

UNIVERZITET U BEOGRADU

MATEMATIČKI FAKULTET

Iva A. Čvorović - Hajdinjak

ANALIZA PROMENLJIVOSTI AKTIVNIH
GALAKTIČKIH JEZGARA
KOMBINOVANOM PRIMENOM
SAMOORGANIZUJUĆIH MAPA I
NEURONSKIH PROCESA

doktorska disertacija

Beograd, 2025.

UNIVERSITY OF BELGRADE
FACULTY OF MATHEMATICS

Iva A. Čvorović - Hajdinjak

ANALISYS OF VARIABILITY OF ACTIVE
GALACTIC NUCLEI BY COMBINED
APLICATION OF SELF-ORGANIZING
MAPS AND NERUAL PROCESSESS

Doctoral Dissertation

Belgrade, 2025.

Mentor:

prof. dr Anđelka Kovačević, vanredni profesor
Univerzitet u Beogradu, Matematički fakultet

Članovi komisije:

prof. dr Dragana Ilić,
redovni profesor Matematičkog fakulteta Univerziteta u Beogradu

prof. dr Luka Č. Popović,
naučni savetnik Astronomske opservatorije
i redovni profesor Matematičkog fakulteta Univerziteta u Beogradu

prof. dr Dušan Onić,
vanredni profesor Matematičkog fakulteta Univerziteta u Beogradu

prof. dr Mladen Nikolić,
vanredni profesor Matematičkog fakulteta Univerziteta u Beogradu

dr Aleksandra Čiprijanović,
Associate Scientist, Fermi National Accelerator Laboratory,
Data Science, Simulation and Learning Division, Cosmic AI group lead

Datum odbrane: _____

Zahvalnica

Najveću zahvalnost za višegodišnji rad na ovoj disertaciji dugujem svojoj mentorki prof. dr. Anđelki Kovačević, koja me je strpljivo vodila, nesebično pomagala i davala vetar u leđa u savladavanju svih izazova na koje sam nailazila. Vreme, koje je posvetila našem radu, znanje, kreativnost, podrška i razumevanje, bili su ključni na svakom koraku. Neizmerno sam zahvalna na njenoj upornosti i motivaciji, bez koje ne bih uspela da završim ovaj rad.

Zahvalnost dugujem i svim članovima tima sa kojima sam imala čast da radim ovih godina, a koji su mi prenosili znanje, savetovali me i davali inspiraciju nebrojeno puta. Posebno bih izdvojila prof. dr. Draganu Ilić, koja je uvek bila spremna da pomogne, odgovori na svako pitanje i da prijateljske reči podrške, i prof. dr. Luku Č. Popovića kome sam zahvalna na prenesenom znanju i veoma korisnim i stručnim smernicama.

Veliku zahvalnost dugujem i svojoj porodici, koja predstavlja moje „standardne sveće“, određujući me u prostoru i vremenu. Svojim roditeljima Verici i Aleksandru i bratu Vuku, jer su me podržavali i pomagali mi da ispunim svoje želje, uprkos svim izazovima. Svojoj deci, Hani i Maksimu zahvalna sam na motivaciji, безусловnoj ljubavi i sreći, kojom mi ispunjavaju svaki trenutak.

Naslov disertacije: Analiza promjenljivosti Aktivnih galaktičkih jezgara kombinovanom primenom samoorganizujućih mapa i neuronskih procesa.

Sažetak: Ova doktorska disertacija bavi se razvojem i primenom naprednih metoda za analizu vremenske promjenljivosti aktivnih galaktičkih jezgara (AGJ) kroz modelovanje njihovih optičkih krivih sjaja. Disertacija kombinuje tehnike nenadgledanog i generativnog učenja, koristeći samoorganizujuće mape (SOM) za preprocesiranje podataka i uslovne neuronske procese za predviđanje krivih sjaja.

Po prvi put u analizi krivih sjaja AGJ implementirano je klasterovanje putem SOM metode za preprocesiranje, kao i primena neuronskih procesa za modelovanje stohastičke promjenljivosti u optičkom domenu. Ovaj inovativni pristup omogućava efikasnije modelovanje strukture krivih sjaja sa neravnomernim uzorkovanjem i nedostajućim posmatranjima.

Razvijen je programski paket QNPy, optimizovan za masovno paralelno procesiranje velikih vremenskih serija. Metodologija je testirana na krivama sjaja iz All-Sky Automated Survey for SuperNovae (ASAS-SN) i SWIFT/BAT misije, koje obuhvataju širok spektar vremenskih skala i promjenljivosti.

Analiza rezultata pokazuje da klasterovanje krivih sjaja SOM metodom omogućava unapređenje performansi neuronskih procesa, posebno za objekte sa jednostavnijim obrascima promjenljivosti. Ispitani su uticaji hiperparametara SOM metode na kvalitet klasterovanja i performanse predikcije. Modeli su validirani kvantitativnim merenjima funkcije greške i srednje kvadratne greške na stvarnim posmatračkim podacima.

Predloženi metodološki okvir demonstrira potencijal za skalabilnu obradu velikih vremenskih serija koje će biti generisane projektima kao što je Vera C. Rubin Observatory Legacy Survey of Space and Time (LSST), omogućavajući automatizovanu klasifikaciju, detekciju anomalija i izdvajanje naučno značajnih objekata iz kataloga sa stotinama miliona izvora.

Ključne reči: Aktivna galaktička jezgra, krive sjaja, neuronski procesi, samoorganizujućih mape.

Naučna oblast: Astronomija i astrofizika

Uža naučna oblast: Aktivna galaktična jezgra

Dissertation title: Analysis of variability of Active Galactic Nuclei by combined application of Self-organizing maps and Neural processes

Abstract: This doctoral dissertation addresses the development and application of advanced methods for analyzing the temporal variability of active galactic nuclei (AGN) through the modeling of their optical light curves. The research integrates unsupervised and generative learning techniques, by combining Self-Organizing Maps (SOM) for data preprocessing and Conditional Neural Processes (CNP) for light curve prediction.

For the first time in the study of AGN light curves, clustering via SOM has been implemented for preprocessing, alongside the application of CNP for modeling variability. This innovative approach facilitates a more effective modeling of light curves characterized by uneven sampling and missing observations.

The QNPy software package was developed and optimized for large-scale parallel processing of extensive time series data. The proposed methodology was validated using light curves from the All-Sky Automated Survey for SuperNovae (ASAS-SN) and the SWIFT/BAT mission, covering a broad range of time scales and variability.

The analysis prove that clustering light curves with SOM enhances the performance of neural process, particularly for objects exhibiting simpler variability patterns. The effects of SOM hyperparameters on clustering and prediction performance were carefully examined. The models were validated using loss function and mean squared error evaluations on real data.

The proposed methodology shows strong potential for scalable processing of the large time-series data, anticipated in upcoming projects such as the Vera C. Rubin Observatory's Legacy Survey of Space and Time, enabling automated classification, anomaly detection, and the extraction of scientifically significant objects from catalogs containing hundreds of millions of sources.

Key words: Active Galactic Nuclei, light curves, Neural processes, Self-Organizing Map.

Scientific field: Astronomy and astrophysics

Scientific subfield: Active Galactic Nuclei

Sadržaj

1. Uvod	1
1.1. Predmet doktorske disertacije	3
1.2. Cilj doktorske disertacije	6
1.3. Aktivna galaktička jezgra	7
2. Promenljivost	13
2.1. Radio-astronomija.....	14
2.2. Infracrveni domen.....	20
2.3. Optički i UV domen	26
2.4. AGJ - X-zračenje	34
2.5. Gama zračenje.....	39
3. Podaci.....	45
4. Metode	51
4.1. Neuronski procesi.....	52
4.2. Samoorganizujuće mape	59
5. Rezultati	66
5.1. Rezultati modelovanja CNP metodom	66
5.2. Optimizacija paralelizacijom	71
5.3. Rezultati klasterovanja SOM metodom	77
6. Diskusija rezultata	89
7. Zaključak i budući rad	95
Literatura.....	97
Prilozi	114
Prilog 1: Modeli svetlosnih krivih bez prethodnog klasterovanja.....	116
Prilog 2: Modeli svetlosnih krivih iz klastera 4.....	161
Prilog 3: Modeli svetlosnih krivih iz klastera 13.....	162
Prilog 4: Modeli svetlosnih krivih iz klastera 16.....	163
Biografija autora	164
Изјава о ауторству	165
Изјава о истоветности штампане и електронске верзије докторског рада	166
Изјава о коришћењу	167

1. Uvod

Naučno je prihvaćeno da gotovo sve galaksije u svojim jezgrima poseduju supermasivne crne rupe - SMCR (Rees, 1984; Rees et al, 1982). Jedan deo posmatrane populacije galaksija poznat je kao aktivne galaksije, posebno one na većim crvenim pomacima - kvazari (Atanacković & Vukićević-Karabin, 2010). Ovi objekti se izdvajaju prisustvom aktivnih supermasivnih crnih rupa u svojim jezgrima, koje akretuju materijal iz neposredne okoline, oslobađajući pri tom ogromne količine energije širom elektromagnetnog spektra. Kao posledica ovih procesa, aktivna galaktička jezgra (AGJ) često nadmašuju po sjaju svoje matične galaksije.

Kvazari su otkriveni širom noćnog neba i posmatrani na većim crvenim pomacima, što ih čini ključnim za razumevanje formiranja i evolucije ranog Univerzuma. Ipak, unutrašnje oblasti AGJ ostaju teško dostupne direktnim posmatranjima, usled njihove male uglovne veličine i ograničenja postojećih tehnoloških mogućnosti u rezoluciji.

Kako bi se prevazišla ova ograničenja, razvijene su indirektno metode za istraživanje fizičkih svojstava materije u neposrednoj blizini centralne SMCR. Na osnovu ovih metoda, danas se zna da su supermasivne crne rupe okružene akrecionim diskovima, oblastima koje emituju spektralne linije poznate kao oblast širokih linija (Broad Line Region, BLR), dok su sve zajedno obavijene torusima prišine. Primenom tehnike reverberacionog mapiranja omogućeno je procenjivanje mase centralne SMCR kroz merenje vremenskog kašnjenja između varijacija u različitim komponentama emisije.

Međutim, uprkos značajnom napretku ostvarenim ovim pristupima, mnogi ključni aspekti unutrašnje strukture AGJ i dalje ostaju nedovoljno poznati. To uključuje prostorne dimenzije akrecionog diska, dinamiku materije u regionu

formiranja emisije širokih linija, kao i međudejstvo između akrecionog diska i ostalih komponenti AGJ.

Ova disertacija usmerena je na primenu i unapređenje savremenih indirektnih metoda za istraživanje unutrašnjih oblasti aktivnih galaktičkih jezgara, kombinujući napredne tehnike nenadgledanog dubokog učenja. Struktura ove doktorske disertacije osmišljena je tako da sistematski vodi čitaoca kroz ključne aspekte istraživanja, od teorijskih osnova i motivacije, preko razvijenih metodoloških pristupa, do analize rezultata i diskusije njihovih naučnih implikacija.

U prvom poglavlju, Uvod, postavlja se opšti okvir istraživanja. Definiše se značaj vremenske promenljivosti AGJ, identifikuju se osnovni izazovi u analizi krivih sjaja i formulišu istraživački ciljevi i doprinosi ovog rada. Drugo poglavlje, Promenljivost AGJ u različitim talasnim domenima, pruža pregled posmatračkih karakteristika AGJ kroz različite delove elektromagnetnog spektra. Poseban akcenat stavljen je na identifikaciju fizičkih procesa koji doprinose promenljivosti u svakom od domena.

Treće poglavlje, pod nazivom Podaci, posvećeno je izboru i pripremi podataka korišćenih u istraživanju i daljoj analizi. Opisani su kriterijumi selekcije krivih sjaja, kao i postupci obrade i optimizacije podataka za primenu metoda dubokog učenja.

U četvrtom poglavlju, Metode, detaljno su predstavljene razvijeni metodološki pristupi, samorganizujuće mape i neuronski procesi. Izložena je konstrukcija samorganizujućih mapa (SOM) za klasifikaciju krivih sjaja, kao i modelovanje vremenskih serija primenom neuronskih procesa (NP).

Peto poglavlje, Rezultati prikazuje dobijene modele i njihove analize, obuhvata opis dobijenih rezultata klasifikacije i predikcije krivih sjaja. Analizirana je tačnost i efikasnost razvijenih modela, kao i identifikovani obrasci promenljivosti u krivama sjaja AGJ.

Šesto poglavlje, *Diskusija*, posvećeno je interpretaciji naučnih implikacija dobijenih rezultata, analizi ograničenja primenjenih metoda i razmatranju mogućnosti za dalje unapređenje istraživačkog pristupa. Sedmo poglavlje, *Zaključci i budući pravci istraživanja*, sumira ostvarene ciljeve disertacije, ističe glavne doprinose i predlaže potencijalne pravce za buduća istraživanja u oblasti analize vremenske promenljivosti aktivnih galaktičkih jezgara.

Na kraju disertacije, u *Prilozima*, prikazani su grafički rezultati modelovanja krivih sjaja kvazara pomoću neuronskih procesa (NP). Prilog 1 sadrži rezultate modelovanja bez prethodnog klasterovanja, dok Prilozi 2, 3 i 4 prikazuju rezultate dobijene nakon primene klasterizacije metodom samorganizujućih mapa. Ovi rezultati vizuelno podržavaju diskusiju o uticaju preprocesiranja na tačnost i efikasnost modela.

1.1. Predmet doktorske disertacije

Predmet ove disertacije je istraživanje vremenske promenljivosti aktivnih galaktičkih jezgara, primenom samoorganizujućih mapa i neuronskih procesa u analizi njihovih optičkih emisionih krivih sjaja. Poznato je da većina masivnih galaksija sadrži supermasivnu crnu rupu u svom jezgru (LaMassa et al, 2015). Aktivne galaksije sadrže aktivno galaktičko jezgo, koje emituje jako elektromagnetno zračenje u celom elektromagnetnom spektru, od radio do gama zračenja. Za razliku od zvezda, kod kojih zračenje nastaje nuklearnom fuzijom, zračenje AGJ nastaje konverzijom gravitacione potencijalne energije pri akumulaciji materijala (Rees, 1984; Rees et al, 1982) u supermasivnu crnu rupu i predstavlja daleko efikasnije oslobađanje energije (Fabian, 1997).

AGJ su ključna za istraživanje i razumevanje akrecije materije pod ekstremnim uslovima, koje opisuje opšta teorija relativnosti (Einstein, 1915). Promenljivost u krivama sjaja AGJ je prisutna u svim domenima

elektromagnetnog spektra i varira od nekoliko minuta da nekoliko meseci (Zhang et al, 2024). Važan problem kod analize podataka svih promenljivih objekata je neravnomerna raspoređenost podataka (posmatranja) u vremenu, kao i veliki razmaci između posmatranja pojedinih objekata, koji mogu biti posledica godišnje vidljivosti datog objekta (Shore, Livio, & van den Heuvel, 1994). Zbog toga često ne možemo sa sigurnošću odrediti periodičnost (Shore et al, 1994). Mehanizmi promenljivosti emisije zračenja AGJ još uvek nisu u potpunosti objašnjeni, a neka od objašnjenja uključuju: prisustvo dvojnih sistema (Graham et al, 2015; Kovačević et al, 2019), nestabilnost akrecionih diskova, nehomogenosti pri akreciji (Kelly, Sobolewska, & Siemiginowska, 2011), termalne fluktuacije, magnetorotirajuće nestabilnosti, dvojni sistemi supermasivnih crnih rupa, eksplozije supernovih, kao i reprocesiranje fotona između diska i korone. Krive sjaja u optičkom domenu potiču iz oblaka gasa, koji se kreće velikom brzinom u širokolinijskom regionu supermasivne crne rupe (Elvis, 2000; Urry, 1995). Analiza promenljivosti u optičkom domenu omogućava razumevanje fizičkih procesa koji generišu ovu emisiju (Wagner & Witzel, 1995; Ulrich et al, 1997, Ulrich et al 2003) i strukturu AGJ (Antonucci, 1993; Richards et al, 2006; Bonfield et al, 2010; Shang et al, 2011).

Spektroskopske analize su bile od ključnog značaja za proučavanje sastava i kinematike AGJ. Krive sjaja AGJ su nelinearne, nepravilne, razučene sa ekstremnim flerovima i šumom (Krolik, 1999; Osterbrock, 1989; Peterson, 1997). Dugoročna posmatranja AGJ u optičkom domenu su omogućila važne rezultate analiza širokolinijskih regiona ovih objekata. Zaključeno je da se u zavisnosti od luminoznosti uočavaju promenljivosti u optičkim krivama sjaja reda veličine od nekoliko sati (Cho et al, 2021) do nekoliko dana (Manne-Nicholas et al, 2013; Denney, Peterson, & Pogge, 2009; Peterson, 1998; Shapovalova et al, 2019; Wang, Songsheng, Li, Du, & Zhang, 2020). Do sada je u optičkom domenu bilo moguće izučavati promenljivost na vremenskim skalama reda veličine od desetak dana,

dok u drugim domenima, kao što je X -domen, promenljivost je isključivo na kratkim skalama, manjim od jednog dana.

Trenutne naučne hipoteze koje opisuju promenljivost emisije i strukturu AGJ nastale su pre svega analizom dostupnih podataka. Iz tog razloga je statističko modelovanje podataka posmatranja najbolji izbor za dublju analizu fizičke pozadine i strukture izvora. Modelovanje promenljivosti emisionih krivih AGJ omogućava izučavanje njihovih fizičkih svojstava, kao što su geometrija emisionog regiona (Jankov et al, 2021; Peterson, 2006), mase supermasivnih crnih rupa i klasifikaciju AGJ po raznim karakteristikama.

Zbog turbulentne akrecije sa aperiodičnim ponašanjem u neposrednoj okolini crne rupe, kako raste količina podataka, dobijenih posmatranjem AGJ iz opservatorija, predloženi stohastički modeli imaju sve više problema sa konvergencijom, visokom računskom kompleksnošću i slabo određenim opsezima parametara. Sa druge strane, razvoj algoritama veštačkih neuronskih procesa nenadgledanog i generativnog dubokog učenja, koji se mogu primeniti u astronomiji, doveo je do usmeravanja velikog broja stručnjaka iz oblasti vangalaktičke astronomije ka ispitivanju primene alata dubokog učenja za analizu krivih sjaja AGJ. Alati koji su razvijani i korišćeni za modelovanje krivih sjaja AGJ su: prigušena šetnja – damped random walk, DRW (Kelly et al, 2009; Kozłowski, 2017; Sanchez-Saez et al, 2018), Gausovi procesi - Gaussian Process (GP) (Shapovalova et al, 2017; Kovačević et al, 2019; Shapovalova et al, 2019), autoenkoderi (Tachibana et al, 2020; Bank et al, 2021, Sanchez-Saez et al, 2021), uslovni neuronski procesi - Conditional Neural Process - CNP (Čvorović-Hajdinjak et al, 2022) and Latent Stochastic Differential Equations (SDEs) (Fagin et al, 2023).

Modelovanje krivih sjaja AGJ nam omogućava određivanje i izračunavanje njihovih svojstava, kao što su geometrija emisionog regiona, masa supermasivne crne rupe, kao i moguće klasifikacije AGJ radi daljeg lakšeg, preciznijeg, efikasnijeg i detaljnijeg proučavanja i otkrivanja fizičkih procesa od

kojih potiču promjenljivosti koje uočavamo u krivama sjaja, a koji su još uvek neizvesni.

1.2. Cilj doktorske disertacije


U svjetlu ovog dominantnog problema vangalaktičke astronomije, koji se tiče proučavanja promjenljivosti AGJ, korišćenjem kombinovanih neuronskih procesa sa nenadgledanim učenjem, kako bismo saznali više o fizičkim mehanizmima na širokom rasponu vremenskih skala, ova disertacija polazi od hipoteze da se vremenska promjenljivost AGJ može predstaviti u prostoru niže dimenzije, koji generiše enkoder neuronskog procesa. Takođe se pretpostavlja da samoorganizujuće mape ubrzavaju i poboljšavaju proces učenja, ako se krive sjaja prethodno razvrstaju u klustere sa sličnim topološkim osobinama u manje dimenzionom prostoru (Kovačević et al, 2023). Pretpostavlja se da će karakteristične osobine vremenske promjenljivosti AGJ biti dobijene samim enkoderom na nenadgledan način, čime se njihovo modelovanje i predviđanje nedostajućih posmatranja vrši bez bilo kakvih prethodnih pretpostavki o fizičkom modelu AGJ. Trening i validacija modela biće izvedeni korišćenjem podataka krivih sjaja AGJ dobijenih iz programa All-Sky Automated Survey for SuperNovae (ASAS-SN) (Shappee et al, 2017). Nakon procesiranja podataka, biće ispitani fizički parametri promjenljivosti dobijenih klastera objekata i njihovih modela i upoređeni sa poznatim podacima. Proveriće se da li amplituda optičke promjenljivosti AGJ raste sa smanjenjem sjaja, posmatranom talasnom dužinom i Edingtonovim odnosom i da li njihova strukturna funkcija ima strmiji nagib nego kod AGJ sa većom masom crnom rupe. Posebna pažnja biće posvećena traženju i analizi klastera krivih sjaja sa ekstremnim promenama fluksa/magnitudo, koje nam mogu pomoći u razmevanju porekla aktivnosti kod AGJ.

Poseban cilj disertacije je da se ovim metodama omogući prilagodljiv i jasan pristup uočavanja promjenljivosti u velikim skupovima posmatranja, bez oslanjanja na prethodne pretpostavke o fizičkom modelu AGJ.

1.3. Aktivna galaktička jezgra

Marten Šmit (Maarten Schmidt) je 1963. otvorio novu granu proučavanja vangalaktičkih objekata. On je posmatrajući objekat 3C273 uočio da ovaj kvazar ima veoma neobičan spektar i misteriozni mlaz. Proučavajući spektar ovog objekta, shvatio je da se ne radi o novim elementima, već da je u pitanju vodonik, čija je spektralna linija značajno pomerenka ka crvenom delu spektra. Zaključio je da je takav crveni pomak posledica velike udaljenosti ovog objekta (3 milijarde svetlosnih godina), a samim tim i da posmatrano zračenje potiče od veoma jakog izvora. Saznanje da 3C273 ima izuzetno veliku luminoznost, a da sa druge strane zauzima relativno mali prostor, otvorilo je vrata proučavanju objekata sa osobinama koje se mogu objasniti jedino postojanjem velikih crnih rupa u njihovim centrima (Popović & Ilić, 2017). Ovakvi objekti zahtevaju uređaje koji bi bili u mogućnosti da sagledaju i analiziraju svu njihovu kompleksnost i omogućće analizu i razvoj naučnih hipoteza o ovim objektima.


AGJ su vangalaktički objekti čije zračenje potiče od akrecije koja se odvija u supermasivnoj crnoj rupi (mase $M_{\text{BH}} \sim 10^6 - 10^9 M_{\odot}$) u centru posmatrane galaksije. Njihova bolometrijska luminoznost je $L_{\text{bol}} \sim 10^8 - 10^{11} L_{\odot}$. Ovi objekti imaju jaku kontinualnu emisiju na svim talasnim dužinama elektromagnetnog spektra i veoma veliku luminoznost (Slika 1).



Slika 1: Šematski prikaz spektralne energetske raspodele (Spectral Energy Distribution - SED), baziran na posmatranim spektralnim energetskim raspodelama radio tihih AGJ. Crna linija predstavlja totalnu spektralnu energetsku raspodelu, dok različite obojene krive predstavljaju pojedinačne komponente. Primarna emisija iz akrecionog diska AGJ ima maksimum u UV opsegu. Radio jaka AGJ imaju radio emisiju nekoliko reda veličina veću od radio slabih (što je prikazano narandžastim krivama). Na grafiku je prikazan i primer spektralne energetske raspodele u radio i UV opsegu zvezdorodne galaksije (siva kriva, galaksija M82) (Silva et al, 1998).

Kod nekih AGJ je prisutno izbacivanje materije iz jezgra u formi usmerenog mlaza, kao i velike radio strukture na velikim udaljenostima od jezgra (radio ovali). Na osnovu njihovih karakteristika koje su u većoj ili manjoj meri prisutne u određenim aktivnim galaktičkim jezgrima, vršena je njihova podela na brojne klase (Sejfertove galaksije tipa 1, Sejfertove galaksije tipa 2, radio jake, radio slabe, linere, kvazare, blazare i mnoge druge). Kasnije je uočeno da većina ovih naizgled različitih objekata zapravo ima iste karakteristike, ali se

parametri razlikuju zbog: orijentacije objekta (Antonucci, 1993; Urry & Padovani, 1995; Netzer, 2015), stope akrecije (Heckman & Best, 2014), postojanja jakih mlazeva (Padovani, 2016), kao i osobina same galaksije u kojoj se jezgro nalazi i njene okoline (Padovani, 2017).



Slika 2: Šematski prikaz anatomije AGJ prema standardnom unifikacionom modelu (Urry & Padovani, 1995). Model ilustruje ključne komponente AGJ, uključujući centralnu supermasivnu crnu rupu (Black Hole), akrecioni disk (Accretion Disk), oblast širokih linija (Broad Line Region), oblast uskih linija (Narrow Line Region), torus prašine (Obscuring Torus) koji zaklanja unutrašnje strukture, i relativističke mlazeve (Jet). Različite posmatrane osobine AGJ zavise od orijentacije sistema u odnosu na posmatrača.

Posmatranja zračenja različitih talasnih dužina omogućavaju razumevanje različitih fizičkih procesa koji ih uzrokuju. Infracrveno zračenje nam pokazuje regione prašine (torus), koji zaklanjaju zračenje iz optičkog dela spektra. Optičko i UV zračenje potiču iz akrecionog diska i otkrivaju njegove osobine. Ustanovljeno je i da X-zračenje potiče od korone, dok nam posmatranja gama i radio signala omogućavaju da vidimo mlazeve i njihovu strukturu, kao i fizičke procese koji se u njima odvijaju. Kombinovanjem posmatranja u celom elektromagnetnom spektru, kao i analizom porekla i vremenske promenljivosti

različitih komponenti emisije, moguće je rekonstruisati morfologiju AGJ. Na Slici 2 prikazana je šematska struktura AGJ prema standardnom unifikacionom modelu (Antonucci & Miller, 1985; Antonucci, 1993; Urry & Padovani, 1995). U centru sistema nalazi se supermasivna crna rupa koja akretuje materiju iz okolnog akrecionog diska. Ostatak strukture, uključujući oblast širokih linija, oblast uskih linija, torus prašine i relativistički mlazevi, posledica su fizičkih procesa izazvanih akrecijom (Popović & Ilić, 2017).

Jedno aktivno galaktičko jezgro može emitovati ukupnu količinu energije ekvivalentnu zračenju nekoliko milijardi zvezda. Izuzetno kompaktan centralni izvor, zapremine manje od jednog kubnog parseka, generiše emisiju koja se prostire kroz ceo elektromagnetni spektar. Ta emisija uključuje termalno Plankovo zračenje iz akrecionog diska, zakočno (bremsstrahlung) zračenje iz korone, inverzno Komptonovo rasejanje, sinhrotronsko zračenje iz mlazeva, kao i kreaciju i anihilaciju elektron-pozitron parova usled interakcije gama fotona visokih energija (Popović & Ilić, 2017).

Tabela 1: Relevantne svemirske opservatorije za istraživanje AGJ.

Misija	Talasni domen	Status	Relevantnost za AGJ
Hubble Space Telescope (HST)	Optički i UV domen	Aktivna	Proučavanje strukture jezgra, reverberaciono mapiranje
Chandra X-ray Observatory	X domen	Aktivna	Rendgenska posmatranja AGJ visoke rezolucije
XMM-Newton	X domen	Aktivna	Dugotrajna posmatranja promenljivosti AGJ u X domenu
Neil Gehrels Swift Observatory	UV i X domen	Aktivna	Praćenje promenljivosti AGJ u više talasnih domena

Fermi Gamma-ray Space Telescope	Gamma domen	Aktivna	Praćenje emisije visoke energije blazara i AGJ
Gaia	Optički domen, astrometrija	Aktivna	Astrometrijska analiza AGJ, prepoznavanje dvojnih SMCR
James Webb Space Telescope (JWST)	Infracrveni (IR) domen	Aktivna	Proučavanje prašnjavih torusa i slabih AGJ na velikim crvenim pomacima
eROSITA	X domen	Aktivna (pauza od 2022)	Veliki katalog AGJ uočenih posmatranjima u X domenu
Athena	X domen	U pripremi (~2030)	Istraživanja AGJ i evolucije SMCR, posmatranjima u X domenu
Lynx (koncept)	X domen	Predložena	Posmatranja X domena AGJ u veoma visokoj rezoluciji
Roman Space Telescope	Infracrveni i optički domen	U pripremi (~2027)	Širokopolna istraživanja AGJ i reverberacionih karakteristika

Za veliki broj objekata u Univerzumu uočene su promene u luminoznosti tokom vremena. Ova prividna promenljivost može imati brojne uzroke: periodične fizičke promene samog izvora (Cefeide i RR Lyrae), kretanje (binarni sistemi, mikrosočiva, rotacija), eksplozivne pojave (nove i supernove) i akrecija (AGJ). Ono što je karakteristično za aktivna galaktička jezgra je promenljivost u kontinuumu i linijama duž celog spektra, na osnovu koje je moguće odrediti karakteristike ovih objekata. Promenljivost AGJ se objašnjava kao stohastički proces (Kelly et al, 2009, 2014; Graham et al, 2016; Simm et al, 2016). Analizom spektralne gustine snage (power spectral density - PSD), odnosno analizom

distribucije snage signala u frekvencijskom domenu, mogu se otkriti fizički procesi koji proizvode stohastičku promjenljivost AGJ. Glavna prepreka u analizi vremenske promjenljivosti AGJ predstavlja nedovoljna količina podataka i njihova neravnomerna raspoređenost u vremenu, što je očekivano imajući u vidu složenost samih objekata, kao i tehničke izazove izvođenja posmatranja u različitim delovima elektromagnetnog spektra.

Da bi se omogućilo sistematsko istraživanje vremenske promjenljivosti AGJ, neophodna su posmatranja u širokom rasponu elektromagnetnog spektra. Specifične fizičke komponente AGJ emituju dominantno u različitim talasnim domenima, što zahteva kombinovanje podataka iz više spektralnih oblasti. Zbog tehnoloških ograničenja i kompleksnosti samih sistema, dosadašnji skupovi podataka često ostaju fragmentarni i vremenski ograničeni.

Relevantne svemirske misije koje doprinose prikupljanju podataka o AGJ, sa naznakom njihovih karakteristika, talasnih domena koje pokrivaju različite aspekte istraživanja, prikazane su u Tabeli 1. Dugoročno posmatranje ovih izvora u malim razmacima, na svim talasnim dužinama, bi moglo u velikoj meri doprineti proučavanju njihove promjenljivosti, čime bi bilo moguće utvrditi morfologiju izvora i fizičke procese koji bi mogli uzrokovati takve promene u emisiji.

