

UNIVERZITET U BEOGRADU
MATEMATIČKI FAKULTET



Aleksandra Ružić

PREDVIĐANJE VREMENSKIH PRILIKA NA
PODRUČJU SRBIJE NA OSNOVU PROMENA
CIRKULACIJE ATMOSFERE KORIŠĆENJEM
METODA MAŠINSKOG UČENJA

master rad

Beograd, 2024.

Mentor:

dr Mladen NIKOLIĆ, vanredni profesor
Univerzitet u Beogradu, Matematički fakultet

Članovi komisije:

dr Jovana KOVAČEVIĆ, vanredni profesor
Univerzitet u Beogradu, Matematički fakultet

dr Aleksandar KARTELJ, vanredni profesor
Univerzitet u Beogradu, Matematički fakultet

Datum odbrane: _____

*Ovim putem želim da se zahvalim Bošku Milovanoviću sa
Geografskog instituta „Jovan Cvijić” i Suzani Putniković sa
Instituta za meteorologiju Fizičkog fakulteta na pruženim
podacima i domenskom znanju.*

Naslov master rada: Predviđanje vremenskih prilika na području Srbije na osnovu promena cirkulacije atmosfere korišćenjem metoda mašinskog učenja

Rezime: Indeksi atmosferske cirkulacije predstavljaju razlike između različitih polja konstantno visokog vazdušnog pritiska i polja konstantno niskog vazdušnog pritiska. Postojanje tih razlika uzrokuje kretanje velikih vazdušnih masa koje utiču na klimu čitave planete. Primeri indeksa atmosferske cirkulacije su severno-atlantska oscilacija, mediteranska oscilacija, arktička oscilacija, severno morsko-kaspijski indeks, itd. Vrednosti tih indeksa se koriste za predviđanje klimatskih prilika na većim geografskim područjima, npr. vrednosti klimatskih elemenata u toku godišnjih doba na određenom kontinentu. Postavlja se pitanje da li indeksi cirkulacije atmosfere mogu da se koriste za prognozu klimatskih prilika manjeg geografskog područja poput Srbije.

Cilj ovog rada je utvrditi da li se može napraviti model mašinskog učenja koji pravi prognozu temperature vazduha i padavina na području Srbije na osnovu indeksa atmosferske cirkulacije. Upotrebljene su neuronske mreže gde ulaz predstavljaju dnevne vrednosti raznih indeksa atmosferske cirkulacije, a izlaz predstavlja predikciju dnevnih vrednosti minimalne, srednje i maksimalne temperature vazduha i količine padavina. Modeli upotrebljeni u ovom radu su LSTM, CNN i transformer. Testirana je funkcija greške SERA za predikciju ekstremnih vrednosti i rezultati su upoređeni sa rezultatima funkcije MSE. Za implementaciju su korišćeni programski jezik Python i biblioteke TensorFlow, Keras, NumPy i Pandas. Rezultati ovog rada ukazuju na postojanje veze indeksa cirkulacije atmosfere sa temperaturama, ali ne i sa padavinama u Srbiji.

Ključne reči: prognoza, klimatologija, mašinsko učenje, regresija, neuronske mreže, LSTM, transformer, konvolucija, vremenske serije, indeksi atmosferske cirkulacije, SERA

Sadržaj

1	Uvod	1
1.1	Indeksi atmosferske cirkulacije	3
2	Podaci	5
2.1	Atributi	5
2.2	Ciljne promenljive	10
3	Korišćeni modeli mašinskog učenja	16
3.1	Duga kratkoročna memorija - LSTM	16
3.2	Konvolutivne neuronske mreže - CNN	18
3.3	Transformeri	19
3.4	Funkcije greške: MSE i SERA	24
3.5	Arhitektura modela	25
4	Analiza rezultata	27
4.1	Analiza rezultata za temperature	27
4.2	Analiza rezultata za padavine	39
5	Zaključak	40
	Bibliografija	42

Glava 1

Uvod

Klima je meteorološki pojam koji obuhvata skup meteoroloških pojava koje u određenom vremenskom periodu čine prosečno stanje atmosfere na nekom delu planete. Klima se opisuje procenom obrasca varijacija u temperaturi, količini padavina, vlažnosti i drugim meteorološkim promenljivama u datom regionu tokom dugih vremenskih perioda. Klima se razlikuje od vremena po tome što vreme opisuje samo trenutne/kratkoročne uslove tih promenljivih u datom regionu. Klima je statistički profil vremena tokom dužeg vremenskog perioda, što je po preporuci Svetske meteorološke organizacije (eng. World Meteorological Organization) 30 godina [9].

Atmosferska kretanja velikih razmera znatno utiču na klimu širokih geografskih oblasti. Atmosferski indeksi se definišu u cilju kvantifikovanja promenljivosti ovakvih opštih šablona i njihovih efekata na klimu određenog prostora. Oni pružaju uvid u to koliko globalne promene u atmosferi utiču na razvoj lokalnih klimatskih parametara. Indeksi se najčešće koriste za praćenje dugoročnih klimatskih promena nekog regiona [2, 6, 1, 18].

U [15] autori su pokušali da objasne ekstremne temperature kao funkciju tipa atmosferske cirkulacije i temperaturnih indeksa korišćenjem linearne regresije. Korišćenjem statističkih metoda u [7] istraživana je korelacija između indeksa atmosferske cirkulacije i padavina u raznim delovima Evrope. Efekti Mediteranske oscilacije na padavine u Turskoj su proučavani u [14].

Iako postoje istraživanja u ovoj oblasti, većina radova koristi jednostavne statističke metode. Suština ovog rada je korišćenje metoda mašinskog učenja za istraživanje veze između lokalnih vremenskih uslova u Srbiji i globalnih pokazatelja stanja atmosfere kao što su indeksi atmosferske cirkulacije. Postavlja pitanje da li i u kojoj meri određene metode mašinskog učenja mogu detektovati povezanost između

različitih indeksa cirkulacije atmosfere i klimatskih elemenata Srbije. Ako postoji dovoljno velika povezanost, indeksi atmosferske oscilacije se mogu koristiti za vremensku prognozu u Srbiji. Da bi se odgovorilo na dato pitanje, isprobaće se nekoliko metoda mašinskog učenja koji će se koristiti za predikciju dnevnih vrednosti minimalne, srednje i maksimalne temperature vazduha i količine padavina. Ulaz tih modela će biti dnevne vrednosti raznih indeksa cirkulacije atmosfere. Temperature će se predviđati u zajedničkom modelu dok će padavine u zasebnom. Razlog za ovo je priroda podataka. Dok temperature kontinualno prate određeni sezonalni šablon, padavine su dosta teže za predviđanje i bez vidnog obrasca. Postoji više aspekata ovog istraživanja:

1. Da li se može napraviti kvalitetan model?

Za opseg ovog rada, kvalitetan model ne mora nužno da pravi idealnu vremensku prognozu. Vremenske prilike su ipak lokalnog karaktera i kao takve dosta zavise od manjih i bližih klimatskih uticaja. Dovoljno je da grafik predikcija prati opšti oblik grafika ciljne promenljive. Ako je moguće napraviti takav model, može se pretpostaviti da postoji povezanost između dnevnih oscilacija u vremenskim prilikama u Srbiji i globalnih parametara atmosfere planete kao što su indeksi atmosferske oscilacije. Takođe je bitno da model može da pravi predikcije ekstremnih vrednosti. Opseg vrednosti predikcija mora da se približno poklapa sa opsegom ciljne promenljive. Iako to dosta zavisi od izbora modela, takođe zavisi i od izbora funkcije greške. Mala vrednost funkcije greške ne podrazumeva da su ekstremne vrednosti u većini slučajeva predviđene dovoljno dobro. O izboru funkcije greške će biti reči u narednim poglavljima. Modeli iz ovog rada će se porediti sa autoregresivnim modelima tj. modelima zasnovanim na istim metodama mašinskog učenja koji za ulaz primaju samo prethodne vrednosti ciljne promenljive.

