of Technology, Delft, The Netherlands.
- [132] Svendenius, J., Wittenmark, B., (2003) Review of Wheel Modelling and Friction Estimation, Internal Report, Lund Institute of Technology.
- [133] Pacejka, H.B., (2006) Tire and vehicle dynamics. Edition 2, SAE International, 642 pages.
- [134] Jazar, R.N., (2008) Vehicle Dynamics: Theory and Applications. Springer, 1015 pages.
- [135] Tanelli, M., Piroddi, L., Piuri, M., Savaresi, S.M., (2008) Real-time identification of tire-road friction conditions. IEEE International Conference on Control Applications, pp. 25-30.
- [136] Savaresi, S.M., Tanelli, M., (2010) Active braking control system design for vehicles. Springer-Verlag, 1st Edition.
- [137] Savaresi, S.M., Tanelli, M., Langthaler, P., Del Re. L., (2006) Estimation of X-Z tire contact force via embedded accelerometers. Tire Technology International Review, pp. 74-78.

- [138] Savaresi, S.M., Tanelli, M., Cantoni, C., (2007) Mixed slip-deceleration control in automotive braking systems. ASME Journal of Dynamic Systems, Measurements and Control 129, pp. 20-31.
- [139] Tanelli, M., Osorio, G., di Bernardo, M., Savaresi, S.M., Astolfi, A., (2009) Existence, Stability and Robustness Analysis of Limit Cycles in Hybrid Anti-lock Braking Systems. International Journal of Control 82, pp. 659–678.
- [140] Pacejka, H.B., (1993) Tyre Models for Vehicle Dynamic Analysis: Proceedings of the 1st International Colloquium on Tyre Models for Vehicle Dynamics Analysis. Swets & Zeitlinger, 192 pages.
- [141] Schiehle, W.O., (2008) Dynamical Analysis of Vehicle Systems: Theoretical Foundations and Advanced Applications. Springer, 304 pages.
- [142] Dixon, J.C., (1996) Tires, Suspension, and Handling. Society of Automotive Engineers, 621 pages.
- [143] Lugner, P., Plöchl, M., (2005) Tyre models for vehicle dynamic analysis: proceedings of the 3rd International Colloquium on Tyre Models for Vehicle Dynamics Analysis. Taylor & Francis, 539 pages.
- [144] Lugner, P., Plöchl, M., (2007) Tire model performance test (TMPT). Taylor & Francis, 225 pages.
- [145] Janičić, P., Nikolić, M., (2009) Veštačka inteligencija. Matematički fakultet u Beogradu, At URL:
<http://poincare.matf.bg.ac.rs/~janicic//VI.pdf>
- [146] Jackson, P.C., (1985) Introduction to Artificial Intelligence. Courier Dover Publications, 453 pages.
- [147] Russell, S.J., Norvig, P., (2010) Artificial Intelligence: A modern approach. Prentice Hall, 1132 pages.
- [148] Jones, M.T., (2008) Artificial Intelligence: A systems approach, Jones & Bartlett Learning, 498 pages.
- [149] Haugeland, J. (1989) Artificial Intelligence: The very idea. MIT Press, 287 pages.
- [150] Norvig, P., (1992) Paradigms of Artificial Intelligence Programming: Case Studies in Common Lisp. Morgan Kaufmann, 946 pages.
- [151] Ilić, V. (2004) Veštačka inteligencija. At URL:

http://solair.eunet.rs/~ilicv/AI_index.htm

- [152] Buchanan, B.G., Smith, R.G. (1988) Fundamentals of expert systems. *Ann. Rev. Comput. Sci.* 3, pp. 23-58.
- [153] Forsyth, R. (1989) The evolution of intelligence. *Machine Learning: Principles and techniques*, pp. 65-82.
- [154] Ćirović, V., (2007) Veštačke neuronske mreže kao metoda inteligentnog upravljanja. Seminarski rad, Mašinski fakultet Univerziteta u Beogradu.
- [155] Beale, M.H., Hagan, M.T., Demuth, H.B., (2010) Neural Network Toolbox™ 7, Users guide Version 7.0 (Release 2010b), The Math Works, Inc.
- [156] Benitez, V. H., Sanchez, E. N., Loukianov, A.G., (2007) Decentralized adaptive recurrent neural control structure. *Engineering Applications of Artificial Intelligence* 20, pp. 1125-1132.
- [157] Miljković, Z., Aleksendrić, D., (2009) Veštačke neuronske mreže – zbirka zadataka sa izvodima iz teorije. Mašinski fakultet Univerziteta u Beogradu.
- [158] Hassoun, M.H., (1995) Fundamentals of Artificial Neural Networks. MIT Press, 511 pages.
- [159] Rojas, R., (1996) Neural Networks: A Systematic Introduction. Springer, 502 pages.
- [160] Hecht-Nielsen, R., (1990) Neurocomputing. Addison-Wesley Publishing Company, 433 pages.
- [161] Khanna, T., (1990) Foundations of neural networks. Addison-Wesley, 196 pages.
- [162] Chauvin, Y., Rumelhart, D.E. (1995) Backpropagation: Theory, Architectures, and Applications. Routledge, 561 pages.
- [163] Veelenturf, L.P.J., (1995) Analysis and applications of artificial neural newtworks. Prentice Hall, 259 pages.
- [164] Sharkey, A.J.C., (1999) Combining artificial neural nets: ensemble and modular multi-net systems. Springer, 298 pages.
- [165] Rabuñal, J.R., Dorrado, J., (2006) Artificial Neural Networks in Real-Life Applications. Idea Group Inc (IGI), 375 pages.
- [166] Tang, H., Tan, K.C., Zhang, Y., (2007) Neural Networks: Computational Models and Applications. Springer, 299 pages.

