



Univerzitet Singidunum
Departman za posleddiplomske studije

Doktorska disertacija

**UNAPREĐENJE PRECIZNOSTI PREDVIĐANJA STOPE
NEZAPOSLENOSTI PRIMENOM MODELA
REKURENTNIH NEURONSKIH MREŽA
OPTIMIZOVANIH METAHEURISTIKAMA**

Mentor:

prof. dr Nebojša Bačanin-Džakula

Student:

Jelena Čađenović

Beograd, 2026.

UNIVERZITET SINGIDUNUM
DEPARTMAN ZA POSLEDIPLOMSKE STUDIJE
Danijelova 32, Beograd

Kandidat: Jelena Čađenović, master inženjersih sistema u menadžmentu

Broj ineksa: 2012/465111

Studijski program: Inženjerski sistemi u menadžmentu

Tema:

UNAPREĐENJE PRECIZNOSTI PREDVIĐANJA STOPE NEZAPOSLENOSTI PRIMENOM
MODELA REKURENTNIH NEURONSKIH MREŽA OPTIMIZOVANIH
METAHEURISTIKAMA

Mentor:

Prof. dr Nebojša Bačanin-Džakula
Redovni profesor Univerziteta Singidunum, Beograd

Članovi Komisije:

Prof. dr Miodrag Živković
Redovni profesor Univerziteta Singidunum, Beograd

Prof. dr Boško Nikolić
Redovni profesor Univerziteta u Beogradu

ZAHVALNICA

Posvećujem ovu disertaciju sebi i svojim potomcima, svesna odricanja, rada i zalaganja koje sam uložila na putu do njenog završetka. Neka bude podsetnik na snagu istrajnost, strpljenje i veru u znanje, kao i podstrek generacijama koje dolaze da hrabro slede svoje ciljeve. Zahvaljujem se svojim mentorima koji su me još tokom master studija nadahnuli i “zarazili” ljubavlju prema nauci i istraživanju. Posebnu zahvalnost dugujem svom mentoru, profesoru dr Nebojši Bačaninu Džakuli, čiji su nesebičan pristup, izvanredni saveti i veliko znanje bili presudni da ovaj rad privedem kraju.

Veliko hvala mom Petru, koji je bio uz mene i pružao neverovatnu podršku u najtežim i najizazovnijim trenucima. Hvala na razumevanju, strpljenju i stalnom bodrenju da istrajam onda kada je bilo najteže.

Rad posvećujem i svom ocu, koji, nažalost, više nije sa nama, a koji mi je još od najranijeg detinjstva usadio važnost obrazovanja. Duboko sam zahvalna i svojoj majci, od koje sam naučila da sve što započnem uvek dosledno finalizujem i da se trudim da budem među najboljima.

Rezime

Praćenje trendova nezaposlenosti od ključnog je značaja, jer predstavlja ključni indikator opšteg stanja ekonomije, omogućavajući kreatorima politika, vladama i centralnim bankama da procene ekonomske uslove i, kada je potrebno, sprovedu delotvorne politike. Ovi trendovi takođe imaju duboke društvene implikacije, utičući na javno zdravlje, društvenu dobrobit i društvenu stabilnost. Povišene stope nezaposlenosti često su povezane sa porastom siromaštva, društvenom nejednakošću i izazovima u oblasti mentalnog zdravlja. Nadalje, trendovi nezaposlenosti služe kao prediktori budućih ekonomskih kretanja, što naglašava važnost tačnog prognoziranja za kreatore politika, ekonomiste i preduzeća širom sveta. Tradicionalne metode prognoziranja često ne uspevaju da identifikuju složene, nelinearne obrasce u podacima, čime se ograničava njihova prediktivna tačnost. Tehnike mašinskog učenja (ML) nude obećavajuću alternativu zahvaljujući sposobnosti obrade velikih skupova podataka, otkrivanja skrivenih relacija i prilagođavanja dinamičnim ekonomskim uslovima. Oslanjajući se na napredne algoritme, pristupi zasnovani na ML-u mogu značajno unaprediti preciznost predviđanja stope nezaposlenosti. Shodno tome, ovaj rad uvodi hibridni pristup prognoziranju nezaposlenosti, zasnovan na modelu long short-term memory (LSTM) sa mehanizmima pažnje. Radi optimizacije performansi modela, primenjena je varijanta algoritma optimizacije rojem čestica (PSO) za fino podešavanje njegovih hiperparametara. Simulacije sprovedene na podacima iz stvarnog sveta, uz rigorozne komparativne i statističke analize u poređenju sa drugim metodama, pokazuju obećavajuće rezultate, potvrđujući potencijal ovog pristupa za dalekosežne socioekonomske koristi.

Ova disertacija se primarno bavi rešavanjem problema predikcije vremenskih serija, odnosno nezaposlenosti, kroz primenu i optimizaciju postojećih modela veštačke inteligencije, poput neuronskih mreža.

Ključne reči: LSTM, Metaheuristike, PSO, Neuronske mreže, Vremenske serije

Abstract

Monitoring unemployment trends is crucial, as it serves as a key indicator of the overall state of the economy, enabling policymakers, governments, and central banks to assess economic conditions and implement effective policies when necessary. These trends also have profound social implications, impacting public health, social welfare, and social stability. Elevated unemployment rates are often associated with increased poverty, social inequality, and challenges in the field of mental health. Furthermore, unemployment trends act as predictors of future economic movements, highlighting the importance of accurate forecasting for policymakers, economists, and businesses worldwide. Traditional forecasting methods often fail to identify complex, nonlinear patterns within data, limiting their predictive accuracy. Machine learning (ML) techniques offer a promising alternative due to their capability to process large data sets, uncover hidden relationships, and adapt to dynamic economic conditions. By relying on advanced algorithms, ML-based approaches can significantly enhance the precision of unemployment rate predictions. Accordingly, this paper introduces a hybrid approach to unemployment forecasting, based on a long short-term memory (LSTM) model with attention mechanisms. To optimize the model's performance, a variant of the particle swarm optimization (PSO) algorithm was applied for fine-tuning its hyperparameters. Simulations conducted on real-world data, along with rigorous comparative and statistical analyses compared to other methods, demonstrate promising results, confirming the potential of this approach for far-reaching socioeconomic benefits.

Keywords: LSTM, ML, unemployment, Metaheuristics, PSO, Neural networks, Time series prediction.

SADRŽAJ

1	Uvod.....	9
1.1	Metodološke osnove istraživanja.....	10
1.1.1	Problem istraživanja.....	10
1.1.2	Predmet istraživanja.....	10
1.1.3	Ciljevi i zadaci istraživanja.....	12
1.1.4	Hipoteze u istraživanju.....	13
1.1.5	Metode istraživanja.....	14
1.1.6	Naučna i društvena opravdanost istraživanja i očekivani naučni doprinos.....	15
1.2	Struktura rada.....	17
2	Teorijska osnova istraživanja.....	19
2.1	O fenomenu nezaposlenosti i vrstama nezaposlenosti.....	19
2.2	Uticaj nezaposlenosti na globalno tržište i ekonomiju.....	Error! Bookmark not defined.
2.3.	Neki od glavnih ekonomskih indikatora ekonomskog rasta.....	Error! Bookmark not defined.
2.3.1	BDP.....	Error! Bookmark not defined.4
2.3.2	BNP.....	Error! Bookmark not defined.
2.3.3	Ostali makroekonomski indikatori.....	Error! Bookmark not defined.
2.4.	Primena Veštačke inteligencije na predikciju nezaposlenosti.....	30
2.4.1	Modeli vremenskih serija u predikciji nezaposlenosti.....	Error! Bookmark not defined.
3	Analiza dosadašnjih radova.....	Error! Bookmark not defined.
4	Mašinsko učenje i duboko učenje.....	39
4.1	O mašinskom učenju.....	39
4.2	Neuronske mreže.....	40
4.2.1.	Pojam biološkog i veštačkog neurona.....	40
4.2.2.	Duboke neuronske mreže.....	44
4.2.2.2.	Model DNN.....	44
4.2.2.3.	Model CNN.....	44
4.2.2.4.	Model RNN.....	44
4.2.2.5	LSTM i GRU modeli.....	Error! Bookmark not defined.
4.2.2.5.	LSTM model.....	46

4.2.2.6	GRU model	48
4.3	Model zasnovan na mehanizmu pažnje.....	50
4.4.	Problem odabira hiperparametara u dubokom učenju	51
5	Algoritmi optimizacije hiperparametara	52
5.1	Heurističke tehnike optimizacije.....	52
5.1.1.	Mrežna pretraga.....	53
5.2	Metaheurističke tehnike.....	54
5.3	Pregled algoritma čestica rojeva PSO.....	57
5.3.1	Teorijska osnova.....	57
5.3.2	Matematički model.....	59
6	Pregled istraživačkog dela.....	59
6.1.1	Opis istraživanja.....	59
6.1.2	Korišćene procedure i tehnike	60
6.1.2.1	Polazni (baseline) algoritam optimizacije rojem čestica.....	61
6.1.2.2	Modifikovani algoritam optimizacije rojem čestica	63
6.1.2.3	Procedura inicijalizacije zasnovana na kvazi reflektivnom učenju	63
6.1.2.4	Procedura za procenu raznolikosti populacije.....	64
6.1.2.5	Predloženi algoritam EAPSO	68
6.2.	Eksperimentalna postavka	85
6.2.1	Primenjeni kriterijumi za ocenjivanje.....	72
6.2.2	Konačni rezultati LSTM simulacije	74
6.2.3	LSTM-ATT simulacija rezultati.....	79
6.2.4	Statistička validacija rezultata.....	84
7	Zaključak	87
	Literatura.....	89
	PRILOZI.....	99
7.1	Prilog A – Pseudokovi metaheurističkih algoritama	99
7.1.1	PSO Algoritam.....	99
7.1.2	Bat Algoritam (BA)	100
7.1.3	Firefly (FA).....	101
7.1.4	Genski Algoritam (GA).....	102
7.2	Prilog B – Pseudokovi modela neuronskih mreža	103

7.2.1	<i>Algoritam Rekurentne Neuronske mreže.....</i>	<i>1043</i>
7.2.2	<i>Algoritam Dugoročno-kratkoročne memorije</i>	<i>105</i>
7.2.3	<i>Algoritam Zatvorene rekurentne jedinice (GRU)</i>	<i>106</i>
Spisak akronima.....		107
Spisak oznaka		109
Spisak tabela.....		111
Spisak slika		112
Spisak formula		113

1 Uvod

U savremenom poslovnom okruženju praćenje i analiza trenda nezaposlenosti od presudne je važnosti s obzirom na to da se nezaposlenost smatra jednim od najvažnijih indikatora opšteg stanja ekonomije. Povišene stope nezaposlenosti u korelaciji su sa porastom siromaštva, povećanjem društvene nejednakosti, te na kraju izazovima u oblasti mentalnog zdravlja što znači da trend nezaposlenosti ima društvene posledice koje se manifestuju kroz društvenu stabilnost, dobrobit i javno zdravlje. Tako dakle na globalnom nivou nezaposlenost ispoljava heterogene trendove u smislu da je uslovljena različitim faktorima poput ekonomskih, političkih, geopolitičkih, tehnoloških, demografskih. Navedeni faktori često se i prepliću, te utiču jedni na druge čineći analizu i predikciju fenomena nezaposlenosti dodatno kompleksnijom. Ako posmatramo najrazvijenije ekonomije sveta uvidećemo da je stopa nezaposlenosti u proseku stabilnija ali je sa druge strane podložna fluktuacijama usled različitih faktora uticaja poput pandemije COVID-19, svetske ekonomske krize, globalizacije, ratova, političkih previranja u vidu uvođenja sankcija, carina i slično. Svi navedeni faktori privremeno utiču i remete stabilnost ustaljenih tokova što može rezultirati skokovima u stopama nezaposlenosti ali i usporenog i otežanog oporavka tržišta rada. Iz svega navedenog proizilazi da globalna nezaposlenost zahteva multidisciplinarni pristup koji podrazumeva strateško planiranje politike tržišta rada, ulaganje u ljudske resurse, znanje, inovativne mehanizme socijalne zaštite, a posebno prilagođavanje obrazovnog sistema potrebama savremenom tržištu rada. Stoga shvatamo značaj praćenja i analize nezaposlenosti jer služe kao važan prediktor budućih ekonomskih kretanja što ukazuje na potrebu za tačnim prognoziranjem kako bi različiti akteri jednog društva poput ekonomista, političara pravovremeno delovali. U kontekstu obrađivanja velike količine podataka pri analizi nezaposlenosti, tradicionalne metode prognoziranja često su neuspešne jer ne uspevaju da identifikuju složene i nelinearne obrazce u podacima što dovodi do ograničene prediktivne tačnosti. Obećavajuću alternativu međutim predstavljaju tehnike mašinskog učenja upravo zahvaljujući mogućnosti obrade velikog skupa podataka. Pa tako oslanjajući se na napredne algoritme pristupi zasnovani na mašinskom učenju značajno unapređuju preciznost predviđanja stope nezaposlenosti.

1.1 Metodološke osnove istraživanja

1.1.1 Problem istraživanja

Tačnost predviđanja nezaposlenosti umnogome zavisi od kvaliteta i relevantnosti ulaznih podataka, a sem toga na pouzdanost prognoze nezaposlenosti utiču geopolitički, globalni ekonomski trendovi, kao i društveni činioci. Jedan od većih izazova jeste dostupnost i pouzdanost visokokvalitetnih podataka budući da su ekonomski indikatori kao takvi često podložni promenama i kašnjenju. Sa druge strane, modeli mašinskog učenja bivaju neretko kritikovani zbog nedostataka u vidu objašnjivosti, te se kao takvima ne raspolaže sa dovoljnim poverenjem. Stoga modeli mašinskog učenja moraju biti pažljivo prilagođeni svakom konkretnom problemu prognoziranja kroz fino podešavanje hiperparametara, odnosno njihove optimizacije, jer univerzalni model jednostavno ne postoji, posebno kod kompleksnih modela za predviđanje vremenskih serija neophodno je razviti pristup koji primenjuje metaheurističke algoritme kako bi se rešio izazov.

Prema teoremi "nema besplatnog ručka", ne postoji univerzalni algoritam koji je optimalan za sve probleme. Stoga je neophodno prilagođavanje modela mašinskog učenja specifičnim skupovima podataka, što uključuje optimizaciju hiperparametara kao što su broj epoha, struktura slojeva, broj neurona i stopa učenja. Ovaj proces predstavlja NP-težak optimizacioni problem, za čije rešavanje se često koriste metaheurističke metode, stoga standardne determinističke tehnike nisu primenjive te je neophodan stohastički pristup.

Metaheuristike inspirisane inteligencijom rojeva, kao što su algoritmi zasnovani na ponašanju mrava, pčela ili čestica, pokazale su se efikasnim u rešavanju globalnih i kombinatornih NP-teških problema. One nude zadovoljavajuća suboptimalna rešenja u razumnom vremenskom okviru, često nadmašujući tradicionalne metode u pogledu brzine konvergencije i kvaliteta rešenja.

1.1.2 Predmet istraživanja

Pošto možemo reći da veći broj faktora utiče na nezaposlenost kao i da problem predviđanja nezaposlenosti sveukupno predstavlja multivarijntni problem predviđanja vremenskih

serija, tako se kroz ovaj rad primenjuju multivarijantne vremenske serije algoritama za predviđanje, koji koriste istorijske podatke kao i brojne ekonomske indikatore za predviđanje nezaposlenosti u budućnosti.

Kako bi se poboljšala tačnost predviđanja, uveden je modifikovani metaheuristički algoritam, koji se fokusira na optimizaciju hiperparametara kako bi poboljšao performanse osnovnog modela. Ovaj novi pristup ima za cilj da reši izazove koje postavlja nelinearna i dinamična priroda podataka o nezaposlenosti. Efikasnost predloženih metoda ocenjena je kroz simulacije koje su sprovedene koristeći javno dostupne stvarne podatke iz uglednih institucija. Unapređivanjem modela predviđanja, ovaj rad doprinosi pouzdanijim prognozama nezaposlenosti, podržavajući bolju politiku i donošenje odluka u ekonomskom planiranju.

Predmet teorijskog dela istraživačkog rada se svodi na primenu metoda višekriterijumske analize postojećih modela i tehnika koje se koriste u rešavanju navedenog problema, kako bi se odabrao adekvatan početni model koji će kasnije poslužiti kao osnov za definisanje hipoteza i njegovo dalje unapređenje.

Praktični deo istraživanja je usmeren ka opisu konkretnih koraka unapređenja preciznosti predikcije nezaposlenosti kao glavnog problema. Akcenat je stavljen na razvoj i implementaciju unapređenog modela koji kombinuje arhitekturu neuronskih mreža i dugoročno-kratkoročne memorije (*eng. Long Short-Term Memory, LSTM*) sa metaheurističkom optimizacijom zasnovanom na algoritmu rojeva čestica (*eng. Particle Swarm Optimization, PSO*).

U skladu sa svim navedenim, predmet istraživanja doktorske disertacije može da se formuliše kao:

- sveobuhvatni pregled modela i algoritama predviđanja nezaposlenosti te i njihova korelacija a koji su raspoloživi u literaturi;
- unapređenje modela rekurentnih neuronskih mreža za multivarijantno predviđanje vremenskih serija nezaposlenosti
- optimizacija modela rekurentnih neuronskih mreža (LSTM, BiLSTM, GRU, itd) primenom metaheurističkih metoda optimizacije;

- detaljna komparativna analiza osnovnih (baseline) i unapređenih modela rekurentnih neuronskih mreža primenom metaheuristika sa isticanjem prednosti i nedostataka svake metode;
- interpretacija rezultata razvijenih modela najboljih performansi i generisanje značajanih informacija za stručnjake iz domena ekonomije tržišta rada i preduzetništva (osnaživanje samozaposlenja) sa ciljem umanjavanja stope nezaposlenosti.

1.1.3 Ciljevi i zadaci istraživanja

Na osnovu do sada publikovanih istraživanja u relevantnoj, dostupnoj literaturi, može se konstatovati da su metaheuristike zasnovane na inteligenciji rojeva, koje pripadaju kategoriji prirodom inspirisanih algoritama, ostvarile značajan uspeh u primeni, kako na standardnim benchmark testovima, tako i na praktičnim NP -teškim optimizacionim problemima (globalnim i kombinatornim). Sem toga, ovi algoritmi su pokazali superiornost u pogledu brzine konvergencije i kvaliteta rešenja, u odnosu na alternativne metode, tehnike i algoritme.

Dakle, za prilagođavanje RNN modela dubokog učenja za svaki specifičan skup podataka biće korišćene metaheuristike. Cilj je da se istraži kako primenom naprednih modela rekurentnih neuronskih mreža, uz korišćenje metaheurističkih metoda optimizacije može da se poboljša tačnost predviđanja stope nezaposlenosti.

Takođe, teži se ka tome da se najuspešniji modeli analiziraju korišćenjem metoda kao što su SHAP (SHapley Additive exPlanations), LIME (Local Interpretable Model-agnostic Explanations) i SAGE (Shapley Additive Global importance), koji omogućavaju objašnjenje odluka modela mašinskog učenja. Ove tehnike pružaju uvid u to koji faktori i u kojoj meri utiču na nezaposlenost, što može biti od značaja za donošenje daljih bitnih odluka kako bi se isti fenomen umanjio. Formulisanje problema optimizacije hiperparametara, kao i njegovo rešavanje korišćenjem metaheurističkog algoritma optimizacije rojem čestica (*eng. Particle Swarm Optimizer, PSO*)

- Testiranje predloženog modela i njegova eksperimentalna evaluacija na relevantnim skupovima realnih podataka koji su prikupljeni iz više različitih javno dostupnih izvora

- Poređenje performansi predloženog modela sa standardnim pristupima koji su se koristili za rešavanje istog problema

- Interpretacija dobijenih rezultata i generisanje značajnih informacija za stručnjake iz domena tržišta rada

1.1.4 Hipoteze u istraživanju

Analizom opisanog problema, predmeta kao i cilja ovog istraživanja, mogu se definisati sledeće **hipoteze**:

Opšta hipoteza:

Primenom do sada nedovoljno korišćenih modela rekurentnih neuronskih mreža za multivarijantno predviđanje stope nezaposlenosti, moguće je generisati bolja rešenja u smislu brzine konvergencije i kvaliteta rešenja (u kontekstu boljih metrika, MSE, MAE, RMSE, R2), čime će se unaprediti rezultati koje su druge metode optimizacije postigle za istu instancu problema.

Posebna hipoteza:

Na osnovu opšte hipoteze se može izdvojiti posebna hipoteza, koja se odnosi na sam predmet istraživanja, a koja glasi:

H1: Moguće je adaptirati i optimizovati postojeće implementacije modela rekurentnih neuronskih mreža za multivarijantno predviđanje vremenskih serija predviđanja stope nezaposlenosti

Daljim preciziranjem navedene posebne hipoteze, formulišu se pojedinačne koje se odnose na elementarne činioce predmeta istraživanja:

H1a: Moguće je adaptirati postojeće implementacije metaheuristika koje do sada nisu primenjivane u ovom domenu, za optimizaciju modela rekurentnih neuronskih mreža za predviđanje vremenskih serija.

H1b. Moguće je unaprediti postojeće implementacije metaheuristika rojeva, koje su ranije već bile primenjene u ovom domenu, za optimizaciju modela rekurentnih neuronskih mreža za predviđanje vremenskih serija.

H1c: Primenom adaptiranih modela rekurentnih neuronskih mreža i optimizacijom istih dobijeni rezultati istraživanja biće korišćeni od strane donosioca odluka i kreatora politika u svrhu umanjenja stope nezaposlenosti i iznalaženja pravovremenih rešenja.

1.1.5 Metode istraživanja

Da bi se razvile hipoteze koje su u skladu sa predmetom i ciljem istraživanja, biće primenjene metode istraživanja koje su uobičajene u praksi i naučno potvrđene: analitičko–sintetička metoda, deduktivno–induktivna metoda, komparativno-kvantitativna analiza, empirijska metoda, statistička analiza, modeliranje i eksperimentalni deo za dokazivanje hipoteza.

Analitičkim metodom će se obaviti analiza sadržaja relevantne naučne i stručne literature u ovoj oblasti, kao i relevantnih činjenica publikovanih putem elektronskih i drugih medija.

Sintetičkim metodom će se integrisati raščlanjeni analizirani elementi pojave u jednu celinu radi definisanja određenih pravila u ponašanju pojave koja je predmet istraživanja. Drugim rečima, svi prikupljeni podaci biće grupisani metodom sinteze, kako bi se došlo do pouzdanih zaključaka..

Korišćenje **deduktivno–induktivne** metode je u funkciji usmeravanja istraživanja od opšteg ka pojedinačnom, odnosno od pojedinačnog ka opštem u cilju dolaska do adekvatnih zaključaka.

U okviru **komparativno-kvantitativne** analize, a u korelaciji sa ciljevima i problemom istraživanja, kao najadekvatniji pristup izabrana je metoda analize. Konkretno, za analizu prikupljenih rezultata nakon primene metoda, tehnika i metaheuristika za rešavanje problema multivarijantnog predviđanja vremenskih serija cena goriva, koristiće se metoda **kvantitativne analize**.

Metodom **komparativne analize** upoređić se dobijeni rezultati optimizacije i izvešće se zaključak o stvarnom unapređenju rešavanja ovog problema primenom metaheurističkih optimizacionih algoritama.

Primenom **empirijske metode** prikupljeni primarni podaci će biti razmatrani i u svetlu diskutovanih postojećih teorijskih i empirijskih nalaza, odnosno sekundarnih izvora podataka,

kako bi se testirale polazne istraživačke hipoteze. Praktičnim eksperimentisanjem (izvršavanjem predloženog algoritma) dolazi se do primarnih podataka koji će se koristiti u daljoj analizi.

Statistička analiza podrazumeva korišćenje statističkih podataka i metoda u obradi dobijenih rezultata, a u skladu sa postavljenim istraživačkim ciljevima.

Modeliranje podrazumeva konstrukciju matematičkih modela koji predstavljaju validnu predstavu problema koji se proučava i rešava. Za rešavanje optimizacionih problema takođe se posmatraju matematički modeli i formulacije, kao i funkcije cilja problema istraživanja. U eksperimentalnom delu implementacije, sa dodatnim akcentom se sagledavaju tehnike metaheuristika u rešavanju prethodno pomenutog optimizacionog problema.

1.1.6 Naučna i društvena opravdanost istraživanja i očekivani naučni doprinos

Na osnovu do sada navedenog, mogu se konkretno izdvojiti očekivani naučni doprinosi:

- Analiziraće se različiti modeli i algoritmi mašinskog učenja koji se koriste za multivarijantno predviđanje vremenskih serija, uključujući njihovu klasifikaciju i karakteristike
- Istražiće se kako primenom naprednih modela rekurentnih neuronskih mreža, uz korišćenje metaheurističkih metoda optimizacije, može da se poboljša tačnost predviđanja stope nezaposlenosti.
- Izvršiće se poređenje performansi različitih modela mašinskog učenja u rešavanju ovog tipa problema, kao i analiza unapređenih modela optimizovanih različitim metaheurističkim pristupima koji su zastupljeni u literaturi
- Pristupiće se interpretaciji najboljih modela i generisanja korisnog znanja za eksperte iz domena ekonomije i preduzetništva, koje se može upotrebiti za donošenje boljih upravljačkih odluka kao i poboljšanje kvaliteta života, i dostizanje ekonomske stabilnosti

Takođe, može se utvrditi da ova disertacija doprinosi više stepena naučnog nivoa:

- **Fundamentalni (teorijski)** nivo, koji se odnosi na predlog i opis nove arhitekture neuronskih mreža i primena modifikovanog PSO algoritma u cilju predviđanja vremenskih serija i dobijanja što preciznijih rezultata.

- **Naučna klasifikacija**, koja se odnosi na metode višekriterijumske analize.

- **Naučno otkriće** se odnosi na razvoj nove metodologije primene neuronskih mreža i metaheurističke optimizacije sa jasno definisanim postupcima i evaluacijama.

- **Naučno objašnjenje** se odnosi na primenu predloženog modela na stvarnim podacima i izvođenje eksperimentálnih studija koje potvrđuju prednost novog pristupa u poređenju sa standardnim modelima i metodama koji su korišćeni u rešavanju istog problema.

