

Umjetna inteligencija u zaštiti okoliša

Leaković, Emerik

Undergraduate thesis / Završni rad

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Chemical Engineering and Technology / Sveučilište u Zagrebu, Fakultet kemijskog inženjerstva i tehnologije**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:149:234445>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-07-17**



Repository / Repozitorij:

[Repository of Faculty of Chemical Engineering and Technology University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET KEMIJSKOG INŽENJERSTVA I TEHNOLOGIJE
SVEUČILIŠNI PREDDIPLOMSKI STUDIJ

Emerik Leaković

UMJETNA INTELIGENCIJA U ZAŠTITI OKOLIŠA

ZAVRŠNI RAD

Voditelj rada: doc. dr. sc. Šime Ukić

Članovi ispitnog povjerenstva:

doc. dr. sc. Šime Ukić

red. prof. dr. sc. Tomislav Bolanča

dr. sc. Lidija Furač, viša predavačica

Zagreb, rujan 2015.

Prije svega zahvaljujem se svom mentoru dr. sc. Šimi Ukiću na strpljenju, savjetima i pomoći pri izradi ovog rada.

Veliko hvala mojoj cijeloj obitelji, a posebno roditeljima koji su mi omogućili studij, bili podrška i dali dovoljno slobode u donošenju životnih odluka i postupaka.

Od srca hvala i svim prijateljima koji su mi bili suputnici u radosnim, ali i podrška u kriznim trenucima.

Sadržaj

SAŽETAK.....	1
ABSTRACT	2
1. UVOD	3
1.1. Inteligencija	4
2. UMJETNA INTELIGENCIJA.....	5
2.1. Svrha.....	5
2.2. Razvoj.....	5
2.3. Grane AI	6
2.4. Ekspertni sustavi.....	6
2.4.1. Građa ekspertnih sustava	7
2.4.1.1. Baza znanja	8
2.4.1.2. Mehanizmi zaključivanja	10
2.5. Evolucijski algoritmi	11
2.6. Računalni vid.....	14
2.7. Umjetne neuronske mreže	14
2.7.1. Biološka osnova umjetnih neuronskih mreža	15
2.7.2. Osnovni principi umjetnih neuronskih mreža.....	16
2.7.2.1. Vrste umjetnih neuronskih mreža	18
2.7.3. Perceptron i adaline.....	18
2.7.3.1. Učenje umjetnih neuronskih mreža.....	20
2.7.3.2. XOR problem	22
2.7.4. Višeslojne unaprijedne neuronske mreže.....	23
2.7.4.1. Back-propagation	24
2.7.5. Treniranje i pretreniranje	25
2.7.6. RBF mreže	25

2.7.7. Povratne mreže.....	26
2.7.7.1. Jordanova mreža.....	26
2.7.7.2. Elmanova mreža.....	27
2.7.7.3. Hopfieldova mreža.....	28
2.7.8. Samoorganizirajuće mreže.....	28
2.8. Neizrazita logika.....	29
2.8.1. Neizraziti skupovi i funkcije pripadnosti.....	29
2.8.2. Neizrazita pravila.....	31
2.8.3. FIS i ANFIS.....	32
3. PRIMJENA UMJETNE INTELIGENCIJE U ZAŠTITI OKOLIŠA.....	34
3.1. Primjena umjetne inteligencije u zaštiti voda i vodenih ekosustava.....	40
3.1.1. Uređaji za pročišćavanje otpadnih voda.....	40
3.1.2. Praćenje kvalitete voda.....	41
3.1.3. Kontrola onečišćenja voda procjeđivanjem i ispiranjem.....	42
3.1.4. Ostali načini zaštite voda i vodenih ekosustava.....	44
3.1.5. Onečišćenje toksičnim metalima.....	45
3.2. Predviđanje koncentracija zagađivača zraka.....	47
3.2.1. Ozon.....	47
3.2.2. Lebdeće čestice (PM ₁₀ i PM _{2,5}).....	48
3.2.3. CO ₂	49
4. ZAKLJUČAK.....	50
5. LITERATURA.....	51
ŽIVOTOPIS.....	58

SAŽETAK

Cilj ovoga rada je prikazati opću sliku umjetne inteligencije i objasniti osnovne principe funkcioniranja njenih razvijenijih grana, poput umjetnih neuronskih mreža, evolucijskih algoritama, ekspertnih sustava, računalnog vida i neizrazite logike. Jednostavnim primjerima dan je uvid u funkcioniranje iznimno širokog područja umjetne inteligencije, te je obrazložena potreba za daljnjim istraživanjem i inovacijama na dobrobit cjelokupnog društva.

Zaštita okoliša postaje sve značajni aspekt ljudske aktivnosti jer zadnjih nekoliko godina raste svijest o važnosti okoliša koji je izvor dobara, mjesto stanovanja i glavni preduvjet za očuvanje života. Umjetna inteligencija premda još uvijek mlado područje, djeluje na širok spektar različitih problema, pa tako svoju primjenu nalazi i u zaštiti okoliša. U ovom radu dan je i literaturni pregled svih aspekata djelovanja umjetne inteligencije u zaštiti okoliša i ekosustava, procjenama onečišćenja, kontroli kvalitete zraka i voda, gospodarenju prirodnim resursima, donošenju odluka koje mogu utjecati na okoliš i dr.

ABSTRACT

Main purpose of this paper is to present a general image of artificial intelligence as well as the basic principles of functioning of its most developed branches, such as artificial neural networks, evolutionary algorithms, expert systems, computer vision and fuzzy logic. An insight in functioning of very broad area of artificial intelligence was given through simple examples. The need for further research and innovations, as a benefit for entire society, was explained also.

Environment protection is becoming more and more significant aspect of human activity due increase awareness of its importance on human life. Environment is source of goods, place to live and main precondition for life preservation. Although artificial intelligence is relatively young area of human activity, it already has a broad variety of applications, including environment protection. This paper also brings a literature review of different aspects of artificial intelligence activity such as environment and ecosystem protection, assessment of pollution, air and water quality control, natural resource management, decision making etc.

1. UVOD

Porast populacije ljudi te sve veća urbanizacija i industrijalizacija koje su se intenzivno počele odvijati prošloga stoljeća, a danas se još uvijek odvijaju, prisilile su društvo na razmatranje utječe li ljudsko djelovanje na promjene uvjeta u okolišu koji su esencijalni za život na Zemlji. Kao posljedica ljudske zabrinutosti zbog sve većeg nepovoljnog utjecaja na okoliš, razvila se tzv. znanost o okolišu, interdisciplinarno područje koje u obzir uzima i ljudsku aktivnost kao sastavnicu cjelokupnih procesa u okolišu. Ljudi okoliš koriste kao izvor sirovina, iskorištavaju prirodne resurse, nastanjuju se u njemu i grade razne objekte, te okoliš koriste kao odlagalište. A okoliš osigurava izvor hrane, vode i energije. Kako je nakon industrijske revolucije razvoj čovječanstva uhvatio zamah i kako je došlo do razvoja svijesti o vrijednosti i bogatstvu koje se nalazi u okolišu (u obliku navedenih izvora), s druge je strane stvoren mentalitet koji ne shvaća neiscrpnost nabrojanih izvora, koji okoliš uzima zdravo za gotovo i koji se realizira kroz nekontroliranu uporabu umjetnih gnojiva i pesticida, nelegalno odlaganje otpada, nekontroliranu eksploataciju šumskog bogatstva, prosipanje nafte u more, prekomjernu emisiju spojeva koji utječu na klimatske promjene i ugrožavaju ljudsko zdravlje, i još mnogo toga. Nikada se neće moći potpuno eliminirati svi faktori koji ne-povoljno utječu na okoliš, ali se svakako mogu poduzeti značajne mjere zaštite kako bi se smanjilo ili u najmanju ruku usporilo onečišćenje, te identificiralo i prognoziralo potencijalne štetne učinke s ciljem preventivnog djelovanja, jer je okoliš upravo ono što omogućava život.

Kao sve veća asistencija zaštiti okoliša, u novije vrijeme nameće se područje umjetne inteligencije. Znanost o okolišu i umjetna inteligencija su obje od velikog strateškog interesa za društvo jer pružaju održiva rješenja i mogu se široko primijeniti u cilju zaštite okoliša.

Umjetna inteligencija trenutno obuhvaća veliku raznolikost potpolja, od područja s općom svrhom poput percepcije i logičkog zaključivanja, do specifičnih zadataka poput igranja šaha, dokazivanja matematičkih teorema, dijagnoze bolesti, stvaranja matematičkih modela koji opisuju razne procese, prognožiranja nekih budućih događaja i drugo.¹

Umjetna inteligencija u zaštiti okoliša može znatno pojednostaviti već ustaljene postupke zaštite, olakšati gospodarenje prirodnim resursima, predvidjeti koncentracije raznih zagađivala, pratiti kvalitetu zraka i vode te u konačnici smanjiti financijske izdatke.

1.1. Inteligencija

Inteligencija je većini ljudi dosta teško shvatljiv pojam, iako se koristi u svakodnevnoj uporabi. Neki smatraju da inteligentna osoba zna puno, dok drugi misle da ta osoba misli brzo. Inteligencija je zapravo sposobnost rješavanja problema i snalaženje u novim situacijama. Važni aspekti ljudske inteligencije su: korištenje intuicije, zdravi razum, rasuđivanje, kreativnost, usmjerenost cilju, znanje, uvjerenja i razumijevanje uzročno-posljedičnih veza. Koliko god ljudska inteligencija bila snažna i duboka, ona ima svoja ograničenja. Ljudi su intelektualno pogrešivi, imaju ograničenu bazu znanja (nisu svi ljudi pročitali sve knjige i prošli kroz sva iskustva), a osim toga, procesuiranje podataka u mozgu je jako sporo uspoređujući s današnjim računalima. Ljudska inteligencija se manifestira na dva načina: komunikacijom (verbalnom ekspresijom, kroz tekst, slikama...) i učenjem, tj. skupljanjem znanja kroz iskustvo.

Učinkovita komunikacija zahtjeva vještine analize poruke (primalac poruke tj. ulaz informacije) i sinteze poruke (pošiljaoc poruke tj. izlaz informacije). Onaj koji sastavlja poruku, bilo da je to pismo, pjesma, glazbena kompozicija, slika ili neki drugi oblik komunikacije, mora biti sposoban sastaviti ju na način da ona nešto znači onome koji ju prima. S druge pak strane, i razumijevanje poruke također zahtijeva inteligenciju. Primalac poruke mora znati značenje većine znakova koje koristi pošiljaoc te imati neko znanje o kontekstu poruke. Primalac može postavljati ciljana pitanja kako bi skupio dijelove informacija koje nedostaju za razumijevanje kompletne poruke.

Sposobnost učenja ili prilagođavanja novim situacijama, smatra se vitalnom komponentom inteligencije. One životinje koje se brže prilagođavaju promjenama u svojoj okolini smatraju se inteligentnijima od onih koje to rade sporije ili se pak nisu uopće uspjele prilagoditi. Način učenja koji koriste ljudi čini se puno sofisticiraniji od onoga kod životinja, ali je vrlo vjerojatno da su osnove učenja zajedničke. Organiziranje znanja je jako važna komponenta procesa učenja. Kako su dijelovi informacija povezani i raspoređeni u memoriji čovjeka ili stroja, jako je važno. Činjenice moraju biti dostupne kada je to potrebno, a vještine moraju odigrati ulogu kada dođe do prigodne situacije. Dio znanja je okvir u kojem mogu biti pohranjene razne činjenice i aspekti iskustva. Taj okvir mora omogućiti poveznicama da povežu nove i stare okvire.²

2. UMJETNA INTELIGENCIJA

Umjetna inteligencija (eng. artificial intelligence, AI) je znanstveno polje koje obuhvaća računalne tehnike za izvršavanje zadataka za koje je potrebna inteligencija kada ih rješavaju ljudi. Takvi zadaci mogu biti: dijagnosticiranje bolesti, pisanje priča ili skladanje glazbenih djela, pronalaženje matematičkih teorema, sastavljanje i analiza proizvoda u tvornicama, pregovaranje i sklapanje međunarodnih ugovora te još puno toga.²

2.1. Svrha

Čovječanstvo si je dalo ime *homo sapiens*, što znači „mudri čovjek“ zbog toga što su nam naši mentalni kapaciteti jako bitni u svakodnevnom životu i samoshvaćanju. Polje umjetne inteligencije pokušava razumjeti inteligentna bića (subjekte). Prema tome, jedan od glavnih razloga proučavanja umjetne inteligencije jeste učenje o sebi samima s ciljem boljeg razumijevanja procesa mišljenja, učenja i percepcije. Za razliku od filozofije i psihologije, koje također proučavaju inteligenciju, AI osim razumijevanja pokušava i izgraditi inteligentne subjekte. Razvoj tih novih subjekata tj. alata je važan jer oni mogu imati komercijalnu vrijednost, mogu poboljšati kvalitetu života te povećati učinkovitost raznih kompanija i organizacija.^{1,2}

2.2. Razvoj

Proučavanje inteligencije jedno je od najstarijih disciplina. Već prije 2000 godina, filozofi su pokušali razumjeti kako se odvijaju procesi poput gledanja, učenja, pamćenja i mišljenja.

Umjetna inteligencija jedna je od novijih disciplina u znanosti koja je u jako kratkom roku postala iznimno popularna. Pa ipak, počeci nisu bili pretjerano ohrabrujući. Tijekom ranih i srednjih šezdesetih godina dvadesetoga stoljeća, pretjerano ambiciozni projekt automatskog prevođenja s engleskog jezika na ruski jezik je ne samo propao, nego i umanjio poštovanje i entuzijazam prema umjetnoj inteligenciji kao području istraživanja.²

Danas se može reći da se AI, na krilima mogućnosti što ih donosi razvoj informatike, ne samo oporavila, već su moderne ideje primjene puno kompleksnije i, što je najvažnije, postižu se izimno zanimljivi rezultati. Sve češće znanstvenici iz drugih područja istraživanja postepeno ulaze u područje umjetne inteligencije, gdje pronalaze alate za sistematizaciju i automatizaciju intelektualnih zadataka na kojima su radili tokom svog dosadašnjeg radnog vijeka. Slično tome, ljudi koji se bave umjetnom inteligencijom mogu primijeniti svoje znanje

na bilo koje područje ljudskog djelovanja, poput dokazivanja matematičkih teorema, igranja šaha, zaštite okoliša, dijagnosticiranja bolesti i dr.¹

2.3. Grane AI

Sav razvoj koji se dogodio u području umjetne inteligencije se može klasificirati u nekoliko specifičnih grana:

- *Ekspertni sustavi*: Računalni programi dizajnirani za rješavanje problema poput stručnjaka (eksperta) u pojedinom području.³
- *Umjetne neuronske mreže*: Računalne mreže koje pokušavaju simulirati mrežu živčanih stanica ljudskog centralnog živčanog sustava.⁴
- *Neizrazita logika*: Osigurava približno ali učinkovito značenje opisivanih ponašanja sustava koji su jako složeni, loše definirani, ili teški za matematičku analizu.⁵
- *Evolucijski algoritmi*: Oponašaju biološku evoluciju u postupku optimizacije složenih problema.⁶
- *Računalni vid*: Matematičke tehnike za pojavu trodimenzionalnog oblika u slikama. Pokušaj opisivanja svijeta kojeg vidimo u jednoj ili više slika rekonstruiranjem svojstava poput oblika, osvjetljenja i raspršenja boja.⁷
- *Robotika*: Bavi se kontrolom robota koji upravljaju objektima, a koristeći informacije od senzora.³
- *Hibridni sustavi*: Kombinacije navedenih sustava.⁶

2.4. Ekspertni sustavi

Kao što je prethodno rečeno, ekspertni sustavi (eng. *expert systems*, ES) su programi dizajnirani da simuliraju proces rješavanja specifičnih problema na način kako to radi iskusni stručnjak. Naime, oni koriste određeno znanje i specifične kontrolne strategije kako bi došli do rješenja postavljenog problema. Iako su ES programi, ne nazivaju se programima jer obuhvaćaju više različitih komponenti koje su pri simulaciji u međudjelovanju.³

Mnogi današnji znanstvenici upućeni u AI raspravljaju o tome pripadaju li uopće ES u područje umjetne inteligencije. Jasno je da su neki primjeri ekspertnih sustava praktični primjeri umjetno inteligentnih sustava, dok drugi pak to izričito nisu. Jednako tome, između

tih dviju krajnosti postoji cijeli niz primjera ekspertnih sustava oko kojih se može beskonačno sporiti jesu li AI ili ne. Kao primjer ekspertnih sustava koje ne bismo smatrali umjetnom inteligencijom naveo bih baze znanja; one koje sadrže sve bitne informacije i unaprijednim mehanizmom zaključivanja donose odluke koje su strogo točne ili strogo netočne, što možda ne predstavlja najučinkovitiju strategiju. ES koje se smatra umjetnom inteligencijom koriste nekompletne baze znanja i trebaju mehanizme zaključivanja koji rade s određenom nesigurnošću kako bi operirali tim bazama znanja, a rezultati nisu uvijek jednostavno klasificirani kao točni ili kao netočni. Takav pogled na ekspertne sustave uključuje heuristiku⁸. U filozofiji znanosti pod heurističkim se postupkom razumije dolaženje do znanstvenog rješenja ili otkrića putem pokušaja i pogrešaka, nagađanjima i opovrgavanjima. U modernoj logici opisuje proces koji može riješiti određenu vrstu problema, ali ne jamči uspješno rješenje.⁹ Poblize proučavajući bilo koji proces odlučivanja od strane stručnjaka otkriva da on koristi činjenice i heuristiku kako bi došao do odluke. Heuristika po svojoj prirodi ne daje uvijek dobre rezultate, odnosno može dovesti i do pogreške. Čak i najbriljantniji stručnjaci su samo ljudi te prema tome mogu pogriješiti. No, bez obzira na to, čak iako je čovjek svjestan da su stručnjakove procjene i odluke krive, on vjeruje stručnjaku. Ta činjenica sugestira da ekspertnom sustavu napravljenom kako bi radio na razini stručnjaka mora biti dozvoljeno činiti pogreške.⁸ Stručnjaci svoje znanje izražavaju pomoću pravila. Pojam „pravilo“ u AI, koje se koristi za izražavanje znanja, najčešće podrazumijeva AKO – ONDA strukturu.¹⁰ Takva pravila osiguravaju način rješavanja problema, vrlo su jednostavna, lako ih je razumjeti i kreirati, te se lako ugrađuju u računalo.¹⁰

2.4.1. Građa ekspertnih sustava

ES obuhvaćaju nekoliko komponenti od kojih su najvažnije *baza znanja* i *kontrolni mehanizam*.