2. Promenljivost

Energija i spektar emitovanog zračenja u AGJ određeni su stopom akrecije mase \dot{M} , koja predstavlja količinu materije koja pristiže na supermasivnu crnu rupu po jedinici vremena i efikasnošću konverzije mase u zračenje η . Ukupna emitovana snaga akrecionog diska izražava se sa: $L = \eta \dot{M} c^2$, gde je c brzina svetlost ($c = 299792458 \text{ m/s} \cong 3 \times 10^8 \text{ m/s}$). Pri uslovu hidrostatičke ravnoteže (pritiska zračenja i gravitacije), akrecija dostiže Edingtonovu graničnu vrednost (Krolik, 1999; Abramowicz, M. A., Calvani, M., & Nobili, 1980; Shakura & Sunyaev, 1973):

$$\dot{M}_E = \frac{16\pi G m_p M}{c \sigma_T} \mu_{GR} , \quad (2.1)$$

gde je M masa objekta, G gravitaciona konstanta, V , σ_T je vrednost koja predstavlja vrtovatnoću da će foton biti rasejan na slobodnom elektronu, pod pretpostavkom da elektron nije ubrzan do relativističkih brzina (Thompson cross section), $\mu_{GR} \equiv \frac{r_g}{r_{in}} \ll 1$, gde je $r_g = \frac{2MG}{c^2}$, gravitacioni radijus centralnog objekta.

Odgovarajuća Edingtonova luminoznost data je izrazom:

$$L_E = \frac{4\pi G m_p M}{\sigma_T} = 1,257 \times 10^{38} \frac{M}{M_\odot} \frac{\text{erg}}{\text{s}} . \quad (2.2)$$

Edingtonova luminoznost (sjajanost) predstavlja odnos vrednosti pritiska zračenja i gravitacione sile kod crnih rupa iznad koje radijacija nadjačava gravitaciju. Posmatrane luminoznosti AGJ kreću se od $\sim 10^{42}$ do $\sim 10^{48} \text{ erg/s}$, što implicira da centralne supermasivne crne rupe imaju mase¹ između 10^5 do $10^9 M_\odot$ (Krolik, 1999).

Za kvantitativno ispitivanje vremenske promenljivosti AGJ, može se primeniti metoda analize razlika flukseva između parova posmatranja odvojenih

¹ Na osnovu poznate vrednosti luminoznosti moguće je proceniti karakteristične dimenzije regiona iz kog promenljivost potiče, koristeći brzinu svetlosti ($c \approx 3 \times 10^5 \text{ km/s}$) i izraz za Švarcšildov poluprečnik $R_s = 2GM/c^2$.

različitim vremenskim razmacima. Ova metodologija, koja se široko koristi u studijama promenljivosti kvazara (MacLeod et al, 2010), omogućava konstrukciju zavisnosti promena fluksa od vremenskog intervala.

Za svaki par merenja definišu se:

$$\Delta t = t_j - t_i \quad , \quad (2.3)$$

$$\Delta \log F = \log F(t_j) / F(t_i) \quad , \quad (2.4)$$

gde su F fluksevi zračenja izmereni u vremenima t_i i t_j , respektivno. Logaritamska razlika flukseva $\Delta \log F$, koristi se da bi se omogućilo simetrično poređenje povećanja i smanjenja intenziteta, kao i da bi se olakšala interpretacija relativnih promena. Prikaz svih izračunatih vrednosti $\Delta \log F$ u funkciji Δt pruža preliminarni uvid u karakteristike vremenske promenljivosti, dok agregacija ovih vrednosti u binovima vremenskih razmaka omogućava dalje konstrukcije, kao što je strukturalna funkcija (Structure Function, SF), koja kvantitativno opisuje rast promenljivosti emisije sa povećanjem vremenskog razmaka. Tradicionalni statistički alati za stohastičko modelovanje krivih sjaja aktivnih galaktičkih jezgara u cilju analize promenljivosti su prigušena slučajna šetnja (DRW) i (perturbacijski vođeni) prigušeni harmonijski oscilator (DHO). Metoda kojom se utvrđuju varijacije je analiza stepene spektralne gustine (Power Spectral Density - PSD). PSD signala opisuje kako je snaga tog signala raspoređena po frekvenciji. Obično se izračunava kao Fourierova transformacija funkcije autokorelacije signala. Za signal u vremenskom domenu $x(t)$, PSD definiše se kao Fourierova transformacija autokorelacione funkcije.

2.1. Radio-astronomija

Aktivna galaktička jezgra emituju zračenje koje nastaje kao posledica akrecije koja se odvija u supermasivnoj crnoj rupi u centru posmatrane galaksije. Frekvencije koje obuhvataju radio spektar su od oko 10 MHz ($\lambda \sim 30$ m) do nekoliko desetina


GHz (e.g. 30 GHz, $\lambda = 1$ cm). Oko deset procenata AGJ su radio jaka AGJ (Jiang et al, 2007). Ova činjenica obezbeđuje dodatani način za identifikaciju AGJ, imajući u vidu da su zvezde slabi radio izvori, pa tako ako uočimo optički izvor koji je istovremeno i jak radio izvor, velika je verovatnoća da će to biti radio jako AGJ (drugi jaki izvori radio emisije mogu biti zvezdorodni regioni). Za radio jako AGJ su karakteristični i relativistički mlazevi, koji se linearno prostiru izbacujući energiju i čestice iz kompaktnog centralnog regiona AGJ na udaljenostima od nekoliko kiloparseka do nekoliko mekgaparseka (Begelman et al, 1984; Peterson, 1997).

Nakon opšte karakterizacije radio emisije AGJ, posebnu pažnju posvećujemo aspektima analize njihove vremenske promenljivosti. Ona će nam omogućiti sagledavanje ključnih uvida u unutrašnju strukturu mlazeva i akrecionih procesa.

Periodičnost posmatrane emisije u radio spektru se smatra jednom od karakterističnih odlika AGJ. Za radio jako AGJ, radio promenljivost u najvećoj meri potiče od sinhrotronske emisije iz relativističkih tokova plazme u mlazevima koji se prostiru sa suprotnih strana AGJ (Urry & Padovani 1995). Promenljivost u radio spektru AGJ je posmatrana na velikom broju objekata u brojnim opservatorijama desetinama godina. Na osnovu posmatranja i teorijskih modela, ustanovljeno je da postoje nehomogenosti u mlazevima (Aller et al, 1985; Marscher & Gear, 1985; Hughes et al. 1991; Lister et al, 2001, 2009; Marscher et al, 2008, 2010). Poznato je da najveći flerovi (ekstremi u emisionim linijama) potiču od stvaranja i relativističkog kretanja, koji se vide kao radio čvorovi (Hughes et al, 1991), dok manje varijacije mogu biti uzrokovane promenom smera i Doplerovim efektom u mlazevima (Camenzind & Krockenberger, 1992; Gopal-Krishna & Wiita, 1992).

Posebno nas zanimaju statističke osobine fluktuacija, uključujući amplitude i vremenske skale, koje mogu otkriti unutrašnje fizičke procese u mlazevima. Flerovi u radio spektru radio mlazeva AGJ su objašnjeni modelima

udarnih talasa (Marscher & Gear, 1985; Hughes et al, 1985). Prema ovim modelima udarni talas se formira u bazi mlaza i kreće se niz mlaz (Popović & Ilić, 2017). Tokom tog procesa se uočava sinhrotronska radijacija na različitim frekvencijama, a posmatrane karakteristike zavise od faze u kojoj se udarni talas nalazi (Slika 3).



Slika 3: Fizički model udarnih talasa u mlazu crne rupe (black hole) (Marscher & Gear, 1985). Talas se kreće duž mlaza. Elektroni (relativistic electrons) kroz koje prolazi front talasa (propagating shock front) dobijaju ubrzanje i emituju sinhrotronsku radijaciju (synchrotron emission) iza talasnog fronta.


U mlazevima materije imamo relativističke elektrone u magnetnom polju koji emituju sinhrotronsko zračenje, koje je izvor novih fotona. Sinhrotronski fotoni mogu intereagovati sa elektronima u procesima inverznog Komptonovog rasejanja. Elektroni učestvuju u interakciji dva puta, pa se taj poces naziva sinhrotronsko sopstveno Komptonovo rasejanje (Sinchrotron Self-Compton - SCC).

Periodičnost se može javiti i kao posledica turbulencijame u mlazevima (Marscher et al, 2008; Marscher, 2014; Calafut & Wiita, 2015) ili različitim brzinama u pojedinim regionima mlazeva (Giannios et al, 2009). Promene u smeru unutrašnjeg dela mlaza su ustanovljene korišćenjem dugobazične interferometrije (very long baseline interferometry - VLBI) (Biretta et al, 1986; Piner, 2003; Caproni & Abraham, 2004; Lister et al, 2013).

AGJ koja imaju mlazeve, usmerene u ravni ka posmatraču nazivaju se blazari. Promenljivost kod blazara je veoma drugačija od promenljivosti kod drugih AGJ. Njih karakteriše veoma jaka promenljivost na svim talasnim dužinama. Za razliku od radio slabih kvazara ili Sejfertovih galaksija, blazari pokazuju veliku promenljivost u infracrvenom i radio kontinuumu. Polarizacija kontinuuma je takođe značajna. Stepem polarizacije i amplitude promenljivosti koreliraju sa luminoznošću izvora, što nije slučaj kod drugih AGJ. Detektovana energija je izrazito velika (TeV) što ukazuje da zračenje kontinuuma potiče od relativističkih mlazeva, jer ovakve karakteristike ukazuju na netermalno (sinhrotronsko i inverzno Komptonovo) zračenje.

Podela radio galaksija se može izvršiti i prema njihovoj radio morfologiji, pa tako imamo dve kategorije: FR I (Fanaroff-Riley, 1974) – to su izvori kod kojih dominira emisija iz mlazeva i centralnog dela, slabijeg intenziteta i FR II (Fanaroff-Riley, 1974), kod kojih dominira emisija iz ovala i imaju veću luminoznost. Pronađeni su i neki izvori koji imaju karakteristike oba tipa (hybrid-morphology radio sources - HYMORS), tačnije strukturu tipa FR I sa jedne strane radio izvora, a strukturu FR II sa druge strane (Gopal-Krishna & Wiita, 2000). Ovi objekti su važni, jer mogu objasniti razloge različitih morfologija. Uočavanje različitih struktura može biti posledica različitih karakteristika sredine sa različitih strana AGJ (Bicknell, 1994; Gopal-Krishna & Wiita, 2001; Massaglia et al, 2016) ili položaja i kretanja objekta u odnosu na pravac posmatranja i vremenski razmak između uzastopnih posmatranja

(Gopal-Krishna & Wiita, 2000, 2004; Massaglia, 2003; Wold et al, 2007; Kawakatu et al, 2009; Kapinska et al, 2017).



Slika 4: Kriva sjaja u radio opsegu objekta J1415+1320 na različitim frekvencijama (Vaddi et al 2022). Prikazani podaci su prikupljeni u različitim projektima/teleskopima – Owens Valley Radio Observatory (OVRO, Richards et al, 2014), Green Bank Interferometer (GBI, Lazio et al, 2001), Submillimeter Common User Bolometer Array (SCUBA, Jenness et al, 2010), Very Long Baseline Array (VLBA, Lister et al, 2009), University of Michigan Radio Astronomy Observatory (UMRAO, Aller et al, 2010).


Na Slici 4 su prikazani delovi krive sjaja u radio opsegu na različitim frekvencijama, objekta J1415+1320. Podaci obuhvataju period od skoro 40 godina (1978 - 2018), koji su prikupljeni tokom različitih posmatračkih programa. Jasno je vidljiva promenljivost na svim prikazanim frekvencijama, koja je višeg intenziteta na većim frekvencijama. Ako se fokusiramo na podatke iz UMRAO posmatranja, može se uočiti da se karakteristike promenljivosti koje su uočljive

na 15 GHz, ponavljaju i na 8 i 5 GHz, s tim što je intenzitet promenljivosti slabiji. Takođe se vidi smanjenje u promenljivosti nakon 2002. godine. Dugoročno i višetalasno praćenje svetlosnih krivih sjaja omogućava detekciju retkih fenomena poput gravitacionog sočiva, koje se manifestuje kao simultana i simetrična promena fluksa na svim posmatranim frekvencijama. Narandžasti rombovi na Slici 4 označavaju prosečne vrednosti 10 do 15 uzastopnih posmatranja (koja su obavljena u razmaku od nekoliko dana) na frekvenciji od 327 MHz tokom perioda od 1989. do 2017. Jasno su uočljiva dva flera, koja se vide i na visim frekvencijama (podaci prikupljeni u OVRO).

Uočene promene su u skladu sa modelom koji predviđa ekspanziju oblaka relativističkih elektrona² (Marscher & Gear, 1985), kao i modelom udarnih talasa (van der Laan, 1966). Posebno je zanimljiva simetrična ahromatska promenljivost (SAV) na višim frekvencijama, čiji uzrok može biti efekat gravitacionog mili-sočiva (Slika 5). Ovaj efekat se vidi kao udubljenje u obliku slova U krivi sjaja (simetrično u posmatranom vremenskom intervalu). Ovakva pojava je veoma retka i smatra se da je posledica emisije iz jezgra blazara J1415+1320, koja biva „zaklonjena“ masom $10^2 - 10^5 M_{\odot}$. U prilog ovom objašnjenju ide i činjenica da je uočena pojava prisutna na svim posmatranim frekvencijama, što je karakteristično za gravitaciona sočiva. Ahromatska priroda ove promenljivosti ukazuje na eksterno poreklo, kao što je gravitaciono sočivo.

Objekti koji bi mogli zadovoljiti uslov dat za masu gravitacionog sočiva ($10^2 - 10^5 M_{\odot}$), mogu biti gusta jezgra globularnih jata ili molekularni oblaci, kao i masivne crne rupe. Moguće je i da se sočivo sastoji od više komponenti koje projektuju svetlost u liniji posmatranja, ali nisu međusobno gravitaciono vezani. Uzimajući u obzir ova razmatranja, jasno je da se posmatranjem i daljom analizom AGJ može doći do mogućih objašnjenja strukture izvora, ali i strukture i raspodele mase između nas i posmatranog objekta.

² Elektrona koji se kreću relativističkim brzinama.



Slika 5: Kriva sjaja objekta J1415+1320 na različitim frekvencijama sa vidljivim simetričnim ahromatskim promenljivostima (SAP) na istaknutim površinama. „Udubljenja“ u obliku slova U na krivama sjaja, trajanja oko godinu dana, uočena 1993, 2000, 2009. i 2014. godine (Vedantham et al, 2017).

2.2. Infracrveni domen

Posmatranja u infracrvenom delu spektra imaju značajnu ulogu u razumevanju strukture i evolucije AGJ. Infracrveni spektar se može podeliti na tri dela:

1. blisko infracrveno područje (near-infrared - NIR (1 - 3 μm)),
2. srednje infracrveno područje (mid-infrared - MIR (3 - 50 μm)) i
3. daleko infracrveno područje (far-infrared - FIR (50 - 500 μm)).

Infracrveno zračenje dominira AGJ SED na talasnim dužinama od jednog do nekoliko desetina mikrometara. Slika 6 prikazuje doprinos različitih struktura u infracrvenom spektru AGJ. Na najvećim skalama, reda veličine desetina

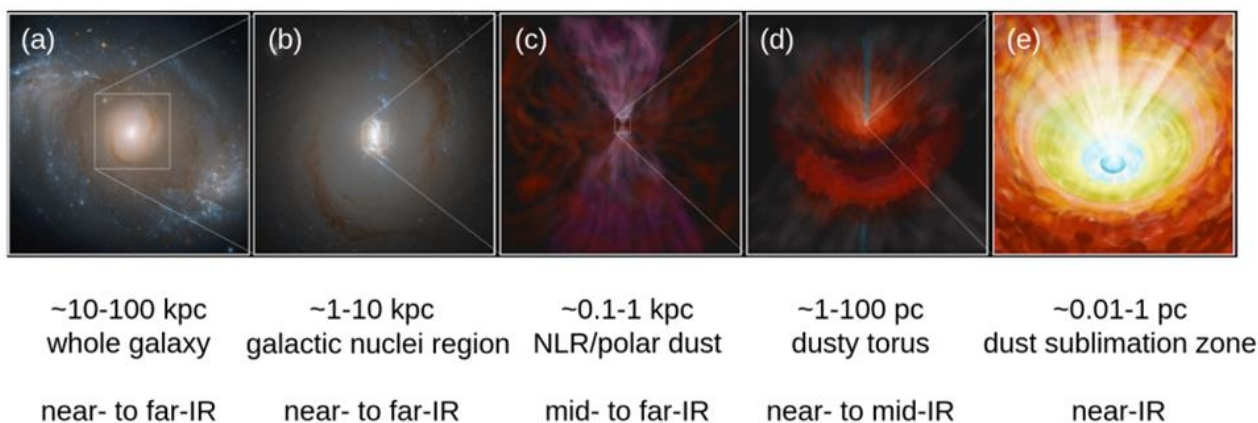
kiloparseka, dominira emisija cele galaksije domaćina, sa izraženim udelom zvezdanog zračenja u bliskom i dalekom infracrvenom opsegu. Približavanjem centralnim regionima, na udaljenostima reda veličine nekoliko stotina parseka, emisija postaje sve više vezana za galaktičko jezgro, gde u near-IR delu spektra preovlađuje svetlost iz gustih zvezdanih populacija. U regionu koji se nalazi na ~100 parseka od SMCR, oblast uskolinijskih linija (NLR) i polarni konusi prašine emituju dominantno u srednjem infracrvenom opsegu, usled reemitovanja zračenja iz AGJ kroz zagrejanu prašinu. Još bliže SMCR, na skalama reda veličine 1-100 parseka, nalazi se torus prašine, čija emisija u mid-IR i far-IR opsegu potiče od apsorpcije i reemitovanja energije iz akrecionog diska. Najzad, u centralnom regionu torusa (~0.01-1 parsek), sublimacija prašine uzrokuje jaku emisiju u near-IR delu spektra, neposredno povezanu sa najdubljim slojevima akrecionog diska i njegovim termalnim izvorom zračenja.

Model AGJ u kome struktura sadrži „torus prašine“ dosta dobro objašnjava uočene osobine različitih AGJ. Po ovom modelu akrecioni disk je okružen torusom prašine, molekularnog i neutralnog gasa, koji zaklanja širokilinijski region (broad line region - BLR). Ovaj model odgovara i unifikacionoj šemi (Antonucci, 1993; Urry & Padovani, 1995) po kojoj AGJ Tipa 1 i Tipa 2 imaju istu strukturu, a razlike koje se uočavaju u njihovim emisionim linijama potiču od ugla posmatranja u odnosu na prašinu u torusu (kod Tipa 2 torus zaklanja akrecioni disk i širokolinijski region).

Najveći deo energije AGJ nastaje u akrecionom disku i vidljiv je u UV i optičkom delu spektra. Prašina u torusu apsorbuje deo emisije koja nastaje u akrecionom disku. Ta emisija se zagreva i reemituje kao infracrvena radijacija (Rieke, 1978). To je utvrđeno na osnovu promenljivosti u optičkom i infracrvenom delu spectra, nakon čega je utvrđeno da postoji korelacija između zračenja u bliskom infracrvenom i optičkom delu spektra (Suganuma et al, 2006; Lira et al, 2011, 2015). Emisija u optičkom delu spektra dolazi prvenstveno iz

akrecionog diska, dok infracrveno zračenje potiče od torusa prašine (Lira et al, 2011, 2015).

Nakon što su opisane prostorne komponente, koje doprinose emisiji u infracrvenom spektru, sledeća sekcija se fokusira na vremenske promene emisije. Analiza vremenskih promena emisije omogućava proučavanje dinamike torusa i akrecionog diska.




Slika 6: Ilustracija različitih komponenti aktivnog galaktičkog jezgra koje doprinose emisiji u infracrvenom delu spektra, sa prikazom prostorne skale i dominantnih talasnih dužina. Od cele galaksije (*whole galaxy*) do unutrašnjih regiona torusa (*dusty torus*), različite strukture zrače u *near-IR*, *mid-IR* i *far-IR* opsezima. Ovaj prikaz ističe kako prostorna udaljenost od centralne supermasivne crne rupe određuje dominantni deo infracrvenog spektra emisije (Lyu & Rieke, 2022).

Tačna morfologija torusa još uvek nije poznata. Analize posmatranja, odnosno promenljivosti daju nekoliko mogućnosti strukture torusa. Na osnovu nekih je moguće zaključiti da je prašina u torusu ravnomerno raspoređena (Pier & Krolik, 1992; Dullemond & van Bemmelen, 2005; Fritz, Franceschini, & Hatziminaoglou, 2006). Sa druge strane postoje indicije i da se javljaju optički i geometrijski debeli oblaci unutar torusa (Krolik & Begelman, 1988; Nenkova, Ivezić, & Elitzur, 2002; Nenkova et al, 2008; Elitzur & Shlosman, 2006; Tristram

et al, 2007), dok je u nekim radovima razmatrana kombinacija ova dva modela (Stalevski et al, 2012; Stalevski et al, 2016; Gandhi et al, 2010). Posmatranja u bliskom infracrvenom delu spektra idu u prilog grudvastoj strukturi torusa (Nenkova et al, 2008; Nikutta et al, 2009; Hatziminaoglou et al, 2015), ali i dalje nije moguće odbaciti druge modele (Feltre et al, 2012).

Proučavanje promenljivosti u NIR je veoma kompleksno i zahtevno, jer kontaminacija od galaksije domaćina na ovim talasnim dužinama (Slika 7) može biti veoma velika (Hernan-Caballero et al, 2016).



Slika 7: Ilustracija mogućeg uticaja prašine iz galaksije domaćina na spektralnu energetska raspodelu u infracrvenom delu spektra AGJ (Sajina et al, 2022). Prikazano je poređenje spektra pre (levo) i posle (desno) procesiranja od strane prašine galaksije domaćina.


Zbog kontaminacija emisije od strane galaksije domaćina je za većinu izvora, promenljivost centralnog izvora u NIR zaklonjena radijacijom zvezda i HII regiona iz same galaksije. Ranija istraživanja promenljivosti u NIR

(Neugebauer et al, 1989) su pokazala da je samo polovina izvora na ovim frekvencijama promenljiva, dok novija (Enya et al, 2002) sugerišu da većina AGJ ima uočljivu promenljivost u IR. Potrebna je velika količina podataka i dugoročno posmatranje u IR opsegu da bi se jasnije utvrdile odlike područja iz kojih dolazi ova emisija.

Među svim vangalaktickim objektima, AGJ su primarni izvori koji pokazuju velike promene u MIR opsegu, na skalama reda veličine nekoliko godina. Ova osobina se zato može koristiti kao dodatni metod za prepoznavanje AGJ (Kozłowski et al, 2010). Utvrđeno je da postoji korelacija između emisije u NIR iz torusa i emisije u optičkom delu spektra (Suganuma et al, 2006; Lira et al, 2011, 2015), koja potiče primarno iz akrecionog diska. Ova osobina omogućava da se promenljivost koja se uočava u IR opsegu koristi za izračunavanje veličine crne rupe reverberacionim mapiranjem. Varijacije u emisiji u IR delu spektra mogu ukazivati i na nehomogenosti u torusu, kao i na perturbacije u akrecionom disku od koga potiče zračenje. Reverberaciono mapiranje u infracrvenom domenu omogućava nezavisno merenje veličine torusa, pružajući ključne informacije o geometriji i strukturi regiona oko akrecionog diska.

Jedno zanimljivo istraživanje koristi između ostalog i upravo tu činjenicu da je infracrvena emisija u torusu odraz (posledica) emisije u akrecionom disku (koja se u najvećem obimu može posmatrati u optičkom i UV delu spektra). Naime, u radu Sheng et al. iz 2017, se analizira promenljivost u MIR nekoliko AGJ promenljivog tipa. AGJ promenljivog tipa su AGJ kod kojih se široke emisione linije pojavljuju i nestaju u različitim periodima posmatranja, Tip 1 (Sejfertove galaksije Tipa 1) - one koje imaju široke emisione linije koje potiču iz širokolinijskog regiona; Tip 2 (Sejfertove galaksije Tipa 2) - one koje imaju uske emisione linije koje potiču iz uskolinijskog regiona, jer je po unifikacionom modelu (Antonucci, 1993; Urry & Padovani, 1995) širokolinijski region zaklonjen torusom prašine, zbog ugla posmatranja). Poznato je nekoliko primera AGJ promenljivog tipa (iz Tipa 2 u Tip 1, Khachikian & Weedman, 1971; iz Tipa 1 u

Tip 2, Penston & Perez, 1984), kod kojih je uočeno nestajanje i pojavljivanje širokih linija (Slika 8). Mali broj ovakvih objekata je uočen, što otežava detaljniju analizu.




Slika 8: Spektar AGJ promjenljivog tipa J1115+0544 u optičkom i NIR delu spektra. Plavom bojom je označeno posmatranje LAMOST 2015, a crnom SDSS iz 2002. Na osnovu podataka Sloan Digital Sky Survey (SDSS) i Large Sky Area Multi-Object Fiber Spectroscopic Telescope (LAMOST) otkriveno je 21 novih AGJ promjenljivog tipa (Qian Yang et al, 2018).

Nije sasvim jasno zašto se javljaju ove promene. Neke od mogućnosti su: postojanje objekata, koji se nalazi na liniji posmatranja i svojim kretanjem povremeno zakloni emisiju iz širokolinijskog regiona (Goodrich, 1989). Ukoliko je priroda uočenih varijacija ahromatska, to bi moglo da sugeriše da promenljivost nije lokalnog porekla (npr. akrecione nestabilnosti), već da je verovatnije uzrokovana eksternim efektima kao što su gravitaciona sočiva. Druga mogućnost je da su ovakve promene posledica dramatičnih promena intenziteta akrecije u nestabilnom akrecionom disku (Sheng et al, 2017). Dok reverberacioni efekti ukazuju na strukturu oko jedne supermasivne crne rupe,

dodatni oblici promenljivosti, kao što su periodične promene, mogu ukazati na postojanje binarnih sistema supermasivnih crnih rupa (SMBHB).

2.3. Optički i UV domen

Kada posmatramo SED AGJ, uočavamo da emisija koja potiče od termalne emisije iz akrecionog diska pri temperaturi reda veličine 10^4K , ima izbočen oblik sa maksimumom u UV oblasti (Slika 9). Interesantan deo u ovom opsegu spektra je “veliko plavo ispupčenje” (big blue bump), koje predstavlja zaravnjenje maksimalnog dela kontinuuma i prostire se u opsegu od ~ 1000 do 4000 \AA .

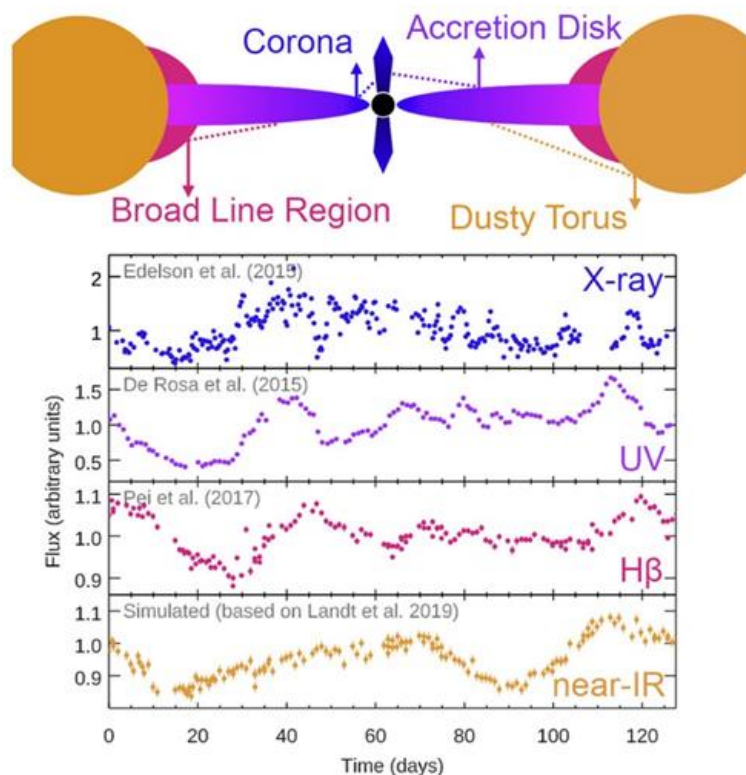


Slika 9: Spektralna energetska raspodela (SED) aktivnih galaktičkih jezgara od radio do X-zračenja. SED radio-slabilh AGJ prikazan je punom crnom linijom, dok je SED radio-jačih AGJ prikazan isprekidanom linijom. Ovaj prikaz omogućava identifikaciju dominantnih komponenti – relativističkog mlaza (Relativistic Jet), prašine (Dust), akrecionog diska (Accretion disk) i korone (Corona) – koje doprinose ukupnoj emisiji AGJ (Elvis et al, 1994).

Emisija u UV i optičkom delu spektra omogućava istraživanje procesa akrecije u AGJ, dok praćenje promenljivosti u ovim domenima pruža uvid u unutrašnje strukture akrecionog diska i korone. Ranija istraživanja su utvrdila jaku korelaciju između optičkog, UV i X zračenja (Uttley et al, 2003; Arevalo et al, 2008, 2009; Breedt et al, 2009, 2010; McHardy et al, 2016; Troyer et al, 2016; Buisson et al, 2017), gde emisija i promenljivost zračenja na dužim talasnim dužinama prati onu na kraćim (odnosno ona na kraćim inicira onu na dužim). Posmatranjima u optičkom delu spektra je moguće otkriti više AGJ nego posmatranjima na drugim talasnim dužinama. Ipak, ovim posmatranjima je lakše uočiti luminoznije izvore ($L/L_E > 0.01$, najčešće klasifikovani kao kvazari ili AGJ Tipa Sejfer I), pa nisu predstavljene sve klase AGJ ravnomerno. Emisiju u optičkom i UV spektru (Slika 10) manje luminoznih AGJ može biti teže videti zbog gasovitog materijala kojim je okruženo posmatrano galaktičko jezgro, a koji potče od zvezda i međuzvezdane sredine ili međugalaktičkih oblaka. Promenljivost u različitim opsezima zračenja ukazuje na kašnjenje u odzivu različitih komponenti AGJ, što omogućava mapiranje njihove unutrašnje strukture.

Ultraljubičasto i optičko zračenje nastaje uglavnom iz akrecionog diska, ali i iz oblasti nešto udaljenijih od crne rupe nego što je to slučaj sa X-kontinuumom. Ovo zračenje je opisano Plankovim zračenjem. Problem sa posmatranjima u optičkom delu spektra je što jaki izvori optičkog zračenja nisu nužno AGJ (kao što je na primer slučaj kod radio, infracrvenog i X-zračenja (Lehmer et al, 2012)). Kvazari visoke luminoznosti su tačkasti izvori kao i zvezde, koje ih po broju daleko premašuju (posebno na određenim crvenim pomacima, čiji je veliki broj uočen tokom posmatranja Sloan Digital Sky Survey - SDSS). Kvazare sa nešto manjom luminoznošću je takođe teško odrediti optičkim posmatranjima (na primer teleskopima Dark Energy Survey - DES i Vera C Rubin Observaotry Legacy Survey of Space and Time - LSST), jer ih je bez pomoći spektroskopije teško razlikovati od običnih galaksija. Još jedna prepreka kod

posmatranja u optičkom delu spektra je ekstinkcija u samoj galaksiji domaćinu AGJ, odnosno sopstveno pocrvenjenje.