Pored ovoga, možemo takođe pretpostaviti da je naučno istraživanje opravdano iz više razloga, među kojima se izdvajaju najrelevantniji:

- **Unapređenje oblasti predikcije vremenskih serija:** Ovim istraživanjem se ide korak napred ka poboljšanju i većoj inovativnosti na polju predviđanja vremenskih serija, pogotovu kada govorimo o nezaposlenosti. Ovime se rešavaju mnogi izazovi i problemi koji mogu nastati prilikom eksperimentisanja u ovim oblastima, a koji su nedovoljno dobro proučavani u dostupnoj literaturi.
- **Razvoj novih kombinovanih metoda:** Ovo istraživanje kombinuje dve napredne i vrlo popularne oblasti – neuronske mreže i metaheurističku optimizaciju, čime se značajno popularizuje pristup rešavanju određenih problema implementacijom hibridnih modela koji mogu biti primenjeni na širokom dijapazonu relevantnih podataka, u cilju dobijanja što boljih konačnih rezultata.
- **Bolje razumevanje optimizacije ovakvih modela:** Iako je ovo vrlo popularna oblast, i dalje postoji ograničen broj naučnih radova koji sistematski primenjuju metaheuristike u rešavanju različitih optimizacionih problema, a pogotovu kada je reč o predikciji vremenskih serija, koja je sama po sebi vrlo kompleksna oblast. Na osnovu ovoga se može zaključiti da je i sam potencijal primene ovakvih modela u rešavanju ovog problema nedovoljno istraživan. Stoga, ovaj

rad ima za cilj da pomogne u boljem razumevanju korišćenih tehnika i dodatno ohrabri njihovu primenu konkretno u rešavanju problema nezaposlenosti.

Sa druge strane, društvena opravdanosti istraživanja se može ogledati u sledećem:

- **Preciznije predikcije nezaposlenosti:** Pomaže se društvu, tržištima različitih ekonomija, preduzećima i donosiocima poslovnih odluka da bolje planiraju i donesu strateške odluke zasnovane na pouzdanim podacima. Ovime se omogućava bolja usklađenost sa svetskim tržištem, kao i veća adaptivnost vrlo čestim promenama koje nastaju u okviru nekih spoljašnjih činioca koji značajno mogu uticati na nezaposlenost
- **Podrška stabilnosti tržišta:** Donošenjem pravovremenih odluka koje su bazirane na preciznim rezultatima, omogućava se mnogo bolje i efikasnije upravljanje resursima, kao i uspostavljanje stabilnije kontrole nad njima.
- **Primena u nekim drugim ekonomskim modelima:** Jedna od osnovnih ideja ovog istraživanje je da, između ostalog, pokaže i kako predloženi model koji je razvijen ne mora biti nužno ograničen samo na problem predikcije nezaposlenosti. Kao što je u jednoj od prethodnih sekcija ovog rada napomenuto, jedan od ciljeva jeste i dovoljno dobro generalizovati predloženu arhitekturu, kako bi ona bila primenljiva u predikcijama i nekih drugih socioekonomskih vremenskih serija, kao što je predviđanje nezaposlenosti

1.2 Struktura rada

Disertacija će se sastojati iz uvoda, šest poglavlja i zaključka.

U uvodnom delu doktorske disertacije ukratko će biti izložen problem vezan za nezaposlenost, značaj tačnih prognoza, odnosno dobijenih rezultata za ekonomiju, te opisani izazovi u vezi sa dugoročnim i kratkoročnim predviđanjima vremenskih serija, koje ovaj rad ima za cilj da nadomesti. Takođe će biti razmatrani načini upotrebe modela Veštačke inteligencije, dodatno optimizovanih metaheurističkim algoritmom rojeva čestica, u rešavanju prethodno

napomenutog problema. Na kraju biće predstavljeni osnovni ciljevi i hipoteze istraživanja, kao i metodološki pristup koji se koristi i njegova naučno-društvena opravdanost.

Prvo poglavlje biće posvećeno osnovnim aspektima predviđanja nezaposlenosti, sa fokusom na ekonomske, političke i sociološke i druge faktore koji utiču na nezaposlenost. Biće istražene i dosadašnje tehnike koje se koriste za predviđanje nezaposlenosti, kao što su neki standardni ekonometrijski modeli, statističke metode, ali moderni pristupi koji se baziraju na modelima mašinskog učenja.

Drugo poglavlje će dati detaljan pregled i analizu dostupne literature i načinih istraživanja rađenih u okviru oblasti predikcije nezaposlenosti.

Treće poglavlje će predstaviti osnovne modele dubokog učenja, sa posebnim akcentom na rekurentne neuronske mreže (*eng. Recurrent Neural Networks, RNN*) i njihove podtipove, kao što su LSTM (*eng. Long Short-Term Memory*) i GRU (*eng. Gated Recurrent Unit*). Biće detaljno razmatrane matematičke osnove ovih modela, njihova primena u predviđanju vremenskih serija i prilagođavanje za specifične izazove predviđanja nezaposlenosti. Takođe, biće istražen značaj podešavanja hiperparametara u optimizaciji ovih modela.

U četvrtom poglavlju biće prikazana taksonomija optimizacionih algoritama. U ovom poglavlju biće razmatrana primena optimizacije rojem čestica (*eng. Particle Swarm Optimization, PSO*) u kontekstu unapređenja performansi rekurentnih neuronskih mreža za predviđanje nezaposlenosti. Detaljno će biti predstavljeni postupci integracije PSO sa RNN modelima, kao i kako ova kombinacija omogućava efikasnije učenje i predviđanje. Takođe, biće diskutovane prednosti i izazovi ovog pristupa u odnosu na standardne metode optimizacije.

U petom poglavlju, detaljnije će biti opisane i analizirane metaheuristike inteligencije rojeva u cilju predviđanja nezaposlenosti. Biće prikazani konkretni eksperimenti sa setovima podataka o nezaposlenosti, metodologija obrade podataka, kao i implementacija RNN modela sa PSO za optimizaciju hiperparametara. Biće analizirani rezultati implementacije i poređeni sa tradicionalnim metodama.

U okviru šestog, eksperimentalnog, poglavlja biće prikazana evaluacija razvijenih modela korišćenjem različitih metrika performansi, kao što su tačnost predviđanja, greške u predviđanju, i stabilnost modela. Biće razmotren uticaj optimizacije rojem čestica na poboljšanje tačnosti

modela u poređenju sa osnovnim rekurentnim mrežama bez optimizacije. Takođe, biće predstavljeni grafikoni i vizualizacije koji ilustruju dobijene rezultate. Dodatno će biti prikazana i interpretacija dobijenih ishoda, korišćenjem metoda poput SHAP/LIME, o kojoj će nešto kasnije biti više reči. Pozivajući se na čuvenu teoremu „nema besplatnog ručka“, u nastavku poglavlja biće predstavljeni i konkretni koraci za dalji razvoj modela i dodatno unapređenje njihovih performansi kroz dodatne optimizacije.

Na kraju disertacije biće iznet zaključak uz dodatnu diskusiju o ostalim mogućim pravcima razvoja i poboljšanja u ovoj oblasti.

2 Teorijska osnova istraživanja

2.1 O fenomenu nezaposlenosti i vrstama nezaposlenosti

Nezaposlenost predstavlja ekonomsko odnosno društveno stanje u kome deo radno sposobnog stanovništva aktivno traži zaposlenje, pri čemu ostaje bez prilike da iskoristi svoje radne kapacitete i potencijale. Odnosno, u užem smislu, nezaposlenost posmatramo kao odsustvo stabilnog radnog odnosa te i redovnih prihoda, dok u širem kontekstu nezaposlenost podrazumeva narušavanje ekonomskog, socijalnog, psihološkog blagostanja pojedinca ali i zajednice kojoj pripada.

Ako govorimo o stopi nezaposlenosti, ona predstavlja jedan od bitnijih pokazatelja „zdravlja“ ekonomije i društva, te tako visoka stopa nezaposlenosti upravo ukazuje na više problema kao što su nizak nivo privredne aktivnosti, nedovoljna eksploataciju ljudskih resursa, što za posledicu ima nizak kvalitet života jednog društva.

Postoji nekoliko različitih tipova nezaposlenosti u zavisnosti od namene i ciljeva konkretne analize. Najčešća klasifikacija nezaposlenosti jeste prema uzrocima pa tada govorimo o **frikcionalnoj nezaposlenosti, strukturnoj i cikličnoj**. **Frikcionalna nezaposlenost** podrazumeva promenu posla odnosno kada zaposleni iz različitih razloga (preseljenje, sezonska potražnja posla, potraga za boljom poslovnom prilikom) menjaju radno mesto, ovaj oblik nezaposlenosti je česta pojava na tržištu rada i smatra se normalnom. **Strukturna nezaposlenost** predstavlja nesklad između kompetencija zaposlenog i tržišta rada, a do ovakvog nesklada može doći zbog tehnoloških promena, transformacije tržišta što direktno utiče na potražnju za određenim profilima. Takođe, neadekvatno obrazovanje i stručnost za kojim tržište iskazuje potrebe može dovesti do uvećanja strukturne nezaposlenosti. Ovaj tip nezaposlenosti je dugoročnog karaktera, te se mora uložiti dodatni napor ka ulaganju u znanje, obrazovanje i obuku stručnog kadra koje je tržištu neophodno. Novi vid strukturalne nezaposlenosti jeste **tehnološka nezaposlenost** koja nastaje kao posledica tehnološkog napretka i inovacija, što za sobom nosi potrebu za adekvatnom, obučenom i kompetentnom radnom snagom. **Ciklična nezaposlenost** javlja se kao posledica fluktuacija odnosno promena na tržištu poslovanja koji su ciklični, povezana je sa ekonomskim usporavanjem odnosno recesijom, pri čemu dolazi do pada potražnje za robom i/ili uslugama, ili pak

neusagrašenosti ponude i potražnje. Kada govorimo o recesiji, ovde postoji rizik i opasnost da se frikciona nezaposlenost pretvori u dugoročnu odnosno strukturnu nezaposlenost.

Sem navedenih, postoje ne manje bitne **dugoročna nezaposlenost** i **prikrivena nezaposlenost**. **Dugoročna nezaposlenost** podrazumeva vremenski period koji je pojedinac proveo u statusu kao nezaposleni. Prema nekim kriterijumima dugoročno nezaposlena lica su ona koja traže posao aktivno duže od 6 meseci, a drugi pak da je taj period duži od godinu dana. Praćenje ovog vida nezaposlenosti je izuzetno značajno jer postoji rizik od prelaska u tržišnu neaktivnost. Dugoročna nezaposlenost može nastati kao posledica recesije, strukturnih problema (tehnološke inovacije, premeštanje industrije), nedostatak kompetencija pa nisu u stanju da odgovore znanjem i veštinama na novonastale potrebe tržišta. Ovaj vid nezaposlenosti dugoročno gledano vodi ka smanjenju životnog standarda, uvećanju siromaštva, pa ostavlja i psihološke posledice jer se takve osobe često susreću sa stresom, anksioznošću i depresijom. Sve zajedno ovaj vid nezaposlenosti dovodi do marginalizacije pojedinaca i uvećanja socijalne nejednakosti. **Prikrivena nezaposlenost** odnosi se na pojedince koji su formalno zaposleni ali ne rade puno radno vreme (part time poslovi). Pored formalno nezaposlenih, prikrivena nezaposlenost predstavlja neiskorišćenu radnu snagu jednog društva, ovakav vid nezaposlenja se nekada formulisao kao nedovoljna zaposlenost. Ovakav vid nezaposlenja ima takođe izražene socijalne posledice koje podrazumevaju osećaj nesigurnosti i nezadovoljstva pojedinaca, što može izazvati i društvene posledice.

Mnogobrojni su dakle faktori koji utiču na nivo nezaposlenosti poput globalizacije, demografskih promena, tehnoloških promena, migracija, tržišnih promena, pa upravo pomenuti faktori posebno su uočljivi na tržištima rada u zemljama u tranziciji. Takva tržišta vrlo su specifična, prolaze kroz period oblikovanja, reorganizacije, privatizacije, institucionalnih, strukturnih promena te se sve navedeno reflektuje na broj nezaposlenih.

Razvoj modernih tehnologija, za posledicu ima i modelovanja velikih informacionih sistema koji pomažu u donošenju dobrih odluka i razumevanju tržišta i nezaposlenih. Ova disertacija, u tom smislu, kao svoj cilj ima predstavljanje još jednog načina prikupljanja, obrade relevantnih podataka, kao i predviđanja novih šablona i promena, koristeći metode veštačke

inteligencije, o kojima će biti nešto više reči u narednoj sekciji. Osnovni cilj je definisati metodologiju kojom se mogu na neki način nadomestiti nedostaci postojećih informacionih sistema, uzimajući u obzir i određene izazove koji se mogu javiti, kao što su pouzdanost, stabilnost, efikasnost i tačnost postojećih tehnika predviđanja.

2.2 Uticaj nezaposlenosti na globalno tržište i ekonomiju

Nezaposlenost predstavlja jedan od centralnih makroekonomskih problema savremenih ekonomija, jer istovremeno generiše ekonomske, socijalne i političke posledice. Na globalnom tržištu deluje kroz više kanala: utiče na agregatnu tražnju i investicije, menja obrasce međunarodne trgovine i tokove kapitala, preoblikuje migracione kretanje i doznake, te utiče na raspodelu dohotka, siromaštvo i održivost rasta. Sa aspekta ekonomske politike, razumevanje mehanizama kroz koje nezaposlenost deluje od suštinskog je značaja za dizajn mera koje istovremeno stabilizuju ciklus, unapređuju produktivnost i podstiču inkluzivni rast.

Nezaposlenost utiče na agregatne makroekonomske veličine kroz nekoliko mehanizama, to su agregatna potražnja i potrošnja u okviru koje viša nezaposlenost smanjuje raspoloživi dohodak i potrošnju domaćinstava, slabi maloprodaju i usluge, te utiče na ukupnu tražnju. Takođe, pojačana sklonost štednji iz predostrožnosti i niži kreditni kapacitet dodatno prigušuju potražnju. Implikacije na investicije podrazumevaju da slabija tražnja erodira očekivanu profitabilnost i smanjuje ulaganja privatnog sektora, dok sa druge strane veća neizvesnost i premije rizika odlažu investicione odluke i tehnološka unapređenja. Potom, što se tiče fiskalne stabilnosti, rast isplata naknada za nezaposlene i pad poreskih prihoda povećavaju fiskalni deficit, dok veća fiskalna opterećenost može limitirati prostor za proaktivne politike u narednim fazama ciklusa. Kada je u pitanju produktivnost i histereza, dugotrajan izostanak sa tržišta rada smanjuje veštine, motivaciju i „zapošljivost”, snižavajući potencijalni output pa ovi efekti pojačavaju strukturnu nezaposlenost, čak i kada se ciklični uslovi poprave. Uticaj na cene i plate je takav da rast nezaposlenosti smanjuje pregovaračku moć radnika, što prigušuje rast plata i opterećuje domaću tražnju, pa slabije plate mogu obuzdati inflatorne pritiske u kratkom roku, ali uz cenu većih realnih dispariteta.

Što se tiče efekata na globalno tržište i međunarodne tokove, na globalnom nivou, nezaposlenost domaće ekonomije preliva se preko granica, pa tako ako pratimo trgovinske kanale, može se uvideti da niža domaća potrošnja smanjuje uvoz, utičući na izvozne performanse

trgovinskih partnera. Takođe, promene relativnih cena, valutni kursevi i troškovi rada utiču na konkurentnost i obrasce razmene. Kroz lance snabdevanja, smanjenje potražnje remeti narudžbine duž globalnih lanaca vrednosti, utičući na kapacitete i zapošljavanje u zemljama-dobavljačima, pa nesklad između ponude veština, znanja i novih tehnologija mogu usporiti reorijentaciju lanaca ka većoj otpornosti. Ako pratimo tokove kapitala i premije rizika, više stope nezaposlenosti mogu podići percepciju rizika, povisiti troškove zaduživanja i smanjiti priliv stranih direktnih investicija, raste volatilnost na finansijskim tržištima, produbljujući kontraktione impulse. Ako pak posmatramo migracije i oznake, nedostatak poslova podstiče emigraciju, pa u kratkom roku može smanjiti pritisak na domaće tržište rada. Doznake dijaspore deluju stabilizaciono na potrošnju, ali dugoročno odliv mozgova može sniziti produktivni potencijal. Dolazi do usporavanja globalne tražnje spušta cene sirovina, što pogađa izvoznike resurse, dok ciklične modifikacije utiču na investicione planove u energetici, rudarstvu i poljoprivredi. Ako posmatramo distribucione i socijalne aspekte, nezaposlenost je snažno povezana sa nejednakošću i socijalnom kohezijom. Pa tako raspodela dohotka podrazumeva da gubitak posla i pad plata šire jaz između kvintila, dok finansijska imovina koncentriše dobitke. Uticaj na siromaštvo i socijalna isključenost podrazumevaju da dugotrajna nezaposlenost povećava rizik od siromaštva, pogotovo u domaćinstvima sa zavisnom decom. Zatim dolazi do segmentacije tržišta rada, odnosno, mladi, žene, niskokvalifikovani i ruralna područja trpe nesrazmerno veći teret. Kroz prizmu neformalne ekonomije to znači da u odsustvu prilika raste učešće neformalnih aranžmana, sa slabijom zaštitom radnika i nižom produktivnošću. Kroz prizmu političke ekonomije, rast nezaposlenosti može pojačati društvene tenzije i polarizaciju, utičući na stabilnost i očekivanja investitora. U eri znanja, neophodno je posmatrati strukturne promene koje podrazumevaju tehnologiju, digitalizaciju i tranziciju. Tehnološke promene i strukturne transformacije preoblikuju tražnju za veštinama tako da automatizacija i digitalizacija smanjuju potražnju za rutinskim zadacima, dok raste tražnja za kognitivno-analitičkim, tehničkim i „mekim” veštinama. Zelena tranzicija menja strukturnu mapu radnih mesta (otvaranje „zelenih” zanimanja) bez adekvatnih prekvalifikacija i fleksibilnih obrazovnih sistema, tranzicija može povećati strukturnu nezaposlenost i regionalne disparitete.

Implikacije na ekonomsku politiku su takve da efikasne politike adresiraju i ciklične strukturne

dimenzije nezaposlenosti. Makroekonomska stabilizacija podrazumeva koordinaciju fiskalne i monetarne politike radi podrške agregatnoj tražnji i recesijama, ali i jačanje automatskih stabilizatora (progresivno oporezivanje, naknade za nezaposlene uz podsticaje za reaktivaciju).

Neophodne su dakle aktivne mere tržišta rada a koje podrazumevaju ciljane obuke i prekvalifikacije subvencije za zapošljavanje ranjivih grupa, javni radovi sa merljivim ishodima, programska podrška samozapošljavanju i razvoju malih i srednjih preduzeća (mentorstvo, pristup finansiranju, poslovne mreže). Takođe od izuzetnog su značaja strukturne i institucionalne reforme koje podrazumevaju fleksigurnost: kombinacija razumnog nivoa fleksibilnosti ugovora i snažne socijalne sigurnosti. Fleksigurnost kao podsticaj je posebno zaživeo i do danas primenjiv vrlo uspešno u Danskoj. Sem toga neophodno je unapređenje poslovnog okruženja (pravo, regulativa, konkurencija, pristup kapitalu), a od vitalnog značaja je obrazovna reforma i saradnja sa privredom (dualne šeme, stažiranje, centri kompetencija).

Nezaposlenost deluje kao multiplikativni šok na globalno tržište i ekonomiju: smanjuje agregatnu tražnju i investicije, podiže neizvesnost i rizike, menja trgovinske tokove i lance snabdevanja, utiče na migracije i doznake, a istovremeno produbljuje nejednakosti i slabi ljudski kapital. Dugoročno posmatrano, bez sveobuhvatnog odgovora politike, ciklični gubici transformišu se u strukturne ožiljke (histerezu), snižavajući potencijalni rast i ugrožavajući društvenu koheziju. Najefikasniji pristupi objedinjuju makroekonomsku stabilizaciju, aktivne mere tržišta rada, strukturne reforme u obrazovanju i inovacionim ekosistemima, kao i ciljane, inkluzivne regionalne politike. Na taj način ublažavaju se kratkoročni šokovi, ubrzava strukturno prilagođavanje i unapređuje održiv, inkluzivan ekonomski rast na globalnom nivou.

2.3 Indikatori ekonomskog rasta

Ekonomski rast predstavlja željeni cilj svakog društva. Konvencionalni način merjenja uspeha privrede u suštini je praćenje privrednog rasta, koji se u neoklasičnoj ekonomiji postavlja kao glavni cilj ekonomske politike. Tokom kriznih perioda ova orijentacija dodatno jača, te se

izlaz iz nepovoljnih kretanja dominantno traži kroz ostvarivanje stopa rasta iznad jediničnog nivoa (iznad 1). U takvom okviru, dimenzije društvenog blagostanja, degradacija životne sredine i subjektivno zadovoljstvo stanovništva neretko bivaju potisnuti u drugi plan zarad postizanja pozitivnih vrednosti makroekonomskih pokazatelja, čak i kada su te promene marginalne. Kvantifikacija privrednog rasta zasniva se na primeni makroekonomskih agregata koji sumiraju ukupne ekonomske aktivnosti privrede. Privredni rast, kao indikator ekonomskog napretka, standardno se izražava godišnjim povećanjem dva temeljna agregata nacionalnih računa: bruto domaćeg proizvoda (BDP) i nacionalnog dohotka.

2.3.1. Bruto domaći proizvod (BDP)

Zamisao bruto domaćeg proizvoda (BDP), zajedno sa metodama njegovog merenja i primene kao pokazatelja ekonomskog blagostanja, razvijena je tokom tridesetih i četrdesetih godina dvadesetog veka. To je bio period svetskih ratova i ozbiljnih ekonomskih kriza. U Sjedinjenim Američkim Državama (SAD), donosioci odluka koristili su statističke indikatore kako bi opravdali politike usmerene na ublažavanje tadašnje krize. Kada je postalo jasno da će SAD aktivno učestvovati u Drugom svetskom ratu, te se pojavila se bojazan da bi takav korak mogao dodatno oslabiti privredu koja se tek oporavljala od posledica velike depresije. Radi smirivanja javnosti, politički akteri su se pozvali na BDP kao dokaz da je ekonomija dovoljno snažna da obezbedi resurse za ratne napore bez značajnog pogoršanja životnog standarda građana (Costanza et al., 2009). BDP je davne 1934.godine razvijen za potrebe američkog Kongresa pa je postavljen za glavni merni instrument privrede jedne zemlje te i danas predstavlja neizostavni indikator svih analiza privrednih aktivnosti. BDP se i danas smatra ključnim pokazateljem ekonomskog napretka i polaznom osnovom za poređenje životnog standarda različitih zemalja o potvrđuje i izveštaj Svetske banke, u kojem se među glavnim zaključcima navodi da jedino dugoročno visoke stope rasta BDP-a mogu rešiti problem siromaštva na globalnom nivou (Commission on Growth and Development, 2008).

Bruto domaći proizvod može se definisati kao ukupna vrednost dobara i usluga proizvedenih u jednoj ekonomiji u toku jedne godine umanjena za vrednost dobara i usluga koje

su korišćene u proizvodnji (Bureau of Economic Analysis, 2015). Postoji nekoliko pristupa za merenje BDP-a (Bulin & Baltatescu, 2015) i to su:

- Pristup zasnovan na proizvodnji – BDP se utvrđuje kao zbir tržišnih vrednosti finalnih dobara i usluga proizvedenih u jednoj zemlji u toku jedne godine
- Pristup zasnovan na rashodima - Polazna pretpostavka ovog pristupa jeste da će svaka proizvedena roba ili usluga naći kupca. Shodno tome, BDP se definiše kao zbir ukupnih rashoda za finalna dobra i usluge proizvedene unutar jedne zemlje u određenom vremenskom periodu. Pa su ključne komponente BDP-a lična potrošnja, javna (državna potrošnja), investicije i neto izvoz (izvoz minus uvoz)
- Pristup zasnovan na prihodima – ovaj pristup meri BDP sabiranjem svih dohodaka ostvarenih u privredi tokom određenog vremenskog perioda, a to su porezi uplaćeni državi, dobit preduzeća, naknade zaposlenima (zarade i ostala primanja)

BDP se meri u valuti zemlje u kojoj se određuje, pa je to za Srbiju recimo dinar, za Ameriku dolar, Nemačku euro. Ako želimo da poredimo životni standard građanja Srbije sa drugim zemljama, potrebno je da se koristi BDP po glavi stanovnika a koji se utvrđuje kao odnos između bruto domaćeg proizvoda i ukupnog broja stanovnika. Povremeno se umesto bruto domaćeg proizvoda izraženog u trenutnim cenama (nominalno bruto domaći proizvod) koristi njegova verzija korigovana za očekivanu stopu inflacije (realni bruto domaći proizvod) (Bergh, 2009). Isključenjem uticaja inflacije meri se isključivo stvarna (realna) ekonomska aktivnost (Dyan & Sheiner, 2018). BDP i korišćenje istog kao indikatora ekonomskog prosperiteta broji mnoge prednosti kao što su jednostavnost, linearnost, univerzalnost, mogućnost pojednostavljenog razumevanja na koji način ekonomija jedne zemlje funkcioniše.

BDP se kao indikator često zloupotrebljava ili preciznije rečeno, preuveličava. Iako predstavlja meru proizvodnje a ne dohodka, BDP se često koristi kao pokazatelje blagostanja, odnosno životnog standard stanovništva. Međutim, treba imati na umu da životni standard ne predstavlja monetarnu kategoriju.

Iako je BDP neumitno jedan od najčešće korišćenih indikatora privrednog rasta, postoje razlozi kojih se dovodi u pitanje opravdanost njegove upotrebe u navedenu svrhu (Marone, 2012).

- u obračun BDP-a ulaze samo dobra i usluge koje imaju cenu i prodaju se na formalnim tržištima. Time se izostavlja niz činilaca važnih za ljudsko blagostanje i ekonomski napredak, uključujući neplaćene aktivnosti poput podizanja dece, volontiranja i vođenja domaćinstva. Dodatno, sporno je da li pojedine aktivnosti koje ulaze u kalkulaciju BDP-a zaista treba smatrati doprinosom privrednom rastu.
- BDP ne obuhvata aspekte šireg kvaliteta života, kao što su nivo društvenog nasilja, pristup prirodnom okruženju, fizičko i mentalno zdravlje stanovništva, zagušenost saobraćaja i slično
- BDP ne registruje promene u vrednosti imovine, iako je sposobnost efikasnog korišćenja realne i finansijske imovine u uslovima nepredviđenog pada prihoda jedan od ključnih oslonaca za uobičajeno funkcionisanje domaćinstava.
- BDP ne uključuje pokazatelje siromaštva niti raspodele (dohotka ili bogatstva). Zanemarivanje ekonomskih aktivnosti koje ne podrazumevaju novčane transakcije dovodi u pitanje upotrebljivost BDP-a za poređenje performansi bogatih i siromašnih zemalja.
- intermedijarna dobra su isključena iz obračuna BDP-a; jedno od obrazloženja za to jeste izbegavanje dvostrukog računanja.

Najozbiljnija zamerka BDP-u jeste da ne pruža uvid u životni standard: čak i kada dođe do rasta BDP-a, nije jasno kako se novo stvoreno bogatstvo raspodeljuje, niti da li je porast posledica većih državnih izdataka ili drugih činilaca. Kao što je već pomenuto, životni standard nije monetarna kategorija, te stoga za njegovu valjanu procenu neophodno je, pored novčanih pokazatelja, uključiti i druge društveno relevantne dimenzije, poput odsustva kriminala, visokog stepena ličnih sloboda, zaštita životne sredine, pristup bezbednoj pijaćoj vodi, nivo obrazovanja isličnih pokazatelja kvaliteta života.