- [167] Hopfield, J.J., (1982) Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences, 'Etats-Unis* 79, pp. 2554–2558.
- [168] Sontag, E.D., (1996) Recurrent Neural Networks: Some Systems-Theoretic Aspects. Dept. of Mathematics, Rutgers University, NB, 'Etats-Unis.
- [169] Klir, G.J., Yuan, B., (1995) Fuzzy Sets and Fuzzy Logic: Theory and Applications. Prentice Hall, 592 pages.
- [170] Ganesh, M., (2006) Introduction To Fuzzy Sets And Fuzzy Logic, PHI Learning Pvt. Ltd., 256 pages.
- [171] Buckley, J.J., Eslami, E., (2002) An Introduction to Fuzzy Logic and Fuzzy Sets. Springer, 284 pages.
- [172] Subašić, P., (1997) Fuzzy logika i neuronske mreže. Tehnička knjiga, Beograd.
- [173] Nauck, D., Klawon, F., Kruse, R. (1997) Foundations of Neuro-Fuzzy Systems. Wiley, Chichester.
- [174] Cox, E., (1994) The Fuzzy Systems Handbook. Cambridge, MA: Academic Press.
- [175] Kosko, B., (1997) Fuzzy Engineering. Upper Saddle River, NJ: Prentice Hall.
- [176] Zadeh, L.A., (1965) Fuzzy sets. *Information and Control* 8, pp. 338–353.
- [177] Leondes, C.T., (1999) Fuzzy Theory Systems: Techniques and Applications. Gulf Professional Publishing, 1777 pages.
- [178] Vernon, J., (2006) Fuzzy Logic Systems. Control Systems Principles, At URL: <http://www.control-systems-principles.co.uk/whitepapers/fuzzy-logic-systems.pdf>
- [179] Sivanandam, S.N., Sumathi, S., Deepa, S.N., (2007) Introduction to Fuzzy Logic Using Matlab. Springer, 430 pages.
- [180] Weise, T., (2009) Global Optimization Algorithms – Theory and Application [online]. Germany, it-weise.de (self-published). Available from: <http://www.it-weise.de/>
- [181] Haupt, R.L., Haupt, S.E, (2004) Practical genetic algorithms. Second edition, John Wiley & Sons, Inc.

- [182] Goldberg, D.E., (1989) Algorithms in Search, Optimization and Machine Learning. Addison-Westey.
- [183] Schultz, A.C., Grefenstette, J.J., De Jong, K.A., (1993) Test and Evaluating by Genetic Algorithms. IEEE Expert, pp. 9-14.
- [184] Goldberg, D.E., (1985) Genetic algorithms and rule learning in dynamic system control. Proc. Int. Conf. on Genetic Algorithms and their Applications, Carnegie Mellon University, Pittsburgh.
- [185] Vugdelija, M., Kratica, J., Filipović, V., Radojević, S., (1996) Mogućnosti genetskih algoritama u mašinskom učenju. At URL:
alas.matf.bg.ac.yu/~kratica/papers/jup96.pdf
- [186] Mitchell, M., (1998) An Introduction to Genetic Algorithms. MIT Press, 209 pages.
- [187] Reeves, C.R., Rowe, J.E., (2002) Genetic Algorithms: Principles and Perspectives. Springer, 332 pages.
- [188] Michalewicz, Z., (1996) Genetic Algorithms + Data Structures. Springer, 387 pages.
- [189] Rajasekaran, S., Vijayalakshmi, G.A., (2004) Neural Networks, Fuzzy Logic and Genetic Algorithms: Synthesis and Applications. PHI Learning Pvt. Ltd., 456 pages.
- [190] D'heygere, T., Goethals, P.L.M., De Pauw, N., (2002) Use of Genetic Algorithms to select Input Variables in Artificial Neural Network Models for the Prediction of Benthic Macroinvertebrates. At URL:
www.iemss.org/iemss2002/proceedings/pdf/volume%20due/261_dheyge re.pdf
- [191] Koehn, P., (1994) Combining Genetic Algorithms and Neural Networks: The Encoding problem. Master's thesis, University of Erlangen and The University of Tennessee, Knoxville,
www.iccs.inf.ed.ac.uk/~pkoechn/publications/gann94.pdf
- [192] Proger, T., Zenzen, M., (2002) Method Of Terminating Electronic Brake Force Distribution - Patent 6367892, Continental Teves AG & Co.