Slika 10: Standardni model strukture AGJ sa označenim regionima iz kojih potiče emisija, uz prikaz vremenskih promena u X, UV i NIR opsezima za NGC 5548. Ovaj model ilustruje vezu između različitih regija i vremenskog odziva zračenja na promene u akreciji (Cackett et al, 2021).

U spektrima AGJ, kod kojih ugao posmatranja omogućava vidljivost širokolinijskog regiona, mogu se videti emisione linije gasa, koji se kreće brzinama od nekoliko hiljada kilometara u sekundi. Izvor širokih emisioh linija je širokolinijski region, koji se nalazi između supermasivne crne rupe i unutrašnjeg zida torusa prašine. U tom regionu se nalazi fotojonizovani gas koji je zagrejan radijacijom koja poriče iz akrecionog diska, koji okružuje supermasivnu crnu rupu. Uske linije u spektru AGJ koji potiču od gasa koji se

kreće brzinama 300 do 1000 kilometara u sekundi u uskolinijskom regionu (Narrow Line Region - NLR). Ovaj region je veličine oko nekoliko stotina parseka i nalazi se iznad i ispod ravni torusa prašine.

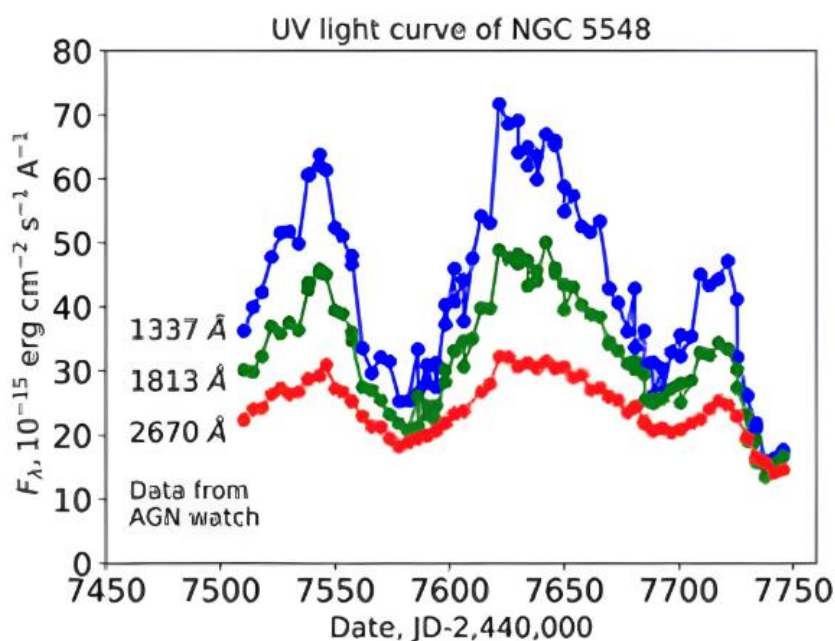
Utvrđivanje promenljivosti nije od velike pomoći u ovom slučaju jer dok se amplituda promenljivosti povećava na nižim luminoznostima (Vanden Berk et al, 2004), deo optičke emisije iz centralnog dela AGJ se smanjuje. Najveća prepreka u prepoznavanju AGJ izvora optičkom fotometrijom je neprozračni deo AGJ odnosno torus prašine kod AGJ Tipa 2 (uprkos tome najveći deo AGJ Tipa 2 je otkriven upravo posmatranjima u optičkom domenu). Takođe je važno napomenuti da u ovom delu spektra uvek postoji „kontaminacija“ od strane emisije iz zvezda (Slika 11). Takođe je primetno da je promenljivost manja na skalama od nekoliko dana, nego na većim od nekoliko nedelja i meseci, gde su primetne velike varijacije.



Slika 11: Kriva sjaja NGC 5548 u vidljivom delu spektra (5100 \AA), koja obuhvata skoro dve decenije posmatranja. Horizontalna linija prikazuje konstantni doprinos zvezdane svetlosti galaksije domaćina (Peterson et al, 1999).

O promenljivosti u optičkom i UV delu spektra znamo da se povećava sa smanjenjem talasne dužine (Slika 12), smanjenjem luminoznosti i potencijalno

smenjenjem mase crne rupe (Vanden Berk et al, 2004; de Vries et al, 2005). Optička promenljivost je jedna od metoda identifikacije kvazara (Eyer, 2002; Gehaet al, 2003; Rengstorf et al, 2004; Kozłowski et al, 2010). U cilju proučavanja promenljivosti krivih sjaja razvijene su metode za modelovanje krivih sjaja stohastičkim procesima (Damped Random Walk (Kelly et al, 2009; Kozłowski et al, 2010; MacLeod et al, 2010), mašinsko učenje - autoencoder (Tachibana et al, 2020) i dr).




Slika 12: Promenljivost u UV delu spektra NGC 5548 tokom perioda od 250 dana. Vidljivo je da su amplitude promenljivosti veće pri kraćim talasnim dužinama, što ukazuje na unutrašnje procese bliske akrecionom disku (Lawrence, 2018).

Fizički procesi koji uzrokuju promenljivost u optičkom i UV spektru još uvek nisu sasvim jasni. Neke od do sada predloženih mogućnosti koji bi mogli izazvati promenljivost u optičkom/UV delu spektra su: termalne fluktuacije izazvane turbulencijama u magnetnom polju (King et al, 2004; Kelly et al, 2009, 2011), nestabilnosti u akrecionom disku (Takeuchi et al, 1995; Kawaguchi et al, 1998), promena u stepenu zaklonjenosti izvora, promena u stopi akrecije,

mikrosočiva (Hawkins, 1993, 2010), uticaj plimskih sila u slučaju kada se zvezda nađe pod uticajem gravitacionih sila crne rupe (Tidal disruption events - TDEs).

Važno dostignuće u razumevanju optičke/UV promenljivosti je bilo otkrivanje među-domenskih crvenih lagova (veće talasne dužine laguju, odnosno zaostaju iza kraćih), koji su reda veličine nekoliko sati, do jednog dana (Sergeyev et al, 2005). Ovi lagovi (kašnjenja) su previše kratki da bi se mogli opisati nekim spoljašnjim faktorima. Zbog toga je zaključeno da je najverovatniji uzrok zagrevanje od strane izvora X-zračenja iz centra AGJ. Izračunate amplitude lagova odgovaraju pretpostavljenom reprocesiranju X-zračenja u disku (Cackett, Horne & Win kler, 2007; Edelson et al, 2015). Analize posmatranja UV/optičkog, infracrvenog i X-zračenja su potvrdile ove hipoteze, a time objasnile i promenljivost u torusu prašine (McHardy et al, 2014; Vazquez et al, 2015). Ova pretpostavka takođe objašnjava i zašto je promenljivost veća u X domenu nego u UV i optičkom. Analize posmatranja u X i optičkom domenu na većim vremenskim skalama (nekoliko meseci do godinu dana) su otkrile da su u optičkom delu spektra varijacije na ovim skalama uočljivije od onih u X-domenu (Arevalo et al, 2009; Breedt et al, 2010; Uttley et al, 2003). Ove pojave ne mogu biti objašnjene reprocesiranjem emisije X-zraka, već zahtevaju dodatnu analizu procesa koji se odvijaju u samom disku.

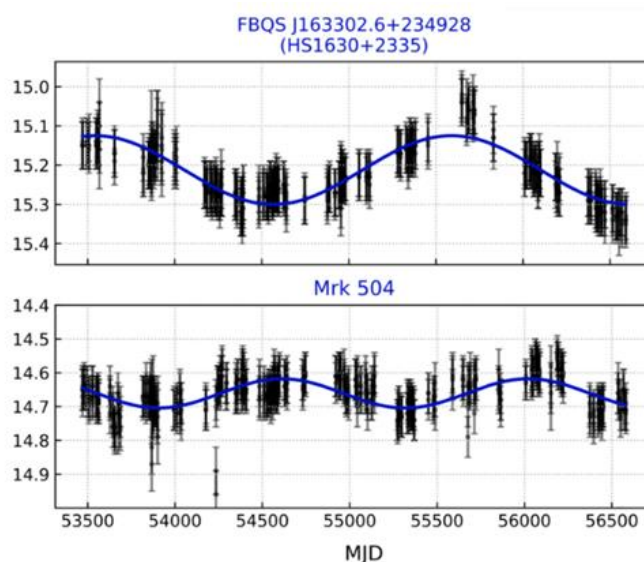
Još jedan od mogućih uzroka promenljivosti zračenja u optičkom delu spektra su dvojni sistemi supermasivnih crnih rupa (supermassive black hole binaries - SMBHB) koje su na malim udaljenostima (manjim od 1 parseka). Dvojni sistemi (Slika 13) u zavisnosti od blizine komponenti (samim tim morfologije celog dvojnog sistema), mogu imati različite uticaje kako na profile emisionih linija uočljive u optičkom delu spektra (Popović & Ilić, 2017), tako i na krive sjaja u dužem vremenskom periodu (nekoliko godina).



Slika 13: Binarni sistem supermasivnih crnih rupa Mrk 463. Levo je slika u optičkom domenu HST, a desno je su prikazane konture istog sistema u X-domeni (Chandra). Na obe slike su jasno vidljiva dva jezgra (Panessa et al, 2002).

Periodičnost u krivama sjaja (promena u intenzitetu magnituda) može imati različite uzroke, među kojima čak i orbitiranje komponenti SMBHB sistema. Tako na primer posmatranja izvedena dosadašnjim programima otkriveno je oko 150 mogućih kandidata SMBHB (Slika 14, D'Orazio & Charisi, 2023). Ovakvi sistemi supermasivnih crnih rupa mogu nastati kao posledica spajanja galaksija (D'Orazio et al, 2017). Iako ih je teško uočiti, jer su rastojanja među komponentama na malim razmacima, zahvaljujući efektu promenljivosti koji je uočljiv na krivama sjaja, moguće je izdvojiti potencijalne kandidate. Periodičnost može biti pojačana uticajem gravitacionih sočiva (Popović, 2012). Takođe je moguće da sistem ima više od dve komponente, čime bi kako profili linija, tako i krive sjaja bile kompleksnije.

Periodičnost može biti posledica i perturbacija u akrecionom disku, ali se očekuje da bi periodična pojačana akrecija izazvala ekstremnije pomene u krivama sjaja od onih koje je moguće uočiti kod nekih od posmatranih kandidata SMBHB (PG1302-102 – ravnomerno sinusoidalna).




Slika 14: Magnitude u optičkom delu spektra dva kandidata binarnih sistema supermasivnih crnih rupa. Jasno je vidljiva promenljivost prikazana plavom linijom (Xin et al, 2020).

Model relativističkog Doplerovog efekta odgovara podacima dobijenim iz posmatranja kvazara PG1302-102 (D’Orazio, 2017). Prema ovom modelu UV zračenje prati optičko, ali sa 2 do 3 puta većom amplitudom od optičke. Ovaj efekat je pokazatelj orbitalnog kretanja crnih rupa u dvojnog sistema supermasivnih crnih rupa.

Dvojni sistemi supermasivnih crnih rupa su i jaki emiteri gravitacionih talasa, pa bi mogući kandidati uočeni posmatranjima u optičkom i UV delu spektra, mogli biti potvrđeni detektorima gravitacionih talasa (Laser Interferometer Space Antenna - LISA) (Amaro-Seoane et al, 2017). Dalja istraživanja odnosa različitih parametara AGJ i promenljivosti u optičkom i UV delu spektra bi mogla u velikoj meri pomoći boljem razumevanju strukture i pozadinskih fizičkih procesa.

2.4. AGJ – X-zračenje

X-zračenje u aktivnim galaktičkim jezgrima nastaje kao posledica procesa koji se odvijaju tokom akrecije materije u unutrašnjim regionima akrecionog diska i u koroni oko supermasivne crne rupe. Ovi procesi oslobađaju visokoenergetsko zračenje kroz različite mehanizme, uključujući termalno Komptonovo raspršenje fotona iz akrecionog diska u vreloj koroni, refleksiju X-zraka sa površine diska, fluorescenciju i rekombinaciju koje dovode do formiranja Fe K α linije, kao i termalnu emisiju niske energije (ispod 1 keV) iz unutrašnjih regiona diska. Na Slici 15 prikazana je tipična spektralna raspodela X-zračenja AGJ (Mushotzky, Done, & Pounds, 1993; Jovanović & Popović, 2009; Done, 2010; Gilfanov & Merloni, 2014).




Slika 15: Tipična spektralna raspodela X-zračenja AGJ. Prikazani su doprinosi različitih komponenti: termalne emisije (power law), viška meke emisije (soft excess), fluorescencije Fe K α linije i Komptonovog izbočenja (Compton hump) (Fabianno, 2006).

Spektralna raspodela X-zračenja AGJ je najizraženija u oblasti od 0.5 do 100 keV. U intervalu između 2 keV i 100 keV, spektar F_ν približno prati stepeni zakon:

$$F_\nu \propto \nu^\alpha, \quad (2.5)$$

gde je ν frekvencija, a spektralni indeks α iznosi približno između 0.7 i 0.9, zavisno od toga da li je AGJ radio-jako (radio loud - RL) ili radio-slabo (radio quiet - RQ).



Slika 16: Šematski prikaz strukture AGJ, sa naglašenim mestima nastanka X-zračenja u unutrašnjim regionima akrecionog diska i korone. Prikazano je i poreklo radio i infracrvenog zračenja, kao i relativističkih mlazeva (Jovanović & Popović, 2009).

Posmatranja u X-domenima omogućavaju gotovo potpunu distinkciju AGJ od ostalih izvora. Jedan od ključnih razloga za to jeste sposobnost X-zraka da prodiru kroz gas i prašinu čak i vrlo visoke gustine, posebno u slučajevima kada je izvor zračenja dovoljno jak. Pored toga, X-zračenje koje potiče iz same galaksije domaćina je mnogo slabijeg intenziteta u poređenju sa X-zračenjem koje

potiče iz AGJ, što dodatno olakšava njihovu identifikaciju (Brandt & Alexander, 2015).

Termalno emisiona X-zračenje koje nastaje u unutrašnjim regionima akrecionog diska (Slika 16) može biti i manjih energija (Sobolewska, Siemiginowska, & Zycki, 2004). Emisija X-zračenja je modifikovana zbog interakcije sa materijom iz jezgra (refleksija, rasejanje i fotoelektrična apsorpcija). Jačina ovih komponenti varira od izvora do izvora, a u najvećoj meri zavisi od razlika u geometriji i inklinacije torusa u odnosu na ugao posmatranja. Emisija iz korone je usko povezana sa emisijom iz akrecionog diska (Steffen et al, 2006; Lusso & Risaliti, 2016).

Prva posmatranja X-zračenja bila su 1960-tih godina (Giacconi, 2009). Nakon toga su lansirane brojne opservatorije (Chandra, XMM-Newton, NuSTAR i td.) koje su vršile posmatranja u ovom delu spektra (koja nisu moguća sa površine Zemlje, jer X-zrake apsorbuje atmosfera).

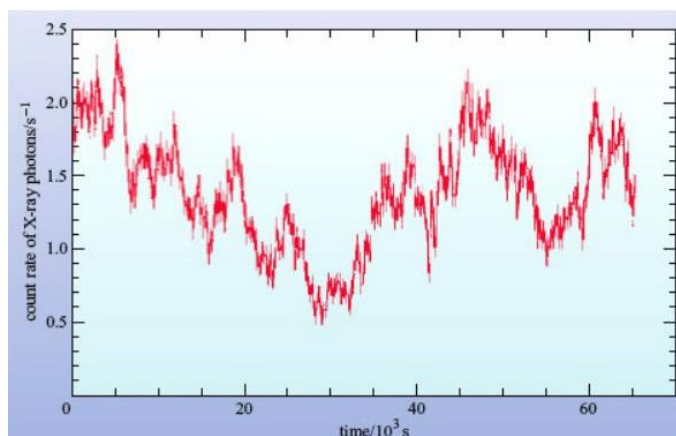
Kod AGJ sa uočenom slabom luminoznošću u X-zračenju, zračenje iz galaksije domaćina može uticati na posmatranu emisiju iz AGJ i time doprineti otežanom definisanju AGJ. Ovakvi slučajevi su najčešće okarakterisani kao dvojni izvori X-zračenja odnosno, rendgenski ili X-dvojni sistemi (Fabbiano, 2006; Remillard & McClintock, 2006). Kako je X-zračenje skoro univerzalno za AGJ, ono ne favorizuje uočavanje AGJ određenih karakteristika (masa crne rupe MBH ili Edingtonov odnos L/L_E). X-zračenje je uočeno kod AGJ sa različitim masama centralne crne rupe i na veliki crvenim pomacima (Hickox et al, 2009; Page et al, 2014; Baldassare et al, 2015; Chen et al, 2017).

Dugoročna posmatranja u domenu X-zračenja AGJ na malim crvenim pomacima, omogućilo je značajan napredak u karakterizaciji promenljivosti u ovom domenu. Ove analize su ključne za razumevanje promenljivosti AGJ. Glavna karakteristika promenljivosti AGJ je „crveni šum“ (Slika 17), odnosno pojava većih varijacija u amplitudama tokom dužeg vremenskog perioda (Lawrence et al. 1987).


Prva istraživanja promenljivosti X-zračenja su bila fokusirana na određivanje karakterističnih vremenskih skala (McHardy, 2001). Jedna od metoda kojom se utvrđuju varijacije je analiza stepene spektralne gustine (Power Spectral Density - PSD). Na većim frekvencijama (kraćim vremenskim skalama), PSD je okarakterisana strmim nagibom, gde je koeficijent $\alpha \sim -2$. Na nižim frekvencijama (dužim vremenskim skalama) gradijent PSD je $\alpha \sim -1$, što predstavlja šum treperenja (flicker noise). Kasnijim istraživanjima je utvrđeno da je vremenska skala (TB) povezana sa masom crne rupe (MBH): što je veća masa crne rupe, to je duža (veća) vremenska skala (utvrđena je linearna zavisnost: $TB \propto MBH$ (Markowitz et al, 2003; Papadakis, 2004)). Ipak, ubrzo je uočeno odstupanje kod objekata, kod kojih su u spektru prisutne uske linije. Sajfertove galaksije Tipa 1 sa uskim linijama (Narrow-line Seyfert 1 galaxies - NLS 1) predstavljaju posebnu klasu AGJ, za koju je karakteristična brza i velika periodičnost, kao i druge specifične karakteristike (masa crne rupe je manja od drugih AGJ, nalaze se u spiralnim galaksijama, najbrži emiteri gama zraka). Za NLS 1 se smatra da u centru imaju malu crnu rupu koja ima veliku stopu akrecije, koja je blizu Edingtonove granice. Činjenica da su vremenske skale prekida (the break time scales) kod NLS 1 kraće od onih kod AGJ sa širokim linijama, sugerise da one zavise i od drugog parametra, kao što je stopa akrecije ili spin crne rupe (McHardy et al, 2004; Uttley & McHardy, 2005).

Mogući izvori zagrevanja gasa u akrecionom disku su udari/talasi (Courvoisier & Turler, 2005; Ishibashi & Courvoisier, 2009) koji se javljaju između elemenata (grudvi) u akrecionom disku prilikom njihove interakcije, koja uzrokuje emisiju. Grudve u akrecionom disku se kreću različitim brzinama, određenim gravitacionim poljem centralne crne rupe, prateći različite orbite, koje zavise od početnih uslova. U centralnim regionima, grudve koje se sudaraju okarakterisane su visokim relativnim brzinama. Kada se dva takva toka koja se kreću visokim brzinama sudare ili konvergiraju, nastaju udari/talasi. Ovaj proces oslobađa veliku količinu kinetičke energije, koja se konvertuje u radijaciju.

Optički gusti i tanki udari/talasi mogu biti posmatrani u optičkom/UV i X delu spektra.



Slika 17: Primer promenljivosti Sejfert galaksije MCG-6-30-15 u X domenu, uočene tokom posmatranja u Chandra X-ray opservatoriji. Najbrže fluktuacije signala mogu biti posledica šuma, dok aperiodična promenljivost na skalama od nekoliko hiljada sekundi predstavljaju karakteristiku AGJ (Lee et al, 2002).



Slika 18: Krive sjaja Sejfert galaksije NGC 3516 (Iwasawa et al, 2004), na opsezima: 0.3 – 10 keV (gornji panel), crvena karakteristika linije Fe Ka (srednji panel) i 6.4 keV linija (donji panel).

Posmatrana promenljivost AGJ u X domenu nekada ne odgovara standardnom modelu akrecionog diska. Satelitom XMM-Newton u krivi sjaja Sejfertove galaksije NGC 3516 (Slika 18), uočena je promenljiva “crvena” karakteristika na liniji 6,1 keV (Iwasawa et al., 2004). Ova neobična karakteristika pokazuje promenljivost reda veličine 25 ks. U radu Iwasawa et al. (2004) je zaključeno da je ova spektralna osobina pokazatelj pege koja rotira oko crne rupe u akrecionom disku.

Pored perturbacija, promenljivost može nastati i kao posledica efekata gravitacionih sočiva, kao i apsorpcije X zračenja. Za detaljnije razumevanje ovih efekata, potrebna su učestala posmatranja različitih tipova AGJ.

2.5. Gama zračenje

Emisija gama zračenja se uočava u delu visokog energetskog opsega (High Energy - HE) između 100 MeV i 100 GeV i veoma visokog energetskog opsega (Very High Energy - VHE) u opsegu između 50 GeV i 10 TeV. Gama zračenje predstavlja deo elektromagnetnog spektra na kome se emituje najveća energija i većina objekata ga ne emituje, uključujući i ekstragalaktičke objekte među kojima su i AGJ koja nemaju mlazeve.

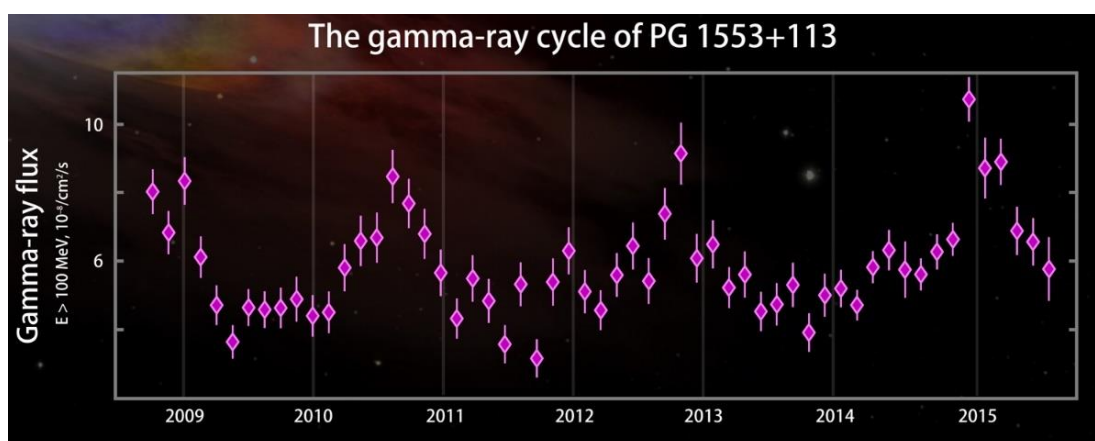
Blazari, iako dosta retki, dominiraju kao izvori gama zraka. Emisija blazara prekriva ceo elektromagnetni spektar i njom dominira netermalno zračenje u relativističkim mlazovima, koji su usmereni prema posmatraču (Urry & Padovani, 1995). Poreklo ovog zračenja je objašnjeno (Maraschi, Ghisellini & Celotti, 1992) inverznim Komptonovim rasejanjem u mlazovima i njihovom sinhrotronskom emisijom.

AGJ mogu biti snažni emiteri MeV-GeV-TeV gama zraka koji nastaju u relativističkim mlazovima centralne crne rupe. Većina AGJ koje emituju gama

zrake se nazivaju blazari. Blazari koji čine posebnu klasu AGJ u koju spadaju radio jaki objekti sa veoma izraženom promenljivošću, zrače jako polarizovano zračenje u optičkom i radio spektru. Njihova jaka emisija i promenljivost se mogu objasniti i kroz Doplerov efekat koji je pojačan u slučaju kada je mlaz usmeren u pravcu posmatrača (Urry & Padovani, 1995). Standardni blazar karakteriše mlaz relativističke magnetizovane plazme koju izbacuje rotirajuća akretivna crna rupa u smeru posmatrača. Uočene su dve klase blazara, jednu čine radio kvazari sa ravnim spektrom (flat-spectrum radio-quasar - FSRQ), koji imaju jaka eksterna radio polja, emisiju širokih optičkih linija i torus prašine. Druga klasa su BL Lac objekti (BL Lacertae), koje karakteriše slabija advekcija i gama spektar koji nastaju inverznim Komptonovim rasejanjem. Objekti BL Lac pokazuju veoma izraženu promenljivost i pikove u UV i X zračenju.


Blazari su izvori zračenja sa izrazito velikom promenljivošću. Promenljivost koje se dešavaju na vremenskim skalama od oko jednog dana su uočene 1991. analiziranjem flerova 3C 279 (Hartman et al, 1991). Kasnije su razvijeni instrumenti koji su mogli da uoče promenljivost i na mnogo manjim vremenskim skalama. Fermi Large Area Telescope (LAT) može da uoči promene tokom najvećih eksplozija koje se odvijaju u vremenskim skalama reda veličine par sati. Uočene su i promene koje se odvijaju u još kraćim vremenskim intervalima. Tokom dugoročnog posmatranja objekta PG 1553+113 (Slika 19) od avgusta 2008. do jula 2015. uočena je promenljivost reda veličine 2 - 3 eV. Varijacije se kod ovog objekta javljaju u periodu od oko dve godine. Iako postoji više mogućih uzroka ovakve promenljivosti, na osnovu podataka, koji su prikupljeni dugogodišnjim posmatranjima optičkog dela spektra ovog objekta (Tuorla Observatory u Finskoj, Lick Observatory u Kaliforniji i Catalina Sky Survey u Arizoni), podacima optičkog i X domena (NASA's Swift spacecraft) i radio posmatranja (Owens Valley Radio Observatory u Kaliforniji), utvrđeno je da su ciklične varijacije vidljivih i radio talasa slične onima koje se mogu uočiti u gama opsegu. Periodičnost varijacija u istim intervalima na celom spektru,

ukazuje da je ona nije posledica fluktuacija u gama-zracima, već da se radi o dvojnem sistemu i predviđeno je da će ona nastaviti da se ponavlja na svake dve godine. Zaista, naknadnim programom posmatranja ovog objekta je utvrđeno da je 2017. ponovo došlo do pojačanja emisije gama zračenja što je dodatno potvrdilo prvobitnu hipotezu. Najverovatnije objašnjenje mogućih uzroka ove periodičnosti je prisustvo druge supermasivne crne rupe koja na maloj udaljenosti orbitira oko one koja je izvor uočenih mlazeva (Tavani et al, 2017).



Slika 19: Dugoročno, kontinuirano posmatranje blazara PG 1553+113 Fermi Gamma-ray svemirskim teleskopom uočena je periodična promenljivost u gama emisiji ovog blazara. Postoji nekoliko mogućih objašnjenja ove promenljivosti, a jedno od njih je da je u pitanju dvojni sistem (NASA's Goddard Space Flight Center/CI Lab).


Još jedno zanimljivo istraživanje za koje je neophodna analiza emisije u gama opsegu su AGJ, tačnije blazari promenljivog tipa (Changing Look AGJ). Razlike između dve glavne klase blazara, BL Lac i FSRQ, jasno su uočljive kroz njihove spektralne raspodele i ponašanje u optičkom i gama opsegu (Slika 20). Poznato je da je promenljivost u različitim vremenskim intervalima, na svim opsezima elektromagnetnog spektra, karakteristična odlika AGJ, ali nije uvek jasno šta je njihov uzrok. Proučavanje AGJ promenljivog tipa kod blazara može dati korisne informacije potrebne za razumevanje procesa koji se odvijaju u radio mlazevima (Mishra et al, 2021).



Slika 20: Prikaz spektralne energetske raspodele dve klase blazara: BL Lac (levo) i FSRQ (desno). Kod FSRQ su jasno uočljive široke emisione linije, dok je spektar BL Lac „ravan“ (Padovani, "Fermi and Jansky" Workshop 2011).

Zbog promenljivosti u različitim vremenskim intervalima od velike važnosti je vršenje posmatranja na različitim frekvencijama, kako bi se upoređivanjem promenljivosti došlo do jasnije slike mogućih uzroka. Unificirani model AGJ predviđa da njihova podela pre svega zavisi od orijentacije u odnosu na pravac posmatranja. AGJ promenljivog tipa ukazuju da osim pravca posmatranja, može biti i drugih uzročnika različitih karakteristika AGJ.

Višegodišnja spektroskopska posmatranja omogućavaju praćenje promena kako u kontinuumu tako i u profilima spektralnih linija, pružajući uvid u evoluciju emisijskih procesa. Tako naprimer korišćenjem podataka iz opservatorije Las Cumbres Observatory Global Telescope Network (LCOGT) za objekat B2 1420+32, uočena je promenljivost kako spektralna u kontinuumu i emisionim linijama, tako i promenljivost u optičkom i gama zračenju tokom perioda od nedelju do mesec dana. Analizom ovih posmatranja utvrđeno je da je su promene u jačini fluksa u optičkom i gama opsegu, reda veličine 4 magnitude (za optički) i 8 (za gama), tokom perioda od 2016. do 2019. godine (Mishra et al, 2021).



Slika 21: Spektroskopski podaci blazara B2 1420+32 izmereni u različitim trenucima, poređani hronološki (odozdo na gore). MJD posmatranja je prikazana pored svake krive sjaja. Jasno je uočljiva promena intenziteta i profila spektralnih linija (Mishra et al, 2021).


Pored promenljivosti u spektralnim linijama (u optičkom i gama opsegu), primetne su i velike varijacije u spektru (Slika 21). Uočene promene kod ovog objekta između karakteristika FSRQ i BL Lac ukazuju na nekoliko mogućih uzroka ove pojave, među kojima su promene u stopi akrecije, promene veličine ugla mlaza (Mishra et al, 2021; Pushkarev et al, 2009), efekat “failed wind” (neuspeli vetar) gde material koji je usmeren od akrecionog diska, nema dovoljnu brzinu udaljavanja i ne može da se odvoji od gravitacionog potencijala crne rupe. Na taj način blokira radijaciju iz centralnog regiona, što za posledicu ima promenu izgleda spektra (tipa AGJ). Slične promene primećene su i kod drugih blazara (VRO 42.22.01 (Vermeulen et al, 1995) i 5BZB J0724+2621 (Alvarez et al, 2016)), ali pošto su takva posmatranja blazara promeljivog tipa, koja uključuju i

spektroskopsku analizu retka, ove promene još uvek nisu dovoljno razjašnjene. Dalja spektralna i višetalasna istraživanja neophodna su za razumevanje promenljivih karakteristika blazara i povezivanje ovih promena sa unutrašnjom dinamikom akrecionih sistema.