Baza znanja je skup svih potrebnih informacija za rješavanje problema. Proces skupljanja i organizacije znanja, kao i ugradnja tog sustava u obliku baze znanja u sustav, težak je zadatak. Bazu znanja potrebno je kontinuirano ažurirati jer količina znanja u bilo kojem području svakodnevno raste. Prema tome, mora postojati *jedinica za primanje znanja* koja će se nalaziti između stručnjaka tj. inženjera koji unosi znanje i baze znanja.

Kontrolni mehanizam je komponenta ekspertnog sustava koja se može sastojati od nekoliko vrsti mehanizama zaključivanja, a provjerava dostupne činjenice, odabire prigodne izvore znanja iz baze znanja, spaja činjenice sa znanjem i skuplja dodatne činjenice.

Kad ekspertni sustav započne proces zaključivanja, potrebna je pohrana ustanovljenih činjenica za daljnju upotrebu. Komponenta u kojoj se pohranjuju te nove činjenice, odnosno trenutni stupanj riješenosti problema naziva se *radnom memorijom*.

Kad god stručnjak ponudi rješenje ili donese odluku, program želi znati kako je stručnjak došao do te odluke. Također, kada stručnjak koristi određeno znanje, računalo želi znati zašto je baš ta činjenica potrebna u rješavanju problema. Za to postoji posebna jedinica koja odgovara na pitanja *kako* i *zašto*, a naziva se *jedinicom za objašnjenja*.

Korisnik ekspertnog sustava vrši interakciju s ekspertnim sustavom, bilo unošenjem podataka tj. definiranjem nekakvih parametara, bilo monitoringom nad procesom rješavanja problema. Prijenos informacija između korisnika i ekspertnog sustava tekstualno ili grafički mora se moći izvršiti na učinkovit način. Stoga je kao sastavni dio ekspertnog sustava postavljeno *korisničko sučelje* koje ima sposobnost operiranja tekstualnim i grafičkim podacima.³



Slika 1. Shematski prikaz ekspertnog sustava

2.4.1.1. Baza znanja

Kao što je već u spomenuto, baza znanja sadrži specifično znanje potrebno za rješavanje problema. Bazu kreira inženjer organizirajući znanje u takav oblik da ono bude upotrebljivo u ekspertnom sustavu. Znanje prikuplja iz razgovora sa stručnjakom. Inženjer

koji razvija bazu znanja mora biti dobro upućen u tehnologiju ekspertnih sustava. On ne mora biti stručnjak u području za koji gradi taj sustav, ali neko općenito znanje i upoznatost s ključnim pojmovima je ipak potrebno kako bi se olakšala komunikacija između inženjera (programera) i stručnjaka. Poželjno je npr. da inženjer ima neko općenito znanje o medicini kako bi lakše, u suradnji s liječnikom, napravio ekspertni sustav za dijagnozu bolesti.

Znanje u inženjerstvu koje se koristi za rješavanje problema može se podijeliti u tri skupine: sastavljeno znanje (znanje proizašlo iz iskustva stručnjaka, sakupljeno iz starih udžbenika i zapisa...), kvalitativno znanje (znanje koje se sastoji od pravila, približnih teorija, zdravog razuma...), kvantitativno znanje (bavi se tehnikama temeljenim na matematičkim teoremima).

Također može se podijeliti i na dva dijela. Prvi dio opisuje scenarije tj. bavi se fizikalnim svojstvima problema (deklarativno znanje, ono koje tumači), dok drugi dio opisuje kako koristiti znanje, tj. koristi najpogodniju tehniku za rješavanje problema i dolazak do odluke, odnosno zaključka.

Razvoj ekspertnog sustava uključuje prikupljanje znanja od priznatog stručnjaka na određenom području, dokumentaciju i organizaciju tog znanja, stvaranje mreža znanja, provjeravanje dostupnosti znanja, i u konačnici, preoblikovanje mreže znanja u računalni program korištenjem prigodnih alata. Takav program je formalni sustav za pohranu podataka (činjenica), veza između podataka, i strategija za njihovo korištenje. Općenito, ekspertni sustav ima znanje o fizikalnim stvarima, o vezama između njih, o događajima i vezama između događaja te posjeduje znanje o vezama između stvari i događaja.

Prikaz znanja može se odviti na nekoliko načina. Inženjer treba odlučiti koji dio znanja treba biti prikazan u kojem obliku, ovisno o prirodi znanja i učinkovitosti uporabe tog znanja. Najčešće metode za prikaz znanja su predikatna logika (eng. *predicate logic*), proizvodna pravila (eng. *production rules*), okvirne (objektne) i semantičke mreže (eng. *frames (objects) and semantic networks*) i konvencionalni (uobičajeni) programi (eng. *conventional programs*).³

Proizvodna pravila su jednostavan, ali moćan, oblik prikaza znanja. Već je spomenuta struktura „AKO – ONDA“ koja predstavlja proizvodna pravila, jednostavna je za razumjeti i lako se kreira. Bilo koje produkcijsko pravilo sastoji se od "AKO" dijela koji se naziva *prednjim članom (premisom ili uvjetom)* i "ONDA" dijela koji se naziva *proizlaznim članom (zaključakom ili djelovanjem)*. Pravilo može imati više prednjih članova koji se povezuju ključnim riječima „I“ (konjunkcija) i „ILI“ (disjunkcija), te kombinacijom tih dviju riječi. Prednji član pravila sastoji se od dva dijela: objekta (lingvistička značajka) i njegove


vrijednosti. Objekt i njegova vrijednost su povezani operatorom; operator identificira objekt i pripisuje mu vrijednost. Operatori poput „je“, „jesu“, „nije“, „nisu“ koriste se za pripisivanje simboličke vrijednosti lingvističkom objektu, ali ES mogu koristiti i matematičke operatore kako bi im pripisali neku brojčanu vrijednost.

Znanje pohranjeno u pravilima može se shematski prikazati u obliku mreže. Baza znanja se sastoji od velikog broja pravila, a pravila mogu biti logički raspoređena u različite baze.³

2.4.1.2. Mehanizmi zaključivanja

Mehanizmi zaključivanja su strategije kontrole pretražnih tehnika koje pretražuju baze podataka kako bi se došlo do odluka. Kako ES pretežno procesiraju simbole (simboli se koriste za prikaz različitih vrsta znanja poput činjenica, koncepata ili pravila¹⁰), proces zaključivanja barata simbolima povezujući simbole činjenica s pravilima i tako stvarajući nove činjenice. Taj proces se lančano nastavlja dok se ne dostigne postavljeni cilj. U ES zaključivanje se može provesti na mnogo načina. Dva popularna načina su unazadno ulančavanje (eng. *backward chaining*) i unaprijedno ulančavanje (eng. *forward chaining*).³ Spajanje "AKO" dijelova pravila s činjenicama tvori lanac zaključivanja koji pokazuje kako ES primjenjuje pravila kako bi došao do zaključka.¹⁰ Unazadno ulančavanje je ciljem vođen proces; ES ima cilj (hipotetsko rješenje), a mehanizmi zaključivanja pokušavaju naći dokaze da potvrde to rješenje. S druge strane, unaprijedno ulančavanje je podacima upravljani proces; korisnik sustava mora dati sve dostupne podatke prije početka zaključivanja jer mehanizmi zaključivanja pokušavaju ustanoviti činjenice potrebne za postizanje rješenja.³

- Pravilo 1.* AKO Y je istinit
I D je istinit
ONDA Z je istinit
- Pravilo 2.* AKO X je istinit
I B je istinit
I E je istinit
ONDA Y je istinit
- Pravilo 3.* AKO A je istinit
ONDA X je istinit



Slika 2. Shematski prikaz lančanog zaključivanja u ES

2.5. Evolucijski algoritmi

Evolucijski algoritmi (eng. *evolutionary algorithms*, EA) su postupci optimizacije, učenja i modeliranja koji se temelje na mehanizmu prirodne evolucije. Do nastanka evolucijski algoritama dolazi zbog želje za boljim razumijevanjem prirodne evolucije i pokušaja primjene načela prirodne evolucije pri rješavanju određenih zadataka. Začetak prvih zamisli o primjeni evolucijskih načela pri rješavanju tehničkih zadataka javlja se 50-ih godina dvadesetoga stoljeća.¹¹ Područje evolucijskih algoritama ima puno „osnivača“, a razloga tome je više. U spomenuto vrijeme razvijene tehnike nisu bile primjenjive pa se stoga o njima nije čulo, niti su bile zapamćene te su mnogi znanstvenici s razvojem EA metodologije kretali od nule. Drugi razlog leži u interdisciplinarnom karakteru evolucijskih algoritama. EA je područje primjene biološke teorije u računalnim znanostima kako bi se rješavali problemi u desecima drugih područja, što znači da su različite grupe ljudi imale iste ideje o korištenju EA neovisno jedni o drugima, bez da su imali saznanja o postignućima drugih. Treći izvor višestrukih korijena EA je nastao zbog problema u nazivlju. Većina terminologije je posuđena iz biologije, ali je dosta proizvoljna i ne slaže se načelno sa značenjima u biologiji.¹³ 60-ih godina su razvijena tri postupka zasnovana na načelima biološke evolucije: evolucijsko programiranje, evolucijske strategije i genetički algoritmi. Od tada se evolucijski algoritmi konstantno razvijaju i primjenjuju u raznim područjima ljudskog djelovanja.¹²

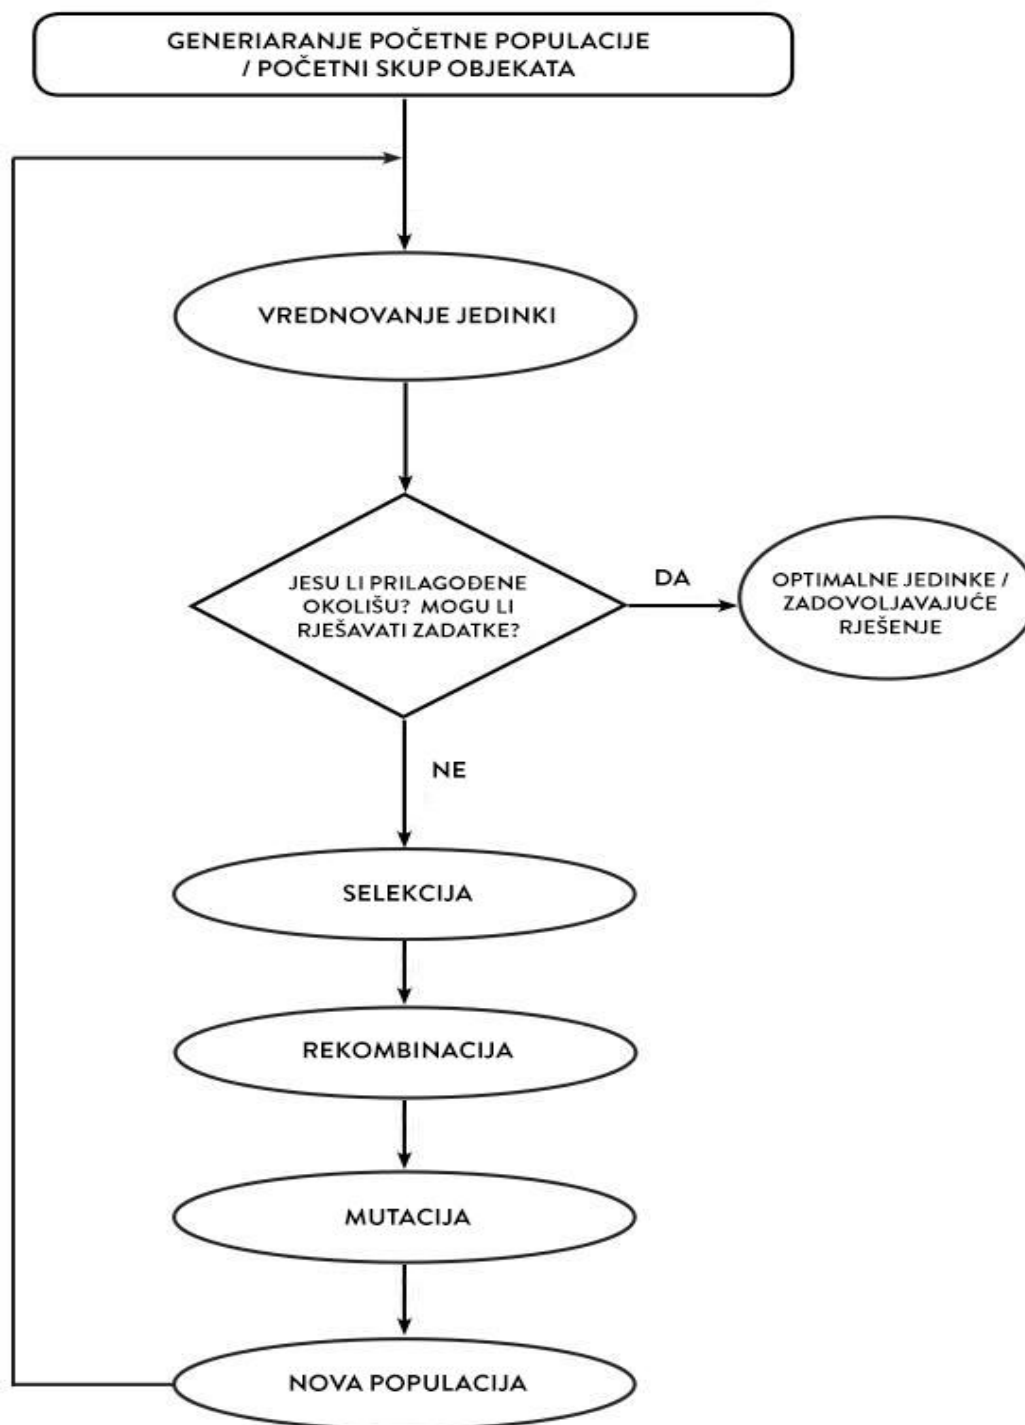
Biološki gledano, evolucija se odvija promjenama u genetskom bazenu populacije tijekom vremena. Genetski bazen je skup svih gena u nekoj vrsti ili populaciji, a gen je nasljedna jedinica koja se može prenositi iz generacije u generaciju.¹⁴ Geni su pak organizirani u kromosome (linearan niz dušičnih baza duž polinukleotidnog lanca, molekulu DNA) koji predstavljaju apstraktan prikaz rješenja u evolucijskom algoritmu.⁶ Teorija biološke evolucije temelji se na nekoliko opće prihvaćenih pretpostavki¹²:

- i. Postoji populacija koja može stvarati potomke.** Populacija je skup živih organizama koji borave na ograničenom području u određenom trenutku. Za mehanizam evolucije nužno je postojanje naraštaja više jedinki koje se mogu razmnožavati. Kod evolucijskih algoritama populacija je skup neovisnih matematičkih objekata (npr. skup realnih brojeva, skup decimalnih brojeva, skup vektora itd.)
- ii. Populacija se razmnožava (stvara potomke).** U biologiji novi naraštaj nastaje iz postojećeg postupkom razmnožavanja (rekombinacije, križanja). Pri tome novi naraštaj nasljeđuje značajke svojih prethodnika. Kod evolucijskih algoritama

rekombinacija predstavlja stvaranje novih matematičkih objekata na temelju postojećih uporabom matematičkih operatora.