2. Uporediti uspešnost različitih modela.

Postavlja se pitanje kakav model najviše odgovarama potrebama ovog rada. Isprobaće se više vrsta neuronskih mreža (LSTM [3], CNN [17] i transformeri [16]) koje će se međusobno porediti. Za svaki model koristiće se dve funkcije greške: MSE i SERA. SERA [12] je funkcija greške osmišljena da više penalizuje greške pri predikciji ekstremnih vrednosti. Njena uspešnost u predikciji ekstremnih vrednosti će se porediti sa standardnom MSE funkcijom. Takođe,

za svaki model će se uz ulazne podatke, dodati informacija o godišnjem dobu i porediti sa modelom koji je primio samo ulazne podatke.

3. Uporediti rezultate iz različitih mernih stanica.

Ciljne promenljive se uzimaju iz 12 gradova širom Srbije. Za svaki grad će se trenirati poseban model. Poređić se uspešnost modela za različite gradove. Očekivani rezultat je da svi gradovi imaju sličan kvalitet modela. Ako neki grad ima drastično bolju predikciju, to bi postavilo pitanje zašto je taj grad bolje povezan sa atmosferskim indeksima. Iako bi traženje odgovora na to pitanje prevazilazilo opseg ovog rada, moglo bi predstavljati dalji pravac istraživanja.

1.1 Indeksi atmosferske cirkulacije

Postoji više načina da se opiše prostorna struktura globalnih atmosferskih pojava koja obuhvata trenutno stanje njihove varijabilnosti i njihov razvoj kroz vreme. Samim tim, postoji više prihvaćenih definicija klimatskih indeksa. Jedna od uobičajenih je da je dnevna vrednost indeksa cirkulacije atmosfere linearna kombinacija (najčešće razlika) anomalija vazdušnog pritiska na nivou mora tj. SLP (eng. sea level pressure) izmerenog tog dana u različitim stanicama regije u kojoj se pojavljuje atmosferska pojava koja se meri [2]. U radu, indeks je vremenska serija jedne skalarne promenljive koja predstavlja dnevnu vrednost indeksa.

U ovoj sekciji biće navedene definicije klimatskih indeksa koji će se koristiti u radu. Pored ovih indeksa koristiće se i podaci o cirkulaciji atmosfere u Srbiji.

- Severno atlantska oscilacija - NAO (eng. North Atlantic Oscillation)

NAO indeks meri razliku u SLP-u azorskog anticiklona i islandskog ciklona. Azorski anticiklon (azorski maksimum) je oblast visokog vazdušnog pritiska južno od Azorskih ostrva. Islandski ciklon (islandski minimum) je oblast niskog vazdušnog pritiska između Islanda i južnog Grenlanda [2].

- Arktička oscilacija - AO (eng. Arctic Oscillation)

Arktička oscilacija se definiše pomoću jačine atmosferskog pritiska iznad Arktika. Kada je AO u pozitivnoj fazi, vazdušni pritisak iznad Arktika je niži nego uobičajeno. Pozitivan AO obično izaziva veće količine padavina na severu Evrope i suše na Mediteranu, dok negativan AO izaziva povećanu količinu padavina tokom zime u južnoj Evropi i Mediteranu [7].

- Atlantska višedecenijska oscilacija - AMO (eng. Atlantic multidecadal oscillation)

AMO predstavlja klimatski mod Severnog Atlantika, koji se menja u višedecenijskom rasponu. AMO indeks je mera promenljivosti temperature površine mora - SST (eng. sea surface temperature), prilagođena tako da se otkloni trend klimatskog zagrevanja indukovano ljudskim faktorom. Šabloni su ciklični, trajanja oko 50-70 godina i opisuju dalekosežne promene u SST-u, što potom utiče na mnoge druge atmosferske faktore [13].

- Severno morski-kaspijski šablon - NCP¹ (eng. North Sea-Caspian Pattern)

NCP označava telekonekciju između Severnog mora i Kaspijskog jezera. NCP ima kompleksnu korelaciju sa padavinama na Balkanu, u Turskoj i Izraelu. Otkrivena je negativna korelacija sa zimskim padavinama i pozitivna sa letnjim padavinama na egejskoj obali Turske. Prijavljene su i negativne korelacije NCP-a i padavina u centralnoj, zapadnoj i severno-zapadnoj Evropi [6, 1, 7].

- Indeks mediteranske oscilacije - MOI (eng. Mediterranean Oscillation Index)

Postoje razne definicije ove klimatske pojave. U radu se koristi MOI1 koji predstavlja razliku vazdušnog pritiska između Alžira i Kaira. Drugi primer je MOI2 koji predstavlja razliku vazdušnog pritiska između Gibraltara i Izraela. Dokazane su značajne korelacije MOI i klimatskih parametara Mediterana kao što su temperatura i padavine [2, 7].

- Indeks zapadno mediteranske oscilacije - WeMOI (eng. West Mediterranean Oscillation Index)

WeMOI meri razliku u pritiscima između Kadiza u jugozapadnoj Španiji i Padove u severnoj Italiji. Pozitivni WeMOI je povezan sa smanjenjem padavina na jugozapadu i istoku Iberijskog poluostrva i sa povećanjem padavina na severnom i u centralnom delu Iberijskog poluostrva [7].

¹U daljem tekstu je predstavljen skraćenicom NSCI (eng. North-Sea Caspian Index)

Glava 2

Podaci

Ulazni podaci su vremenske serije koje predstavljaju vrednosti atmosferskih indeksa, dok su ciljne promenljive vremenske serije koje predstavljaju minimalnu, srednju i maksimalnu dnevnu temperaturu i količinu padavina u raznim gradovima u Srbiji. Sve vremenske serije su podaci mereni između 01.01.1961. i 01.12.2005. Sve nedostajuće vrednosti su interpolirane. Podaci su normalizovani tokom preprocesiranja. Skup podataka je hronološki podeljen na trening, validacioni i testni skup u odnosu 70:15:15.

2.1 Atributi

Vrednosti sledećih atmosferskih indeksa se koriste za ulazne podatke: NAO, MOI, NSCI, AMO i AO. Podaci koji se mere dnevno su tip cirkulacije, NAO, MOI i AO. Ostali podaci su vremenske serije čije se vrednosti računaju mesečno. U tabelama 2.1, 2.2, 2.3, 2.4, 2.5 i 2.6 prikazane su osnovne statistike ovih indeksa za ceo skup i za svako godišnje doba. Tabele pokazuju da vrednosti različitih atributa pripadaju drugačijim opsezima i zato moraju biti normalizovani.