3. Podaci

Za inicijalno ispitivanje primenljivosti, tačnosti i brzine uslovnog neuronskog procesa (Conditional Neural Process - CNP) (Garnelo et al, 2018), koji smo razvili sa namerom da pre svega modeluje krive sjaja kvazara sa bilo kakvim nepravilnostima, korišćen je najpre skup koji se sastojao od 153 krive sjaja AGJ (Slika 22).


Ovi objekti su prvi put primećeni u posmatranju Swift Burst Alert Telescope - SWIFT/BAT (9-Month BAT Survey, Tueller et al, 2008). Optičke krive sjaja ovih objekata su kasnije posmatrane i podaci sačuvani u bazi podataka: All Sky Automated Survey - the ASAS-SN database³ (Holoien et al, 2017). Svaka od krivih sjaja ovih AGJ predstavlja emisionu krivu sjaja optičkog (g filter) dela spektra.



Slika 22: Raspodela broja posmatranja skupa od 153 krive sjaja AGN uzorka koji je korišćen za testiranje CNP metode (Čvorovic-Hajdinjak et al, 2022).


³ Više detalja o ovim podacima se može naći na: <https://swift.gsfc.nasa.gov/results/bs9mon/>

Ovi podaci imaju zahtevnu strukturu, što ih čini idealnim za testiranje sposobnosti neuronskih procesa da generalizuju u uslovima velike nepravilnosti i vremenskih prekida. Pored toga, ovi podaci su odabrani za ispitivanje primeljnivosti CNP i zato što su uzorkovani sa površine koja pokriva 80% neba. Na *Slici 23*, crvene tačke predstavljaju izvore sa detektovanim X-zračenjem, plave označavaju jake izvore X-zračenja, dok zelene tačke predstavljaju zvezde. Veličina tačaka proporcionalna je jačini fluksa izvora. Ovakva raspodela omogućava vizuelni uvid u prostorne karakteristike uzorka, kao i eventualne pristrasnosti u selekciji izvora. Takođe primećujemo razne vrste raznolikosti među objektima, kako u strukturi, tako i broju podataka. Posmatranja pojedinačnih objekata izvođena su između 100 i 600 puta, tako da svaka kriva sjaja ima između 100 i 600 tačaka.



Slika 23: Raspodela objekata BAT pregleda neba (Tueller et al, 2008) među kojima 153 AGJ koji su korišćeni za testiranje CNP metode. Crvene tačke predstavljaju izvore X zračenja, plave su izvori jakog X zračenja, a zelene su zvezde. Prečnik tačaka je proporcionalan jačini fluksa izvora (preuzeto sa <https://swift.gsfc.nasa.gov/results/bs9mon/>).

Na krivama sjaja uočavaju se sezonske „rupe“ u posmatranju, nepravilnosti i prekidi u posmatranjima. Ove karakteristike predstavljaju realne izazove koji će biti prisutni i u budućim vremenskim pregledima kao što je LSST, što ovaj skup čini posebno vrednim za testiranje metoda neuronskih procesa. Uočena su dva bitna ograničenja u posmatranjima zemaljskim teleskopima (Moreno et al, 2019): prvo su sezonske „praznine“ (rupe - propusti - procepi - nedostaci), koji nastaju kao posledica nemogućnosti posmatranja određenog objekta tokom nekog dela godine, jer nije u vidnom polju teleskopa, na šta ne možemo da utičemo. Druge nepravilnosti u posmatranjima koje dovode do neravnomerno raspoređenih posmatranja su ograničenja u planiranju posmatranja, nepravilno rasporedjene epohe i drugi tehnički uslovi/razlozi. Zbog toga imamo nepravilno raspoređene podatke za neke objekte (Slika 24).



Slika 24: Primer podataka koji se mogu očekivati pri merenju. Na levom grafiku je izmeren fluks objekta Fairall 9, a na desnom objekta 2MASXJ11454045m1827149. Ovi podaci su korišćeni tokom ispitivanja CNP metode za modelovanje krivih sjaja kvazara (Čvorović – Hajdinjak et al, 2022).

Kod objekata Fairall 9 imamo podatke o jačini fluksa koji su mereni 246 puta tokom 1318 dana. Na Slici 24 (levo) su takođe uočljive i dve „praznine“ od po 100 dana, tokom kojih nemamo nikakve podatke za ovaj objekat.

Za prvu fazu testiranja odabrano je 153 objekta. Podaci koji su za njih bili dostupni obuhvataju period posmatranja od 2000 dana. To je značajan period za utvrđivanje upotrebljivosti modelovanja CNP metodom za optičke krive sjaja AGJ.

Osim utvrđivanja efikasnosti CNP na pojedinačnim krivama sjaja svakog AGJ iz ASAS-SN (Shappee et al, 2017; Kochanek et al, 2017) baze, naš cilj je bio i ispitivanje upotreba modifikovanog CNP (QNP⁴) za masovno modelovanje krivih sjaja iz istog skupa. Zadati skup ima veliku pokrivenost i dovoljno veliki broj krivih sjaja sa dosta podataka za svaku krivu (100 do 600 tačaka). Odabrane su 139 krive sjaja iz ASAS-SN skupa, sa neobičnim osobinama, koje su veoma teške za modelovanje a uključuju: flerove, moguće kvazi-periodične oscilacije, praznine i nehomogeno raspoređena merenja. Testiranje QNP metode na ovom skupu za modelovanje krivih sjaja sa velikim nepravilnostima omogućila je identifikaciju unapređenja modela za masovno vremensko modelovanje AGJ izvora, o čemu će biti diskutovano u Glavi 6.

Greške dobijenih posmatranja objekata integrisane su u QNP metodu kako bi se povećala raznolikost skupa za treniranje, smanjio rizik od preprilagođavanje⁵, i unapredila sposobnost modela za generalizaciju na nove podatke. Cilj ovog pristupa je omogućavanje primene modela na raznovrsne skupove podataka, kao i različite tipove objekata.

Ovaj skup krivih sjaja je odabran, jer je na njemu ispitan CNP (Čvorović Hajdinjak et al, 2022), koji predstavlja osnovu QNP metode za masovano modelovanje krivih sjaja kvazara. Potreba za takvim alatom potiče od očekivane ogromne količine podataka koja će biti prikupljena tokom narednih generacija

⁴ Detaljan kod i opis metode se može pogledati na <https://github.com/kittytheastronaut/QNP/>.

⁵ Preprilagođavanje (overfitting) je problem koji se može javiti prilikom mašinskog učenja, kada se model tokom treniranja prezasiti podacima koji imaju sličnu strukturu. Model tada „nauči“ određeni obrazac karakterističan za podatke iz skupa za treniranje i greška pri testiranju modela na novim podacima postaje veća. Ovakav model je izgubio sposobnost generalizacije, zbog lošeg izbora podataka u skupu za treniranje.

vremenskih posmatranja neba, posebno u okviru projekta Legacy Survey of Space and Time (LSST) na opservatoriji Vera C. Rubin (Abell et al, 2009; Ivezić et al, 2019). LSST će vrši posmatranja sa različitim kadencama tokom više od deset godina, pokrivajući milione AGJ izvora (Brandt et al, 2018; Bianco et al, 2021) u šest filtera - ugrizy. Ovolika količina podataka će zahtevati efikasan alat za njihovo procesiranje (i kasniju analizu). Radi unapređenja efikasnosti QNPy alata za masovno modelovanje, isprobani su i mogući benefiti preprocesiranja ASAS-SN podataka krivih sjaja metodom samoorganizujućih mapa za klasterovanje. Klasterovanje je primenjeno (Čvorović-Hajdinjak, 2024) na istom skupu podataka na kome je radjeno masovno modelovanje, kako bi bilo jasno utvrđeno da li se klasterovanjem može postići unapređenje QNPy modelovanja, u smislu brzine i tačnosti dobijenih modela krivih sjaja.

SOM model (koji je detaljno objašnjen u Poglavlju 4.2) je odabran jer može da obradi različite vrste podataka, nezavisno od njihove strukture i homogenosti. Sa druge strane SOM zahteva da oblik ulaznih podataka (u vektorskom/tenzorskom obliku) bude konzistentan (Kohonen, 1990). Da bi omogućili odgovarajuću strukturu ulaznih podataka, odnosno uniformnost dimenzije naših krivih sjaja, bilo je potrebno uraditi dodavanje ili izbacivanje nekih podataka (Rejeb et al, 2022). Korišćenje SOM modela omogućilo je strukturisanje ulaznih podataka, lakšu normalizaciju kao i brzi trening.

S obzirom na to da svi podaci moraju biti uneti u model u tenzorskom obliku sa fiksnim dimenzijama, bilo je neophodno prilagoditi dužine krivih sjaja. Ne želeći da ih „skraćujemo“ (izbacujemo tačke - posmatranja da bi ih doveli na istu dužinu), jer su nam je svako posmatranje bitno, krive sjaja su nadograđivane/dopunjavane dodavanjem potrebnog broja tačaka, srednjom vrednoću magnitude u ravnomernim razmacima na kraju originalnih podataka, kod svake od krivih sjaja, do dostizanja maksimalnog broja tačaka (odnosno broja tačaka krive sjaja u ASAS-SN skupu koja ima maksimalni broj tačaka). Postoje i

druge metode, koje bi mogle biti isprobane kao alternativa ovoj, radi utvrđivanja da li bi rezultati klasterovanja bili bolji (više o tome u Poglavljima 4 i 5).

Takođe, podaci su standardizovani u pogledu veličina fluksa/magnituda, čime su omogućeni stabilniji ulazni uslovi za treniranje neuronskog procesa. Standardizacija je sprovedena normalizacijom posmatranih vrednosti tako da budu unutar definisanih granica $[-2,2]$ po preporuci iz literature *Garnelo et al, 2018*), čime je minimizovan uticaj apsolutnih razlika u jačini zračenja između različitih objekata. Na ovaj način obezbeđena je homogenost podataka neophodna za efikasnu obuku neuronskog procesa i smanjena zavisnost performansi modela od apsolutnih vrednosti merenja. Takođe, radi efikasnijeg procesiranja i veće tačnosti modelovanih krivih sjaja, one su tokom procesa preprocesiranja skalirane i rađena je normalizacija podataka, čime nije narušena topološka struktura, koja nam je bila od značaja za dalju analzu.

Histogram (na Slici 22) pokazuje koliko posmatranja ima svaki od objekata. Većina objekata ima između 100 i 300 tačaka, dok manji broj dostiže i do 600 posmatranja. Ovakva raspodela ukazuje na neravnomernost u dostupnosti podataka za različite izvore, što predstavlja važan izazov za modelovanje neuronskim procesima.

4. Metode

Za potrebe modelovanja i analize krivih sjaja AGJ ranije su korišćeni Gausovi procesi - GP (Kovačvić et al, 2019; Shapovalova et al, 2017; Shapovalova et al, 2019). Ovi procesi su dali motivaciju i osnovu za dalju nadogradnju alata, koji bi efikasnije i tačnije obavljao modelovanje podataka krivih sjaja kvazara, odnosno model koji bi kombinovao koncepte GP i neuronskih procesa. Ovde ću predstaviti ukratko GP iz perspektive mašinskog učenja pre detaljnog objašnjenja NP.

GP je stohastički proces sa sekvencom parova slučajnih promenljivih $\{(x_i, Y_i), \text{ gde } i \in [1, n]\}$. Označimo sa (x_i, y_i) uzorak koji je dobijen iz (X_i, Y_i) , gde su: $Y = [Y_1, Y_2, \dots, Y_n]$, $X = [X_1, X_2, \dots, X_n]$. Definišemo prethodnu raspodelu: $[P(Y | X) = N(m(X), \kappa(X, X'))]$. Ovde je κ je kernel funkcija koja meri udaljenost između uzoraka, a m srednja funkcija (obično postavljena na $m(x) = 0$, jer su ulazni podaci obično normalizovani). U skladu sa time, svi ulazni podaci su prethodno normalizovani pre modelovanja. U ovom radu termin „normalizacija“ koristi se za MinMax skaliranje na interval $[0,1]$. Ova standardizacija podataka omogućava stabilniju i efikasniju obuku modela, smanjujući rizik od numeričkih problema prilikom optimizacije.

GP je neparametarski metod koji omogućava brzo i inkrementalno učenje iz uzoraka putem ažuriranja aposteriorne raspodele i pruža procenu greške preko varijanse. Međutim, GP daje slabije rezultate u sledećim slučajevima:

- Veliki broj dimenzija X ili Y utiče negativno na efikasnost metode.
- Veliki broj trening uzoraka (trošak predviđanja raste linearno sa n).
- Korelacija između (X_i, Y_i) , naime GP je konačno razmenljiv, što znači da redosled (X_i, Y_i) ne utiče na raspodelu.

Da bi se prevazišli prethodni problemi kreiran je NP koji koristi drugačiju apriornu raspodelu od GP-a. Umesto da tražena vrednost Y_{n+1} direktno zavise od X i Y (kontekstni ulazi), NP uvodi latentnu Gausovu promenljivu (z), čiji srednja vrednost (μ) i varijansa (σ) zavise od X i Y .

NP postiže konstantno vreme predviđanja enkodiranjem informacija iz kontekstualnih ulaza X i Y u karakteristike konstantne veličine, odnosno srednju vrednost i varijansu z . U narednom poglavlju opisaćemo detaljno neuronski proces za modelovanje krivih sjaja kvazara i samoorganizirajuće mape za klasterovanje (grupisanje) krivih sjaja kvazara prema topolškim svojstvima.

4.1. Neuronski procesi

Neuronski procesi su se pokazali kao dobar alat za modelovanje (fitovanje) podataka koji imaju stohastičku strukturu, bez uključivanja dodatnih parametara i pretpostavki u proces modelovanja. Pre ulaska u neuronsku mrežu, ulazni podaci – vremenski trenuci (x_i) i odgovarajuće merene vrednosti fluksa ili magnitude (y_i) se normalizuju. Ova normalizacija osigurava konzistentnost među različitim objektima i poboljšava stabilnost i brzinu konvergencije neuronskog procesa (Garnelo et al, 2018; Čvorović-Hajdinjak, 2024). Imajući u vidu da su krive sjaja AGJ veoma kompleksne, a da o samim objektima nemamo dovoljno jasno utvrđenu teorijsku sliku, na osnovu koje bi mogli davati sigurne pretpostavke o parametrima, CNP (Conditional Neural Process) metoda (Garnelo et al, 2018), koja se bazira isključivo na podacima (posmatranjima krivih sjaja) se nametnula kao očigledno rešenje modelovanja ovih podataka.

U formalnom statističkom smislu, CNP su parametarski modeli, jer je broj njihovih parametara (težine enkodera i dekodera) fiksiran unapred i ne zavisi od veličine skupa podataka. Za razliku od toga, gausovi procesi (GP) su

neparametarski, jer njihova složenost i memorijski zahtevi rastu sa brojem obučavajućih podataka – svi podaci se koriste tokom predviđanja. (Goodfellow, Pouget-Abadie, Mirza et al, 2020). Sa druge strane u funkcionalnom smislu, CNP modeli imitiraju ponašanje neparametarskih modela, poput GP (Garnelo et al, 2018). Umesto da koriste unapred definisanu funkciju sličnosti (kernel), oni uče predstave konteksta kroz enkoder i iz tih predstava izvode predviđanja, čime se adaptiraju različitim funkcijskim raspodelama.

Metoda CNP je implementirana kao metoda nadgledanog učenja sa ciljem da aproksimira nepoznatu funkciju (posmatranja koja nemamo), uzimajući samo ograničeni podskup poznatih podataka. Metoda CNP je u ovom istraživanju prvi put iskorišćena za potrebe modelovanja i analize krivih sjaja kvazara.

Arhitektura inicijalnog neuronskog procesa, koju smo implementirali je razvijena u programskom jeziku Python korišćene su brojne biblioteke i moduli, među kojima je jedna od navažnijih biblioteka: TensorFlow (Abadi et al, 2016). Arhitektura CNP se sastoji od dva višeslojna perceptrona (neuronskih procesa) i agregatora. Ulazni podaci su tačke (posmatranja) u dvodimenzionalnom prostoru, pri čemu je x_i vreme u kome vršeno posmatranje određenog objekta u mernim jedinicama: julijanski datum, dok je y_i izmereni fluks (ili magnituda) tog objekta u tom trenutku u jedinicama mJy. Podaci se se nakon pripreme, dele nasumično dele na trening, validacioni i test skup, u odnosu 80:10:10 (pri čemu su isprobavane i drugi odnosi tokom istraživanja, ali su oni dali slabije rezultate), Program je napravljen da se odnos ovih skupova može lako modifikovati, kao i uzimati nasumično procenat sa određenim ograničenjima. Validacioni skup je takođe bio korišćen potrebe ranog zaustavlja procesa učenja, pri dostizanju zadate tačnosti rezultata.

Zadatak koji treba da reši naš neuronski proces je da „pogodi“ vrednosti fluksa (magnituda) u vremenskim trenucima kada nisu vršena posmatranja i nemamo relane vrednosti. To nam je potrebno da bi dobili što realističniji i kontinuirani prikaz krive sjaja. Do toga dolazimo tako što prvo iz našeg skupa

podataka O , koji se sastoji od n tačaka, izdvojimo podskup O_N od N tačaka, koje nazivamo kontekstne tačke i drugi podskup sa m tačaka za koje uzimamo samo vremenske trenutke, to su nam ciljne tačke, odnosno skup ciljnih tačaka T . Nakon procesiranja dobićemo predikciju fluksa (ili magnitude) u vremenskim trenucima tačaka ciljnog skupa. Rezultate ćemo onda moći da uporedimo sa stvarnim izmerenim vrednostima, utvrdimo tačnost metode i u svakoj narednoj iteraciji unapredimo parametre neuronskog procesa.

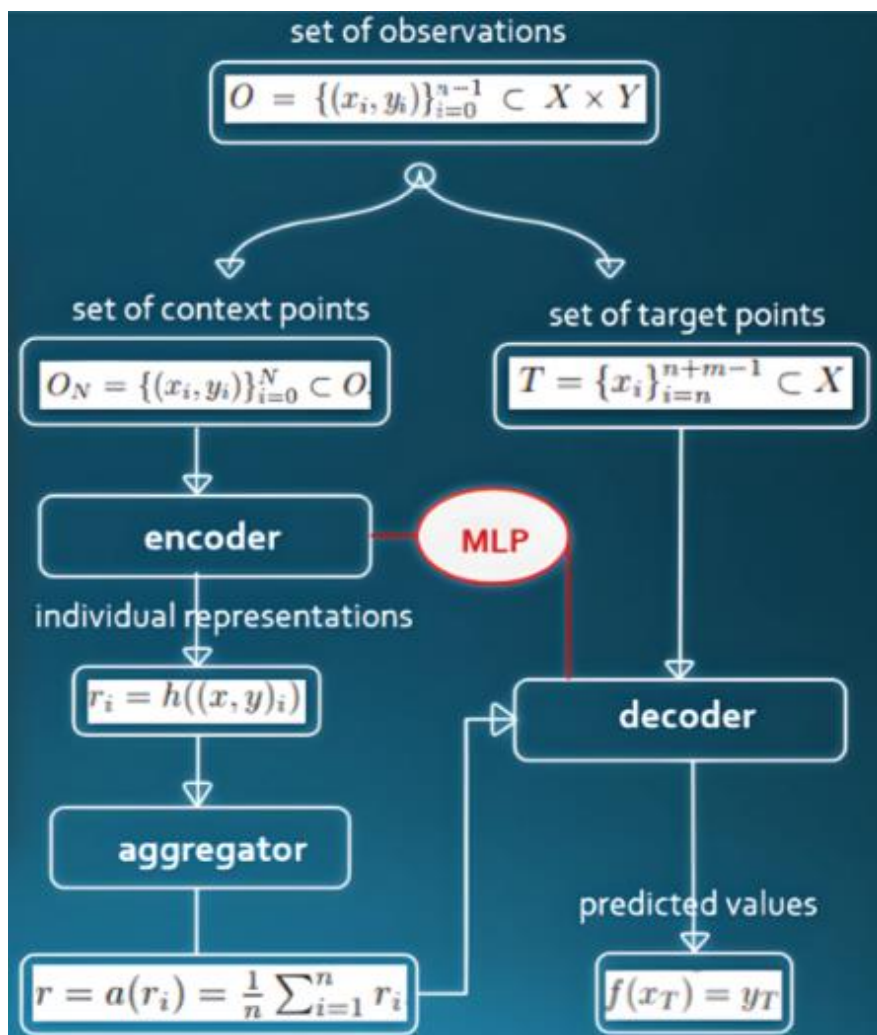
$$O = \{(x_i, y_i)\}_{i=0}^{n-1} \subset X \times Y, \quad (4.1)$$

$$O_N = \{(x_i, y_i)\}_{i=0}^N \subset O, \quad (4.2)$$

$$T = \{(x_i)\}_{i=n}^{n+m+1} \subset X. \quad (4.3)$$

Kontekstne tačke se koriste za treniranje neuronskog procesa, dok se ciljne tačke koriste za predikciju, odnosno modelovanje krive sjaja. Skup kontekstnih tačaka se ubacuje u enkoder kao što je prikazano na Slici 25.

Enkoder je neuronski proces, tačnije, višeslojni perceptron (MLP – multi-layer perceptron), koji od svake ulazne vrednosti (kontekstne tačke) proizvodi izlaz niže dimenzije (označenu funkcijom h na Slici 25): $r_i = h((x, y)_i)$. Vrednost r_i se izračunava stohastičkim procesima i raličita je za svaku kontekstnu tačku $(x, y)_i$. Agregator kombinuje reprezentativne vrednosti r_i svih kontekstnih tačaka, čime se dobije jedinstvena reprezentacija r . Naša implementacija agregatora (označena funkcijom a na Slici 25) izračunava r kako srednju vrednost svih r_i . Ova vrednost bi trebalo da sadrži informacije nepoznate funkcije koju želimo da otkrijemo sa nekolicinom kontekstnih tačaka, koje su nam dostupne. Ovu jedinstvenu vrednost r kombinujemo sa ciljnim tačkama x_i (neobeležene tačke) i to predstavlja ulaz za dekoder. Dekoder, koje je takođe višeslojni perceptron, izračunava za svaku ciljnu vrednost izlaz, odnosno srednju vrednost i varijansu raspodele predikcija.



Slika 25: Šematski prikaz uslovnog neuronskog procesa (CNP), gde je prikazan tok podataka. Skup posmatranja O deli se na kontekstne tačke (O_N) i ciljne tačke (T). Enkoder generiše individualne reprezentacije (r_i), koje agregator kombinuje u zajedničku reprezentaciju (r). Zatim (r) i ciljne ulazne vrednosti (x_T) prosleđuju se dekoderu radi predikcije izlazne vrednosti ($f(x_T) = y_T$). Oznaka MLP predstavlja višeslojni perceptron. Kontkstne tačke se procesiraju u enkoderu i agregatoru. Izlazni rezultat ovog procesa se šalje u dekoder zajedno sa ciljnim tačakama da bi se izračunala predikcija (Čvorović – Hajdinjak et al, 2022).

Pomoću srednje vrednosti i varijanse izračunava se logaritam verovatnoće predikcija y , koji se koristi za optimizaciju metode propagacijom unazad i

ažuriranjem parametara (težišne vrednosti) neuronskog procesa u svakoj iteraciji. Funkcija greške odgovara funkciji negativnog logaritma verovatnoće realnih (tačnih, izmerenih) vrednosti ciljnih tačaka, pod predviđenom raspodelom, pa se može interpretirati kao stepen u kom statistički model odgovara merenju. Jednostavnije objašnjenje je da se greška između realnih i vrednosti predikcija, meri funkcijom greške. Funkcija greške ukazuje koliko tačno algoritam uspeva da modeluje funkciju da bi se dobio željeni rezultat. Funkcija greške se odnosi na penalizaciju modela, koji ne uspeva da odredi očekivane rezultate (Nikolić et al, 2019). Ako je devijacija modela velika i funkcija greške će biti velika i obrnuto.

U prvoj fazi našeg istraživanja, koristili smo ciljne tačke za koje smo znali relane (izmerene) vrednosti magnitude (ili fluksa) da bi mogli da izračunamo koliko su tačne predikcije koje model daje na izlazu svake iteracije. U drugoj fazi, koristili smo ekvidistantne ciljne tačke da predvidimo vrednosti, što nam je omogućilo da napravimo model funkcije koja je prikladnija za dalje analize. Cilj treniranja je da se minuzuje funkcija greške (Garnelo et al, 2018).

$$\mathcal{L}(\theta) = -\mathbb{E}_{f \sim P} \left[\mathbb{E}_N \left[\log Q_{\theta}(\{y_i\}_{i=0}^{n-1} | \mathcal{O}_N, \{x_i\}_{i=0}^{n-1}) \right] \right] \quad (4.4)$$

Sa smanjenjem funkcije greške, logaritam verovatnoće ciljnih predikcija postaje veći, tj. predviđena raspodela postaje bolji statistički model datog uzorka. Za optimizaciju je korišćen optimizator Adam (Kingma et al, 2017) sa stopom učenja 0,0001. Adam optimizator se pokazao dobro za optimizaciju stohastičkih funkcija, kao i problema sa velikim brojem podataka. Pored toga, pokazao se dobro kod modelovanja nestacionarnih ciljeva, sa veoma šumovitim i razućenim gradijentima (Kingma et al, 2017). Takođe je efikasan za izračunavanje i ne zahteva puno memorijskog prostora, što ga čini pogodnim za naše potrebe. Ovakav pristup modelovanju podataka, dozvoljava metodu da se oslanja samo na empirijske podatke, bez nametanja potrebe za teorijskim pretpostavkama u

vezi sa podacima (Garnelo et al, 2018), što je od izuzetnog značaja i prvi put ispitano na krivama sjaja AGJ.

Metoda CNP može da napravi dobre predikcije sa malom količinom podataka. To je demonstrirano na Slici 26, gde je korišćen veštački kreiran uzorak (skup rasutih podataka) napravljen GP-om. Arhitekturu CNP-a sačinjavaju:

1. enkoder, koji se sastoji od 5 slojeva. Ulazni i unutrašnji slojevi koriste linearnu⁶ funkciju sa po 128 ulaznih i izlaznih nerona (osim ulaznog sloja koji ima 2 ulazna čvora, jer imamo dva vektora, koji predstavljaju ulazne vrednosti). Spoljašnji sloj koristi funkciju Relu⁷;
2. agregator, koristi funkciju torch.mean⁸ kako bi odredio srednju vrednost izlaznih vrednosti enkodera;
3. dekodler, koji se sastoji od 6 slojeva. Ulazni i prva tri unutrašnja sloja koriste linearnu funkciju, zatim imamo još jedan unutrašnji sloj koji koristi funkciju Relu. Izlazni sloj dekodera koristi funkciju Softplus⁹.


Realna kriva (tačni podaci) je na Slici 26 predstavljena crnom isprekidanom linijom, dok su kontekstne tačke koje su predstavljale ulazne podatke tri crne tačke. Model je predvideo srednju vrednost i varijansu, koja je na slici obeležena zelenom linijom i svetlozelenim osenčenim regionom, respektivno. Ovaj model je dobijen nakon sto hiljada iteracija. Sledeći korak je ispitiavnje ovog modela na podacima (merenjima) krivih sjaja AGJ, koji su opisani u poglavlju Podaci.

⁶ Više detalja o ovoj funkciji se može pogledati na <https://docs.pytorch.org/docs/stable/generated/torch.nn.Linear.html> .

⁷ Više detalja o ovoj funkciji se može pogledati na: <https://docs.pytorch.org/docs/stable/generated/torch.nn.ReLU.html> .

⁸ Više detalja o ovoj funkciji se može pogledati na <https://docs.pytorch.org/docs/stable/generated/torch.mean.html> .

⁹ Više detalja o ovoj funkciji se može naći na: <https://docs.pytorch.org/docs/stable/generated/torch.nn.Softplus.html> .



Slika 26: Modelovanje GP generisane krive metodom CNP nakon 100 000 iteracija. Svetlo zeleni region je jedan sigma interval poverenja. Crne tačke su kontekstne tačke. Crna isprekidana linija predstavlja stvarne vrednosti krive, zelena srednju vrednost predviđanja (Garnelo et al, 2018).

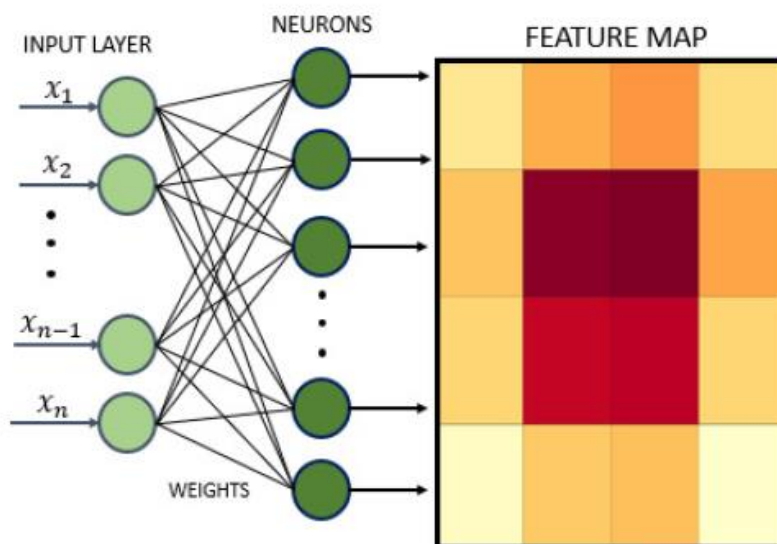
Drugi cilj našeg rada je da napravimo kod koji je adaptibilan za procesiranje veoma velike količine podataka (krivih sjaja kvazara i drugih objekata), koji se očekuju da budu prikupljeni tokom LSST projekta. Zbog ovog razloga probali smo i da uradimo inicijalna ispitivanja paralelizacije našeg koda i testiramo performanse. Testiranje različitih konfiguracija, radi ubrzavanja treniranja i ftovanja krivih je rađeno na SUPERAST kompjuteru (HPE ProLiant DL380 Gen10 2x Xeon 4210-S 64GB SFF) čiji server se nalazi na katedri za Astronomiju, Matematičkog fakulteta na Beogradskom univerzitetu (što je detaljnije objašnjeno u Kovačević et al, 2021). Na SUPERASTu postoje dva čvora, pri čemu se tokom testiranja svaki sastojao od 40 jezgara, 128GB RAM, 2TB memorije SSD i 3 DP GFLOPS (DoublePrecision Giga Floating Point Operations Per Second). Rezultati ovih testiranja su prikazani u poglavlju Rezultati i predstavljaju jedan od pravaca u kome se može odvijati dalja optimizacija izvršavanja koda.

Nakon što se CNP kojim su vršena inicijalna testiranja i primenljivost na skupu podataka krivih sjaja AGJ pokazao kao dobro rešenje, on je unapređen za masovnu obradu (QNP_y), radi implementacije u budućim projektima, kod kojih se očekuje veoma velika količina podataka.

4.2. Samoorganizujuće mape

U ovom poglavlju opisujemo primenu samoorganizujućih mapa za klasterovanje krivih sjaja AGJ. Prvo ukratko predstavljamo osnovne koncepte SOM procesa, zatim definišemo način obrade podataka, uključujući normalizaciju ulaza i konfiguraciju hiperparametara.

