

SVEUČILIŠTE U SPLITU

FAKULTET ELEKTROTEHNIKE, STROJARSTVA I

BRODOGRADNJE

POSLIJEDIPLOMSKI DOKTORSKI STUDIJ ELEKTROTEHNIKE I

INFORMACIJSKE TEHNOLOGIJE

KVALIFIKACIJSKI ISPIT

**Metode dubinskog učenja i višekriterijske
GIS analize**

JURICA ĐEREK

Split, studeni 2021.

SADRŽAJ

1. Uvod	3
2. Dubinsko učenje	5
2.1. Neuronske mreže	5
2.1.1. Treniranje neuronske mreže	10
2.1.2. Evaluacija i validacija neuronske mreže	11
2.1.3. Istraživanja u prepoznavanju objekata i govora	13
2.2. Konvolucijske neuronske mreže	15
2.3. Duboko učenje i akustika	17
2.4. Budućnost dubinskog učenja	20
3. Višekriterijska GIS analiza	22
3.1. AHP metoda	23
3.2. Neizrazita AHP metoda	25
3.2.1. Analiza neizrazitog opsega	27
3.2.2. Metoda temeljena na α -izrezu	30
3.3. Višekriterijska GIS analiza i subjektivnost	31
Zaključak	33
Literatura	35
Sažetak	45

1. UVOD

Pojavom prvih računala i njihovim razvojem se počelo postavljati pitanje mogu li takvi uređaji postati inteligentni. Danas se Umjetna inteligencija (engl. *Artificial Intelligence - AI*) naveliko koristi u raznim primjenama: automatizacija rutinskog rada, prepoznavanje slika i videozapisa, u medicini kod postavljanja dijagnoza i slično [1]. Široka lepeza primjene dubinskog učenja je dovela do naglog razvoja u istraživanju dubinskog učenja, posebno u području neuronskih mreža. Njihov razvoj se intenzivira početkom novog tisućljeća zajedno s razvojem hardvera. Kad govorimo o neuronskim mrežama, govorimo o paradigmi koja se temelji na neuronima koji su osnovna građevna jedinica ljudskog mozga. Nastoji se imitirati način rada i povezivanja ljudskih neurona kako bi se oponašao način donošenja odluka kod čovjeka. Naravno da takve građevne jedinice po veličini nisu ni blizu veličini ljudskog mozga, no i dalje daju zapažene rezultate kod donošenja odluka ili općenito generalizacije problema. U tu problematiku se uklapaju i različite primjene neuronskih mreža, odnosno, koja arhitektura i veličina mreže je pogodna za koju primjenu, pri čemu treba uzeti u obzir i resurse kojima korisnik raspolaze. Poseban je naglasak stavljen na proces učenja mreže budući da je on ključan u tome kako će mreža reagirati na neke dosad nepoznate ulazne vrijednosti. Kod treniranja mreža, za razliku od uobičajenog programiranja, nije poznato kako će mreža reagirati za one vrijednosti koje ne upadaju u područje vrijednosti podataka s kojima je mreža trenirana. Zbog toga se naglašava važnost odabira pogodne arhitekture mreže i strategija testiranja da bi mreža imala mogućnost što bolje generalizirati podatke i da što manje griješi. Tu se ističe postupak validacije mreže koji ima poseban značaj kod upotrebe mreža u jako važnim primjenama gdje greške mogu imati teške posljedice (upravljanje strojevima, upravljanje vozilima, medicina i sl.)

Geografski informacijski sustavi (GIS) predstavljaju sustave kojima se, između ostalog, analiziraju i prikazuju geoprostorni podaci. Jedna od najvažnijih primjena GIS-a je donošenje odluka vezanih za okoliš analizom dostupnih geoprostornih podataka. Na takve odluke utječe puno kriterija pa se postavlja pitanje koje sve kriterije možemo uzeti u obzir, na koji način ih vrednovati, koju težinu dati pojedinom kriteriju, koji su minimalni zahtjevi koje svaka lokacija mora ispunjavati i slično. Ovom problematikom se bavi višekriterijska GIS analiza. Predstavljaju se metode kojima se može odmjeriti važnost pojedinih kriterija. U praksi se vrlo često radi o projektima koji mogu imati velik gospodarski benefit, no s druge strane, itekako mogu utjecati na živote ljudi i općenito živih bića u okolici i mogu pridonijeti znatnom utjecaju na

ekosustav, onečišćenja i na izgled okoliša. Primjer takvih projekata su izgradnja vjetroelektrana, golf-terena, nuklearnih reaktora i sl. Višekriterijska GIS analiza tu pomaže u donošenju kompromisne odluke između gospodarstva i očuvanja okoliša, odnosno, da se postigne što veći gospodarski benefit uz što manji utjecaj na okoliš.

U ovom radu su prikazane metode dubinskog učenja s posebnim naglaskom na neuronske mreže. Napravljen je pregled različitih arhitektura neuronskih mreža, postupak treniranja i validacije mreže. Također, govori se i o višekriterijskog GIS analizi te se opisuju metode koje se koriste kod određivanja težine kriterija.

2. DUBINSKO UČENJE

Dubinsko učenje predstavlja postupak u kojem višeslojni modeli nastoje naučiti podatke koristeći više razina apstrakcije [2]. U velikim setovima podataka koristeći mehanizam povratnog širenja (engl. *Backpropagation*) postoji mogućnost da se ukaže na to kako računalo treba prilagoditi svoje inicijalne parametre da bi dobio reprezentativne podatke u trenutnim i sljedećim slojevima u odnosu na prethodne slojeve. Dovoljan broj točnih transformacija može dovesti do učenja jako složenih funkcija. Ključan aspekt dubokog učenja je u tome što težine i spojeve pojedinih slojeva nisu dizajnirali eksperti; oni se uče iz podataka prema već zadanoj proceduri.

Promatrajući pojednostavljeno, kod umjetne inteligencije postoje dvije paradigme učenja: nadahnuti logikom i nadahnuti mozgom [3]. Kod paradigme nadahnute logikom, suština inteligencije je sekvencijalno zaključivanje. Cilj je implementirati donošenje zaključaka u računala koristeći pravila zaključivanja koje je osmislio čovjek koja djeluju na simboličkim izrazima koji formaliziraju znanje. Kod ove paradigme ne postoji unutarnja struktura; odnosi prema drugim simbolima predstavljaju značenje. Paradigma nadahnuti mozgom promatra učenje iz podataka kao bit inteligencije i ima za cilj provesti učenje osmišljavanjem ili razvijanjem pravila za izmjenu jakosti veze u simuliranim mrežama umjetnih neurona. Kod ove paradigme, vanjski simboli koji se koriste za komunikaciju su pretvoreni u vektore neuralne aktivnosti s razgranatom strukturom sličnosti. Vektori aktivnosti se mogu koristiti za modeliranje strukture koja se sastoji od nizova simbola na način da se uče odgovarajući vektori aktivnosti za svaki simbol i učenjem nelinearnih transformacija koje omogućuju popunjavanje vektora aktivnosti koji nedostaju elementima niza simbola. Prvi takav primjer je prikazan u [4] gdje su autori predstavili back-propagation kao metodu učenja za neuronske mreže. Konkretni primjer korištenja backprop mreže je prikazan u [5] gdje su autori koristili mrežu za predviđanje riječi u rečenicama. Mogućnost automatske generalizacije je osnovna prednost upotrebe vektora neuralne aktivnosti.

2.1. Neuronske mreže


Unatoč tome što je princip rada neuronskih mreža poznat još od 80-ih godina 20. stoljeća, intenzivno istraživanje na neuronskim mrežama počinje početkom 2000-ih rastom jakosti hardvera (procesori i grafičke kartice), kao i većoj dostupnosti velikih setova podataka (Internet) [3]. S razvitkom softvera kao što su Tensorflow [6], PyTorch [7], Torch [8], Caffè [9],

Theano [10] su omogućili treniranje kompliciranih mreža, mogućnost korištenja različitih modela i fleksibilnost u građenju arhitekture mreže.

Razvoj Neuronskih mreža (ili Umjetnih neuronskih mreža, engl. *Artificial Neural Network - ANN*) se temelji na pokušaju da se simulira biološki živčani sustav međusobnim povezivanjem većeg broja jednostavnih elemenata (neurona). Takva kompleksna struktura ima mogućnost samoorganizacije i učenja, no nazivanje toga inteligencijom za sobom vuče brojne rasprave [11]. Dok se ljudski mozak sastoji od otprilike sto milijardi neurona, rijetko koja neuronska mreža broji više od par tisuća neurona. Nadalje, neuronske mreže su usporedive sa statističkim metodama koje imaju mogućnost obrade velikih količina podataka i predviđanje trenda kretanja podataka u budućnosti - no, to ih ne čini inteligentnima.

Istraživanja na neuronskim mrežama su motivirana načinom rada ljudske inteligencije koja se temelji na visoko-paraleliziranim nelinearnim neuronima koji uče prilagođavajući jačinu međusobnih veza.

Na Slici 2.1 je prikazan model jednostavne linearne regresije.




Slika 2.1: Jednostavna linearna regresija [11]

Krugom su predstavljene varijable dok kvadrati predstavljaju funkciju koja se primjenjuje na ulaznu varijablu. Svaki neuron je definiran matematičkom funkcijom koja transformira ulaz u izlaz. Jednostavna jednoslojna neuronska mreža izračunava linearnu kombinaciju ulaza na kojoj (najčešće nelinearna) aktivacijska funkcija djeluje i proizvodi izlaz. Neke uobičajene aktivacijske funkcije su:

- Linearna: $a(x) = x$
- Hiperbolični tangens: $a(x) = \tanh(x)$
- Sigmoidna: $a(x) = (1 + e^{-x})^{-1}$
- Funkcija praga: $a(x) = 0$ za $x < 0$, inače 1
- Gaussova: $a(x) = e^{-\frac{x^2}{2}}$

Za opis funkcije pojedinog neurona, koristi se tzv. funkcija mapiranja Γ koja svakom neuronu i dodjeljuje podskup $\Gamma(i) \subseteq V$ koji se sastoji od svih prethodnika tog neurona [12]. V predstavlja skup svih neurona. Veza između i -tog i j -tog neurona je karakterizirana težinskim koeficijentom ω_{ij} , a i -ti neuron s koeficijentom praga ϑ_i . Težinskim koeficijentom ω_{ij} se određuje važnost pojedine veze u mreži (Slika 2.2).



Slika 2.2: Veza dvaju neurona [12]


Izlazna vrijednost i -tog neurona x_i se izračunava:

$$x_i = f(\xi_i) \quad (2.1)$$

$$\xi_i = \vartheta_i + \sum_{j \in \Gamma_i} \omega_{ij} x_j \quad (2.2)$$


pri čemu je $f(\xi_i)$ aktivacijska funkcija, a veličina ξ_i se naziva potencijal i -tog neurona.

Umjetne neuronske mreže su korisne samo ako su posložene na način da mogu odraditi zadatak prepoznavanja uzoraka, zbog čega su organizirane u obliku slojeva [13]. Međuslojne veze mogu biti organizirane kao *feed forward* ili *feedback* gdje se procesna jedinica (sloj) može aktivirati više od jednom. Na slici 2.3 je prikazan primjer troslojne feedforward neuronske mreže.



Slika 2.3: Troslojna feedforward neuronska mreža [12]

Kod feed forward neuronskih mreža ne postoji nikakva povratna vaza pa se informacija može kretati samo od ulaznog sloja prema izlaznom. U feedback neuronskim mrežama postoji mogućnost da se informacija kreće u oba smjera (ulazni prema izlaznom sloju i obrnuto). Pošto prethodni slojevi mogu dobiti informacije o pogreškama iz sljedećih slojeva, to se može iskoristiti da se model prilagodi da bolje nauči ono što se traži od mreže. Na slici 2.4 prikazan primjer feedback neuronske mreže.