Tabela 2.1: Prikaz deskriptivnih statistika AO indeksa

	count	mean	std	min	25%	50%	75%	max
ao	16405.0	-0.077667	1.436646	-7.432610	-0.916660	-0.030915	0.812356	5.911144
winter	4031.0	-0.290951	1.906442	-7.432610	-1.534410	-0.213381	0.994236	5.911144
spring	4139.0	0.015435	1.460033	-6.364555	-0.898878	0.049733	0.976074	4.916886
summer	4140.0	-0.027228	0.889498	-5.992157	-0.607429	-0.027406	0.573880	2.988235
fall	4095.0	-0.012811	1.295135	-5.097911	-0.855006	0.022196	0.838368	4.544460

Tabela 2.2: Prikaz deskriptivnih statistika NAO indeksa

	count	mean	std	min	25%	50%	75%	max
full	16406.0	-3.263519	119.279221	-505.06	-71.125	4.050	72.3375	433.57
winter	4031.0	-15.116897	158.968968	-505.06	-113.900	-1.870	99.1050	433.57
spring	4140.0	-3.832198	124.426064	-464.21	-84.050	-2.450	79.9525	392.55
summer	4140.0	3.400998	68.743538	-293.82	-40.380	8.305	52.5025	193.13
fall	4095.0	2.241780	107.197485	-373.55	-68.540	7.020	78.1300	295.02

Tabela 2.3: Prikaz deskriptivnih statistika MOI indeksa

	count	mean	std	min	25%	50%	75%	max
full	16406.0	0.294156	1.000894	-4.899	0.20825	0.4850	0.8050	3.593
winter	4031.0	0.088035	1.320072	-4.899	0.10000	0.4530	0.8540	3.593
spring	4140.0	0.184542	1.062138	-4.805	0.14975	0.4425	0.7790	3.417
summer	4140.0	0.630392	0.445684	-1.910	0.32100	0.5760	0.8605	2.490
fall	4095.0	0.267943	0.888003	-4.169	0.21100	0.4550	0.7400	2.730

Tabela 2.4: Prikaz deskriptivnih statistika NSCI indeksa

	count	mean	std	min	25%	50%	75%	max
full	540.0	0.026444	0.931007	-2.52	-0.550	0.03	0.650	2.42
winter	135.0	0.067778	0.958264	-2.18	-0.540	0.01	0.675	2.42
spring	135.0	-0.036000	0.937822	-2.09	-0.595	-0.06	0.635	2.21
summer	135.0	0.087852	0.934834	-2.52	-0.470	0.14	0.625	2.40
fall	135.0	-0.013852	0.896504	-2.32	-0.525	0.02	0.575	2.12

Tabela 2.5: Prikaz deskriptivnih statistika WeMOI indeksa

	count	mean	std	min	25%	50%	75%	max
full	540.0	0.235500	1.083245	-3.21	-0.480	0.245	0.940	3.96
winter	135.0	0.140222	0.953019	-2.25	-0.495	0.110	0.765	2.48
spring	135.0	0.353185	1.213402	-3.06	-0.490	0.330	1.140	3.96
summer	135.0	0.199111	0.982387	-3.04	-0.405	0.270	0.890	2.56
fall	135.0	0.249481	1.161743	-3.21	-0.430	0.250	1.045	3.49

Tabela 2.6: Prikaz deskriptivnih statistika AMO indeksa

	count	mean	std	min	25%	50%	75%	max
full	540.0	-0.078870	0.176678	-0.57	-0.200	-0.07	0.0425	0.38
winter	135.0	-0.079630	0.189045	-0.57	-0.215	-0.07	0.0450	0.33
spring	135.0	-0.068222	0.161221	-0.46	-0.180	-0.06	0.0600	0.26
summer	135.0	-0.074370	0.177762	-0.44	-0.210	-0.07	0.0550	0.38
fall	135.0	-0.093259	0.178567	-0.51	-0.190	-0.09	0.0050	0.36

Uz indekse cirkulacije atmosfere se takođe koristi dnevna vremenska serija koja označava tip cirkulacije atmosfere tog dana u Srbiji. Tip cirkulacije atmosfere je predstavljen smerom kretanja vazdušnih masa. Vrednosti te vremenske serije su predstavljene brojevima od 1 do 10 i označavaju smer cirkulisanja vazduha. Smer kretanja vazdušnih masa može biti jedan od 8 linijskih geografskih smerova (zapadni, severozapadni, severni itd.) i može biti jedan od dva ciklična (ciklon i anticiklon). Preslikavanje smeru u broj je prikazano u tabeli 2.7. U tabeli 2.8 je prikazano koliko se svaki tip cirkulacije javlja u svakom godišnjem dobu tj. koliko dana u datom godišnjem dobu ima određen tip cirkulacije. Može se primetiti da je anticiklon najčešći obrazac kretanja vazdušnih masa u Srbiji. Zimi se često javljaju istočni i jugoistočni tip cirkulacije, koji se poklapaju sa pojavom košave, jugoistočnog vetra koji duva sa Karpata. Leti je izražen severoistočni tip, koji je odgovoran za velike količine padavina [10]. Pri preprocesiranju ovog atributa, mora se uzeti u obzir činjenica da nije kategorički već ordinalni tj. postoje vrednosti atributa koje su međusobno sličnije od drugih. Na primer, severni tip je sličniji istočnom nego što je južnom. Međutim, mora se primetiti da ovaj atribut nije „linearno” ordinalan, već kružno. Da bi se ovo bolje prikazalo, treba zamisliti prvih 8 vrednosti ovog atributa kao jednako udaljene tačke na kružnici u redosledu u kom su navedene u tabeli. Tačka koja označava 1 (zapad) je najudaljenija od tačke 5 (istok) i podjednako je udaljena od tačke 2 (severozapad) i tačke 7 (jugozapad). Iz navedenog se može zaključiti da je smisleno atribut zameniti sa dva nova koji predstavljaju x i y osu tačaka na jediničnoj kružnici sa centrom u koordinatnom početku. Tačke će predstavljati geografski smislen smer (zapad će biti $(-1, 0)$, jug će biti $(0, -1)$, istok $(1, 0)$, sever $(0, 1)$, itd.). Problem prave poslednje dve vrednosti: ciklon i anticiklon. Ove dve tačke su najviše udaljene jedna od druge. Od svih ostalih su podjednako različite. Zato se dodaje i treći atribut koji predstavlja z osu. Za prvih 8 tačaka, z atribut će biti 0, za ciklon će biti 1, a za anticiklon će biti -1.

Tabela 2.7: Kodovi cirkulacije atmosfere u Srbiji

Kod	Smer cirkulacije
1	zapadni
2	severozapadni
3	severni
4	severoistočni
5	istočni
6	jugoistočni
7	južni
8	jugozapadni
9	ciklon
10	anticiklon


Tabela 2.8: Čestina tipova cirkulacije po godišnjim dobima

	winter	spring	summer	fall	total
W	216	290	101	154	761
NW	130	287	197	91	705
N	136	302	521	177	1136
NE	235	409	879	317	1840
E	521	341	585	493	1940
SE	530	365	153	464	1512
S	278	303	100	331	1012
SW	244	257	79	314	894
cyclon	663	777	463	457	2360
anticyclon	1078	809	1062	1297	4246


2.2 Ciljne promenljive

Vremenski podaci sledećih gradova su se koristili kao ciljne promenljive: Beograd, Kikinda, Niš, Novi Sad, Požega, Smederevska Palanka, Sombor, Kragujevac, Veliko Gradište, Loznica, Palić i Valjevo. Vremenski podaci uključuju minimalnu, srednju i maksimalnu dnevnu temperaturu i količinu dnevnih padavina. Na narednim slikama se vide osnovne statistike za sva četiri elementa. Na slikama 2.1-2.12 vizualizovane su raspodele temperatura za svaki grad, pomoću grafika koji prikazuju medijanu i prvi i treći kvartil. Na slici 2.13 prikazani su histogrami padavina po gradovima.


Treba primetiti da svi podaci imaju ekstremne vrednosti, daleko veće ili manje od proseka. Ekstremne vrednosti su normalna pojava u ovom domenu. Dobar model za ovu svrhu bi trebalo da bude u stanju da adekvatno predvidi ekstreme. Ovo posebno važi za padavine jer više od pola dana koji se posmatraju nemaju padavine. Dakle, uzimajući u obzir koliko često se javljaju padavine, svaki dan u kom je vrednost padavina veća od nule se može smatrati ekstremom.