Pristalice upotrebe BDP-a u načelu prihvataju gore navedene primedbe, ali naglašavaju da treba jasno definisati u koje svrhe se nacionalni računi mogu i smeju koristiti. Drugim rečima, BDP je delimičan indikator blagostanja: pruža uvid u godišnji obim proizvodnje, odnosno dohodak na nivou čitave ekonomije, ali ne otkriva ko konkretno ima koristi od tog ostvarenja, niti da li je takva proizvodnja održiva ili posledica prekomernog trošenja prirodnih resursa. Otuda proizlazi neosporna potreba za dodatnim statističkim računima koji bi pratili pomenute dimenzije (raspodelu

koristi, održivost, i druge relevantne pokazatelje). Za razliku od bruto domaćeg proizvoda, koji je mera proizvodnje, bruto nacionalni dohodak je mera dohotka.

BDP je najrasprostranjeniji pokazatelj ekonomske aktivnosti država. Njegovo izračunavanje počiva na međunarodno standardizovanoj metodologiji i višedecenijskoj praksi, uz stalna konceptualna preispitivanja i unapređenja. Snaga ovog indikatora leži u tome što ukupnu ekonomsku aktivnost svodi na jedinstvenu meru — cenu, odnosno monetarnu vrednost. Kada se izvrši prilagođavanje na inflaciju, moguće je vremensko poređenje podataka. Uprkos svemu, BDP i dalje meri samo tržišnu proizvodnju, iako se neretko pogrešno koristi kao pokazatelj blagostanja. Neadekvatno predstavljanje važnih društvenih karakteristika pogrešnim indikatorima može dovesti do netačnih zaključaka, a posledično i do neodmerenih smernica i strategija delovanja. Na kraju, zaključujemo da su uprkos brojnim ograničenjima, benefiti izračunavanja BDP-a umnogome značajniji od nedostataka, te se shodno tome i dalje smatra za jedan od najbitnijih pokazatelja privrede jednog društva.

2.3.2.Bruto nacionalni proizvod (BNP)

U ovom odeljku pomenućemo bruto nacionalni proizvod (BNP). Za razliku od BDP-a, ovaj indikator obuhvata isključivo dohodak koji ostvaruju rezidenti, bez obzira na to gde je prihod generisan (Ramey, 2021). Razlika između bruto domaćeg proizvoda (BDP) i bruto nacionalnog proizvoda (BNP) zavisi od zemlje do zemlje. U ekonomijama sa velikim udelom preduzeća u stranom vlasništvu, BDP je obično veći od BNP-a. Vrednost dobara i usluga koje proizvedu ta preduzeća ulazi u BDP, ali ne i u BNP, jer pripada nerezidentima. Shodno tome, BNP predstavlja meru proizvodnje/dohotka koja se može pripisati isključivo rezidentima, tj. “nacionalnu” produktivnost.

2.3.3.Ostali makroekonomski indikatori razvoja

Zbog brojnih ograničenja BDP-a kao pokazatelja ekonomskog napretka, istraživači su razvili kompozitne indekse koji, pored ekonomskih dimenzija, obuhvataju i socijalne, ekološke i druge aspekte važne za ukupan kvalitet života.

Neki od takvih indikatora su

- **Indeks ljudskog razvoja** (engl. *Human Development Index, HDI*) razvijen od strane programa Ujedinjenih nacija za razvoj. Ovaj indeks polazi od pretpostavke da ljudski razvoj podrazumeva da ljudi poseduju dug, zdrav život, omogućeno obrazovanje, te imaju pravo na pristojan životni standard (Herre & Arriagada, 2023).
- **Indeks ljudskog razvoja** korigovan za nejednakosti (engl. *Inequality-adjusted Human Development Index*) Ovaj indeks koristi iste principe za merenje kao i prethodni. Za razliku od originalnog indeksa, korigovana verzija polazi od pretpostavke da se očekivani životni vek, obrazovanje i prihodi razlikuju unutar zemalja. Zbog toga se za njegovo kreiranje koriste i podaci o nejednakosti unutar zemlje za svaku od navedenih dimenzija. Na taj način se vrši korekcija prosečnih rezultata originalnog indeksa.
- **Indikator istinskog napretka** razvili su (Daly & Cobb, 1994) kao pristup merenju ekonomske aktivnosti koji će pružiti bolje smernice od bruto domaćeg proizvoda onima koji su zainteresovani za unapređenje ekonomskog blagostanja. Ovaj indeks meri održivost tekućih prihoda, procenjujući da li je ekonomski prosperitet rezultat življenja od kamata na društveni kapital ili njegovog trošenja. Za utvrđivanje ovog indeksa korišćeno je 26 indikatora. (Daly & Cobb, 1994)
- **Indeks srećne planete** je implementiran je 2006. godine od strane Nika Marksa (engl. *NicMarks*) u okviru Fondacije za novu ekonomiju (engl. *New Economics Foundation*). Ovaj indeks meri koliko dobro zemlje napreduju u postizanju održive dobrobiti. Drugim rečima, koliko su uspešne u podršci svojim stanovnicima da žive kvalitetno u sadašnjosti, dok osiguravaju da i drugi mogu da žive najmanje istim nivoom kvaliteta u budućnosti (Abdallah, Hoffman, & Akenji, 2024). Indeks je sačinjen od tri dimenzije: očekivani životni vek pri rođenju, zadovoljstvo životom i ekološki otisak.
- **Indeks fizičkog kvaliteta života** je zapravo indikator razvojnog indeksa kreiranog od strane Istraživačkog instituta Ujedinjenih nacija za društveni razvoj (engl. *United Nations Research Institute for Social Development*). Razvojni indeks je razvijen je pomoću 9 društvenih i 7 ekonomskih indikatora među kojima su: prosečan broj članova domaćinstva po jednoj sobi, dnevna potrošnja namirnica životinjskog porekla po stanovniku, poljoprivredna proizvodnja po radniku, procenat ekonomski aktivnog stanovništva koja imaju struju, gas i tako dalje.

Pored vodećih indikatora (*engl. Leading Economic Indicators*) LEI, u ekonomiji se koriste i drugi indikatori, ali svi oni zajedno obezbeđuju oblikovanje fiskalne i monetarne politike na bazi informacija i predikcija koje pružaju. Ovi drugi indikatori mogu se definisati kao (Investopedia, 2023) trenutni indikatori ili CEI (*engl. Coincident Economic indicator*) koji prikazuju trenutno stanje jedne ekonomije. Jedan predstavnik ovih pokazatelja je BDP o kome je već bilo reči, a drugi mogu biti podaci o kretanju ličnog dohodka. Postoje takođe, Indikatori kašnjenja (*engl. Lagging Indicators*) koji pokazuju prošla dešavanja u privredi, poznati su tek nakon nastanka određenih promena i mogu biti korisni u utvrđivanju obrasca ponašanja. Predstavnik indikatora kašnjenja je Indeks potrošačkih cena koji ukazuje na promene stope inflacije, a može biti i stopa nezaposlenosti. Svi indikatori imaju istu suštinu, a to je da se koriste za praćenje i predviđanje promena u određenim aktivnostima ili procesima. Komponente ekonomskih indikatora podrazumevaju skup određenih pokazatelja kojima se mogu predviđati kretanja u privredi npr. rano otkrivanje bitnih promena u poslovnim ciklusima. LEI Svrstavamo u dve kategorije (Radović-Stojanović, 2009) i to su pojedinačni ili vodeći indikatori (koriste se u predviđanjima na nivou sektora ili grade određene privrede) i kompozitni indikatori (oslikavaju kretanje privrede u celini odnosno jedne nacionalne ekonomije). LEI se mogu definisati kao vremenske serije određenih makroekonomskih pokazatelja, kao što su a primer BDP, inflacija ili nezaposlenost, kojima se prate promene u privredi odnosno ekonomiji. Ukoliko se prati pretpostavka o postojanju poslovnih ciklusa, odnosno postojanju faze ekspanzije i faze recesije, onda LEI mogu biti dobri indikatori smanjivanja ovih faza, odnosno, mog use koristiti za identifikaciju pomenutih faza i pružanju informacija o trenutnom stanju ekonomije kao i njenim očekivanim promenama. Leading Economic Index (LEI) predstavlja ključni ekonomski indikator koji se koristi za predviđanje budućih ekonomskih kretanja, te se kao takav koristi za prognoze u SAD-u, pri čemu The Conference Board kao neprofitna organizacija za istraživanje ekonomije sa sedištem u SAD-u na mesečnom nivou ažurira i publikuje podatke u vezi sa ovim indeksom.

OECD kao kompozitni indikatori podrazumevaju skup statističkih podataka i analitičkih alata koji se koriste za predviđanje budućih kretanja u ekonomiji, obuhvatajući različite ekonomske pokazatelje poput industrijske proizvodnje, potrošnje, trgovine, zapošljavanja i drugih faktora kako bi pružili informacije o tome u kojem pravcu se kreće ekonomska aktivnost. Kompozitni vodeći indikatori formiraju se na osnovu pokazatelja a koji moraju da zadovolje

određene zahteve (OECD, 2025) : Indikatori moraju biti ekonomski važni, što znači da postoji jasna povezanost između njih i glavnog ekonomskog trenda. Preferiraju se indikatori koji široko pokrivaju ekonomske aktivnosti, umesto onih koji su usko definisani. Više se koriste mesečni podaci u odnosu na kvartalne, jer pružaju češće informacije. Bolje je koristiti podatke koji nisu često podložni velikim izmenama nakon prvog objavljivanja. Podaci treba da budu dostupni brzo nakon završetka perioda koji pokrivaju. Prednost imaju dugotrajni nizovi podataka bez prekida.

2.4 Primena veštačke inteligencije u predikciji nezaposlenosti

Predikcija nezaposlenosti predstavlja ključno pitanje makroekonomske analize i kreiranja javnih politika. Tačna i pravovremena prognoza omogućava planiranje fiskalnih izdataka (naknade za nezaposlene, aktivne mere tržišta rada), kalibraciju monetarne politike, evaluaciju strukturnih reformi i bolje upravljanje socijalnim rizicima. Razvoj veštačke inteligencije ali i mašinskog učenja (ML) otvorio je nove mogućnosti za modelovanje kompleksnih, nelinearnih i visokodimenzionalnih odnosa, integraciju alternativnih izvora podataka i realnoivremensko “nowcasting” ažuriranje prognoza. Time se dopunjuje i nadgrađuje klasični ekonometrijski pristup, posebno u uslovima strukturnih lomova, nestacionarnosti i promenljive dinamike tržišta rada. Istorijski posmatrano začeci istraživanja i analize vremenskih serija datiraju još iz perioda tridesetih godina prošlog veka pojavom klasičnih stohastičkih pristupa. To su najpre bile osnovne, konceptualne ideje, dok sistematično i praktično modelovanje vremenskih serija opočinje šezdesetih godina, a intenzivno se unapređuje sedamdesetih godina dvadesetog veka najpre u oblasti ekonomije pa potom inženjerstva.

2.4.1. Neki od modela vremenskih serija u predikciji nezaposlenosti

U analizi i predikciji kretanja nezaposlenosti koegzistiraju dva komplementarna metodološka pristupa: klasična ekonometrija i veštačka inteligencija/mašinsko učenje (ML). Klasična ekonometrija obuhvata modele kao što su ARIMA/ARIMAX i VAR/VECM, kao i strukturne relacije poput Phillips-ove krive, Okun-ovog zakona i Beveridge-ove relacije. Njene ključne prednosti su transparentnost i jasna interpretacija parametara, što omogućava povezivanje rezultata sa teorijskim okvirom i politikama. Ipak, ova paradigma se suočava sa ograničenjima u

prisustvu izraženih nelinearnosti, promena režima i visoke dimenzionalnosti podataka, što često karakteriše savremene tržišne i radne dinamike. Suprotno tome, pristupi veštačke inteligencije i mašinskog učenja stavljaju težište na prediktivni učinak i robusnost u kompleksnim, visokodimenzionim i potencijalno nestrukturiranim skupovima podataka. Ovi modeli prirodno obuhvataju nelinearne interakcije, efekte pragova i heterogenost između regiona i sektora, što je naročito relevantno kada nezaposlenost zavisi od višestrukih, međusobno uslovljenih faktora. Pošto oba okvira poseduju različite snage, praksa sve češće koristi hibridne pristupe koji kombinuju ekonometrijsku strukturisanost i objašnjivost sa prediktivnom moći ML modela, obezbeđujući tako bolji balans između interpretabilnosti i performansi

Prvi utemeljeni okvir u razvoju bila je ARIMA metodologija, nelinearni model vremenskih serija koji kroz autoregresiju, diferenciranje i pomični prosek modeluje autokorelaciju i (de)trend, tipično za kratkoročne prognoze stacionariziranih serija. Daljim razvojem na scenu stupa ARIMAX, koji nasleđuje i proširuje ARIMA model, egzogenim regresorima radi hvatanja dodatnih informacija.

Za predviđanje vremenskih serija u upotrebi je i VAR koji simultano modeluje više endogenih serija preko sopstvenih i unakrsnih zaostajanja, hvatajući dinamiku međuzavisnosti. VECM je varijanta za kointegrirane serije, koja razlaže kratkoročne prilagodbe i dugoročne ravnotežne odnose kroz korekcionu komponentu greške.

Gore pomenuta Philipsova kriva predstavlja empirijsku relaciju između inflacije (ili njenog ubrzanja) i nezaposlenosti/output-gapa, koja odražava kratkoročni kompromis i očekivanja. U praksi se koristi kao deo strukturnih makro modela za prognozu inflacije uz dodatne formule. Ova model je ograničen nije samostalni prediktivni model te se stoga koristi se unutar šireg modelskog okvira.

Okunov zakon je polu-empirijska veza između promena u stopi nezaposlenosti i rasta BDP-a/odstupanja od potencijalnog outputa. Omogućava “prevođenje” prognoza rasta u projekcije nezaposlenosti, uz koeficijente specifične za zemlju i period. Takođe je za potrebe prognoziranja ograničen, nije pun model, ali je koristan za brze orijentacione projekcije.

Beveridge-ova relacija je dijagnostički alat pre svega, pa sam po sebi nema snažan prediktivni kapacitet bez dopunskog modelovanja. Prati negativnu vezu između stope

nezaposlenosti i stope slobodnih radnih mesta, indikativna za efikasnost uparivanja na tržištu rada i frikcije, a pomerena krive signaliziraju strukturne promene u “matchingu”.

Veštačka inteligencija i mašinsko učenje fokus stavlja na prediktivni učinak i robusnost u kompleksnim strukturama podataka, kao i mogućnost hvatanja nelinearnih interakcija, efekata pragova i heterogenosti across regiona/sektora. Klasična ekonometrija uz veštačku inteligenciju i mašinsko učenje biva komplementarna, te praksa sve češće koristi hibridne modele radi balansa, interpretabilnosti i performansi.

Neki od modela stabala koji ovde imaju primenu su : Random Forest, Gradient Boosting (XGBoost, LightGBM, CatBoost): dobri za tabelarne podatke, robusni na nelinearnosti i interakcije; lako se kombinuju sa lagovima i “rolling” svojstvima.

U domenu dubokog učenja za vremenske serije, rekurentne arhitekture (RNN/LSTM/GRU) omogućavaju hvatanje sekvencijalnih obrazaca, dok su novije arhitekture poput N-BEATS i Temporal Fusion Transformer (TFT) dizajnirane za višehorizontne prognoze sa više ulaznih varijabli i promenljivom važnošću karakteristika kroz vreme. Konvolucionistički pristupi za vremenske serije (TCN) koriste dilatirane konvolucije za modelovanje dugih zavisnosti bez potrebe za rekurencijom, često uz konkurentan ili bolji prediktivni učinak u odnosu na RNN-klasu, uz veću paralelizabilnost. Kada su u pitanju prostorno-vremenske dinamike nezaposlenosti, naročito u regionalnim analizama, graf neuronske mreže (GNN) i varijante kao što je Graph-TFT integrišu prostorne susednosti i vremensku dinamiku u jedinstven okvir. Ovi modeli su naročito korisni kada nezaposlenost pokazuje difuzne obrasce i preliva se preko administrativnih granica, npr. usled zatvaranja velikog poslodavca ili promene sektorske strukture u susednim regionima.

Hibridni i kompozitni pristupi bili bi ARIMA/VAR + ML reziduali (korekcija nelinearnosti), stacking/blending različitih modela, Bayesovi modeli i kvantilna regresija za distribucione prognoze. Tipičan postupak je kombinacija ARIMA/VAR kao bazne, teorijski ukorenjene komponente, sa ML-modelom koji uči preostale nelinearne obrasce iz reziduala. Pored toga, „stacking” i „blending” različitih modela omogućavaju agregiranje komplementarnih prednosti pojedinačnih algoritama. Za distribucione prognoze, koje su važne u politikama rada i upravljanju rizikom, primenjuju se Bayesovi modeli i kvantilna regresija, čime se eksplicitno modeluje čitava prediktivna distribucija, a ne samo očekivana vrednost.

Poseban segment predstavlja nowcasting, gde se u prognozama mesečnih ili kvartalnih stopa nezaposlenosti integrišu visokofrekventni izvori podataka (npr. sedmični ili dnevni signali). Ovakvi sistemi oslanjaju se na dinamičko re-težiranje izvora kroz vreme, prilagođavajući relativnu važnost indikatora u skladu sa promenama režima, sezonskim obrascima i pojavom novih šokova. U praksi, nowcasting okviri često kombinuju više struja podataka (zvanične statistike, oglase za posao, pretrage na internetu, podatke o mobilnosti) kroz ansambl ili probabilističke modele, postižući pravovremene i informacijski bogate signale pre zvaničnih objava.

Validacija vremenskih serija mora očuvati vremenski redosled podataka kako bi se izbeglo curenje informacija i pristrasna procena performansi. U tom smislu, najprikladniji protokoli obuhvataju “rolling origin” (walk-forward) validaciju, koja postepeno pomera granicu između trening i test skupa u realističnom, hronološkom rasporedu, kao i blok-krosvalidaciju, gde se podaci dele u uzastopne vremenske blokove radi smanjenja uticaja autokorelacije. U složenijim postavkama, posebno kada je potrebno istovremeno birati obeležja i optimizovati hiperparametre, preporučuju se ugnježdene (nested) šeme validacije koje razdvajaju unutrašnju optimizaciju modela od spoljašnje procene generalizacione sposobnosti. Nasuprot tome, nasumična podela (random split) se ne preporučuje jer narušava vremensku strukturu serije i dovodi do precenjene tačnosti.

Evaluacija prediktivnih performansi treba da diferencira tačkaste i distribucione (probabilističke) prognoze. Za tačkaste prognoze, standardne metrike uključuju srednju apsolutnu grešku (MAE), koren srednje kvadratne greške (RMSE) i procentualne varijante poput MAPE/sMAPE, koje olakšavaju uporedivost između različitih nivoa serija. Kada su u fokusu verovatnosne prognoze, pogodnije su metrike koje ocenjuju celu prediktivnu distribuciju, kao što je CRPS (*engl. Continuous Ranked Probability Score*), dok se za kvantilne prognoze koristi “pinball loss” koji direktno penalizuje odstupanja po zadatim kvantilima. Pored toga, neophodno je proveriti kalibraciju i pokrivenost intervala predviđanja, kako bi se ocenila usklađenost nominalnih verovatnoća sa empirijskim učestalošću događaja.

Sistematsko poređenje sa referentnim modelima (benchmarking) ključno je za procenu stvarne vrednosti predloženog pristupa. Uobičajeni benchmarci uključuju naivne modele (random walk, sezonski naivni), jednostavne metode eksponencijalnog zaglađivanja i klasične

ekonometrijske modele poput ARIMA i VAR, u zavisnosti od prirode i dimenzionalnosti problema. Statistička značajnost razlika u performansama treba da se proverava odgovarajućim testovima (npr. testovi razlika u greškama prognoze) kako bi se izbegli zaključci zasnovani na slučajnim varijacijama u uzorcima.

Konačno, analiza stabilnosti i robustnosti procena predstavlja sastavni deo dobre prakse. Neophodno je ispitati ponašanje modela pre i posle strukturnih šokova (npr. pandemijskih ili geopolitičkih događaja), sprovoditi “backtesting” kroz period krize i oporavka, te proceniti osetljivost rezultata na revizije podataka i promene vintidža. Ovakav pristup omogućava uvid u otpornost modela na promene režima i obezbeđuje veću pouzdanost prognoza u realnim uslovima donošanja odluka.

3 Pregled dosadašnjih istraživanja prognoziranja nezaposlenosti

Prognoziranje nezaposlenosti postalo je jedan od ključnih ciljeva ekonomskih istraživanja, s obzirom na značajan uticaj stopa nezaposlenosti na finansijsku stabilnost zemlje, javno zdravlje i individualnu dobrobit. Istorijski posmatrano, prognoziranje trendova nezaposlenosti bilo je veoma složeno usled kompleksnosti tržišta rada i uticaja brojnih makroekonomskih činilaca, poput inflacije, tehnološkog napretka i promena politika (Montgomery et al., 1998; Rothman, 1998).

Tradicionalne tehnike oslanjale su se na statističke modele koji koriste istorijske ekonomske indikatore (Proietti, 2003), ali su noviji napreci u oblasti mašinskog učenja (ML) i analitike velikih podataka značajno unapredili tačnost prognoziranja. Korišćenjem velikih skupova podataka iz različitih sektora, savremeni pristupi omogućavaju praćenje i prognoziranje trendova nezaposlenosti u realnom vremenu, pomažući vladama i kreatorima politika da sprovedu blagovremene intervencije radi ublažavanja gubitka radnih mesta (Ahmad et al., 2023; Kant et al., 2022). Za rešavanje problema prognoziranja nezaposlenosti često su korišćeni i onlajn alati, poput Google Trends-a (Aaronson, 2022; Simionescu & Cifuentes-Faura, 2022).

Značajan izazov u prognoziranju nezaposlenosti jeste njena inherentna zavisnost od brojnih društvenih faktora, što dovodi do fluktuacija koje mogu da zakomplikuju zadato predviđanje. Jedan od perspektivnih pristupa prognoziranju nezaposlenosti obuhvata tehnike prognoziranja vremenskih serija (Bacanin et al., 2023), koje su sa zapaženim ishodom uspešno primenjivane u različitim domenima. Algoritmi veštačke inteligencije (AI) mogu dodatno unaprediti tačnost prognoziranja vremenskih serija učeći iz obrađenih podataka i otkrivajući složene relacije koje postoje među obeležjima. Rekurentne neuronske mreže (RNN) posebno su pogodne za prognoziranje vremenskih serija zbog svoje sposobnosti modelovanja sekvencijalnih podataka (Zameer et al., 2023; Moradzadeh et al., 2023). Pored toga, primenjivani su i drugi modeli dubokog učenja, sa ohrabrujućim rezultatima (Moradzadeh et al. 2023 ; Salman et al., 2024). Brojne studije ističu efikasnost LSTM mreža (Olcay et al., 2024; Jailani et al., 2023) i kapiranih rekurentnih jedinica (gated recurrent units, GRU) (Guo et al., 2023; Xu et al., 2024) za ovaj specifični zadatak.

Usredsređujući se na razmatrani problem prognoziranja nezaposlenosti, pregled literature pokazuje da su različite metode mašinskog učenja primenjivane u prošlosti sa različitim uspehom, pri čemu svaka nudi jedinstvene prednosti i nedostatke (Gogas et al., 2022; Celbi, 2023).

Regresioni modeli, kao što je linearna regresija, često su korišćeni zbog svoje jednostavnosti i interpretabilnosti (Puspajuita, 2018; Katris, 2020). Modeli zasnovani na stablima (tree-based), poput stabala odluke, slučajnih šuma (random forests) i mašina gradijentnog bustinga (gradient boosting machines), takođe su pokazali potencijal zahvaljujući sposobnosti da obrađuju nelinearnosti i visokodimenzionalne podatke (Gupta et al., 2022; Gabrikova et al., 2023; Nandha Gopal & Muthukaruppasamy, 2024). Neuronske mreže, naročito rekurentne neuronske mreže (RNN) i LSTM, sve su popularnije za ovaj zadatak, s obzirom na njihov kapacitet da uče iz sekvencijalnih podataka i modeluju vremenske zavisnosti u ekonomskim indikatorima (Singhania, & Kundu, 2020; Grybauskas et al., 2023). Tehnike selekcije obeležja (feature selection) takođe su često primenjivane radi redukcije dimenzionalnosti i unapređenja performansi modela fokusiranjem na najvažnije prediktore (Mulaudzi & Ajoodha, 2021; Mulero & Garc'ia-Hiernaux, 2021).

Srodna linija istraživanja razmatra evidencijalne neuronske mreže za makroekonomsko prognoziranje u uslovima izražene neizvesnosti. Rad (Mati et al., 2024) predlaže evidencijalnu neuronsku mrežu sa Gausovim slučajnim fazi brojevima za predviđanje indeksa potrošačkih cena (CPI) u ekonomijama Zapadne Afrike. Strukturni prekidi i egzogeni šokovi povezani sa COVID-19 i ratom Rusije i Ukrajine eksplicitno su ugrađeni kao indikatorske (binarne) promenljive. Njihov model obezbeđuje i tačkaste prognoze i eksplicitnu karakterizaciju neizvesnosti predviđanja putem funkcije verovanja definisane nad realnom pravom, pri čemu postiže višu prediktivnu tačnost od tradicionalnih referentnih ARIMA modela za više zemalja. Za razliku od toga, ovo istraživanje je fokusirano na multivarijantno prognoziranje nezaposlenosti korišćenjem sekvencijalnih modela zasnovanih na LSTM-u sa mehanizmom pažnje. Iako su modeli veštačke inteligencije pokazali značajan potencijal u aplikacijama prognoziranja, integrisanje metaheurističkih optimizacionih algoritama nudi mogućnost dodatnog unapređenja performansi uz minimizaciju računarskog opterećenja. Uprkos toj perspektivi, kombinacija metaheurističkog podešavanja i modela veštačke inteligencije za potrebe prognoziranja nezaposlenosti ostaje nedovoljno istražena.

Shodno tome, cilj ove disertacije, između ostalog je da popuni taj jaz uvođenjem izmenjenog metaheurističkog algoritma, prilagođenog izboru optimalnog skupa hiperparametara za problem prognoziranja nezaposlenosti uz korišćenje LSTM arhitektura sa mehanizmom pažnje. Predloženi pristup teži postizanju dovoljno tačnih predikcija uz zadržavanje niske računarske

složenosti. Sve navedeno ima za kranji cilj što bolju interpretaciju dobijenih rezultata na osnovu kojih bi se donosile pravovremene poslovne oduke.

4 Mašinsko učenje i duboko učenje

U ovom poglavlju biće dat osnovni prikaz taksonomije dubokog učenja, njegov kratak istorijat kao i značaj koji ostvaruje na naučnom polju, pogotovu kada govorimo o predikciji vremenskih serija. Takođe, biće prikazani i modeli koji su korišćeni u samom istraživačkom procesu, kao i značaj njihove optimizacije radi dobijanja što preciznijih rezultata.