SOM su neuronski procesi koje se sastoje od skupa povezanih čvorova/neurona u strukturi koja šematski podseća na model neurona u biološkom mozgu. Neuroni su kod neuronskih procesa grupisani tako da formiraju slojeve (Gang, 2023). Klasterovanje je tip nenadgledanog učenja, koje se koristi da bi se otkrili oblici i odnosi u podacima, koje je veoma teško drugačije prepoznati (Nikolić et al, 2019). Postoji mnogo algoritama koji se koriste za klasterovanje podataka: k-means (Ordoñas-Pascual & Sanchez Almeida, 2014), Gausovi (Toth et al, 2019), spektralno klasterovanje (Ng et al, 2001), hijerarhijsko klasterovanje (Yu & Hou, 2022), itd. Među mnogim algoritmima mašinskog učenja koji se bave ovim problemom, izdvojili smo metodu samoorganizujućih mapa, zbog veoma dobrog vizuelnog prikaza podataka, klasterovanja i mogućnosti za smanjenje dimenzionalnosti (Slika 27). SOM je korišćen u astronomiji za mapiranje empirijskih relacija boja galaksija prema crvenom pomaku (Buchs et al, 2019). Ovaj algoritam je takođe korišćen za vizuelizaciju i izračunavanje-procenu određenih fizičkih osobina galaksija (Hemmati et al, 2019).



Slika 27: SOM su neuronski procesi koji se koriste za nenadgledano učenje. Mogu se koristiti sa smanjenje dimenzionalnosti. Prikazana mapa je izlaz (mapa karakteristika) nakon klasterovanja SWIFT/BAT podataka (Čvorović – Hajdinjak, 2024).

Primena SOM za klasterovanje krivih sjaja AGJ predstavlja potpuno nov pristup, koje je izabran zbog prednosti koje nam omogućavaju karakteristike SOM metode. Najpre SOM je veoma dobar u smanjenju dimenzionalnosti kompleksnih podataka, pri čemu ostaju očuvane topološke i metričke relacije u podacima. To ga čini idealnim za analizu podataka visoke dimenzionalnosti, kao što su krive sjaja AGJ. To je posebno korisno za identifikaciju skrivenih struktura krivih sjaja, koje je nemoguće uočiti drugim metodama. SOM može da uoči nelineane i nestacionarne promjenljivosti kod krivih sjaja AGJ, klasterovanjem krive sjaja sličnog oblika, koji je baziran na amplitudama promjenljivosti, vremenskim skalama promjenljivosti, i sl. Podela krivih sjaja u klaster, SOM omogućava precizniju kasniju obradu i modelovanje, gde svaki klaster može predstavljati drugačiji arhetip promjenljivosti. Modelovanje svakog klastera odvojeno, bi nam omogućilo kreiranje tačnijeg i više specijalizovanog modela,

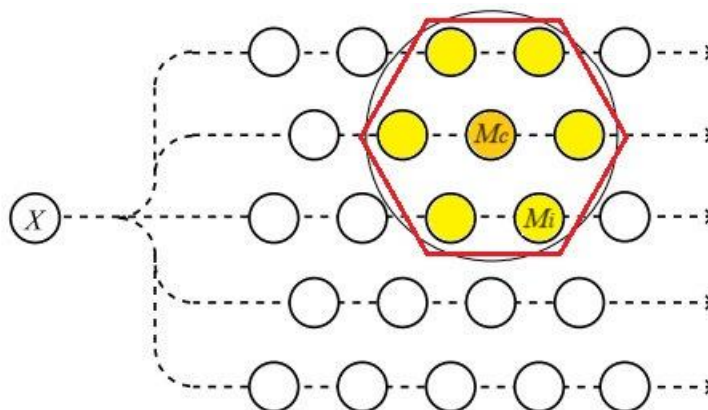
koji uzima u obzir specifične karakteristike i specifičan šum svakog pojedinačnog klastera. Ovakav pristup može pomoći u kvalitetnijem modelovanju (predviđanju, uočavanju) krivih sjaja specifičnih za svaki klaster, a kasnije i lakšu analizu fizičkih procesa koji uzrokuju takvu vrstu promenljivosti. Pored toga, SOM može unaprediti efikasnost procesa modelovanja (predviđanja) krivih sjaja, tako što će se fokusirati na određene odlike krivih sjaja svakog od klasterovanih podskupova, što će dati bolje rezultate od modela koji bi koristio sve podatke pokušavajući da nađe jedan model koji odgovara svim (različitim) tipovima krivih sjaja.

SOM metoda, takođe poznata kao i Kohonenova mreža (Kohonen, 1990) se bazira na kompetitivnom učenju. Neuroni (ili čvorovi) se „takmiče“ koji će biti aktiviran uzimajući u obzir ulazni skup podataka. Neuron koji je najbolje odgovara unetim podacima, naziva se pobednički neuron ili jedinica koja najviše odgovara (best matching unit - BMU).

Svaki neuron ima svoj težinski vektor, koji je istih dimenzija kao i ulazni podaci. Na početku treniranja SOM mreže, težinski vektori čvorova inicijalizuju se nasumično. Tokom propagacije unapred, ulazne vrednosti se porede sa čvorovima (Slika 28), korišćenjem „funkcije suseda“, koja izračunava težinu susedstva, odnosno poziciju na mapi. MiniSOM metoda (Vettigli, 2018), koju smo mi koristili ima nekoliko opcija koje se mogu postaviti za „funkciju suseda“. Tokom testiranja je utvrđeno da je za SWIFT/BAT podatke najbolje koristiti Gausovu funkciju (gde bi parametar sigma, koji definiše koliki je uticaj susednih čvorovima bio podešen na 2,0), kao što se može videti u poglavlju Rezultati. Tokom procesa treniranja, algoritam izračunava Euklidsku distancu između težišnih vektora i trenutne ulazne vrednosti:

$$d(x, w_j) = \sqrt{\sum_{i=0}^{p-1} (x_i - w_{ij})^2}, \quad (4.5)$$

gde vektor $x = (x_0, \dots, x_{p-1})$ predstavlja ulaznu vrednost, dok w_{ij} predstavlja težišnu vrednost čvora j . Udaljenost (koja se može odrediti Euklidskom ili nekom drugom metrikom) određuje razliku između vektora iste veličine.



Slika 28: Adaptiran prikaz iz rada Kohonen, 1990, koji ilustruje SOM implementaciju. Ulazni vektor X se poredi sa skupom čvorova M_i . Čvor M_c koji je "najsličniji" ulaznom vektoru je pobednički čvor. Njemu susedni čvorovi su sličniji vektoru X od ostalih (Čvorović – Hajdinjak, 2024).

S obzirom da se tokom treniranja u SOM mrežama koristi Euklidska distanca između vektora podataka i težinskih vektora čvorova, normalizacija podataka je ključna, kako bi se obezbedilo da sve promenljive imaju isti uticaj na određivanje udaljenosti. Normalizacija je takođe neophodna za stabilnosti treniranja.

Čvor koji je najbliži ulaznom čvoru predstavlja BMU. Težinske vrednosti u algoritmu se ažuriraju na sledeći način, da bi se adaptirala raspodela podataka:

$$w_{ij}(t + 1) = w_{ij}(t) + \theta_j(t)\alpha(t)(x_i(t) - w_{ij}(t)) \quad , \quad (4.6)$$

gde je $i = 0, \dots, p - 1$; t predstavlja iteraciju; $\theta_j(t)$ je funkcija suseda; a $0 < \alpha(t) < 1$ koje vremenom monotono opada, je stopa učenja. Funkcija suseda određuje u

kojoj meri se svaki izlazni čvor ažurira u skladu sa trenutnom šemom treniranja (Nikolić et al., 2019). Gausova funkcija je uobičajen izbor za funkciju suseda:

$$f(x, \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad (4.7)$$

gde x predstavlja ulaznu vrednost, dok su μ i σ , srednja vrednost i standardna devijacija (respektivno).

Metoda miniSom (Vettigli, 2018) takođe daje mogućnost da se izabere drugačija topologija za klasterovanje: pravougana ili haksagonalna, kao i različite metode za normalizaciju podataka (pomoću funkcija: 'minmax', 'standard', 'robust'), može se menjati i stopa učenja itd. Nakon pažljivog testiranja sa različitim konfiguracijama ovih parametara i analize rezultata, došli smo do zaključka da je za SWIFT/BAT podatke najbolja kombinacija hiperparametara sledeća:

- (i) funkcija za normalizaciju: 'minmax' - to je funkcija koja normalizuje podatke u fazi njihove pripreme za treniranje
- (ii) funkcija suseda: 'gaussian' - za određivanje susedstva BMU i ažuriranje težišnih vrednosti
- (iii) broj iteracija za treniranje: 50000
- (iv) topologija: 'rectangular' - pravougano susedstvo
- (v) stopa učenja: 0.01
- (vi) sigma: 2.0 - uticaj susednih čvorova

Funkcija koja je korišćena za normalizaciju „minmax“ je razvijena u paketu `sklearn.preprocessing.MinMaxScaler`¹⁰. Ona transformiše ulazne podatke na interval $[0, 1]$, na sledeći način:

¹⁰ Više detalja se može pronaći na <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html>

$$x_{std} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad , \quad (4.8)$$

$$x_{scaled} = x_{std}(max - min) + min \quad , \quad (4.9)$$

gde min i max određuju interval u kom hoćemo da skaliramo podatke (u našem slučaju $min = 0$, a $max = 1$). Zbog odgovarajuće veličine skupa, klasterovanje ovih podataka izvršeno je brzo i efikasno. Ceo proces je trajao ≈ 5 minuta.

Tokom testiranja sa različitom konfiguracijom hiperparametara, primećeno je da pored funkcije skaliranja tokom preprocesiranja podataka, topologije i intenziteta uticaja susednih čvorova, na rezultate klasterovanje SOM metodom takođe utiču i tačke u krivama sjaja koje u velikoj meri odstupaju od ostalih (autlejeri). Mali skupovi pogrešno klasterovanih krivih sjaja su za posledicu imali znatno lošije performanse kasnijeg modelovanja krivih sjaja QNPy metodom. Nakon razmatranja ovog problema, dodati su dodatni koraci u preproceranju (sređivanju krivih sjaja pre klasterovanja), koji su otklanjali autlejere funkcijom Z-Score:

$$z = \left| \frac{m - \mu}{\sigma} \right| \quad , \quad (4.10)$$

gde je m izmerena magnituda tokom posmatranja određenog objekta u određenom trenutku, μ je srednja vrednost svih magnituda te krive sjaja, a σ je standardna devijacija. Svaka tačka (posmatranje) kod koje je izmerena vrednost z bila manja od 2.0 je odrstanjena iz skupa tačaka te krive sjaja, jer je smatrana autlejerom.

Broj klastera (jata) je takođe hiperparametar SOM metode (Kohonen 2013, 2014). Formula kojom se izračunava idealan broj klastera u koje delimo skup svih krivih sjaja je bila ažurirana tokom brojnih eksperimenata na različitim kombinacijama skupova, da bi dobili jednačinu koja u velikoj meri odgovara različitim skupovima krivih sjaja. Bilo nam je važno da izbegnemo rezultat klasterovanja koji bi sadržao veliki broj klastera sa malim brojem krivih sjaja u

svakom klasteru, jer bi to mogao da dovede do problema sa overfittingom u daljem modelovanju krive pomoću neuronskog procesa QNPy. Sa druge strane, mali broj klastera sa velikim brojem krivih sjaja, koje nemaju previše sličnosti bi nam dao generalizovane klastere (jata) koji ne bi poboljšali performance daljeg modelovanja krivih sjaja QNPy metodom. Došli smo do formule koja određuje broj klastera na osnovu dužine ulaznih podataka. Tačnije dužina ulaznih krivih sjaja - vektora (koje su prethodno dopunjene da bi bile iste dužine) određuju okvir i granice mape klastera. Ova vrednost se izračunava na osnovu jednačine:

$$g = R_u(\sqrt{\sqrt{n}}) \quad , \quad (4.11)$$

gde je g broj granica koje čine mapu klastera, $R_u(x)$ je funkcija koja vraća namanji ceo broj veći ili jednak broju x , a n je dužina ulaznih (dopunjenih) krivih sjaja.

Rezultati ovih testiranja su prikazani i analizirani u Poglavlju 5.

5. Rezultati

U ovom poglavlju će biti detaljnije objašnjeni rezultati dugogodišnjeg testiranja modelovanja krivih sjaja uslovnim neuronskim procesom, koja je napravljena posebno za potrebe modelovanja krivih sjaja ovih objekata na osnovu podataka, koji su prikupljeni u višegodišnjim posmatranjima. Nakon inicijalnog ustanovljavanja upotrebljivosti ove metode za dobijanje upotrebljivih rezultata za dalju analizu, CNP je unapređen da procesira veliku količinu krivih sjaja istvremeno (QNP_{Py} metoda). S obzirom na stohastičku prirodu podataka i strukturalne razlike među krivama sjaja, testiranja su sprovedena na reprezentativnim uzorcima kako bi se obuhvatile različite kategorije promenljivosti AGJ izvora. Rezultati testiranja te unapređene metode će takođe biti prikazani i diskutovani u daljem tekstu, kao i konačna optimizacija koda preprocesiranjem krivih sjaja SOM metodom klasterovanja.

5.1. Rezultati modelovanja CNP metodom

Prikazaćemo nekoliko reprezentativnih primera modelovanih krivih sjaja AGJ nakon 300 000 iteracija, koje pokazuju kakve rezultate CNP daje sa veoma različitim skupovima podatka, odnosno krivama sjaja, koje imaju veoma specifične i različite karakteristike. Određene krive sjaja su pokazale veću složenost za modelovanje, sa izraženim razlikama u strukturi, što je uobičajeno za AGJ izvore, zbog čega su ovi objekti i veoma kompleksni za analizu. U prvoj fazi je utvrđivana efikasnost CNP na pojedinačnim krivama sjaja svakog AGJ iz ASAS-SN (Shappee et al, 2017; Kochanek et al, 2017) baze. Nakon toga je ispitana

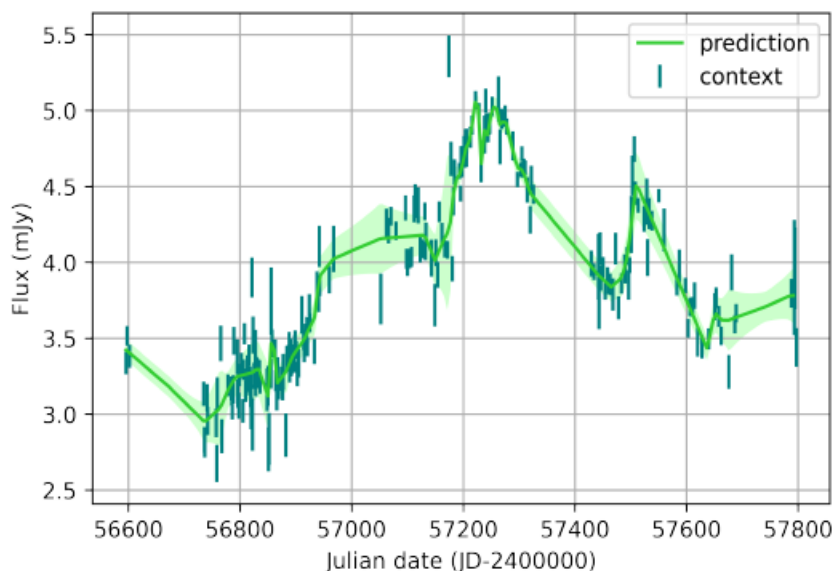
Rezultati

upotreba modifikovanog CNP (QNP_y) za masovno modelovanje na istim krivama sjaja (što je detaljno objašnjeno u Poglavlju 5.3).

Tabela 2: Osnovni paramettri CNP modela za nekoliko odabranih reprezentativnih primera koji su dobijeni u inicijalnim testiranjima. Kolone u tabeli predstavljaju (s leva nadesno): naziv objekta čiju krivu sjaja posmatramo, broj merenja koji imamo za taj objekat, odnosno broj tačaka krive sjaja koje su nam poznate (n), vremenski interval (raspon) u kome su obavljena merenja prikazan u danima (L), vreme izvršenja CNP metode za 300 000 iteracija i najbolje dobijene vrednosti za funkciju greške ($loss$).


Objekat	N	L (dani)	T (sekunde)	Loss
3C 382	225	1253	1735	0.004859
Fairall 9	246	1318	1898	0.007852
Mrk 509	259	1319	1857	0.001648
NGC 7469	264	2136	1809	0.008796
2MASXJ11454045-1827149	376	2138	1917	0.177469

Prva dva objekta iz Tabele 2, koja su predstavljane na Slikama 29 i 30 uočavamo dominantne promene gradijenta u krivama sjaja. U ovoj tabeli su navedeni detalji izdvojenih objekata, koji su tokom inicijalnih testiranja dali prikazane rezultate. Na Slici 29 se može videti da je modelovana kriva sjaja objekta 3C 382, obližnje ($z = 0.058$) radio galaksije sa širokim linijama (BLRG – brad line radio galaxy) u čijem centru se nalazi supermasivna crna rupa mase $1.0 \pm 0.3 \times 10^9 M_{\odot}$ (izračunata reverberacionim mapiranjem, Fausnaugh et al, 2017). Interval u kome su vršena posmatranja je 1253 dana (Tabela 2). Vidimo da je CNP metoda uspela da modeluje (sa velikom tačnošću predvidi) promenu gradijenta iz uzlaznog u silazni, sa istaknutim vrhom na 57250 MJD.




Slika 29: CNP modelovanje krive sjaja 3C 382 nakon 300000 iteracija. Svetlo zelena kriva (prediction) srednja vrednost modela, pri čemu su plave uspravne linije kontekstne tačke korišćene za treniranje (context), sa greškama merenja. Svetlo zelena površina je interval poverenja koji zavisi od broja kontekstnih tačaka (Čvorović – Hajdinjak et al, 2022).

Na Slici 30 je prikazana upotreba CNP metode za modelovanje krive sjaja objekta Fairall 9. To je radio tiha Sajfert tipa 1 galaksija, udaljena $z = 0.0461$ (Lauberts et al, 1989). Ona takođe ima u centru aktivno galaktičko jezgro mase $2.55 \pm 0.56 \times 10^8 M_{\odot}$ (izmereno reverberacionim mapiranjem, Peterson et al, 2004). Vremenski interval u kome su vršena merenja fluksa objekta Fairall 9 je 1318 dana. Dobijen model krive sjaja AGJ pokazuje ekstremne promene gradijenta u periodima od 400 dana. Vidimo da CNP može da “nauči” brze varijacije, ali je potreban veliki broj iteracija da bi se dobio dobar i upotrebljiv rezultat za dalju analizu.




Slika 30: CNP modelovanje krive sjaja Fairair 9 nakon 300000 iteracija. Svetlo zelena kriva (prediction) srednja vrednost modela, pri čemu su plave uspravne linije kontekstne tačke korišćene za treniranje (context), sa greškama merenja. Svetlo zelena površina je interval poverenja koji zavisi od broja kontekstnih tačaka (Čvorović – Hajdinjak et al, 2022).

Kriva sjaja Sejfert 1 galaksije 2MASX J11454045-1827149 (Slika 31) je primer krive sjaja, tačnije podataka veoma kompleksne strukture, sa malom gustinom posmatranja (merenja) u prvih 1000 dana, na koju se nadovezuju sledećih 1000 dana, gde imamo jako usko zbijene podatke, sa vidljivim flerovima (lokalnim maksimumima) i nekoliko uzastopnih vrhova (pikova), koji mogu ukazivati na neku vrstu kvaziperiodičnih oscilacija, kod ovog objekta. Interval u kome su vršena posmatranja iznosi 2138 dana.




Slika 31: Isto kao za Sliku 30, samo za objekat 2MASX J11454045-1827149.

Modelovana kriva sjaja bliske Sejfert 1 galaksije ($z = 0.034$) Markarijan 509 (Slika 31), pokazuje model sa sekvencijalnim primenama gradijenta (Marshall et al, 2009), uprkos nepravilnoj gustini posmatranja i nekoliko većih praznina u posmatranjima. Ovaj objekat je posmatran 1319 dana.



Slika 32: Isto kao za Sliku 29, samo za objekat Mrk 509.

Poslednji izdvojeni primer u ovom inicijalnom testiranju je Seifer 1 galaksija NGC 7469 (Slika 33). Model pokazuje jasan konveksan oblik krive sjaja, koja ima nepravilnu strukturu, sa nekoliko velikih praznina u podacima, flerova i mogućih kvaziperiodičnih oscilacija. Posmatranja za ovaj objekat su vršena tokom vremenskog intervala od 2136 dana, što omogućava detaljniju detekciju dugoperiodičnih varijacija.



Slika 33: Isto kao za Sliku 30, samo za objekat NGC 7469.

5.2. Optimizacija paralelizacijom

Tokom procesa testiranja nailazili smo na brojne izazove. Izazovi, poput strukturalne složenosti i prisustva praznina u podacima, zahtevali su podelu podataka na podsakupe radi efikasnijeg testiranja performansi modela. Podskupovi su pravljani kada su postojale velike praznine u podacima (2MASX J11454045-1827149, Fairall 9, 3C 382, NGC 7469), nekad su izbacivani outlejeri –

flerovi ((2MASX J11454045-1827149, 3C 382, Fairall 9) ili su izbacivane dodatne nepotrebne iteracije (3C 382, NGC 7469). Sve je to ispitivano u cilju povećanja efikasnosti – smanjenja vremena izvršavanja programa i povećanja tačnosti rezultata.

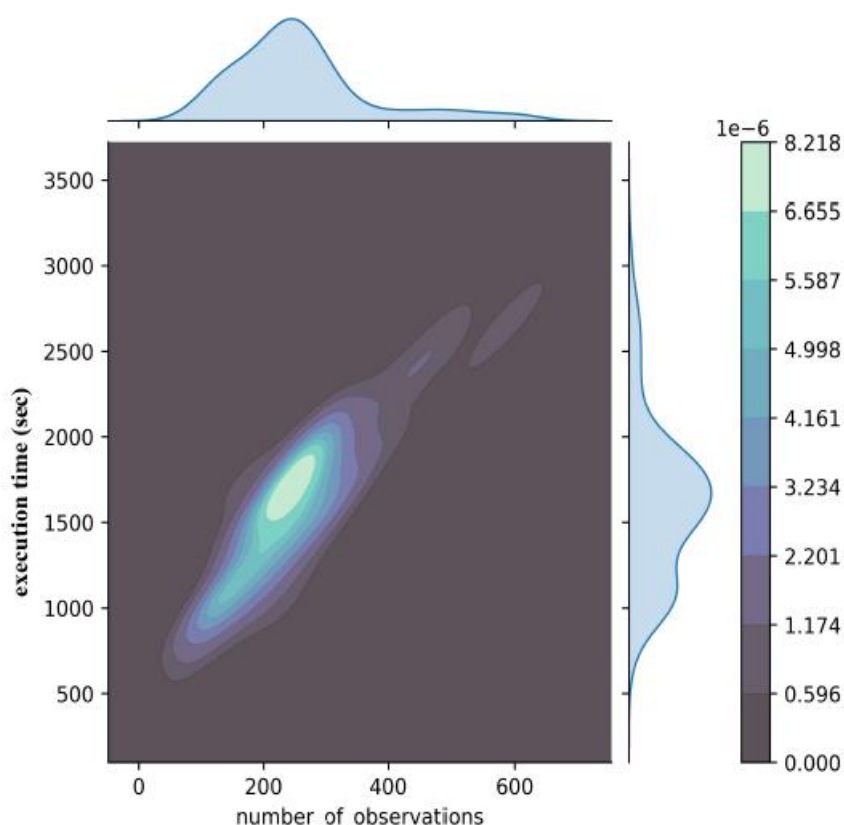
Kao što je pomenuto u Poglavlju 4, za funkciju greške (loss) se uzima negativni logaritam verovatnoće i kao takav on omogućava merenje preciznosti rezultata CNP metode, poređenjem vrednosti predikcija sa realnim merenjima u ciljnim tačkama. Cilj je da se minimizuje greška predikcija CNP metodom, pa se tako vrednost funkcije greške smanjuje sa povećanjem broja iteracija. Njena vrednost u velikoj meri zavisi od broja iteracija. Na osnovu primera koji su dati u Tabeli 2 možemo videti da funkcija greške za prikazane primere ima vrednosti između 0.0016 i 0.1775, što ukazuje da CNP metoda pravi dobre predikcije. U našem modelu, standardna devijacija Gausove raspodele, koja predstavlja izlaznu varijansu za svaku ciljnu tačku, parametrizovana je primenom softplus funkcije. Ovaj izbor osigurava da vrednost bude strogo pozitivna, što je neophodno za ispravno izračunavanje verovatnoće u okviru funkcije gubitka bazirane na logaritmu verovatnoća.

$$\ln(1 + e^x) \in (0, \infty) \quad (5.1)$$

Dakle, softplus funkcija korišćena je zbog svoje glatke prirode i stabilnog ponašanja pri velikim vrednostima ulaza, čime omogućava stabilniju aproksimaciju logaritama verovatnoća.

Kod je testiran sa različitim konfiguracijama neuronaskog procesa, brojem iteracija, broj slojeva u procesu i brojem ciljnih tačaka. Nakon ispitivanja, testiranja i analize rezultata za sva 153 objekta koji su bili procesirani u ovom testiranju, uočena je linearna zavisnost između funkcije greske (loss) i broja merenja (Slika 34). Ovo nas je navelo na zaključak da bi paralelizacija podataka mogla unaprediti efikasnost CNP i to ne samo brzinu izvršavanja programa, nego i unaprediti tačnost predikcije. Iako paralelna obrada sama po sebi ne utiče

direktno na strukturu modela, ona omogućava obradu većeg broja kontekstualnih tačaka u jedinici vremena, čime se statistički poboljšava verovatnoća da agregirana reprezentacija obuhvati relevantne osobine funkcije. Radovi poput Kim et al. (2019) i Le et al. (2020) pokazuju da kvalitet reprezentacije konteksta igra ključnu ulogu u tačnosti predviđanja, te da arhitekture koje bolje koriste veći broj ulaznih tačaka postižu bolje rezultate. U tom smislu, paralelizacija je indirektan, ali važan mehanizam za poboljšanje performansi.




Slika 34: Vreme izvršavanja programa u sekundama kao funkcija broja merenja (tačaka) za 300 000 iteracija i svih 153 krivih sjaja. Sporedni grafici prikazuju margine distribucije vremena izvršavanja i broja merenja, što omogućava dodatni uvid u statističku zavisnost između ovih parametara. Boje predstavljaju funkciju gustine verovatnoće (Čvorović – Hajdinjak et al, 2022).


Deljenjem svake krive sjaja na podintervale (duž vremenske dimenzije, MJD), bi rezultovalo manje kompleksnim strukturama u svakom podskupu i time bi modelovanje krive sjaja (predikcije u ciljnim tačkama) bilo manje zahtevno. Ovaj pristup je korišćen kod modelovanja kriva CNP metodom za potrebe pripreme krivih sjaja AGJ za reverberaciono mapiranje (Jankov et al, 2021).

Radi utvrđivanja mogućnosti dalje optimizacije koda, implementirana je i testirana paralelizacija podataka, korišćenjem modula mpi4py (Dalcin et al, 2018). Prvi testovi su bili malih razmera (2, 4 i 8 jezgara) da bi se utvrdile mogući problemi i rešili pre sveobuhvatnijeg ispitivanja.

Najbolji rezultati (63%) su uočeni prilikom testiranja na 4 jezgra sa 300 iteracija (Slika 35). Uočena je još jedna zanimljivost koja se pojavila tokom testiranja sa 3000 iteracija. Tada se vreme izvršenja smanjivalo sa povećanjem broja jezgara dok broj jezgara nije dostigao 4, gde smo imali minimum, odnosno - najbolje (najbrže) vreme izvršenja. Sa daljim povećanjem broja procesorskih jedinica, nije došlo do daljeg smanjenja vremena izvršenja programa (Slika 36).



Slika 35: Ubrzanje vremena izvršenja u procentima na 4 jezgra u funkciji broja iteracija. Ubrzanje se smanjuje sa povećanjem broja iteracija (Čvorović – Hajdinjak, I. et al, 2022).



Slika 36: Ubrzanje vremena izvršenja za 300 iteracija na 1, 2, 4 i 8 jezgara. Testirano na klasteru kompjutera. Vidljivo je da vreme izvršenja (mm:ss:ms) dostiže minimum na 4 jezgra (Čvorović – Hajdinjak et al, 2022).


Naša inicijalna hipoteza je da je ovaj fenomen gde se sa povećanjem broja jezgara, nakon određenog broja, smanjuje brzina izvršenja programa je da je ovo reprezentacija Amdalovog zakona (Amdahl, 1967), koji se opisuje ubrzanje koje se dobija paralelizacijom (Karbowski, 2015):

$$S(s, p) = \frac{1}{\beta(s,1) + [1 - \beta(s,1)]/p} \quad (5.2)$$

gde je $S(s, p)$ ubrzanje koje zavisi od veličine problema s i broja procesora p . Sekvencijalni deo koda je obeležen sa $\beta(s, 1)$, dok je $T(s, p)$ celokupno realno vreme izvršenja programa na mašini sa p procesora. $T(s, 1)$ označava vreme izvršavanja programa na jednom procesoru. Amdalov zakon ograničava vreme ubrzanja izvršenja programa za veliki broj procesora p :

$$S(s, p) \xrightarrow{p \rightarrow \infty} \frac{1}{\beta(s, 1)} \quad (5.3)$$

Da bi ispitali da li ovo zasta primer Amdalovog zakona, izvršili smo izračunavanja prikazana Slici 37. Ovakav tip zavisnosti je naročito očekivan kod modela sa velikim brojem iteracija, gde sekvencijalna komponenta izvršavanja ograničava ukupno ubrzanje. Vidimo da se funkcija greške (loss) menja tokom modelovanja krivih sjaja sa 300 000 iteracija. Čini se da funkcija greške nekad dostiže minimum vrlo brzo (nakon nekoliko hiljada iteracija), što sugeriše da je dalje treniranje nepotrebno i vreme izvršenja za te slučajeve bi moglo biti daleko kraće. Dodatno, bilo bi zanimljivo ispitati optimalan broj podataka koje bi koristili tokom procesa učenja (kontekstnih tačaka) da bi dobili najtačnije rezultate modelovanja, a time skratili i dodatno skratili vreme izvršenja programa.



Slika 37: Poređenje funkcije greške CNP modela za prethodno prikazane objekte, u odnosu na broj iteracija. Legenda pokazuje boju funkcije greske za svaki objekat (Čvorović – Hajdinjak et al, 2022).

Buduća istraživanja će uključiti testiranje CNP modela za određivanje modela krivih sjaja sa velikim prazninama u podacima, koje bi veštački kreirali uklanjajući poznate podatke iz velikih, dobro semplovanih krivih sjaja.