Slika 2.1: Prikaz temperatura u Beogradu




Slika 2.2: Prikaz temperatura u Kikindi




Slika 2.3: Prikaz temperatura u Nišu




Slika 2.4: Prikaz temperatura u Novom Sadu




Slika 2.5: Prikaz temperatura u Požegi




Slika 2.6: Prikaz temperatura u Smederevskoj Palanci




Slika 2.7: Prikaz temperatura u Somboru




Slika 2.8: Prikaz temperatura u Kragujevcu




Slika 2.9: Prikaz temperatura u Velikom Gradištu




Slika 2.10: Prikaz temperatura u Smederevskoj Palanci



Slika 2.11: Prikaz temperatura u Loznici



Slika 2.12: Prikaz temperatura na Paliću



Slika 2.13: Histogram padavina za sve gradove

Glava 3

Korišćeni modeli mašinskog učenja

U ovom poglavlju biće ukratko opisani modeli mašinskog učenja korišćeni u radu: LSTM, CNN i transformeri. Takođe, biće objašnjena funkcija greške SERA koja je korišćena da bi se tačnije predviđale ekstremne vrednosti.

3.1 Duga kratkoročna memorija - LSTM

Rekurentne neuronske mreže su prirodan izbor u domenu vremenskih serija. Međutim, one su problematične kada je neophodno koristiti dugoročne veze između podataka. Zbog pojave nestajućih gradijenata (eng. vanishing gradient), osim što obučavanje mreže postaje nestabilno, uticaj podataka opada što se ide dalje u prošlost. LSTM (eng. Long short-term memory) [3] je vrsta rekurentne neuronske mreže koja ublažava taj problem.

LSTM uvodi dve nove vrste ćelija: ćelije stanja i kapije. Ćelije stanja se koriste da bi se čuvala informacija o prošlim ulazima i one predstavljaju kombinaciju kratkoročnog i dugoročnog sećanja. Pri svakom novom ulazu, one se ažuriraju. Kapije služe da pri ažuriranju ćelije stanja, kontrolišu uticaj ulaza i prošle vrednosti ćelije stanja. Kapija zaboravljanja kontroliše informacije iz prošlog stanja, a ulazna kapija kontroliše uticaj ulaznih podataka [3]. Shema LSTM-a prikazana je na slici 3.1. Matematička formulacija je sledeća:

$$c^{(0)} = 0$$

$$h^{(0)} = 0$$

$$z^{(t)} = \tanh(W_z x^{(t)} + U_z h^{(t-1)} + b_z)$$

$$i^{(t)} = \sigma(W_i x^{(t)} + U_i h^{(t-1)} + b_i)$$

$$f^{(t)} = \sigma(W_f x^{(t)} + U_f h^{(t-1)} + b_f)$$


$$c^{(t)} = f^{(t)} \odot c^{(t-1)} + i^{(t)} \odot z^{(t)}$$

$$q^{(t)} = \sigma(W_q x^{(t)} + U_q h^{(t-1)} + b_q)$$

$$h^{(t)} = \tanh(c^{(t)}) \odot q^{(t)}$$

gde su:

- c ćelije stanja
- h vrednost izlaza
- z transformisani ulaz
- i ulazna kapija
- f kapija zaboravljanja
- q izlazna kapija
- W , U i b su jedinstveni parametri za svaku ćeliju koji se uče treniranjem



Slika 3.1: Shema LSTM

3.2 Konvolutivne neuronske mreže - CNN

CNN (eng. Convolutional Neural Network) se najčešće primenjuju u obradi signala (zvuka, slike i drugih vremenskih serija) i teksta. Zasniva se na učenju filtera, koji mogu otkriti određena svojstva signala operacijom konvolucije [5].

Konvolucija [4] je matematička operacija nad funkcijama, definisana sledećom formulom:

$$(f * g)(x) = \int_{-\infty}^{\infty} f(x-t)g(t)dt$$

U diskretnom smislu, konvolucija je operacija nad nizovima. Ako su a i b nizovi dužine p i q , konvolucija $(a * b)$ je niz čiji se elementi definišu sledećim izrazom:

$$(a * b)_n = \sum_{\substack{i,j \\ i+j=n}} a_i b_j$$


gde je $n \leq p + q - 1$. U dvodimenzionalnom slučaju, a i b su matrice dimenzija $p \times r$ i $q \times s$:

$$(a * b)_{n,m} = \sum_{\substack{i,j \\ i+j=n}} \sum_{\substack{k,l \\ k+l=m}} a_{i,k} b_{j,l}$$

gde su $n \leq p + q - 1$ i $m \leq r + s - 1$. Kada se konvolucija koristi u kontekstu neuronskih mreža, a je niz/matrica ulaznih podataka, a b je filter koji se primenjuje. Filter konvolucijom registruje da li i gde ulazni signal poseduje neko svojstvo. U CNN modelu, filteri su parametri mreže koji se uče minimizacijom greške predviđanja. Diskretna 1-D konvolucija se koristi za vremenske serije, dok se diskretna 2-D konvolucija koristi za slike. Treba primetiti da je u matematičkim definicijama, rezultat većih dimenzija od ulaza. Za potrebe neuronskih mreža, ne uzimaju se u obzir slučajevi kada se u sumi ne može iskoristiti ceo filter. Tada je rezultat manjih dimenzija nego ulaz. Zato se često vrši proširivanje (eng. padding) nulama ili vrednostima koje su već na obodu, tako da je veličina rezultata jednaka veličini ulaznih podataka pre proširivanja.

Struktura CNN-a se najčešće sastoji od dve vrste slojeva – konvolutivnih slojeva (eng. convolution layer) i slojeva agregacije (eng. pooling layer). Konvolutivni sloj ima ulogu konstrukcije novih atributa. Sloj agregacije ukрупnjuje informacije koje dobija iz prethodnog sloja, obično tako što računa neku jednostavnu funkciju agregacije susednih jedinica prethodnog sloja, poput maksimuma ili proseka. Agregacija uprošćava model čime smanjuje kompleksnost izračunavanja pri optimizaciji i šansu

da se model previše prilagodi podacima. [5]. Primer mreže koja služi za klasifikaciju slike dat je na slici 3.2¹. Na slici se vidi da se primenom konvolucije filtera i izlaza iz prethodnog sloja kreiraju sve kompleksniji atributi.



Slika 3.2: Shema CNN

3.3 Transformeri

Transformeri [16] su neuronske mreže koje su postale jako uspešne u prevođenju teksta sa jednog na drugi jezik, generisanju slika ili zvuka na osnovu teksta, stvaranju transkripta na osnovu audio zapisa itd. Arhitektura transformera je prikazana na slici 3.3². Iako su se retko uspešno koristile za predikciju vremenskih serija, koristiće se za potrebe ovog rada i porediti sa ostalim modelima.

Kratak prikaz transformera koji će biti dat je vezan za prevođenje teksta, što je i originalna svrha ove neuronske mreže [16]. Nakon toga će se opisati adaptacije originalne arhitekture koje su omogućile da se transformeri primene u ovom radu.

Transformeri se sastoje od tri osnovna dela:

- Ulazno kodiranje tokena i poziciono kodiranje

Rečenica koja se prevodi se razdvoji na listu tokena. Tokeni su najčešće delovi reči ali da bi objašnjenje bilo više intuitivno, pretpostaviće se da su u pitanju reči. Nakon toga, tokeni se pretvaraju u vektore realnih brojeva. U obradi prirodnih jezika, ovo se najčešće postiže tako što se formira matrica koja predstavlja rečnik svih mogućih reči. Rečnik svaki token preslikava u odgovarajući vektor. Matrica koja predstavlja taj rečnik je deo parametara mreže

¹Slika preuzeta sa <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

²Slika uzeta iz 3.3

koji se treniranjem optimizuju. Reči koje su semantički bliske bi trebalo nakon treniranja da se preslikavaju u prostorno bliske vektore.