4.1 Mašinsko učenje

Mašinsko učenje u tesnoj je korelaciji sa poljem veštačke inteligencije. Mašinsko učenje (*eng. Machine Learning - ML*) se fokusira na razvoj algoritama koji omogućavaju računarima da uče iz podataka, umesto da se oslanjaju na eksplicitno programiranje. Ovi algoritmi imaju sposobnost da identifikuju statističke pravilnosti i obrasce unutar podataka što ih čini različitim od metoda koje ljudi koriste prilikom sticanja znanja. U okviru mašinskog učenja postoji širok spektar algoritama koji iterativno uče iz podataka kako bi poboljšali svoje performance, opisali podatke i na kraju predvideli buduće ishode. Proces izrade efikasnog ML modela podrazumeva dve faze i to, fazu treninga i fazu testiranja. Faza treninga predstavlja intenzivan istraživački process u kojem se sistemu obezbeđuje označeni ili neoznačeni podaci. Potom se podaci čuvaju u prostoru karakteristika kako bi se koristili za buduća predviđanja. Pojednostavljeno rečeno ML koristi poznate podatke unutar svog prostora karakteristika kako bi predvideo rezultate za neoznačene podatke. Na ovaj način uspešan ML model se oslanja na svoja iskustva i razumevanja sa ciljem predviđanja rezultata. Algoritme mašinskog učenja delimo u četiri glavne vrste, to su nadgledano, nenadgledano, polunadgledano i pojčano učenje. Može se reći da su zajednički koraci za sve oblike procesa mašinskog učenja (Mitchell, 1997) prikupljanje podataka, priprema podataka, analiza i unapređenje, izbor metode mašinskog učenja, obuka konfiguracija i evaluacija, ten a kraju izbor modela koji će se koristiti na osnovu rezultata kao i testiranje.


- **Nadgledano učenje (eng. *Supervised Learning*)** – smatra se najvažnijim modelom mašinskog učenja. Ovo je tip mašinskog učenja gde modeli uče iz nekih označenih, labeliranih podataka i vrlo često se koristi za potrebe klasifikacije ili regresije. Jedna od zanimljivih osobina ovog modela jeste uključenost čoveka koja je neophodna kako bi se kreirao skup podataka a kojikasnije samostalno funkcioniše učeći na bazi datog primera koji se dobija putem ulaza.
- **Nenadgledano učenje (eng. *Unsupervised Learning*)** – modeli uče i otkrivaju strukturu u podacima koji nisu označeni, bez pomoći I uključenosti čoveka. imamo različite metode kao što su klasterovanje (eng. *Clustering*), redukcija dimenzionalnosti (eng. *Dimensionality Reduction*) i mnogi drugi. Modeli neuronskih mreža (*Neural Network NN*), samoorganizirajuća mapa (*Self Organizing Map SOP*), adaptivna rezonantna teorija (*Adaptive resonance Theory ART*) takođe koriste nenadgledano učenje.
- **Učenje sa podsticajem (eng. *Reinforcement Learning*)** – ovaj model zajedno sa nadgledanim I nenadgledanim predstavlja jedan od osnovnih modela mašinskog učenja. Modeli uče nove šablone kroz princip nagrade ili kazne. Koristi se za rešavanje brojnih problema u stvarnom svetu poput teorije igara, menadžment lanca snabdevanja, inteligencija roja, upravljanje avionima, robotika kao imnoge druge (Staker, 2021)

Izuzev prethodno navedenih osnovnih podela, u sklopu mašinskog učenja postoji i jedna specifična podoblast koja se zove duboko učenje (eng. *Deep Learning*). Ovaj tip mašinskog učenja predstavlja kombinaciju nadgledanog i nenadgledanog pristupa, koji se u glavnom bazira na arhitekturama neuronskih mreža sa više slojeva. Ova podoblast se često smatra posebnom taksonomijom zbog svoje specifične primene, kapaciteta i sposobnosti za učenje iz nekih prethodno neobrađenih setova podataka (Goodfellow et al., 2016). Duboko učenje doživljava neverovatnu ekspanziju što je dovelo do unapređenja različitih disciplina poput klasifikacije slike, obradu prirodnog jezika, prepoznavanje govora.

4.2 Neuronske mreže

4.2.1 Pojam biološkog i veštačkog neurona

Neuroni su ćelije odgovorne za različite funkcije u organizmu, pa između ostalog oni prenose signale kroz nervni sistem omogućavajući komunikaciju različitih delova tela. Neuroni su međusobno povezani pomoću aksona i dendrita a regije povezivanja aksona i dendrita nazivaju se sinapsama. Biološki neuroni proizvode kratke električne impulse ili signale koji putuju duž aksona i čine da sinapse šalju hemijske signale – neurotransmitere. Jačina sinaptičkih veza zavisi od spoljašnjih faktora, pa se tako i menja. Pod uticajem promena odvija se učenje kod živih organizama. Ovaj biološki mehanizam je simuliran u veštačkim neuronskim mrežama, pri čemu se ove mreže sastoje od računskih jedinica koje se nazivaju neuronima. Neuroni su međusobno povezani putem težina koje imaju istu ulogu kao jačina sinaptičkih veza u živom organizmu.



Slika 1 Biološki neuron


Proces učenja (treninga) u veštačkim neuronskim mrežama odvija se promenom težina koje povezuju neurone. Kao što su spoljašnji stimulansi potrebni za učenje kod bioloških organizama, veštačke neuronske mreže koriste trening podatke koji sadrže primere ulazno-izlaznih parova funkcije koju treba naučiti. Ovi podaci se unose u mrežu koristeći reprezentacije ulaza kako bi se izvršile predikcije izlaza. Podaci za obuku pružaju povratne informacije o tačnosti težina u mreži na osnovu toga koliko dobro predviđeni izlaz za određeni ulaz odgovara stvarnim vrednostima

izlaza iz podataka za obuku. Greške koje mreža pravi prilikom izračunavanja funkcije mogu se smatrati oblikom neprijatne povratne informacije, slično onoj koju bi biološki organizam doživeo, što dovodi do prilagođavanja jačina sinaptičkih veza. Na sličan način, težine između neurona u mreži se modifikuju kao odgovor na greške u predikciji. Promena težine ima za cilj modifikaciju izračunate funkcije a koja rezultira tačnijim predikcijama u budućim iteracijama.

Pojam neuronskih mreža uvode MekKuloh (*eng. Mc Culloch*) i Pits (*eng. Pitts*), četrdesetih godina prošlog veka kada su predstavili prvi formalni oblik ovog modela. Njihov pojednostavljeni matematički model ilustruje kako bi biološki neuroni mogli da međusobno deuju u mozgu životinja kako bi izvršavali složene računarske opercije koristeći logiku zasnovanu na tvrdnjama (*eng. propositional logic*).

Kada govorimo u arhitekturi klasičnih neuronskih mreža, možemo reći da se one sastoje od neurona i slojeva. Svaka tradicionalna neuronska mreža se sadrži 3 komponente i to su:

1. Ulazni sloj (*eng. Input layer*) – Prima ulazne podatke
2. Skriveni slojevi (*eng. Hidden layers*) – Obrađuju podatke kroz nelinearne transformacije
3. Izlazni sloj (*eng. Output layer*) – Generiše rezultat



Slika 2 Arhitektura neuronske mreže

Svaki od slojeva se sastoji od više neurona, gde je svaki neuron jednog sloja povezan sa neuronima prethodnog sloja putem težina (*eng. weights*) i bijasa (*eng. bias*). Težine predstavljaju

glavne faktore koji određuju koliko će signal iz jednog neurona prethodnog sloja uticati na aktivaciju neurona u narednom sloju. Sa druge strane, bijas predstavlja dodatnu konstantu koja omogućava modelu da pomeri aktivacionu funkciju neurona nezavisno od ulaznih vrednosti. Svaki neuron ima zadatak da na svom izlazu računa svoju aktivaciju primenom takozvane aktivacione funkcije na određeni ponderisani skup ulaznih podataka, odnosno signala koji su došli iz prethodnog sloja.


Rad jednog neurona možemo matematički prikazati sledećom formulom:

$$y = f\left(\sum_{i=1}^n w_i x_i + bt\right)$$

Jednačina 1 Matematički prikaz neurona

Gde su:

- x_j – ulazne vrednosti za neuron
- w_j – težina koja odgovara ulazu x_i
- $\sum_{i=1}^n w_i x_i$ – zbir ponderisanih ulaza
- bt – bijas
- $f(\cdot)$ – aktivaciona funkcija
- y - izlaz neurona nakon primene funkcije aktivacije



Slika 3 Arhitektura neurona

Kada govorimo o aktivacionoj funkciji, možemo reći da ona predstavlja takođe jednu od ključnih komponenti u arhitekturama neuronskih mreža, jer omogućava da se uvede izvesna nelinearnost u radu samog modela i time pospeši preciznost generalizacije. Ovime se neuronskim mrežama omogućava da modeluju određene složene obrasce i zavisnosti među podacima (Goodfellow et al., 2016). Glavni zadatak aktivacione funkcije je da dohvati ulaznu sumu, odnosno ponderisani zbir ulaznih podataka – signala, najčešće iz prethodnog sloja i transformiše je u adekvatni izlaz (*eng. output*) koji se šalje dalje kroz mrežu, odnosno na naredni sloj.

4.2.2 Neki od modela neuronskih mreža

4.2.2.1 Neuronske mreže (engl. Neural Networks –NN)

Ovi modeli su zasigurno među najpopularnijim jer se široko koriste za rešavanje raznih problema. Kao što sam naziv i sugeriše, inspirisani su biološkim neuronskim mrežama i načinom na koji one funkcionišu, odnosno kako biološki mozak obrađuje informacije. Osnovna jedinica rada, kako u prirodnim, tako i u veštačkim neuronskim mrežama, su neuroni raspoređeni u različite slojeve. Ulazni podaci se transformišu i kreću kroz slojeve mreže, omogućavajući modelovanje i razumevanje složenijih obrazaca unutar njih.

4.2.2.2 Duboke Neuronske mreže (engl. Deep Neural Networks –DNN)

Duboke neuronske mreže su specifična vrsta klasičnih neuronskih mreža, koje se odlikuju prisustvom više skrivenih slojeva (*eng. Hidden layers*). Ova dodatna složenost u arhitekturi je razlog za njihov jedinstveni naziv. Više skrivenih slojeva omogućava mrežama da identifikuju i bolje razumeju složene obrasce i šablone unutar podataka, obradom i transformacijom ulaznih informacija kroz više faza. Na taj način, duboke neuronske mreže mogu da prepoznaju hijerarhijske šablone i odnose u podacima, pri čemu se ovi šabloni obično kreću od jednostavnih obrazaca na nižim nivoima hijerarhije do složenijih i apstraktnijih koncepata na višim nivoima

4.2.2.3 Konvolutivne neuronske mreže (engl. Convolutional Neural Networks – CNN)


Konvolutivne neuronske mreže predstavljaju specifičan tip klasičnih neuronskih mreža, koje se široko koriste za obradu podataka prikazanih u obliku matrica, poput slika ili drugih multimedijalnih sadržaja. Njihova ključna karakteristika je upotreba konvolutivnih filtera (*eng. convolutional filters*), koji omogućavaju automatsku ekstrakciju relevantnih osobina iz podataka, što je i osnovni razlog za njihov naziv. Kroz primenu ovih filtera, model postepeno prepoznaje sve složenije strukture, počevši od osnovnih ivica pa sve do kompleksnijih formi kao što su lica, slova, brojevi ili razni objekti.

4.2.2.4 Rekurentne neuronske mreže (engl. Recurrent Neural Networks –RNN)

Kako bi se nadomestili nedostaci koji su postojali u klasičnim modelima neuronskih mreža, došlo je do pojave novog podtipa ili podarhitekture ovih modela pod nazivom rekurentne neuronske mreže (*eng. Recurrent neural networks, RNN*). Ove mreže praktično imaju sposobnost da „pamte“ informacije o prethodnim ulazima putem takozvanih skrivenih stanja (*eng. hidden states*) (Elman, 1990). Tako osnovna arhitektura RNN-a podrazumeva ulazne, izlazne jedinice i skrivene jedinice prikazano slikom 3.

RNN modeli su zapravo vrsta nadgledanih modela mašinskog učenja (Amalou et al.,2022). RNN je tip neuronske mreže Ovi modeli se najviše koriste za obradu sekvencijalnih podataka, tako

što se vrlo često kombinuju sa takozvanim modelima dugoročno-kratkoročne memorije (*eng. Long term-short term memory*), čime se rešava problem dugoročnih zavisnosti ili eksplozije gradijenata. Sekvencijalni podaci podrazumevaju primere poput teksta, govora, vremenskih serija ili nekih kontinualnih signala. Glavna prednost ovih modela leži u činjenici da oni ove podatke obrađuju sukcesivno, i samim time sva nova stanja zavise od izlaza iz prethodnih slojeva, i na taj način model polako „pamti“ određene obrasce kroz vreme.



Slika 4 Arhitektura rekurentnih neuronskih mreža RNN

RNN ćeliju možemo matematički prikazati kao formulu

$$h_t = \sigma(Wx_h x_t + W_h h_{t-1} - 1 + b_h)$$

Jednačina 2 Model RNN mreže

Pri čemu su

- **x_t** – ulaz u mrežu u trenutnom vremenskom koraku **t**
- **h_t** – skriveno stanje neurona u vremenskom koraku **t**

- $ht - 1$ – skriveno stanje iz prethodnog vremenskog koraka
- Wxh – matrica težina koja povezuje trenutni ulaz xt sa skrivenim stanjem ht
- Whh – matrica težina koja povezuje prethodno stanje $ht - 1$ sa trenutnim stanjem ht
- bh - bijas skrivenog sloja
- $\sigma(\cdot)$ – aktivaciona funkcija

Na osnovu ovoga, možemo zaključiti da informacije iz prethodnih slojeva mogu uticati na trenutni izlaz, što omogućava ovom tipu modela da efikasno modeluje vremenske zavisnosti. Ova karakteristika je posebno korisna u situacijama kada je potrebno predvideti buduće vrednosti na osnovu dostupnih istorijskih obrazaca i sekvencijalne prirode podataka. Međutim, kod RNN mreža mogu se javiti problemi nestajanja (*eng. vanishing gradients*) ili eksplozije gradijenata (*eng. exploding gradients*) što implicira da će kada je vremenski interval dug rezultati prethodnog učenja postepeno izbledeti ili postati manje relevantni. Kako bi se prevezišao ovakav izazov, Hochreiter i Schmidhuber su osmislili model duge kratkoročne memorije (*engl. Long Short-Term Memory*) (Hochreiter, S., & Schmidhuber 1997). Dok je Cho 2014. predstavio GRU (*eng. Gated Recurrent Unit – GRU*), jednostavniju vrstu LSTM modela koji koriste manje parametara, te su stoga optimalniji za neke jednostavne i brže obuke.

4.2.2.5 LSTM model

Kao što je ranije pomenuto, ključni problemi sa neuronskim mrežama, kao što su nestajući ili eksplodirajući gradijenti, obično se javljaju tokom obuke modela na dugim sekvencijalnim podacima. Ovo za posledicu ima uticaj na preciznost konačnih predikcija i sposobnosti modela da generalizuje i ustanovi naučene obrasce (Bengio, Simard, & Frasconi, 1994). U cilju prevazilaženja postojećih nedostataka, tokom devedesetih godina prošlog veka došlo je do razvoja modela dugoročno-kratkoročnih memorija (*eng. Long Short-Term Memory – LSTM*) (Hochreiter & Schmidhuber, 1997).

Ako posmatramo arhitekturu ovih modela, možemo videti da ona predstavlja proširenje arhitekture klasičnih rekurentnih neuronskih mreža uvođenjem takozvanih memorijskih ćelija (*eng. memory cell*). Dakle, osnovna jedinica LSTM-a je memorijski blok koji se uglavnom sastoji

od memorijske ćelije i tri upravljačke jedinice i to ulazne kapije, izlazne kapije i kapije zaborava. Kapije (*eng. gates*) su zapravo posebni mehanizmi koji zapravo služe za filtriranje informacija, odnosno pomažu samoj mreži da odredi koje informacije treba zadržati, zaboraviti ili dodati (Gers, Schmidhuber, & Cummins, 2000). Na osnovu izloženog može se zaključiti da ovi modeli donekle simuliraju biološko pamćenje, odnosno biološki mehanizam obrade i skladištenja nekih informacija.

Tabela 1 Prikaz tipova kapija i njihove primene

Tip kapije	Simbol	Funkcija	Matematička formula
Ulazna kapija	i_t	Kontroliše koliko novih informacija iz trenutnog ulaza x_t treba dodati u stanje ćelije	$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$
Kapija zaboravljanja	f_t	Odlučuje koje informacije iz prethodnog stanja ćelije C_{t-1} treba zaboraviti	$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$
Izlazna kapija	o_t	Određuje koji deo stanja ćelije C_t ide na izlaz h_t	$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$
Ćelija kandidat	$\tilde{C}_t$	Kreira potencijalni novi sadržaj stanja ćelije koji može biti dodan preko input gate	$\tilde{C}_t = \tanh(W_C[h_{t-1}, x_t] + b_C)$

Pri čemu su

- h_{t-1} - prethodni izlaz
- x_t - trenutni ulaz
- C_{t-1} - prethodno stanje ćelije
- σ - sigmoid funkcija aktivacije
- ***tanh*** - tangens hiperbolična funkcija

Prethodno stanje ovih ćelija C_{t-1} se može delimično „resetovati“, kako bi se napravio dovoljan prostor za ažurno stanje same ćelije C_t , koje se zatim popunjava nekim novim informacijama. Matematički gledano, ovo možemo formalizovati korišćenjem takozvanog elementnog proizvoda (*eng. Element-wise product*), označen simbolom $\odot$, koji se koristi zajedno sa kapijom zaboravljanja f_t . Prikaz ovog proizvoda dat je sledećom formulom:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$$

Jednačina 3 Prethodno stanje ćelije

Inicijalni izlaz sigmoidalne funkcije o_t se dalje transformiše u zavisnosti od trenutnog stanja ćelije, i ovo je prikazano narednom formulom:

$$o_t = \sigma(W_o x_t + U_o h_{t-1} - 1 + b_o)$$

Jednačina 4 Izlaz sigmoidalne funkcije

Konačni izlaz se zatim prosleđuje kroz *tanh* sloj, čime se formira ažurirano skriveno stanje modela, a što je predstavljeno formulom:

$$h_t = o_t \odot \tanh(C_t)$$

Jednačina 5 Konačni izlaz prosleđen tanh funkciji

Pri čemu su:

- W_o, U_o – težinske matrice
- b_o - pristrasnost

4.2.2.6 GRU model

Rekurentna jedinica ograničena kapijama (eng. *Gated Recurrent Unit – GRU*) koju je predstavio Cho 2014. godine sa ciljem prevazilaženja problema nestajućih gradijenata sa kojim se susreću konvencionalne rekurentne mreže i predložila arhitektura sa manje parametara u odnosu na LSTM arhitekturu. Poput LSTM, GRU koristi kapije koje modulišu protok informacija unutar jedinice, pa je ideja ovih modela je da zapravo predstave dosta jednostavniju varijantu prethodno opisane LSTM arhitekture, uz zadržavanje svih njihovih prednosti. Takođe dosta se olakšala implementacija i trening ovih modela, uz dosta manje potrebnih parametara i računarskih resursa (Cho et al., 2014). Zbog svoje jednostavne arhitekture i mogućnosti da dosta ubrzaju process treniranja, ovi modeli stižu jako veliku popularnost i primenu u mnogim istraživanjima i eksperimentima koji se odnose na obradu prirodnog jezika (eng. *Natural Language Processing*,

NLP), prepoznavanje govora ili predviđanje vremenskih serija (Jozefowicz, Zaremba, & Sutskever, 2015).

Jednostavnost ovih arhitektura se ogleda u tome što za razliku od klasičnih LSTM modela, GRU modeli koriste zapravo samo dve glavne kapije:

1. Reset kapija (*eng. Reset gate*) – odlučuje koliko prethodnih informacija treba ignorisati, odnosno zanemariti, a koja se može matematički predstaviti sledećom formulom:

$$rt = \sigma(Wrxt + Urht - 1 + br)$$

Jednačina 1 Reset kapija

2. Ažurirajuća kapija (*eng. Update gate*) – odlučuje koliko trenutnih informacija treba ažurirati i zadržati za neki naredni vremenski korak, a koja se može formalizovati narednom formulom:

$$zt = \sigma(Wzxt + Uzht - 1 + bz)$$

Jednačina 7 Ažurirajuća kapija

Takođe, za razliku od LSTM-a modela, ove arhitekture ne koriste memorijske ćelije, već imaju takozvano skriveno stanje neurona, u okviru kojih se čuvaju sve informacije. Ovo dodatno pojednostavljuje njihovu celokupnu strukturu i samim time omogućava značajno bržu propagaciju određenih informacija kroz ostatak mreže (Chung et al., 2014).

Kandidatsko skriveno stanje neurona možemo predstaviti sledećom formulom:

$$h_{\sim t} = \varphi(Whxt + Uh(rt \odot ht - 1) + bh)$$

Jednačina 8 Kandidatsko skriveno stanje neurona

Dok se ažuriranje ovog stanja može matematički formalizovati na sledeći način:

$$ht = (1 - zt) \odot ht - 1 + zt \odot h_{\sim t}$$

Jednačina 9 Ažuriranje kandidatskog stanja

Pri čemu su:

- x_t — ulazni vektor u vremenskom koraku t
- h_{t-1} — skriveno stanje iz prethodnog koraka (vektor dimenzije n_h)
- z_t — vektor vrata ažuriranja, sa vrednostima u intervalu $[0,1]$
- r_t — vektor vrata resetovanja, sa vrednostima u intervalu $[0,1]$
- $\tilde{h}_t$ — kandidatsko (privremeno) skriveno stanje (vrednosti obično u $[-1,1]$)
- h_t — ažurirano skriveno stanje u koraku t
- W_z, W_r, W_h — težinske matrice za ulaz x_t (dimenzije $n_h \times n_x$)
- U_z, U_r, U_h — težinske matrice za prethodno skriveno stanje h_{t-1} (dimenzije $n_h \times n_h$)
- b_z, b_r, b_h — vektori bias-a (dimenzije n_h)
- $\sigma(\cdot)$ — sigmoidna aktivaciona funkcija: $\sigma(u) = \frac{1}{1+e^{-u}}$
- $\varphi(\cdot)$ — obično tanh ili druga nelinearna funkcija (često tanh)
- $\odot$ — element-po-element (*eng. Element-wise*) proizvod

4.3 Model zasnovan na mehanizmu pažnje

Luongov mehanizam pažnje (Luong, 2015) široko je korišćen u neuronskom mašinskom prevođenju i sekvenca-u-sekvencu (sequence-to-sequence, seq2seq) modelima, naročito u kombinaciji sa LSTM mrežama (Mati et al.,2024; Raffel et al.,2017) Primarni cilj Luongovog mehanizma pažnje jeste unapređenje poravnanja (*engl.alignment*) između enkodera i dekodera u seq2seq arhitekturama, omogućavajući dekoderu da se u svakom koraku dekodiranja fokusira na najrelevantnije delove ulazne sekvence. Luong pažnja računa skorove pažnje neposrednim upoređivanjem tekućeg skrivenog stanja dekodera sa svim skrivenim stanjima enkodera, pri čemu se generiše kontekstni vektor koji pomaže dekoderu da donosi tačnije predikcije. Skor pažnje određuje se primenom specifične scoring funkcije, kao što su skalarni proizvod (dot), general ili konkatenacija (concat), a zatim se normalizuje softmaxs funkcijom.

Luongov mehanizam pažnje može se kategorizovati u dve osnovne klase: globalnu pažnju i lokalnu pažnju. Kod globalne pažnje, dekoder u svakom vremenskom koraku uzima u obzir sva skrivena stanja enkodera, čime se obezbeđuje da se celokupna ulazna sekvenca razmotri tokom

procesa dekodiranja. Nasuprot tome, lokalna pažnja sužava fokus na specifičan podskup stanja enkodera unutar dinamički određenog prozora, na taj način smanjujući računarsku složenost uz zadržavanje snažnih performansi u različitim zadacima. Njena sposobnost da obezbedi dinamički kontekst računanjem ponderisanih kombinacija stanja enkodera čini je važnom komponentom mnogih savremenih LSTM-zasnovanih seq2seq Sistema.

Ovaj rad koristi LSTM model zasnovan na Luongovom mehanizmu pažnje. U svakom vremenskom koraku dekodiranja t izračunava se težina pažnje w_t za izvorne tokene, uz uslov da $\sum_s w_t(s) = 1$ i da za svako s važi $w_t(s) \geq 0$. Skriveno stanje h_t odgovara predviđenom tokenu u odgovarajućem vremenskom koraku, dok ponderisana suma $\sum_s w_t(s) * h^s$ obezbeđuje kontekstni vektor. Različiti mehanizmi pažnje razlikuju se po načinu računanja ovih težina. U Luongovom modelu pažnje, težine se dobijaju primenom softmax funkcije na skalirane skorove svakog tokena. Skor se računa korišćenjem skalarnog proizvoda između skrivenog stanja dekodera h_t i skrivenog stanja enkodera h_s , nakon čega sledi linearna transformacija preko matrice W_a .

4.4 Problem odabira hiperparametara u dubokom učenju

Optimizacija hiperparametara ključan je aspekt mašinskog učenja i ispitivana je u kontekstu predviđanja nezaposlenosti korišćenjem metaheurističkih algoritama. S obzirom na složenost modela dubokog učenja, posebno rekurentnih neuronskih mreža, možemo reći da je pravilno odabiranje hiperparametara jedan od ključnih zadataka prilikom njihove implementacije.

Hiperparametri ne predstavljaju rezultat težina koje je model naučio tokom treniranja, već vrednosti koje programmer sam unapred definiše prilikom inicijalne implementacije, a pre samog procesa treninga (Bengio, 2012).

Kao i većina procesa koji su do sada spomenuti, podešavanje hiperparametara se može odvijati ručno, ali se takođe može i automatizovati. Ručno podešavanje ovih hiperparametara može biti korisno u nekim ekperimentalnim situacijama ili kada su modeli jednostavni i ne treniraju se nad većim skupom podataka. Međutim, prilikom rešavanja nekih značajnih i realnih problema, ovaj proces nije dovoljno skalabilan i dovoljno te se se praktično mora uključiti i faktor ljudske greške. Kako bi se ovi izazovi prevazišli, došlo je do pojave nove oblasti koja se specifično bavi

automatizovanim pristupom optimizacije hiperparametara koristeći razne metode i algoritme (Feurer & Hutter, 2019).

5 Algoritmi optimizacije hiperparametara

Optimizacione algoritme moguće je podeliti na determinističke i stohaističke, ili pak na egzaktna i aproksimativna. Stohastički algoritmi mogu biti heuristički (značilo bi da se nešto pronađe metodom pokušaja i pogrešaka) i metaheuristički.