- iii. **Događaju se slučajne promjene značajki jedinke koje uzrokuju varijacije (dolazi do mutacija).** Nasljedne značajke (geni) mogu se mijenjati samo mutacijom tj. slučajnom promjenom koja nastaje uslijed nekog vanjskog utjecaja i koja se dalje nasljeđuje. Zbog toga se može dogoditi da neki od potomaka imaju značajke koje nema niti jedan od njegovih prethodnika. Kod evolucijskih algoritama, mutacija je slučajna promjena matematičkog objekta koja nastaje stohastičkom primjenom odgovarajućeg matematičkog operatora na jedinku.
- iv. **Preživljavaju najспособniji (prirodna selekcija).** Ovisno o prilagodbi okolišu neke jedinke naraštaja će stvoriti više potomaka od drugih, a ako se to ponavlja tijekom više generacija, povećat će se zastupljenost genotipova jedinki koje stvaraju više potomaka. Prirodna selekcija je jedini mehanizam evolucije koji vodi k boljoj prilagodbi naraštaja okolišu. Kod evolucijskih algoritama selekcija je proces odbacivanja nekih matematičkih objekata određenog skupa (populacije).
- v. **Postupak nastanka novog naraštaja se ponavlja odnosno, postupak promjene je iterativan.** U biologiji se promjene neprestano događaju. Kako se mijenjaju uvjeti u okolišu, tako se jedinke navedenim mehanizmom iz generacije u generaciju nastoje prilagoditi tim promjenama. Kod evolucijskog algoritma postupak rekombinacije, mutacije i selekcije se ponavlja sve dok se ne postigne zadovoljavajuće rješenje postavljenog zadatka.

Najrašireniji oblik evolucijskih algoritama jest genetički algoritam kojeg se u smislu prethodno opisanog evolucijskog algoritma shematski može prikazati na sljedeći način:



Slika 3. Shematski prikaz genetičkog algoritma

EA spadaju u šire područje znanosti o spoznaji (kognitivna znanost), a u uže područje inteligentnih algoritama. Glavne značajke inteligentnih algoritama su: prilagodljivost okolišu, mogućnost oponašanja postupaka iz prirode, mogućnosti dobivanja dobrih približnih rješenja uz prihvatljiv utrošak vremena i sklopovlja, široko područje primjene.

2.6. Računalni vid

Kao ljudi, percipiramo trodimenzionalnu strukturu svijeta oko nas s očitom lakoćom. Gledajući uokvireni portret glupe ljudi, lako možemo nabrojati imena osoba na slici pa čak i pogoditi njihovo emocionalno stanje prema njihovim izrazima lica. Psiholozi i drugi znanstvenici koji se bavili percepcijom dugi niz godina su pokušavali shvatiti kako funkcionira vizualni sustav, pa su čak osmislili optičke iluzije kako bi opovrgnuli neke principe, ali cijeli taj sustav ostaje i dalje zagonetan.

Istraživači u području računalnog vida (eng. *computer vision*, RV) paralelno razvijaju matematičke tehnike za dobivanje trodimenzionalnih oblika i pojavu objekata na slikama. Danas postoje pouzdane tehnike za dobivanje djelomičnih 3D modela okoline od nekoliko stotina djelomičnih fotografija koje se preklapaju. Ako postoji dovoljan set pogleda na objekt, može se točno izraditi 3D model objekta koristeći stereo-povezivanje. Mogu se pratiti kretnje osoba, pa se čak mogu i na slici prepoznati i imenovati osobe, kombinirajući njihova lica, odjeću te detekciju i prepoznavanje kose. No, unatoč svim tim napretcima, imati računalo koje će interpretirati sliku kao, recimo, dvogodišnje dijete, ostaje zasad nedostižno.⁷

Iako su RV algoritmi trenutno skloni pogreškama u velikoj mjeri, oni nalaze primjenu u raznim područjima ljudskog djelovanja (pregledavanje strojeva, trgovina, medicina, automobilska sigurnost, nadzor, prepoznavanje otisaka prstiju i ostalo).⁷

2.7. Umjetne neuronske mreže


Umjetne neuronske mreže (eng. *artificial neural networks*, ANN) su računalne mreže koje pokušavaju simulirati rad ljudskog živčanog sustava. Istraživanja i razvoj umjetnih neuronskih mreža motivirani su spoznajama o građi i načinu funkcioniranja ljudskog mozga te njegovim nevjerojatno velikim sposobnostima u rješavanju složenih problema. ANN omogućava rješavanje jednostavnih računalnih operacija poput zbrajanja, množenja, ali i složenih ili matematički loše definiranih problema. Konvencionalni algoritmi sastoje se od složenih setova jednadžbi koje se mogu primjeniti samo za zadani problem. ANN će računalno i algoritamski nerijetko biti jednostavnije, a imati će mogućnost bavljenja znatno širim spektrom problema. Primjerice, ako muha izbjegava prepreke u letu ili kada miš izbjegava mačku, oni zasigurno putem ne rješavaju diferencijalne jednadžbe niti koriste složene uzorke algoritama. Njihov mozak je jednostavan i zato ANN teži k toj jednostavnosti u rješavanju problema.

Još jedan aspekt ANN-a koji ih razlikuje od običnih računala je njihova visoka paralelnost. Konvencionalno digitalno računalo je serijski stroj. Ako se jedan tranzistor (od njih milijun) pokvari, dolazi do zastoja cijelog sustava. U ljudskom centralnom živčanom sustavu, tisuće živčanih stanica umire godišnje dok mozak bez obzira na to nastavlja funkcionirati normalno (osim kada odumru živčane stanice na nekim ključnim lokacijama).⁴

2.7.1. Biološka osnova umjetnih neuronskih mreža

Biološka neuronska mreža se sastoji od otprilike 10^{11} živčanih stanica (neurona). Ljudski mozak isuviše je složen da bi se mogao opisati postojećim metodama neurofiziologije i razumjeti način njegova djelovanja premda je već dosta njegovih funkcionalnih aktivnosti objašnjeno. Živčane stanice organizirane su u module (slojeve, eng. *layers*) i međusobno povezane u složenu mrežu s otprilike 10^{15} međusobnih veza. Tako gusto povezana mreža živaca osigurava izuzetno veliku računsku i memorijsku moć ljudskog mozga.

Živčana stanica, kao osnovna gradivna jedinica biološke neuronske mreže, prima i obrađuje informacije (signale) od drugih živčanih stanica i/ili osjetilnih organa. Ona se može pojednostavljeno prikazati kao stanica sastavljena od tijela, aksona te mnoštva dendrita (**Slika 4.**)¹⁵



Slika 4. Prikaz živčane stanice i sinapse (veze između dvije živčane stanice)


Akson se može zamisliti kao tanka cjevčica čiji je jedan kraj povezan na tijelo neurona, a drugi kraj je razgranat. Tijelo živčane stanice koje uključuje staničnu jezgru je mjesto na kojem se odvija najviše „računanja“ tj. stvara se impuls (na temelju pristiglih signala preko dendrita). Impuls generiran u tijelu stanice zatim putuje kroz akson do sinapsi u obliku elektrokemijskih procesa. Sinapsa je veza između dvije živčane stanice, a čine ju završeci aksona jedne stanice (predsinaptičke) i dendriti druge stanice (postsinaptičke). Akson jednog neurona može formirati sinaptičke veze s mnoštvom drugih neurona. Prema tome, jedan neuron može primati signale od mnoštva drugih neurona, što označava postojanje biološke neuronske mreže. Važno je naglasiti da pristigli signali u postsinaptički neuron nisu istog intenziteta (različita im je težina, eng. *weight*). Signali iz predsinaptičkog neurona se preko sinapse kemijskim transmiterima (neurotransmiterima) prenose u postsinaptički neuron. Ti signali mogu biti pobuđujući (eng. *excitatory*) ili smirujući (eng. *inhibitory*), a matematički gledano imaju suprotan predznak. Oni se zatim prosljeđuju do tijela stanice u kojem se prikupljaju i obrađuju. Ako je kumulativna vrijednost pristiglih signala, tijekom kratkog vremenskog intervala, veća od praga osjetljivosti neurona (kritične vrijednosti, eng. *threshold value*), tijelo neurona generira impulse koji se šalju duž aksona prema drugim neuronima. Ako je ta vrijednost manja od kritične, neuron ostaje nepobuđen i ne generira impulse.^{4,5,15}

Iz toga se može zaključiti da se obrada signala u neuronu odvija kroz dvije odvojene operacije¹⁵:

- **Sinaptička operacija:** daje određeni značaj (težinu) svakom ulaznom signalu u neuron,
- **Somatska operacija:** prikuplja sve ulazne signale, te ako je njihova kumulativna vrijednost veća od kritične, generira impulse koje šalje prema drugim neuronima

2.7.2. Osnovni principi umjetnih neuronskih mreža


Analogno biološkim umjetnim mrežama, mogu se izraditi i ANN (**Slika 5.**). Umjetna mreža se sastoji od jednostavnih procesnih jedinica koje komuniciraju slanjem signala jedna drugoj preko jedne (ili više) veza definiranih određenim težinskim koeficijentom (w_{nj}).



Slika 5. Osnovna jedinica umjetne neuronske mreže

Procesna jedinica (ekvivalent živčanjoj stanici) sastoji se od sumatora i aktivacijske funkcije. Ona prima signale (x_j) od prethodnih jedinica ili vanjskih izvora. Svaki pristigli signal se modificira množenjem s težinskim koeficijentom veze. Sumator zbraja sve pristigle modificirane signale i zbroj uspoređuje s kritičnom vrijednošću (pragom osjetljivosti neurona), a aktivacijska funkcija potom, ako je zbroj veći od kritične vrijednosti, generira izlazni signal i šalje ga prema izlazu iz jedinice.⁶ „ θ “ predstavlja konstantnu ulaznu vrijednost u procesnu jedinicu tj. ulaznu vrijednost neovisnu o ostalim ulaznim vrijednostima u mrežu (eksterna vrijednost, eng. *bias*).¹⁶

Unutar neuronskog sustava korisno je razlikovati tri vrste slojeva neurona: ulazni sloj (eng. *input leyer*) koji sadrži neurone čija je dužnost primanje podataka (signala) iz okoline neuronske mreže (izvana), izlazni sloj (eng. *output layer*) u kojem se nalaze neuroni koji šalju podatke iz neuronske mreže, i skriveni slojevi (eng. *hidden units*) kojih može biti jedan ili više, a nalaze se između ulaznih i izlaznih jedinica. Neuronska mreža u kojoj nema skrivenih slojeva smatra se jednoslojnom, a ukoliko skriveni slojevi postoje govormo o višeslojnoj mreži.¹⁶



Slika 6. Shematski prikaz višeslojne umjetne neuronske mreže

2.7.2.1. Vrste umjetnih neuronskih mreža

Umjetne neuronske mreže mogu se razlikovati prema smjeru putovanja podataka te ih prema tome dijelimo na unaprijedne i povratne mreže. Unaprijedne mreže (eng. *feed-forward neural networks*) su mreže u kojima informacije teku (prenose se) striktno od ulaznih neurona prema izlaznima tj. ne postoje povratne veze. Podaci se prenose od izlaza jednog neurona do ulaza u neuron sljedećeg sloja;¹⁶ dakle veze među neuronima istog sloja nisu dozvoljene. Ukoliko neuroni u unaprijednoj mreži nisu povezani samo s neuronima susjednih slojeva (prethodnih i sljedbenih) nego i s neuronima drugih prethodnih slojeva, govorimo o kaskadnim unaprijednim mrežama (eng. *cascade-forward neural network*).⁶

Mreže kod kojih signal putuje u oba smjera tj. mreže koje sadrže povrate veze nazivaju se povratne neuronske mreže (eng. *recurrent networks*).

2.7.3. Perceptron i adaline


Perceptron je povijesno gledano najstarija umjetna neuronska mreža i također je osnovna gradivna jedinica gotovo svih umjetnih neuronskih mreža. Građa i način rada perceptrona u biti su objašnjeni kod opisa osnovnih principa rada neuronskih mreža. Svi ulazi se „otežavaju“ i zbrajaju u sumatoru neurona. Izlazna vrijednost se dobije aktivacijom izlaznog neurona što predstavlja funkciju ulaznih vrijednosti:

$$y = f(z) = f\left(\sum_i w_i \cdot x_i + \theta\right) \quad (1)$$

Kod perceptrona najčešći oblik aktivacijske funkcije je funkcija signum (**Slika 7.**), granična funkcija prema kojoj izlazna vrijednost iz neurona može biti 1 ili -1, ovisno o ulazu:

$$f(z) = \begin{cases} 1 & \text{ako je } z > 0 \\ -1 & \text{ako je drugačije} \end{cases} \quad (2)$$

Mreža se prema tome može koristiti za klasifikacijske zadatke tj. može odlučiti kojem od dva razreda pripada ulazni uzorak. Ako je ukupni ulaz pozitivan, uzorku će biti pripisana vrijednost 1, a ako je negativan, -1.



Slika 7. Grafički prikaz signum funkcije


Razdvajanje između ta dva razreda može se prikazati pravcem koji ima jednadžbu:

$$w_1 \cdot x_1 + w_2 \cdot x_2 + \theta = 0 \quad (3)$$

koja u eksplicitnom obliku izgleda:

$$x_2 = - (w_1/w_2) \cdot x_1 - (\theta/w_2) \quad (4)$$

iz čega se vidi da težine tj. težinski koeficijenti određuju nagib pravca (klasifikacijskog ili razdjelnog pravca), a θ udaljenost od izvorišnog pravca tj. poziciju¹⁶.



Slika 8. Geometrijski prikaz linearne granice tj. klasifikacijske funkcije jednostavne neuronske mreže

Adaline (eng. *Adaptive Linar Element*) je također primjer jednostavne neuronske mreže koja zapravo ima osnovnu strukturu perceptrona. Fizički se adaline može zamisliti kao jednostavni uređaj sastavljen od niza otpornika spojenih u strujni krug koji može sumirati struje uzrokovane ulaznim naponskim signalima. Centralni dio (sumator) najčešće je popraćen kvantizatorom koji određuje hoće li izlazna vrijednost biti +1 ili -1 na temelju polarosti sume dobivene u sumatoru.¹⁶

2.7.3.1. Učenje umjetnih neuronskih mreža

Neuronska mreža mora biti konfigurirana tako da primjena seta ulaznih vrijednosti proizvede poželjni set izlaznih vrijednosti tj. moraju se podesiti težine i pragovi osjetljivosti. Postoje razne metode za postavljanje težina (jačina) veza između jedinica. Jedan način je eksplicitno namještanje težina korištenjem *a priori* znanja. Drugi način je "učenje" neuronskih mreža prema nekim obrascima i puštanje da se težine i pragovi osjetljivosti sami promjene prema određenom pravilu učenja.¹⁶ Učenje je iterativan postupak i predstavlja jedno od osnovnih svojstava umjetnih neuronskih mreža.⁶

Postoje dvije vrste učenja koje možemo okarakterizirati kao:

- **Nadgledano učenje** (eng. *supervised* ili *associative learning*) u kojem je potreban skup poznatih vrijednosti ulaznih i izlaznih varijabli. U početku se definira struktura umjetne neuronske mreže (broj ulaza i izlaza iz neuronske mreže, broj skrivenih slojeva i neurona u tim skrivenim slojevima) i početne težine. Početne težine se najčešće usvoje generiranjem slučajnih brojeva. Zatim

se računaju vrijednosti izlaznih varijabli, a dobiveni rezultati se uspoređuju s predviđenima (vanjskim referentnim vrijednostima) te se računa razlika. Ta razlika predstavlja pogrešku neuronske mreže. Pogreška se zatim koristi za računanje novih težina korištenjem usvojenog algoritma (pravila) te se postupak iteracijski ponavlja sve dok pogreška ne postane minimalno prihvatljiva, odnosno mreža postane utrenirana (naučena).⁶

- **Nenadgledano učenje** (eng. *unsupervised* ili *self-organisation learning*) u kojem nisu poznate izlazne vrijednosti. Na ulaz mreže se dovode skupine ulaznih varijabli te se mreža mora sama organizirati podešavanjem parametara prema definiranom algoritmu. Kod ovog načina učenja, sustav (mreža) bi trebao sam otkriti statistički istaknute značajke u ulaznim podacima (korelacije, uzorke ili kategorije). Sustav mora sam razviti svoj način prikaza ulaznih stimulacija.^{6,16}

Važno pitanje koje se javlja jest kako naučiti tj. istrenirati neuronske mreže, odnosno kako podesiti težine i eksterne ulaze u mrežu (θ) da daju točne rezultate. Za to postoje dvije metode: *perceptron* i *delta pravilo učenja*. Obje metode su iterativni postupci koji prilagođavaju težinske koeficijente ne bi li mreža davala točne (željene) rezultate. Prvo se mreži prezentira uzorak po kojem treba učiti kako bi se postigle očekivane vrijednosti na izlazu. Novi težinski koeficijenti dobivaju se dodavanjem određene korekcije staroj vrijednosti (isto tako se podešava i eksterni signal θ).

$$w_{i+1} = w_i + \Delta w_i \quad (5)$$

$$\theta_{i+1} = \theta_i + \Delta \theta_i \quad (6)$$

Stoga je očito da je glavno pitanje kako izračunati spoemnute korekcije?¹⁶

Perceptron pravilo učenja

Perceptron pravilo učenja (eng. *perceptron learning rule*) može se predstaviti kroz nekoliko koraka. Prvo je potrebno osigurati nekoliko skupova podataka koji će poslužiti za treniranje neuronske mreže, te je potrebno pretpostaviti da postoji željena (očekivana) vrijednost na izlazu iz mreže. Nasumično se odaberu težinski koeficijenti, kao i skup podataka koji će biti ulazni signal u mrežu. Ako se pokaže da izlazna vrijednost ne odgovara željenoj vrijednosti ($y \neq d(x)$) tj. da perceptron daje netočan odgovor, svi težinski koeficijenti se modificiraju prema korekciji:

$$\Delta w_i = d(x) \cdot x_i \quad (7)$$

Postupak se ponavlja odabirom drugih podataka iz skupa podataka. Bolje je ako postoji više podataka kako bi se mreža što bolje istrenirala. Ako mreža odgovori točno tj. u skladu sa željenom vrijednosti, težinski koeficijenti se ne modificiraju.¹⁶

Delta pravilo

Delta pravilo (eng. *delta rule*) predstavlja na neki način poopćenje načina učenja objašnjenog kod perceptrona. Ovo pravilo temelji se na metodi padajućeg gradijenta¹⁷ (eng. *gradient descent method*), a ideja je da se težine mijenjaju proporcionalno negativnoj vrijednosti gradijenta pogreške. Kada se koristi delta pravilo, tada se perceptron zapravo naziva adaline. Takva jednostavna mreža poput perceptrona odnosno adaline, sposobna je prikazati linearnu povezanost između vrijednosti izlaznih i ulaznih jedinica te je stoga kod delta pravila fokus na toj linearnoj povezanosti.