Slika 2.4: Feedback neuronska mreža [14]

Primjer korištenja jednostavne feedforward neuronske mreže je prikazan u [15] gdje je korištena jednostavna neuronska mreža s 3 sloja, od čega je jedan sakriveni, za prepoznavanje udaljenosti do naslaga minerala kuroko u Japanu. Skriveni sloj se sastoji od pet neurona, a hiperbolični tangens je korišten kao aktivacijska funkcija. Ulaz u mrežu su rengenke snimke koje sadrže podatke o postojanju i količini drugih minerala u zemlji, a koji mogu indicirati da je u blizini nalazište traženog minerala (pirit, sericit i gips s anhidritom). Autori zaključuju da su uspješno uspjeli identificirati područja bogata mineralom kuroko jer su uspješno identificirali sva dosad poznata nalazišta te su pokazali da i ovakva jednostavna i mala feedforward neuronska mreža može davati značajne predikcije.

Jedan od načina upotrebe feedback neuronske mreže je prikazan u [16] gdje je iskorištena troslojna feedback neuronska mreža za filtriranje seizmoloških podataka. Naime, seizmološki podaci u sebi mogu sadržavati veliku količinu šuma. Takvi nefiltrani podaci su otežani za čitanje i potrebno je iskustvo da bi se oni mogli očitati sa zadovoljavajućom točnošću. Autori su zaključili da im je troslojna feedback neuronska mreža smanjila šum u signalu za 50%. Prema dobivenim rezultatima zaključuju da ove neuronska mreža može prepoznati više vrsta šuma (npr. izravni i refraktirani valovi, nasumični šum, odroni tla) i značajno ih smanjiti.

Razvoj neuronskih mreža nije išao samo u smjeru povećavanja slojeva (produblјivanje mreže) [17], već je bilo puno napretka kod procedura treninga i arhitekturi koja se prilagođava ulaznim podacima [18]. Zanimljiv doprinos je prikazan u radu [19] gdje su autori proučavali Deep

Belief Network (DBN), nenadzirani algoritam učenja, [20]. Na empirički način su istraživali rad mreže i pokušali pronaći njegovu najbolju primjenu te su zaključili da strategija treniranja ovakve vrste mreže, koja najviše koristi kod optimizacije mreže, se radi s inicijalnim težinama koje teže lokalnom minimumu vrijednosti.

2.1.1. Treniranje neuronske mreže

Da bi neuronska mreža mogla raditi ono što joj je zadano, mora naučiti prilagoditi vezu između neurona, odnosno između ulaza i izlaza. Proces treniranja neuronske mreže se sastoji od koraka u kojima se prilagođavaju vrijednosti težine i praga pojedinog neurona i veza s drugim neuronima, tako da bi se mreža prilagodila da na izlazu daje (približno) željene rezultate za svaku ulaznu vrijednost. Koraci od kojih se sastoji treniranje mreže se zove algoritam učenja [21]. Obično se set podataka po kojima mreža uči dijeli u dva seta: set za treniranje i set za testiranje u odnosu 60-90:40-10. Set za testiranje služi za provjeru mreže na način da se mreža istrenira i isproba tako da se na ulaz stave podaci za testiranje. Na izlazu se dobivaju podaci te se donosi ocjena je li nam takva mreža prihvatljiva.

Nadzirano učenje (engl. *Supervised learning*) predstavlja strategiju treniranja u kojem je, uz ulazni set podataka, dostupan i željeni izlaz. Težinske vrijednosti i vrijednosti praga neurona i veza se kontinuirano prilagođavaju primjenom koraka treniranja mreže. Mreža se smatra treniranom kad je razlika unutar prihvatljivog raspona vrijednosti.

Nenadzirano učenje (engl. *Unsupervised learning*) je strategija treniranja u kojem ne postoje informacija o željenoj vrijednosti izlaza. Mreža ima zadatak da se sama organizira na način da identificira klastere prema sličnostima. Također, korisnik može pomoći mreži svojim znanjem tako da apriori specificira maksimalni broj klastera.

Podržano učenje (engl. *Reinforcement learning*) se smatra varijacijom nadziranog učenja [22]. Algoritmi učenja rade na način da se oslanjaju na kvalitativne i kvantitativne informacije dobivene od okoline da bi se procijenila performansa učenja i na osnovu toga prilagodile vrijednosti pragova.

Izvanmrežno učenje (engl. *offline learning*, još i *batch learning*) je postupak učenja u kojem se vrijednosti težina veza i pragova prilagođavaju nakon što je završen postupak treniranja za cijeli trening set.

Suprotno od izvanmrežnog učenja, mrežno učenje (engl. *Online learning*), prilagođava vrijednosti nakon upotrebe svakog uzorka za testiranje. To omogućuje da se određeni uzorak, u sred procesa učenja, može odbaciti. Često se koristi kod sustava kod kojih se vrijednosti brzo mijenjaju.

Postoje situacije u kojima nije moguće doći do većeg opsega ulaznih podataka za treniranje u odnosu na potrebnu kompleksnost mreže. U tom slučaju se često započinje predtreniranje s nekim drugim izvorom informacija u svrhu stvaranja slojeva detektora značajki, zatim se fino ugađaju detektori značajki uz pomoć ulaznih podataka. U krajnjim slučajevima, moguće je generirati slojeve detektora značajki bez ikakvih podataka slaganjem autoenkoder (engl. *Auto-encoder*) neuronske mreže [23]. Najprije se kreiraju dva sloja detektora značajki i svaki sljedeći sloj rekonstruira onaj prethodni i tako se stvaraju skriveni slojevi. Kad se stvori takva arhitektura koja se sastoji od nekoliko istreniranih skrivenih slojeva, pokušava se predvidjeti značajku u zadnjem sloju i greška se vraća natrag da bi se podesili detektori značajki. Treba uzeti u obzir značaj detektora značajki u ovom slučaju budući da su omogućili da se još ne iskoristi ulazne podatke koji znaju biti količinski šturi. Predtreniranje može kreirati značajke koje kod krajnje klasifikacije uopće nisu važne, no, uzimajući u obzir važnost ulaznih podataka, svako predtreniranje je korisno dokle god olakšava posao treniranja. Postupak predtreniranja je jako bitan da se ukloni općeprihvaćena činjenica da su duboke mreže teške za treniranje. U tom smislu je zanimljiv rad [24] u kojem se naglašava važnost dubine učenja, ali se i postavlja pitanje je li dovoljno ubacivati samo slojeve da bismo dobili mrežu koja bolje radi. Naravno da se tu odmah javlja problem nestajanja [25] ili eksplozije [26] gradijenata koje ometaju konvergenciju. Nakon rješavanja tog problema, javlja se problem stagnacije ili degradacije točnosti treniranja do kojeg dovodi jednostavno dodavanje više slojeva na mrežu [27] što govori da nije baš jednostavno optimizirati mrežu prema željama korisnika. Upravo zbog toga, u već spomenutom radu [24], se autori bave problemom degradacije i predstavljaju svoj *deep residual learning framework*.

2.1.2. Evaluacija i validacija neuronske mreže

Neuronske mreže su našle svoje mjesto primjene u širokom spektru zanimanja, među kojima su i ona osjetljiva na pogreške, naprimjer, dijagnostika u medicini [28, 29], procjena kreditne sposobnosti [30], upravljanje automobilima [31]... Zbog toga je jako važna informacija o tome

koliko se moguće pouzdati u izlaze koje nam generira mreža za unesene ulaze.

Potrebno je razdvojiti dvije razine pristupa validaciji mreže. U prvome je cilj izlaznim podacima pridijeliti podatak o mogućnosti da je takav podatak točan (razina pouzdanosti). Ovo omogućuje da se velik broj podataka obradi, a da se oni podaci koji imaju nisku razinu pouzdanosti odbace ili da ih obradi čovjek sam. Druga razina predstavlja garanciju da će mreža davati pouzdane podatke za bilo koji ulaz, što je puno rigoroznije i teže za ostvariti [32].

Budući da je način rada neuronskih mreža daleko od intuitivnog čovjeku koji se ne bavi tim područjem, veliko je pitanje na koji način približiti rizike korištenja takve mreže. Neuronske mreže nisu "programirane" u klasičnom smislu, ne postoje eksplicitna pravila kojima se određuje njihovo ponašanje. One rade po nekakvom modelu naučenom iz dijela ulaznih podataka i njima pripadnih izlaznih podataka tako da nije moguće predvidjeti koji će biti izlaz za većinu vrijednosti ulaza.

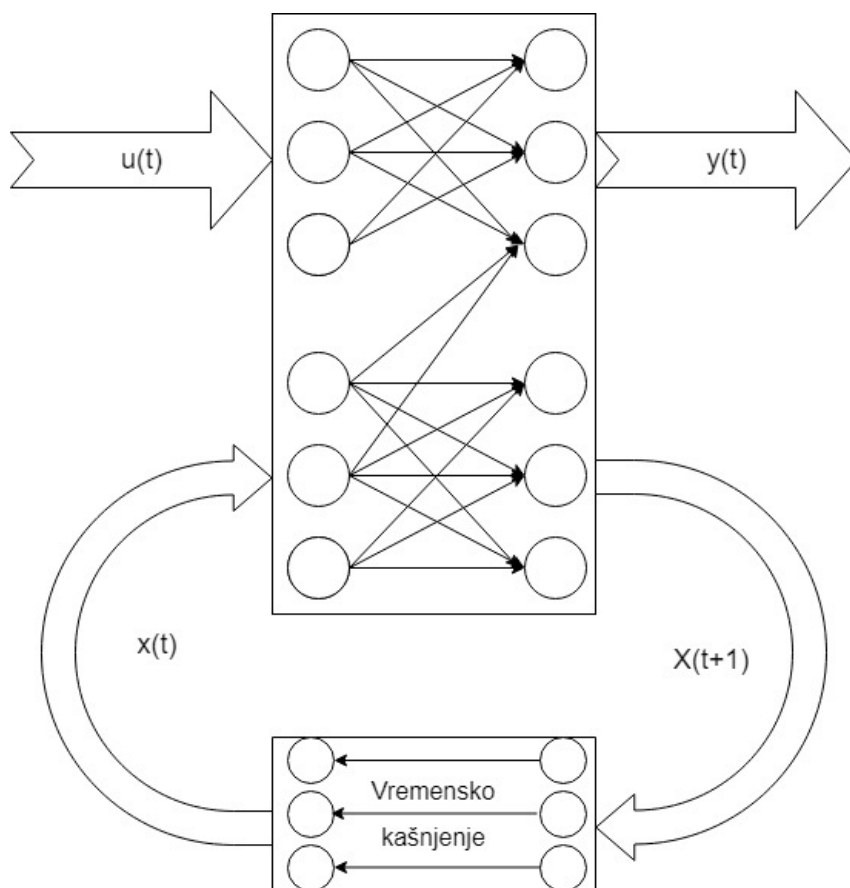
Svrha evaluacije i verifikacije mreže je da otkrije i locira svaku slabost unutar samog sustava [33]. Ocjenjivanje sustava ima širi opseg nego što je bio tijekom generiranja mreže kada je cilj optimizirati performase. U ovoj fazi je potrebno ocijeniti jesu li zahtjevi, ciljevi i potrebe korisnika ispunjeni na osnovu više tehnika:

- Provjera faze treniranja: Procjenjuje se način na koji je trenirana mreža i radi se ocjena ispravnih i neispravnih izlaza za određene ulaze
- Odabir tehnike testiranja: U ovoj fazi je glavni problem nedovoljna količina testnih podataka što je prepreka adekvatnom testiranju mreže. U to, treba imati širok raspon ispravnih i neispravnih podataka, pogotovo onih blizu granica prihvatljivog ponašanja. Ako mreža radi prepoznavanje slika ili objekata na slikama, potrebno se uvjeriti da će mreža raditi kad su objekt/slika prisutni i kad nisu. Stvarni podaci za testiranje trebaju biti iskorišteni kad god je to moguće.
- Korištenje simulacija: Učinkovita metoda za evaluaciju mreže, ako odražava okružje u kojem će se mreža koristiti
- Testiranje od strane stručnjaka: Iskoristiti znanje i iskustvo nekoga tko je iskusan u području mreža za davanje mišljenja o mreži
- Testiranje od strane korisnika: Pošto će korisnici koristiti taj sustav, važno je da ga i oni provjere radi procjene odgovara li sustav standardima korištenja korisnika.