5.1 Heurističke tehnike optimizacije

Heurističke metode optimizacije hiperparametara predstavljaju značajno jednostavne, ali vrlo efikasne, a posebno pogodne kada se primenjuju u situacijama gde matematički formalizovan model nije dostupan, ili kada je prostor pretrage prevelik da bi bio u dovoljnoj meri analiziran, u upotrebi su još od perioda pedesetih godina prošlog veka (Kirkpatrick et al., 1983). Upotrebom ovih modela došlo se do zaključka da igraju ključnu ulogu u poboljšavanju performansi učenja modela i da dosta mogu uticati na preciznost konačnih predikcija, što je dovelo do velike popularnosti u daljem naučnom istraživanju ove oblasti.

Ove metode su najčešće korišćene za rešavanje problema optimalnog izbora hiperparametara, koje se do tada, rešavalo isključivo manuelnim putem. Kako su vremenom modeli, ali i sami problemi koji su se rešavali postali složeniji, ovakav pristup je postajao sve manje i manje održiv, a verovatnoća greške izazvane ljudskim faktorom, tokom ovog procesa sve veća. Kako bi se prevazišli i predupredili nedostaci ovakvog pristupa, na scenu stupaju primene dveju relevantnih heurističkih metoda, koje i danas predstavljaju predmet brojnih istraživanja, a to su: mrežna (*eng. Grid search*) i nasumična pretraga (*eng. Random search*).

Izuzev rešavanja mnogobrojnih problema manualnog pristupa odabira optimalnih hiperparametara, ove dve metode su takođe predstavile i naučnu osnovu za razvoj dosta naprednijih pristupa, kao što su na primer Bajesova optimizacija, genetski algoritmi optimizacije i algoritmi rojeva čestica (Bergstra & Bengio, 2012; Snoek et al., 2012).

Iako su obe metode ostvarile svoj veliki potencijal na naučnom polju, dosta dugo je tehnika mrežne pretrage bila popularnija, zbog svoje jednostavne implementacije i lakog razumevanja. Međutim, nešto kasnije, brojnim dodatnim istraživanima i analizama utvrđeno je da i metoda nasumične pretrage takođe ostvaruje dosta dobre rezultate u praksi (Bergstra & Bengio, 2012).

5.1.1 Mrežna pretraga

Algoritam mrežne pretrage (*eng. Grid search - GS*) predstavlja najčešći pristup u optimizaciji hiperparametara, kombinujući pretragu mreže i manualno podešavanje. Nekoliko je različitih benefita pri korišćenju mrežnih pretraga recimo, manualna optimizacija omogućava uvid tokom rada u process optimizacije, jednostavna je za implementaciju, ne postoje tehničke prepreke za manualnu optimizaciju. Međutim, može se reći da ovaj algoritam “trpi prokletstvo” dimenzionalnosti, broj kombinacija mogućih vrednosti raste eksponencijalno sa brojem hiperparametara, može se zaključiti da ima malu prilagodljivost.

Ovo dalje možemo matematički formalizovati koristeći narednu formulu:

$$\theta^* = \arg \max_{\theta_1 \in V_1, \theta_2 \in V_2, \dots, \theta_n \in V_n} \text{Score}(\theta_1, \theta_2, \dots, \theta_n)$$

Jednačina 10 Mrežna pretraga

Gde su:

- θ_i — hiperparametar i-tog tipa
- V_i — skup vrednosti za θ_i
- θ^* — optimalna kombinacija hiperparametara
- $\text{Score}(\dots)$ — metrička funkcija koja meri performanse modela (npr. tačnost, F1-score)

5.1.2 Metoda slučajnog pretraživanja (*eng. Random search RS*)

Kako i sam naziv kaže, ova metoda nasumične pretrage (*eng. Random search*) podrazumeva da se nasumično biraju kombinacije različitih hiperparametara iz nekih unapred definisanih distribucija. Umesto iscrpne pretrage mrežnog prostora, ova tehnika se bazira na stohastičkom uzorkovanju prostora (Bergstra & Bengio, 2012).

Za isti broj iteracija metoda slučajnog pretraživanja (RS) ima polje rezultate , pa možemo reći, nadmašuje algoritam mrežne pretrage (GS), poseduje sofisticiranije pristupe za podešavanje hiperparametara. U visokodimenzionalnim prostorima RS zahteva znatno manje računarskih resursa u odnosu na GS.

Ako uzmemo isti primer kao u prethodnoj sekciji sa parametrima stope učenja i brojem neurona, ali pod pretpostavkom da želimo da testiramo pet različitih kombinacija – ovaj algoritam će iz dostupnog prostora izabrati nasumično pet tačaka. Na ovaj način se na postojeće vrednosti parametara mogu dodati i vrednosti iz različitih delova prostora koji se pretražuje, te se tako mogu ispitati i određene oblasti koje bi algoritam mrežne pretrage možda propustio.

Ovaj algoritam možemo matematički formalizovati korišćenjem sledeće formule:

$$\theta^* = \arg \max_{\theta \sim P(\Theta)} \text{Score}(\theta)$$

Jednačina 2 Metoda slučajnoj pretraživanja

Gde su:

- θ — vektor hiperparametara
- $P(\Theta)$ — distribucija iz koje se nasumično uzorkuju vrednosti hiperparametara
- $\text{Score}(\theta)$ — metrička funkcija (npr. tačnost, F1-score, RMSE...)
- θ^* — kombinacija hiperparametara koja daje najbolji rezultat

U neke ključne nedostatke ovog pristupa, možemo uključiti sledeće:

1. Rezultati mogu pretežno da zavise od faktora sreće, zbog svoje stohastičke prirode
2. Nema sigurnih garancija da će optimalna vrednost uvek biti pronađena
3. Zbog ovoga je teže analizirati osetljivost model na odabir vrednosti hiperparametara

Implementacijom klasičnih, heurističkih metoda, značajno je porasla popularnost automatizovanom pristupu prilikom odabira hiperparametara, čime su se drastično poboljšale performanse i preciznost mnogih modela, pogotovu u kontekstu predviđanja vremenskih serija.

5.2 Metaheurističke tehnike

Pojam Metaheuristika (*eng. Metaheuristics*) potiče još iz osamdesetih godina prošlog veka, a popularizovao ga je Glover (Glover, 1986). Možemo reći da metaheuristike zborno predstavljaju posebnu podoblast optimizacije hiperparametara, koje se baziraju na određenom skupu algoritama i njihovom korišćenju u rešavanju određenih kompleksnijih problema, koje klasične heurističke metode ne mogu rešiti (Talbi, 2009). Pa tako metaheurističke algoritme posmatramo kao unapređene heuristike zbog prefiksa -meta, koji podrazumeva “nešto iznad”, “više”.

Kao ključne karakteristike ovih modela, možemo izvoditi:

1. Stohastička priroda – koriste slučajnost u generisanju i selekciji optimalnog rešenja
2. Globalna pretraga – izbegavaju lokalne minimume pomoću strategija eksploracije
3. Ne zavise od gradijenata – ovo ih posebno čini primenljivim u rešavanju problema sa skupovima podataka koji su nelinearni
4. Veća fleksibilnost i robusnost – vrlo lako se prilagođavaju različitim tipovima problema i mogu davati prilično stabilna rešenja

Postoje **prirodom inspirisane metaheuristike** odnosno, algoritmi koji oponašaju prirodne procese i metaheuristike koje nisu inspirisane prirodom.

Metaheuristike koje nisu inspirisane prirodom, tu kao što i sam naziv kaže, spadaju oni algoritmi koji nisu inspirisani prirodnim procesima, niti ponašanjem životinja u prirodi. Postoji veliki broj metaheuristika koje pripadaju ovoj kategoriji, a samo neke od njih, su Monte Karlo metod (*eng. Monte Carlo method*), lokalna pretraga, gramzivi algoritmi i tabu pretraga.

U grupu **metaheuristika inspirisanih prirodom**, spadaju oni algoritmi koji su inspirisani nekim prirodnim fenomenom, ponanašanjem ljudi ili životinja. Ove algoritme možemo podeliti u dve grupe i to: Evolutivni algoritme i metaheuristike inspirisane inteligencijom rojeva. Postoji veliki broj algoritama inspirisanih prirodom, samo neki od njih i su: Evolutivni algoritam, Genetski algoritam i Simulirano kaljenje, metaheuristike koje su inspirisane inteligencijom rojeva.

Evolutivni algoritmi (eng. *Evolutionary Algorithms - EA*) su stohastičke populacione metaheuristike (eng. *Population-Based*), metaheuristike bazirane na populaciji, koje su uspešno primenjivane na mnoge stvarne i kompleksne problem, zasnovani su na ideji takmičenja. Oni predstavljaju klasu iterativnih optimizacionih algoritama koji simuliraju evoluciju vrsta, a baziraju se na evoluciji populacije jedinki. Inicijalna populacija se kreira slučajnim generisanjem. Ciljana funkcija dodeljuje svakoj jedinki vrednost fitnesa koja meri njenu sposobnost za zadati problem. U svakoj iteraciji, biraju se jedinke koje će biti roditelji, pri čemu one sa višim fitnesom imaju veće izglede da budu odabrane. Izabrani roditelji stvaraju potomke primenom operatora varijacije. Na kraju se primenjuje strategija zamene odnosno selekcije koja određuje koja će jedinka ostati u populaciji i nastaviti evoluciju, a process se ponavlja dok se ne ispuni kriterijum zaustavljanja. Genotip predstavlja kodiranje, dok fenotip predstavlja rešenje. Dakle, genotip mora biti dekodiran kako bi se generisao fenotip. Fitnes (prilagođenost jedinke) označava koliko je jedinka sposobna da opstane u datom okruženju. Prilikom direktnog kodiranja genotip je sličan fenotipu. Ukoliko se primeni indirektno kodiranje genotip i fenotip imaju različite strukture, pa je neophodna funkcija dekodiranja koja prevodi genotip u fenotip. (Talbi, 2009)

Evolutivni algoritmi podrazumevaju četiri kategorije i to su prema Simonu (Simon, 2013) : Genetski algoritmi (eng. *Genetic Algorithms - GA*), Evolutivno programiranje (eng. *Evolutionary Programming*), Evolutivne strategije (eng. *Evolutionary Strategies*), i Genetsko programiranje (eng. *Genetic Programming*).

Genetski algoritmi (eng. **Genetic Algorithms - GA**) predstavljaju najznačajniju grupu , podrazumeva netradicionalnu tehniku pretrage. Netradicionalne metode mogu prevazići slabosti klasičnih pristupa, poput pretpostavke da su promenljive kontinualne. Genetski algoritam (GA) je posebno pogodan za probleme sa diskretnim promenljivama i u većini slučajeva pronalazi globalno optimalno rešenje (Nayak, 2020). Genetski algoritmi su računarski modeli koji oponašaju prirodnu selekciju kako bi rešili optimizacione zadatke. Neke od ključnih osobina su da se populacija sastoji od jedinki, pri čemu mnoge imaju sposobnost razmnožavanja. Jedinke opstaju ograničeno vreme. Unutar populacije postoji raznolikost. Na kraju, veća sposobnost preživljavanja usko je povezana sa većim reproduktivnim uspehom. Svaka pojedinačna osobina određena je dvema kopijama istog gena (parom alela), upravo zato se ljudi smatraju diploidnim organizmima jer za svaku karakteristiku imaju po dva alela. Kod nekih biljaka i životinja postoji haploidno stanje, gde se osobina određuje samo jednim skupom gena. Postoje i poliploidni organizmi, kod

kojih osobine zavise od više od dva skupa gena. U diploidnim organizmima aleli mogu biti dominantni ili recesivni. Ako su prisutni jedan dominantni i jedan recesivni alel, ispoljiće se karakteristika koju određuje dominantni. Recesivni alel određuje osobinu samo kada su obe kopije recesivne (oba alela ista) (Simon, 2013). Genetski material se ne prenosi na potomstvo kao savršena kopija, pa tokom prenosa dolazi do izmena odnosno mutacija. Uzroci pojave mutacija uključuju nesavršen rad bioloških mehanizama. Većina mutacija je neutralna pa kao takva ne ostavlja gotovo nikakav uticaj na potomstvo.

5.3 Pregled algoritma čestica rojeva

5.3.1 Teorijska osnova

Algoritam čestica rojeva (*eng. Particle Swarm Optimizer – PSO*) predstavlja jedan od popularnijih i često korišćenih metaheurističkih algoritama. To je je stohastička, populaciona metaheuristika zasnovana na konceptu inteligencije rojeva. Svoju primenu je pronašao u rešavanju brojnih optimizacionih problema (Kennedy & Eberhart, 1995). Ono što je glavna karakteristika ovog algoritma jeste to da je on u potpunosti osmišljen da imitira kolektivno ponašanje prirodnih sistema, poput jata ptica i riba koja zajednički traže izvore hrane. Koordinacija se spontano pojavljuje kroz lokalne interakcije i kretanja, bez centralne kontrole. Prvobitno je razvijena za kontinualne optimizacione zadatke, ali se uspešno prilagođava i diskretnim problemima.

Za razliku od mnogih drugih metoda, ovaj algoritam ne koristi operatore ukrštanja niti mutacije. Umesto toga, oponaša kolektivno kretanje populacije: modelira čestice/agente koji se kreću kroz prostor pretrage. Svaki agent ažurira svoju poziciju na osnovu sopstvenog iskustva i informacija dobijenih od ostatka roja (populacije). Ovakav pristup omogućava efikasno pokrivanje prostora rešenja i dobar balans između istraživanja (eksploracije) i iskorišćavanja (eksploatacije).

Kada govorimo o eksploraciji, u ovom kontekstu je možemo definisati kao sposobnost čestica da istražuju različite oblasti datog prostora pretrage. Na ovaj način se znatno povećava verovatnoća pronalazjenja globalnog optimuma. Suprotno ovome, eksploatacija predstavlja fokusirano pretraživanje u okviru već nađenih optimalnih rešenja. Ovime se dosta dobro

optimizuju već postojeće pozicije agenata u okviru prostora rešenja, te se samim time poboljšava i kvalitet dobijenog rešenja (Kennedy & Eberhart, 1995).

5.3.2 Matematički model

Model PSO algoritma možemo matematički formalizovati koristeći formule za predstavljanje ažuriranje brzine i konkretne pozicije čestica u okviru dostupnog prostora rešenja.

Ažuriranje brzine čestice možemo predstaviti sledećom formulom:

$$v_i^{t+1} = w \cdot v_i^t + c_1 \cdot r_1 \cdot (pbest_i - x_i^t) + c_2 \cdot r_2 \cdot (gbest - x_i^t)$$

Jednačina 12 Ažuriranje brzine čestice

Ažuriranje pozicije čestice se može predstaviti na sledeći način:

$$x_i^{t+1} = x_i^t + v_i^{t+1}$$

Jednačina 13 Ažuriranje pozicije čestice

Gde su:

- x_i^t - trenutna pozicija i-te čestice u iteraciji t
- v_i^t - trenutna brzina i-te čestice u iteraciji t
- $pbest_i$ - najbolja pozicija do sada i-te čestice
- $gbest$ - globalno najbolja pozicija svih čestica
- W - težinski faktor inercije (*eng. inertia weight*)
- c_1, c_2 - koeficijenti učenja (*eng. cognitive components*)
- r_1, r_2 - slučajne vrednosti u intervalu [0,1]

6 Pregled istraživačkog dela

Nakon teorijske postavke i analize oblasti koje prate istraživački deo ove disertacije, u ovom poglavlju biće predstavljeno samo istraživanje, podaci, kao i opis eksperimenata koji su izvršeni i rezultati koji su dobijeni izvođenjem istih. Kao deo samog zaključka, biće dat kratak osvrt na hipoteze opisane na samom početku ovog rada i kako su zapravo ovi eksperimenti, odnosno dobijeni rezultati pomogli u njihovom dokazivanju.

6.1.1 Opis istraživanja

Praćenje trendova nezaposlenosti od suštinskog je značaja, jer predstavlja važan indikator opšteg stanja ekonomije, pomažući kreatorima politika, vladama i centralnim bankama da procene ekonomske uslove i, po potrebi, sprovedu delotvorne politike (Uddin & Rahman, 2023; Priambodo 2021). Stalne promene stopa nezaposlenosti odražavaju se na ekonomske cikluse, poput ekspanzije ili recesije, utičući na odluke o programima otvaranja radnih mesta, monetarnim politikama i inicijativama za razvoj radne snage (Akhmad et al., 2022). Ovi trendovi takođe su od velikog značaja za preduzeća, budući da direktno utiču na potrošnju, tražnju i investicione strategije, čineći ih ključnim za poslovne aktivnosti kao što su planiranje, zapošljavanje i tržišna ekspanzija (Christiano, et al., 2021; Fonseca, 2022).

Već uveliko razvijena oblast mašinskog učenja, a posebno predviđanje vremenskih serija, čuvaju veliki i još uvek nedovoljno istraženi potencijal za unapređenjem prognoza nezaposlenosti. Analizom postojeće literature uočen je značajni prostor za dodatno poboljšanje postojećih modela kroz primenu naprednijih arhitektura neuronskih mreža, kao i tehnika optimizacije.

Međutim, s obzirom na to da na performanse značajno može uticati i izbor adekvatnih hiperparametara, ovaj rad predlaže implementaciju modifikovane varijante algoritma za optimizaciju koji se bazira na roju čestica (*eng. Particle Swarm Optimizer, PSO*), kako bi se što bolje pomoglo u dodatnoj optimizaciji same arhitekture modela i parametara treniranja, bez gubitka u preciznosti konačnih rezultata. Razlog za izbor baš ovog optimizacionog algoritma zapravo leži u Wolpertovom (*eng. Wolpert*) teoremu o nepostojanju univerzalnog rešenja (*eng. No-free lunch theorem*), koji navodi da ne postoji univerzalan superioran algoritam koji daje najbolje rezultate za svaki optimizacioni problem (Wolpert & Macready, 1997). Zbog toga je neophodno

eksperimentisati sa više optimizacionih algoritama, a kako je ovaj algoritam postigao veoma ohrabrujuće rezultate tokom eksperimenata manjeg obima, izabran je za dalje modifikacije kako bi se postigli još bolji rezultati u rešavanju problema predviđanja nezaposlenosti.

Kada govorimo o konačnim rezultatima ovog istraživanja, kako bi se oni što jasnije sagledali i kako bi se što bolje razumeo doprinos primene ovakvog modela, sprovedena je i komparativna analiza korišćenjem javno dostupnih podataka nezaposlenosti, a nad kojima je takođe primenjeno nekoliko savremenih optimizacionih algoritama. Dobijeni rezultati su prošli kroz detaljnu statističku validaciju kako bi se potvrdila značajnost dobijenih nalaza.

Nakon svega izloženog, naučni doprinos ovog istraživanja možemo kategorisati na sledeći način:

- Predložena je modifikovana implementacija dobro poznatog PSO algoritma, sa ciljem adresiranja uočenih nedostataka osnovne (baseline) implementacije.
- Razvijeni algoritam je korišćen za optimizaciju hiperparametara LSTM mreže u zadatku prognoziranja nezaposlenosti.
- Sprovedena je temeljna komparativna analiza sa nekoliko savremenih, snažnih optimizatora, primenjenih u identičnoj eksperimentalnoj postavci.

6.1.2 Korišćene procedure i tehnike

Proces podešavanja hiperparametara predstavlja ključnu komponentu u prilagođavanju ML modela za precizno prognoziranje i efikasnu implementaciju. Pažljivim odabirom hiperparametara, prediktivni modeli mogu se prilagoditi specifičnim aplikacijama, čime se unapređuju ukupne performanse (Harvat & Martín-Guerrero, 2022; Zang & Shami, 2020). Dodatno, optimizacija može rezultirati modelima koji zahtevaju manje računarskih resursa, postižući ravnotežu između tačnosti i efikasnosti. Ipak, ovaj proces podešavanja hiperparametara suočava se sa značajnim izazovima zbog obimnih domena pretrage, što ga čini NP-teškim (NP-hard) problemom (Bassey, 2023). Radi savladavanja složenosti NP-teških problema, istraživači su ispitali različite tehnike, pri čemu su metaheuristički algoritmi postali široko korišćen pristup. Metaheurističke optimizacione metode oslanjaju se na stohastičke postupke pretrage, vođene slučajnošću, radi efikasnog istraživanja prostora pretrage i identifikacije optimalnih rešenja. Za razliku od tradicionalnih determinističkih algoritama, koji se uobičajeno smatraju neadekvatnim

za NP-teške zadatke zbog nerazumno visokih računarskih zahteva, metaheuristički algoritmi su sposobni da pronađu dovoljno dobra rešenja (iako ne garantovano i globalno najbolja) u prihvatljivom vremenu i uz razumne računarske resurse. Tokom godina predstavljeni su brojni metaheuristički algoritmi, poput PSO (Kennedy&Eberhart, 1995), koji je korišćen i u ovom istraživanju, zatim algoritma slepih miševa (*bat algorithm*, BA) (Ocal 2024), algoritma svitaca (*firefly algorithm*, FA) (Yang & He, 2013) i genetskih algoritama (GA) (Yang & He, 2013). Novije metode obuhvataju algoritam pretrage reptila (reptile search algorithm, RSA) (Mirjalili, 2019), algoritam optimizacije rakova (*crayfish optimization algorithm*, COA) (Abualigah et al.,2022), algoritam optimizacije šimpanzi (*chimp optimization algorithm*, ChOA) (Jia et al.,2020) i sinh–cosh optimizator (SCHO) (Bai et al.,2023) Ovi algoritmi su demonstrirali značajan uspeh u različitim domenima, naročito u podešavanju hiperparametara ML modela. Među zapaženim primenama izdvajaju se oblast zdravstva (Minic et al.,2022; Jovanovic et al., 2023; Jovanovic et al., 2023) , analiza sentimenta (Jovanovic et al., 2023; Mladenovic et al.,2024), prognoziranje u oblasti obnovljive energije (Dobrojevic et al.,2024 & Pavlov-Kagadejev et al., 2024), kao i drugi zadaci prognoziranja vremenskih serija (Damaševičius et al., 2024 & Viloth et al., 2024).

6.1.2.1 Polazni (baseline) algoritam optimizacije rojem čestica

Kao što je ranije napomenuto, jedan od glavnih nedostataka klasičnog algoritma optimizacije rojem čestica je njegova tendencija ka sporijoj konvergenciji u kasnijim iteracijama njegovog izvršavanja.

Standardna PSO metaheuristika pripada populacionim optimizacionim metodama i nadahnuta je kolektivnim obrascima ponašanja jata ptica i riba (Kennedy &Eberhart ,1995). Istražuje n-dimenzioni prostor pretrage, pri čemu kandidatska rešenja, svako predstavljeno kao čestica, odgovaraju mogućim vrednostima ciljne funkcije i kreću se unutar tog n-dimenzionog prostora. Sve čestice održavaju zapis o svojoj lično najboljoj poziciji (pbest), dok istovremeno prate najbolju poziciju koju su pronašle druge čestice u svom susedstvu (nbest). Kada se čitav roj tretira kao jedno susedstvo, najbolja pozicija među svim jedinkama smatra se globalno najboljom (gbest). Pošto čestice razmenjuju podatke o pejzažu pretrage, PSO se svrstava u tehnike inteligencije roja.

PSO započinje nasumičnim dodeljivanjem početnih pozicija svim česticama. Svaka čestica potom se kreće ka najbolje rangiranoj čestici, a čitava populacija kolektivno teži pronalaženju globalno optimalne lokacije. U fazi inicijalizacije, pozicije i brzine čestica nasumično se generišu primenom procedure inicijalizacije PSO-a, kako je navedeno jednačinom 14

$$x_{i,d}(0) = rnd() \times (max - min) + min$$

Jednačina 14 Inicijalizacija

Gde $x_{i,d}(0)$ odgovara početnoj poziciji i-tog rešenja u dimenziji d, funkcija označena kao rnd() koristi se za generisanje proizvoljnog broja u intervalu [0, 1], dok max i min predstavljaju granice prostora pretrage za datu dimenziju.

Svaka čestica iterativno prilagođava svoju poziciju uz očuvanje svoje brzine. Lično najbolja pozicija čestice predstavljena je kao $p_{i,d}$, dok je globalno najbolja pozicija data sa $p_{g,d}$.

Trenutna brzina čestice i duž d-te dimenzije u iteraciji t može se izračunati primenom jednačina

$$v_{i,d}(t) = \omega \times v_{i,d}(t-1) + c1 \times rnd_1 \times (p_{i,d}(t-1) - x_{i,d}(t-1)) + c2 \times rnd_2 \times (p_{g,d} - x_{i,d}(t-1))$$

Jednačina 15 brzina

$$v_{i,d} \in [-v_{max}, v_{max}]$$

Jednačina 16

Jednačine 15,16 obuhvataju nekoliko ključnih elemenata. Funkcije rnd1 i rnd2 generišu nasumične vrednosti u opsegu [0, 1]. Kontrolne promenljive c1 i c2 upravljaju uticajem ličnog iskustva i socijalne interakcije. Težinski faktor inercije ω reguliše ravnotežu između lokalnog i globalnog istraživanja (eksploracije). Brzina svake čestice ograničena je na interval $[-v_{max}, v_{max}]$ pri čemu je v_{max} unapred definisana maksimalna granica. Ovo ograničenje obezbeđuje da aktivnost čestice ostane unutar zadatog prostora pretrage i ograničava istraživanje na region između trenutne pozicije čestice i ciljane lokacije.

6.1.2.2 Modifikovani algoritam optimizacije rojem čestica

Osnovni PSO (Kennedy & Eberhart, 1995) algoritam pokazuje obećavajuće performanse u optimizaciji. Iako spada među najranije optimizacione pristupe, i dalje se široko primenjuje za optimizaciju arhitektura mašinskog učenja (ML). Nedavna studija Mati i saradnika (Mati et al., 2024) primenila je veštačku neuronsku mrežu (ANN), optimizovanu standardnim PSO-om, za prognoziranje emisija CO₂ u četiri afričke ekonomije sa visokim emisijama. Njihov model je u ovom scenariju značajno nadmašio referentne (bazne) modele. Druga nedavna studija Jovanović i saradnika (Jovanović et al., 2024) koristila je PSO za optimizaciju LSTM mreža sa više glava (multi-headed) u problemu predviđanja cena goriva, uz ohrabrujuće rezultate. PSO je takođe nedavno korišćen za prognoziranje opterećenja u računarstvu u oblaku (Bacanin et al., 2023), predviđanje broja igrača na platformi Steam (Jovanovic et al., 2024), predviđanje brodskih ruta (Xu et al., 2024) i u medicini (Yadav & Kumar, 2025). Međutim, opsežne empirijske simulacije, kao i benčmarki sprovedeni korišćenjem standardnih evaluacionih funkcija (Luo et al., 2007), ukazuju na to da postoji prostor za dodatna poboljšanja. Uprkos zavidnoj dugovečnosti PSO-a, mogu se uočiti određeni nedostaci koji, pod izvesnim uslovima optimizacije, dovode do manje povoljnih ishoda. Algoritam ispoljava ograničenu eksploraciju prostora pretrage i sklonost ka konvergenciji ka suboptimalnim lokalnim rešenjima. Ovaj rad nastoji da adresira uočene nedostatke i nadogradi povoljne performanse osnovne metaheuristike putem hibridizacije. Predstavlja se modifikovana, adaptivna verzija PSO-a, dobijena hibridizacijom sa genetskim algoritmom (GA) (Mirjalili 2019), čime se postiže unapređena diversifikacija i prevazilaze neki od uočenih nedostataka osnovnog optimizatora.