Za dani ulazni skup podataka, P, izlazna vrijednost iz mreže se razlikuje od očekivane vrijednosti d_p za $(d_p - y_p)$ gdje je y_p stvarna izlazna vrijednost za zadani skup P. Tada delta pravilo koristi funkciju pogreške (eng. *error function*) temeljenu na navedenoj razlici, kako bi prilagodila otežavajuće faktore. Nakon niza matematičkih operacija, funkcija na kraju ima oblik:

$$\Delta_p w_j = \gamma \cdot \delta_p \cdot x_j \quad (8)$$

gdje δ_p predstavlja razliku $\delta_p = (d_p - y_p)$, γ koeficijent proporcionalnosti, $\Delta_p w_j$ iznos za koji treba adaptirati težinu, a x_j ulazni podatak povezan na težinu koju se prilagođava.¹⁶


2.7.3.2. XOR problem

Dva znanstvenika, Minsky i Papert, otkrili su obeshrabrujuća ograničenja prethodno opisanih jednoslojnih neuronskih mreža u rješavanju problema. Njihovi rezultati su pokazali da jednoslojni perceptron ne može prikazati jednostavnu logičku operaciju ekskluzivne disjunkcije (XOR). To je logička operacija kod koje je rezultat (izlaz) istinit ako i samo ako je jedan od ulaza istinit. Ako su oba ulaza istinita ili ako su oba ulaza neistinita, izlaz će biti neistinit. Ako se istina označi s 1, a neistina s -1, to se može prikazati tablično:

Tablica 2.1. Tablica istinitosti za operaciju ekskluzivne disjunkcije

SKUP	x_1	x_2	d
A	1	1	-1
B	1	-1	1
C	-1	1	1
D	-1	-1	-1

Tablica pokazuje očekivanu vezu između skupova podataka na ulazu i njihovih izlaznih vrijednosti dobivenih ekskluzivnom disjunkcijom. Vidljivo je da skupovi A i D pripadaju jednom razredu jer imaju istu vrijednost na izlazu (-1), dok skupovi B i C pripadaju drugom razredu. To se može grafički prikazati ovako:




Slika 9. Grafički prikaz skupova ulaznih vrijednosti

Iz grafa se jasno vidi da se skupovi A i D od skupova B i C ne mogu biti pravcem podijeljeni u dva odvojena razreda tj. ne postoji pravac koji bi to uspješno napravio, što znači da perceptron ne može riješiti ovaj klasifikacijski problem.¹⁶

2.7.4. Višeslojne unaprijedne neuronske mreže

Specifični problem iz *poglavlja 3.4.3.2.* može biti riješen dodavanjem skrivenih slojeva. Time mreža postaje višeslojna (višeslojni perceptron). Četiri ulazna skupa podataka, koji su sada u trodimenzionalnom prostoru, mogu lako odvojiti ravninom na dva razreda (grupe), što je i poželjno. Jednostavni primjerci pokazuju da se dodavanjem skrivenog sloja povećao broj problema rješivih unaprijednim mrežama koje nalikuju na perceptron.

Kod unaprijednih neuronskih mreža s više slojevan neuroni ulaznog sloja, N_i , primaju signale (podatke, parametre) koje šalju u prvi sloj skrivenih jedinica $N_{h,1}$ (Slika 10.). U ulaznim neuronima se ne odvija nikakav proces. Neuroni skrivenih slojeva primaju informacije pristigle iz neurona prethodnog sloja te eksterni signal (θ , u literaturi poznat kao *bias*), množe ih s težinama pojedinih veza, sumiraju i ostvarenu sumu na poslijetku aktiviraju. Aktivirani signal šalje se neuronima sljedećeg sloja. Važno je istaknuti da ne postoje veze između neurona u istom sloju. Informacija tako putuje mrežom dok ne dođe do sloja izlaznih neurona, N_o .¹⁶



Slika 10. Višeslojna mreža s h skrivenih slojeva

2.7.4.1. Back-propagation

Dodavanjem skrivenih slojeva, povećao se stupanj rješivosti problema, ali su se izgubila usvojena pravila učenja kojima su se optimirali težinski koeficijenti. Iz tog razloga osmišljena je metoda *back-propagation* (BP) koju se smatra poopćenim delta pravilom za nelinearne aktivacijske funkcije i višeslojne mreže.

Cijeli BP proces intuitivno je vrlo jasan. Kada su uzorci za učenje utvrđeni (pričvršćeni, *clamped*), aktivacijske vrijednosti se šire do izlaznih neurona gdje se stvarne izlazne vrijednosti uspoređuju sa željenim izlaznim vrijednostima. To obično pokaže postojanje pogreške u svakom od izlaznih neurona. Pogrešku se može označiti s e_o za svaki pojedini izlazni neuron o . Cilj je dovesti e_o u nulu.

Najjednostavnija metoda za postizanje tog cilja je tzv. „pohlepna metoda“ (eng. *greedy method*): nastoje se promijeniti veze u neuronskoj mreži na način da pogreška na izlazu bude nula za taj isti uzorak podataka. Iz delta pravila poznato je, da ukoliko se želi smanjiti pogreška, treba prilagoditi otežavajuće faktore. To je prvi, ali nedovoljan korak jer se promijene težine neurona samo skrivenog sloja koji je povezan s izlaznim, dok težine iz ulaznog sloja u skriveni ostaju nepromijenjene. Kako bi se adaptirale težine od ulaznog do skrivenog sloja, ponovno se mora primijeniti delta pravilo. U tome slučaju, doduše, ne postoji δ vrijednost za skrivene neurone. Taj problem je riješen lančanim pravilom koji radi sljedeće: pogreška izlaznih neurona o se raspodijeli svim skrivenim neuronima koji su povezani s izlaznim neuronima, a te pogreške se otežaju množenjem s otežavajućim faktorima. Drugačije rečeno, skriveni sloj h prima deltu (δ) od svakog izlaznog neurona, pomnoženu s težinskim koeficijentom koji je zadan između tih neurona. Pa se tako delta skrivenog sloja može prikazati kao suma umnožaka delti svih izlaznih neurona i otežavajućih faktora kojima su povezani izlazni i skriveni neuroni:

$$\delta_h = \sum_o \delta_o \cdot w_{ho} \quad (9)$$


Ako se želi nastaviti BP proces u smjeru ulaznih neurona, potrebno je prvo primijeniti aktivacijsku funkciju skrivenih neurona na deltu. Postupak je iterativan što znači da se ponavlja dok se ne postignu zadovoljavajući rezultati tj. do trenutka kada pogreške više nema ili je minimalizirana.¹⁶

2.7.5. Treniranje i pretreniranje

Prije treniranja (učenja), skup podataka potrebno je podijeliti na skup za treniranje i skup za testiranje. Skup za treniranje služi za podešavanje modela, dok skup za testiranje služi za utvrđivanje kada je potrebno prekinuti treniranje kako bi se spriječilo pretreniranje.⁶

2.7.6. RBF mreže

RBF mreže (eng. *radial basis function networks*) u principu predstavljaju mreže kod kojih je aktivacijska funkcija radijalna funkcija. Radijalne funkcije spadaju u poseban razred funkcija. Njihovo karakteristično svojstvo je da im odziv monotono opada ili se povećava s udaljavanjem od centralne točke. Centralna točka (točka u kojoj je odziv funkcije najveći), udaljenost od centralne točke (radijus), ali i odabrana krivulja raspodjele, parametri su radijalne funkcije. Tipični primjer radijalne funkcije je Gaussova funkcija (**Slika 11.**).¹⁸



Slika 11. Gaussova krivulja

RBF neuronske mreže dvoslojne su (jedan skriveni sloj) unaprijedne neuronske mreže. Kao aktivacijska funkcija koristi se radijalna baza funkcija, a izlazni sloj sastoji se od perceptrona s linearnom aktivacijskom funkcijom.¹⁵

2.7.7. Povratne mreže

U unaprijednim mrežama opisanim u prethodnim poglavljima rezultati na izlazu ovise isključivo o trenutačnom stanju ulaza i vrijednostima parametara mreže. To svojstvo čini unaprijedne mreže strukturno stabilnima, no ponekad njihova primjena ne zadovoljava. Naime, neuroni sktivenog sloja ne smiju se povezati međusobno, kao ni povratno s neuronima iz prethodnih slojeva. Primjerice, ako je potrebno da neuronska mreža sačuva neku informaciju neodređeni vremenski period, tada unaprijedna mreža ne zadovoljava jer ima konačni impulsni odziv.¹⁵ Ukoliko bi se mreža strukturno napravila tako da spomenute zapreke budu omogućene, tada govorimo o povratnim mrežama (eng. *recurrent networks*).


Što se tiče učenja povratnih mreža, postoje povratne mreže kod kojih se aktivacijske vrijednosti opetovano ažuriraju (propagacija se konstantno odvija) sve dok se ne dosegne stabilna točka nakon koje se otežavajući faktori prilagode, ali postoje i mreže u kojima se pravilo učenja koristi nakon svake propagacije.¹⁶

Osnovni primjeri povratnih mreža su Jordanova, Elmanova i Hopfieldova mreža.¹⁶

2.7.7.1. Jordanova mreža

Jedna od najstarijih povratnih mreža je Jordanova mreža. U ovoj mreži vrijednosti na izlazu se ponovno vraćaju u ulazni sloj u kojem se nalaze dodatni ulazni neuroni nazvani neurni stanja (eng. *state units*). Postoji toliko neurona stanja koliko ima izlaznih neurona iz


mreže. Veza između izlaznog neurona i neurona stanja ostvarena je težinskim koeficijentom koji je fiksiran i iznosi 1 (fiksiran je jer se učenje manifestira adaptiranjem otežavajućih faktora između ulaznih i skrivenih neurona te skrivenih i izlaznih neurona). Prema tome, za učenje ovakve mreže upotrijebljavaju se pravila učenja kao i kod višeslojnog perceptrona.¹⁶



Slika 12. Jordanova mreža

2.7.7.2. Elmanova mreža


U Elmanovoj mreži se uvodi niz neurona koje se nazivaju kontekstnim neuronima (eng. *context units*) koji zapravo predstavljaju dodatne ulazne neurone koji dobivaju ulazne signale od neurona skrivenog sloja. Mreža je slična Jordanovoj, samo što dodatne ulazni neuroni nisu povezani s izlaznim nego sa skrivenim neuronima. Težinski koeficijent je također fiksiran na 1.¹⁶



Slika 13. Elmanova mreža

2.7.7.3. Hopfieldova mreža

Hopfieldova mreža sastoji se od N međusobno povezanih neurona. Svaki neuron je povezan sa svim ostalim neuronima osim sa samim sobom. Svaki neuron svoje aktivacijske vrijednosti ažurira neovisno o drugim neuronima. To sve znači da su sve neuronske jedinice ujedno ulazne i izlazne jedinice.¹⁶



Slika 14. Shematski prikaz Hopfieldove mreže


Osnovna primjena Hopfieldove mreže je asocijativna memorija. Asocijativna memorija je sposobna odrediti je li dani podatak sadržan u jednoj od adresa odnosno lokacija. U ovome slučaju, težinski koeficijenti koji su veza između neurona moraju biti postavljeni tako da je stanje sustava koje odgovara uzorcima koji moraju biti pohranjeni u mreži stabilno.

2.7.8. Samoorganizirajuće mreže

Samoorganizirajuće mreže (eng. *Self-Organising Networks*, SON) se zapravo nastavljaju na Hopfieldove mreže, ali razlika je u tome što kod SON ne postoje podaci za treniranje sastavljeni od ulaznih i poželjnih izlaznih vrijednosti. Jedine osigurane informacije su skupovi ulaznih podataka. Prema tome, riječ je o nenadgledanom učenju. Nenadgledano prilagođavanje težinskih koeficijenata najčešće je bazirano na nekom obliku globalnog natjecanja između neurona. Jedan od osnovnih primjera jeste natjecateljsko učenje (eng. *competitive learning*) kojeg ju osmislili Rumelhart i Zipser 1985.²⁰

Natjecateljsko učenje je postupak učenja koji dijeli skup ulaznih uzoraka u klastere („grozdove“) koji su svojstveni ulaznim podacima. Primjer mreže u kojoj se koristi netjecateljsko učenje prikazan je na **slici 15**. Svi izlazni neuroni o spojeni su otežavajućim

faktorima w_{io} na sve ulazne neurone i . Kada se uzorak ulaznih vrijednosti prezentira mreži, samo jedan izlazni neuron mreže će se aktivirati („pobijediti“). Ako je mreža ispravno istrenirana, svi ulazni uzorci koji pripadaju jednom od klastera, imati će istog „pobjednika“.¹⁶



Slika 15. Shematski prikaz jednostavne mreže u kojoj se koristi natjecateljsko učenje

2.8. Neizrazita logika

Neizrazitua logika (eng. *fuzzy logic*) razvijena je sredinom 1960-ih na temelju matematičkih teorija neizrazitih skupova, što predstavlja poopćenje klasične logike. Razvijena je kako bi se kategorizirali oni problemi kod kojih se moraju koristiti neprecizni podaci ili oni kod kojih su pravila zaključivanja formulirana na općenit način. U klasičnoj logici element ili pripada ili ne pripada skupu, dok u neizrazitoj logici, osim istinite (1) i neistinite (0), tvrdnje mogu biti djelomično istinite tj. mogu primiti vrijednosti između 0 i 1.

Na taj način pokušalo se omogućiti modeliranje semantičkih neodređenosti ljudskoga jezika tj. formalizirati ljudsko zaključivanje na temelju neprecizno određenih (neizrazitih) informacija. Dopuštanjem da tvrdnje budu između istine i neistine, neizrazita logika osigurava fleksibilnost u zaključivanju što ju čini sposobnom da u obzir uzima nesigurnosti i nepreciznosti.¹⁹⁻²²

2.8.1. Neizraziti skupovi i funkcije pripadnosti

U klasičnoj teoriji skupova, skup predstavlja kolekciju objekata koji dijele neko zajedničko svojstvo. Definicija skupa je intuitivna jer pojmovi "skup", "kolekcija" i "klasa" predstavljaju sinonime, isto kao i pojmovi "objekt", "član" i "element".


Pripadnost objekta klasičnom skupu točno je određena: ili je objekt unutar skupa ili je izvan njega. Pripadnost objekta x skupu B može se izraziti funkcijom pripadnosti, μ_B koja ima samo dvije vrijednosti i definirana je s:

$$\mu_B(x) = \begin{cases} 1, & \text{za } x \in B \\ 0, & \text{za } x \notin B \end{cases} \quad (10)$$

U nekim podjelama objekata na skupove stroga definicija pripadnosti nije prikladna jer nekada nije moguće odrediti zadovoljavajuću izrazitu granicu između objekata. Kao tipičan primjer često se navodi problem matematičkog opisa ljudske percepcije temperature okoline, gdje se po iznosu vrlo bliske numeričke vrijednosti mogu naći u različitim skupovima. Tako npr. osoba upitana za klasifikaciju temperatura zraka, u skup vruće može smjestiti sve temperature od veće od 30 °C, dok će intuitivno vrlo bliska vrijednost od 29,9 °C pripadati nekom drugom skupu (**Slika 16. (a)**).