- [193] Stanković, M., Stanković, S., (2008) Primena teorije obučavanja na uklanjanje šuma pomoću talasića. Univerzitet u Beogradu, Elektrotehnički fakultet.
- [194] Jakovljević, Ž., Petrović, P., (2011) Prepoznavanje kontaktnih stanja u robotizovanoj montaži. Mašinski fakultet Univerziteta u Beogradu, 208 str.
- [195] Van Fleet, P.J., (2008) Discrete wavelet transformations: an elementary approach with applications. John Wiley & Sons, 535 pages.
- [196] Mohideen S.K., Perumal, S.A., Sathik, M.M., (2008) Image De-noising using Discrete Wavelet transform. IJCSNS International Journal of Computer Science and Network Security 8 (1), pp. 213-216.
- [197] Starčević, Đ., Petrović, V., (2012) Uklanjanje šuma iz medicinskih slika manipulacijom modula koeficijenata kompleksne wavelet transformacije. Infoteh-Jahorina 11, pp. 686-691.
- [198] Jensen, A., Cour-Harbo, A., (2001) Ripples in Mathematics: The Discrete Wavelet Transform. Springer, 246 pages.
- [199] Debnath, L., (2002) Wavelet Transforms and Their Applications. Springer, 565 pages.
- [200] Lavry, D., (1997) Undersatnding IIR (Infinite Impulse Response) Filters. Lavry Engineering, 5 pages.
- [201] Aleksendrić D., Jakovljević Ž., Ćirović V., (2012) Intelligent control of braking process, Expert Systems with Applications 39/14, pp. 11758-11765.

Прилог 1.

Изјава о ауторству

Потписани-а Велимир Ђијоровић

број уписа Д5/05

Изјављујем

да је докторска дисертација под насловом

ИСТРАЖИВАЊЕ МОГУЋНОСТИ ПРИМЕНЕ ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ У

ПРЕДВИЂАЊУ ПЕРФОРМАНСИ КОЧНОГ СИСТЕМА МОТОРНИХ ВОЗИЛА

- резултат сопственог истраживачког рада,
- да предложена дисертација у целини ни у деловима није била предложена за добијање било које дипломе према студијским програмима других високошколских установа,
- да су резултати коректно наведени и
- да нисам кршио/ла ауторска права и користио интелектуалну својину других лица.

Потпис докторанда

У Београду, 20.08.2012.

Велимир Ђијоровић

Прилог 2.

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора Велимир Ђировић

Број уписа Д5/05

Студијски програм 3+2

Наслов рада Истраживање могућности примене вештачке интелигенције у предвиђању перформанси кочног система моторних возила

Ментор Доц. др Драган Александрић

Потписани ВЕЛИМИР ЂИРОВИЋ

изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла за објављивање на порталу **Дигиталног репозиторијума Универзитета у Београду**.

Дозвољавам да се објаве моји лични подаци везани за добијање академског звања доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис докторанда

У Београду, 20.08.2012.

Велимир Ђировић

Прилог 3.

Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Истраживање могућности примене вештачке интелигенције у предвиђању

перформанси кочног система моторних возила

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигитални репозиторијум Универзитета у Београду могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио/ла.

1. Ауторство
2. Ауторство - некомерцијално
3. Ауторство – некомерцијално – без прераде
4. Ауторство – некомерцијално – делити под истим условима
5. Ауторство – без прераде
6. Ауторство – делити под истим условима

(Молимо да заокружите само једну од шест понуђених лиценци, кратак опис лиценци дат је на полеђини листа).

Потпис докторанда

У Београду, 20.08.2012.

Велимир Ђуроњик

BIOGRAFIJA AUTORA

Ime i prezime: Velimir Ćirović

Datum rođenja: 26.08.1981.

Mesto rođenja: Gornji Milanovac, Republika Srbija

Školovanje:

1988 – 1996 Osnovna škola „Sava Kerković“ u Ljigu
1996 – 2000 Gimnazija „Branislav Petronijević“ u Ljigu
2000 – 2005 Studije na Mašinskom fakultetu u Beogradu, odsek za motorna vozila
25.05.2005. Odbranjen diplomski rad pod nazivom „Primena programskog paketa CATIA za simulaciju rada planetarnih prenosnika snage“
2005 – 2008 Doktorske studije na Mašinskom fakultetu u Beogradu
2006 – 2007 Služenje vojnog roka

Kretanje u poslu:

2005 – 2006 Akviziter osiguranja, DDOR Novi Sad AD
2007 – 2010 Saradnik u sektoru za prodaju osiguranja, SAVA Osiguranje AD
2010 – 2011 Istraživač pripravnik, Inovacioni centar Mašinskog fakulteta u Beogradu
2011 – Istraživač saradnik, Inovacioni centar Mašinskog fakulteta u Beogradu