6.1.2.3 Procedura inicijalizacije zasnovana na kvazi-reflektivnom učenju

Prva modifikacija integriše pristup kvazi-reflektivnom učenju (QRL) (Bacanin et al., 2024) radi unapređenja diverziteta populacije tokom početne (inicijalne) faze. Polovina populacije generiše se putem tradicionalne faze inicijalizacije PSO-a. QRL pristup koristi se za formiranje preostalog dela populacije kako bi se povećao stepen varijabilnosti u ukupno generisanoj populaciji. Generalno govoreći, kvazi reflektivno učenje (*eng. Quasi-Reflexive Learning, QRL*) možemo definisati kao jednu od strategija inicijalizacije populacije kod optimizacionih algoritama. Dakle, glavni cilj ove procedure jeste povećanje raznolikosti same početne populacije i smanjenje verovatnoće brzog zapadanja u lokalne minimume.

Standarni koraci QRL inicijalizacije podrazumevaju generisanje novih čestica, kreiranje kvazi-reflektivne čestice, izbor između osnovnih i reflektivnih čestica i na kraju formiranje početne populacije.

pođimo od jednačine kojom definišemo reflektivnu česticu

$$xi' = L + U - xix_i' = L + U - x_i xi' = L + U - xi$$

Jednačina 17 Definicija reflektivne čestice

Pri čemu su L i U donje i gornje granice prostora pretrage.

Novi agenti sintetišu se kao kvazi-refleksivne opozicione jedinice, na osnovu jednačine

$$X_j^{qr} = rnd \left(\frac{lbj + ubj}{2}, X_j \right)$$

Jednačina 18 Kvazi-refleksno suprotna komponenta za svaku komponentu Xj

Za svaku komponentu Xj se određuje njena kvazi-refleksno suprotna komponenta X_j^{qr} , što možemo predstaviti sledećom formulom:

Pri čemu :

- $rnd(\cdot)$ označava slučajan broj u opsegu između srednje vrednosti granica $\frac{lbj + ubj}{2}$ i komponente X_j

6.1.2.4. Procedura za procenu raznolikosti populacije

Kada govorimo o samom procesu pretrage dostupnog prostora rešenja kod metaheurističkih optimizacionih algoritama, možemo reći da se on efektivno može ispratiti analizom raznolikosti populacije.

Jedna od metoda praćenja diverziteta populacije jeste L1 norma (Bacanin et al., 2024) Ona uzima u obzir i varijansu među rešenjima i složenost problema. Sledeće jednačine daju L1 normu za populaciju od k jedinki i dimenzionalnost d

1. Prosečna vrednost za dimenziju j :

$$\bar{x}_j = \frac{1}{d} \sum_{i=1}^k x_{ij}$$

Jednačina 19 Prosečna vrednosti dimenzije j

2. Diverzitet po dimenziji:

$$Dvs_j^p = \frac{1}{k} \sum_{i=1}^k |x_{ij} - \bar{x}_j|$$

Jednačina 20 Diverzitet po dimenziji j

3. Ukupna raznolikost populacije:

$$Dvs^p = \frac{1}{d} \sum_{j=1}^d Dvs_j^p$$

Jednačina 21 ukupna raznolikost populacije

Gde su:

- $\bar{x}$ – srednja vrednost pozicija svih jedinki u svakoj dimenziji
- D_j^p – mera raznolikosti pozicija u nekoj dimenziji
- D^p – skalarni indikator ukupne raznolikosti populacije²

Ovde Dvs_j^p predstavlja diskretni vektor diverziteta, poznat i kao L1 norma; Dvs^p je ukupni (mereni) skor diverziteta populacije, a x je prosečni vektor položaja čestica u svakoj dimenziji. Optimizaciona procedura dinamički reguliše stepen diverziteta kako bi se u početnoj fazi podstakla veća raznolikost. Radi kontrole ove raznolikosti, L1 norma koristi dinamičku pragovnu promenljivu Dvs_t . Ako diverzitet populacije padne ispod propisanog praga, uklanja se podskup najmanje produktivnih jedinki. Jednačina (22) daje početnu vrednost diverziteta Dvs_0 , koja predstavlja inicijalnu vrednost promenljive Dvs_t zadužene za praćenje diverziteta

Dodatni kontrolni parametar označen kao **nrs** (broj rešenja za zamenu), u ovom istraživanju empirijski je postavljen na 2. Na početku izvršavanja izračunava se početna vrednost praga Dt_0 prema formuli:

$$Dv_{st0} = \sum_{j=1}^{NP} \frac{(ub_j - lb_j)}{2 \times NP}$$

Jednačina 22 Računanje početne vrednosti praga Dt_0


U skladu sa jednačinom 23, promenljiva Dv_{st} mora biti snižena u odnosu na početnu vrednost $Dv_{st} = Dv_{st0}$ kada čestice počnu da konvergiraju ka optimalnoj zoni tokom izvršavanja algoritma.

$$Dv_{st+1} = Dv_{st} - Dv_{st} \cdot \frac{t}{T}$$

Jednačina 23

Gde t i $t + 1$ označavaju tekuću, odnosno narednu iteraciju, a T je ukupan broj rundi u jednom pokretanju. Kako se Dv_{st} postepeno smanjuje u završnim fazama rada, ovaj mehanizam će se isključiti bez obzira na vrednost Dv_{sP}

Na kraju svake iteracije pokretanja, vrednošću n_{rp} označeni slabije performantni (sub-performantni) jedinki se uklanjaju iz skupa i zamenjuju novim sintetičkim rešenjima. Vrednost n_{rp} je empirijski određena radi postizanja najjeg nivoa performansi, pri čemu je utvrđeno da $n_{rp} = 2$ daje najpovoljnije ishode. Rekompozicija nasumičnog para jedinki iz populacije, u slučaju da važi $Dv_{st} < Dv_{sP}$, daje ova dodatna rešenja. U suprotnom, bira se najbolji skup kandidata radi generisanja novih jedinki. U oba slučaja, novi pojedinci se proizvode postupcima ukrštanja (crossover) i mutacije vođenim GA (Mirjalili, 2019). Pristup ukrštanja koristi se za kreiranje potomaka spajanjem parametara svakog roditelja, kao što je prikazano na ilustraciji niže.




Slika 5 Cross-over mehanizam

Međutim, proces mutacije omogućava suptilnije izmene u sintetičkim rešenjima nasumičnom izmenom komponenti generisane jedinke. Slika 5 ilustruje ovaj mutacioni tok (proces). Proces mutacije i ukrštanja kontrolišu se verovatnoćama CP i MP, pri čemu je empirijski pokazano da vrednosti $CP = 0.1$ i $MP = 0.1$ daju najbolje rezultate. Proceduralni pseudokod izmenjene metaheuristike dat je u Algoritmu 1; u skladu sa primenjenim izmenama, algoritam je jednostavno nazvan evoluciono-adaptivni PSO (EAPSO).

Predloženi EAPSO algoritam razlikuje se od tradicionalnog PSO-a kroz nekoliko dodatnih mehanizama osmišljenih da očuvaju diverzitet populacije i umanje preuranjenu konvergenciju. Prvo, polovina početne populacije formira se primenom pristupa kvazi-adaptivnog učenja, čime se povećava varijabilnost početnih rešenja. Drugo, diverzitet se prati pomoću L1 norme, a kroz iteracije se primenjuje dinamički prag kako bi se sprečilo urušavanje roja u usku oblast prostora pretrage. Treće, najslabija rešenja se periodično uklanjaju i zamenjuju putem genetičkog ukrštanja (crossover) i mutacije, čime se uvode nove strukturne kombinacije koje nisu dostupne standardnim PSO ažuriranjima. Ovi kombinovani elementi održavaju snažniju ravnotežu između istraživanja (eksploatacije) i iskorišćavanja (eksploatacije), unapređuju stabilnost optimizacionog postupka i

smanjuju verovatnoću konvergencije ka nepovoljnim lokalnim optimumima. Kao rezultat, predloženi algoritam obezbeđuje robusnije ishode podešavanja hiperparametara od osnovnog PSO-a u primeni na zadatak prognoziranja nezaposlenosti. Najzad, složenost EAPSO-a ista je kao i kod izvorne verzije, budući da integrisane modifikacije ne uvode nova evaluiranja funkcije prilagođenosti (*eng. fitness function evaluations, FFE*), pri čemu je FFE najskuplja operacija u izvršavanju algoritma.



Slika 6 Mehanizam mutacije

6.1.2.5. Predloženi algoritam – EAPSO

Algoritam 1 *EAPSO proceduralni kod*

Korak 1: Inicijalizuj 50 % početne populacije P koristeći PSO

Korak 2: generisati preostalih 50% populacije P koristeći QRL na osnovu postojećih jedinki u P

Korak 3: Postavi $n_{rp} = 2$

Korak 4: dok ($t < T$) radi:

- a. Poređaj rešenja u P prema njihovoj funkciji prilagođenosti
- b. za svako rešenje X koje pripada P radi:
 1. Primeni PSO pretragu
 2. Izračunaj D_{vsp}

3. Ukloni iz populacije npr čestice sa najnižom prilagođenošću
4. Ako je $Dvsp < Dvst$ onda
Zameni uklonjene čestice generisanjem novih primenom ukrštanja nad npr nasumice odabranih jedinki (rešenja)
Ili
Zameni uklonjene čestice rekombinacijom npr najboljih čestica.

Završi ako


Generisati nasumičnu vrednost u opsegu 0,1

Primeni mutaciju na nove čestice

Kraj petlje

Vratiti jedinku sa najboljom vrednošću prilagođenosti.

Radi vizuelizacije predloženog procesa optimizacionog okvira korišćenog u sprovedenim simulacijama, dijagram toka dat je na Slici 7. U početku se podaci koji se koriste za obuku, validaciju i testiranje kandidatskih modela razdvajaju, kako je opisano u delu o eksperimentalnoj postavci ovog rada. Inicijalizovani agenti, kodirani vrednostima parametara, koriste se za inicijalizaciju novih modela. Ovi modeli se zatim obučavaju na skupu za obuku i ocenjuju na validacionim podacima. Nakon evaluacija na validacionim podacima, agenti se rangiraju i njihove pozicije se shodno tome ažuriraju. Ovaj proces se iterativno ponavlja sve dok se ne ispuni unapred određeni kriterijum. Za simulacije sprovedene u ovoj studiji, kriterijum zaustavljanja postavljen je kao maksimalan broj iteracija. Kada se kriterijum ispuni, optimizacija se obustavlja i vraća se najbolji model. Najbolji model se potom ponovo ocenjuje korišćenjem test podataka radi utvrđivanja performansi.




Slika 7 Dijagram toka predloženog optimizacionog okvira

6.2. Eksperimentalna postavka, rezultati simulacije i perspektiva objašnjivosti

Radi evaluacije predloženog pristupa prikupljen je kompozitni skup podataka iz više izvora, sa javno dostupne platforme <https://fred.stlouisfed.org/>. Kompozitni skup obuhvata podatke o početnim (unemployment) zahtevima za naknadu (ICSA), prosečnim satnicama svih zaposlenih (CES0500000003), kao i podatke o indeksu Standard & Poor's 500 (S&P 500). Podaci obuhvataju nedeljne uzorke od 2015. do decembra 2024. godine (vreme prikupljanja i poslednjeg pristupa). Vizuelizacija kompozitnog skupa podataka prikazana je na Slici 4. Uočljiv je izražen skok u ICSA (početnim zahtevima za nezaposlenost) približno na sredini skupa podataka. Ovaj

skok je prouzrokovao velikim gubicima radnih mesta i gašenjem preduzeća tokom početnih faza pandemije COVID-19. Pošto je ovu promenu izazvao spoljašnji, a ne ekonomski faktor, u skup podataka uvedena je dodatna binarna promenljiva (pandemic). Ova promenljiva označava početak pandemije i postavlja se na 1 tokom trajanja krize. Inicijalnih 70% podataka koristi se za obuku modela za prognoziranje. Sledećih 10% koristi se za validaciju i sprečavanje curenja informacija tokom procesa podešavanja hiperparametara. Konačno, poslednjih 20% podataka zadržava se za evaluaciju modela. U pogledu detaljnih metrika, radi obezbeđivanja valjanijeg poređenja, nad celokupnim skupom podataka sprovedena je desetostruka unakrsna validacija (10-fold cross-validation) za modele sa najboljim performansama.



Slika 8 Vizualizacija skupa podataka o nezaposlenosti

U komparativnoj analizi sa predloženim modifikovanim algoritmom primenjen je niz optimizacionih metaheuristika. Uključeni su osnovni PSO (Kennedy & Eberhart, 1995), kao i GA (Mirjalili, 2019). Takođe su evaluirane i dobro utemeljene optimizacione tehnike, kao što su VNS (Mladenovic & Hansen, 1997) i FA (Mirjalili, 2019). Pored njih, razmatrani su i savremeni algoritmi, uključujući RSA (Abualigah et al., 2022), ChOA (Bai et al., 2023) i COLSHADE (Gurrola-Ramos et al., 2020). Svaki algoritam je nezavisno implementiran korišćenjem standardnih podešavanja predloženih u izvornim radovima koji su ih uveli. Agenti optimizatora predstavljaju kodiranje rešenja za hiperparametre LSTM mreže. Zbog velikih računarskih zahteva optimizacije, simulacije su sprovedene sa veličinom populacije od osam agenata, a broj iteracija je ograničen na osam. Ipak, simulacije su izvršene u 30 nezavisnih pokretanja sa različitim semenkama (*eng.seed*)

kako bi se omogućila dodatna statistička validacija. Optimizacije parametara LSTM-a sprovedene su iz empirijski unapred određenih, ograničenih opsega prikazanih u Tabeli 2. Sprovedena su dva odvojena eksperimenta: prvi koristi čiste LSTM mreže, dok drugi uključuje slojeve pažnje u LSTM mreži.

Broj neurona pažnje u drugom eksperimentu takođe određuju metaheuristički optimizatori. Neophodno je ponovo naglasiti da je u studiji primenjen ograničen broj rešenja u populaciji i iteracija zbog računarskih zahteva povezanih sa podešavanjem hiperparametara. Svako kandidatsko rešenje odgovara posebnoj LSTM konfiguraciji koja mora biti obučena i ocenjena na zasebnim segmentima podataka. Ovaj postupak zahteva značajne računarske resurse, budući da su i obuka i validacija rekurentnih arhitektura iterativne i vremenski zahtevne. Povećanje veličine populacije ili broja optimizacionih ciklusa proporcionalno bi uvećalo računarski trošak, bez jasne garancije da bi se dobila suštinski bolja rešenja. Dostižna poboljšanja performansi mogu postati marginalna nakon što optimizator istraži najuticajnije regione prostora pretrage

Tabela 2 LSTM parametri

Limit	learning rate	dropout	number of epochs	neurons	attention neurons
Lower	.0001	.05	50	50	50
Upper	.0100	.20	100	200	200

6.2.1. Primenjeni kriterijumi za ocenjivanje

Kreirani modeli ocenjuju se standardnim skupom regresionih metrika (Tatachar, 2021):

- srednja kvadratna greška korena (RMSE),
- srednja apsolutna greška (MAE),
- srednja kvadratna greška (MSE),
- koeficijent determinacije (R^2).

Ovi metrički pokazatelji se mogu izračunati prema formulama (24), (25), (26) i (27), redom.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (b_i - \hat{b}_i)^2}$$

Jednačina 24 Srednja kvadratna greška korena

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |b_i - \hat{b}_i|$$

Jednačina 25 Srednja apsolutna greška

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (b_i - \hat{b}_i)^2$$

Jednačina 26 Srednja kvadratna greška

$$R^2 = 1 - \frac{\sum_{i=1}^n (b_i - \hat{b}_i)^2}{\sum_{i=1}^n (b_i - \bar{b})^2}$$

Jednačina 27 Koeficijent determinacije

U datim formulama, stvarne i projektovane vrednosti za i-ti uzorak predstavljene su kao b_i i $\hat{b}_i$, srednja vrednost označena je kao $\bar{b}$, a veličina uzorka kao n . Radi obezbeđivanja potpunije slike performansi modela, tokom optimizacije je praćen i indeks slaganja (index of agreement, IoA) (Willmott, 2012). Tokom optimizacija metrika RMSE koristi se kao funkcija cilja, čime se zadatak formuliše kao problem minimizacije. Dodatno, korišćen je još jedan metrički pokazatelj za bolje ocenjivanje sintetisanih modela — indeks slaganja (IoA), koji je definisan jednačinom 29. Ovaj indeks meri stepen usklađenosti između predviđenih vrednosti modela i stvarnih rezultata ili ciljeva. Visoka vrednost ovog indeksa ukazuje na dobru performansu modela, odnosno na snažno slaganje između predviđanja i stvarnih rezultata.

$$IoA = 1 - \frac{\sum_{i=1}^n (b_i - \hat{b}_i)^2}{\sum_{i=1}^n (|b_i - \bar{b}| + |\hat{b}_i - \bar{b}|)^2}$$

Jednačina 283 Indeks slaganja

Pri čemu su

- $b_i, \hat{b}_i$ – stvarne i predviđene vrednosti za i-to posmatranje
- $\bar{b}$ – aritmetička sredina stvarnih podataka


6.2.2. Konačni rezultati, LSTM simulacije

Sprovedena su dva skupa eksperimenata u ovom radu. Prvi ispituje potencijal LSTM-a bez slojeva pažnje za predviđanje stopa nezaposlenosti. Drugi eksperiment ponavlja ove simulacije uz uvođenje slojeva pažnje. Konačno, postignuti ishodi podvrgnuti su rigoroznoj statističkoj validaciji kako bi se potvrdilo da su uočena poboljšanja statistički značajna. Postignuti rezultati LSTM simulacija u pogledu vrednosti funkcije cilja prikazani su u Tabeli 3. Uvedeni modifikovani algoritam ostvario je najbolje rezultate za sve scenarije simulacija, sa RMSE vrednošću od 0,007458 u najboljem, 0,007625 u najgorem, te 0,007533 i 0,007503 u prosečnom i medijalnom slučaju.

Tabela 3 Poređenje vrednosti funkcije cilja u LSTM simulacijama prognoziranja nezaposlenosti između modela optimizovanih metaheurističkim algoritmima.

Method	Best	Worst	Mean	Median	Std	Var
LSTM-EAPSO	0.007458	0.007625	0.007533	0.007503	5.97E-05	3.56E-09
LSTM-PSO	0.007541	0.008311	0.007960	0.007994	3.02E-04	9.13E-08
LSTM-VNS	0.007508	0.007695	0.007577	0.007588	6.49E-05	4.21E-09
LSTM-GA	0.007461	0.007643	0.007542	0.007543	4.71E-05	2.22E-09
LSTM-FA	0.007473	0.007930	0.007609	0.007535	1.65E-04	2.72E-08
LSTM-RSA	0.007538	0.007707	0.007621	0.007605	5.24E-05	2.75E-09
LSTM-ChOA	0.007508	0.007770	0.007658	0.007662	8.72E-05	7.60E-09
LSTM-COLSHADE	0.007483	0.007646	0.007569	0.007566	5.30E-05	2.81E-09

Visok stepen stabilnosti demonstrirao je GA. Međutim, izostanak povoljnih ishoda zabeležen kod GA sugerije da su verovatno prisutni nedovoljna eksploracija ili preuranjena konvergencija.




Slika 9. Dijagram raspodele ishoda funkcije cilja u LSTM simulacijama prognoziranja nezaposlenosti

Poređenja između optimizatora u pogledu stabilnosti funkcije cilja, kao i stabilnosti indikatorske funkcije, prikazana su na Slici 8 i Slici 9, respektivno. Uočava se primetno poboljšanje stabilnosti u odnosu na osnovni PSO, kao i sposobnost predloženog modela da grupiše rešenja u povoljnijoj oblasti prostora pretrage. Detaljne metrike za modele sa najboljim performansama, optimizovane svakim pristupom, date su u Tabeli 4. Najbolje performanse postigao je model optimizovan EAPSO metodom, ostvarivši najpovoljnije rezultate prema R², MSE i RMSE, sa odgovarajućim vrednostima 0,346581, 0,007458 i 0,086360.



Tabela 4. Detaljne sveukupne metrike LSTM simulacije prognoziranja nezaposlenosti za optimizovane modele sa najboljim performansama.

Method	R ²	MAE	MSE	RMSE	IoA
LSTM-EAPSO	0.346581	0.067381	0.007458	0.086360	0.711016
LSTM-PSO	0.339319	0.067436	0.007541	0.086838	0.727112
LSTM-VNS	0.342217	0.067340	0.007508	0.086648	0.714614
LSTM-GA	0.346324	0.066050	0.007461	0.086377	0.711875
LSTM-FA	0.345235	0.067494	0.007473	0.086449	0.701466
LSTM-RSA	0.339539	0.067538	0.007538	0.086824	0.711715
LSTM-ChOA	0.342168	0.066948	0.007508	0.086651	0.706726
LSTM-COLSHADE	0.344419	0.067036	0.007483	0.086502	0.702920




Slika 10. Dijagrami raspodele ishoda indikatorske funkcije u LSTM simulacijama prognožiranja nezaposlenosti


Dijagrami konvergencije za svaku od metaheuristika uključenih u komparativnu analizu prikazani su na Slici 11 i Slici 12. Poboljšanja konvergencije modifikovanog optimizatora su očigledna: agenti pronalaze najbolje rešenje već do treće iteracije u svakom pokretanju, dok se ostali optimizatori zadržavaju u suboptimalnim regionima tokom procesa. Predikcije koje je proizveo LSTM model sa najboljim performansama, optimizovan pomoću EAPSO algoritma, date su na Slici 13. Odgovarajući hiperparametri koje je odabrao svaki optimizator prikazani su u Tabeli 5, kako bi se olakšala dalja replikabilnost simulacija



Slika 11. Dijagrami konvergencije vrednosti funkcije cilja u LSTM simulaciji prognoziranja nezaposlenosti



Slika12. Dijagrami konvergencije vrednosti indikatorske funkcije u LSTM simulacijama prognoziranja nezaposlenosti



Slika 13 Prognoze modela LSTM-EAPSO sa najboljim performansama

Tabela 5 Hiperparametri najbolje izabranog modela u LSTM simulacijama prognoziranja nezaposlenosti.


Method	LR	Dropout	E.No	L.No	L1	L2	L3
LSTM-EAPSO	1.00e-02	6.16e-02	64	1	100	N/A	N/A
LSTM-PSO	1.00e-02	5.00e-02	68	1	103	N/A	N/A
LSTM-VNS	1.00e-02	6.26e-02	85	1	65	N/A	N/A
LSTM-GA	1.00e-02	1.30e-01	50	1	200	N/A	N/A
LSTM-FA	1.00e-02	2.00e-01	50	1	200	N/A	N/A
LSTM-RSA	6.66e-03	5.00e-02	100	1	176	N/A	N/A
LSTM-ChOA	1.00e-02	1.00e-01	64	1	191	N/A	N/A
LSTM-COLSHADE	1.00e-02	1.77e-01	50	1	174	N/A	N/A

6.2.3. LSTM- ATT simulacija rezultati


Postignuti rezultati LSTM simulacija sa integrisanim slojevima pažnje u pogledu vrednosti funkcije cilja prikazani su u Tabeli 6. Uvedeni modifikovani algoritam ostvario je najbolje rezultate u najboljem izvođenju, sa vrednošću funkcije cilja od 0,007377. PSO optimizator je ostvario najpovoljnije ishode u najgorem, prosečnom i medijalnom slučaju, sa odgovarajućim vrednostima 0,007523, 0,007464 i 0,007473. Visok stepen stabilnosti demonstrirao je algoritam ChOA. Međutim, izostanak povoljnih ishoda koji je demonstrirao GA sugerise da su verovatno prisutni nedovoljna eksploracija ili preuranjena konvergencija. Poređenja između optimizatora u pogledu stabilnosti funkcije cilja, kao i stabilnosti indikatorske funkcije, prikazana su na Slici 14 i Slici 15, respektivno. Može se uočiti blago umanj enje stabilnosti pri poređenju modifikovanog i osnovnog algoritma. Ipak, ovo smanjenje stabilnosti može se smatrati opravdanim s obzirom na ukupna poboljšanja performansi

Tabela 6 Poređenje vrednosti funkcije cilja u LSTM-ATT simulacijama prognoziranja nezaposlenosti između modela optimizovanih metaheurističkim algoritmima

Method	Best	Worst	Mean	Median	Std	Var
LSTM-ATT-EAPSO	0.007377	0.007676	0.007530	0.007555	9.15E-05	8.38E-09
LSTM-ATT-PSO	0.007388	0.007523	0.007464	0.007473	4.40E-05	1.94E-09
LSTM-ATT-VNS	0.007429	0.007612	0.007516	0.007518	5.20E-05	2.71E-09
LSTM-ATT-GA	0.007465	0.007576	0.007524	0.007539	4.08E-05	1.66E-09
LSTM-ATT-FA	0.007453	0.010519	0.008123	0.007630	1.00E-03	1.01E-06
LSTM-ATT-RSA	0.007386	0.007621	0.007542	0.007542	7.06E-05	4.98E-09
LSTM-ATT-ChOA	0.007524	0.007626	0.007574	0.007570	3.72E-05	1.38E-09
LSTM-ATT-COLSHADE	0.007386	0.007646	0.007490	0.007464	8.99E-05	8.08E-09



Slika 14 Dijagrami raspodele vrednosti funkcije cilja u LSTM-ATT simulacijama prognoziranja nezaposlenosti





Slika 15. LSTM-ATT dijagrami raspodele vrednosti indikatorske funkcije u simulacijama prognoziranja nezaposlenosti


Tabela 7. Detaljne sveukupne metrike LSTM-ATT simulacija prognoziranja nezaposlenosti za optimizovane modele sa najboljim performansama.

Method	R ²	MAE	MSE	RMSE	IoA
LSTM-ATT-EAPSO	0.353661	0.066943	0.007377	0.085891	0.723122
LSTM-ATT-PSO	0.352721	0.066673	0.007388	0.085953	0.736391
LSTM-ATT-VNS	0.349163	0.067957	0.007429	0.086189	0.720116
LSTM-ATT-GA	0.345976	0.067347	0.007465	0.086400	0.727115
LSTM-ATT-FA	0.347034	0.068031	0.007453	0.086330	0.714141
LSTM-ATT-RSA	0.352908	0.067287	0.007386	0.085941	0.725478
LSTM-ATT-ChOA	0.340770	0.066759	0.007524	0.086743	0.718747
LSTM-ATT-COLSHADE	0.352917	0.066908	0.007386	0.085940	0.737338


Dijagrami konvergencije za svaku od metaheuristika uključenih u komparativnu analizu prikazani su na Slici 16 i Slici 17. Uticaji na konvergenciju modifikovanog optimizatora su očigledni: agenti pronalaze najbolje rešenje do pete iteracije u svakom pokretanju, dok se ostali optimizatori zadržavaju u suboptimalnim regionima tokom procesa. Predikcije koje je proizveo LSTM-ATT model sa najboljim performansama, optimizovan pomoću EAPSO algoritma, date su na Slici 14. Odgovarajući hiperparametri koje je izabrao svaki optimizator prikazani su u Tabeli 8, radi podrške daljoj replikabilnosti simulacija.