- Provjera sigurnosti: Postoji li mogućnost da, u slučaju pogrešnog izlaza mreže, sustav nekome naudi ili prouzroči štetu.
- Pronalaženje granica između prihvatljivog i neprihvatljivog ponašanja: Za većinu neuronskih mreža je teško pronaći granicu između prihvatljivog i neprihvatljivog ponašanja. Međutim, ako se ta granica može pronaći, čak i samo u nejasnom smislu, tada se povjerenje u korištenje mreže može značajno povećati. Općenito, granica se nalazi isprobavanjem širokog raspona slučajeva u skupu testova i korištenjem testiranja za razdvajanje ovih slučajeva na valjane i nevažeće kategorije.
- Testiranje robusnosti: Napraviti što više "pogrešnih" provjera mreže, npr. pokušati izostaviti neke ulazne podatke ili ubaciti podatke koji nikako ne pripadaju mogućem ulazu mreže
- Testiranje na licu mjesta: Ako je izvedivo, sustav je najbolje isprobati na licu mjesta gdje će biti korišten i da s njim rade korisnici za koje se planira da će raditi na njemu.

2.1.3. Istraživanja u prepoznavanju objekata i govora

Radovi [34] i [35] pokazuju da se neuronske mreže mogu koristiti za akustičko modeliranje. U [34] je prikazana upotreba recurrent neuronskih mreža za prepoznavanje glasova. Konkretno, cilj je napraviti mapiranje iz dijelova parametriziranog govora u sekvencu glasova. Iako je jasno da postoji vidljiva korelacija između dijelova govora i glasova, postoji puno kontekstnih utjecaja na govor koji ovaj problem kompliciraju. U radu [34] je prikazan razvoj hardvera RAP (Ring Array Processor), temeljen na DSP čipovima, koji služi za brzu simulaciju algoritama za treniranje neuronskih mreža. Radi se o višeprocessorskom sustavu koji se bazira na treniranju feedforward mreža za prepoznavanje kontinuiranog govora. Ovaj sustav je olakšao korištenje različitih složenih algoritama time što je omogućio njihovo treniranje na visokim performansama uz nisku potrošnju. Na slici 2.5 je prikazan primjer strukture recurrent mreže za prepoznavanje fonema. Trenutni ulaz, $u(t)$ je prikazan zajedno s trenutnim stanjem $x(t)$. Ova dva vektora se provlače kroz mrežu i daju izlazni vektor $y(t)$ i vektor sljedećeg stanja $x(t+1)$.



Slika 2.5: Recurrent mreža korištena za procjenu vjerojatnosti fonema [36]

Definicija kombiniranog ulaznog vektora označena s $z(t)$, pri čemu je \mathbf{W} označen kao težinska matrica izlaza, \mathbf{V} označen kao sljedeće stanje, glasi:

$$z(t) = \begin{bmatrix} 1 \\ u(t) \\ x(t) \end{bmatrix} \quad (2.3)$$

$$y_i(t) = \frac{1}{1 + e^{(-W_i z(t))}} \quad (2.4)$$

$$x_i(t + 1) = \frac{1}{1 + e^{(-V_i z(t))}} \quad (2.5)$$

2009. godine, autori [37] su koristeći NVidijine grafičke kartice, zajedno s predtrenom dubinskom neuronskom mrežom, bez problema nadjačali tadašnju točnost prepoznavanja glasa. Sve ovo je potaklo jači interes u istraživanju u području akustike i neuronskih mreža. Tako

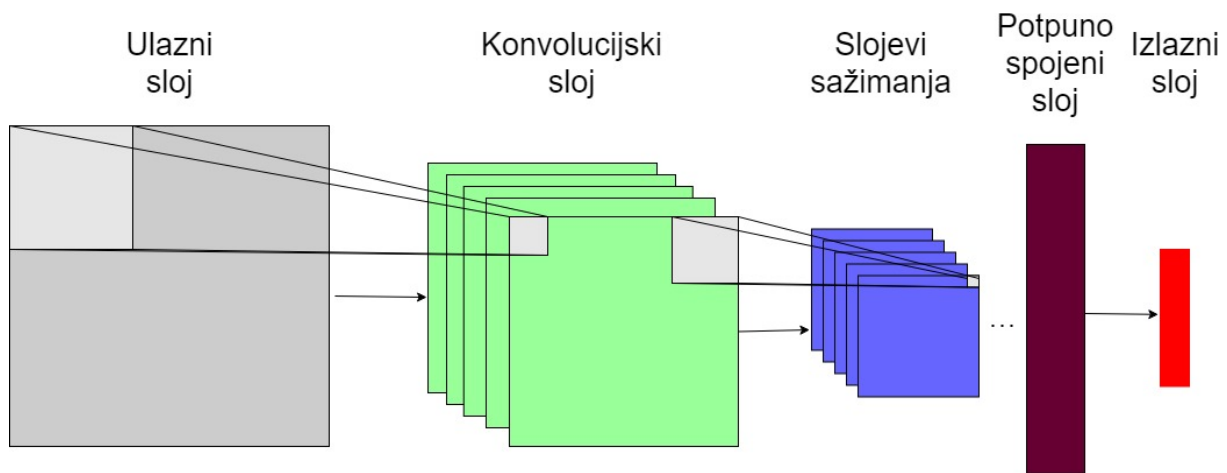
je 2011. u [38] predstavljen model za prepoznavanje govora ovisan o kontekstu (engl. *context-dependent - CD*) za prepoznavanje govora sa širokim rječnikom (engl. *large-vocabulary speech recognition - LVSR*), temeljeno na prethodnim otkrićima u prepoznavanju fonema. Koristeći predtreniranu duboku neuronsku mrežu temeljenu na skrivenom Markovljevom modelu te su uspjeli dati doprinos u poboljšavanju prepoznavanja za 5.8% za MPE (Minimum phone rate) kriterij. Predtreniranje je dalo veliki zamah u istraživanju govora u dubokim neuronskim mrežama zbog toga što, uz rješavanje problema ograničene količine ulaznih podataka, smanjuje pretreniranje (engl. *overfitting*), ali i vrijeme potrebno za fino podešavanje vrijednosti težina neurona kod mreža s povratnom vezom. To je u početku bila jedna od najvećih prepreka korištenju dubokih neuronskih mreža za akustičko modeliranje [39].

Usporedno s razvojem dubokih neuronskih mreža u području akustike, veliki proboj u istraživanju se događa i u prepoznavanju objekata na slikama koristeći neuronske mreže. Značajan doprinos je prikazan u [40], kada su 2012. autori, bez korištenja predtrenirane mreže, istrenirali duboku neuronsku mrežu koja se sastoji od 1.2 milijuna visokokvalitetnih slika razdvojenih u 1000 klasa. Dosadašnji setovi slika su imali dosta manji input, reda veličine 100 tisuća slika (npr. NORB [41] - 194000 slika). Važno je spomenuti i značaj ImageNet [42] baze slika koja se sastoji od više od milijun označenih slika pogodnih za treniranje.

2.2. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže ističemo zbog svoje primjene u različitim područjima vezanih uz prepoznavanje uzoraka, od prepoznavanja objekata na slikama do prepoznavanja glasa. Prednost konvolucijskih neuronskih mreža naspram ostalih je mogućnost smanjenja broja parametara testiranja [43]. To omogućuje upotrebu većih modela za rješavanje kompleksnih zadataka koji nisu bili rješivi klasičnim dubokim neuronskim mrežama. Konvolucijsku neuronsku mrežu je prvi predstavio LeCun [44]. Mreža simulira način obrade ljudskog vida koristeći lokalno receptivno polje, dijeljenje težina i sažimanje. Lokalno polje i dijeljenje težina daju mogućnost da se jedna značajka istakne što može značajno smanjiti opterećenje računanja, dok se sažimanjem može postići nepromjenjivost značajki prema geometrijskim izobličenjima. Zbog toga se često koriste kod računalnog vida [45] i prepoznavanja govora [46].

Primjer konvolucijske mreže je prikazan na slici 2.6.




Slika 2.6: Struktura konvolucijskih neuronskih mreža [47]

Ulazni sloj prima normalizirane slike jednake veličine. Skup podataka u maloj okolini (lokalno receptivno polje) će biti obrađen u konvolucijskom sloju čime se oblikuje mapa značajki za sljedeći sloj. Vrijednost jednog piksela u mapi značajki se može izračunati pomoću:

$$C_k = f(x * W + b) \quad (2.6)$$

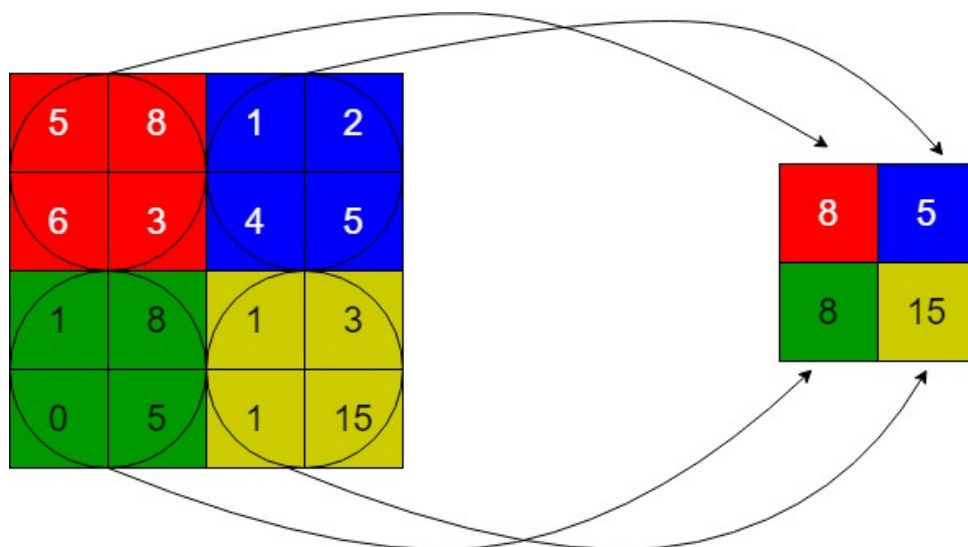
gdje je C_k vrijednost k-tog piksela u mapi značajki, x je vektor vrijednosti piksela u lokalnom receptivnom polju, W je vektor koeficijenata, b je pristranost, dok je f aktivacijska funkcija. Na ulazu u mrežu se nalazi konvolucijski sloj i sloj sažimanja, dok je ostatak mreže nalik običnoj neuronskoj mreži. Arhitektura običnih neuronskih mreža je često takva je da su svi neuroni pojedinog sloja međusobno povezani, dok u istom sloju neuroni ne dijele nikakve veze što daje za pretpostavku da su značajke neovisne. Konvolucijski sloj očekuje podatke koji imaju određene strukture; konvolucijska mreža veže svaki neuron s lokaliziranim podacima koji se zovu receptivna polja. U konvolucijskom sloju se obavlja operacija konvolucije koristeći matricu koja se naziva filter (kernel). Primjer konvolucije je prikazan na slici 2.7.



Slika 2.7: Primjer konvolucije

Prvi skriveni sloj se sastoji od neurona s istim težinama i faktorima pristranosti; time se omogućuje detektriranje iste značajke unutar receptivnog polja. Takvi podaci se mapiraju prema skrivenom sloju kao mapa značajki.

Slojevi sažimanja služe za smanjenje veličine značajki čime se smanjuje količina potrebnog računanja, time se pravi i zaštita od pretreniranja. Kao filter se najčešće koriste usrednjavanje i maksimalna vrijednost (slika 2.8).