Za razliku od klasičnog pristupa, teorija neizrazitih skupova dopušta djelomičnu ili stupnjevitu pripadnost objekata skupu, a funkcijske vrijednosti funkcije pripadnosti nalaze se unutar intervala [0,1]. Pri tome vrijednost 0 označava da je objekt potpuno izvan skupa, 1 da je potpuno unutar skupa, a bilo koja vrijednost između označava djelomičnu pripadnost. Tako definirani skupovi znatno su bliže načinu na koji čovjek doživljava i govorno interpretira osjet temperature zraka. Tako bi prosječan promatrač temperaturu od 22 °C označio s "nije vruće", od 28 °C s "malo je vruće", od 33 °C s "prilično je vruće" i temperaturu od 40 °C s "jako vruće".²² Prema tome, definicija neizrazitih skupova omogućava uvođenje lingvističkih varijabli, što je temelj neizrazite logike.⁶ Pojmovi "vruće", "svježe", "star", "skup" ili "nizak" predstavljaju neizrazite skupove koji određuju jezične varijable ili u užem smislu vrijednosti jezičnih varijabli. Npr. jezična varijabla "cijena" može imati četiri vrijednosti (vrlo niska, niska, visok i vrlo visoka), odnosno četiri odgovarajuća neizrazita skupa.

Neizraziti skup određen je funkcijom pripadnosti tj. svaki objekt x pridružuje se neizrazitom skupu pomoću funkcije pripadnosti. Funkcijom pripadnosti određuje se kako će se svaki objekt preslikati u stupanj pripadnosti između 1 i 0. Funkcija pripadnosti za neki neizraziti skup B može se podijeliti na područje koje je opisano potpunom pripadnošću skupu B , $\mu_B(x) = 1$ (jezgra) i na područje u kojem objekti ne pripadaju potpuno skupu $0 < \mu_B(x) < 1$ (granica) (**Slika 16.(b)**).



Slika 16. Funkcije pripadnosti izrazitog (a) i neizrazitog (b) skupa "vruće"

Način zadavanja funkcije pripadnosti najviše ovisi o karakteru objekata ili podatak koji se grupiraju (diskretni ili kontinuirani) odnosno o domeni (području definicije) skupa. Neke od najčešćih funkcija pripadnosti su trapezoidna, trokutasta, Gaussova, Gaussova kombinacijska, poopćena zvonolika, sigmoidna funkcija i dr.^{6,22}

2.8.2. Neizrazita pravila

Kao što klasična teorija skupova predstavlja temelj klasične logike, tako teorija neizrazitih skupova predstavlja temelj neizrazite logike. Veza između teorije skupova i logike uspostavljena je preko definicije osnovnih operacija nad skupovima i njihovih logičkih ekvivalenata. Osnovne teoretske operacije definirane nad klasičnim skupovima su unija, presjek i komplement. Proširenje skupa funkcijskih vrijednosti funkcija pripadnosti sa samo dvije, $\{0,1\}$ (klasična logika), na cijeli interval $[0,1]$ (neizrazite logika), omogućilo je znatno veći broj definicija osnovnih operacija nad neizrazitim skupovima.

Zadatak neizrazite logike smisliti je kvantitativni model ljudskog razmišljanja koje je izraženo riječima i rečenicama govornog jezika. Tu se polazi od neizrazite propozicije (eng. *fuzzy proposition*). Općeniti oblik neizrazite propozicije dan je s " x je B", gdje je x varijabla, a B jezična vrijednost zadana neizrazitim skupom nad domenom varijable x . Neizrazita propozicija uspoređuje varijablu x i skup B, tj. određuje stupanj pripadnosti varijable x neizrazitom skupu B.

Propozicije se povezuju korištenjem riječi I, ILI i AKO-ONDA. Neizrazito pravilo (eng. *fuzzy rule, fuzzy implication*) nastaje kombinacijom propozicija i veznika (riječi koje povezuju propozicije) i u općem slučaju poprima oblik:

$$\text{AKO } x \text{ je B I } y \text{ je C ONDA } z \text{ je D} \quad (11)$$

gdje "x je B" i "y je C" predstavljaju premise (uvjete), a "z je D" konkluziju (zaključak).²²

Interpretacija neizrazitih pravila oblika AKO-ONDA je proces kojeg se može predočiti u tri stupnja:

- i. **Fazifikacija, omekšavanje ili pretvorba binarno-neizrazito** (eng. *fuzzyfication*) označava proces transformiranja ulaznih izrazitih vrijednosti pomoću funkcije pripadnosti u stupnjeve pripadnosti ulaznih neizrazitih skupova.
- ii. **Primjena neizrazitih operatora** je postupak koji se izvršava ako postoji nekoliko premisa kako bi se dobila vrijednost između 0 i 1 što predstavlja stupanj podrške odnosno rezultat polaznog dijela pravila (lijevog dijela)
- iii. **Primjena implikacijske metode** koja određuje na koji način će se na temelju funkcije pripadnosti za polazni dio pravila odrediti funkcija pripadnosti za izlaznu varijablu.

Na kraju se odvija proces defazifikacije odnosno izoštravanja (eng. *defuzzyficaton*) u kojem se dobiveni neizraziti skup pretvara u izrazite vrijednosti.⁶

2.8.3. FIS i ANFIS

FIS predstavlja neizraziti sustav zaključivanja (eng. *fuzzy inference system*) koji se sastoji od neizrazitih skupova, neizrazitih pravila i neizrazitog zaključivanja. To je zapravo računalni okvir koji ima široku primjenu, posebice u robotici, automatskom vođenju i raspoznavanju uzoraka. FIS može aproksimirati izrazito nelinearne sustave korištenjem skupa pravila. U početku je FIS treniran ručnim podešavanjem parametara, ali je 1993. Jang predstavio pristup s automatskim učenjem, ANFIS.²³

ANFIS je prilagodljivi neuronski sustav neizrazitog zaključivanja (eng. *Adaptive Neuro Fuzzy Inference System*) i predstavlja hibridni sustav koji je kombinacija neuronskih mreža i neizrazitog sustava zaključivanja. Takva mreža sastoji se od fiksnih i prilagodljivih čvorova te usmjerenih veza preko kojih su ti čvorovi povezani. Prilagodljivi čvorovi nalaze se u ulaznom sloju (fazifikacija) i u posljednjem skrivenom sloju (defazifikacija) i predstavljaju funkcije čiji se parametri prilagođavaju kako bi se postilo zadovoljavajuće preslikavanje ulaznih podataka u izlazne vrijednosti. U ostalim skrivenim slojevima nalaze se fiksni čvorovi u kojima se obavlja operacija množenja, a svaki izlaz iz tih čvorova predstavlja težinu pojedinog pravila tj. normalizirane težine pravila. Izlazni sloj sastoji se od samo jednog fiksniranog neurona čija je uloga izračunati konačni izlaz iz ANFIS-a sumiranjem svih signala

iz prethodnog sloja (doprinosi pojedinih pravila). Parametri funkcija pripadnosti podešavaju se pomoću algoritama učenja.

Temeljni algoritam učenja ANFISA-a je BP algoritam koji se koristi kod unaprijednih neuronskih mreža. Primjena BP algoritma pokazala je neke nedostatke poput sporosti i zaglavljivanja u lokalnom minimumu. Stoga se korisnim pokazao hibridni algoritam (eng. *hybrid training*, HY) koji je kombinacija BP algoritma i metode najmanjih kvadrata koja kao glavna pokretačka sila vodi brzom učenju sustava.

Za velike skupove podataka koji obuhvaćaju znatne varijacije, neizraziti sustav može imati bolju generalizaciju korištenjem većeg broja neizrazitih pravila, dok veliki broj pravila za mali raspon podataka može dovesti do pretreniranja pa bi model izgubio sposobnost generalizacije. Stoga je prostor ulaznih podataka potrebno podijeliti grupiranjem podataka tj. stvaranjem klastera, kako bi se smanjio broj pravila.⁶

3. PRIMJENA UMJETNE INTELIGENCIJE U ZAŠTITI OKOLIŠA

Sveobuhvatna primjena i svi aspekti umjetne inteligencije u zaštiti okoliša i ekosustava, procjeni kvalitete vode i zraka i zaštite od prirodnih nepogoda te prednosti i nedostaci takvog pristupa, prikazani su u slijedećem literaturnom pregledu:

Umjetne neuronske mreže pogodan su alat za predviđanje nelinearnih veza što je vidljivo kroz razna istraživanja. Zanimljivo je da se BP pravilo učenja koristi čak i za predviđanje utjecaja proizvodnje krumpira na okoliš.²⁴ Podaci za stvaranje modela su skupljani nasumičnom anketnom metodom od farmera iz 260 farmi u Iranu. Kako bi se procijenio utjecaj na okoliš, izlazne vrijednosti uključuju potencijalno globalno zatopljenje, potencijalnu eutrofikaciju (nagli rast biljne biomase), potencijalnu toksičnost za ljude i kopnene životinje, potencijal zakiseljavanja tla i potencijal stvaranja oksidansa.

Procjena i provođenje nadgledanja okoliša (eng. *environmental compliance*) tj. svih propisanih zakona, odredbi, regulacija i standarda vezanih uz okoliš, kompleksan je i intenzivan posao kojem bi znatno doprinio nekakav oblik sustava podrške odlučivanja. Unatoč dobro dokumentiranoj primjeni daljinskog istraživanja (eng. *remote sensing*) u okolišnim analizama i procjenama, operativnost takve tehnologije u izvršavanju nadgledanja okoliša je u začecima. U Sjedinjenim Američkim Državama je zbog velikog broja zakona i regulacije vezanih za okoliš donesena odluka kako se mora koristiti daljinsko istraživanje kao alat u kontroli zakona o okolišu, iako je postojao stupanj skepticizma vezan za operativnu korisnost i pouzdanost podataka dobivenih daljinskim istraživanjem. Takva metoda može se povezati s umjetnim neuronskim mrežama čiji razvoj pojednostavlja strategiju procesa nadgledanja okoliša. Modeli neuronskih mreža funkcioniraju kao „inteligentni“ klasifikatori koji osiguravaju prostornu karakterizaciju aktivnosti koje bi vjerojatno uzrokovale štetu.²⁵

Kako bi se zaštitilo morsko dno, razvijen je robotski sustav s dijamantnim sustavom za rezanje žica kako bi se prema propisima za zaštitu okoliša uklonili ostaci konstrukcije koja je bila namijenjena za obradu nafte (eng. *oil plant*) u Sjevernom moru.²⁶

Entomopatogene nematode su skupina nematoda (vlaknastih crvi) koje žive u tlu i koje se koriste za kontrolu štetnih insekata. Te životinje uzrokuju smrt kukaca pa iz tog razloga predstavljaju jednu od najboljih alternativa pesticidima koji su u povišenim koncentracijama

iznimno štetni za okoliš jer ulaze u površinske i podzemne vodotokove, ubijaju korisne organizme i izazivaju ozbiljne zdravstvene probleme. U laboratorijskim postupcima i analizama, brojanje je najčešći i najteži dio istraživanja koje se provodi na nematodama. Iz tog razloga predložena je nova mikroskopska metoda detekcije i brojanja mrtvih jedinki vrste *Heterohabditis bacteriophora* korištenjem računalnog vida. Metoda je testirana na 68 mikroskopskih slika koje su uključivale 935 živih i 780 mrtvih crvi. Stupanj prepoznavanja tj. raspoznavanja bio je 85%, što je zadovoljavajuć rezultat.²⁷

Održivost je postala ozbiljna inicijativa u izgradnji ne samo privatnih objekata, nego i javnih zgrada poput bolnica, ureda, gradskih vijećnica itd. Održiva gradnja je praksa dizajniranja, konstruiranja, održavanja i uklanjanja zgrada na način da se očuvaju prirodni resursi i smanji onečišćenje. Sustavi ocjenjivanja osiguravaju procjenu učinka na okoliš i mjere održivosti zgrada primjenom skupa kriterija organiziranih u različite kategorije. Prema tome, dobar sustav ocjenjivanja „zelenih“ zgrada (eng. *Green Building Rate System, GBRS*) odražava karakteristike zgrade. Kao alat za procjenu izvedbene razine „zelene“ zgrade može poslužiti ekspertni sustav baziran na GBRS-u koji analizira učinke faktora koji utječu na izgradnju takve zgrade.²⁸

U posljednjih nekoliko godina, porastom svijesti o potrebi zaštite okoliša i održivog razvoja unutar tvrtke ili poduzeća, „zeleni“ problem je postao sve aktualniji kada je u pitanju nabava materijala tj. opskrba lanca proizvodnje. Glavna svrha „zelenog“ upravljanja opskrbe lanca (eng. *green supply chain management*) je smanjenje onečišćenja okoliša u nizu od nabave sirovog materijala, preko proizvodnje i distribucije, pa sve do same prodaje proizvoda. Štetne tvari koje se nalaze u sirovom materijalu dobivenog (kupljenog) od opskrbljivača, mogu imati ozbiljan učinak na okoliš u bilo kojem dijelu prethodno opisanog lanca. Stoga odabir prikladnog nabavljača sirovog materijala postaje krucijalan problem. Iz tog razloga potrebno je osmisliti model odabira tako da se u obzir uzmu kriteriji praktičnosti tradicionalnog načina odabira nabavljača i ekološke regulacije za zaštitu okoliša. Osmišljen je hibridni model u kojem su integrirani umjetna neuronska mreža i dvije metode analize odluka (eng. *multi-attribute decision analysis method, MADA*), a koji odabire nabavljača ovisno o šest kriterija: kvaliteta, cijena, usluga, dostava, društvena odgovornost i utjecaj na okoliš.²⁹

Šuma je životna zajednica drveća i drugog nižeg bilje te životinja, i iznimno je veliki prirodni, gospodarski i ekološki resurs. Dugi niz godina, istraživači i upravitelji šuma koristili su empirijske statističke i matematičke modele kako bi predvidjeli posljedice djelovanja nad šumama i kako bi lakše donosili određene odluke. U mnogim slučajevima, takvi modeli nisu

korisni za rješavanje nestrukturiranih (nelinearnih) problema te donošenje dobrih odluka u upravljanju šuma postaloje sve teže. Kao alternativa tradicionalnim statističkim modelima, sve privlačnija postaje ideja o primjeni umjetnih neuronskih mreža. Neuronske mreže se primjenjuju u klasifikaciji šumskog područja, u modeliranju dinamike i rasta šuma, u prostornoj analizi podataka, u modeliranju dinamike bolesti koje zahvaćaju drva te u istraživanju klimatskih promjena. Ovakav pristup je potencijalno dobar alat za upravljanje šumskim resursima, premda je tek u začecima, dok budućnost leži u integraciji ovakvih tehnika u sustave za donošenje odluka.³⁰ Osim umjetnih neuronskih mreža, veliku ulogu u donošenju odluka u gospodarenju i upravljanju šumama imaju i ES. Oni su značajno zastupljeni u šumarstvu u Kanadi, gdje se sve više razvijaju.³¹

Umjetna neuronska mreža poslužila je kao pomoćni alat u modeliranju režima podzemnih voda s ciljem sprječavanja uništenja šuma hrasta lužnjaka. Naime, tokom planiranja izgradnje hidroelektrane „Novo Virje“ na rijeci Dravi se nastojalo istražiti utjecaj na okolne šume. Umjetna jezera koja bi nastala njenom izgradnjom, povećala bi razinu podzemnih voda na predjelu obližnje šume i tako ugrozila preživljavanje šumskih vrsta koje su osjetljive na poremećaje u razinama podzemnih voda, posebno hrasta lužnjaka.³²

Način zaštite šuma daleko je najvažniji kroz aspekt zaštite od požara. Šumski požari znatno utječu na okoliš, biljni i životinjski svijet, a jednako tako i na ljudske živote. Jedan od najefikasnijih načina zaštite šuma od požara je predvidjeti koja područja prekrivena šumama bi mogla biti zahvaćena požarom, te koja površina bi izgorjela ukoliko dođe do požara. Šumski požari najčešće se događaju ljeti, na područjima s vrućom, suhom ili mediteranskom klimom. U Portugalu primjerice, godišnje se dogodi između 15000 i 25000 požara u kojima prosječno 200 000 ha površine bude spaljeno. Iz tih razloga se pokušalo smisliti inteligentni sustav za predviđanje požara baziran na genetičkom programiranju. Za stvaranje takvog modela, kao parametri su se koristili analitički podaci o karakteristikama šuma, meteorološki podaci i podaci iz prijašnjih požara. Korišteni su geometrijski semantički operatori koji uključuju znanje povezano s reljefom krajolika. Testiranje metode provodilo se na području NP Montesinho u Portugalu gdje su požari česti i postoje velike razlike u nadmorskoj vidini na relativno malom području. Eksperiment je proveden 50 puta, a rezultati uspoređeni s podacima iz 517 šumskih požara između 2000. i 2003. godine, pokazali su prikladnost takvog sustava za predviđanje požara i naznačuju da istraživanje u ovom smjeru obećava dobre rezultate.³³