Slika 16. LSTM-ATT Dijagrami konvergencije vrednosti funkcije cilja u simulacijama prognožiranja nezaposlenosti



Slika 17. LSTM-ATT dijagram konvergencije indikatorske funkcije u simulacijama prognožiranja nezaposlenosti



Slika 18. Najbolje pokazani model LSTM-ATT-EAPSO za predviđanje nezaposlenosti

Tabela 8 Hiperparametri najbolje odabranog modela u LSTM-ATTsimulacijama prognožiranja nezaposlenosti

Method	LR	dropout	E.No	L.No	L1	L2	L3	Att
LSTM-ATT-EAPSO	1.00e-02	2.00e-01	62	1	50	N/A	N/A	200
LSTM-ATT-PSO	1.00e-02	1.51e-01	100	1	59	N/A	N/A	173
LSTM-ATT-VNS	1.00e-02	5.74e-02	84	1	50	N/A	N/A	200
LSTM-ATT-GA	7.64e-03	2.00e-01	100	1	79	N/A	N/A	81
LSTM-ATT-FA	1.00e-02	2.00e-01	50	1	50	N/A	N/A	50
LSTM-ATT-RSA	7.44e-03	8.76e-02	92	1	50	N/A	N/A	169
LSTM-ATT-ChOA	8.13e-03	5.00e-02	90	1	85	N/A	N/A	106
LSTM-ATT-COLSHADE	8.67e-03	5.10e-02	99	1	80	N/A	N/A	200

6.2.4. Statistička validacija rezultata

Pri oceni algoritama koji se oslanjaju na heurističke mehanizme pretrage, pojedinačna poređenja često nisu dovoljna da bi se utvrdila prednost modifikovanog optimizatora. Neophodno je uspostaviti statističku značajnost kako bi se uzele u obzir odstupajuće vrednosti (outliers) u postignutim rezultatima. (LaTorre et al., 2021) Međutim, radi omogućavanja statističke analize, najpre je potrebno ispuniti nekoliko uslova. Prvo, mora se obezbediti adekvatna veličina uzorka. Simulacije sprovedene u ovoj studiji ponavljane su u 30 nezavisnih pokretanja sa nezavisnim slučajnim „semenkama” (random seeds), čime je ispunjen kriterijum nezavisnosti. Drugo, potrebno je potvrditi homoskedastičnost; u tu svrhu primenjen je Leveneov test (Schultz, 1985).

Sa dobijenom p-vrednošću od 0,62 može se smatrati da je i ovaj kriterijum ispunjen. Konačno, mora biti zadovoljena pretpostavka normalnosti. Primenjen je Shapiro–Wilkov test (Shapiro & Francia, 1972), pri čemu su dobijeni ishodi predstavljeni u Tabeli 8. Pošto su prikazane p-vrednosti ispod praga od 0,05, hipoteza se odbacuje, što znači da uzorci ne potiču iz normalne raspodele. Zapažanja u vezi sa normalnošću mogu se dodatno vizuelno potvrditi na Slici 19, gde su dati dijagrami raspodele funkcije cilja za obe simulacije.

Tabela 9 prikaz rezultata (skorovi) Shapiro–Wilkovog testa normalnosti za eksperimente prognoziranja, radi evaluacije pretpostavke normalnosti

Table 8 Shapiro-Wilk scores for forecasting experiments for normality condition evaluation.



Approach	EAPSO	PSO	VNS	GA	FA	RSA	ChOA	COLSHADE
Unemployment forecasting LSTM	0.032	0.029	0.041	0.028	0.041	0.036	0.039	0.040
Unemployment forecasting LSTM-ATT	0.031	0.034	0.023	0.032	0.023	0.033	0.027	0.033

Table 9 Wilcoxon signed-rank test scores in forecasting experiments.

EAPSO vs. Others	PSO	VNS	GA	FA	RSA	ChOA	COLSHADE
Unemployment forecasting LSTM	0.032	0.038	0.024	0.039	0.037	0.044	0.042
Unemployment forecasting LSTM-ATT	0.031	0.035	0.034	0.028	0.029	0.031	0.043

Pošto uslovi neophodni za primenu parametarskih testova nisu bili ispunjeni, u ovoj studiji primenjen je Vilkoksonov test sa potpisanim rangovima (eng. *Wilcoxon signed-rank test*) (Woolson, 2005) radi poređenja predloženog EAPSO sa drugim optimizatorima. Rezultati testa prikazani su u Tabeli 9. Kako su sve vrednosti ispod praga $\alpha = 0,05$, nalazi ukazuju na statističku značajnost rezultata komparativne analize.

Radi dalje procene dodatne vrednosti predložene optimizacione strategije, tri osnovne (bazne) rekurentne neuronske arhitekture obučene su na istom skupu podataka. U to su uključeni čisti RNN, čisti LSTM i čisti GRU model, pri čemu je svaki treniran sa istim objašnjavajućim obeležjima (features) koja su korišćena u metaheurističkim eksperimentima. Bazne neuronske arhitekture implementirane su kao jednostavni rekurentni modeli bez dodatne regularizacije ili arhitektonskih unapređenja. Arhitekture su se sastojale od jednog rekurentnog sloja (radi usklađivanja sa najboljim optimizovanim LSTM modelima koji su takođe bili jednoslojni) i koristile su podrazumevana podešavanja hiperparametara.



Slika 19. KDE dijagrami funkcije cilja za sprovedene simulacije

Tabela 10 prikaz komparativne analize sa osnovnim rekurentnim modelima

Method	R^2
LSTM-EAPSO	0.346581
LSTM-ATT-EAPSO	0.353661
RNN	-2.501599
LSTM	-5.003286
GRU	-2.437693

7. Zaključak

Praćenje trendova nezaposlenosti od suštinskog je značaja za ocenu zdravlja ekonomije i usmeravanje delotvornih odluka javnih politika. Ovi trendovi ne samo da odražavaju ekonomske uslove, već imaju i značajne društvene implikacije, utičući na javno zdravlje, društvenu dobrobit i društvenu stabilnost. Visoke stope nezaposlenosti često su povezane sa većim siromaštvom, nejednakošću i problemima mentalnog zdravlja. Štaviše, trendovi nezaposlenosti služe kao dragoceni prediktori budućih ekonomskih performansi, što naglašava potrebu za tačnim metodama prognoziranja. Iako se tradicionalni pristupi često suočavaju sa složenošću i nelinearnošću ekonomskih podataka, tehnike mašinskog učenja (ML) predstavljaju snažnu alternativu. ML modeli se ističu sposobnošću obrade velikih skupova podataka, otkrivanja složenih obrazaca i prilagođavanja prilagođavanju promenljivim ekonomskim uslovima, čime se unapređuje prediktivna tačnost. Ova studija predstavlja hibridni pristup prognoziranju nezaposlenosti, koji koristi model zasnovan na LSTM-u sa mehanizmima pažnje i optimizovanim hiperparametrima putem varijante PSO algoritma, EAPSO. Rezultati, verifikovani na podacima iz realnog sveta, potvrđuju efikasnost modela, uz postignuti nizak RMSE od 0,085891.

Kao i svako istraživanje, ova studija ima izvesna ograničenja. Računarski zahtevni procesi povezani sa optimizacijom modela ograničili su simulacije na svega osam iteracija i osam agenata. Dodatno, studija je ograničena na javno dostupne izvore podataka. Budući rad će nastojati da unapredi predloženu metodologiju otklanjanjem ovih nedostataka. Pored toga, biće istražene i potencijalne nove primene predloženog algoritma.

Unapređena tačnost prognoziranja, postignuta optimizovanim modelima zasnovanim na LSTM-u, ima neposredne implikacije za praktično kreiranje politika. Pouzdanije kratkoročne prognoze omogućavaju rano uočavanje nepovoljnih kretanja na tržištu rada, što pomaže vladinim telima i centralnim institucijama u pripremi ciljanih politika i preventivnih mera. Tačne projekcije nezaposlenosti doprinose i planiranju programa tržišta rada i zapošljavanja, socijalnih davanja i fiskalnih mera usmerenih na ublažavanje posledica povećane nezaposlenosti. Štaviše, sposobnost anticipiranja prelomnih tačaka u dinamici tržišta rada unapređuje kapacitete kreatora politika da efikasno alociraju javne resurse i prilagode makroekonomske strategije radi očuvanja ekonomske stabilnosti.

Zaključci studije imaju važne implikacije za kreiranje politika u domenu ekonomskog prognoziranja i upravljanja tržištem rada. Savremene metode mašinskog učenja unapređuju prognoze nezaposlenosti, omogućavajući blagovremenu alokaciju resursa, ciljane intervencije i politike usmerene na smanjenje nezaposlenosti i društvenih problema poput siromaštva. Nadalje, preciznije prognoziranje pomaže centralnim bankama i vladama da osmisle i sprovedu politike koje stabilizuju privredu i podstiču održiv rast, naglašavajući potrebu za uključivanjem tehnologije u ekonomsko planiranje.

Literatura

- [1] Uddin, I., Rahman, K.U.: Impact of corruption, unemployment and inflation on economic growth evidence from developing countries. *Quality & Quantity* 57(3), 2759–2779 (2023)
- [2] Priambodo, A.: The impact of unemployment and poverty on economic growth and the human development index (hdi). *Perwira International Journal of Economics & Business* 1(1), 29–36 (2021)
- [3] Akhmad, A., Amir, A., Saleh, S., Abidin, Z.: Effectiveness of regional government expenditure in reducing unemployment and poverty rate. *European Journal of Development Studies* 2(4), 90–99 (2022)
- [4] Christiano, L.J., Trabandt, M., Walentin, K.: Involuntary unemployment and the business cycle. *Review of Economic Dynamics* 39, 26–54 (2021)
- [5] Fonseca, J.G.: Unemployment, entrepreneurship and firm outcomes. *Review of Economic Dynamics* 45, 322–338 (2022)
- [6] Pratap, P., Dickson, A., Love, M., Zandoni, J., Donato, C., Flynn, M.A., Schulte, P.A.: Public health impacts of underemployment and unemployment in the united 27 states: Exploring perceptions, gaps and opportunities. *International journal of environmental research and public health* 18(19), 10021 (2021)
- [7] Antipova, A.: Analysis of the covid-19 impacts on employment and unemployment across the multi-dimensional social disadvantaged areas. *Social Sciences & Humanities Open* 4(1), 100224 (2021)
- [8] Britto, D.G., Pinotti, P., Sampaio, B.: The effect of job loss and unemployment insurance on crime in brazil. *Econometrica* 90(4), 1393–1423 (2022)
- [9] Schmidpeter, B., Winter-Ebmer, R.: Automation, unemployment, and the role of labor market training. *European Economic Review* 137, 103808 (2021)
- [10] Mathieu, S., Treloar, A., Hawgood, J., Ross, V., Kolves, K.: The role of unemployment, financial hardship, and economic recession on suicidal behaviors and interventions to mitigate their impact: a review. *Frontiers in public health* 10, 907052 (2022)
- [11] Dahliyah, D., Nur, A.N.: The influence of unemployment, human development index and gross domestic product on poverty level. *Golden Ratio of Social Science and Education* 1(2), 95–108 (2021)
- [12] Crump, R.K., Eusepi, S., Giannoni, M., Sahin, A.: The unemployment–inflation trade-off revisited: The phillips curve in covid times. *Journal of Monetary Economics*, 103580 (2024) [13] Bal-Domańska, B.: The impact of macroeconomic and structural factors on the unemployment of young women and men. *Economic Change and Restructuring* 55(2), 1141–1172 (2022)

- [14] Davidescu, A.A., Apostu, S.-A., Paul, A.: Comparative analysis of different univariate forecasting methods in modelling and predicting the romanian unemployment rate for the period 2021–2022. *Entropy* 23(3), 325 (2021)
- [15] Medsker, L., Jain, L.C.: *Recurrent Neural Networks: Design and Applications*. CRC press, (1999)
- [16] Sherstinsky, A.: Fundamentals of recurrent neural network (rnn) and long shortterm memory (lstm) network. *Physica D: Nonlinear Phenomena* 404, 132306 (2020)
- [17] Chung, J., Gulcehre, C., Cho, K., Bengio, Y.: Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555* (2014)
- [18] Wong, E.Y., Schachter, A., Collins, H.N., Song, L., Ta, M.L., Dawadi, S., Neal, S., Pajimula, F.F., Colombara, D.V., Johnson, K., et al.: Cross-sector monitoring 28 and evaluation framework: social, economic, and health conditions impacted during the covid-19 pandemic. *American journal of public health* 111(S3), 215–223 (2021)
- [19] Davidescu, A.A., Apostu, S.-A., Stoica, L.A.: Socioeconomic effects of covid-19 pandemic: Exploring uncertainty in the forecast of the romanian unemployment rate for the period 2020–2023. *Sustainability* 13(13), 7078 (2021)
- [20] Caperna, G., Colagrossi, M., Geraci, A., Mazzarella, G.: A babel of web-searches: Googling unemployment during the pandemic. *Labour Economics* 74, 102097 (2022)
- [21] Wolpert, D.H., Macready, W.G.: No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation* 1(1), 67–82 (1997) <https://doi.org/10.1109/4235.585893>
- [22] Kennedy, J., Eberhart, R.: Particle swarm optimization. In: *Proceedings of ICNN'95 - International Conference on Neural Networks*, vol. 4, pp. 1942–19484 (1995). <https://doi.org/10.1109/ICNN.1995.488968>
- [23] Vaswani, A.: Attention is all you need. *Advances in Neural Information Processing Systems* (2017)
- [24] Luong, M.-T.: Effective approaches to attention-based neural machine translation. *arXiv preprint arXiv:1508.04025* (2015)
- [25] Montgomery, A.L., Zarnowitz, V., Tsay, R.S., Tiao, G.C.: Forecasting the us unemployment rate. *Journal of the American Statistical Association* 93(442), 478–493 (1998) [26] Rothman, P.: Forecasting asymmetric unemployment rates. *Review of Economics and Statistics* 80(1), 164–168 (1998)
- [27] Proietti, T.: Forecasting the us unemployment rate. *Computational Statistics & Data Analysis* 42(3), 451–476 (2003)

- [28] Ahmad, M., Khan, Y.A., Jiang, C., Kazmi, S.J.H., Abbas, S.Z.: The impact of covid-19 on unemployment rate: An intelligent based unemployment rate prediction in selected countries of europe. *International Journal of Finance & Economics* 28(1), 528–543 (2023)
- [29] Kant, D., Pick, A., Winter, J.d.: Nowcasting gdp using machine learning methods. *AStA Advances in Statistical Analysis*, 1–24 (2024)
- [30] Aaronson, D., Brave, S.A., Butters, R.A., Fogarty, M., Sacks, D.W., Seo, B.: Forecasting unemployment insurance claims in realtime with google trends. *International Journal of Forecasting* 38(2), 567–581 (2022) 29
- [31] Simionescu, M., Cifuentes-Faura, J.: Forecasting national and regional youth unemployment in spain using google trends. *Social Indicators Research* 164(3), 1187–1216 (2022)
- [32] Bacanin, N., Jovanovic, L., Zivkovic, M., Kandasamy, V., Antonijevic, M., Deveci, M., Strumberger, I.: Multivariate energy forecasting via metaheuristic tuned long-short term memory and gated recurrent unit neural networks. *Information Sciences* 642, 119122 (2023) [33] Park, K., Yim, J., Lee, H., Park, M., Kim, H.: Real-time solar power estimation through rnn-based attention models. *IEEE Access* (2023)
- [34] Zameer, A., Jaffar, F., Shahid, F., Muneeb, M., Khan, R., Nasir, R.: Short-term solar energy forecasting: Integrated computational intelligence of lstms and gru. *Plos one* 18(10), 0285410 (2023)
- [35] Moradzadeh, A., Moayyed, H., Mohammadi-Ivatloo, B., Vale, Z., Ramos, C., Ghorbani, R.: A novel cyber-resilient solar power forecasting model based on secure federated deep learning and data visualization. *Renewable Energy* 211, 697–705 (2023)
- [36] Salman, D., Direkoglu, C., Kusaf, M., Fahrioglu, M.: Hybrid deep learning models for time series forecasting of solar power. *Neural Computing and Applications*, 1–18 (2024)
- [37] Olcay, K., Tunca, S.G., Ozg ur, M.A.: Forecasting and performance analysis of   energy production in solar power plants using long short-term memory (lstm) and random forest models. *IEEE Access* (2024)
- [38] Jailani, N.L.M., Dhanasegaran, J.K., Alkawsi, G., Alkahtani, A.A., Phing, C.C., Baashar, Y., Capretz, L.F., Al-Shetwi, A.Q., Tiong, S.K.: Investigating the power of lstm-based models in solar energy forecasting. *Processes* 11(5), 1382 (2023)
- [39] Guo, X., Zhan, Y., Zheng, D., Li, L., Qi, Q.: Research on short-term forecasting method of photovoltaic power generation based on clustering so-gru method. *Energy Reports* 9, 786–793 (2023)
- [40] Xu, Y., Zheng, S., Zhu, Q., Wong, K.-c., Wang, X., Lin, Q.: A complementary fused method using gru and xgboost models for long-term solar energy hourly forecasting. *Expert Systems with Applications*, 124286 (2024)

- [41] Gogas, P., Papadimitriou, T., Sofianos, E.: Forecasting unemployment in the euro area with machine learning. *Journal of Forecasting* 41(3), 551–566 (2022)
- [42] Celbi, M.G.: Unemployment in rural europe: A machine learning perspective. *Applied Spatial Analysis and Policy* 16(3), 1071–1095 (2023)
- [43] Puspajuita, E.A.: Factors that influence the rate of unemployment in indonesia. *International Journal of Economics and Finance* 10(1), 140–147 (2018)
- [44] Katris, C.: Prediction of unemployment rates with time series and machine learning techniques. *Computational Economics* 55(2), 673–706 (2020)
- [45] Gupta, R., Pierdzioch, C., Salisu, A.A.: Oil-price uncertainty and the uk unemployment rate: A forecasting experiment with random forests using 150 years of data. *Resources Policy* 77, 102662 (2022)
- [46] Gabrikova, B., Svabova, L., Kramarova, K.: Machine learning ensemble modelling for predicting unemployment duration. *Applied Sciences* 13(18), 10146 (2023)
- [47] Nandha Gopal, J., Muthukaruppasamy, S.: Precision poverty evaluation: Leveraging generalized linear models and xg boost algorithms. *Smart Technologies for Sustainable Development Goals: No Poverty*, 214 (2024)
- [48] Singhania, R., Kundu, S.: Forecasting the united states unemployment rate by using recurrent neural networks with google trends data. *International Journal of Trade, Economics and Finance* 11(6) (2020)
- [49] Grybauskas, A., Pilinkienė, V., Lukauskas, M., Stundžienė, A., Bruneckienė, J.: Nowcasting unemployment using neural networks and multi-dimensional google trends data. *Economies* 11(5), 130 (2023)
- [50] Mulaudzi, R., Ajoodha, R.: Improving the performance of multivariate forecasting models through feature engineering: A south african unemployment rate forecasting case study. In: *Interdisciplinary Research in Technology and Management*, pp. 420–425. CRC Press, ??? (2021)
- [51] Mulero, R., García-Hiernaux, A.: Forecasting spanish unemployment with google trends and dimension reduction techniques. *SERIEs* 12(3), 329–349 (2021)
- [52] Mati, S., Ismael, G.Y., Mohammed, A.A., Hussaini, M., Usman, A.G., Aliyu, N., Alsakarnah, R.A.I., Abba, S.I.: Predicting consumer price index amidst uncertainty: Gaussian random fuzzy number-based evidential neural network for west african economies with covid-19 and russia–ukraine war dynamics. *Engineering Applications of Artificial Intelligence* 136, 109004 (2024)
- [53] Raffel, C., Luong, M.-T., Liu, P.J., Weiss, R.J., Eck, D.: Online and linear-time attention by enforcing monotonic alignments. In: *International Conference on Machine Learning*, pp. 2837–2846 (2017). PMLR

- [54] Harvat, M., Mart'in-Guerrero, J.D.: Memory degradation induced by attention in recurrent neural architectures. *Neurocomputing* 502, 161–176 (2022)
- [55] Yang, L., Shami, A.: On hyperparameter optimization of machine learning 31 algorithms: Theory and practice. *Neurocomputing* 415, 295–316 (2020)
- [56] Bassey, K.E.: Hybrid renewable energy systems modeling. *Engineering Science & Technology Journal* 4(6), 571–588 (2023)
- [57] Ocal, A., Koyuncu, H.: An in-depth study to fine-tune the hyperparameters of " pre-trained transfer learning models with state-of-the-art optimization methods: Osteoarthritis severity classification with optimized architectures. *Swarm and Evolutionary Computation* 89, 101640 (2024)
- [58] Yang, X.-S., He, X.: Bat algorithm: literature review and applications. *International Journal of Bio-Inspired Computation* 5(3), 141–149 (2013) <https://doi.org/10.1504/IJBIC.2013.055093> <https://www.inderscienceonline.com/doi/pdf/10.1504/IJBIC.2013.055093>. PMID: 55093
- [59] Yang, X.-S., He, X.: Firefly algorithm: recent advances and applications. *International journal of swarm intelligence* 1(1), 36–50 (2013)
- [60] Mirjalili, S.: Genetic Algorithm, pp. 43–55. Springer, Cham (2019). https://doi.org/10.1007/978-3-319-93025-1_4. https://doi.org/10.1007/978-3-319-93025-1_4
- [61] Abualigah, L., Elaziz, M.A., Sumari, P., Geem, Z.W., Gandomi, A.H.: Reptile search algorithm (rsa): A nature-inspired meta-heuristic optimizer. *Expert Systems with Applications* 191, 116158 (2022) <https://doi.org/10.1016/j.eswa.2021.116158>
- [62] Jia, H., Rao, H., Wen, C., Mirjalili, S.: Crayfish optimization algorithm. *Artificial Intelligence Review* 56(2), 1919–1979 (2023) <https://doi.org/10.1007/s10462-023-10567-4> [63] Khishe, M., Mosavi, M.R.: Chimp optimization algorithm. *Expert Systems with Applications* 149, 113338 (2020) <https://doi.org/10.1016/j.eswa.2020.113338>
- [64] Bai, J., Li, Y., Zheng, M., Khatir, S., Benaissa, B., Abualigah, L., Abdel Wahab, M.: A sinh cosh optimizer. *Knowledge-Based Systems* 282, 111081 (2023) <https://doi.org/10.1016/j.knosys.2023.111081>
- [65] Minic, A., Jovanovic, L., Bacanin, N., Stoean, C., Zivkovic, M., Spalevic, P., Petrovic, A., Dobrojevic, M., Stoean, R.: Applying recurrent neural networks for anomaly detection in electrocardiogram sensor data. *Sensors* 23(24), 9878 (2023)
- [66] Jovanovic, L., Djuric, M., Zivkovic, M., Jovanovic, D., Strumberger, I., Antonijevic, M., Budimirovic, N., Bacanin, N.: Tuning xgboost by planet optimization algorithm: An application for diabetes classification. In: *Proceedings of Fourth 32 International Conference on Communication, Computing and Electronics Systems: ICCCES 2022*, pp. 787–803 (2023). Springer

- [67] Jovanovic, L., Bacanin, N., Zivkovic, M., Antonijevic, M., Petrovic, A., Zivkovic, T.: Anomaly detection in ecg using recurrent networks optimized by modified metaheuristic algorithm. In: 2023 31st Telecommunications Forum (TELFOR), pp. 1–4 (2023). IEEE
- [68] Mladenovic, D., Antonijevic, M., Jovanovic, L., Simic, V., Zivkovic, M., Bacanin, N., Zivkovic, T., Perisic, J.: Sentiment classification for insider threat identification using metaheuristic optimized machine learning classifiers. *Scientific Reports* 14(1), 25731 (2024) [69] Dobrojevic, M., Jovanovic, L., Babic, L., Cajic, M., Zivkovic, T., Zivkovic, M., Muthusamy, S., Antonijevic, M., Bacanin, N.: Cyberbullying sexism harassment identification by metaheuristics-tuned extreme gradient boosting. *Computers, Materials & Continua* 80(3) (2024)
- [70] Pavlov-Kagadejev, M., Jovanovic, L., Bacanin, N., Deveci, M., Zivkovic, M., Tuba, M., Strumberger, I., Pedrycz, W.: Optimizing long-short-term memory models via metaheuristics for decomposition aided wind energy generation forecasting. *Artificial Intelligence Review* 57(3), 45 (2024)
- [71] Damaševičius, R., Jovanovic, L., Petrovic, A., Zivkovic, M., Bacanin, N., Jovanovic, D., Antonijevic, M.: Decomposition aided attention-based recurrent neural networks for multistep ahead time-series forecasting of renewable power generation. *PeerJ Computer Science* 10 (2024)
- [72] Villoth, S.J., Villoth, J.P., Jovanovic, L., Mani, J., Zivkovic, M., Zivkovic, T., Bacanin, N., Antonijevic, M., Milovanovic, M.: Optimizing error detection in generated code using metaheuristic optimized natural language processing. In: *International Conference on Soft Computing and Its Engineering Applications*, pp. 239–253 (2024). Springer
- [73] Villoth, J.P., Zivkovic, M., Zivkovic, T., Abdel-salam, M., Hammad, M., Jovanovic, L., Simic, V., Bacanin, N.: Two-tier deep and machine learning approach optimized by adaptive multi-population firefly algorithm for software defects prediction. *Neurocomputing* 630, 129695 (2025)
- [74] Bacanin, N., Petrovic, A., Jovanovic, L., Zivkovic, M., Zivkovic, T., Sarac, M.: Parkinson’s disease induced gain freezing detection using gated recurrent units optimized by modified crayfish optimization algorithm. In: *2024 5th International Conference on Mobile Computing and Sustainable Informatics (ICMCSI)*, pp. 1–8 (2024). IEEE
- [75] Bacanin, N., Jovanovic, L., Djordjevic, M., Petrovic, A., Zivkovic, T., Zivkovic, M., Antonijevic, M.: Crop yield forecasting based on echo state network tuned 33 by crayfish optimization algorithm. In: *2024 IEEE International Conference on Contemporary Computing and Communications (InC4)*, vol. 1, pp. 1–6 (2024). IEEE
- [76] Mati, S., Baita, A.J., Ismael, G.Y., Abdullahi, S.G., Samour, A., Ozsahin, D.U.: Enhancing co2 emissions prediction in africa: A novel approach integrating enviroeconomic factors and nature-inspired neural network in the presence of unit root. *Renewable Energy* 237, 121561 (2024)
- [77] Jovanovic, A., Jovanovic, L., Zivkovic, M., Bacanin, N., Simic, V., Pamucar, D., Antonijevic, M.: Particle swarm optimization tuned multi-headed long short-term memory

networks approach for fuel prices forecasting. *Journal of Network and Computer Applications* 233, 104048 (2025)