Slika 2.8: Primjer sažimanja maksimalnom vrijednošću filterom 2×2 i pomakom 2

2.3. Duboko učenje i akustika

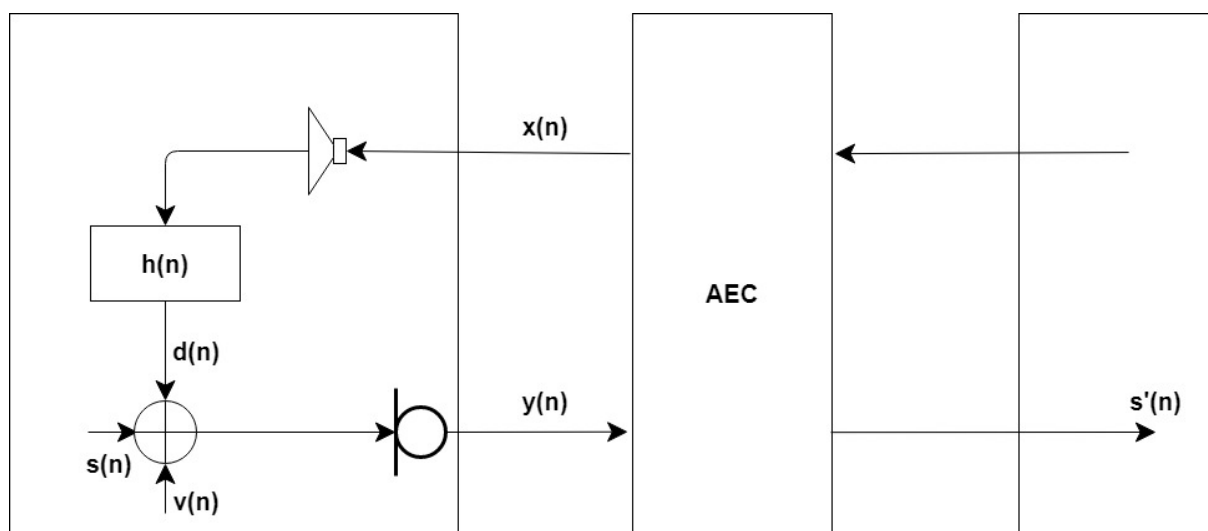
Duboko učenje je pronašlo svoju upotrebu i u području akustike. Zanimljiv rad na tom području je prikazan u [48] gdje su autori, uz pomoć konvolucijskih neuronskih mreža, pokušali riješiti problem lokalizacije više izvora. Kod obrade signala iz niza mikrofona je izvor lokacije jako važan podatak kojeg je teško procijeniti. Dotadašnje metode pate od nedostataka do kojih dolazi u bučnijim uvjetima i uvjetima visoke jeke [49, 50]. Korištena je konvolucijska mreža s filterom 2×1 što znači da svaki filter uči korelacije između susjednih mikrofona. Proces treniranja je napravljen prema postupku u [51] gdje su najprije generirani trening signali za jedan izvor u različitim uvjetima. Zatim su, za određenu postavku niza izvora, dva višekanalna trening signala, u odnosu prema različitom smjeru upada (DOA - direction-of-arrival), su konkatenerani u vremenskoj domeni. Ovaj postupak se ponavlja za sve kombinacije DOA za različite akustičke uvjete potrebne za trening.

Velik dio problema s kojima se susreću akustičari uključuju buku i jeku. Tako je u radu [52]

prikazano na koji su način autori iskoristili neuronske mreže za poništavanje jeke u bučnim uvjetima i u uvjetima u kojima oba sugovornika govore u isto vrijeme. Do jeke dolazi kad su zvučnik i mikroskop povezani u komunikacijski sustav u kojem mikroskop skuplja zvuk sa zvučnika zajedno s njegovim odjekom. Ako se tim slučajem ne rukuje pravilno, korisnik koji sluša može čuti sam sebe odgođeno s vremenom potrebnom za zvuk napravi krug u sustavu i pomičešano s trenutnim signalom koji dolazi. Ovaj problem je danas prisutan kod aplikacija za prijenos govora, kod telekonferencija, mobilne komunikacije, hands-free telefonije i sl. Obično se poništavanje buke postiže prepoznavanjem impulsnog odziva između zvučnika i mikrofona koristeći FIR filter [53]. Pristup rješavanju problema istovremenog razgovora dvaju sudionika se temelji na korištenju detektora istovremenog govora (DTD - double talk detector) [54]. Signal primljen preko mikrofona, uz jeku i govor sadržava pozadinsku buku. Za suzbijanje pozadinske bude se obično primijenjuje post-filter [55].

Mogućnost recurrent neuronskih mreža da modeliraju funkcije s promjenjivim vremenom igra važnu ulogu kod problema suzbijanja jeke. Long short-term memory (LSTM) [56] je varijanta recurrent mreže koja dobro modelira vremenske ovisnosti i ima dobre performanse u odvajanju govora od buke i kod poboljšanja govora u bučnim uvjetima [57]. Autori [52] predstavljaju dvosmjerni LSTM (bidirectional LSTM - BLSTM) kao mrežu za nadzirano učenje za predviđanje idealnog omjera značajki izvojenih iz miješanog signala govora. Klasični akustički model je prikazan na slici x, gdje se signal mikrofona $y(n)$ sastoji od jeke $d(n)$, zvuka na bližoj strani $s(n)$ i pozadinske buke $v(n)$, a prikazano je na slici 2.9:

$$y(n) = d(n) + s(n) + v(n) \quad (2.7)$$



Slika 2.9: Dijagram nastanka jeku u akustičkom sustavu [52]

Do jeku dolazi konvolucijom signala iz zvučnika s impulsnim odzivom sobe nakon čega su odjek, blizinski govor i pozadinska buka pomiješani i stvaraju signal u mikrofonu. Taj se signal prenosi u AEC sustav (AEC - acoustic echo cancellation) koji će suzbiti jeku.

Za evaluaciju AEC sustava, autori su koristili TIMIT bazu [58] iz koje su slučajnim odabirom izvukli 100 parova govornika, od čega 40 muško-ženskih, 30 muško-muških i 30 žensko-ženskih. Postoji 10 izgovora uzorkovanih na 16 kHz za svakog govornika; tri izgovora istog govornika na daljem kraju su odabrani slučajno i konkatenirani čime čine signal na daljem kraju. Svaki izgovor govornika na bližem kraju je proširen na jednaku veličinu kao i onaj na daljem kraju popunjavanjem praznina nulama. Sedam izgovora ovih govornika se koristi za stvaranje miješanih signala, a svaki signal pri kraju miješa se s pet različitih signala na daljoj strani. Ukupno postoji 3500 miješanih signala za trening. Preostala tri izgovora koriste se za stvaranje 300 miješanih signala gdje se svaki signal na bližoj strani miješa s jednim signalom na daljoj strani. Da bi se istražila generalizacija govornika prema predloženoj metodi, nasumično su odabrana još 10 parova govornika (4 muško-ženska para, 3 muško-muška para i 3 žensko-ženska para) od ostatka od 430 govornika u TIMIT bazi i stvoreno još 100 testnih miješanih signala.

Eksperimentom se ispituje performansa BLSTM metode u situacijama istovremenog govora s dvije strane, pozadinske buke (dodan bijeli šum u signal) i nelinearne distorzije uzrokovane utjecajima pojačala i zvučnika, a taj utjecaj se simulira kroz dva koraka. Najprije se uzrokuje jaki clipping [59] na signalu na daljoj strani čime se oponaša karakteristika pojačala snage:

$$x_{hard}(n) = \begin{cases} -x_{max}, & \text{za } x(n) < -x_{max} \\ x(n), & \text{za } |x(n)| \leq x_{max} \\ x_{max}, & \text{za } x(n) > x_{max} \end{cases} \quad (2.8)$$

pri čemu je x_{max} postavljen na 80% maksimalne jačine ulaznog signala. Sigmoidalna funkcija bez memorije [60] koja oponaša utjecaj karakteristika zvučnika:

$$x_{NL} = \gamma \left(\frac{2}{1 + e^{(-a*b(n))}} - 1 \right) \quad (2.9)$$

gdje je

$$b(n) = 1.5 \times x_{hard}(n) - 0.3 \times x_{hard}^2(n) \quad (2.10)$$

pri čemu je sigmoidno pojačanje γ postavljeno na 4, a sigmoidni nagib a je postavljen na 4 ako je $b(n) > 0$, inače je 0.5.

Za svaki miješani signal za trening, procesira se $x(n)$ iz čega se dobiva $x_{NL}(n)$, zatim se nelinearno procesirani daljinski signal na daljoj strani konvoluirao sa slučajno odabranim impulsnim odzivom čime se generira signal jeka $d(n)$. Odnos signal-jeka je postavljen na 3.5 dB, a bijeli šum je dodan na 10 dB odnosa signal-šum.

Što se tiče rezultata, autori su pokazali da BLSTM zaista daje napredak kod situacija u kojima imamo jeku, pozadinsku buku ili istovremeni razgovor dvaju sudionika što se vidi iz rezultata pri čemu je ERLE (Echo return lost enhancement) poboljšao s 39.98 na 49.26, a PESQ (Perceptual evaluation of speech quality) s 2.15 na 2.69.

2.4. Budućnost dubinskog učenja

Performanse sistema dubokog učenja se mogu poboljšati povećanjem mreže (iako to nije uvijek pravilo), no generalno, velikim povećavanjem ulaznih podataka i mogućnošću bržeg izračuna, možemo poboljšati performanse duboke mreže. Primjer za to je jezični model GPT-3 [61]. Općenito, NLP modeli (NLP - Neural language processing) pokazuju da dodavanje velikih skupova podataka u ulazu u mrežu poboljšava performanse. Da bi se pretrenirana NLP mreža fino ugodila za specifični zadatak, potrebne su desetine tisuća ulaznih podataka, za razliku od ljudi koji pomoću par primjera i uputa nauče kako upotrebljavati pojedinu jezičnu specifičnost. U radu je korišten jednak model i arhitektura kao i kod prethodnika GPT-2 modela [62], uključuju-

jući inicijalizaciju i normalizaciju modela. Jedina je razlika u količini ulaznih podataka, GPT-3 ima 175 milijardi ulaznih parametara, dok GPT-2 ima "samo" 1.5 milijardi. Model GPT-2 je na LAMBADA [63] setu podataka ostvario točnost od 63.24%, dok je GPT-3 to unaprijedio na 76.2%. Nadalje, dobri primjeri da kod NLP sustava performanse rastu s rastom ulaznih parametara su chatbotovi BlenderBot [64] i Meena [65]. Trenutno se veliki napor ulaže u povećanje postojećih mreža što će ih donekle poboljšati, no, većina temeljnih problema s kojima se suočava duboko učenje se neće time riješiti.

Usporedba ljudskih mogućnosti učenja s načinima i mogućnostima učenja u dubokom učenju donosi zanimljive zaključke. Nadzirano učenje zahtijeva veliku količinu ulaznih podataka, dok nenadzirano može zahtijevati velik broj pokušaja, dok čovjek ima tu mogućnost da bez većih problema i u kratko vrijeme generalizira problem. Također, trenutni modeli nisu otporni na promjene u distribuciji dok se ljudi jako brzo i s malo primjera prilagode promjeni. Od samih početaka strojnog učenja, teoretičari su kretali od pretpostavki da će testni slučajevi uvijek dolaziti iz istih distribucija iz kojih dolaze slučajevi na osnovu kojih se radi trening. Međutim, u stvarnom svijetu je to rijetko slučaj zbog čega često sustavi na prelasku iz laboratorija u stvarni svijet postaju praktički beskorisni. Zbog toga je potrebno postići veću robusnost prilikom promjene u distribuciji. Neuroznanost pokazuje da su skupine obližnjih neurona čvrsto povezane i postoji mogućnost da predstavljaju višu razinu vrijednosti koja ne mora biti samo skalar, već može biti i skup koordiniranih vrijednosti. Neuronske mreže koje objektima i njihovim dijelovima dodjeljuju unutarnje referentne okvire i prepoznaju objekte korištenjem geometrijskih odnosa između dijelova trebale bi biti daleko manje ranjive na promjene u distribucijama.

Kod dubinskog učenja težine se polako prilagođavaju novim vrijednostima temeljeno na novim primjerima. Dodavanje težina koje mogu brzo mijenjati svoju vrijednost daje nove mogućnosti mreži pošto se stvara kratkoročna visokokapacitivna memorija što omogućuje bržu i lakšu prilagodbu novonastaloj situaciji.

Čovjek ima mogućnost sustavne generalizacije što znači da ima mogućnost iskoristiti već naučena znanja i vještine u novom okruženju. Primjer za to je učenje vožnje motora nakon što smo naučili voziti auto i bicikl. Budućnost dubinskog učenja će se temeljiti upravo na takvom načinu učenja - da se iskoriste prethodno stečena znanja i iskoriste u lakšem prilagođavanju novoj okolini pri čemu se ističe važnost zadržavanja postojećih prednosti dubinskog učenja.