5.3. Rezultati klasterovanja SOM metodom

Metoda CNP se pokazala kao zadovoljavajuća za obradu krivih sjaja i pravljenje njihovih modela koji su pogodni za dalju analizu. Sa pojavom novih, moćnijih teleskopa (LSST) očekuje se da će količina podataka biti izuzetno velika i da bez pomoći neuronskih procesa sa mogućnostima masovne obrade tih podataka, neće biti moguće uraditi dobru analizu. Metoda CNP je nadograđena tako da može da obrađuje i modeluje podatke velikog broja krivih sjaja odjednom. Ova nova metoda (QNP_y) je testirana na podacima iz skupa krivih sjaja prikupljenih u SWIFT/BAT misiji (više detalja o podacima je dato u Poglavlju 4). Nakon brojnih testiranja i analiza, uočeno da iako QNP_y metoda daje solidne modele krivih sjaja, ipak oni nekad nisu dovoljno dobri za dalju analizu, posebno kada je skup krivih sjaja sastavljen od krivih sjaja sa veoma različitim karakteristikama. Da bi utvrdili da li mogli nekako da prevaziđemo ovaj izazov i unapredimo efikasnost i tačnost QNP_y metode, probali smo da nađemo brzo i jednostavno rešenje kojem bi pretprocesiranjem velikog skupa krivih sjaja, razdvojili krive sjaja prema njihovim topološkim svojstvima. Za te potrebe smo koristili SOM metodu koja klasteruje krive sjaja prema topoloskim svojstvima koja mogu biti povezana sa fizickim svojstvima objekata u klasteru, a koji se uspesno mogu modelovati QNP_y metodom (Kovačević et al, 2023). S obzirom na očekivani obim podataka koji će LSST generisati, unapređenje skalabilnosti kroz klasterovanje SOM metodom predstavlja ključni korak u omogućavanju masovnog modelovanja.


Da bi utvrdili da li će klasterovanje krivih sjaja unaprediti modelovanje neuronskim procesom QNP_y, odrađeni su sledeći koraci:

- 1) ceo skup podataka, koji se sastoji od 139 krivih sjaja je modelovan metodom QNPy; rezultati su sačuvani za kasniju analizu;
- 2) ceo skup podataka, koji se sastoji od 139 krivih sjaja je procesiran SOM metodom. Ovaj proces podrazumeva: dopunjavanje krivih sjaja do dužine najduže krive sjaja, preslikavanje svake od krive sjaja na interval $[0,1][0,600]$. Dopunjavanje se vrši dodavanjem srednje vrednosti krive, uniformno, uzimajući u obzir najmanje vremensko rastojanje u krivoj sjaja. Normalizacija se obavlja pomoću prethodno objašnjenje funkcije za normalizaciju MinMax i konačno klasterovanje (grupisanje krivih sjaja u klasterne (jata) prema sličnim topološkim osobinama);
- 3) analiziranje rezultata i korekcije hiperparametara SOM metode, do dobijanja najoptimalnijih mogućih rezultata;
- 4) biranje nekoliko reprezentativnih klastera radi dalje analize;
- 5) uzimanje podataka originalnih krivih sjaja (pre dopune i skaliranja) iz svakog od odabranih klastera i procesiranje tih pojedinačnih klastera QNPy metodom;
- 6) poređenje rezultata rezultata – dobijenog modela krive sjaja kao rezultata procesiranja celog skupa i kao rezultata procesiranja klastera u koju ju je SOM metod smestio.

Ukljanjanje autlejera, određivanje optimalne konfiguracije hiperparametara i pažljivo preprocesiranje, rezultovali su u boljoj raspodeli krivih sjaja u klasterne (Slika 38), kao i manji broj pograšno klasterovanih krivih sjaja. SOM metoda je podegrupisulila SWIFT/BAT podatke u 16 klastera (Slika 39).



Slika 38: Broj krivih sjaja u svakom od klastera pre (zeleno) i posle (plavo) otklanjanja outlejera iz krivih sjaja iz SFIFT/BAT skupa krivih sjaja kvazara (Čvorović – Hajdinjak, 2024).




Slika 39: Broj krivih sjaja u svakom klasteru, nakon procerianja SOM metodom (nakon dopune, normalizacije i otklanjanja outlejera) podataka SWIFT/BAT krivih sjaja kvazara (Čvorović – Hajdinjak, 2024).

Vizuelni prikaz krivih sjaja podjeljenih u klasterne (Slika 40) pokazuje kompleksnost zadatka i rezultat koji je SOM algoritam uspeo da dobije, grupišući krive sjaja prema (promenama gradijenta) njihovoj strukturi. Vidimo da je u nekim klasterima (3, 4, 8, 9, 11, 12, 14) dopunjavanje krivih u značajnoj meri uticalo na oblik ulazne krive sjaja. Iako je prilikom ove konfiguracije hiperparametara identifikovano 16 različitih klastera (Slika 41), daljom analizom je ustanovljeno da se ovi klasteri mogu svrstati u 4 generalne grupe, na osnovu određenih sličnosti među krivama sjaja u grupama.

- 1) Klasteri sa malom promenljivošću (Clusters with Low Variability: C-LV). U tu grupu spadaju klasteri: 4, 10 i 14, koji pokazuju usko grupisane krive sjaja sa minimalnim razmacima između pojedinačnih posmatranja (tačaka). Takva karakteristika je indikativna za homogeno ponašanje, što ukazuje na mali stepen promenljivosti ili šuma među podacima koji su prikupljeni.
- 2) Klasteri sa umerenom promenljivošću (Clusters with Moderate Variability: C-MV). Krive sjaja koje su smeštene u klasterne 2, 5, 6, 9, 12 i 13 pripadaju ovoj grupi. Uprkos tome što su u nekoj meri tačke raštrkane, pojedinačne krive sjaja u ovim klasterima zadržavaju koherentne oblike i mogu biti kategorisane kao krive sjaja sa umerenom promenljivošću.
- 3) Klasteri sa velikom promenljivošću (Clusters with High Variability: C-HV). Klasteri koji sadrže krive sjaja sa izraženim divergencijama od srednjih vrednosti, sadrže krive sjaja sa visokom promenljivošću. To su klasteri 1, 3, 7, 11 i 15, kod kojih se uočava veoma velika promenljivost u krivama sjaja. Ovo ukazuje na veliki stepen promenljivosti izvora (kvazara) ili visok stepen okolnog šuma prilikom posmatranja.
- 4) Jedinstveni klasteri (Unique Clusters: C-U). Klaster 8 se upadljivo razlikuje od ostalih klastera. Moguće da je to indikacija različitog tipa promenljivosti ili efekta simetričnih podataka. Oblik latiničnog slova „S“

je prisutna kod krivih sjaja u klasteru 8, što može ukazivati na kvaziperiodične oscilacije (QPO). Ovakvo oscilatorno ponašanje sugerise na pozadinske periodične procese koji mogu biti vezani za dinamiku u akrecionom disku ili interakciju sa magnetnim poljem centralne supermasivne crne rupe, te zahteva detaljniju analizu u budućnosti.



Slika 40: Vizuelni prikaz svakog od 16 klastera, sa srednjom krivom prikazanom plavom bojom. SOM metoda zahteva da sve krive sjaja budu iste dužine. Krive sjaja su dopunjene vrednošću srednje magnitude. Nakon dopunjavanja, krive sjaja su mapirane (skalirane) na isti interval i klasterovane (Čvorović-Hajdinjak, 2024).

Dodatno, klaster 16 pokazuje veoma specifičnu strukturu, koja sadrži krive sjaja koje imaju karakteristike krivih sjaja sa flerovima (ekstremima – naglih pojačanja jačine signala) praćenih postepenim spustom (sporijim smanjenjem jačine signala), što je primetno i u srednjoj krivoj. Ovakav oblik krive sjaja bi mogao da sugeriše na prolazne događaje koji se dešavaju u objektu ili njegovoj okolini. Ovakvi modeli će nam pomoći da dublje analiziramo i razumemo dinamiku i fizičke procese AGJ. Prisustvo flerova, koje je uočljivo u krivama sjaja klastera 16, zahteva dodatna ispitivanja da bi se otkrila priroda ovakvih događaja i njihovih astrofizičkih implikacija.

Pored toga, neki klasteri se sastoje od krivih sjaja koje su dopunjavane sa veoma različitim brojem tačaka (klasteri 2, 5, 6). Ovo bi moglo da utiče na sam proces klasterovanja ovako izmenjenih krivih sjaja (jer bi originalne mogle imati drugačiju strukturu i biti drugačije grupisane). Da bi utvrdili da li klasterovanje može unaprediti QNPy modelovanje skupa krivih sjaja SWIFT/BAT, sledeći klasteri su odabrani, na osnovu nekoliko razloga (datih u Tabeli 3). Cilj je bio da se analizama i testiranjem pokrije što više mogućih različitih slučajeva, da bi se dobio što generalniji zaključak kao i dobre i loše strane SOM klasterovanja SWIFT/BAT skupa.


Tabela 3: Klasteri odabrani za analizu efekta klasterovanja SOM metodom (preprocesiranje) na performanse modelovanja QNPy metodom:

Broj klastera	Broj krivih u klasteru	Razog izbora ovog klastera
4 (C-LV tip)	6	Mali broj krivih sjaja i specifična struktura sa jednom velikom promenom gradijenta
13 (C-MV tip)	12	Klaster sa najvećim brojem krivih sjaja, srednja kriva ima vidljivu strukturu
1 (C-HV tip)	11	Klaster sa izrazito promenljivim krivama sjaja i različitim brojem tačaka kojima su dopunjavane originalne krive sjaja

Rezultati


8 (C-U tip)	11	Različit od drugih klastera, sa mogućom indikacijom drugačijeg tipa promenljivosti
16 (specifičan tip)	8	Srednja kriva ima veoma specifičnu strukturu sa karakteristikama koje podsećaju na flerove

Klaster 4 je primer klastera sa malom promenljivošću (cluster with Low Variability: C-LV). Ovaj kluster se sastoji od šest krivih sjaja sa veoma sličnom strukturom i upadljivim nagibima. Na Slici 40 je prikazana razlika modelovanja krive sjaja 3C273, kada se modeluje ceo skup podataka (levo) i kada se modeluje samo klaster 4 (desno). Funkcija greške i srednja kvadratna greška za ovaj objekat, su daleko manje kada QNPy procesira samo klaster 4. Obe modelovane krive sjaja (plave linije) prate glavnu promenu gradijenta, ali model koji je napravljen nakon preprocesiranja SOM klasterovanjem prolazi lepo kroz središnje tačke na najnižem i najvišem delu krive sjaja.




Slika 41: QNPy model krive sjaja 3C273 nakon 3000 iteracija. Podaci su najpre transformisani na interval $[-2,2]$ tokom preprocesiranja. Crveni region je 1 sigma interval poverenja. Levo je prikazan model krive sjaja 3C273 nakon procesiranja celog skupa, desno je model krive sjaja 3C273 nakon procesiranja klastera 4. Klaster 4 je primer klastera sa malom promenljivošću (C-LV). Srednja kriva – model je prikazana plavom linijom (Čvorović - Hajdinjak, 2024).

Klaster 13 je primer klastera sa umerenom promenljivošću (Clusters with Moderate Variability: C-MV). Ovaj klaster se sastoji od 12 krivih sjaja sa sličnom strukturom i upadljivom promenom gradijenta. Na Slici 42 je prikazana razlika modelovanja krive sjaja Mrk6, kada se modeluje ceo skup podataka (levo) i kada se modeluje samo klaster 13 (desno). Ovaj objekat pruža primer adaptacije CNP modela na krivu sa višestrukim prazninama i promenama gradijenta. Funkcija greške i srednja kvadratna greška za ovaj objekat, su manje kada QNPY procesira samo klaster 13. Obe modelovane krive sjaja prate promene gradijenta, ali u slučaju modelovanja nakon klasterovanja (desno), modelovana kriva sjaja objekta Mrk6 (plave linije) bolje prati podatke od početka do kraja krive sjaja (doseže bliže najvišim i najnižim magnitudama), dok model koji nastaje obradom celog skupa krivih sjaja (a ne samo klastera 13) ostaje bliže srednjoj vrednosti magnitute (levo), na celoj dužini krive sjaja.




Slika 42: QNPY model krive sjaja Mrk6 nakon 3000 iteracija. Podaci su najpre transformisani na interval $[-2,2][[-2,2]$ tokom preprocesiranja. Crveni region je 1 sigma interval poverenja. Levo je prikazan model krive sjaja Mrk6 nakon procesiranja celog skupa, desno je model krive sjaja Mrk6 nakon procesiranja klastera 13. Klaster 13 je primer klastera sa umerenom promenljivošću (C-MV). Srednja kriva – model je prikazana plavom linijom (Čvorović - Hajdinjak, 2024).

Klaster 1 je primer klastera sa velikom promenljivošću (Clusters with High Variability: C-HV). Ovaj klaster se sastoji od 11 krivih sjaja sa veoma promenljivom strukturom. Na *Slici 43* je prikazana razlika modelovanja krive sjaja IC4329A, kada se modeluje ceo skup podataka (levo) i kada se modeluje samo klaster 1 (desno). Funkcija greške i srednja kvadratna greška za ovaj objekat, su veće kada QNPy procesira samo klaster 1. Obe modelovane krive sjaja prate promene gradijenta, ali ni jedna od njih ne uspeva da isprati detalje krive sjaja. Dok u prvom modelu, koji nastaje nakon procesiranja celog skupa od 139 krivih sjaja (levo) primećujemo male promene gradijenta u regionima gde je veća gustina tačaka, drugi model koji nastaje nakon procesiranja klastera 1, je potpuno "gladak". Ovo može indikovati da za klasterne koji sadrže veoma promenljive krive sjaja, rezultati modelovanja su približno slični modelovanju celog skupa, što je takođe impresivno, imajući u vidu da je količina podataka (na osnovu kojih algoritam "uči") više od 10 puta manja. Samim tim je i procesiranje daleko efikasnije (za modelovanje klastera je potrebno par minuta, dok je za ceo skup potrebno nekoliko sati, na istom kompjuteru uz ista podešavanja hiperparametara).



Slika 43: Isto kao i slici 43 samo za krivu sjaja objekta IC4329A, koja pripada klasteru 1. Klaster 1 je primer klastera sa velikom promenljivošću (C-HV). Srednja kriva – model je prikazana plavom linijom (Čvorović - Hajdinjak, 2024).


Klaster 8 je primer jedinstvenog klastera (Unique Cluster: C-U). Ovaj klaster se sastoji od 5 krivih sjaja sa veoma specifičnom strukturom. Na *Slici 44* je prikazana razlika modelovanja krive sjaja IRAS09149m6206, kada se modeluje ceo skup podataka (levo) i kada se modeluje samo klaster 8 (desno). Funkcija greške i srednja kvadratna greška za ovaj objekat, su veće kada QNPy procesira samo klaster 8. Obe modelovane krive sjaja prate glavnu promenu gradijenta, ali u prvom slučaju (levo) kad je korišćen ceo skup kriva ima više detalja i uočljivih manjih promena gradijenta u delovima gde su tačke gušće raspoređene. Drugi grafik (gde su modelovane samo krive sjaja iz klastera 8) ima jednostavniju strukturu koja prati glavni trend raspodele podataka (tačaka). Ovo indikuje da klasteri koji imaju krive sjaja jedinstvenog oblika (neke moguće i pogrešno klasterovane), posebno ako se sastoje od malog broja krivih sjaja (u ovom slučaju 6 krivih sjaja), rezultati modelovanja su manje tačni od modelovanja celog skupa podataka.



Slika 44: QNPy model krive sjaja IRAS09149m6206 nakon 3000 iteracija. Podaci su najpre transformisani na interval $[-2,2][[-2,2]$ tokom preprocesiranja. Crveni region je 1 sigma interval poverenja. Levo je prikazan model krive sjaja IRAS09149m6206 nakon procesiranja celog skupa, desno je model krive sjaja IRAS09149m6206 nakon procesiranja klastera 8. Klaster 8 je primer jedinstvenog klastera (C-U). Srednja kriva – model je prikazana plavom linijom (Čvorović - Hajdinjak, 2024).

Klaster 16 se sastoji od 8 krivih sjaja i ima veoma zanimljiv oblik srednje krive sjaja. Nakon dalje analize krivih sjaja koje su klasterovane u ovom klasteru, jasno je da su neke od njih pogrešno klasterovane. Najočigledniji primer je kriva 3C382 (prikazana na Slici 45), koja bi vizuelnom analizom trebalo da bude klasterovana u klaster 4. Nakon procesiranja klastera 16 metodom QNPy, rezultati su se razlikovali od krive do krive. Na Slici 45 je vidljivo da modelovanje celog skupa podataka daje bolje rezultate, kada klasterovanje nije urađeno korektno.

Kriva na levom grafiku prati glavnu promenu gradijenta i celokupnu strukturu podataka, dok desni model krive sjaja (kada je treniran samo klaster 16) ostaje u nivou srednje vrednosti magnitude poznatih tačaka, prateći promenu gradijenta u prvom delu krive sjaja. Takođe možemo videti da funkcija greške i srednja kvadratna greška mogu imati niže vrednosti i za manje tačan model. Ovo može biti posledica činjenice da su skupovi za testiranje i validaciju previse mali za klasterovane krive sjaja, pa je veća verovatnoća da će nasumično odabrana kriva odgovarati modelu. Na osnovu svega ovoga zaključujemo da je potrebno dalje raditi na unapređenju metode za klasterovanje krivih sjaja.



Slika 45: Isto kao na Slici 44 samo za objekat 3C382 iz klastera 16, koji predstavlja specifičan tip klastera, kako je ranije opisano (Čvorović - Hajdinjak, 2024).

Kao što vidimo iz prethodnih rezultata jedan od ključnih izazova u modelovanju vremenskih serija neuralnim procesom (NP) bio je nedostatak uravnoteženosti između različitih topoloških obrazaca u podacima. Ovo posebno ilustrujemo u Prilozima gde je prikazno 432 objekta sa različitim osobinama u promenljivosti sjaja. Trening i validacija su izvršeni na celom skupu, pri čemu objekti sa glatkim trendovima i manjim oscilacijama pokazuju uske intervale poverenja i niske vrednosti greške i MSE.

Rezultati modelovanja svih krivih sjaja bez prethodnog procesiranja SOM metodom, kao i još neki primeri rezultata modelovanih krivih sjaja nakon klasterovanja, se mogu pogledati u Poglavlju Prilozi, na kraju rada.

6. Diskusija rezultata

Aktivna galaktička jezgra, a posebno kvazari su jedni od najjačih izvora elektromagnetnog zračenja u Univezumu. Njihova radijacija pokriva ceo spektar na veoma kompleksan način. Sakupljanje i analiziranje podataka krivih sjaja ovih objekata otkriva njihovu složenu strukturu. Sa razvojem tehnologija za posmatranje (prikupljanje podataka) potrebno je razviti i tehnologije koje mogu obraditi veliku količinu sveobuhvatnijih, dugoročnih merenja, kako bi mogle da se vrše dalje analize i razvijaju hipoteze uzroka i načina emisije ovih objekata, a time i njihova strukture, nastanka, okoline, razvoja i td.

U istraživanjima koja su opisana u ovom radu, najpre je implemetiran uslovni neuronski proces i ispitana je njegova primena na modelovanje krivih sjaja AGJ. Testiran je najpre uzorak od 153 AGJ, čiji su podaci dobijenu u projektu ASAS-SN, a koji dostižu vremenski raspon oko 2000 dana. Prvi rezultati su bili veoma ohrabrujući. Ova vrsta neuronskog procesa se pokazala kao veoma dobra alternativa prethodnim metodama, koje su se koristile za modelovanje ovakvih podataka. Koliko je autoru poznato, ovo predstavlja prvo sistematsko korišćenje uslovnih neuronskih procesa za modelovanje svetlosnih krivih AGJ. CNP je pravio tačne predikcije nakon treniranja na različitim tipovima podataka krivih sjaja AGJ, bez dodatnih teorijskih pretpostavki ili simuliranih podataka. Uočeno je da vreme izvršenja programa raste sa brojem zadatih kontekstnih tačaka (posmatranja). Zaključeno je da bi bila poželjna dalja optimizacija i paralelizacija koda, da bi se dobio efikasniji alat za procesiranje značajnijeg broja podataka.

Inicijalni rezultati sugerišu da je CNP adekvatan alat za modelovanje podataka sa stohastičkom strukturom i nasumičnom promenom gradijenta, ali i da je za dobre rezultate potreban veliki broj iteracija, a samim tim i značajno vreme obrade (izvršenja) programa. CNP predstavlja dobru alternativu

modelovanju GP, koji su ranije korišćeni za modelovanje AGJ krivih sjaja, a koji su imali za cilj dobijanje reprezentacije varijacija krivih sjaja i njihovih eventualnih pravilnosti (ponavljanja) tokom vremena (Kovačević et al, 2018). Čak iako CNP nema optimalno vreme izvršenja, on je kompatibilan sa drugim algoritmima mašinskog učenja koji su bazirani na GP. Sposobnost CNP da skalira funkcije i velike skupove podataka, indicira da bi mogla postojati mogućnost za dalju upotrebu CNP u analizama krivih sjaja AGJ.

Uzimajući u obzir da CNP može biti efikasniji u modelovanju podataka, rezultati indikuju da bi bilo poželjno napraviti dodatne optimizacije koda, kako bi se mogao koristiti u analizama podataka dugoročnih posmatranja, kao što su podaci koje očekujemo da dobijemo tokom rada teleskopa Vera C. Rubin LSST (Ivezić et al, 2019). Tokom rada ovog teleskopa očekuje se prikupljanje podataka o milionima krivih sjaja AGJ. Upravo iz tog razloga je CNP dodatno razvijen i unapređen da bi mogao da vrši masovno procesiranje krivih sjaja AGJ odjednom (a ne jednu po jednu kao kod CNP). Da bi unapredili naše programske alate, sa ciljem da stvorimo alat koji može savladati ogromnu količinu podataka, koje očekujemo u budućnosti, na adekvatan način, razvijen je QNPy program (na osnovu CNP metode) koji može masovno da obrađuje krive sjaja AGJ.

QNPy je uslovni neuronski proces, koji se pokazao kao dobar alat za modelovanje promenljivih i kompleksnih krivih sjaja AGJ. Ipak, za obradu velikog broja nasumično odabranih različitih krivih sjaja AGJ, QNPy nije dovoljno efikasan. U želji da unapredimo performanse QNPy metode, pokušali smo da odradimo preprocesiranje krivih sjaja AGJ SOM metodom klasterovanja. Tako bi krive sjaja bile podaljenje u podskupove slične topologije, čime bi procesiranje svakog pojedinačnog klastera bilo daleko brže i tačnije, odnosno efikasnije. Ovo predstavlja prvo poznato korišćenje SOM metoda kao preprocesorske faze za unapređenje modelovanja svetlosnih krivih AGJ.

SWIFT/BAT podaci (detaljno objašnjeni u Poglavlju Podaci) su korišćeni, jer predstavljaju dobru početnu tačku za ispitivanje podobnosti SOM metode na

skupu koji sadrži kompleksne, stohastičke, nepravilne i vrlo različite krive sjaja (različiti izvori – tipovi AGJ). Ovaj skup je sastavljen od 139 komplikovanih, promenljivih, nehomogenih krivij sjaja, sa dosta praznina, različitim strukturama i dužinama krivih sjaja.

Testiranje neuronskih procesa (QNP_y) na krivama sjaja kompleksne strukture, sa velikim nedostacima u podacima, pomaže u proceni primene i adaptibilnosti QNP_y modela. SOM metoda je odabrana za unapređenje celokupnog procesa, klasterovanjem u fazi preprocesiranja, pre svega jer nije previše kompleksan model nenadgledanog mašinskog učenja. Pored toga, SOM radi dosta brzo, što je od velike važnosti za potrebe preprocesiranja velike količine podataka. Treniranje se vrši kompetitivnim neuronskim procesom (neuroni se „takmiče“ koji će biti aktivirani u kom trenutku). Kompetitivan proces nalazi jedinicu koja je najslabija zadatoj ulaznoj vrednosti (best matching unit - BMU). Nakon toga BMU i njegovi susedi usklađuju svoje težišne vrednosti. U ovom radu je korišćena MiniSom¹¹ implementacija SOM i klasterovane su SWIFT/BAT krive sjaja. Izabrano je nekoliko reprezentativnih klastera, koji su modeovani samostalno QNP_y metodom i rezultati su upoređeni sa modelima koji su dobijeni procesiranjem celog skupa.

Primećeno je da hiperparametri SOM metode (funkcija suseda, topologija mreže itd) u velikoj meri utiču na proces i rezultate klasterovanja. Dodatno, SOM metoda zahteva normalizaciju ulaznih podataka (krivih sjaja) i njihovu transformaciju na isti interval. Uočeno je da otklanjanja autlejera iz krivih sjaja ima pozitivan uticaj na kvalitetnije (tačnije) klasterovanje, kao i ravnomerniju (više ujednačenu) raspodelu krivih sjaja među klasterima.

Rezultati istraživanja indikuju da krive sjaja iz klastera čija srednja kriva ima jasne strukture i malu ili srednju promenljivost (C-LV, C-MV), pokazuju veći napredak pri modelovanju QNP_y metodom, od onih sa velikim stepenom promenljivosti (C-HV) ili jedinstvenom strukturom (C-U), posebno ako takvi

¹¹ Više detalja o MiniSom metodi može se pronaći na: <https://pypi.org/project/MiniSom/>

klasteri sadrže mali broj krivih sjaja. Poređenjem rezultata modelovanih krivih sjaja pre i posle klasterovanja, pokazuje da dobro klasterovanje može doprineti u većoj meri poboljšanju performansi i efikasnosti QNPy metode. Ipak, pokazalo se i da je SOM metoda veoma osetljiva na neke karakteristike ulaznih podataka, što može dovesti do pogrešno klasterovanih krivih sjaja. U tim slučajevima, rezultati QNPy su manje pouzdani kada se modelovanje radi na takvom klasteru nego na celom skupu podataka. Ne samo zato što ima manje podataka od kojih može da „nauči“ model krive sjaja, nego i zato što većina krivih sjaja nema određene karakteristike koje prisutne kod pogrešno klasterovanih krivih sjaja.

Klasterovanje krivih sjaja AGJ u cilju preprocesiranja bi moglo značajno da unapredi modelovanje QNPy metodom, ali samo klasterovanje je potrebno dalje unaprediti u cilju postizanja optimalnih rezultata. Metoda SOM bi mogla biti korišćena za ove potrebe, ali su potrebne dodatne analize i testiranja na različitim skupovima podataka, sa pažljivim odabirom hiperparametara i dobrom pripremom ulaznih podataka. Rezultati sa komentarima u Poglavlju Prilozi pokazuju da je modelovanje vremenskih serija neuronskim procesom veoma osetljivo na raznolikost obrazaca u podacima. Iako je fitovanje krivih bez prethodnog klasterovanja dalo zadovoljavajuće rezultate za objekte sa glatkim trendovima, kao što su NGC4395 i Mrk6, isti pristup pokazuje ograničenja kada se primenjuje na objekte sa veoma naglim promenama, ili širokim rasipanjem, kao što su NGC7469, ESO121mG028, i 3C454. Ova ograničenja ilustruju važnost korišćenja sofisticiranijih pristupa za balansiranje topološke raznolikosti podataka.

Implementacija klasterovanja u funkciji preprocesiranja, značajno je poboljšala performanse modela segmentacijom podataka na osnovu obrazaca varijabilnosti. Analiza pojedinačnih klastera dodatno osvetlja efikasnost ovog pristupa. Na primer, u klasteru 4, u kojem preovlađuju glatki trendovi sa povremenim oscilacijama, model je postigao niske vrednosti greške i srednje kvadratne greške (MSE), što je zabeleženo kod objekta 3C273 (Loss = 39.63, MSE

= 0.19). Ovi rezultati ukazuju na visoku efikasnost modela za predikciju unutar ovog klastera.

U klasteru 13, koji uključuje objekte sa izraženijom varijabilnošću, poput ESO198m024, model je uspešno pratio osnovne trendove, međutim interval poverenja postaje širi u oblastima sa naglim promenama, reflektujući povećanu nesigurnost u predikcijama. Ovi nalazi ukazuju na potrebu za dodatnim unapređenjima modela kako bi se preciznije opisala oscilatorna ponašanja kod ovakvih izvora.

Klaster 16 predstavlja najveći izazov, jer uključuje objekte sa kompleksnim trendovima i izraženim oscilacijama. Dok je model uspeo da ostvari solidne rezultate za objekte kao što je 3C382 (Loss = 206.61, MSE = 0.45), obrada objekata poput 4Cp74 (Loss = 1073.38, MSE = 0.71) i dalje pokazuje ograničenja trenutnog pristupa. Široki intervali poverenja i visoke vrednosti greške u ovom klasteru jasno ukazuju na potrebu za razvojem dodatnih prilagođenih modela za precizno modelovanje ovakvih složenih vremenskih serija.

Iz gore navedenog vidimo da pristup bez prethodnog klasterovanja, daje zadovoljavajuće rezultate samo za objekte sa jednostavnim obrascima promenljivosti. Međutim, kako kompleksnost podataka raste, performanse modela opadaju, što se ogleda u širim intervalima poverenja i višim vrednostima greške i MSE. Pristup koji koristi klasterovanje omogućava modelu da se prilagodi specifičnim osobinama podataka u svakom klasteru, čime se značajno poboljšava performansa modela. Ovo posebno dolazi do izražaja kod objekata sa izraženim obrascima promenljivosti, gde klasterovanje pruža preciznije i uravnoteženije rezultate. Iako klasterovanje predstavlja značajan korak napred, nekoliko izazova ostaje. Pre svega intenzivne oscilacije kod objekata sa naglim promenama ili izraženim oscilacijama, kao što su 4Cp74 i XSSJ0505, i dalje predstavljaju problem za model. Potrebna su dodatna unapređenja modela, kao što je implementacija prilagodljivih modela koji uzimaju u obzir promene u obrascima ponašanja vremenskih serija (Raju et al, in prep).

Pored vidljivih poboljšanja performansi kroz primenu kasterovanja, analiza rezultata ukazala je na tri ključna izazova u modelovanju svetlosnih krivih AGJ: intenzivne i neregularne oscilacije u fluksu, neravnomernu raspodelu i gustinu posmatračkih tačaka, i ograničenu sposobnost generalizacije modela na veoma različite obrasce variabilnosti.

Intenzivne oscilacije dovode do širenja intervala poverenja i povećanja greške predikcije, naročito u oblastima sa naglim promenama svetlosnog toka. Neravnomerno uzorkovanje dodatno komplikuje zadatak modelovanja, jer standardni pristupi pretpostavljaju relativno uniformnu pokrivenost podataka. Problemi sa generalizacijom modela upućuju na činjenicu da trenirani modeli često uspešno uče dominantne forme u okviru pojedinačnih klastera, ali pokazuju slabiju sposobnost da uzmu u obzir vremensku bliskost ili udaljenost ponašanja svetlosnih krivih van obrazaca na kojima su obučeni.

Ova ograničenja jasno ukazuju na potrebu za unapređenjem metodološkog pristupa kroz implementaciju mehanizama pažnje (attention mechanisms, (Soydaner, 2022)), koji bi omogućili modelima da selektivno fokusiraju predikciju na informativne delove svetlosne krive, kao i kroz uvođenje latentnih prostora reprezentacija, čime bi se omogućila adaptivnija i robusnija karakterizacija složenih obrazaca variabilnosti. Razvoj ovih dodatnih arhitektura predstavlja prirodan pravac za buduća istraživanja u domenu automatizovanog modelovanja svetlosnih krivih aktivnih galaktičkih jezgara. Takođe, objekti sa izraženim rasipanjem, poput NGC2522, zahtevaju dodatne korake u obradi podataka, kao što je filtriranje anomalija. Pored toga, trebalo bi generalizovati model. Iako klasterisanje poboljšava performanse unutar pojedinačnih klastera, potrebno je dodatno istražiti kako rezultati iz jednog klastera mogu doprineti boljem razumevanju i modelovanju sličnih objekata u drugim skupovima podataka. Kratka analiza rezultata uticaja preprocesiranja i klasterizacije na modelovanje, u Prilozima su prikazani grafički rezultati modelovanja za ceo skup i za pojedinačne klastere sa karakterističnim formama promenljivosti.