Transformer obrađuje sve tokene istovremeno pa da se ne bi izgubila informacija o redosledu tokena, u ulazne vektore se ugrađuje informacija o poziciji reči u rečenici. To se postiže pozicionim kodiranjem. Poziciono kodiranje je preslikavanje rednog broja tokena u rečenici u vektor. Taj vektor se potom sabira sa ulaznim vektorom koji predstavlja dati token. Poziciono kodiranje može biti fiksno ili naučeno treniranjem mreže. U [16] se koristi fiksno kodiranje funkcijama:

$$PE(pos, 2i) = \sin(pos/10000^{2i/d_{model}})$$

$$PE(pos, 2i + 1) = \cos(pos/10000^{2i/d_{model}})$$

gde je pos pozicija tokena u rečenici, i indeks koda u vektoru, a d_{model} dimenzija ulaznog vektora

- Enkoder

Enkoder se sastoji od N istih celina koje se nadovezuju (izlaz jedne je ulaz u sledeću). Jedna celina se sastoji od ćelije sa više paralelnih jedinica pažnje (eng. multi-head attention) i potpuno povezanog sloja.

Osnova transformera je mehanizam pažnje. Mehanizam pažnje omogućava da se uhvate kontekstualni odnosi između svih parova tokena. Jedna glava pažnje prikazana na slici 3.4³ (eng. single head attention) transformiše ulaznu matricu matricama upita Q (eng. query), ključeva K (eng. key) i vrednosti V (eng. value). Njihova svrha se može približno opisati na sledeći način:

- Transformacija tokena u vrednost označava kontekstualnu promenu tokena u odnosu na ostale tokene. Ista reč može da ima različita značenja u odnosu na kontekst u kom se upotrebljava. Na primer, reč „glava” će imati isto ulazno kodiranje u svakom tekstu, iako je značenje drugačije u kontekstu transformera u odnosu na tekst iz anatomije. Transformacija matricom vrednosti će ulaznom vektoru dodeljenom reči „glava” dodati informaciju o kontekstu neuronskih mreža u slučaju transformera, a u slučaju teksta iz oblasti anatomije će ugraditi kontekst medicine.

³Slika preuzeta sa <https://jalammar.github.io/illustrated-transformer/>


- Matrice upita i ključa određuju koliko na jedan token utiču ostali tokeni. Može se reći da matrice ključa predstavljaju vrednosti neke implicitne osobine tokena, a da matrica upita vrši pretragu nad tim ključem. Množenjem matrica Q i K , dobijaju se vrednosti proporcionalne tome koliko ključevi odgovaraju upitu.

Množenjem datih matrica, uticaji svih vrednosti i upita se kombinuju u novi vektor koji predstavlja izlaz iz jedne glave pažnje. Glava pažnje se fokusira na jedan aspekt konteksta. Najčešće se u enkoderu koriste ćelije više glava pažnje (eng. multi-head attention) da bi se pokrio čitav kontekst rečenice. U tom slučaju, izlazi iz svih glava pažnje se nadovezuju i množe sa matricom projekcije. Time je omogućeno da se u izlazu pokriju svi aspekti konteksta.


- Dekoder

Dekoder je slične strukture kao enkoder. Razlika je u dodatnoj ćeliji pažnje koja obrađuje izlazne tokene odnosno reči ulazne rečenice prevedene na drugi jezik. Kodiranje izlaznih tokena se vrši na isti način kao kodiranje ulaznih tokena. Ta dodatna ćelija pažnje je maskirana (eng. masked multi-head attention) da bi se izbegao uticaj kasnijih reči na trenutnu reč. Izlaz iz enkodera i maskirane ćelije pažnje predstavljaju ulaz u još jednu ćeliju pažnje na koju se zatim nadovezuje potpuno povezan sloj.

Za svrhe ovog rada, korišćen je samo enkoder. Ulazno kodiranje je izbačeno s obzirom da je ono neophodno za prebacivanje teksta u numeričke podatke, a kako su u ovom problemu podaci već numerički, nije nam potrebno. Koristi se isto poziciono kodiranje kao u [16]. Dekoder koji je u originalnom primeru bio neophodan za obradu izlaznog teksta je suvišan za predikciju vremenskih serija. Iskorišćena je implementacija enkodera sa zvaničnog sajta biblioteke keras [8]. Jedina razlika je u aktivacionoj funkciji poslednjeg potpuno povezanog sloja. U primeru se enkoder koristi za klasifikaciju pa je iskorišćena softmax funkcija. Implementacija u ovom radu će koristiti relu funkciju s obzirom da se radi regresija.



Slika 3.3: Shema transformera



Slika 3.4: Glava pažnje

3.4 Funkcije greške: MSE i SERA

Istraživanja u domenu nebalansiranih skupova podataka su se većinski bazirala na rešavanje problema tačne klasifikacije slučajeva koji pripadaju retkoj klasi. Načini rešavanja sličnih problema u regresiji su retki iz nekoliko razloga. Jedan od razloga bi bila pretpostavka da je svaka tačka domena regresije podjednako bitna. Standardne metrike koje se koriste za ocenu kvaliteta modela uglavnom ocenjuju model na osnovu kvaliteta predikcije na najčešćim tačkama u domenu. Najčešća funkcija greške je srednje kvadratna greška - MSE (eng. Mean Squared Error).

Funkcija greške predložena u [12] je kvadratna greška relevantne oblasti - SERA (eng. Squared Error Relevance Area). Ideja iza ove funkcije je da se više penalizuju greške pri predviđanju tačaka koje su bitnije po nekom kriterijumu. Da bi se definisala ova funkcija neophodno je uvesti pojam funkcije relevantnosti (eng. relevance function). Funkcija relevantnosti ϕ preslikava ciljnu promenljivu u opseg $[0, 1]$. Ova funkcija opisuje kriterijum po kojem ocenjujemo bitnost tačaka- tačke sa većom funkcijom relevantnosti su bitnije. Relevantna kvadratna greška - SER (eng. Squared Error Relevance) je suma kvadratnih grešaka tačaka iz domena gde je vrednost funkcije relevantnosti ciljne promenljive iznad zadatog $t \in [0, 1]$. SERA je integral funkcije SER po t , od 0 do 1. Matematička formulacija je data ispod:

$$\begin{aligned} D &= \{(\mathbf{x}_i, y_i), i \in (1, N)\} \\ \phi &: Y \rightarrow [0, 1] \\ D^t &= \{(\mathbf{x}_i, y_i) \in D, \phi(y_i) \geq t\} \\ SER_t &= \sum_{y_i \in D^t} (\hat{y}_i - y_i)^2 \\ SERA &= \int_0^1 SER_t dt \end{aligned}$$

gde važi:

- D je skup podataka koje model obrađuje
- $\mathbf{x}_i$ je vektor ulaznih podataka
- y_i je ciljna promenljiva
- Y je domen ciljne promenljive

- ϕ je funkcija relevantnosti

U implementaciji u ovom radu, SERA je aproksimirana izrazom:

$$SERA = \sum_{i=0}^N SER_{i/N}$$

Funkcija relevantnosti je u ovom radu definisana na sledeći način:

$$\phi(y) = (2y - 1)^2$$

gde je $y \in [0, 1]$ jer su ciljne promenljive normalizovane. Ovom definicijom, vrednosti ϕ su unutar $[0, 1]$ i vrednosti y blizu 0 i 1 imaju značajno veću vrednost ϕ .