3. VIŠEKRITERIJSKA GIS ANALIZA

Geografski informacijski sustavi (GIS) su računalni sustavi koji služe za prikupljanje, pohranu, ispitivanje, analizu i prikaz geoprostornih podataka [66]. Geoprostorni podaci su oni podaci koji opisuju lokaciju zajedno s atributima koji se odnose na tu lokaciju. Prema [66], geoprostorni podaci sadrže lokaciju određenog obilježja u prostoru. Ovisno o načinu prikaza obilježja u prostoru, oni mogu biti prikazani kao vektorski ili rasterski podaci. Kada se za prikaz koristi geometrijski objekt (točka, linija, poligon), onda govorimo o vektorskom prikazu podataka. Rasterski prikaz podataka koristi ćelije u obliku rešetki za prikaz na način da vrijednost ćelije odgovara atributu prostornog obilježja.

Proces donošenja odluka vezanih uz okoliš temeljena na prikazu i analizi dostupnih podataka je jedna od najvažnijih primjena Geografskih informacijskih sustava [67]. Da bi se donijela što utemeljenija odluka, uzima se u obzir više kriterija koji mogu biti kombinirani i evaluirani. Višekriterijska GIS analiza obično ima dva pristupa; prvi pristup pretpostavlja da su ulazni podaci na osnovu kojih se donosi odluka, u *Boolean* obliku, što bi značilo da imaju vrijednost 1 ili 0 (istina ili laž). Bolji, ujedno i češći pristup, je onaj u kojem su kontinuirani podaci standardizirani na zajednički raspon i onda kombinirani zajedno s pridijeljenim težinskim faktorima, taj pristup nosi naziv ponderirana linearna kombinacija (*engl. Weighted linear combination - WLC*)

Ponderirana linearna kombinacija, kao pristup višekriterijskoj GIS analizi, se iz kriterija izračunava kao zbroj svakog kriterija pomnoženog s faktorom težine:

$$S = \sum w_i x_i \quad (3.1)$$

gdje je S mjera prikladnosti određene lokacije temeljene na višekriterijskoj analizi, w_i predstavlja težinu i -tog kriterija, a x_i vrijednost i -tog kriterija.

Prije postupka objedinjavanja pojedinih kriterija, najprije je potrebno podatke koji predstavljaju određeni kriterij standardizirati (normalizirati). Najčešći princip normalizacije je prikazan jednadžbom:

$$X_i = \frac{R_i - R_{min}}{R_{max} - R_{min}} \quad (3.2)$$


gdje R predstavlja vrijednost kriterija, R_{min} minimalna, a R_{max} maksimalna vrijednost kriterija iz skupa.

3.1. AHP metoda

AHP (*engl. Analytical Hierarchy Process* - Analitički hijerarhijski proces) metoda koristi hijerarhijske strukture da bi predstavili problem nakon čega se razvijaju prioriteta za sve alternative temeljeno na odluci korisnika [68]. Prema [69], AHP proces uključuje sljedeće korake [70]:

- Definicija nestrukturiranog problema
- Razvoj AHP hijerarhije
- Usporedba svaki-sa-svakim u parovima
- Procjena relativnih težina
- Provjera konzistentnosti
- Dobivanje rezultata

U koraku definicije nestrukturiranog problem treba prepoznati nestrukturirani problem i jasno navesti ciljeve i ishode. Razvoj AHP hijerarhije započinje s razbijanjem kompleksnog problema u hijerarhijsku strukturu koja se sastoji od elemenata koji utječu na odabir [71] (Slika 3.1)



Slika 3.1: Hijerarhijska struktura problema odluke [70]

Usporedba svaki-sa-svakim u parovima se radi prema matrici:

$$A = \begin{bmatrix} 1 & \frac{w_1}{w_2} & \dots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & 1 & \dots & \frac{w_2}{w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \dots & 1 \end{bmatrix} \quad (3.3)$$

Gdje je matrica A matrica usporedbe, w_1 težina elementa 1, w_n težina n -tog elementa. Iz odnosa pojedinih težina dobivamo informaciju o važnosti pojedinog kriterija. Procjena relativne težine

kriterija (W) dobiven iz matrice A se dobiva sljedećim izrazom [71]:

$$(A - \lambda_{max}I) \times W = 0 \quad (3.4)$$

gdje je λ_{max} najveća svojstvena vrijednost matrice A , I je jedinična matrica.

Provjerava se konzistencija kako bi se osiguralo da postoji dosljednost u donesenim težinama. Indeks konzistentnosti (CI) izračunava se na sljedeći način:

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (3.5)$$

Posljednji korak predstavlja konačan izračun rezultata prema izrazu:

$$W_i^s = \sum_{j=1}^m w_{ij}^s w_j^a, i = 1, \dots, n \quad (3.6)$$

pri čemu je W_i^s ukupna težina područja i , w_{ij}^s je vrijednost kriterija j za područje i , w_j^a je vrijednost težine za kriterij j , m predstavlja ukupan broj kriterija, a n broj područja.

Zanimljiv primjer korištenja AHP metode kod višekriterijske GIS analize je prikazan u radu [72], gdje su autori prikazali način donošenja odluke o lokaciji industrijskog pogona na području Vojvodine, Republika Srbija. Autori su prema podacima o investicijskoj klimi u Srbiji poredali kriterije po važnosti, dajući im ocjenu od rasponu od 1-10. Tako su zaključili da je dostupnost kvalitetne radne snage najvažniji faktor, odmah uz cijenu rada. Pri vrhu po važnosti su također i prometna infrastruktura, dostupnost sirovina, dok je mogućnost smještaja (hoteli i sl.) ocijenjeno najnižom ocjenom. Prema autorima, kombinacija kriterija zajedno s težinama je dala kvalitetno rješenje za prostornu analizu Vojvodine za odabir lokacije industrijskog pogona.

Rad [73] prikazuje upotrebu AHP metode višekriterijske GIS analize u svrhu odabira najpogodnije biciklističke staze u ruralnom području. Kriteriji koji su uzeti u obzir su: duljina segmenta ceste, vrsta ceste, nagib, udaljenost do pitke vode i udaljenost do jedinice Hitne medicinske pomoći. Određeno je da se generiraju dvije vrste biciklističkih staza; one strmije i dulje koje su namijenjene iskusnim biciklistima i staze koje su kraće i blažeg nagiba za bicikliste amatere. Autori zaključuju da se GIS može koristiti za rutiranje temeljeno na višekriterijskoj analizi. Također, naglašava se važnost prikladne dodijele težine kriterijima.

Još jedan primjer korištenja višekriterijske GIS analize temeljene na AHP metodi je prikazan u radu [74] gdje su se autori pozabavili upotrebom višekriterijske GIS analize u području

turizma. Turizam je jedna od najdinamičnijih i najbrže rastućih industrija te je prepoznata kao prilika za generiranje prihoda i zaposlenosti u državnim ekonomijama [75]. Turizam, uz pozitivne utjecaje, može imati i one negativne, poglavito na okoliš. Stoga je cilj višekriterijske analize da se smanje negativni utjecaji. U ovom radu je prikazana procjena utjecaja turizma na okoliš u gradu Langroodu (Iran).

3.2. Neizrazita AHP metoda


Iako popularna i relativno jednostavna, AHP metoda ima svoje manjkavosti u vidu da nije dovoljno dobra u preslikavanju ljudskog načina razmišljanja u donošenju odluka; ljudska odluka o težini se teško na pravi način može pretočiti u konkretnu numeričku vrijednost [76]. Puno bliže ljudskom načinu razmišljanja kod donošenja odluka je Neizrazita AHP (Fuzzy AHP) metoda jer bolje tolerira nejasnoću i dvosmislenost [77, 78] koja postoji u ljudskom načinu razmišljanja i odlučivanja.

Rad [76] objašnjava neizraziti pristup u AHP metodi i objašnjava empirijsko istraživanje koje veže uz taj pristup. Istraživanje se bavi problemom odabira ponuda s kojima se suočava lokalna vlada u državi Viktoriji, Australija pri čemu se posebno naglašava kompleksnost takvog problema i potreba za strukturalnim pristupom da bi se donijela primjerena i konzistentna odluka o ponudama. Donošenje odluke o najboljoj ponudi za specifični projekt je složen proces u kojem ukupna kvaliteta treba biti uzeta u obzir i evaluirana prema višekriterijskoj analizi. Subjektivne procjene su jako često uključene u kriterije za odabir ponude, a to uključuje neprecizne podatke. Zbog toga se autori u ovom slučaju odlučuju na korištenje neizrazitog pristupa za rješavanje ovog problema. U radu je pokazano da je neizraziti pristup AHP metodi koncept koji se adekvatno nosi s nesigurnošću i nepreciznošću ljudskog donošenja odluka i da ga je potrebno uključiti u višekriterijska razmatranja kad god je u njega uključena subjektivnost. To potvrđuje i rad [77] u kojem je također opisana neizrazita AHP metoda, zajedno s imaginarnim primjerom u kojem se donosi odluka o pružatelju nekakve usluge u kojem su za ocjenu izabrana tri kriterija: cijena usluge, kvaliteta usluge i vrijeme isporuke. Potencijalni pružatelji usluga su tri tvrtke i potrebno je izabrati onu koja na najbolji način zadovoljava sve kriterije. Unatoč tome što se radi o relativno jednostavnom problemu s malim brojem kriterija, autori smatraju da su prednosti neizrazitog pristupa itekako uočljive i u rješavanju složenijih problema. Sličan primjer je prikazan u [78] gdje autori koriste neizraziti AHP pristup kao pomoć firmama u Tur-

skoj. Koristeći neizrazitu AHP metodu, vagaju se ključne kompetencije jedne tehnologije ili proizvoda na temelju odgovora od strane 16 menadžera iz različitih turskih tvrtki. Na osnovu rezultata su doneseni zaključci. Ulaganje u jednu tehnologiju ili proizvod može rezultirati velikim promjenama. Ako uzmemo u obzir da pojedina tvrtka može imati velik broj tehnologija i proizvoda, stvar se dodatno komplicira. Stoga autori naglašavaju važnost koncepta upravljanja tehnologijom da bi se što bolje iskoristio potencijal tvrtke.

Prema [79] u kojem je predstavljena matematička podloga Fuzzy teorije prema kojoj se funkcija pripadnosti određenoj klasi nalazi unutar [0,1]. Glavna osobina neizrazite metode je u grupiranju podataka u klase koje nemaju jasno razgraničene vrijednosti [80]. Način prikaza neizrazite usporedbe je pomoću fuzzy broja; jedan od načina njegovog prikaza je trokutasti neizraziti broj. Trokutasti neizraziti broj je definiran s tri realna broja (l,m,u) kako slijedi (Slika 3.2):

$$\mu_A(x) = \begin{cases} \frac{x-l}{m-l}, & \text{za } l \leq x \leq m \\ \frac{u-x}{u-m}, & \text{za } m \leq x \leq u \\ 0, & \text{inače} \end{cases} \quad (3.7)$$

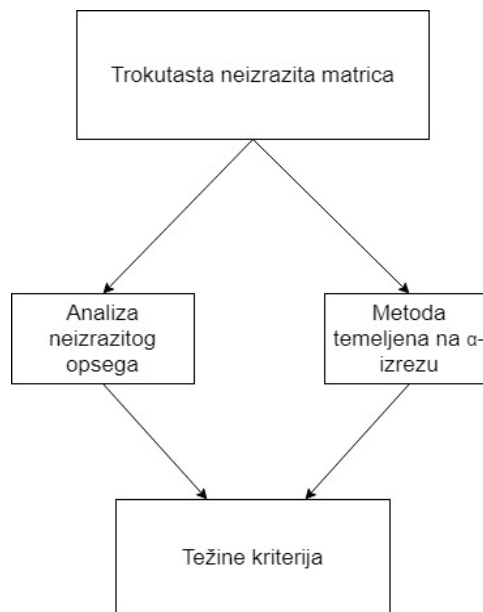


Slika 3.2: Trokutasti neizraziti broj [70]

Slično kao kod AHP metode, trebamo konstruirati matricu za usporedbu svaki-sa-svakim. Trokutasta neizrazita matrica se definira kako slijedi:

$$\tilde{A} = (\tilde{a}_{ij})_{n \times m} = \begin{bmatrix} (1, 1, 1) & (l_{12}, m_{12}, u_{12}) & \dots & (l_{1n}, m_{1n}, u_{1n}) \\ (l_{21}, m_{21}, u_{21}) & (1, 1, 1) & \dots & (l_{2n}, m_{2n}, u_{2n}) \\ \vdots & \vdots & \ddots & \vdots \\ (l_{n1}, m_{n1}, u_{n1}) & (l_{n2}, m_{n2}, u_{n2}) & \dots & (1, 1, 1) \end{bmatrix} \quad (3.8)$$

Izračun težina iz trokutaste neizrazite matrice može biti izračunat korištenjem različitih metoda; ovdje su predstavljene dvije metode: analiza neizrazitog opsega i metoda temeljena na α -izrezu (slika 3.3).