U istu svrhu osmišljena je i umjetna neuronska mreža tj. višeslojni perceptron čiji je broj skrivenih slojeva određen heuristički, a težine prilagođene BP algoritmom. 12 parametara je korišteno na ulazu u mrežu, dok izlazni signal predstavlja cjelokupnu površinu u hektarima odgovarajućeg područja koje bi izgorilo. Svrha primjene perceptrona je predvidjeti, u funkciji svih parametara, koja je cjelokupna površina koja bi izgorjela ako se ne učini ništa kako bi se prevenirala katastrofa. Rezultati ovakve primjene umjetnih neuronskih mreža su zadovoljavajući i potiču na nastavak istraživanja s ciljem boljeg optimiranja građe mreže.³⁴

U borbi protiv šumskih požara počele su se koristiti i tehnike računalnog vida. One uključuju mjerenja svojstava šumskog požara (frontalni dio vatre, visina plamena, nagibni kut plamena i širinu baze vatre) kako bi se razvile napredne strategije u borbi protiv požara. Računalni sustav trodimenzionalno percipira vatru te se može koristiti za vizualizaciju razvoja i širenja požara. On integrira slike dobivene od kamera i infracrvenih kamere, koristi senzore i GPS, te na taj način omogućava bržu detekciju požara i efikasniju mobilizaciju postrojbi za gašenje nastalih požara.³⁵

Poplave koje se javljaju u gradskim područjima najčešće su uzrokovane prevelikom količinom kiše koju odvodni sustavi (slivni kanali) ne mogu efikasno ukloniti. Osim štete privatnom vlasništvu i poslovnim objektima, javljaju se značajni humanitarni troškovi i naponi zbog fizičkih i mentalnih zdravstvenih problema (razvoj bolesti) i zbog evakuacije i relokacije ljudi pogođenih poplavom. Iz tog razloga razvijen je način da se uz genetski algoritam izvrši procjena očekivane godišnje štete, vjerojatnosti da će doći do poplave i vrijeme zadržavanja vode, kako bi se procijenio ukupni trošak potrebnih promjena u sustavima za odvodnju vode.³⁶

Zanimljivo je postojanje mogućnosti predviđanja pojave potresa kako bi se spriječile mnogobrojne ljudske žrtve i velike ekološke katastrofe. Nakon velikog broja potresa, seizmolozi mogu rezimirati broj fenomena koji se nazivaju potresni prekursori jer se odvijaju prije samog potresa. Ti fenomeni koji se događaju prije samog potresa jako su komplicirani, nisu lako ponovljivi i postoji ih veliki broj te je cilj pronaći poveznicu između potresa i tih fenomena pomoću računala i umjetne inteligencije. Na tragu toga razvijen je inteligentni sustav tj. ekspertni sustav za donošenje odluka u predviđanju potresa, IDSSEP (eng. *Intelligent Decision Support System for Earthquake Predictions*). Informacije o fenomenima i iskustva stručnjaka se skupe, sortiraju, oblikuju i pohranjuju u bazu znanja kao pravila. Za pronalazak veza između prekursora i potresa koristi se mehanizam automatskog zaključivanja. Tako stručnjaci štede svoje vlastito vrijeme, a predviđanja su objektivnija i sveobuhvatnija.

IDSSEP je 1995. godine počela koristiti Kina na cijelom svom teritoriju. Predviđanja koja su napravljena bila su iznimno uspješna i predviđen je cijeli niz snažnih potresa.³⁷

Područje umjetne inteligencije poznato pod nazivom ES primjenjivo je i na druga područja poput znanosti, tehnologije i trgovine. Također imaju sve veći utjecaj na vegetacijske znanosti i ekologiju općenito.³⁸ Ekolozi posjeduju razne alate za skupljanje i analiziranje podataka, ali relativno malo alata koji olakšavaju zaključivanje u ekologiji. Razvoj umjetne inteligencije osigurao je tehnologije za upravljanje znanjem. Te nove tehnologije mogu se primjenjivati u raznim područjima ekologije, poput modeliranja i simuliranja, razvoja teorija, upravljanja prirodnim resursima, donošenja odluka i drugom.³⁹ Učinkovita zaštita okoliša uvelike ovisi o kvaliteti dostupnih informacija korištenih za donošenje prikladnih odluka.⁴⁰ ES su se zapravo pokazali kao zahvalan alat za donošenje takvih odluka, a njihov dizajn i izgradnju predstavili su N. Poch i suradnici.⁴¹ ES se može koristiti i kao alat koji omogućuje identifikaciju utjecaja na okoliš. Identifikacija je uz procjenu utjecaja na okoliš iznimno bitna u proučavanju utjecaja na okoliš općenito. U tu svrhu, izgrađen je ekspertni sustav baziran na geografskom informacijskom sustavu (eng. *geographic information system*).⁴² ES građeni su i u svrhu zaštite okoliša u rudarstvu.⁴³

Kako ekonomija sve više napreduje, tako primjetno raste i učestalost događaja štetnih za okoliš. Već je dobro poznato da je upravljanu hitnim (vanrednim) situacijama potreban sustav spremnosti. Statistika je pokazala da je u industrijaliziranim zemljama djelovanje u skladu sa sustavom spremnosti za vanredna stanja u okolišu smanjilo štetu za više od 90% u usporedbi sa slučajevima bez takvog sustava. Kroz istraživanja se utvrdilo da je za razvoj takvih sustava najbolja tehnologija zaključivanja temeljena na slučajevima⁴⁴ (eng. *Case-Based Reasoning*, CBR). CBR je popularna metoda zaključivanja koja koristi iskustva iz prethodno riješenih problema kako bi došla do rješenja trenutnog problema. Nedostatak CBR metode je to što njezin rad otežava nedovoljan broj slučajeva i teškoće u adaptaciji tih slučajeva. Iz tog razloga, CBR tehnologiju se pokušalo povezati s poboljšanim genetičkim algoritmom (eng. *Improved Genetic Algorithm*, IGA). Primjena prototipa CBR-IGA sustava testirana je na hipotetskoj situaciji curenja amonijaka u Shangaiju. Rezultati su pokazali da IGA može riješiti problem adaptacije i učinkovito proširiti bazu slučajeva. Sve više se raspravlja o budućim istraživanjima na tom području tj. o unošenju neuronskih mreža u kombinaciju kako bi se povećala brzina i točnost odgovora na hitne situacije u okolišu.

Kako bi se uvela ravnoteža u odnos zaštite prirode i zarade (iskorištavanjem prirodnih resursa) nastale su tzv. „usluge ekosustava“ (eng. *Ecosystem Services*). One osiguravaju

kohezivni znanstveni pristup mnogim mehanizmima kroz koje priroda doprinosi ljudskom blagostanju. Kako bi se ocijenile usluge ekosustava i njihova vrijednost prikazala ljudima, s ciljem lakšeg i učinkovitijeg donošenja odluka vezanih uz okoliš, razvijen je novi alat naziva ARIES (eng. *Artificial Intelligence and Ecosystem Services*). ARIES pomaže otkriti, razumjeti i izmjeriti okolišnu imovinu (eng. *environmental assets*), te otkriti koji faktori utječu na vrijednost te imovine prema potrebama i prioritetima tj. potražnji.⁴⁵

Zbog uređivanja te rudničkih i konstrukcijskih aktivnosti na zemlji koja je bila obrađivana (kultivirana), sve više i više tla se iskopava, premješta, odlaže i obnavlja. U mnogo slučajeva, takva obnovljena zemljišta pokazuju znakove strukturne degradacije poput prekompaktnosti i nakupljanja vode. Za ocjenu i procjenu fizikalne kvaliteta takvog tla ne postoji mnogo metoda pa se tom problemu pokušalo pristupiti sa stajališta umjetne inteligencije. Razvijen je hibridni model, ekspertni sustav baziran na neizrazitoj logici (eng. *fuzzy logic expert system*) koji dopušta evaluaciju potencijalne produktivnosti biljaka izraslih na obnovljenom tlu, mjerenjem fizikalnih parametara tla.⁴⁶ Eksperimenti provedeni na tom modelu pokazali su dobre rezultate i dokazali da je hibridni model dobar za procjenu kvalitete tla, uzimajući u obzir sve neodređenosti i dvosmislenosti koje su obavezno uključene u takve zadatke.

Korištenjem baze podataka 1987. razvijena je „obitelj“ ekspertnih sustava nazvana HazardExpert koja je predviđala toksičnost spojeva u sedam različitih razreda toksičnosti (onkogenost, mutagenost, teratogenost, iritacija, osjetljivost, imunotoksičnost, neurotoksičnost). Za predviđanje toksičnih efekata metabolita, takvi računalni programi analiziraju njihovu strukturu, a zatim pretražuju toksične fragmente kojima pripisuju određenu očekivanu toksičnost jer toksičnost molekule najviše ovisi o njezinoj strukturi. HazardExpert kombiniran je i s umjetnim neuronskim mrežama.⁴⁷ Metode učenja svojstvene umjetnoj inteligenciji koriste se i za konstrukciju QSAR modela (eng. *Quantitative Structure-Activity Relationship*) kako bi se predvidjela biorazgradivost kemikalija u okolišu. Neke kemikalije u okolišu ne izazivaju onečišćenja, ali njihovim raspadom (razgradnjom) nastaju produkti koji potencijalno mogu naštetiti okolišu. Stoga je QSAR metoda, koja na temelju strukture spoja pokušava odrediti svojstva tog spoja, nadasve zanimljiv alat za identifikaciju i razumijevanje ključnih svojstava kemikalija i mehanizama u procjeni biorazgradivosti i prema tome, moguće kontaminacije okoliša.⁴⁸

3.1. Primjena umjetne inteligencije u zaštiti voda i vodenih ekosustava

3.1.1. Uređaji za pročišćavanje otpadnih voda

Danas se sve veći naglasak stavlja na zaštitu okoliša pa tako svako industrijsko postrojenje, gradovi i ruralne sredine moraju voditi brigu u tome što ispuštaju ili emitiraju u okoliš. Jedan od značajnih načina zaštite okoliša je obrada otpadnih voda. Odabir optimalnih načina sakupljanja i uređaja za obradu tih otpadnih voda kompleksan je proces, naročito u ruralnim sredinama. Kako je danas zakonima propisana obaveza provedbe obrade otpadnih voda u naseljima, praksa je pokazala da pri odabiru načina pročišćavanja najveću ulogu ima financijski kriterij. U te kriterije je uračunata gradnja, upravljanje i održavanje sustava. Konvencionalni pristup proračunu troškova pojedinih tipova postupaka obrade otpadnih voda znatno komplicira odabir optimalnog rješenja jer je potrebno uložiti veliki trud u proračun veličina i dimenzija postrojenja i u konačnici sve to sagledati iz financijskog aspekta. Kako bi se odabralo optimalno rješenje, taj postupak mora biti napravljen za svaki oblik obrade kako bi se različita rješenja mogla usporediti. To sve zahtijeva puno vremena, truda i veći stupanj stručnosti. Kako bi se olakšao i ubrzao taj postupak, analizirana je mogućnost korištenja umjetnih neuronskih mreža. Kreirana je mreža NENECOS (eng. *NEurol Network for approximate Estimation of COst of wastewater Systems*) koja omogućava jednostavnu, brzu i primjereno točnu procjenu cjelokupnih troškova. Ograničenje NENECOS-a je mogućnost približne procjene samo za manja ruralna naselja s maksimalno 500 ekvivalent stanovnika.⁴⁹

ANN mogu se koristiti i za predviđanje rada budućeg postrojenja za pročišćavanje otpadnih voda na temelju starijih podataka. U Egiptu je proveden eksperiment u kojem su za učenje neuronske mreže korišteni podaci s velikog uređaja u Kairu. Glavni parametri koji su se uvrštavali su kemijska potrošnja kisika (KPK) i suspendirana suha tvar. Zatim je konstruirano manje postrojenje u laboratoriju i kroz 10 mjeseci se skupljalo podatke koji su služili za provjeravanje dobivenog modela. Metoda se pokazala uspješnom.⁵⁰

Za uređaj za pročišćavanje otpadnih voda vezani su i neki drugi problemi. Uređaji za obradu otpadnih voda jedan su od najvećih izvora onečišćenja zraka neugodnim mirisom. Zbog sve veće brige o okolišu, javlja se sve veći broj pritužbi zbog neugodnih mirisa koji mogu nastati tokom procesa koji se odvija bez prisutstva kisika ili zbog velikog vremena zadržavanja otpadne vode. Kako bi se odredile granice i postavili zakonski standardi, moraju se definirati povjerljive i učinkovite metode mjerenja neugodnog mirisa. U svrhu karakterizacije mirisa koristio se elektronski nos, uređaj koji oponaša način djelovanja olfaktivnog sustava s ciljem prepoznavanja mirisa. Postavljeno je 12 nosova koji su skupljali

uzorke s 12 lokacija unutar postrojenja (uređaja). Ti podaci su obrađeni umjetnom neuronskom mrežom istreniranom BP algoritmom kako bi se ocijenila sposobnost elektronskog nosa za skupljanje uzoraka mirisa. Također se umjetnom neuronskim mrežom pokušala naći poveznica između neugodnog mirisa i BPK. Rezultati su pokazali da je korelacija između uzoraka mirisa i BPK veća od 90%. Također je utvrđeno da je elektronski nos dobar način za klasifikaciju uzoraka mirisa otpadne vode te da će se moći koristiti kao indikator u monitoringu biokemijske aktivnosti otpadnih voda.⁵¹

3.1.2. Praćenje kvalitete voda

Zanimljiv primjer korištenja neuronskih mreža za modeliranje u okolišu nalazi se u Australiji. Tamo su napravljena dva istraživanja: prognoziranje slanosti rijeke Murray kod mosta Murray četrnaest dana unaprijed i predviđanje učestalosti pojave mikroorganizma *Anabaena spp.* iz grupe cijanobakterija u istoj rijeci, četiri tjedna unaprijed.⁵² Rijeka Murray je veliki južnoaustralski izvor vode. Primijetilo se da rijeka doživljava visoku razinu saliniteta i da je sklona razvoju velikog broja toksičnih modrozelenih algi (cijanobakterija). Predviđanjem slanosti i koncentracije algi, čak nekoliko tjedana unaprijed, mogu se primijeniti razne strategije kako bi se ublažili problemi kvalitete vode.