Modeli će koristiti MSE i SERA. Porediće se kvalitet rezultata po preciznosti predikcije ekstremnih vrednosti i opštoj preciznosti. U ocenu kvaliteta modela ulaziće i koliko opseg predikcija odgovara opsegu ciljnih promenljivih.

3.5 Arhitektura modela

Modeli koji su predstavljeni imaju jednostavnu arhitekturu. Isprobani su kompleksniji modeli, ali oni nisu dali bolje rezultate. Dalji pravac istraživanja bi uključio traženje adekvatnije arhitekture modela.

Podaci su podeljeni na trening, validacioni i test skup u odnosu 70:15:15. Ulaz je dimenzija (l, t, f) gde je l dužina vremenske serije, t veličina vremenskog prozora i f broj atributa.

- LSTM

Model koji koristi LSTM ima jedan LSTM sloj od 32 neurona koji koristi relu aktivacionu funkciju, dropout sloj podešen na 0.2 i potpuno povezan sloj.

- CNN

Model koji koristi CNN sadrži:

- jednodimenzionalni konvolutivni sloj sa 32 neurona, relu aktivacionom funkcijom i filterom veličine 3
- sloj za agregaciju
- dropout sloj postavljen na 0.2
- potpuno povezan sloj

- Transformer

Enkoder koji se koristi u ovom radu sadrži 4 bloka. Blok se sastoji iz ćelije pažnje sa 11 glava i potpuno povezanog sloja koji je implementiran jedno-dimenzionalnim konvolutivnim slojem koji ima filter veličine 4. Jedna glava pažnje koristi matrice dimenzije 32. Potpuno povezan sloj koji je izlaz iz enkodera ima 32 neurona. Dropout slojevi su postavljeni na 0.2.

Glava 4

Analiza rezultata

U ovom poglavlju će se analizirati i porediti modeli koji su korišćeni. Prvo će se analizirati rezultati za modele koji služe za predikciju temperatura, a zatim modeli koji služe za predikciju padavina.

Upotrebljene su tri vrste neuronskih mreža: LSTM, CNN i transformeri. Za svaku od njih je treniran model koji prima samo ulazne podatke i model koji prima ulazne podatke i informaciju o danu u godini. Za svaku od tih kombinacija, trenirana su dva modela: jedan koristi MSE, a drugi SERA kao funkciju greške.

4.1 Analiza rezultata za temperature

S obzirom da je ukupno trenirano 18 modela, neće svaki ponaosob biti pomenut, već će se porediti grupe modela. Prvo će se porediti grupa modela koja prima samo ulazne podatke sa modelima koji, uz ulazne podatke, primaju i informaciju o danu u godini. Nakon toga će se porediti grupa modela koji koriste MSE kao funkciju greške sa grupom modela koji koriste funkciju SERA. Zatim će se prikazati autoregresivni modeli koji će služiti kao reper ostalim modelima. Sve prethodne analize će biti prikazane nad podacima za Beograd. U poslednjoj sekciji će biti upoređeni rezultati za sve gradove. Za poređenje gradova, biće prikazani rezultati modela koji su uz ulazne podatke primili i podatak o danu u godini.

Poređenje modela koji koriste informaciju o danu u godini sa modelima koji koriste samo ulazne podatke

Svi modeli koji su koristili samo ulazne podatke su bili skloni preprilagođavanju. To je prikazano na tabelama 4.1 i 4.2 gde se mogu uporediti greške na trening skupu i validacionom skupu za modele koji primaju samo ulazne podatke. Grafici greške svih modela za trening skup su bili ujednačeni, dok su za validaciju oscilovali, pogotovo za modele koji koriste CNN. Uprkos tome, grafici predikcija uglavnom uspevaju da isprate opšti trend ciljnih promenljivih. Na slikama 4.1 i 4.2 prikazani su grafici greške za model koji koristi CNN. Na 4.1 je grafik modela koji koristi MSE, a na 4.2 je grafik modela koji koristi SERA kao funkciju greške. Na levom grafiku je prikazana funkcija greške, a na desnom druga funkcija kao metrika. Na slikama 4.3, 4.4 i 4.5 za isti model prikazani su grafici predikcija ciljnih promenljivih za trening, validacioni i test skup. Predikcije trening skupa dosledno prate sezonalni šablon što znači da prave godišnje oscilacije slične amplitude kao oscilacije ciljnih promenljivih. Predikcije validacionog i test skupa takođe prave godišnje oscilacije koje prate oscilacije ciljnih promenljivih ali imaju vidno manju amplitudu. Ovo je pokazatelj preprilagođenosti modela.


Tabela 4.1: Ocena modela koji koriste MSE

	LSTM	CNN	Transformer
trening	0.0062	0.0085	0.0078
validacija	0.0188	0.0160	0.0160
test	0.0177	0.0158	0.0201


Tabela 4.2: Ocena modela koji koriste SERA

	LSTM	CNN	Transformer
trening	170.50	220.00	190.87
validacija	472.80	500.40	518.90
test	617.98	554.69	558.04


GLAVA 4. ANALIZA REZULTATA




Slika 4.1: Grafik greške za CNN model sa funkcijom greške MSE




Slika 4.2: Grafik greške za CNN model sa funkcijom greške SERA



Slika 4.3: Grafik predikcija na trening skupu za CNN model sa funkcijom greške MSE



Slika 4.4: Grafik predikcija na validacionom skupu za CNN model sa funkcijom greške MSE



Slika 4.5: Grafik predikcija na test skupu za CNN model sa funkcijom greške MSE

Modeli koji su primili informaciju o danu u godini uz ostale ulazne podatke su se značajno bolje pokazali. Ocene su bile bolje i preprilagođavanje je bilo manje. U tabelama 4.3 i 4.4 se mogu uporediti vrednosti funkcije greške na test skupu za modele koji koriste samo ulazne promenljive i za modele koji koriste informaciju o danu u godini. Na slikama 4.6 i 4.7 su upoređeni grafici predikcija na test skupu transformer modela sa funkcijom greške MSE koji prima samo indekse i modela koji uz indekse prima dan u godini. Grafik predikcija modela koji uz indekse prima dan u godini dosta jasnije prati grafik ciljnih promenljivih.

Dan u godini je vrednost između 1 i 365¹ koja je ciklične prirode. To znači da je prvi dan u godini bliži poslednjem nego što je trećem. Dan u godini će biti predstavljen sa dva atributa koji će se računati na sledeći način:

$$S_c = \cos\left(\frac{2\pi(d-15)}{365}\right)$$

$$S_s = \sin\left(\frac{2\pi(d-15)}{365}\right)$$

gde je d redni broj dana u godini.

Smanjivanjem dana u godini za 15 se postiže da atributi imaju maksimalne i minimalne vrednosti u sredini godišnjih doba (15.januar, 16.april, 17.jul i 16.oktobar).


Tabela 4.3: Vrednost funkcije greške modela koji koriste MSE

	LSTM	CNN	Transformer
bez dana u godini	0.0177	0.0158	0.02010
sa danom u godini	0.0045	0.0068	0.0053


Tabela 4.4: Vrednost funkcije greške modela koji koriste SERA

	LSTM	CNN	Transformer
bez dana u godini	617.98	554.69	558.04
sa danom u godini	135.92	160.49	143.81

¹S obzirom da za ovu namenu nemaju poseban uticaj, zanemarićemo prestupne godine radi lakšeg računa.