Slika 3.3: Dijagram metoda izračuna težina iz neizrazite trokutaste matrice

3.2.1. Analiza neizrazitog opsega

Originalnog imena *Fuzzy Extent Analysis*, ovu metodu je predstavio Chang u radu [81]. Ova metoda se koristi kod izračuna težina iz trokutaste neizrazite matrice. Izračun se vrši u četiri koraka. U prvom koraku se radi izračun normaliziranih vrijednosti stupaca:

$$\tilde{S}_i = \sum_{j=1}^n \tilde{a}_{ij} \otimes \left[\sum_{k=1}^n \sum_{j=1}^n \tilde{a}_{kj} \right]^{-1} \quad (3.9)$$


gdje \otimes predstavlja množenje dvaju neizrazitih brojeva. U idućem koraku se izračunava vjerojatnost da je $\tilde{S}_i \geq \tilde{S}_j$ prema izrazu:

$$V(\tilde{S}_i \geq \tilde{S}_j) = \begin{cases} 1, & \text{za } m_i \geq m_j \\ \frac{u_i - l_j}{(u_i - m_i) + (m_j - l_j)}, & \text{za } l_j \leq u_i \quad i, j = 1, \dots, n; j \neq i \\ 0, & \text{inače} \end{cases} \quad (3.10)$$

gdje je

$$\tilde{S}_i = (l_i, m_i, u_i) \text{ i } \tilde{S}_j = (l_j, m_j, u_j) \quad (3.11)$$

Na Slici 3.4 je grafički prikazana vjerojatnost $\tilde{S}_i \geq \tilde{S}_j$.



Slika 3.4: Prikaz vjerojatnosti $\tilde{S}_i \geq \tilde{S}_j$ [70]

Treći korak je izračun vjerojatnosti da \tilde{S}_i bude veći od svih $n-1$ ostalih neizrazitih brojeva \tilde{S}_j :

$$V(\tilde{S}_i \geq \tilde{S}_j \mid j = 1, \dots, n; j \neq i) = \min_{j \in \{1, \dots, n\}, j \neq i} V(\tilde{S}_i \geq \tilde{S}_j), \quad i = 1, \dots, n \quad (3.12)$$

Četvrti korak je izračun vektora prioriteta $W = (w_1, \dots, w_n)^T$ iz neizrazite matrice usporedbe \tilde{A} prema:

$$w_i = \frac{V(\tilde{S}_i \geq \tilde{S}_j \mid j = 1, \dots, n; j \neq i)}{\sum_{k=1}^n V(\tilde{S}_k \geq \tilde{S}_j \mid j = 1, \dots, n; j \neq k)} \quad i = 1, \dots, n \quad (3.13)$$

Šarenilo mogućnosti primjene višekriterijske GIS analize je prikazano i radom [82] gdje je višekriterijska analiza temeljena na AHP metodi analizom neizrazitog opsega, iskorištena za odabir lokacije vjetroelektrane. Upotreba GIS višekriterijske analize u ovakvu svrhu se jako dobro uklapa zbog toga što se prilikom planiranja lokacije vjetroelektrane mora voditi računa da se maksimalno iskoristi energija vjetra, a da se s druge strane što manje utječe na okoliš

(vizualni utjecaj, buka, utjecaj na divlje životinje, elektromagnetski utjecaj). U početku je bilo potrebno izabrati širu regiju koja će biti promatrana kao prikladna. Izabrano je područje Kozani koje je dio pokrajine Zapadne Makedonije u Grčkoj. Radi se o planinskom području s visokim potencijalom energije vjetra. Pošto to područje već proizvodi 50% ukupne energije u Grčkoj, infrastruktura je postojeća pa tu nisu potrebna velika dodatna ulaganja. Analiza je započela s izuzimanjem onih mjesta na kojima nikako nije moguća gradnja vjetroelektrane prema određenim kriterijima pri čemu su u obzir uzete površine veličine 150×150 metara.:

- Društvena implikacija vjetroelektrana (vizualni utjecaj, utjecaj buke, estetika okoliša). Sva urbana područja su isključena, i to u okolini 1000 m od naselja s više od 2000 stanovnika, 1500 m od tradicionalnih naselja, 500 m od naselja s manje od 2000 stanovnika
- Udaljena manje od 1000 m od zaštićenih područja da bi se sačuvala estetika prirodnog okruženja
- Udaljena manje od 1000 m od svih arheoloških i kulturalnih spomenika
- Udaljena manje od 1000 m od turističkih objekata (hotela, kuća za odmor)
- Isključena su industrijska područja, rudnici, gradilišta, vlažna područja, navodnjavana poljoprivredna zemljišta i sl.
- Gdje je prosječna brzina vjetra manja od 4.5 m/s i nagibi veći od 25%
- Udaljenost manja od 150 m od ceste i 3000 m od aerodroma

Sada se rade analize preostalog područja, ali s važnom razlikom da više nema isključivosti (prikladno ili nije prikladno), sada se kriteriji mjere na kontinuiranoj ljestvici. Kriteriji su:

- Nagib
- Brzina vjetra
- Iskorištenost zemlje (Likertova ljestvica - uključuje ekonomske i okolišne aspekte)
- Udaljenost do ceste
- Udaljenost do zaštićenih prirodnih područja
- Udaljenost do zaštićenih povijesnih/arheoloških spomenika

Neizraziti setovi su iskorišteni za izračun težina pojedinog kriterija, nakon čega se konačni indeks prikladnosti izračunavao kao zbroj umnožaka težine i vrijednosti pojedinog kriterija.

Autori zaključuju da, unatoč tome što se njihovo istraživanje može dodatno nadograditi, je dovoljno precizno da se koristi na nacionalnoj ili regionalnoj razini u donošenju odluke o pogodnoj lokaciji za vjetroelektranu.

3.2.2. Metoda temeljena na α -izrezu

Unatoč tome što je teža za izračun, prednost metode temeljene na α -izrezu u odnosu na analizu neizrazitog opsega što se može uzeti u obzir nesigurnost donositelja odluke. U ovoj metodi se izračunava matrica performansi (P) koja se dobiva množenjem vektora neizrazitih težina pojedinog kriterija s matricom odluke za alternative za svaki kriterij i zbrajanjem dobivenih vektora:

$$\tilde{p} = \begin{bmatrix} (l_1, m_1, u_1) \\ (l_2, m_2, u_2) \\ \vdots \\ (l_n, m_n, u_n) \end{bmatrix} \quad (3.14)$$

gdje je n broj alternativa.

Prema [83], za provjeru i usporedbu neizrazitih brojeva, ako su A i B neizraziti brojevi s α -izrezom, $A_\alpha = [a_{\alpha-}, a_{\alpha+}]$, $B_\alpha = [b_{\alpha-}, b_{\alpha+}]$. Vrijedi da je A manji ili jednak od B ($A \leq B$), ako vrijedi da je $a_{\alpha-} < b_{\alpha-}$ i $a_{\alpha+} < b_{\alpha+}$ za sve α u području $(0,1]$.

U sljedećem koraku se matrica performansi transformira u intervalnu matricu performansi:

$$\tilde{p}_\alpha = \begin{pmatrix} (\alpha\text{Left}_1, \alpha\text{Right}_1) \\ (\alpha\text{Left}_2, \alpha\text{Right}_2) \\ \vdots \\ (\alpha\text{Left}_n, \alpha\text{Right}_n) \end{pmatrix} \quad (3.15)$$

pri čemu vrijedi:

$$\alpha\text{Left} = [a \times (m - l)] + l\alpha\text{Right} = u - [a \times (u - m)] \quad (3.16)$$

α -izrez predstavlja količinu nesigurnosti u neizrazitom području; čovjek sam donosi odluku prema vlastitom nahodjenju o njegovoj vrijednosti. Vrijednost može biti između 0 i 1, od najmanje sigurnosti do najveće sigurnosti.

Zadnji korak predstavlja pretvaranje matrice intervala u čistu (oštru, *engl. crisp*) vrijednost. Postupak se sastoji od upotrebe Lambda funkcije koja predstavlja stav čovjeka koji donosi odluku; on može biti pesimističan, optimističan ili umjeren. Lambda vrijednost se nalazi u području između [0,1], a njezinu vrijednost donosi čovjek prema svom nahođenju:

$$C_\lambda = \begin{pmatrix} C_{\lambda 1} \\ C_{\lambda 2} \\ \vdots \\ C_{\lambda n} \end{pmatrix} \quad (3.17)$$

pri čemu je:

$$C_\lambda = \lambda \times \alpha\text{Right} + [(1 - \lambda) \times \alpha\text{Left}] \quad (3.18)$$

C_λ predstavlja čistu (oštru) vrijednost.

Rad u kojem je predstavljena još jedna metoda izračuna biciklističkih ruta je prikazan u [84]. Autori su kao kriterij odabira staze u gradskom okruženju izabrali volumen prometa, širina rubnjaka, širina pločnika, ograničenje brzine, kvaliteta kolnika i postojeće prepreke. Uz to, za odabir težina kriterija su koristili neizrastu AHP metodu temeljenu na α -izrezu.

3.3. Višekriterijska GIS analiza i subjektivnost

Kroz cijeli prikaz višekriterijske GIS analize se provlači problem uvlačenja ljudskih odluka u višekriterijsko računanje. Dok računalo prilikom svog izračuna napravi egzaktan izračun i donese rezultat, bilo kakvo uplitanje čovjeka u taj izračun nužno uključuje i nesigurnost. Cijelo ovo poglavlje je bilo posvećeno upravo tome, kako na pravi način prikazati ljudski način razmišljanja, njegovu subjektivnost i nesigurnost, a da pri tome dobijemo što vjerodostojniji rezultat. Počevši od najjednostavnijih metoda koje uključuju osnovno zbrajanje i množenje, odabir kriterija i njihovih težina se zakomplicirao upotrebom metoda koje uzimaju u obzir ljudsku nesigurnost. Također, treba uzeti u obzir da čovjek koji donosi odluke treba ipak imati određenu ekspertizu u području u kojem radi procjene.

Stoga se postavlja pitanje, postoji li mogućnost da se analiza, koja se inače provodi višekriterijskom analizom, provede na način da se isključi mogućnost uplitanja čovjeka u donošenje odluka oko računanja i time spriječi nesigurnost i čestu potrebu za ekspertizom. Tu se otvara

moгуćnost iskorištenja metoda dubinskog ućenja. Metode dubinskog ućenja imaju moгуćnost pretoćiti ljudsku ekspertizu u model koji se može iskoristiti za više podrućja. Time bi se eliminirala potreba za stalnim provođenjem ekspertiza s jedne strane, dok bi se s druge strane eliminirala ljudska nesigurnost u donošenju odluka vezanih za pojedine kriterije. Shodno tome, bilo bi zanimljivo vidjeti moгуćnosti dubinskog ućenja u nadopunjavanju metoda višekriterijskih analiza.