[78] Bacanin, N., Simic, V., Zivkovic, M., Alrasheedi, M., Petrovic, A.: Cloud computing load prediction by decomposition reinforced attention long short-term memory network optimized by modified particle swarm optimization algorithm. *Annals of Operations Research*, 1–34 (2023)

[79] Jovanovic, L., Zivkovic, M., Zivkovic, T., Bacanin, N., Dubljanin, D., Malisic, S.: Steam players count prediction using gru optimized by modified pso. In: 2024 32nd Telecommunications Forum (TELFOR), pp. 1–4 (2024). IEEE

[80] Xu, P., Lan, D., Yang, H., Zhang, S., Kim, H., Shin, I.: Ship formation and route optimization design based on improved pso and dp algorithm. *IEEE Access* (2025)

[81] Yadav, A.R., Kumar, V.N.: Pso-optimized fractional order cnns for enhanced breast cancer detection. *Results in Engineering* 26, 104559 (2025)

[82] Luo, W., Lin, X., Li, C., Yang, S., Shi, Y.: Benchmark functions for cec 2022 competition on seeking multiple optima in dynamic environments. *arXiv preprint arXiv:2201.00523* (2022) [83] Rahnamayan, S., Tizhoosh, H.R., Salama, M.M.: Quasi-oppositional differential evolution. In: 2007 IEEE Congress on Evolutionary Computation, pp. 2229–2236 (2007). IEEE

[84] Cheng, S., Shi, Y.: Diversity control in particle swarm optimization. In: 2011 IEEE Symposium on Swarm Intelligence, pp. 1–9 (2011). <https://doi.org/10.1109/SIS.2011.5952581>

[85] Mladenović, N., Hansen, P.: Variable neighborhood search. *Computers & Operations Research* 24(11), 1097–1100 (1997) [https://doi.org/10.1016/S0305-0548\(97\)00031-2](https://doi.org/10.1016/S0305-0548(97)00031-2)

[86] Gurrola-Ramos, J., Hernández-Aguirre, A., Dalmau-Cedeño, O.: Colshade for 34 real-world single-objective constrained optimization problems. In: 2020 IEEE Congress on Evolutionary Computation (CEC), pp. 1–8 (2020). <https://doi.org/10.1109/CEC48606.2020.9185583>

[87] Tatachar, A.V.: Comparative assessment of regression models based on model evaluation metrics. *International Journal of Innovative Technology and Exploring Engineering* 8(9), 853–860 (2021)

[88] Willmott, C.J., Robeson, S.M., Matsuura, K.: A refined index of model performance. *International Journal of climatology* 32(13), 2088–2094 (2012)

[89] LaTorre, A., Molina, D., Osaba, E., Poyatos, J., Del Ser, J., Herrera, F.: A prescription of methodological guidelines for comparing bio-inspired optimization algorithms. *Swarm and Evolutionary Computation* 67, 100973 (2021) <https://doi.org/10.1016/j.swevo.2021.100973> [90] Schultz, B.B.: Levene's Test for Relative Variation. *Systematic Biology* 34(4), 449–456 (1985) <https://doi.org/10.1093/sysbio/34.4.449> <https://academic.oup.com/sysbio/article-pdf/34/4/449/4637295/34-4-449.pdf>

- [91] Shapiro, S.S., Francia, R.S.: An approximate analysis of variance test for normality. *Journal of the American Statistical Association* 67(337), 215–216 (1972) <https://doi.org/10.1080/01621459.1972.10481232> <https://www.tandfonline.com/doi/pdf/10.1080/01621459.1972.10481232>
- [92] Woolson, R.F.: Wilcoxon signed-rank test (2005) <https://doi.org/10.1002/0470011815.b2a15177> <https://onlinelibrary.wiley.com/doi/pdf/10.1002/0470011815.b2a15177>
- [93] Costanza, R., Hart, M., Posner, S.M., & Talberth, J. (2009). *Beyond GDP: The Need for New Measures of Progress*.
- [94] Commission on Growth and Development (2008). *The Growth Report: Strategies for Sustained Growth and Inclusive Development*. Washington, DC: World Bank.
- [95] Bureau of Economic Analysis (2015). *Measuring the Economy: A Primer on GDP and the National Income and Product Accounts*
- [96] Bulin, D., & Baltatescu, I. (2015). GDP as a measure of economic growth and welfare: brief critical assessment. *National Strategies Observer (NOS)*, Institute for World Economy, Romanian Academy, 1.
- [97] Bergh, J. C. J. M. (2009). The GDP paradox. *Journal of Economic Psychology*, 30(2), 117–135. doi:10.1016/j.joep.2008.12.001 10.1016/j.joep.2008.12.001
- [98] Dynan, K., and Sheiner, L. (2018). *GDP as a Measure of Economic Well-being*. Hutchins Center Working Paper #43.
- [99] Marone, H. (2012). *Measuring Economic Progress and Well-Being: How to move beyond GDP?*. Oxfam America Research Backgrounder series: <http://www.oxfamamerica.org/publications/measuring-economic-progress-and-wellbeing-how-to-move-beyond-gdp>.
- [100] Ramey, K. (2021). *The Changeover from GNP to GDP*, Survey of Current Business, Bureau of Economic Analysis, 101(3), 1–3.
- [101] Daly, H. E., & Cobb, J. B. Jr. (1994). *For The Common Good: Redirecting the Economy toward Community, the Environment, and a Sustainable Future*.
- [102] Abdallah, S., Hoffman, A., & Akenji, L. (2024). *The 2024 Happy Planet Index*. Hot or Cool Institute, Berlin.
- [103] Nayak, S.: *Fundamentals of optimization techniques with algorithms*. Academic Press (2020)
- [104] Simon, D.: *Evolutionary optimization algorithms*. John Wiley & Sons (2013)
- [105] Talbi, E.G.: *Metaheuristics: from design to implementation*. John Wiley & Sons (2009)

- [106] Andonie, R.: Hyperparameter optimization in learning systems. *Journal of Membrane Computing* 1(4), 279–291 (2019)
- [107] OECD, 2025. OECD Composite Leading Indicators (CLI). [online] Available at <https://www.oecd.org/en/data/datasets/oecd-composite-leading-indicators-clis.html>
- [108] Amalou, I., Mouhni, N., & Abdali, A. (2022). Multivariate time series prediction by RNN architectures for energy consumption forecasting. *Energy Reports*, 8, 1084–1091
- [109] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780
- [110] Bulin, D., & Baltatescu, I. (2015). GDP as a measure of economic growth and welfare: Brief critical assessment. National Strategies Observer
- [111] Herre, B., & Arriagada, P. (2023). The Human Development Index and related indices: What they are and what we can learn from them. *Our World in Data*
- [112] Abdallah, S., Hoffman, A., & Akenji, L. (2024). The 2024 Happy Planet Index. Hot or Cool Institute.
- [113] Radović-Stojanović, Jelena. "Ekonomski razvoj i blagostanje: Izabrani indikatori." *Megatrend revija*, vol. 6, br. 2, 2009, str. 119-134
- [114] Mati, S., Abba, S. I., Muhammed, M. S., & Al-shami, A. S. (2024). Predicting Consumer Price Index amidst uncertainty: Gaussian Random Fuzzy Number-based Evidential Neural Network for West African economies with COVID-19 and Russia-Ukraine war dynamics. *Engineering Applications of Artificial Intelligence*, 136
- [115] Mitchell, Tom M. *Machine Learning*. McGraw-Hill Education, 1997
- [116] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. Mit Press
- [117] Elman, J. L. Finding structure in time. (1990) *Cognitive Science*,
- [118] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1724–1734.
- [119] Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166. doi.org
- [120] Jozefowicz, Rafal, et al. "An Empirical Exploration of Recurrent Network Architectures." *Proceedings of the 32nd International Conference on Machine Learning*, vol. 37, 2015

- [121] Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451–2471
- [122] Chung, Junyoung, et al. "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling." 2014
- [123] Raffel, C., Luong, T., Liu, P. J., Weiss, R. J., & Eck, D. (2017). Online and linear-time attention by enforcing monotonic alignments. *Proceedings of the 34th International Conference on Machine Learning*, 70, 2837–2846
- [124] Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. In F. Hutter, L. Kotthoff, & J. Vanschoren (Eds.), *Automated Machine Learning: Methods, Systems, Challenges* (pp. 3–33). Springer
- [125] Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(10), 281–305
- [126] Feurer, M., & Hutter, F. (2019). Hyperparameter Optimization. U: Hutter, F., Kotthoff, L., Vanschoren, J. (ur.) *Automated Machine Learning*. Springer
- [127] Kirkpatrick, Scott, et al. "Optimization by Simulated Annealing." *Science*, vol. 220, no. 4598, 1983, pp. 671-80
- [128] Snoek, Jasper, et al. "Practical Bayesian Optimization of Machine Learning Algorithms." *Advances in Neural Information Processing Systems*, vol. 25, 2012
- [129] Glover, Fred. "Future Paths for Integer Programming and Links to Artificial Intelligence." *Computers & Operations Research*, vol. 13, no. 5, 1986
- [130] Simon, D. (2013). *Evolutionary optimization algorithms: Biologically-inspired and population-based approaches to computer intelligence*. John Wiley & Sons
- [131] Kennedy, James, and Russell Eberhart. "Particle Swarm Optimization." *Proceedings of ICNN'95 - International Conference on Neural Networks*, vol. 4, 1995, pp. 1942-1948.

PRILOZI

7.1. Prilog A – Pseudokovi metaheurističkih algoritama

7.1.1. PSO Algoritam

Algoritam 1 *Pseudokod PSO*

Input: broj čestica N, dimenzija D, funkcija cilja $f(x)$, max iteracija T

Output: najbolje rešenje gbest

Procedure:

Korak 1: Inicijalizuj položaje i brzine čestica nasumično.

Korak 2: Izračunaj vrednosti funkcije cilja $f(x)$ za svaku česticu.

Korak 3: Postavi pbest za svaku česticu i globalno najbolje rešenje gbest.

Korak 4: Za svaku iteraciju $t = 1$ do T:

Ažuriraj brzine čestica:

$$v_i = w \cdot v_i + c^1 \cdot r^1 \cdot (pbest_i - x_i) + c^2 \cdot r^2 \cdot (gbest - x_i)$$

Ažuriraj položaje: $x_i = x_i + v_i$

Izračunaj novu vrednost $f(x_i)$

Ažuriraj pbest i gbest ako je novo rešenje bolje

Korak 5: Vрати gbest.

7.1.2. Bat Algoritam (BA)

Algoritam 1 *Pseudokod BA*

Input: broj slepih miševa N , funkcija cilja $f(x)$, max iteracija T

Output: optimalno rešenje $best$

Procedure:

Korak 1: Inicijalizuj pozicije i brzine slepih miševa.

Korak 2: Dodeli frekvenciju, glasnoću i stopu pulsa svakom mišu.

Korak 3: Za svaku iteraciju $t = 1$ do T :

Ažuriraj frekvenciju i brzinu.

Pomeri pozicije slepih miševa.

Ako je slučajni broj $<$ stopa pulsa, izaberi lokalno rešenje.

Ako je slučajni broj $<$ glasnoća i novo rešenje je bolje, prihvati ga.

Ažuriraj $best$.

Korak 4: Vрати $best$.

7.1.3.Firefly Algoritam (FA)

Algoritam 1 *Pseudokod FA*

Input: broj svitaca N , funkcija cilja $f(x)$, max iteracija T

Output: optimalno rešenje best

Procedure:

Korak 1: Inicijalizuj pozicije svitaca.

Korak 2: Za svaku iteraciju $t = 1$ do T :

Za svaki par svitaca (i, j) :

Ako je $f(x_j)$ bolji od $f(x_i)$, pomeri i ka j :

$$x_i = x_i + \beta_0 \cdot e^{(-\gamma r^2)}(x_j - x_i) + \alpha \cdot \varepsilon$$

Ažuriraj best.

Korak 3: Vрати best.

7.1.4. Genski Algoritam (GA)

Algoritam 1 *Pseudokod GA*

Input: početna populacija, funkcija cilja $f(x)$, max generacija G

Output: optimalno rešenje best

Procedure:

Korak 1: Inicijalizuj populaciju nasumično.

Korak 2: Za svaku generaciju $g = 1$ do G :

Izračunaj fitnes svih jedinki.

Selektuj jedinke za ukrštanje.

Primeni ukrštanje (crossover).

Primeni mutaciju.

Formiraj novu populaciju.

Ažuriraj best.

Korak 3: Vрати best.

7.2. Prilog B – Pseudokodi modela neuronskih mreža

7.2.1. Algoritam Rekurentne Neuronske mreže

Algoritam 1 *Pseudokod Rekurentne Neuronske mreže (RNN)*

Input: ulazne sekvence X , ciljevi Y , broj epoha E

Output: trenirani model

Procedure:

Korak 1: Inicijalizuj težine nasumično.

Korak 2: Za svaku epohu $e = 1$ do E :

 Za svaki vremenski korak t :

$$h_t = f(W_{xh} \cdot x_t + W_{hh} \cdot h_{t-1} + b_h)$$

$$y_t = W_{hy} \cdot h_t + b_y$$

 Izračunaj grešku (loss).

 Izvrši propagaciju unazad kroz vreme (BPTT).

 Ažuriraj težine.

Korak 3: Vрати trenirani model.

7.2.2. Algoritam Dugoročno-kratkoročne memorije

Algoritam 1 *Pseudokod Dugoročno-kratkoročne memorije (LSTM)*

Input: ulazne sekvence X, ciljevi Y, broj epoha E

Output: trenirani model

Procedure:

Korak 1: Inicijalizuj težine i stanja ćelija.

Korak 2: Za svaku epohu $e = 1$ do E:

Za svaki vremenski korak t:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t$$

$$h_t = o_t \cdot \tanh(c_t)$$

Izračunaj grešku (loss).

Izvrši propagaciju unazad kroz vreme (BPTT).

Ažuriraj težine.

Korak 3: Vрати trenirani model.

7.2.3. Algoritam Zatvorene rekurentne jedinice (GRU)

Algoritam 1 *Pseudokod zatvorene rekurentne jedinice (GRU)*

Input: ulazne sekvence X , ciljevi Y , broj epoha E

Output: trenirani model

Procedure:

Korak 1: Inicijalizuj težine i skrivena stanja.

Korak 2: Za svaku epohu $e = 1$ do E :

Za svaki vremenski korak t :

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t])$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t])$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t \cdot h_{t-1}, x_t])$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t$$

Izračunaj grešku (loss).

Izvrši propagaciju unazad kroz vreme (BPTT).

Ažuriraj težine.

Korak 3: Vрати trenirani model.

Spisak akronima

AI (*Artificial Intelligence*) – veštačka inteligencija

AHP (*Analytic Hierarchy Process*) – metoda višekriterijumskog odlučivanja

AR (*Autoregressive*) – autoregresivni model

ARIMA (*Autoregressive Integrated Moving Average*) – integrisani autoregresivni model pokretnih proseka

ARMA (*Autoregressive Moving Average*) – autoregresivni model pokretnih proseka

ARAS (*Additive Ratio Assessment*) – metoda višekriterijumskog odlučivanja

BA (*Bat Algorithm*) – algoritam optimizacije inspirisan ponašanjem slepih miševa

BPTT (*Backpropagation Through Time*) – algoritam za treniranje rekurentnih neuronskih mreža propagacijom unazad kroz vreme

DP (*Dynamic Programming*) – dinamičko programiranje

FA (*Firefly Algorithm*) – algoritam optimizacije inspirisan ponašanjem svitaca

GA (*Genetic Algorithm*) – genetski algoritam

GRU (*Gated Recurrent Unit*) – rekurentna neuronska jedinica sa kontrolnim vratima

GREY (*Grey Relational Analysis*) – analiza sivih relacija

LSTM (*Long Short-Term Memory*) – duga kratkoročna memorija (rekurentna neuronska mreža)

MA (*Moving Average*) – model pokretnih proseka

ML – (*Machine learning*) – mašinsko učenje

MSE (*Mean Squared Error*) – srednja kvadratna greška

NFLT (*No Free Lunch Theorem*) – teorema bez besplatnog ručka

NP (*Non-deterministic Polynomial time*) – klasa problema rešivih u nedeterminističkom polinomijalnom vremenu

OF (*Objective Function*) – ciljna funkcija

PSO (*Particle Swarm Optimization*) – optimizacija rojem čestica

QRL (*Q-learning Reinforcement Learning*) – učenje pojačavanjem zasnovano na Q-funkciji

RFO (*Red Fox Optimization*) – algoritam optimizacije inspirisan ponašanjem crvene lisice

RNN (*Recurrent Neural Network*) – rekurentna neuronska mreža

RMSE (*Root Mean Squared Error*) – koren srednje kvadratne greške

SAGPSO (*Self-Adaptive Genetic Particle Swarm Optimization*) – samoadaptivna kombinacija genetskog algoritma i optimizacije rojem čestica

SARIMA (*Seasonal Autoregressive Integrated Moving Average*) – sezonski integrisani autoregresivni model pokretnih proseka

SSA (*Salp Swarm Algorithm*) – algoritam optimizacije inspirisan ponašanjem morskih puževa (salpi)

XAI (*Explainable Artificial Intelligence*) – objašnjiva veštačka inteligencija

Spisak oznaka

$\mathbf{x}_t$ – ulazni vektor u trenutku t

$\mathbf{y}_t$ – izlazni vektor u trenutku t

$\mathbf{h}_t$ – skriveno stanje u trenutku t

$\mathbf{c}_t$ – stanje ćelije (cell state) u LSTM-u

$\mathbf{f}_t$ – vektor izlaza forget gate u LSTM-u

$\mathbf{i}_t$ – vektor izlaza input gate u LSTM-u

$\mathbf{o}_t$ – vektor izlaza output gate u LSTM-u

$\tilde{\mathbf{c}}_t$ – kandidat vrednosti za stanje ćelije u LSTM-u

$\mathbf{z}_t$ – update gate u GRU

$\mathbf{r}_t$ – reset gate u GRU

$\tilde{\mathbf{h}}_t$ – kandidat skrivenog stanja u GRU

$\mathbf{W}_f, \mathbf{W}_i, \mathbf{W}_o, \mathbf{W}_c$ – matrice težina u LSTM-u

$\mathbf{W}_{hh}, \mathbf{W}_{xh}, \mathbf{W}_{hy}$ – matrice težina u RNN-u

$\mathbf{b}_f, \mathbf{b}_i, \mathbf{b}_o, \mathbf{b}_c$ – vektori praga (bias) u LSTM-u

σ (sigmoid) – sigmoidna funkcija aktivacije

$\tanh$ – hiperbolička tangens funkcija aktivacije

ϵ – nasumična varijabla za poremećaj (random noise)

β_0 – osnovni koeficijent privlačnosti u Firefly algoritmu

γ – parametar za prigušivanje svetlosti u Firefly algoritmu

α – parametar za jačinu slučajnog poremećaja

w – inercioni faktor u PSO algoritmu

c₁, c₂ – koeficijenti u PSO algoritmu (kognitivna i socijalna komponenta)

r₁, r₂ – slučajne vrednosti iz [0,1] u PSO algoritmu

gbest – globalno najbolje rešenje u PSO algoritmu

pbest – najbolje rešenje čestice u PSO algoritmu

N – veličina populacije (broj jedinki, čestica, svitaca, lisica, zečeva...)

T – broj iteracija (trajanje algoritma)

E – broj epoha u treniranju neuronske mreže

G – broj generacija u GA

Spisak tabela

TABELA 1 PRIKAZ TIPOVA KAPIJE I NJIHOVE PRIMENE.....	47
TABELA 2 LSTM PARAMETRI	72
TABELA 3 POREĐENJE VREDNOSTI FUNKCIJE CILJA U LSTM SIMULACIJAMA PROGNOZIRANJA NEZAPOSLENOSTI IZMEĐU MODELA OPTIMIZOVANIH METAHEURISTIČKIM ALGORITMIMA.....	74
TABELA 4 DETALJNE SVEUKUPNE METRIKE LSTM SIMULACIJE PROGNOZIRANJA NEZAPOSLENOSTI ZA OPTIMIZOVANE MODELE SA NAJBOLJIM PERFORMANSAMA	75
TABELA 5 HIPERPARAMETRI NAJBOLJE IZABRANOG MODELA U LSTM SIMULACIJAMA NEZAPOSLENOSTI.....	79
TABELA 6 POREĐENJE VREDNOSTI FUNKCIJE CILJA U LSTM-ATT SIMULACIJAMA NEZAPOSLENOSTI IZMEĐU MODELA OPTIMIZOVANIH METAHEURISTIČKIM ALGORITMIMA.....	80
TABELA 7 DETALJNE SVEUKUPNE METRIKE LSTM-ATT SIMULACIJA PROGNOZIRANJA NEZAPOSLENOSTI ZA OPTIMIZOVANE MODELE SA NAJBOLJIM PERFORMANSAMA	81
TABELA 8 HIPERPARAMETRI NAJBOLJE ODABRANOG MODELA U LSTM- ATTSIMULACIJAMA PROGNOZIRANJA NEZAPOSLENOSTI	84
TABELA 9 PRIKSZ REZULTATA (SKOROV I SHAPIRO-WILKOVOG TESTA NORMALNOSTI ZA EKSPERIMENTE PROGNOZIRANJA RADI EVALUACIJE PRETPOSTAVKE NORMALNOSTI	85
<i>TABELA 10 PRIKAZ KOMPARATIVNE ANALIZE SA OSNOVNIM REKURENTNIM MODELIMA</i>	86

Spisak slika

SLIKA 1 BIOLOŠKI NEURON	40
SLIKA 2 ARHITEKTURA NEURONSKE MREŽE	ERROR! BOOKMARK NOT DEFINED.
SLIKA 3 ARHITEKTURA NEURONA	43
SLIKA 4 ARHITEKTURA REKURENTNIH NEURONSKIH MREŽA	45
SLIKA 5 CROSS OVER MEHANIZAM	67
SLIKA 6 MEHANIZAM MUTACIJE	ERROR! BOOKMARK NOT DEFINED.
SLIKA 7 DIJAGRAM TOKA PREDLOŽENOG OPTIMIZACIONOG OKVIRA	70
SLIKA 8 VIZUALIZACIJA SKUPA PODATAKA O NEZAPOSLENOSTI.....	ERROR!
BOOKMARK NOT DEFINED.	
SLIKA 9 DIJAGRAM RASPODELE ISHODA FUNKCIJE CILJA U LSTM SIMULACIJI PROGOZE NEZAPOSLENOSTI.....	68
SLIKA 10 DIJAGRAM RASPODELE ISHODA INDIKATORSKE FUNKCIJE U LSTM SIMULACIJI PROGNOZE NEZAPOSLENOSTI.....	76
SLIKA 11 DIJAGRAM KONVERGENCIJE VREDNOSTI FUNKCIJE CILJA U LSTM SIMULACIJI PROGNOZE NEZAPOSLENOSTI.....	77
SLIKA 12 DIJAGRAM KONVERGENCIJE VREDNOSTI INDIKATORSKE FUNKCIJE U LSTM SIMULACIJAMA PROGNOZE NEZAPOSLENOSTI	78
SLIKA 13 PROGNOZE MODELA LSTM-EAPSO SA NAJBOLJIM PERFORMANSAMA...	80
SLIKA 14 DIJAGRAM RASPODELE VREDNOSTI FUNKCIJE CILJA U LSTM-ATT SIMULACIJI PROGNOZIRANJA NEZAPOSLENOSTI.....	ERROR! BOOKMARK NOT DEFINED.80
SLIKA 15 LSTM-ATT DIJAGRAM RASPODELE VREDNOSTI INDIKATORA FUNKCIJE U SIMULACIJI PROGNOZE NEZAPOSLENOSTI.....	80
SLIKA 16 LSTM-ATT DIJAGRAM KONVERGENCIJE VREDNOSTI FUNKCIJE CILJA U SIMULACIJI PROGNOZE NEZAPOSLENOSTI.....	ERROR! BOOKMARK NOT DEFINED.
SLIKA 17 LSTM-ATT DIJAGRAM KONVERGENCIJE INDIKATORSKE FUNKCIJE U SIMULACIJAMA PROGNOZIRANJA NEZAPOSLENOSTI.....	ERROR! BOOKMARK NOT DEFINED.
SLIKA 18 NAJBOLJE POKAZANI MODEL LSTM-EAPSO ZA PREDVIĐANJE NEZAPOSLENOSTI.....	84

SLIKA 19 KDE DIJAGRAM FUNKCIJE **ERROR! BOOKMARK NOT DEFINED.**

Spisak formula

JEDNAČINA 1 MATEMATIČKI PRIKAZ NEURONA	42
JEDNAČINA 2 MODEL RNN MREŽE.....	45
JEDNAČINA 3 PRETHODNO STANJE ĆELIJE	48
JEDNAČINA 4 IZLAZ SIGMOIDNE FUNKCIJE	48
JEDNAČINA 5 KONAČNI IZLAZ PROSLEĐEN TANH FUNKCIJE	48
JEDNAČINA 6 RESET KAPIJA.....	49
JEDNAČINA 7 AŽURIRAJUĆA KAPIJA	46
JEDNAČINA 8 KANDIDATSKO SKRIVENO STANJE NEURONA	49
JEDNAČINA 9 AŽURIRANJE KANDIDATSKOG STANJA.....	49
JEDNAČINA 10 MREŽNA PRETRAGA	53
JEDNAČINA 11 METODA SLUČAJNOG PRETRAŽIVANJA	54
JEDNAČINA 12 AŽURIRANJE BRZINE ĆESTICE	58
JEDNAČINA 13 AŽURIRANJE POZICIJE ĆESTICE	58
JEDNAČINA 14 INICIJALIZACIJA.....	50
JEDNAČINA 15 BRZINA	ERROR! BOOKMARK NOT DEFINED.
JEDNAČINA 16 BRZINA ĆESTICE	ERROR! BOOKMARK NOT DEFINED.
JEDNAČINA 17 DEFINICIJA REFLEKTIVNE ĆESTICE	64
JEDNAČINA 18 KVAZI REFLEKSNO SUPROTNA	ERROR! BOOKMARK NOT DEFINED.
JEDNAČINA 19 PROSEČNA VREDNOST DIMENZIJE J	ERROR! BOOKMARK NOT DEFINED.
JEDNAČINA 20 DIVERZITET PO DIMENZIJI J	ERROR! BOOKMARK NOT DEFINED.
JEDNAČINA 21 UKUPNA RAZNOLIKOST POPULACIJE.....	ERROR! BOOKMARK NOT DEFINED.
JEDNAČINA 22 RAČUNANJE POČETNE VREDNOSTI	54
JEDNAČINA 23 NASUMIČNA PRETRAGA	55
JEDNAČINA 24 SREDNJA KVADRANTNA GREŠKA KORENA	59
JEDNAČINA 25 SREDNJA APSOLUTNA GREŠKA	59
JEDNAČINA 26 SREDNJA KVADRANTNA GREŠKA	73
JEDNAČINA 27 KOEFICIJENT DETERMINACIJE	73
JEDNAČINA 28 INDEKS SLAGANJA.....	74