Poznato je da određene biljne i životinjske vrste mogu biti indikatori kvalitete vode i zraka, odnosno okoliša u kojem žive. U većini slučajeva, ta je pojava empirijski određena. U Koreji su se iz rijeke Suyong vadile ličinke *Chironomus samoensis* kako bi se ispitao njihov odgovor na tretman karbofuranom (insekticidom) pri niskim koncentracijama, te kako bi se ispitala mogućnost korištenja sustava umjetne inteligencije za monitoring kvalitete vode. Karbofuran je visokotoksičan spoj za riječne beskralješnjake. Praćeno je dvodimenzionalno kretanje ličinki prije i poslije dodavanja karbofurana u vodu. Varijable dobivene temeljem analize kretanja korištene su kao ulazne vrijednosti za treniranje višeslojnog perceptrona. Tako istrenirana mreža pokazala je učinkovitu detekciju u uzorcima kretanja prije i poslije izloženosti insekticidu. Na taj način je demonstrirano da bi neuronske mreže (uz metode kojima se određuju ulazne varijable) bile koristan alat za automatski monitoring ponašanja (kretanja) u svrhu procjene kvalitete vode.⁵³

Ribe se često koriste kao indikatori kvalitete okoliša u vodenim ekosustavima. Takvi pokazatelji daleko su od idealnih, uglavnom jer se baziraju na pretpostavkama koje ponekad nisu točne. Takav pristup oslanja se na procjenu stručnjaka u odabiru mjerenja i određivanja ekološkog statusa. Pod pretpostavkom da niti jedna procedura u ocjeni ekološkog statusa ne može biti kompletno objektivna, treba osmisliti način na koji bi se najobjektivnije provela

optimizacija procesa ocjenjivanja. Iz tog razloga je u centralnoj Italiji dizajniran ekspertni sustav baziran na višeslojnom perceptronu, s jednostavnim sučeljem za lakši pristup "ne-tehničkim" osobama. Neuronska mreža rekonstruira stručnjakovo zaključivanje na temelju abiotičkih deskriptora i sastava skupina riba, dajući suglasnu procjenu ekološkog statusa.⁵⁴

Analize vode u rijeci Ganges u Indiji pokazale su visok stupanj onečišćenosti što je indiciralo na hitnu potrebu za mjerama smanjenja onečišćenja. Primijenjen je hibridni model samoorganizirajućih mapa i umjetnih neuronskih mreža kako bi se predvidjeli glavni izvori onečišćenja.⁵⁵

Kako se urbanizacija još uvijek odvija, tako se nastavlja smanjenje kvalitete vode za opskrbu. U cilju minimalizacije štete koja sve više prijeti vodenim ekosustavima, mora se proučiti šira slika problema. Postoji ogroman broj kompleksnih i međusobno povezanih procesa koji utječu na kvalitetu kišnice tj. oborina. Procesi uzorkovanja i mjerenja nekih osnovnih parametara dosta su skupi, a njihov nedostatak onemogućuje stvaranje modela za predviđanje kvalitete. U SAD-u se najboljim rješenjem za predviđanje kvalitete kišnice pokazala umjetna neuronska mreža. Njome se analiziralo pet parametara (KPK, olovo, suspendirane čvrste tvari, ukupni dušik i ukupni fosfor). Metoda je uspoređena s metodom linearne regresije i pokazala je nešto lošije rezultate.⁵⁶

Model umjetne neuronske mreže napravljen je za brzu procjenu i predviđanje odabranih parametara kvalitete obalnih voda u Singapuru. Procjenjivali su se parametri poput slanosti, temperature, količine otopljenog kisika, količine nutrijenata i klorofila.⁵⁷

Otopljeni kisik je jedan od ključnih parametara u analizi kvalitete vode. On je pod utjecajem BPK, procesa nitrifikacije, reaeracije, sedimentacije, fotosinteze, te temperature i drugih parametara. Iz tog razloga teško je procijeniti i predvidjeti količinu otopljenog kisika, a dostupne metode su komplicirane i troše puno vremena. Umjetne neuronske mreže omogućile su procjenu mjesečnih vrijednosti otopljenog kisika na temelju podataka o nitratima, nitritima, temperaturi i BPK).⁵⁸

3.1.3. Kontrola onečišćenja voda procjeđivanjem i ispiranjem

Veliki potencijalni utjecaji na okoliš povezani su s procjeđivanjem vode kroz odlagališta čvrstog otpada. To ima najveći utjecaj na onečišćenje podzemnih i površinskih voda. Procjeđivanje se događa kada se kapljevina (kišnica, otopljeni snijeg ili otpad sam po sebi) procijedi kroz odlagališne jedinice i dođe do dna ili rubova odlagališta. Prolaskom kroz otpad, kapljevina transportira širok spektar kemikalija do krajeva odlagališta. Kada ta procijeđena kapljevina dospije u okoliš, predstavlja veliki problem, te je stoga kritični element

kod dizajniranja odlagališta osigurati mogućnosti upravljanja procjedom tj. njegovo skupljanje i zbrinjavanje. Najvažniji meteorološki čimbenici koji utječu na protok vode kroz smeće i brzinu nakupljanja procjeda su količina oborina, temperatura zraka i relativna vlažnost. U Istambulu je osmišljena je osmišljena prognostička metoda za ocjenjivanje i upravljanje procjednim protokom. Metoda je bazirana na neuronskoj mreži NN-LEAP (eng. *neural network – based leachate prediction model*) koja koristi BP algoritam za učenje.⁵⁹ Nakon treniranja mreže, ona na temelju meteoroloških podataka može predvidjeti protoke kroz odlagalište. Konačno, prema tim predviđanjima (izlaznim vrijednostima iz neuronske mreže) poduzimaju se određene strateške mjere kako ne bi došlo do procjeđivanja u okoliš.

Rezervoari vode (spremnici podzemnih voda) skloni su kontaminaciji zagađivalima iz industrije, kućanstava i poljoprivrede. Izvori onečišćenja podzemne vode su razni i uključuju slučajna izlivanja, odlagališta, cjevovode, poljoprivredne aktivnosti i još mnogo toga. Od tih izvora, oni povezani s poljoprivrednim aktivnostima znaju uzrokovati onečišćenja u velikoj mjeri posebno zbog gnojiva (sadrže nitrata) i raznih kancerogenih supstanci pronađenih u pesticidima. Nitrat je najčešći zagađivač pronađen u rezervoarima pitke vode. On se zbog svoje visoke mobilnosti lako ispire iz tla i dolazi u podzemne vode. Povišene koncentracije nitrata u pitkoj vodi povezane su s nizom zdravstvenih problema: uzrokuju methemoglobinemiju i povezuje ih se s nastankom tumorskih stanica u probavnom traktu.

Zbog visoke rasprostranjenosti izvora nitrata teško je procijeniti kvalitetu vode i kvantitativno odrediti količinu nitrata koji se ispire iz tla te je stoga potrebno odrediti model prema kojem bi se to moglo izračunati, a osim toga dobro bi bilo smisliti model prema kojem bi se odredilo koliko nitrata ima u tlu kako bi se optimalno trošila gnojiva. Poteškoće koje se javljaju kod razvoje takvih modela su potreba za velikom količinom podataka i potreba za velikom količinom znanja o fizikalnim, kemijskim i biološkim procesima. Kako bi se nadišle poteškoće, mnogi istraživači se uspješno koristili umjetne neuronske mreže.⁶⁰ U Engleskoj su umjetne neuronske mreže korištene za procjenu kontaminiranosti privatnih bunara nitratom. Uspješnost predviđanja je bila 50%.⁶¹ Umjetnom neuronskom mrežom pokušalo se simulirati ispiranje nitrata u podzemnu vodu sa zadane površine. Cilj simulacije bio je na temelju ulaznih parametara odrediti koji sustav upravljanja nitratom je najpogodniji. Rezultati su pokazali da npr. sadnja kukuruza zajedno s ljučjom može smanjiti ispiranje nitrata za 50%.⁶²

Za simulaciju prostorne distribucije nitrata u zalihama vode, može se koristiti i modularna neuronska mreža (eng. *modular neural network*) kao posebna vrste umjetnih neuronskih mreža. Ona fizički dijeli problem na jednostavnije zadatke i tako ga lakše rješava.⁶⁰

3.1.4. Ostali načini zaštite voda i vodenih ekosustava

Cvjetanje mora

Cvjetanje mora je ubrzan rast i akumulacija algi (fitoplanktona) u vodenim sustavima. U suptropskim obalnim vodama Hong Konga, cvjetanje mora i crveno obojenje mora (prekomjerno razmnožavanje mikroorganizama iz skupine *Dinoflagellate*) česta su pojava pa su toga često i predmet istraživanja. Cvjetanje mora često dovodi do ozbiljnog trošenja otopljenog kisika, što pak dovodi do ugibanja riba i ostalih morskih organizama. Kroz protekla dva desetljeća, nekoliko puta se dogodio masovni pomor ribe zbog cvjetanja mora i nedostatka kisika (bila su pogođena i uzgajališta ribe što je uzrokovalo značajne ekonomske gubitke). Iz tih razloga stvorila se potreba za predviđanjem uistinu nepredvidivog prirodnog procesa. Za to se najboljim rješenjem pokazalo predviđanje pomoću umjetnih neuronskih mreža. Često korišteni BP algoritam je zadužen za učenje neuronske mreže. Modeliranje je bazirano na opsežnim podacima o kvaliteti vode u razdoblju od 18 godina (1982. – 2000.) i na četverogodišnjem setu podataka o količini fitoplanktona (1996. – 2000.) mjerenim na dvije različite lokacije. Pošto je cilj predvidjeti cvjetanje mora, kao ulazne parametre potrebno je uzeti sve faktore koji utječu na rast i razmnožavanje fitoplanktona. Rezultati su pokazali da će koncentracija fitoplanktona ovisiti najviše o koncentraciji fitoplanktona koja je bila prethodna 1-2 tjedna.⁶³

Praćenje količine suspendirane tvari

Informacije o opterećenju vode suspendiranim čvrstim tvarima bitne su za upravljanje vodama i zaštitu okoliša. Opterećenje suspendiranim čvrstim tvarima za tri rijeke u SAD-u (Mississippi, Missouri i Rio Grande) procijenjeno je korištenjem umjetnih neuronskih mreža, točnije višeslojnim perceptronom s BP pravilom učenja. Procjena se vršila korištenjem prijašnjih dnevnih i tjednih hidroklmatoloških podataka. Takav pristup može se potencijalno koristiti za smanjenje učestalosti skupih postupaka analize.⁶⁴

Predviđanje nastanka nusprodukata u postupku dezinfekcije vode

U procesima klorinacije vode u cilju dezinfekcije može doći do stvaranja nusprodukata, najčešće trihalogenmetana (THM) koji predstavljaju visoki rizik za ljudsko zdravlje zbog kancerogenih svojstava. Kako bi ih se kontroliralo, potrebno je znati u kojoj mjeri se nalaze u vodi. Određivanje THM-a laboratorijskim analizama mukotrpan je i skup proces koji oduzima puno vremena. Stoga će velika pomoć biti razvoj modela za predviđanje nastanka THM-a u

kloriranim vodama. Za taj zadatak razvijene su tri metode umjetne inteligencije bazirane na umjetnim neuronskim mrežama i genetskom programiranju. Za razvoj modela korišteni su podaci iz literature, a šest parametara je korišteno kao ulaz u mrežu (pH, temperatura, otopljeni organsku ugljik, doza klor, koncentracija bromida i kontaktno vrijeme). Opće sposobnosti i sposobnosti predviđanja mreža ocijenjeni su statističkim testovima, a rezultati su otkrili da su svi modeli podjednako dobri u predviđanju nastanka THM-a tijekom postupka dezinfekcije vode.⁶⁵

Ponašanje plutajućih barijera pod utjecajem valova, struja i vjetra

Plutajuće zatvorene barijere su esencijalne naprave za prevenciju, ili na najmanju ruku, za smanjenje obalnog onečišćenja. Njihova zadaća je zadržati zagađivala i zaustaviti njihovo širenje. Danas se morem (tankerima) preveze i do 100 milijuna tona nafte dnevno. Unatoč konstantnim povećanjima sigurnosti i pooštavanja sigurnosnih mjera, gotovo je nemoguće svesti rizik od izlivanja nafte na minimum. Osim nafte, u moru se može naći raznog plutajućeg otpada stvorenog ljudskim nemarom.

Iako barijere imaju veliko značenje, problematika njihovog ponašanja se ne shvaća ozbiljno. One su jedino korisne ako pod utjecajem valova, struja i vjetra ne propuštaju sadržaj. No to se ipak događa i to na načina da sadržaj pobjegne ispod barijere (zbog valova i struje) ili prijeđe preko (zbog vjetra). Navedeno propuštanje sadržaja se najčešće dogodi ako su dimenzije barijere premalene tj. ako je gustoća zagađivača jako velika. Zato je razvijen model umjetne inteligencije s fokusom na učinkovit nacrt plutajućih barijera. Taj model je višeslojni perceptron koji je učen BP algoritmom. Skup podataka je dobiven kroz opširne laboratorijske postupke u kojima je sedam modela barijera podvrgnuto brojim kombinacijama valova i struja. Podaci su nasumično podijeljeni u dva skupa, jedan za učenje, a drugi za testiranje modela. Ulazne i izlazne vrijednosti određene su na temelju dimenzijske analize i laboratorijskih rezultata. Od brojnih isprobanih modela, najbolji se pokazao onaj s dva skrivena sloja s po dvanaest neuronskih jedinica u svakom. Ovim eksperimentom se pokazalo da umjetna inteligencija može znatno pomoći u izradi optimalnog nacrta i dimenzija plutajućih barijera.⁶⁶

3.1.5. Onečišćenje toksičnim metalima

Ubrzana industrijalizacija ozbiljno pridonosi ispuštanju teških metala u vodu i okoliš. Rastuća koncentracija teških metala u izvorima vode predstavlja veliku opasnost za zdravlje. Adsorpcija je jedna od metoda učinkovitog uklanjanja metalnih iona iz vode, a adsorpcijske

izoterme su jedan od načina izražavanja ravnotežne veze između adsorbata i adsorbenta. Konvencionalni matematički modeli koji opisuju takvu ravnotežu vrlo često nisu dobri zbog kompleksnosti i nelinearnosti u procesu adsorpcije. Umjetne neuronske mreže mogu su korak bliže rješavanju takvog problema. Za adsorpciju nikla i kroma na sintetski adsorbent razvijena su tri modela s različitom strukturom za procjenu učinkovitosti adsorpcije, ravnotežnih koncentracija i količinu adsorbirane tvari po jedinici adsorbenta. Ulazne varijable najčešće su doza adsorbenta, pH, vrijeme kontakta, temperatura, početna koncentracija. Rezultati uspoređeni s podacima za testiranje pokazuju da ovakav pristup vrši dobru primjenu.⁶⁷ Postoje i razvijeni modeli za adsorpciju kroma.⁶⁸ Umjetne neuronske mreže mogu poslužiti i kod uklanjanje arsena (As^{3+}), jednog od najtoksičnijih metala, a razvijeni modeli mogu predvidjeti učinkovitost adsorpcije s prihvatljivom preciznošću.⁶⁹

Teški metali, kao što je već navedeno, imaju toksična svojstva, ali imaju i tendenciju akumulacije u prehrambenom lancu. Zbog toga čak i malim koncentracijama mogu biti štetni za okoliš i svrstava ih se u grupu okolišnih otrova. Al^{3+} , Co^{2+} i Ni^{2+} su metalni ioni koji se simultano pojavljuju u širokom spektru uzoraka, bilo okolišnih, industrijskih ili geoloških. UV-VIS spektrofotometrijske tehnike su jedne od najkorisnijih analitičkih metoda zbog svoje brzine, jednostavnosti i primjenjivosti. No, paralelno određivanje navedenih metalnih iona korištenjem uobičajenih spektrofotometrijskih metoda je teško, zato što se apsorpcijski spektri najčešće preklapaju. Zbog toga nije moguća kvantitativna analize uporabom te metode. U tu svrhu primijenjen je ANFIS sustav čiji je cilj pronaći model koji će točno povezati ulaze (rezultate spektrofotometrijske analize tj. podatke o apsorpciji) sa željenim vrijednostima (koncentracijom). Rezultati analize na laboratorijski primijenjenim otopinama, pokazali su dobre rezultate što indicira na korisnost ovakve metode u određivanju navedenih iona u sintetskim i prirodnim matricama.⁷⁰

Veliko narušavanje kvalitete vode uzrokuje istraživanje bakra u rudniku Sarcheshmeh u Iranu zbog nakupljanja kiselina iz rudnika. Oksidacija sulfidnih minerala, posebno pirita izloženog atmosferskom kisiku tijekom ili nakon aktivnosti u rudniku, zakiseljava vodu. Niski pH takvih otopina uzrokuje daljnje otapanje i procjeđivanje ostalih metala (Ni, Mn, Zn, Cu, Cd i Pb) u vodene sustave, što ima štetan utjecaj na život u vodenim ekosustavima i okoliš koji ga okružuje. Ti toksični metali najčešće završe u rijeci Shur. Predviđanje koncentracije toksičnih metala u toj rijeci je korisno za razvoj valjanih sanacijskih metoda i metoda monitoringa. Iz tog razloga osmišljen je umjetno inteligentni model za predviđanje koncentracije željezovih i niklovihih iona, SVM model (eng. *support vector machine*).⁷¹

3.2. Predviđanje koncentracija zagađivača zraka

Onečišćenje zraka rastući je problem. Štetni učinci zagađivača zraka na zdravlje dobro su poznati. Na mjestima na kojima geografski i meteorološki uvjeti onemogućuju dobru cirkulaciju zraka, i na mjestima s velikom populacijom ljudi tj. u gradovima koji nisu planski izgrađeni, koncentracija zagađivača u zraku može postati iznimno visoka. Ako bi bilo moguće par dana unaprijed predvidjeti trenutke kada bi moglo doći do takvih situacija, mogle bi se poduzeti učinkovitije mjere zaštite ljudi. Kontrola onečišćenosti zraka je potrebna kako takve situacije vremenom ne bi postale sve gore. U zadnjih nekoliko godina, sve više metoda umjetne inteligencije se koristi za postupanje s problemima u okolišu. Tako su razvijene umjetne neuronske mreže za predviđanje emisija i koncentracija najčešćih zagađivača zraka poput ozona (u niskim slojevima atmosfere), lebdeći čestica, CO, NO₂, SO₂.⁷² Za procjenu i predviđanje kvalitete zraka, također se koristi i neizrazita logika (Mexico City).⁷³ Razvijene su metode za procjenu emisije CO, pomoću umjetnih neuronskih mreža i ANFIS-a⁷⁴, metode za procjenu NO₂ koje se temelje na umjetnim neuronskim mrežama⁷⁵ ili kombinaciji analize glavnih komponenti i RBF mreža.⁷⁶ ANFIS je također korišten za procjenu koncentracije SO₂, koji zajedno s NO₂ i O₃ stvara smog, a i jedan je od glavnih uzročnika kiselih kiša.⁷⁷

3.2.1. Ozon

Troposferski ozon kada se nalazi u troposferi je koristan jer apsorbira ultraljubičasto sunčevo zračenje, no kada se u značajnim količinama nađe u nižim slojevima atmosfere, ima negativan utjecaj na okoliš i zdravlje ljudi. Poznato je da je ozon snažan oksidans i jedan od glavnih sastavnica fotokemijskog smoga kojeg se smatra jednim od ključnih zagađivača koji smanjuju kvalitetu zraka uzrokujući ozbiljne zdravstvene tegobe i uništavanje vegetacije i ratarskih usjeva. Ozon je sekundarni zagađivač zraka zato što nije direktno emitiran u atmosferu. Upravo iz tog razloga predstavlja ozbiljni ekološki problem kojeg je teško predvidjeti i kontrolirati. Visoka koncentracija ozona snažno je povezana s meteorološkim stanjem i do nje obično dolazi za sunčanih dana kada primarni zagađivači (dušikovi oksidi i nemetanski ugljikovodici) fotokemijski reagiraju potaknuti snažnom solarnom radijacijom i visokim temperaturama.^{78,79}

Kuvajt je država smještena na sjeveru Arapskog jezera i većina zemlje je pustinja. Klima je tipično suha s vrućim ljetima, a temperatura može doseći i 50°C. Zbog gustog prometa, velika količina zagađivača biva emitirana u atmosferu. Zbog takvih uvjeta bilo je potrebno smisliti kako predvidjeti i pratiti koncentraciju ozona. U tu svrhu pokušalo se

poslužiti umjetnim neuronskim mrežama.⁷⁸ Razvijeni su modeli neuronskih mreža kako bi se predvidjela koncentracija ozona, kao funkcija meteoroloških uvjeta i raznih parametara kvalitete zraka. Umjetne neuronske mreže pogodne su za uporabu zbog sposobnosti učenja na starim podacima, te zbog sposobnosti modeliranja nelinearnih podataka. U konkretnom slučaju, mreža je modelirana uzimanjem podataka o kvaliteti zraka kada su koncentracije ozona bile najveće. Trinaest varijabli unošeno je na ulaz u mrežu, dok je vrijednost na izlazu pokazivala koncentraciju ozona. Otkriveno je da najviše utjecaja na koncentraciju ozona imaju primarni zagađivači pa zatim meteorološki uvjeti od kojih najviše relativna vlažnost, a najmanje sunčevo zračenje.