ZAKLJUČAK

Neuronske mreže su najraširenija metoda strojnog učenja koja je pronašla svoju primjenu u raznim područjima. Iako se prvi put spominju 80-ih godina 20. stoljeća, rad na njihovom istraživanju eksponencijalno raste početkom 2000-ih s jačanjem hardvera i mogućnošću treniranja kompleksnih mreža unutar razumnog vremenskog okvira. Neuronske mreže svoj princip rada duguju pokušaju simulacije rada živčanog sustava na način da se međusobno povezuje velik broj jediničnih elemenata (neurona). Takve strukture imaju mogućnost samoorganizacije i učenja i imaju mogućnost obrade velikih količina podataka i time predviđanja podataka u budućnosti. Različite arhitekture i kompleksnost neuronskih mreža odgovaraju različitim problemima koji se nastoje riješiti. Tako je predstavljena *backprop* neuronska mreža koja ima mogućnost učenja tako da prethodni neuroni dobivaju informaciju koliko je njihova procjena bila točna i na osnovu toga prilagođavaju svoje vrijednosti da se približe onoj željenoj. Takva mreža je korisna u primjeni kod sustava u kojima postoji međuovisnost ulaznih podataka (npr. raspored riječi u rečenici, predviđanje slova u riječi, predviđanje riječi u rečenicama). Prilikom treniranja mreže, potrebno je obratiti pozornost na podatke koji se koriste za treniranje mreže; potrebno je da ih bude u dovoljnoj količini i da su dovoljno raspršeni da se mreža može što bolje generalizirati. Velik napredak u razvoju i primjeni neuronskih mreža imaju i pretrenirane mreže. Takve mreže su unaprijed istrenirane na velikoj količini podataka i samo je potrebna manja ulaznih podataka za robusnu i veliku mrežu. Time je dana mogućnost da se i malom količinom podataka i relativno slabim hardverskim mogućnostima mogu napraviti velike mreže koje će biti prikladne za korištenje. Također je predstavljena i konvolucijska mreža kao jedna od najvažnijih od svih neuronskih mreža, pogotovo u svojoj primjeni u prepoznavanju uzoraka. Važno je naglasiti i korištenje dubokog učenja u akustici gdje su neuronske mreže našle svoju primjenu u rješavanju problema s kojim se akustičari svaki dan susreću, od prepoznavanja lokacije izvora zvuka, do sprječavanja pozadinske buke, mikrofonije i istovremenog govora.

Geografski informacijski sustavi se koriste kod obrade i analize geoprostornih podataka. Na osnovu tih podataka i analiza, mogu se donijeti brojni zaključci vezani za određenu lokaciju i za njezine mogućnosti. Međutim, često se postavlja pitanje na koji način vrednovati pojedine značajke lokacije. Važna primjena GIS-a predstavlja višekriterijska GIS analiza koja nudi metode težinskog vaganja pojedinog kriterija i dobivanje ocjene za neku lokaciju obzirom na kriterije. Posebno pronalazi svoju primjenu kod velikih projekata sa značajnom površinom ras-

prostranjenosti i posljedično utjecajem na okoliš. U tim situacijama, višekriterijska GIS analiza omogućuje da se objektivno izmjere sve varijable koje utječu na odluku i da se donese konačna ocjena s transparentno prikazanim svim kompromisima donesenim u tom slučaju.

LITERATURA

- [1] Goodfellow, I.; Bengio, Y.; Courville, A., *Deep learning*, MIT press, 2016.
- [2] LeCun, Y.; Bengio, Y.; Hinton, G., “Deep learning”, *nature*, Vol. 521(7553), 436–444, 2015.
- [3] Bengio, Y.; Lecun, Y.; Hinton, G., “Deep learning for AI”, *Communications of the ACM*, Vol. 64(7), 58–65, srpanj 2021.
- [4] Rumelhart, D. E.; Hinton, G. E.; Williams, R. J., “Learning representations by back-propagating errors”, *nature*, Vol. 323(6088), 533–536, 1986.
- [5] Bengio, Y.; Ducharme, R.; Vincent, P., “A neural probabilistic language model”, *Advances in Neural Information Processing Systems*, pp. 932–938, 2001.
- [6] Abadi, M.; Barham, P.; Chen, J.; Chen, Z.; Davis, A.; Dean, J.; Devin, M.; Ghemawat, S.; Irving, G.; Isard, M. et al., “Tensorflow: A system for large-scale machine learning”, *12th {USENIX} symposium on operating systems design and implementation ({OSDI} 16)*, pp. 265–283, 2016.
- [7] Paszke, A.; Gross, S.; Chintala, S.; Chanan, G.; Yang, E.; DeVito, Z.; Lin, Z.; Desmaison, A.; Antiga, L.; Lerer, A., “Automatic differentiation in pytorch”, 2017.
- [8] Collobert, R.; Kavukcuoglu, K.; Farabet, C., “Torch7: A matlab-like environment for machine learning”, *BigLearn, NIPS workshop*, CONF, 2011.
- [9] Jia, Y.; Shelhamer, E.; Donahue, J.; Karayev, S.; Long, J.; Girshick, R.; Guadarrama, S.; Darrell, T., “Caffe: Convolutional architecture for fast feature embedding”, *Proceedings of the 22nd ACM international conference on Multimedia*, pp. 675–678, 2014.
- [10] Bergstra, J.; Breuleux, O.; Bastien, F.; Lamblin, P.; Pascanu, R.; Desjardins, G.; Turian, J.; Warde-Farley, D.; Bengio, Y., “Theano: a cpu and gpu math expression compiler”, *Proceedings of the Python for scientific computing conference (SciPy)*, 4, pp. 1–7, Austin, TX, 2010.
- [11] Sarle, W. S., “Neural networks and statistical models”, 1994.
- [12] Svozil, D.; Kvasnicka, V.; Pospichal, J., “Introduction to multi-layer feed-forward neural networks”, *Chemometrics and intelligent laboratory systems*, Vol. 39(1), 43–62, 1997.

- [13] Yegnanarayana, B., “Artificial neural networks prentice-hall of india”, *New Delhi*, 2006.
- [14] Raza, M. Q.; Khosravi, A., “A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings”, *Renewable and Sustainable Energy Reviews*, Vol. 50, 1352–1372, 2015.
- [15] Singer, D. A.; Kouda, R., “Application of a feedforward neural network in the search for kuroko deposits in the hokuroku district, japan”, *Mathematical Geology*, Vol. 28(8), 1017–1023, 1996.
- [16] Djarfour, N.; Aïfa, T.; Baddari, K.; Mihoubi, A.; Ferahtia, J., “Application of feedback connection artificial neural network to seismic data filtering”, Vol. 340(6), 335–344, *lipanj* 2008.
- [17] Utgoff, P. E.; Stracuzzi, D. J., “Many-layered learning”, *Neural computation*, Vol. 14(10), 2497–2529, 2002.
- [18] Glorot, X.; Bordes, A.; Bengio, Y., “Deep sparse rectifier neural networks”, *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, pp. 315–323, *JMLR Workshop and Conference Proceedings*, 2011.
- [19] Bengio, Y.; Lamblin, P.; Popovici, D.; Larochelle, H., “Greedy layer-wise training of deep networks”, *Advances in neural information processing systems*, pp. 153–160, 2007.
- [20] Hinton, G. E.; Osindero, S.; Teh, Y.-W., “A fast learning algorithm for deep belief nets”, *Neural computation*, Vol. 18(7), 1527–1554, 2006.
- [21] Da Silva, I. N.; Spatti, D. H.; Flauzino, R. A.; Liboni, L. H. B.; Reis Alves, S. F.dos , “Artificial neural network architectures and training processes”, *Artificial neural networks*, pp. 21–28, Springer, 2017.
- [22] Sutton, R. S.; Barto, A. G. et al., *Introduction to reinforcement learning*, 135, MIT press Cambridge, 1998.
- [23] Hinton, G. E.; Salakhutdinov, R. R., “Reducing the dimensionality of data with neural networks”, *science*, Vol. 313(5786), 504–507, 2006.
- [24] He, K.; Zhang, X.; Ren, S.; Sun, J., “Deep residual learning for image recognition”, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.

- [25] Bengio, Y.; Simard, P.; Frasconi, P., “Learning long-term dependencies with gradient descent is difficult”, *IEEE transactions on neural networks*, Vol. 5(2), 157–166, 1994.
- [26] Glorot, X.; Bengio, Y., “Understanding the difficulty of training deep feedforward neural networks”, *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pp. 249–256, JMLR Workshop and Conference Proceedings, 2010.
- [27] He, K.; Sun, J., “Convolutional neural networks at constrained time cost”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2015.
- [28] Baxt, W. G., “Use of an artificial neural network for the diagnosis of myocardial infarction”, *Annals of internal medicine*, Vol. 115(11), 843–848, 1991.
- [29] AbuSharekh, E. K.; Abu-Naser, S. S. et al., “Diagnosis of hepatitis virus using artificial neural network”, 2018.
- [30] Yotsawat, W.; Wattuya, P.; Srivihok, A., “A novel method for credit scoring based on cost-sensitive neural network ensemble”, *IEEE Access*, 2021.
- [31] Dangskul, W.; Phattaravatin, K.; Rattanaporn, K.; Kidjaidure, Y., “Real-time control using convolution neural network for self-driving cars”, *2021 7th International Conference on Engineering, Applied Sciences and Technology (ICEAST)*, pp. 125–128, IEEE, 2021.
- [32] Bishop, C. M., “Novelty detection and neural network validation”, *IEE Proceedings-Vision, Image and Signal processing*, Vol. 141(4), 217–222, 1994.
- [33] Peterson, G. E., “Foundation for neural network verification and validation”, *Science of Artificial Neural Networks II*, 1966, pp. 196–207, International Society for Optics and Photonics, 1993.
- [34] Robinson, A. J., “An application of recurrent nets to phone probability estimation”, *IEEE transactions on Neural Networks*, Vol. 5(2), 298–305, 1994.
- [35] Morgan, N.; Beck, J.; Allman, E.; Beer, J., “Rap: A ring array processor for multilayer perceptron applications”, *International Conference on Acoustics, Speech, and Signal Processing*, pp. 1005–1008, IEEE, 1990.
- [36] Robinson, A. J.; Fallside, F., “Static and dynamic error propagation networks with application to speech coding”, *Neural information processing systems*, pp. 632–641, Citeseer, 1988.

- [37] Mohamed, A.-r.; Dahl, G.; Hinton, G. et al., “Deep belief networks for phone recognition”, *Nips workshop on deep learning for speech recognition and related applications*, 1, p. 39, Vancouver, Canada, 2009.
- [38] Dahl, G. E.; Yu, D.; Deng, L.; Acero, A., “Context-dependent pre-trained deep neural networks for large-vocabulary speech recognition”, *IEEE Transactions on audio, speech, and language processing*, Vol. 20(1), 30–42, 2011.
- [39] Hinton, G.; Deng, L.; Yu, D.; Dahl, G. E.; Mohamed, A.-r.; Jaitly, N.; Senior, A.; Vanhoucke, V.; Nguyen, P.; Sainath, T. N. et al., “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups”, *IEEE Signal processing magazine*, Vol. 29(6), 82–97, 2012.
- [40] Krizhevsky, A.; Sutskever, I.; Hinton, G. E., “Imagenet classification with deep convolutional neural networks”, *Advances in neural information processing systems*, Vol. 25, 1097–1105, 2012.
- [41] LeCun, Y.; Huang, F. J.; Bottou, L., “Learning methods for generic object recognition with invariance to pose and lighting”, *Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004. CVPR 2004.*, 2, pp. II–104, IEEE, 2004.
- [42] Deng, J.; Dong, W.; Socher, R.; Li, L.-J.; Li, K.; Fei-Fei, L., “Imagenet: A large-scale hierarchical image database”, *2009 IEEE conference on computer vision and pattern recognition*, pp. 248–255, Ieee, 2009.
- [43] Albawi, S.; Mohammed, T. A.; Al-Zawi, S., “Understanding of a convolutional neural network”, *2017 International Conference on Engineering and Technology (ICET)*, pp. 1–6, Ieee, 2017.
- [44] LeCun, Y.; Bottou, L.; Bengio, Y.; Haffner, P., “Gradient-based learning applied to document recognition”, *Proceedings of the IEEE*, Vol. 86(11), 2278–2324, 1998.
- [45] Szegedy, C.; Liu, W.; Jia, Y.; Sermanet, P.; Reed, S.; Anguelov, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A., “Going deeper with convolutions”, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 1–9, 2015.
- [46] Abdel-Hamid, O.; Mohamed, A.-r.; Jiang, H.; Penn, G., “Applying convolutional neural networks concepts to hybrid nn-hmm model for speech recognition”, *2012 IEEE interna-*