Slika 4.6: Grafik predikcija na test skupu za transformer model sa funkcijom greške MSE koji prima samo indekse



Slika 4.7: Grafik predikcija na test skupu za transformer model sa funkcijom greške MSE koji prima indekse i dan u godini


Poređenje funkcija greške: MSE i SERA

Modeli koji su koristili MSE kao funkciju greške su imali manji opseg predikcija od opsega pravih vrednosti. Cilj uvođenja funkcije SERA je bio da se proširi opseg predikcija, a da se ukupna greška modela ne poveća značajno.

Sve kombinacije modela su imale slične gornje granice opsega predikcija, koje su bile 6-8 strepeni manje od gornjih granica opsega pravih vrednosti. Modeli koji su koristili LSTM i transformere i primali samo ulazne podatke su imali značajno više donje granice opsega predikcija od donjih granica opsega pravih vrednosti. Ostali modeli su isto imali više donje granice opsega predikcija mada ne toliko.

Korišćenje funkcije SERA kod svih modela omogućilo je da se proširi donja granica opsega predikcija, ali ne i gornja. Treba istaći da korišćenje funkcije SERA nije smanjilo gornju granicu predikcija. Modeli koji su primali samo ulazne podatke imali su manju opštu preciznost kada je korišćena SERA kao funkcija greške u odnosu na iste modele koji su koristili MSE. Slično se može reći za modele koji su primili informaciju o danu u godinu uz ulazne podatke ali kod tih modela razlika u preciznosti nije toliko značajna.

Funkcija SERA značajno menja raspodelu predikcija u odnosu na MSE. To se može videti poređenjem histograma predikcija na test skupu modela koji koriste MSE i modela koji koriste SERA. Na slici 4.8 je histogram predikcija LSTM modela koji koristi samo ulazne podatke i MSE, a na slici 4.9 histogram predikcija LSTM modela koji koristi samo ulazne podatke i SERA. Na slikama 4.10 i 4.11 su histogrami predikcija transformer modela koji koriste samo ulazne podatke. Prvi model koristi MSE, a drugi SERA. Vrednosti pri kraju opsega su više zastupljene. Iako je ova promena preterana i ne doprinosi poboljšanju modela, ona je u skladu sa svrhom funkcije SERA i dokaz je da je moguće promeniti raspodelu predikcija tako da su više zastupljene ekstremne vrednosti. S obzirom da funkcija relevantnosti određuje šta su ekstremne vrednosti za dati problem, izbor ove funkcije značajno utiče na rezultat primene SERA. Boljim izborom funkcije, promena raspodele se može regulisati. Dalji pravac istraživanja bi uključivao eksperimentisanje sa funkcijama relevantnosti koje bi više odgovarale domenu ovog rada.



Slika 4.11: Histogrami predikcija test skupa transformer modela koji koristi samo ulazne promenljive i SERA

Poređenje sa autoregresivnim modelom

Temperature iz prethodnog perioda sadrže u sebi implicitne informacije o svim meteorološkim pojavama koje utiču na njih. Pitanje je koji udeo toga mogu da objasne indeksi atmosfere cirkulacije. Zato će se autoregresivni modeli koristiti kao reper ostalim modelima. U tabelama 4.5 i 4.6 su prikazane vrednosti funkcije greške na test skupu koje porede autoregresivne modele sa ostalim modelima.

Tabela 4.5: Poređenje funkcije greške sa autoregresivnim modelom (MSE)


	LSTM	CNN	Transformer
Indeksi	0.0177	0.0158	0.0201
Indeksi sa danom	0.0045	0.0068	0.0053
Autoregresivni model	0.0027	0.0039	0.0095

Tabela 4.6: Poređenje funkcije greške sa autoregresivnim modelom (SERA)


	LSTM	CNN	Transformer
Indeksi	617.98	554.69	558.04
Indeksi sa danom	135.92	160.49	143.81
Autoregresivni model	72.26	95.57	214.05

Autoregresivni modeli koji su koristili LSTM i CNN su imali manje vrednosti funkcije greške u poređenju sa istim modelima koji su koristili ulazne podatke sa danima u godini. Na slikama 4.12 i 4.13 upoređene su predikcije na test skupu CNN modela koji prima ulazne podatke i informaciju o danu u godini i autoregresivnog CNN modela. Oba modela uspevaju da isprate sezonski šablon ciljnih promenljivih ali predikcije autoregresivnog modela su imale veće poklapanje lokalnih oscilacija sa ciljnim promenljivama nego predikcije modela koji koristi indekse.


Suprotno se pokazalo za transformere. Greške su bile veće nego kod modela koji su primali ulazne podatke i dane. Predikcija ekstrema je takođe bila lošija. Predikcije autoregresivnog modela uspevaju da naprave adekvatne godišnje oscilacije ali nemaju lokalnu varijabilnost koju imaju ciljne promenljive. Na slikama 4.14 i 4.15 upoređene su predikcije na test skupu transformera koji prima ulazne podatke i informaciju o danu u godini i transformera koji prima prethodne temperature.




Slika 4.12: Predikcije CNN modela sa danom i funkcijom greške MSE



Slika 4.13: Predikcije autoregresivnog CNN modela sa funkcijom greške MSE



Slika 4.14: Predikcije transformera sa danom i funkcijom greške MSE



Slika 4.15: Predikcije autoregresivnog transformera sa funkcijom greške MSE

Poređenje rezultata u različitim gradovima

Poređiće se modeli koji koriste informaciju o danu u godini za različite gradove. Svi gradovi imaju slične rezultate modela, što je i očekivano. Vrednost funkcije greške je slična i u slučaju MSE i u slučaju SERA. U tabelama 4.7 4.8 su prikazane ocene modela na test skupu svih gradova.

Tabela 4.7: Funkcija greške modela koji koriste MSE za različite gradove


	LSTM	CNN	Transformer
Beograd	0.0046	0.0057	0.0054
Kikinda	0.0044	0.0049	0.0049
Niš	0.0052	0.0055	0.0059
Novi Sad	0.0046	0.0050	0.0048
Požega	0.0051	0.0055	0.0057
Smederevska Palanka	0.0048	0.0064	0.0047
Sombor	0.0054	0.0059	0.0057
Kragujevac	0.0048	0.0063	0.0053
Veliko Gradište	0.0050	0.0054	0.0051
Loznica	0.0049	0.0076	0.0062
Palić	0.0051	0.0082	0.0054
Valjevo	0.0051	0.0053	0.0057

Tabela 4.8: Funkcija greške modela koji koriste SERA za različite gradove

	LSTM	CNN	Transformer
Beograd	145.48	193.13	129.57
Kikinda	168.85	169.08	189.28
Niš	164.12	175.28	165.69
Novi Sad	143.43	205.40	141.21
Požega	143.86	233.64	197.48
Smederevska Palanka	158.64	137.07	155.36
Sombor	187.40	238.33	180.36
Kragujevac	153.82	186.22	196.18
Veliko Gradište	154.33	188.52	169.06
Loznica	172.47	168.08	184.29
Palić	172.44	182.91	197.72
Valjevo	134.12	183.87	153.71

4.2 Analiza rezultata za padavine

Nijedan model koji je pomenut za predikciju temperatura nije bio uspešan za predikciju padavina, čak ni autoregresivni. Greška svih modela je tokom treniranja bila skoro konstanta i za sve modele MSE ocena je bila oko 0.003. Prave vrednosti padavina su uglavnom blizu 0, dok je većina predikcija svih modela bila iznad 0. To se može primetiti na slici 4.16 koja prikazuje histogram pravih vrednosti i histogram predikcija na test skupu za LSTM autoregresivni model koji koristi MSE. Funkcija SERA nije doprinela poboljšanju modela. Moguće je da bi se predikcije modela popravile promenom funkcije relevantnosti, ali istraživanje tog tipa prevazilazi opseg ovog rada.