7. Zaključak i budući rad

Izučavanje promenljivosti AGJ zahteva veliku količinu podataka, pa je ograničeno učestalošću posmatranja i izborom samih objekata (favorizovanje određenih objekata, zbog strategije posmatranja i tehničkih ograničenja instrumenata). Zbog toga rezultati često nisu kompletni, a samim tim je i interpretacija rezultata nepotpuna. Opsežna, učestala i dugoročna posmatranja izvora u različitim spektrima i na većim daljinama bi u budućnosti mogla doprineti boljem razumevanju uzroka promenljivosti, a time i strukture i evolucije ovih objekata. Pored praćenja promenljivosti, spektralna analiza promena bi u velikoj meri doprinela jasnijoj distinkciji mogućih uzroka promenljivosti (posebno kod utvrđivanja AGJ promenljivog tipa).

Metode predstavljene u ovoj tezi omogućavaju kreiranje modela kvazara, koji nam daju dobru predstavu promenljivosti emisije kvazara. Ovim postupkom je omogućeno uočavanje posebnih karakteristika, poput dugotrajnih flerova, koji nastaju kao posledica uticaja gravitacionih sočiva, kao i drugih specifičnih pojava u određenim podskupovima kvazara.

Sa boljim razumevanjem promenljivosti i većim skupom podataka, moguće je razviti programske alate (korišćenjem mašinskog učenja i neuronskih procesa), koji bi mogli da obavljaju automatsko za početak klasterovanje, a kasnije i klasifikaciju objekata, odnosno automatsko izdvajanje potencijalnih AGJ, uočavanje promene (flerove) itd. SOM algoritam za preprocesiranje, selekciju i inicijalnu topološku organizaciju svetlosnih krivih bi se mogao testirati na skupu krivih sjaja čiji podaci su prikupljeni tokom istog perioda i sadrže jednak i broj posmatranja (tačaka), čime bi se umanjio uticaj mapiranja nejednakih krivih sjaja na isti interval, kao i dopuna krivih sjaja, koje nemaju isti broj tačaka, a koje SOM zahteva na ulazu. Na taj način krive sjaja ne bi imale

nikakve promene u strukturi u trenutku klasterovanja. Podaci koje je prikupio ZTF (Zwecky Transient Facility), bi mogli biti dobar izbor za dalje analize, jer imaju ujednačenije krive sjaja, što ih čini dobrim uzorkom za dalje ispitivanje efikasnosti QNPy metode i kreiranje sveobuhvatnije analize, koja bi dalja dublje razumevanje ponašanja i karakteristika krivih sjaja, a samim tim i njihovo dalje teorijsko modelovanje i interpretaciju.

Dopunjavanje krivih sjaja bi se takođe trebalo raditi i na druge načine, na primer interpolacijom, reflektivnim dopunjavanjem¹² ili replikacijom¹³. Odabir broja klastera bi se mogao dalje analizirati, radi nalaženja optimalnih strategija dopunjavanja zavisno od morfologije svetlosnih krivih za različite potrebe proučavanja. Klasterovanje bi se trebalo izvoditi i drugim metodama da bi se utvrdilo koja daje najbolje rezultet klasterovanja i time najviše doprinela unapređenju efikasnosti QNPy procesiranja. Rezultati prikazani u Prilozima potvrđuju da preprocesiranje pomoću klasterizacije može značajno unaprediti modelovanje svetlosnih krivih, naročito kod izvora sa izraženom varijabilnošću.

Nakon toga bi se mogla izvesti i klasifikacija samih AGJ prema uočenim osobinama, koja bi mogla dati jasniju sliku o njihovom nastanku i evoluciji. Poznato je da su karakteristike AGJ povezane sa karakteristikama galaksija u čijim se jezgrima nalaze, pa bi tako detljna analiza različitih AGJ, mogla dovesti do boljeg razumavanja samih galaksija. Dalje integrisanje modela varijabilnosti AGJ sa morfološkim i spektroskopskim karakteristikama matičnih galaksija otvara mogućnosti za kompleksno mapiranje ko-evolucije supermasivnih crnih rupa i njihovih galaktičkih domaćina.

¹² Dopunjavanje podataka refleksijom bi podrazumevalo da se podaci nadovežu na postojeće u suprotnom redosledu, do potrebne dužine krive (kao u ogledalu).

¹³ Dopunjavanje podataka replikacijom bi podrazumevanje nadovezivanje podataka na kraj krive u istom redosledu, do potrebnog broja tačaka (ponavljanje krive, jedan ili više puta uzastopno).

Literatura

- Abadi M., Agarwal A., Barham P., et al. (2016). *TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems*. eprint arXiv:1603.04467.
- Abell A. A., Allison J., Anderson S. F., et al. (2009). *LSST Science Book, Version 2.0*. eprint arXiv:0912.0201.
- Abramowicz, M. A., Calvani, M., Nobili, L. (1980). *Thick accretion disks with super-Eddington luminosities*. *Astrophysical Journal*, 242, 772-788.
- Aller, H. D., Aller, M. F., Latimer, G. E., et al. (1985). *Spectra and linear polarizations of extragalactic variable sources at centimeter wavelengths*. *Astrophysical Journal*, 59, 513-768.
- Aller M. F., Aller H. D., Hughes P. A. (2010). *Radio Band Observations of Blazar Variability*. *Journal of Astrophysics and Astronomy*. 32, 5-11.
- Alvarez E., Cuoco A., Mirabal N., Zaharijas G. (2016). *Searches for correlation between UHECR events and high-energy gamma-ray Fermi-LAT data*. *Journal of Cosmology and Astroparticle Physics*, 12, 023.
- Amaro-Seoane, P., Audley H., Babak S., Baker J., et al. (2017). *Laser Interferometer Space Antenna*. eprint arXiv:1702.00786.
- Amdahl, G.M. (1967). *Validity of the Single Processor Approach to Achieving Large Scale Computing Capabilities*. *Proceedings of the April 18-20, 1967, Spring Joint Computer Conference*.
- Antonucci, R. R. J., Miller, J. S. (1985). *Spectropolarimetry and the nature of NGC 1068*. *Astrophysical Journal*, 297, 621-632.
- Antonucci, R. (1993). *Unified models for active galactic nuclei and quasars*. *Annual Rev. Astron. Astrophys*, 31, 473-521
- Arévalo, P., Uttley, P., Kaspi, S., Breedt, E., Lira, P., McHardy, I. M. (2008). *Correlated X-ray/optical variability in the quasar MR2251-178*. *Monthly Notices of the Royal Astronomical Society*, 389, 1479-1488.
- Arévalo, P. (2009). *Probing the Accretion Disc--Corona Connection in AGN through X-ray and Optical Variability*. *The Starburst-AGN Connection*. *ASP Conference Series*, 408, 296.
- Atanacković, O., Vukićević-Karabin, M. (2010). *Opšta astrofizika*. *Zavod za udžbenike*.
- Baldassare, V., Reines, A. E., Gallo, E., Green, J. E. (2015). *Studying the nuclear morphology of a dwarf galaxy with a 50, 000 solar mass black hole*. *Hubble Space Telescope observing program 14187*.

- Bank, D., Koenigstein, N., Giryes, R. (2021). *Autoencoders*. Published in Deep Learning in Science.
- Begelman, M. C., Blandford, R., Rees, M. (1984). *Theory of extragalactic radio sources*. *Reviews of Modern Physics*, 56, 255.
- Bianco, F., Ivezić, Ž., Jones, L., Graham, M., Marshall, P., Saha, A., et al. (2021). *Optimization of the Observing Cadence for the Rubin Observatory Legacy Survey of Space and Time: a pioneering process of community-focused experimental design*. *The Astrophysical Journal*.
- Bicknell, G. V. (1994). *Extragalactic radio sources and the role of relativistic jets*. *Australian Journal of Physics*, 47, 669-680.
- Biretta, J. A., Moore, R. L., Cohen, M. H. (1986). *The evolution of the compact radio source in 3C 345. I - VLBI observations*. *Astrophysical Journal, Part 1*, 308, 93-109.
- Bonfield, D., Sun, Y., Davey, N., Jarvis, M. J., Abdalla, F., Banerji, M., Adams, R. (2010). *Photometric redshift estimation using Gaussian processes*. *Monthly Notices of the Royal Astronomical Society*.
- Brandt, A. (2015). *Cosmic X-ray Surveys of Distant Active Galaxies: The Demographics, Physics, and Ecology of Growing Supermassive Black Holes*. *The Astronomy and Astrophysics Review*, 23, 1.
- Brandt, W. N., Alexander, D. M. (2015). *Cosmic X-ray surveys of distant active galaxies. The demographics, physics, and ecology of growing supermassive black holes*. *The Astronomy and Astrophysics Review*, 23, 93.
- Brandt, N., Ni, Q., Yang, G., Anderson, S., Assef, R., Barth, A. et al. (2018). *Active Galaxy Science in the LSST Deep-Drilling Fields: Footprints, Cadence Requirements, and Total-Depth Requirements*. *The Astrophysical Journal*.
- Breedt, E., Arévalo, P., McHardy, I. M., Uttley, P., Sergeev, S. G., Minezaki, T., Yoshii, Y., Gaskell, C. M., Cackett, E. M., Horne, K., Koshida, S. (2009). *Long-term optical and X-ray variability of the Seyfert galaxy Markarian 79*. *Monthly Notices of the Royal Astronomical Society*, 394, 1, 427-437.
- Breedt, E., McHardy, I. M., Arévalo, P., Uttley, P., Sergeev, S. G., Minezaki, T., Yoshii, Y., Sakata, Y., Lira, P., Chesnok, N. G. (2010). *Twelve years of X-ray and optical variability in the Seyfert galaxy NGC 4051*. *Monthly Notices of the Royal Astronomical Society*, 403, 2, 605-619.
- Begelman, M. C. (1984). *A Nuclear Regula-Tori Model for Quasars and Seyferts. VLBI and Compact Radio Sources*. Symposium no. 110 held in Bologna, Italy, June 27-July 1, 1983. Edited by R. Fanti, K. Kellermann, and G. Setti. 227.

- Buchs, R., Davis, C., Gruen, D., DeRose, J., Alarcon, A., Bernstein, G. et al. (2019). *Phenotypic redshifts with self-organizing maps: A novel method to characterize redshift distributions of source galaxies for weak lensing*. Monthly Notices of the Royal Astronomical Society.
- Buisson, D. J. K., Lohfink, A. M., Alston, W. N. , Fabian, A. C. (2017). *Ultraviolet and X-ray variability of active galactic nuclei with Swift*. Monthly Notices of the Royal Astronomical Society, 464, 3, 3194-3218.
- Cackett, E., Horne, K.; Winkler, H. (2007). *Testing thermal reprocessing in active galactic nuclei accretion discs*. Monthly Notices of the Royal Astronomical Society, 380, 2, 669-682.
- Cackett, E., Bentz, M., Kara, E. (2021). *Reverberation mapping of active galactic nuclei: from X-ray corona to dusty torus*. iScience, 24, 6, 102-557.
- Calafut, W., Wiita, P. J. (2015). *Modeling the Emission from Turbulent Relativistic Jets in Active Galactic Nuclei*. Journal of Astrophysics and Astronomy, 36, 2, 255-268.
- Camenzind, K., Krockenberger, M. (1992). *The lighthouse effect of relativistic jets in blazars. A geometric origin of intraday variability*. Astronomy and Astrophysics, 255, 59-62.
- Caproni, A. (2004). *Jet precession and its observational evidence: The cases of 3C 345 and 3C 120*. Cambridge University Press, 83-84.
- Caproni, A., Abraham, Z. (2004). *Can long-term periodic variability and jet helicity in 3C 120 be explained by jet precession?* Monthly Notices of the Royal Astronomical Society, 349, 4, 1218-1226.
- Chen, C., Hickox, R. C., Goulding, A. D., Stern, D., Assef, R., Kochanek, C. S., Brown, M. J. I., Harrison, C. M., Hainline, K. N., Alberts, S., Alexander, D. M., Brodwin, M. et al. (2014). *The X-Ray and Mid-infrared Luminosities in Luminous Type 1 Quasars*. The Astrophysical Journal, 837, 2, 145, 12.
- Cho, H., Woo, J., Treu, T., Williams, P. R., Armen, S. F., Barth, A. J., Bennert, V. N., Cho, W., Filippenko, A. V., Gallo, E., Geum, J., et al. (2021). *Ha Reverberation Mapping of the Intermediate-mass Active Galactic Nucleus in NGC 4395*. The Astrophysical Journal, 921, 2, 98, 11
- Čvorović Hajdinjak, I., Kovačević, A. B., Ilić, D., Popović, L. Č., Dai, X., Jankov, I. et al. (2022). *Conditional Neural Process for non-parametric modeling of AGN light curves*. Serbian Astronomical Journal, 208, 17-27.
- Čvorović Hajdinjak, I. (2024). *Modeling Quasar Variability Through Self-Organizing Map-Based Neural Process*. Astronomische Nachrichten.

- Denney, K., Watson, L. C., Peterson, B. M., Pogge, R. W., Atlee, D. W., Bentz, J. C. Bird, M. C., Brokofsky, D. J. et al. (2009). *A Revised Broad-line Region Radius and Black Hole Mass for the Narrow-line Seyfert 1 NGC 4051*. The Astrophysical Journal, 702, 2, 1353-1366.
- de Vries, W. H., Becker, R. H., White, R. L., Loomis C. (2005). *Structure Function Analysis of Long-Term Quasar Variability*. The Astronomical Journal, 129, 2, 615-629.
- Done, C. (2010). *Observational characteristics of accretion onto black holes*. Cambridge University Press, 184 - 226.
- D'Orazio, D. et al. (2017). *Lighthouse in the dust: infrared echoes of periodic emission from massive black hole binaries*★. Monthly Notices of the Royal Astronomical Society, 470, 1, 1198-1217.
- D'Orazio, D., Charisi, M. (2023). *Observational Signatures of Supermassive Black Hole Binaries*. e-Print: 2310.16896
- Dullemond, C. P., van Bemmell, I. M. (2005). *Clumpy tori around active galactic nuclei*. Astronomy and Astrophysics, 436, 1, 47-56.
- Edelson, R., Gelbord, J. M., Horne, K., McHardy, I. M., Peterson, B. M., Arévalo, P., Breeveld, A. A., De Rosa, G., Evans, P. A., Goad, M. R. et al. (2015). *Space Telescope and Optical Reverberation Mapping Project. II. Swift and HST Reverberation Mapping of the Accretion Disk of NGC 5548*. The Astrophysical Journal, 806, 1, 129, 14.
- Einstein, A. (1915). *On the General Theory of Relativity*. Sitzungsber. Preuss. Akad. Wiss. Berlin (Math. Phys.), 778-786.
- Enya, K., Yoshii, Y., Kobayashi, Y., Minezaki, T., Suganuma, M., Tomita, H., Peterson, B. A. (2002). *JHK' Imaging Photometry of Seyfert 1 Active Galactic Nuclei and Quasars. III. Variability of Radio-Quiet and Radio-Loud Active Galactic Nuclei*. The Astrophysical Journal Supplement Series, 141, 1, 45-59.
- Elvis, M. (1994). *Atlas of Quasar Energy Distributions*. Astrophysical Journal Supplement, 95, 1.
- Elityur, M., Sholsman, I. (2006). *The AGN-obscuring Torus: The End of the "Doughnut" Paradigm?* The Astrophysical Journal, 648, 2, L101-L104.
- Elvis, M. (2000). *Adolescent Black Holes may be Hard to Find*. American Astronomical Society meeting #235, id. 304.23. Bulletin of the American Astronomical Society, 52, 1.
- Eyer, L. (2002). *Search for QSO Candidates in OGLE-II Data*. Acta Astronomica, 52, 241-262.

- Fabian, A. C., Brandt, W. N., McMahon, R. G., Hook, I. M. (1997). *The extreme X-ray luminosity of the $z=4.72$ radio-loud quasar GB 1428+4217*. Monthly Notices of the Royal Astronomical Society.
- Fabian, A. C. (2006). *X-ray Reflections on AGN*. Proceedings of the The X-ray Universe 2005 (ESA SP-604), 463.
- Fanaroff, B. L, Riley, J. M. (1974). *The morphology of extragalactic radio sources of high and low luminosity*. Monthly Notices of the Royal Astronomical Society, 167, 31P-36P.
- Fagin, J., Park, J. W., Best, H., Hung-Hsu Chan, J., Ford, K. E., Graham, M. J., et al. (2023). *Latent Stochastic Differential Equations for Modeling Quasar Variability and Inferring Black Hole Properties*. The Astrophysical Journal, 965, 2
- Feltre, A., Hatziminaoglou, E., Fritz, J., Franceschini, A. (2012). *Smooth and clumpy dust distributions in AGN: a direct comparison of two commonly explored infrared emission models*. Monthly Notices of the Royal Astronomical Society, 426, 1, 120-127.
- Fritz, J., Franceschini, A., Hatziminaoglou, E. (2006). *Revisiting the infrared spectra of active galactic nuclei with a new torus emission model*. Monthly Notices of the Royal Astronomical Society, 366, 3, 767-786.
- Gandhi, P., Horst, H., Smette, A., Höning, S. F., Comastri, A., Gilli, R., Vignali, C., Duschl, W. J. (2010). *Resolved mid-infrared imaging of AGN: an isotropic measure of intrinsic power*. Proceedings of the International Conference. AIP Conference Proceedings, 1248, 431-432.
- Gang, L. (2023). *Clustering with Neural Network and Index*. Tsinghua University
- Garnelo, M., Rodenbaum, D., Maddison, C. J. et al. (2018), *Conditional Neural Processes*. In International Conference on Machine Learning 2018.
- Geha, M., Alcock, C., Allsman, R. A., Alves, D. R., Axelrod, T. S., Becker, A. C. et al. (2003). *Variability-selected Quasars in MACHO Project Magellanic Cloud Fields*. The Astronomical Journal, 125, 1, 1-12.
- Giacconi, R. (2009). *History of X-ray telescopes and astronomy*. *Experimental Astronomy*, 25, 1-3, 143-156.
- Giannios, D., Uzdensky, D. A., Begelman, M. C. (2009). *Fast TeV variability in blazars: jets in a jet*. Monthly Notices of the Royal Astronomical Society: Letters, 395, 1, L29-L33.
- Gilfano, M., Merloni, A. (2014). *Observational Appearance of Black Holes in X-Ray Binaries and AGN*. Space Science Reviews, 183, 1-4, 121-148.

- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B. et al. (2020). *Generative adversarial networks*. 63, 139–144
- Goodrich, R. (1989). *Spectropolarimetry and Variability of Seyfert 1.8 and 1.9 Galaxies*. *Astrophysical Journal*, 340, 190.
- Gopal-Krishna, W., Paul J. (1992). *Swinging jets and the variability of active nuclei*. *Astronomy and Astrophysics*, 259, 109-117.
- Gopal-Krishna, Wiita, P. J. (2000). *Extragalactic radio sources with hybrid morphology: implications for the Fanaroff-Riley dichotomy*. *Astronomy and Astrophysics*, 363, 507-516.
- Gopal-Krishna, Wiita, P. J. (2001). *Was the Cosmic Web of Protogalactic Material Permeated by Lobes of Radio Galaxies During the Quasar Era?* *The Astrophysical Journal*, 560, 2, L115-L118.
- Graham, M. et al. (2015). *Quasars in the Time Domain: Supermassive Black Hole Binaries and Extreme Objects*. American Astronomical Society, AAS Meeting #227, id.243.40.
- Graham, M, et al. (2016). *Beyond statistical descriptions of variability*. *American Astronomical Society*, AAS Meeting #227, id.310.01.
- Hartman, R. C. et al. (1991). *High Energy Gamma Radiation from Quasar 3C279 Detected by the EGRET Telescope on the Compton Gamma-Ray Observatory*. *Bulletin of the American Astronomical Society*, 23, 1344.
- Hatziminaoglou, E. et al. (2015). *VizieR Online Data Catalog: SWIRE/SDSS quasars. II. Type 2 AGN (Hatziminaoglou+, 2009)*. *VizieR On-line Data Catalog: J/ Monthly Notices of the Royal Astronomical Society /399/1206*. Originally published in: 2009MNRAS.399.1206H.
- Hawkins, M. R. S. (1993). *Gravitational microlensing, quasar variability and missing matter*. *Nature*, 366, 6452, 242-245.
- Hawkins, M. R. S. (2010). *On time dilation in quasar light curves*. *Monthly Notices of the Royal Astronomical Society*, 405, 3, 1940-1946.
- Heckman, T., Best, P. (2014). *The Coevolution of Galaxies and Supermassive Black Holes: Insights from Surveys of the Contemporary Universe*. *Annual Review of Astronomy and Astrophysics*, 52.
- Hemmati, S., Capak, P., Masters, D., Davidzon, I., Dore, O., Kruk, J. et al. (2019). *Photometric Redshift Calibration Requirements for WFIRST Weak Lensing Cosmology: Predictions from CANDELS*. *The Astrophysical Journal*.
- Hernan-Caballero, A. et al. (2016). *The near-to-mid infrared spectrum of quasars*. *Monthly Notices of the Royal Astronomical Society*, 463, 2, 2064-2078.

- Hickox, R. et al. (2009). *Host Galaxies, Clustering, Eddington Ratios, and Evolution of Radio, X-Ray, and Infrared-Selected AGNs*. *The Astrophysical Journal*, 696, 1, 891-919.
- Holoien, T. W.-S., Brown, J. S., Vallety, P. J., Stanek, K. Z., Kochanek, C. S., Shappee, B. J. et al. (2019). *The ASAS-SN bright supernova catalogue – IV. 2017*. *Monthly Notices of the Royal Astronomical Society*.
- Hughes, P. A. et al. (1985). *The Shocking Events in 3C 279*. *Bulletin of the American Astronomical Society*, 17, 889.
- Hughes, P. A. et al. (1991). *Synchrotron Emission from Shocked Relativistic Jets. III. Models for the Centimeter Wave Band Quiescent and Burst Emission from 3C 279 and OT 081*. *Astrophysical Journal*, 374, 57.
- Ishibashi, W., Courvoisier, T. J. (2009). *AGN UV and X-ray luminosities in clumpy accretion flows*. *Astronomy and Astrophysics*, 495, 1, 113-120.
- Ivezić, Ž., Kahn, S. M., Tyson, J. A., Abel, B., Acosta, E., Allsman, R., et al. (2019). *LSST: From Science Drivers to Reference Design and Anticipated Data Products*. *The Astrophysical Journal*.
- Iwasawa, K., Miniutti, G., Fabian, A. C. (2004). *Modulations of the redshifted Fe K emission in AGN and the implied black hole mass*. *American Astronomical Society, HEAD meeting #8, id.26.08*; *Bulletin of the American Astronomical Society*, 36, 960.
- Jankov, I., Kovačević, A., Ilić, D., Popović, L., Radović, V. et al. (2021). *Photoreverberation mapping of quasars in the context of LSST observing strategies*. *Astronomischen Nachrichten*.
- Jenness, T. et al. (2010). *Observations of flat-spectrum radio sources at $\lambda 850\mu\text{m}$ from the James Clerk Maxwell Telescope II. April 2000 to June 2005*. *Monthly Notices of the Royal Astronomical Society*, 401, 2, 1240-1254.
- Jiang, L. et al. (2007). *Evolution of Quasar Population at $z \approx 6$* . *American Astronomical Society, AAS Meeting #211, id.45.23*; *Bulletin of the American Astronomical Society*, 39, 799.
- Jovanovic, P., Popovic, L. C. (2009). *Central Engine of Active Galaxies as the Most Powerful Source of X-Ray Radiation in the Universe*. *Publications of the Astronomical Observatory of Belgrade*, 86, 153-160.
- Kapinska, A. D. et al. (2017). *Radio Galaxy Zoo: A Search for Hybrid Morphology Radio Galaxies*. *The Astronomical Journal*, 154, 6, 253.
- Karbowski, A. (2015). *Decomposition and Parallelization of Linear Programming Algorithms*. In: Szewczyk, R., Zieliński, C., Kaliczyńska, M. (eds) *Progress in*

- Automation, Robotics and Measuring Techniques. ICA 2015. Advances in Intelligent Systems and Computing*, 350. Springer, Cham.
- Kawaguchi, T. et al. (1998). *Optical Variability in AGNs and Disk Instability or Starbursts? The Hot Universe*. Proceedings of IAU Symposium #188. Edited by Katsuji Koyama, Shunji Kitamoto, Masayuki Itoh. Dordrecht: Kluwer Academic, 451.
- Kawakatu, N. et al. (2009). *Exploring the Disk-Jet Connection from the Properties of Narrow-Line Regions in Powerful YoVng Radio-Loud Active Galactic Nuclei*. The Astrophysical Journal, 693, 2, 1686-1695.
- Kelly, B. C., Bechtold, J., & Siemiginowska, A. (2009). *Are the Variations in Quasar Optical Flux Driven by Thermal Fluctuations?* The Astrophysical Journal.
- Kelly, B. et al. (2011). *A Stochastic Model for the Luminosity Fluctuations of Accreting Black Holes*. The Astrophysical Journal, 730, 1, 52, 20.
- Khachikyan, É. Ya., Weedman, D. W. (1971). A spectroscopic study of luminous galactic nuclei. *Astrophysics*, Vol. 7, Issue 3, p. 231-240.
- Kim, H., Mnih, A., Schwarz, J., Garnelo, M., et al. (2019). *Attentive neural processes*. In the 7th International Conference on Learning Representations, ICLR 2019, New Orleans, LA, USA, May 6-9, 2019. OpenReview.net, URL: <https://openreview.net/forum?id=SkE6PjC9KX>.
- King, A. R. et al. (2004). *Variability in black hole accretion discs*. Monthly Notices of the Royal Astronomical Society, 348, 1, 111-122.
- Kingma, D., Ba, J. (2017), Adam: A Method for Stochastic Optimization.
- Kochanek, C., Shappee, B., Stanek, K., Holoien, T., Thompson, T. A., Prieto, J. et al. (2017). *The All-Sky Automated Survey for Supernovae (ASAS-SN) Light Curve Server v1.0*. Publications of the Astronomical Society of the Pacific.
- Kohonen, T. (1990). *The self-organizing map*. Proceedings of the IEEE.
- Kohonen, T. (2013). *Essentials of the self-organizing map*. Neural Networks.
- Kohonen, T. (2014). *MATLAB Implementations and Applications of the Self-Organizing Map*. Unigrafia Oy.
- Kovačević, A. et al. (2021). *On possible proxies of AGN light-curves cadence selection in future time domain surveys*. Monthly Notices of the Royal Astronomical Society, 505, 4, 5012-5028.
- Kovačević, A. B., Ilić, D., Popović, L. Č., Andrić Mitrović, N., Nikolić, M., Pavlović, M. S. et al. (2023). *Deep Learning of Quasar Lightcurves in the LSST Era*. Universe.

- Kovačević, A. B., Popović, L. Č., Simić, S., Ilić, D. (2019). *The Optical Variability of Supermassive Black Hole Binary Candidate PG 1302-102: Periodicity and Perturbation in the Light Curve*. The Astrophysical Journal.
- Kozłowski, S. (2010). *Quantifying Quasar Variability as Part of a General Approach to Classifying Continuously Varying Sources*. The Astrophysical Journal, 708, 2, 927-945.
- Kozłowski, S. (2017). *A Method to Measure the Unbiased Decorrelation Timescale of the AGN Variable Signal from Structure Functions*. The Astrophysical Journal.
- Krolik, J., Begelman, M. (1988). *Molecular Tori in Seyfert Galaxies: Feeding the Monster and Hiding It*. Astrophysical Journal, 32, 9, 702.
- Krolik, J. (1999). *Active galactic nuclei: from the central black hole to the galactic environment*. Princeton University Press.
- LaMassa, S., Cales, S., Moran, E., Myers, A., Richards, G., Eracleous, M. et al. (2015). *The Discovery of the First "Changing Look" Quasar*. The Astrophysical Journal.
- Lauberts, A. et al. (1989). *The surface photometry catalogue of the ESO-Uppsala galaxies*. Garching: European Southern Observatory.
- Lawrence, A. (1987). *Classification of active galaxies and the prospect of a unified phenomenology*. Publications of the Astronomical Society of the Pacific, 99, 309-334.
- Lawrence, A. et al. (2018). *Quasar viscosity crisis*. Nature Astronomy, 2, 102-103.
- Le, T. A., Kim, H., Garnelo, M., et al. (2018). *Empirical evaluation of neural process objectives*. In NeurIPS workshop on Bayesian Deep Learning.
- Lee, H. (2009). *Spectropolarimetry and Unification of Active Galactic Nuclei*. BLACK HOLE ASTROPHYSICS 2002. Proceedings of the Sixth APCTP Winter School. Edited by Hyun Kyu Lee (Hanyang University, Korea) & Myeong-Gu Park (Kyungpook National University, Korea). Published by World Scientific Publishing Co. Pt. Ltd., 2002. ISBN #9789812776761, 271-287.
- Lehmer, B. D. et al. (2012). *The 4 Ms Chandra Deep Field-South Number Counts Apportioned by Source Class: Pervasive Active Galactic Nuclei and the Ascent of Normal Galaxies*. The Astrophysical Journal, 752, 1, 46, 23.
- Lira, P. et al. (2011). *Optical and near-IR long-term monitoring of NGC 3783 and MR 2251-178: evidence for variable near-IR emission from thin accretion discs*. Monthly Notices of the Royal Astronomical Society, 415, 2, 1290-1303.