- tional conference on Acoustics, speech and signal processing (ICASSP)*, pp. 4277–4280, IEEE, 2012.
- [47] Peng, M.; Wang, C.; Chen, T.; Liu, G., “Nirfacenet: A convolutional neural network for near-infrared face identification”, *Information*, Vol. 7(4), 61, 2016.
- [48] Chakrabarty, S.; Habets, E. A., “Multi-speaker localization using convolutional neural network trained with noise”, *arXiv preprint arXiv:1712.04276*, 2017.
- [49] Benesty, J.; Chen, J.; Huang, Y., *Microphone array signal processing*, 1, Springer Science & Business Media, 2008.
- [50] Brandstein, M. S.; Silverman, H. F., “A robust method for speech signal time-delay estimation in reverberant rooms”, *1997 IEEE International Conference on Acoustics, Speech, and Signal Processing*, 1, pp. 375–378, IEEE, 1997.
- [51] Chakrabarty, S.; Habets, E. A., “Broadband doa estimation using convolutional neural networks trained with noise signals”, *2017 IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA)*, pp. 136–140, IEEE, 2017.
- [52] Zhang, H.; Wang, D., “Deep learning for acoustic echo cancellation in noisy and double-talk scenarios”, *Training*, Vol. 161(2), 322, 2018.
- [53] Benesty, J.; Gänsler, T.; Morgan, D. R.; Sondhi, M. M.; Gay, S. L. et al., “Advances in network and acoustic echo cancellation”, 2001.
- [54] Hamidia, M.; Amrouche, A., “A new robust double-talk detector based on the stockwell transform for acoustic echo cancellation”, *Digital Signal Processing*, Vol. 60, 99–112, 2017.
- [55] Turbin, V.; Gilloire, A.; Scalart, P., “Comparison of three post-filtering algorithms for residual acoustic echo reduction”, *1997 IEEE International Conference on Acoustics, Speech, and Signal Processing*, 1, pp. 307–310, IEEE, 1997.
- [56] Hochreiter, S.; Schmidhuber, J., “Long short-term memory”, *Neural computation*, Vol. 9 (8), 1735–1780, 1997.
- [57] Erdogan, H.; Hershey, J. R.; Watanabe, S.; Le Roux, J., “Phase-sensitive and recognition-boosted speech separation using deep recurrent neural networks”, *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 708–712,

IEEE, 2015.

- [58] Lamel, L. F.; Kassel, R. H.; Seneff, S., “Speech database development: Design and analysis of the acoustic-phonetic corpus”, *Speech Input/Output Assessment and Speech Databases*, 1989.
- [59] Malik, S.; Enzner, G., “State-space frequency-domain adaptive filtering for nonlinear acoustic echo cancellation”, *IEEE Transactions on audio, speech, and language processing*, Vol. 20(7), 2065–2079, 2012.
- [60] Comminiello, D.; Scarpiniti, M.; Azpicueta-Ruiz, L. A.; Arenas-García, J.; Uncini, A., “Functional link adaptive filters for nonlinear acoustic echo cancellation”, *IEEE Transactions on Audio, Speech, and Language Processing*, Vol. 21(7), 1502–1512, 2013.
- [61] Brown, T. B.; Mann, B.; Ryder, N.; Subbiah, M.; Kaplan, J.; Dhariwal, P.; Neelakantan, A.; Shyam, P.; Sastry, G.; Askell, A. et al., “Language models are few-shot learners”, *arXiv preprint arXiv:2005.14165*, 2020.
- [62] Radford, A.; Wu, J.; Child, R.; Luan, D.; Amodei, D.; Sutskever, I. et al., “Language models are unsupervised multitask learners”, *OpenAI blog*, Vol. 1(8), 9, 2019.
- [63] Paperno, D.; Kruszewski, G.; Lazaridou, A.; Pham, Q. N.; Bernardi, R.; Pezzelle, S.; Baroni, M.; Boleda, G.; Fernández, R., “The lambda dataset: Word prediction requiring a broad discourse context”, *arXiv preprint arXiv:1606.06031*, 2016.
- [64] Roller, S.; Dinan, E.; Goyal, N.; Ju, D.; Williamson, M.; Liu, Y.; Xu, J.; Ott, M.; Shuster, K.; Smith, E. M. et al., “Recipes for building an open-domain chatbot”, *arXiv preprint arXiv:2004.13637*, 2020.
- [65] Adiwardana, D.; Luong, M.-T.; So, D. R.; Hall, J.; Fiedel, N.; Thoppilan, R.; Yang, Z.; Kulshreshtha, A.; Nemade, G.; Lu, Y. et al., “Towards a human-like open-domain chatbot”, *arXiv preprint arXiv:2001.09977*, 2020.
- [66] Chang, K.-T., “Geographic information system”, ožujak 2019.
- [67] Eastman, J. R., “Multi-criteria evaluation and gis”, *Geographical information systems*, Vol. 1(1), 493–502, 1999.
- [68] Thomas, P. G.; Doherty, P. C., “The analytic hierarchy”, *Process: Planning, Priority Setting, Resource Allocation*, McGraw-Hill, Citeseer, 1980.

- [69] Lee, A. H.; Chen, W.-C.; Chang, C.-J., “A fuzzy ahp and bsc approach for evaluating performance of it department in the manufacturing industry in taiwan”, *Expert systems with applications*, Vol. 34(1), 96–107, 2008.
- [70] Vahidnia, M.; Alesheikh, A.; Alimohammadi, A.; Bassiri, A., “Fuzzy analytical hierarchy process in gis application”, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 37(B2), 593–596, 2008.
- [71] Boroushaki, S.; Malczewski, J., “Implementing an extension of the analytical hierarchy process using ordered weighted averaging operators with fuzzy quantifiers in arcgis”, *Computers & geosciences*, Vol. 34(4), 399–410, 2008.
- [72] Rikalovic, A.; Cosic, I.; Lazarevic, D., “Gis based multi-criteria analysis for industrial site selection”, *Procedia engineering*, Vol. 69, 1054–1063, 2014.
- [73] Đerek, J.; Sikora, M., “Bicycle route planning using multiple criteria gis analysis”, *2019 International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, pp. 1–5, IEEE, 2019.
- [74] Ghamgosar, M.; Haghyghy, M.; Mehrdoust, F.; Arshad, N. et al., “Multicriteria decision making based on analytical hierarchy process (ahp) in gis for tourism”, *Middle-East Journal of Scientific Research*, Vol. 10(4), 501–507, 2011.
- [75] Ritchie, J.; Goeldner, C. R.; McIntosh, R. W., *Tourism: principles, practices, philosophies*, John Wiley & Son (New Jersey), 2003.
- [76] Deng, H., “Multicriteria analysis with fuzzy pairwise comparison”, *International journal of approximate reasoning*, Vol. 21(3), 215–231, 1999.
- [77] Mikhailov, L.; Tsvetinov, P., “Evaluation of services using a fuzzy analytic hierarchy process”, *Applied Soft Computing*, Vol. 5(1), 23–33, 2004.
- [78] Erensal, Y. C.; Öncan, T.; Demircan, M. L., “Determining key capabilities in technology management using fuzzy analytic hierarchy process: A case study of turkey”, *Information Sciences*, Vol. 176(18), 2755–2770, 2006.
- [79] Zadeh, L. A., “Fuzzy sets”, *Fuzzy sets, fuzzy logic, and fuzzy systems: selected papers by Lotfi A Zadeh*, pp. 394–432, World Scientific, 1996.
- [80] Hansen, H. S., “Gis-based multi-criteria analysis of wind farm development”, *ScanGIS*

2005: *Proceedings of the 10th Scandinavian Research Conference on Geographical Information Science*, pp. 75–87, Department of Planning and Environment, 2005.

- [81] Chang, D.-Y., “Applications of the extent analysis method on fuzzy ahp”, *European journal of operational research*, Vol. 95(3), 649–655, 1996.
- [82] Latinopoulos, D.; Kechagia, K., “A gis-based multi-criteria evaluation for wind farm site selection. a regional scale application in greece”, *Renewable Energy*, Vol. 78, 550–560, 2015.
- [83] Wang, L.-X., *A course in fuzzy systems and control*, Prentice-Hall, Inc., 1996.
- [84] Hsu, T.-P.; Lin, Y., “A model for planning a bicycle network with multi-criteria suitability evaluation using gis”, *WIT Transactions on Ecology and the Environment*, Vol. 148, 243–252, 2011.

POPIS OZNAKA I KRATICA

Kratice

Γ	Funkcija mapiranja
γ	Sigmoidalno pojačanje
λ_{max}	Najveća svojstvena vrijednost matrice
$\mu(x)$	Trokutasti neizraziti broj
ω_{ij}	Težinski koeficijent između i-tog i j-tog neurona
\tilde{A}	Trokutasta neizrazita matrica
ϑ_i	Koeficijent praga i-tog neurona
ξ	Potencijal neurona
A	Matrica usporedbe
a	Sigmoidalni nagib
C_k	Vrijednost k-tog piksela u mapi značajki
$d(n)$	Signal jeke
$f(\xi)$	Aktivacijska funkcija
R_{max}	Maksimalna vrijednost kriterija
R_{min}	Minimalna vrijednost kriterija
S	Mjera prikladnosti
$s(n)$	Signal na bližoj strani
$u(t)$	Trenutni ulaz
$v(n)$	Signal pozadinske buke
W	Težinska matrica izlaza
w_i	Težina i-tog kriterija
W_i^s	Ukupna težina područja i
x	Vektor vrijednosti piksela u lokalnom receptivnom polju
$x(t)$	Vektor trenutnog stanja
$x(t + 1)$	Vektor sljedećeg stanja
x_i	Vrijednost i-tog kriterija
x_{hard}	Signal jakog clippinga
x_{max}	Maksimalni signal clippinga

x_{NL}	Signal s dodanom nelinearnom distorzijom
x_i	Izlazna vrijednost i-tog neurona
$y(n)$	Signal mikrofona
$y(t)$	Izlazni vektor

Oznake

AEC	Poništavanje akustičke jeke
AHP	Analitički hijerarhijski proces
AI	Umjetna inteligencija
ANN	Umjetna neuronska mreža
BLSTM	Dvostruki LSTM
CD	Ovisno o kontekstu
CI	Indeks konzistentosti
DBN	Deep Belief Network
DOA	Smjer upada
DSP	Digital Signal Processing
DTD	Detektor dvostrukog govora
ERLE	Echo Return Lost Enhancement
FIR	Konačni impulsni odziv
GIS	Geografski informacijski sustavi
LSTM	Dugotrajna kratkoročna memorija
LVSR	Prepoznavanje govora širokog vokabulara
MPE	Minimalni odnos fonema
NLP	Neurolingvistička obrada
PESQ	Perceptualna evaluacija kvalitete govora
RAP	Ring Array Processor

SAŽETAK

Neuronske mreže su najraširenija i najkorištenija metoda dubinskog učenja. Njihov ubrzani razvoj započinje početkom tisućljeća kada se rapidno razvija računalni hardver što omogućuje lakše generiranje kompleksnijih mreža. Neuronske mreže su pronašle svoju upotrebu u raznim područjima, od kojih su neki jako osjetljivi na pogreške, npr. medicina, samostalno upravljanje strojevima, vozilima i sl. Kod takvih mreža koji se primjenjuju u osjetljivim područjima je potrebno poseban naglasak staviti na validaciju mreže i na nadgledanje rada. Neuronske mreže svoj način rada preslikavaju od načina rada neuralnih sustava u kojima su neuroni međusobno povezani čime je omogućena obrada velike količine podataka i generalizacija tih podataka. Ovisno o vrsti primjene i ulaznih podataka se koriste različite arhitekture mreže.

Geografski informacijski sustavi (GIS) imaju mogućnost obrade i analize geoprostornih podataka. Donošenje odluka vezanih za okolinu na temelju više kriterija je jedna od glavnih primjena GIS-a. Tu se korisne metode višekriterijske GIS analize koje omogućuju da se velika količina kriterija koja utječe na odluku vrednuje, da im se da prikladna težina u odluci, i da se za mikrolokaciju donese ocjena o prikladnosti za određenu svrhu.

Ključne riječi: dubinsko učenje, neuronske mreže, višekriterijska GIS analiza