Slika 4.16: Histogrami ciljnih promenljivih i histogram predikcija autoregresivnog LSTM modela koji koristi MSE

Glava 5

Zaključak

Iako su svi modeli za predviđanje temperatura koji su koristili samo ulazne podatke bili skloni preprilagođavanju, dodavanje informacije o danu u godini uz ostale ulazne podatke je značajno poboljšalo kvalitet svih modela. Ocene su bile bolje i preprilagođavanje je bilo manje.

Predikcija ekstremnih vrednosti je bila loša jer je opseg predikcija svih modela bio manji od opsega ciljnih promenljivih. Korišćenje funkcije SERA kod svih modela omogućilo je da se proširi donja granica opsega predikcija, ali nije promenilo gornju. Takođe, funkcija SERA značajno menja raspodelu predikcija u odnosu na MSE tako da su vrednosti pri kraju opsega više zastupljene. Iako je ova promena prevelika da bi doprinela poboljšanju modela, ona ukazuje da bi se boljim izborom funkcije relevantnosti predikcija ekstrema možda mogla popraviti.

Autoregresivni modeli za predikciju temperatura koji su koristili LSTM i CNN su imali kvalitetnije rezultate u poređenju sa istim modelima koji su koristili ulazne podatke sa danima u godini. Suprotno se pokazalo za autoregresivne modele koji su koristili transformere.

Uspešnost modela za predikciju temperatura za različite gradove je bila slična. To ukazuje da nijedno područje u Srbiji nema jaču vezu sa indeksima cirkulacije atmosfere u odnosu na ostale.

Nijedan model koji je pomenut za predikciju temperatura nije bio uspešan za predikciju padavina, čak ni autoregresivni. Svi modeli su imali sličnu vrednost funkcije greške, opseg i raspodelu predikcija.

Rezultati ovog rada ukazuju na postojanje veze indeksa cirkulacije atmosfere sa temperaturama, ali ne i sa padavinama u Srbiji. U daljem tekstu biće navedeni sledeći koraci u istraživanju.

S obzirom da su modeli za predikciju temperatura lošiji od autoregresivnih modela, oni se ne mogu koristiti za efikasnu vremensku prognozu. Međutim, predikcije temperatura navedenih modela prate opšti šablon pravih vrednosti što pokazuje da postoji veza između indeksa atmosferske cirkulacije i temperatura u Srbiji. Dodavanje informacije o danu u godini je popravilo rezultate dovoljno da se postavi pitanje koji podaci bi mogli da se dodaju ovim modelima da predikcija temperatura bude preciznija.

Dalje istraživanje može da obuhvati eksperimentisanje novim podacima. Pošto je dodavanje informacije o danu u godinu znatno poboljšalo model, moguće je da bi dodavanjem nove meteorološke informacije modeli bili uspešniji.

Napredak je možda moguće napraviti i kompleksnijim modelima. U ovom radu su se koristile jednostavne arhitekture. Dodavanje slojeva i podešavanje hiperparametara neuronske mreže bi možda moglo da popravi rezultate. Istraživanja koja pokazuju da kombinovanje raznih tipova mreža može da popravi predikcije vremenskih serija [11] se mogu koristiti za unapređenje modela.

Jedan od daljih pravaca razvoja bi mogao da uključuje istraživanje preciznije predikcije ekstremnih vrednosti. U ovom radu problem predikcije ekstremnih temperatura [15] je rešavan korišćenjem tehnika iz domena nebalansirane regresije [12] u vidu upotrebe funkcije SERA. Ovakva funkcija greške dosta zavisi od izbora funkcije relevantnosti koja definiše šta se smatra ekstremnom vrednošću u datom domenu. Istraživanje koje bi ponudilo adekvatniju funkciju relevantnosti bi moglo značajno da utiče na rezultate modela iz ovog rada.

Modeli za predikciju padavina su bili nedovoljno uspešni da ukažu na postojanje veze između količine padavina u Srbiji i indeksa atmosferske cirkulacije. S obzirom da su svi modeli dali slične rezultate, moguće je da padavine u Srbiji nisu korelisane sa indeksima atmosferske cirkulacije.

S obzirom na prirodu podataka, sledeći korak u istraživanju bi trebalo da se bavi predikcijom ekstremnih vrednosti. To bi moglo da uključuje definisanje funkcije relevantnosti koja je pogodna za predikciju količine padavina.

Bibliografija

- [1] Michele Brunetti and Haim Kutiel. The relevance of the North Sea-Caspian pattern (NCP) in explaining temperature variability in Europe and the Mediterranean. *Natural Hazards and Earth System Sciences - NAT HAZARDS EARTH SYST SCI*, 11:2881–2888, 10 2011.
- [2] Francisco Criado-Aldeanueva and Javier Soto-Navarro. Climatic indices over the Mediterranean sea: A review. *Applied Sciences*, 10:5790, 08 2020.
- [3] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9:1735–80, 12 1997.
- [4] Arnulf Jentzen, Benno Kuckuck, and Philippe von Wurstemberger. *Mathematical Introduction to Deep Learning: Methods, Implementations, and Theory*. 10 2023.
- [5] Nikhil Ketkar and Jojo Moolayil. *Convolutional Neural Networks*, pages 197–242. Apress, Berkeley, CA, 2021.
- [6] Haim Kutiel and Y. Benaroch. North Sea-Caspian pattern (ncp)– an upper level atmospheric teleconnection affecting the eastern Mediterranean: Identification and definition. *Theoretical and Applied Climatology*, 71:17–28, 01 2002.
- [7] Gisela Müller-Plath, Horst-Joachim Lüdecke, and Sebastian Luening. Long-distance air pressure differences correlate with European rain. *Scientific Reports*, 12:10191, 06 2022.
- [8] Theodoros Ntakouris. Timeseries classification with a Transformer model , 2021. on-line at: https://keras.io/examples/timeseries/timeseries_classification_transformer/.
- [9] Intergovernmental Panel on Climate Change (IPCC). *Annex VII: Glossary*, page 2215–2256. Cambridge University Press, 2023.

- [10] Suzana Putniković, Ivana Tošić, and Vladimir Đurđević. Circulation weather types and their influence on precipitation in serbia. *Meteorology and Atmospheric Physics*, 128:649–662, 10 2016.
- [11] Jingyi Qu, Min Xiao, Liu Yang, and Wenkai Xie. Flight delay regression prediction model based on att-conv-lstm. *Entropy (Basel, Switzerland)*, 25, 05 2023.
- [12] Rita Ribeiro and Nuno Moniz. Imbalanced regression and extreme value prediction. *Machine Learning*, 109:1–33, 09 2020.
- [13] Teija Seitola and Heikki Järvinen. Decadal climate variability and potential predictability in the nordic region: A review. *Boreal Environment Research*, 19:387–407, 11 2014.
- [14] Cenk Sezen and Turgay Partal. The effects of Mediterranean oscillation on temperature and precipitation data in Turkey. *Journal of Water and Climate Change*, 11, 02 2019.
- [15] Ivana Tošić, Suzana Putniković, Milica Tosić, and Irida Lazić. Extreme temperature events in serbia in relation to atmospheric circulation. *Atmosphere*, 12:1584, 11 2021.
- [16] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan Gomez, Lukasz Kaiser, and Illia Polosukhin. Attention is all you need. 06 2017.
- [17] Jianxin Wu. Introduction to convolutional neural networks. 2017.
- [18] Ferat Çağlar, Omer Yetemen, Kwok Pan Chun, and Omer Lutfi Sen. The merit of the North Sea-Caspian pattern in explaining climate variability in the Euro-Mediterranean region. *International Journal of Climatology*, 43(10):4648–4661, 2023.