- Lira, P. et al. (2015). *Long-term monitoring of the archetype Seyfert galaxy MCG-6-30-15: X-ray, optical and near-IR variability of the corona, disc and torus*. *Monthly Notices of the Royal Astronomical Society*, 454, 1, 368-379.
- Lister, M. L. (2001). *Relativistic Beaming and Flux Variability in Active Galactic Nuclei*. *The Astrophysical Journal*, 561, 2, 676-683.
- Lister, M. L. et al. (2009). *MOJAVE: Monitoring of Jets in Active Galactic Nuclei with VLBA Experiments. VI. Kinematics Analysis of a Complete Sample of Blazar Jets*. *The Astronomical Journal*, 138, 6, 1874-1892.
- Lister, M. L. et al. (2013). *MOJAVE. X. Parsec-scale Jet Orientation Variations and Superluminal Motion in Active Galactic Nuclei*. *The Astronomical Journal*, 146, 5, 120, 22.
- Lusso, E., Risaliti, G. (2016). *The Tight Relation between X-Ray and Ultraviolet Luminosity of Quasars*. *The Astrophysical Journal*, 819, 2, 154, 10.
- Lyu, J., Rieke, G. H. (2022). *Polar Dust Emission in Quasar IR SEDs and Its Correlation with Narrow-line Regions*. *The Astrophysical Journal Letters*, 940, Issue 2, L31, 7.
- MacLeod, C. L. et al. (2010). *Modeling the Time Variability of SDSS Stripe 82 Quasars as a Damped Random Walk*. *Astrophysical Journal*, 721, 1014-1033.
- Manne-Nicholas, E., Batiste, M., Valluri, M., Bentz, M. C., Onken, C. A., Ferrarese, L. (2013). *A Stellar Dynamical Black Hole Mass for the Reverberation-Mapped Active Galaxy NGC6814*. *American Astronomical Society, AAS Meeting #227*, 104.08
- Maraschi, L., Celotti, A., Ghisellini, G. (1992). *Wide Jets and the X-Ray and Radio Properties of Bl-Lacertae Objects*. *Physics of Active Galactic Nuclei. Proceedings of the International Conference, held in Heidelberg, Germany, June 3-7, 1991*. Editors, W.J. Duschl, S.J. Wagner, Publisher, Springer-Verlag, Berlin, Germany; New York, NY, 1992. ISBN # 3-540-55554-4. LC # QB858.3. 49, 05.
- Markowitz, A. et al (2003). *Long-Term X-Ray Spectral Variability in Seyfert 1 Galaxies*. *The Astrophysical Journal*, 598, 2, 935-955.
- Marscher, A. et al. (1985). *Multifrequency radio VLBI observations of the superluminal, low-frequency variable quasar NRAO 140*. *Astrophysical Journal*, 290, 735-741.
- Marscher, A. (2008). *The Core of a Blazar Jet. Extragalactic Jets: Theory and Observation from Radio to Gamma Ray ASP Conference Series*. *Astronomical Society of the Pacific*, 437.

- Marscher, A. et al. (2010). *Comprehensive Multi-waveband Monitoring of Gamma-ray Blazars*. American Astronomical Society, HEAD meeting #11, id.33.23; Bulletin of the American Astronomical Society, 41, 709.
- Marscher, A. et al. (2014). *Time-variable Linear Polarization as a Probe of the Compact Jets of Blazars*. American Astronomical Society, AAS Meeting #224, id.221.19.
- Marshall, K. et al. (2009). *Multiwavelength Variability of the Broad Line Radio Galaxy 3C 120*. The Astrophysical Journal, 696, 1, 601-607.
- Massaglia, S. (2003). *Constraining the Parameters of AGN Jets*. Astrophysics and Space Science, 287, 223-233.
- Massaglia, S. et al. (2016). *Making Faranoff-Riley I radio sources. I. Numerical hydrodynamic 3D simulations of low-power jets*. Astronomy & Astrophysics. 596, A12, 10.
- McHardy, I. (2001). *Long Time-Scale X-Ray Variability of AGN. Probing the Physics of Active Galactic Nuclei*, ASP Conference Proceedings, 224.
- McHardy, I. et al. (2004). *Combined long and short time-scale X-ray variability of NGC 4051 with RXTE and XMM-Newton*. Monthly Notices of the Royal Astronomical Society, 348, 3, 783-801.
- McHardy, I. (2014). *Swift monitoring of NGC 5548: X-ray reprocessing and short-term UV/optical variability*. Monthly Notices of the Royal Astronomical Society, 444, 2, 1469-1474.
- McHardy, I. (2016). *The origin of UV-optical variability in AGN and its relationship to X-ray variability*. XMM-Newton: The Next Decade, Proceedings of the Conference held 9-11 May, 2016 at ESAC, Madrid.
- Mishra, Sapna, Gopal-Krishna, Chand, Hum, et al. (2021). *A search for blazar activity in broad-absorption-line quasars*. Monthly Notices of the Royal Astronomical Society.
- Muskotzky, R. et al. (1993). *X-ray spectra and time variability of active galactic nuclei*. Annual Rev. Astron. Astrophys., 3, 717-717.
- Nenkova, M., Ivezić, Ž. et al. (2002). *Dust Emission from Active Galactic Nuclei*. The Astrophysical Journal, 570, 1, L9-L12.
- Nenkova, M. et al (2008). *AGN Dusty Tori. II. Observational Implications of Clumpiness*. The Astrophysical Journal, 685, 1, 16-180.
- Netzer, H. (2015). *Revisiting the Unified Model of Active Galactic Nuclei*. Annual Review of Astronomy and Astrophysics. 53.
- Neugebauer, G. et al. (1989). *The Near-Infrared Variability of a Sample of Optically Selected Quasars*. Astronomical Journal 97, 957.

- Ng, A., Jordan, M., Weiss, Y. (2001). *On Spectral Clustering: Analysis and an algorithm*. Advances in neural information processing systems, 849--856. MIT Press.
- Nikolić, M., Zečević, A. (2019). *Mašinsko učenje*. Beograd: Matematički fakultet
- Nikutta, R. et al. (2009). *On the 10 μm Silicate Feature in Active Galactic Nuclei*. The Astrophysical Journal, 707, 2, 1550-1559.
- Ordovás-Pascual, I., & Sánchez Almeida, J. (2014). *A fast version of the k-means classification algorithm for astronomical applications*. Astronomy and Astrophysics.
- Osterbrock, D. et al. (1989). *Active galactic nuclei*. (NASA, NSF, Texas Academy of Science, Texas Symposium on Relativistic Astrophysics, 14th, Dallas, TX, Dec. 11-16, 1988) New York Academy of Sciences, Annals (ISSN 0077-8923), 571, 1989, 99-109.
- Padovani, P. et al. (2011). *The VLA Survey of Chandra Deep Field South. V. Evolution and Luminosity Functions of Sub-millijansky Radio Sources and the Issue of Radio Emission in Radio-quiet Active Galactic Nuclei*. The Astrophysical Journal, Vol. 740, Issue 1, article id. 20, p. 18.
- Padovani, P. (2016). *Report on the ESO Workshop "Active Galactic Nuclei: what's in a name?"* The Messenger, 165, 44-44.
- Padovani, P. et al. (2017). *Active galactic nuclei: what's in a name?* The Astronomy and Astrophysics Review, 25, 1, 2, 91.
- Page, M. et al. (2014). *X-rays from the redshift 7.1 quasar ULAS J1120+0641*. Monthly Notices of the Royal Astronomical Society.
- Panessa, F., Bassani, L. (2002). *Unabsorbed Seyfert 2 galaxies*. Astronomy and Astrophysics, 394, 435-442.
- Papadakis, E. (2004). *The scaling of the X-ray variability with black hole mass in active galactic nuclei*. Monthly Notices of the Royal Astronomical Society, 348, 1, 207-213.
- Pavlović, M., Raju, A., Kovačević, A., Ilić, D., Čvorović Hajdinjak, I., Nikolić, M. et al. (2024). *Upgrading QNPY: modeling quasar light curves in large surveys*. AOB, 1-40.
- Penston, M. V., Perez, E. (1984). *An evolutionary link between Seyfert I and II galaxies*. Monthly Notices of the Royal Astronomical Society, 211, 33P-39P.
- Peterson, B. (1997). *An Introduction to Active Galactic Nuclei*. An introduction to active galactic nuclei, Publisher: Cambridge, New York Cambridge University Press, Physical description xvi, 238 p. ISBN 0521473489.

- Peterson, B. et al. (1998). *Optical Continuum and Emission-Line Variability of Seyfert 1 Galaxies*. The Astrophysical Journal, 501, 1, 82-93.
- Peterson, B. (2004). *Central Masses and Broad-Line Region Sizes of Active Galactic Nuclei. II. A Homogeneous Analysis of a Large Reverberation-Mapping Database*. The Astrophysical Journal, 613, 2, 682-699.
- Peterson, B. (2006). *The Broad-Line Region in Active Galactic Nuclei*. *Physics of Active Galactic Nuclei at all Scales*, edited by Danielle Alloin, Rachel Johnson and Paulina Lira. Lecture Notes in Physics, 693. ISBN-10 3-540-31207-2; ISBN-13 978-3-540-31207-9; ISSN 0075-8450. Library of Congress Catalog Card No. 2006925838. Published by Springer, Berlin and Heidelberg,.77.
- Pier, E. A. Krolik, J. H. (1992). *Radiation-Pressure--supported Obscuring Tori around Active Galactic Nuclei*. Astrophysical Journal Letters 399, L23.
- Pinner, B. G. et al. (2003). *Relativistic Jet Speeds from the Radio Reference Frame Image Database: The 60 Best-Observed Sources*. American Astronomical Society Meeting 203, id.92.07; Bulletin of the American Astronomical Society, 35, 1355.
- Popović, L., Chavushyan, V. H., Ilić D. et al. (2012). *Long-term optical spectral monitoring of Seyfert 1 galaxies: variability in the broad line region*. 39th COSPAR Scientific Assembly. Held 14-22 July 2012, in Mysore, India. Abstract PSB.1-10-12, 1521.
- Popović, L., Ilić, D. (2017). *Aktivna galaktička jezgra*. Matematički fakultet.
- Pushkarev, A. et al. (2009). *Jet opening angles and gamma-ray brightness of AGN*. Astronomy and Astrophysics, 507, 2, 2009, L33-L36.
- Qian, Y. et al. (2018). *Discovery of 21 New Changing-look AGNs in the Northern Sky*. The Astrophysical Journal, 862 109.
- Raju, A. et al. (in prep). *Metalearning Framework for Multitask Reverberation Mapping in Active Galactic Nuclei*.
- Rees, M. J., Kashlinsky, A. (1982). *Galaxy formation, clustering and the 'hidden mass'*. Proceedings of the Oxford International Symposium, Oxford, England, September 14-18, 1981. (A82-47830 24-90) Dordrecht, D. Reidel Publishing Co., 1982, 259-273.
- Rees, Martin J. (1984). *Black Hole Models for Active Galactic Nuclei*. Annual review of astronomy and astrophysics, 22. Palo Alto, CA, Annual Reviews, Inc., 471-506.
- Rejeb, S., Duveau, C., & Rebafka, T. (2022). *Self-organizing maps for exploration of partially observed data and imputation of missing values*. Chemometrics and Intelligent Laboratory Systems.

- Remillard, R., McClintock, J. (2006). *Active X-ray States of Black Hole Binaries: Current Overview*. Bulletin of the American Astronomical Society, 38, 903.
- Rengstrof, A. W. et al. (2004). *New Quasars Detected via Variability in the QUEST1 Survey*. The Astrophysical Journal, 606, 2, 741-748.
- Richards, G. T., Lacy, M., Storrie-Lombardi, L. J., Hall, P. B., Gallagher, S. C., Hines, D. C. et al. (2006). *Spectral Energy Distributions and Multiwavelength Selection of Type 1 Quasars*. The Astrophysical Journal Supplement Series.
- Richards, J. L. (2014). *VizieR Online Data Catalog: 15GHz variability of γ -ray blazars*. VizieR On-line Data Catalog: J/MNRAS/438/3058. Originally published in: 2014MNRAS.438.3058R.
- Rieke, G. (1978). *Infrared Emission of the Galactic Center and Extragalactic Sources*. Infrared Astronomy, Proceedings of a NATO Advanced Study Institute, held at Erice, Sicily, July 9-20, 1977, Dordrecht: Reidel, 1978, edited by Giancarlo Setti and Giovanni G. Fazio. NATO Advanced Study Institute (ASI) Series C, 38, 159.
- Sajina, A. et al. (2022). *The Past and Future of Mid-Infrared Studies of AGN*. Universe, 8(7), 356.
- Sánchez-Sáez, P., Lira, H., Martí, L., Sánchez-Pi, N., Arredondo, J., Bauer, F. E. et al. (2021). *Searching for Changing-state AGNs in Massive Data Sets. I. Applying Deep Learning and Anomaly-detection Techniques to Find AGNs with Anomalous Variability Behaviors*. The Astronomical Journal.
- Sánchez-Sáez, P., Lira, P., Mejía-Restrepo, J., Ho, L. C., Arévalo, P., Kim, M. et al. (2018). *The QUEST-La Silla AGN Variability Survey: Connection between AGN Variability and Black Hole Physical Properties*. The Astrophysical Journal.
- Sánchez-Sáez, P. et al. (2021). *Searching for Changing-state AGNs in Massive Data Sets. I. Applying Deep Learning and Anomaly-detection Techniques to Find AGNs with Anomalous Variability Behaviors*. The Astronomical Journal, 162, 5, 206, 16.
- Sergeyev, A. (2005). *Photometric monitoring of SBS 1520+530: long-term variability and microlensing*.
- Shang, Z., Brotherton, M. S., Wills, B. J., Wills, D., Cales, S. L., Dale, D. A. et al. (2011). *The next generation atlas of quasar spectral energy distributions from radio to X-rays*. The Astrophysical Journal Supplement Series.
- Shapovalova, A. I., Popović, L. Č., Chavushyan, V. H., Afanasiev, V. L., Ilić, D., Kovačević, A. et al. (2017). *Long-term optical spectral monitoring of NGC 7469*. Monthly Notices of the Royal Astronomical Society.

- Shapovalova, A., Popović, L. Č., Afanasiev, L., Ilić, D., Kovačević, A., Burenkov, N. et al. (2019). *Long-term optical spectral monitoring of a changing-look active galactic nucleus NGC 3516 – I. Continuum and broad-line flux variability*. Monthly Notices of the Royal Astronomical Society.
- Shappee, B., Prieto, J., Grupe, D., Kochanek, C., Stanek, K., De Rosa, G. et al. (2017). *The All-Sky Automated Survey for Supernovae (ASAS-SN) Light Curve Server v1.0*. Publications of the Astronomical Society of the Pacific, 129, 980.
- Shakura, N. I., Sunyaev, R. A. (1973). *Black holes in binary systems. Observational appearance*. Astronomy and Astrophysics, 24, 337 - 355.
- Sheng, Z. et al. (2017). *Mid-infrared Variability of Changing-look AGNs*. The Astrophysical Journal Letters, 846:L7, 7.
- Silva, L. et al. (1998). *Modeling the Effects of Dust on Galactic Spectral Energy Distributions from the Ultraviolet to the Millimeter Band*. The Astrophysical Journal, 509, 1, 103-117.
- Simm, T. et al. (2016). *PSD analysis of optical QSO light curves. Active Galactic Nuclei: what's in a name?* Proceedings of a conference held 27 June - 1 July, 2016 in Garching, id.21.
- Sobolewska, A. (2004). *High-Redshift Radio-quiet Quasars: Exploring the Parameter Space of Accretion Models. I and II. Patchy Corona Model*. The Astrophysical Journal, 617, 1, 102-112.
- Sore, S. et al. (1994). *A Model for the Spectroscopic Variations of the Peculiar Symbiotic Star MWC 560*. Astronomical Journal, 108, 671.
- Soydaner, D. (2022). *Attention mechanism in neural networks: where it comes and where it goes*. Neural Computing and Applications. 34, 16.
- Stalevski, M., Jovanović, P., Popović, L. Č., et al. (2012). *Gravitational microlensing of active galactic nuclei dusty tori*. Monthly Notices of the Royal Astronomical Society, 425, 2, 1576-1584.
- Stalevski, M., Ricci, Cl., Ueda, Y., et al. (2016). *The dust covering factor in active galactic nuclei*. Monthly Notices of the Royal Astronomical Society, 458, 3, 2288-2302.
- Steffen, A. T., Strateva, I., Brandt, W. N. (2006). *The X-Ray-to-Optical Properties of Optically Selected Active Galaxies over Wide Luminosity and Redshift Ranges*. The Astronomical Journal, 131, 6, 2826-2842.
- Suganuma, M. et al. (2006). *Reverberation Measurements of the Inner Radius of the Dust Torus in Nearby Seyfert 1 Galaxies*. The Astrophysical Journal, 639, 1, 46-63.

- Tachibana, Y., Graham, M. J., Kawai, N., Djorgovski, S. G., Drake, A. J., Mahabal, A. A., & Stern, D. (2020). *Deep Modeling of Quasar Variability*. *The Astrophysical Journal*.
- Takeuchi, M. et al. (1995). *X-Ray Fluctuations from Black-Hole Objects and Self Organization of Accretion Disks*. *Publications of the Astronomical Society of Japan*, 47, 617-627.
- Tavani, M. et al. (2017). *LIGO/Virgo G275404: AGILE-GRID detection of a possible gamma-ray transient*. *GRB Coordinates Network, Circular Service*, No. 20754.
- Tristram, K. R. W. (2007). *Mid-infrared interferometry of nearby Active Galactic Nuclei*. PhD Thesis, Combined Faculties for the Natural Sciences and for Mathematics of the Ruperto-Carola University of Heidelberg, Germany, for the degree of Doctor of Natural Sciences.
- Tóth, B. G., Rácz, I. I., & Horváth, I. (2019). *Gaussian-mixture-model-based cluster analysis of gamma-ray bursts in the BATSE catalog*. *Monthly Notices of the Royal Astronomical Society*.
- Troyer, J. et al. (2016). *Correlated X-ray/ultraviolet/optical variability in NGC 6814*. *Monthly Notices of the Royal Astronomical Society*, 456, 4, 4040-4050.
- Tueller, J., Mushotzky, R. F., Barthelmy, S., Cannizzo, J. K., Gehrels, N., Markwardt, C. B. et al. (2008). *SwiftBAT Survey of AGNs*. *The Astrophysical Journal*.
- Ulrich, M. H., Maraschi, L., Urry, C. (2003). *Variability of active galactic nuclei*. *Annual Review of Astronomy and Astrophysics*.
- Ulrich, M. H. et al. (1997). *Variability of Active Galactic Nuclei*. *Annual Review of Astronomy and Astrophysics*, 35, 1997, 445-502.
- Urry, P. (1995). *Unified Schemes for Radio-Loud Active Galactic Nuclei*. *Publications of the Astronomical Society of the Pacific*, 107, 803.
- Uttley, P. et al. (2003). *Correlated Long-Term Optical and X-Ray Variations in NGC 5548*. *The Astrophysical Journal*, 584, 2, L53-L56.
- Uttley, F, McHardz I. (2005). *X-ray variability of NGC 3227 and 5506 and the nature of active galactic nucleus 'states'*. *Monthly Notices of the Royal Astronomical Society*, 363, 2, 586-596.
- Vaddi, S. et al. (2022). *Star formation and AGN activity in galaxy groups*. *American Astronomical Society Meeting #240*, id. 224.07. *Bulletin of the American Astronomical Society*, Vol. 54, No. 6 e-id 2022n6i224p07.

- Vander Berk, D. et al. (2004). *Photometric and Spectroscopic Variability of Quasars*. American Astronomical Society Meeting 205, id.120.02; Bulletin of the American Astronomical Society, 36, 1548.
- van der Laan, H. (1966). *A Model for Variable Extragalactic Radio Sources*. Nature, 211, 5054, 1131-1133.
- Vazquez, B. (2015). *Constraining the size of the dusty torus in Active Galactic Nuclei: An Optical/Infrared Reverberation Lag Study*. Thesis (Ph.D.) Rochester Institute of Technology, 2015. Publication Number: AAT 3742694; ISBN: 9781339352794; Source: Dissertation Abstracts International, Vol.: 77-05(E), section: B. p. 199.
- Wagner, S. J., & Witzel, A. (1995). *Intraday Variability In Quasars and BL Lac Objects*. Annual Review of Astronomy and Astrophysics, 33, 1995, 163-198.
- Wang, J. M., Songsheng, Y., Li, Y. R., Du, P., Zhang, Z. X. (2020). Nature Astronomy, 4, 517-525.. Hierarchical clustering in astronomy. Astronomy and Computing, 100662.
- Vedantham, H. K. et al. (2017). *Symmetric Achromatic Variability in Active Galaxies: A Powerful New Gravitational Lensing Probe?* The Astrophysical Journal, 845, 2, 89, 16.
- Vermeulen, R. C. et al. (1995). *When Is BL Lac Not a BL Lac?* Astrophysical Journal Letters, 452, L5.
- Vettigli, G. (2018). *MiniSom: minimalistic and NumPy-based implementation of the Self Organizing Map*. e-print: <https://github.com/JustGlowing/minisom/>
- Wold, M. et al. (2007). The dependence of quasar variability on black hole mass. Monthly Notices of the Royal Astronomical Society, 375, 3, 989-999.
- Xin, C. et al. (2020). *Correlation between optical and UV variability of a large sample of quasars*. Monthly Notices of the Royal Astronomical Society, 495, 1, 14 03-1413.
- Zhang, X., Yang, F., Guo, Y., Yu, H., Wang, Z., Wang, Z., & Zhang, Q. (2024). *Adaptive Differential Privacy Mechanism Based on Entropy Theory for Preserving Deep Neural Networks*. Mathematics.

Prilozi

U ovom poglavlju predstavljeni su rezultati modelovanja krivih sjaja kvazara upotrebom NP, pri čemu su prikazani i poređeni ishodi modelovanja bez prethodnog klasterovanja (Prilog 1) i nakon klasterovanja krivih sjaja (Prilozi 2, 3 i 4).

Tako, na je primer, objekat NGC4395 sa relativno glatkim trendom u posmatranjima. Model prati podatke prilično dobro, sa malim odstupanjima na krajevima vremenske serije. Ružičasta senka koja označava interval poverenja je relativno uska, što ukazuje na visoko poverenje modela u predikcije (Loss = 245.06, MSE = 0.53). Ove vrednosti ukazuju na zadovoljavajuće performanse modela za ovaj objekat.

Mrk6 ima nešto složeniji trend sa manjim oscilacijama, ali model uspešno prati osnovni obrazac podataka. Ovde je interval poverenja širi u oblastima sa većom oscilacijom, što ukazuje na povećanu nesigurnost u tim regijama (Loss = 181.64, MSE = 0.49). Ovi rezultati pokazuju da CNP metoda može uspešno modelovati serije sa srednje izraženim oscilacijama, ali uz povećanu nesigurnost u kritičnim intervalima.

NGC1142 ima relativno glatku seriju sa nekoliko oscilacija. Model tačno prati podatke, čak i u oblastima sa promenama trenda. Interval poverenja su ujednačeno uski, što ukazuje na visok nivo poverenja modela (Loss = 292.58, MSE = 0.47). Međutim objekti NGC7469, ESO121mG028, 3C454, Mrk841 imaju izražene oscilacije, šire intervale poverenja, i visoke vrednosti greške i MSE, zbog čega model ima poteškoća u preciznom praćenju podataka.

Takodje objekti poput XSSJ0505 i NGC2522 pokazuju značajno rasipanje ili nagle promene koje su retke u skupu zbog čega model ne može da ih isprati. Za razliku od neklasterisanog pristupa, gde su svi podaci tretirani kao homogeni skup, klasterovanje pruža mogućnost segmentacije vremenskih serija na osnovu

sličnih obrazaca. Time se postiže bolje balansiranje između različitih topoloških obrazaca u promenljivosti, što omogućava efikasnije modelovanje svakog segmenta ponaosob. Ovaj pristup omogućava prilagođavanje modela specifičnostima klastera, čime se poboljšavaju performanse modela na kompleksnijim i promenljivim objektima. Ovo ilustrujemo primerima klastera 4, 13, 16 datim u Prilozima, gde su objekti podeljeni u klastere na osnovu obrazaca promenljivosti u njihovim krivama sjaja. Trening i validacija su izvršeni unutar svakog klastera, što je omogućilo bolju efikasnost modela.


Klaster 4 (Prilog 2): Predstavlja primer klastera sa malom promenljivošću. Objekti u ovom klasteru, poput 3C273 i 3C105, pokazuju dominantno glatke trendove sa povremenim oscilacijama. Model uspešno prati osnovne trendove i oscilacije, a interval poverenja (ružičasta senka) ostaje relativno uzak. Na primer, za objekat 3C273, vrednosti greške i MSE su niske (Loss = 39.63, MSE = 0.19), što ukazuje na visoko poverenje modela i preciznost predikcija.

Klaster 13 (Prilog 3): Predstavlja primer klastera sa umerenom promenljivošću. U ovom klasteru preovlađuju objekti sa nešto izraženijom promenljivošću, poput NGC2110 i ESO198m024. Iako model uspešno prati osnovne trendove, interval poverenja je širi u regijama sa izraženijim oscilacijama. Na primer, kod objekta ESO198m024 interval poverenja postaje širi u delovima sa naglim promenama sjaja, što odražava veću nesigurnost modela (Loss = 326.64, MSE = 0.53).


Klaster 16 (Prilog 4): Predstavlja primer klaster se specifičnim krivama. Objekti u ovom klasteru, poput 3C382 i 4Cp74, imaju izražene oscilacije i kompleksne trendove. Kod objekta 3C382, model uspeva da prati osnovni trend sa relativno ujednačenim intervalima poverenja (Loss = 206.61, MSE = 0.45). Međutim, kod 4Cp74, gde su oscilacije intenzivnije, intervali poverenja postaju širi, a vrednosti greške i MSE su visoke (Loss = 1073.38, MSE = 0.71), što ukazuje na izazove u modelovanju ovakvih vremenskih serija.

Prilog 1: Modeli svetlosnih krivih bez prethodnog klasterovanja


Rezultati modelovanja svetlosnih krivih bez prethodnog klasterovanja:




Slika 46: Rezultati modelovanja vremenskih serija bez prethodnog klasterovanja. Plava linija predstavlja srednji model (Mean Model), dok ružičasta oblast prikazuje interval poverenja (Confidence Interval, CI). Crne tačke označavaju posmatrane podatke (Observations). Na vrhu svakog panela navedeni su naziv objekta, vrednosti funkcije greške (Loss) i srednje kvadratne greške (MSE). Oznake „minus“ i „plus“ označavaju način na koji su uračunate greške merenja u datom primeru.




Slika 47: Isto kao Slika 46.




Slika 48: Isto kao Slika 46.




Slika 49: Isto kao Slika 46.




Slika 50: Isto kao Slika 46.




Slika 51: Isto kao Slika 46.




Slika 52: Isto kao Slika 46.




Slika 53: Isto kao Slika 46.




Slika 54: Isto kao Slika 46.




Slika 55: Isto kao Slika 46.




Slika 56: Isto kao Slika 46.




Slika 57: Isto kao Slika 46.




Slika 58: Isto kao Slika 46.




Slika 59: Isto kao Slika 46.




Slika 60: Isto kao Slika 46.




Slika 61: Isto kao Slika 46.




Slika 62: Isto kao Slika 46.




Slika 63: Isto kao Slika 46.




Slika 64: Isto kao Slika 46.




Slika 65: Isto kao Slika 46.




Slika 66: Isto kao Slika 46.




Slika 67: Isto kao Slika 46.




Slika 68: Isto kao Slika 46.




Slika 69: Isto kao Slika 46.




Slika 70: Isto kao Slika 46.




Slika 71: Isto kao Slika 46.




Slika 72: Isto kao Slika 46.




Slika 73: Isto kao Slika 46.




Slika 74: Isto kao Slika 46.




Slika 75: Isto kao Slika 46.




Slika 76: Isto kao Slika 46.




Slika 77: Isto kao Slika 46.




Slika 78: Isto kao Slika 46.




Slika 79: Isto kao Slika 46.




Slika 80: Isto kao Slika 46.




Slika 81: Isto kao Slika 46.




Slika 82: Isto kao Slika 46.




Slika 83: Isto kao Slika 46.




Slika 84: Isto kao Slika 46.




Slika 85: Isto kao Slika 46.




Slika 86: Isto kao Slika 46.




Slika 87: Isto kao Slika 46.



Slika 88: Isto kao Slika 46.




Slika 89: Isto kao Slika 46.



Slika 90: Isto kao Slika 46.

Prilog 2: Modeli svetlosnih krivih iz klastera 4


Rezultati modelovanja svetlosnih krivih reprezentativnih za klaster 4:



Slika 91: Isto kao Slika 46.

Prilog 3: Modeli svetlosnih krivih iz klastera 13


Rezultati modelovanja svetlosnih krivih reprezentativnih za klaster 13:



Slika 92: Isto kao Slika 46.

Prilog 4: Modeli svetlosnih krivih iz klastera 16

Rezultati modelovanja svetlosnih krivih reprezentativnih za klaster 16:



Slika 93: Isto kao Slika 46.

Biografija autora

Iva Čvorović – Hajdinjak, rođena 01.11.1983. godine u Beogradu, gde je završila „Šestu beogradsku gimnaziju“. Školske 2002/2003. godine je upisala studije matematike na smeru „Numerička matematika i optimizacija“ na Prirodno matematičkom fakultetu u Beogradu, a kasnije i smer „Profesor matematike i računarstva“.

Nakon diplomiranja je radila u međunarodnim kompanijama kao IT stručnjak. Godine 2019. završava master studije na Matematičkom fakultetu u Beogradu na Katedri za astromomiju i astrofiziku sa prosečnom ocenom 10 i odbranjenim master radom: „Modeli klasifikacije egzoplaneta prema nastanjivosti dobijeni metodama mašinskog učenja“, pod mentorskom palicom dr. Anđelke Kovačević.

Godine 2020. upisuje doktorske studije na studijskom programu Astronomija i astrofizika na Matematičkom fakulteta u Beogradu. Položila je sve predviđene predmete sa prosečnom ocenom 9,88.

Bavi se istraživačkim radom. Bila je član tima, koji je osvojio pobedničko mesto za klasifikaciju podataka u okviru „LSST AGN Data challenge“ LSST AGJ naučne kolaboracije. Dobitnik je stipendije Legacy Survey of Space and Time (LSST) Corporation Enabling Science Call 2021. godine. Od decembra 2024. je izabrana za istraživača pripravnika u Atronomskoj opservatoriji u Beogradu. Član je projekta Building Deep Learning Engine (DLE) for AGN light-curves i tima LSST UB-MATF SER-SAG-S1 za softverski doprinos projektu LSST.

Autor je jednog samostalnog rada objavljenog u časopisu Serbian Astronomical Journal (M23) iz oblasti istraživanja prezentovane u ovoj disertaciji. Koautor je na sedam radova objavljenih u međunarodnim časopisima, iz oblasti istraživanja prezentovane u ovoj disertaciji. Učestvovala je u prezentovanju svojih i timskih radova i aktivnosti na brojnim lokalnim i međunarodnim konferencijama.

Прилог 1.

Изјава о ауторству

Потписана Ива Чворовић - Хајдињак
број уписа 2009/2020

Изјављујем


да је докторска дисертација под насловом

**Анализа променљивости активних галактичких језгара комбинованом
применом самоорганизујућих мапа и неуронских процеса**

- 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 кршила ауторска права и користио интелектуалну својину других лица.

Потпис докторанда

У Београду, _____



J. Čvorović-Hajdinjak

Прилог 2.

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора Ива Чворовић – Хајдињак
Број уписа 2009/2020
Студијски програм Астрономија и астрофизика
Наслов рада Анализа променљивости активних галактичких језгара комбинованом
применом самоорганизујућих мапа и неуронских процеса
Ментор др. Анђелка Ковачевић

Потписана Ива Чворовић – Хајдињак


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, _____



Прилог 3.

Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Анализа променљивости активних галактичких језгара комбинованом применом самоорганизујућих мапа и неуронских процеса

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, _____

1. Ауторство - Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.

2. Ауторство – некомерцијално. Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.

3. Ауторство - некомерцијално – без прераде. Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну



употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.

4. Ауторство - некомерцијално – делити под истим условима. Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.

5. Ауторство – без прераде. Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.

6. Ауторство - делити под истим условима. Дозвољава умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.