U Kuvajtu je također korištena kombinacija dviju metoda: umjetne neuronske mreže i analize glavnih komponenti (eng. *principal component analysis*).⁷⁹ Takav kombinirani pristup se koristi radi poboljšanja točnosti u predviđanju ozona. Analiza glavnih komponenti vrlo je široko korišten postupak za analizu podataka. Koristi se kako bi se istaknuli najprikladniji podskupovi varijabli, a neuronskom mrežom se obrađuju tako dobiveni podaci. Iako je ANN bolji pristup, u kombinaciji te dvije metoda pokazuju još bolje rezultate.

Veliki problemi zbog povišenih koncentracija ozona javljaju se u Parizu. Tamo je za predviđanje korišten višeslojni perceptron, a prethodno previđene koncentracije ozona poslužile su kao ulazne varijable (uz meteorološke uvjete i NO₂).⁸⁰

3.2.2. Lebdeće čestice (PM₁₀ i PM_{2,5})

Kroz zadnjih petnaest godina onečišćenje zraka u Santiagu, glavnom gradu Čilea, izazivalo je sve veću zabrinutost. Visoke koncentracije zagađivača nakupljaju se zbog otežanog provjetravanja uzrokovanog geografskim položajem grada. Zimi je provjetravanje još otežanije zbog povišenog atmosferskog tlaka i slabih vjetrova. Tijekom tog razdoblja prati se dvadesetčetverosatno kretanje prosječne koncentracije lebdećih čestičnih tvari s promjerom manjim od 10 μm (eng. *particulate matter*, PM₁₀) te se koristi kao indikator kvalitete zraka. Jedan od najvećih izvora PM₁₀ je cestovni promet, a slijede ga razne industrijske djelatnosti i toplane. Takve čestice se zbog svoje veličine lako mogu unijeti u respiratorni sustav i uzrokovati opasne respiratorne bolesti. Zato je razvijen integrirani model umjetne neuronske mreže za prognoziranje maksimalnog dnevnog prosjeka koncentracije PM₁₀, jedan dan unaprijed.⁸¹ Ulazne varijable korištene za stvaranje modela su izmjerene koncentracije do 19 sati, te izmjerene vrijednosti meteoroloških parametara. Izlazna varijabla pokazuje maksimalnu koncentraciju za navedeni dan. Najveća koncentracija između pet predviđenih (podaci prikupljeni na pet stanica od kojih svaka radi neovisno) definira kvalitetu zraka.

Postoje tri razreda kvalitete zraka i svaki ima svoj interval koncentracija PM₁₀: *dobra, loša i kritična*. Prema tome, kvaliteta zraka biti će definirana prema tome u kojem intervalu će se naći najveća predviđena koncentracija. Prognozirane vrijednosti dobivene umjetnim neuronskim mrežama pokazale su bolje rezultate od nekih drugih metoda (poput linearnog modeliranja), te se pokazalo da je odabir ulaznih varijabli jako bitan.

U Santiagu je također razvijena neuronska mreža za predviđanje koncentracije lebdećih čestica promjera 2,5 μm.⁸² U Kini je s istim ciljem korišten višeslojni perceptron.⁸³ Ulazne varijable su većinom prethodno izmjerene koncentracije čestica i meteorološki parametri, a kao izlazna vrijednost se dobije prosječna vrijednost za PM₁₀ za naredni dan. Razvijena je i hibridna metoda koja kombinira analizu putanje zračne mase (eng. *air mass trajectory analysis*) i valne transformacije (eng. *wavelet transformation*) kako bi se poboljšala točnost predviđanja umjetnih neuronskih mreža. Takav model primijenjen je za monitoring onečišćenja zraka u Pekingu i drugim gradovima.⁸⁴ Još jedna hibridna metoda se koristi za poboljšanje točnosti predviđanja kvalitete zraka i to u gradu Temuco, u Čileu, gdje je izgaranje drva za grijanje stambenih prostora veliki izvor onečišćenja. Metoda je kombinacija umjetnih neuronskih mreža i ARIMA (eng. *Autoregressive Integrated Moving Average*). Model ARIMA ima ograničene sposobnosti predviđanja zbog nemogućnosti predviđanja ekstremnih koncentracija, dok neuronske mreže mogu prepoznati nelinearne uzorke, uključujući ekstreme. Hibridni model je uspio prognozirati 80 – 100% kriznih situacija i omogućio prevenciju vanrednog stanja.⁸⁵

3.2.3. CO₂

CO₂ je ispušni plin koji nastaje izgaranjem fosilnih goriva i jedan je od najčešćih stakleničkih plinova prisutnih u atmosferi. Klimatske promjene koje nastaju zbog emisije CO₂ u atmosferu postale su važan i ozbiljan problem. Zato je poželjno pronaći model po kojem bi se mogla predvidjeti emisija CO₂ na temelju potrošnje različitih energenata. Efikasan način za rješavanje takvih zadataka može se ostvariti uporabom umjetnih neuronskih mreža.⁸⁶ Kao ulazni parametri uzimaju se količina nafte, zemnog plina, ugljena i primarna potrošnja energije. Predloženi model korišten je za procjenu emisije CO₂ na godišnjoj bazi. Podacima iz razdoblja od 1982. do 2000. godine mreža je istrenirana (naučena), a podacima od 2003. do 2010. testirana. Iz dobivenih rezultata vidljiv je vrhunski rad i dokazana je visoka učinkovitost umjetnih neuronskih mreža kao alata za rješavanje problema zagađivača koji utječu na klimu i klimatske promjene.

4. ZAKLJUČAK

Umjetna inteligencija jednostavan je alat primjenjiv u zaštiti okoliša, što je prikazano u ovome radu. Korištenje umjetne inteligencije može znatno smanjiti financijske izdatke koji predstavljaju bitan faktor u zaštiti okoliša te može minimalizirati ljudske pogreške i pomoći u donošenju što boljih odluka. Premda je ovo još uvijek mlado područje istraživanja, umjetne inteligencija već sada nalazi široku primjenu u zaštiti okoliša, ali i ostavlja dosta prostora za unaprjeenje.

Prikazane metode možda ponekad ne ulijevaju previše nade zbog prisutne nepreciznosti u analizama, procjenama i predviđanjima, no primarni cilj umjetne inteligencije je asistencija već postojećim metodama zaštite kako bi se takvi postupci ubrzali, optimirali i kako bi se pospješila njihova učinkovitost. Istraživanja u tom smjeru nadasve su dobrodošla i potencijalno mogu donijeti revoluciju u području zaštite okoliša i znanosti o okolišu općenito.

5. LITERATURA

1. S. J. Russell, P. Norvig: *Artificial Intelligence: A Modern Approach*; New Jersey, (1995)
2. S. L. Tanimoto: *The Elements of Artificial Intelligence (An Introduction using LISP)*; Seattle, (1987)
3. C. S. Krishnamorthy, S. Rajeev: *Artificial Intelligence and Expert Systems for Engineers*; CRC Press, Boca Raton, SAD (1996)
4. D. Graupe: *Principles of Artificial Neural Networks (2nd Edition)*; World Scientific Publishing Co. Pte. Ltd., Chicago, (2006)
5. L. C. Jain, N. M. Martin: *Fusion of Neural Networks, Fuzzy Systems and Genetic Algorithms: Industrial Applications*; CRC Press, Boca Raton, SAD (1998)
6. M. Novak Stankov: *Molecular Modeling and Artificial Intelligence in Development of Ion Chromatographic Methods*; Zagreb (2015)
7. R. Szeliski: *Computer Vision: Algorithms and Applications*; Springer, Washington (2010)
8. D. Partridge: *Artificial Intelligence and Software Engineering – Understanding the Promise of the Future*; AMACOM, New York (1998)
9. <http://www.enciklopedija.hr/natuknica.aspx?id=25317> (10. Srpnja 2015.)
10. ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ea072_2s06/notas_de_aula/Lecture02.pdf (13.srpnja 2015.)
11. <http://www.omandev.net/2007/07/expert-system-and-knowledge-based-systems/> (14.srpnja 2015.)
12. D. Grundler: *Evolucijski algoritmi (I) – Pobude i načela*; Zagreb (2001)
13. D. Ashlock: *Evolutionary Computation for Modeling and Optimization*; Springer, Guelph (2005)
14. C. Colby: *Introduction to Evolutionary Biology. Version 2* [Last Update: January 7, 1996] <http://www.talkorigins.org/pdf/faq-intro-to-biology.pdf> (16.srpnja 2015.)
15. I. Petrović, N. Perić: *Inteligentno upravljanje sustavima*; Zagreb (2008)
16. B. Kröse, P. van der Smagt: *An Introduction to Neural Networks*; Amsterdam, (1996)
17. https://www.spsc.tugraz.at/sites/default/files/lecturenotes_3.pdf (1. rujna 2015.)
18. M. J. L. Orr: *Introduction to radial basis function Networks*; Edinburgh (1996)

19. R. Rojas: *Neural Networks*; Springer-Verlag, Berlin, (1996)
20. D. E. Rumelhart, D. Zipster: *Feature Discovery by Competitive Learning*; Cognitive Science **9**, (1987) 75-11
21. F. Derroncourt: *Introduction to Fuzzy Logic*; Cambridge, SAD (2013)
22. http://powerlab.fsb.hr/dloncar/ch_2.pdf (23. srpnja 2015.)
23. J. S. R. Jang: *ANFIS: Adaptive-network-based fuzzy inference system*; Systems, Man and Cybernetics, IEEE Transactions on **23** (1993) 665-685
24. B. Khoshnevisan, S. Rafiee, M. Omid, H. Mousazadeh, P. Sefeedpari: *Prognostication of environmental indices in potato production using artificial neural networks*; Journal of Cleaner Production **52** (2013) 402-409
25. J. K. Lein: *Implementing remote sensing strategies to support environmental compliance assessment: A neural network application*; Environmental Science & Policy **12** (2009) 948-958
26. R. M. Molfinio, M. Zoppi: *A robotic system for underwater eco-sustainable wire-cutting*; Automation in Construction **24** (2012) 213-223
27. F. Kurtuluş, T. C. Ulu: *Detection of dead entomopathogenic nematodes in microscope images using computer vision*; Biosystems Engineering **118** (2014) 29-38
28. M. Nilashi, R. Zakaria, O. Ibrahim, M. Z. A. Majid, R. M. Zin, M. W. Chughtai, N. I. Zainal Abidin, S. R. Sahamir, D. A. Yakubu: *A knowledge-based expert system for assessing the performance level of green buildings*; Knowledge-Based Systems **86** (2015) 194-209
29. R. J. Kuo, Y. C. Wang, F. C. Tien: *Integration of artificial neural network and MADA methods for green supplier selection*; Journal of Cleaner Production **18** (2010) 1161-1170
30. C. Peng, X. Wen: *Recent Applications of Artificial Neural Networks in Forest Resource Management: An Overview*; American Association for Artificial Intelligence Technical, Menlo Park, California (1999)
31. P. Kourtz: *Artificial intelligence: a new tool for forest management*; Canadian Journal of Forest Research **20** (1990) 428-437
32. O. Antonić, D. Hatić, J. Križan, D. Bukovec: *Modelling groundwater regime acceptable for the forest survival after the building of the hydro-electric power plant*; Ecological Modelling **138** (2001) 277-288

33. M. Castelli, L. Vanneschi, A. Popovič: *Predicting Burned Areas of Forest Fires: An Artificial Intelligence Approach*; *Fire Ecology* **11** (2015) 106-118
34. Y. Safi, A. Bouroumi: *Prediction of Forest Fires Using Artificial Neural Networks*; *Applied Mathematical Sciences* **7** (2013) 271-286
35. J. R. Martinez-de Dios, B. C. Arrue, A. Ollero, L. Merino, F. Gómez-Rodríguez: *Computer vision techniques for forest fire perception*; *Image and Vision Computing* **26** (2008) 550-562
36. W. Sayers, D. Savić, Z. Kapelan, R. Kellagher: *Artificial intelligence techniques for flood risk management in urban environments*; *Procedia Engineering* **70** (2014) 1505-1512
37. Z. Shengkui, W. Chengmin, M. Li: *Application of artificial intelligence in earthquake forecasting*; *Peking* (477-481)
38. I. R. Noble: *The role of expert systems in vegetation science*; *Vegetatio* **69** (1987) 115-121
39. E. J. Rykiel Jr.: *Artificial intelligence and expert systems in ecology and natural resource management*; *Ecological Modelling* **46** (1989) 3-8
40. U. Cortés, M. Sanchez-Marre, I. Ceccaroni: *Artificial Intelligence and Environmental Decision Support Systems*; *Artificial Intelligence* **13** (2000) 77-91
41. M. Poch, J. Comas, I. Rodriguez-Roda, M. Sanchez-Marre, U. Cortés: *Designing and building real environmental decision support systems*; *Environmental Modelling & Software* **19** (2004) 857-873
42. C. M. Herero-Jiménez: *An expert system for the identification of environmental impact based on a geographic information system*; *Expert Systems with Applications* **39** (2012) 6672-6682
43. D. Rumenjak: *ES za zaštitu okoliša s primjenom u rudarstvu*; *Rudarsko-geološko-naftni zbornik* **25** (2012) 107-113
44. Z. Liao, X. Mao, P. M. Hannam, T. Zhao: *Adaptation methodology of CBR for environmental emergency preparedness system based on an Improved genetic Algorithm*; *Expert Systems with Applications* **39** (2012) 7029-7040
45. F. Villa, M. Ceroni, K. Bagstad, G. Johnson, S. Krivov: *ARIES (ARTificial Intelligenece for Ecosystem Services): a new tool for ecosystem services assessment, planning, and valuation*; *BioEcon* (2009)
46. M. Kaufmann, S. Tobias, R. Schulin: *Quality evaluation of restored soils with a fuzzy logic expert system*; *Geoderma* **151** (2009) 290-302

47. F. Darvas, Á. Papp, A. Allerdyce, E. Bonfenati, G. Gini, M. Tichý, N. Sobb, A. Citti: *Overview of Different Artificial Intelligence Approaches Combined with a Deductive Logic-based Expert System for Predicting Chemical Toxicity*; AAAI Spring Symposium: Predictive Toxicology of Chemicals, Stanford (1999) 94-99
48. B. Kompare: *Estimating environmental pollution by xenobiotic chemicals using QSAR (QSBR) models based on artificial intelligence*; Water Science and Technology **37** (1998) 9-18
49. D. Vouk, D. Malus, I. Halkijević: *Neural networks in economic analyses of wastewater systems*; Expert Systems with Application **38** (2011) 10031-10085
50. M. M. Hamed, M. G. Khalafallah, E. A. Hassanien: *Prediction of wastewater treatment plant performance using artificial neural network*; Environmental Modelling & Software **19** (2004) 919- 928
51. G. Onkin-Engin, I. Demir, S. N. Engin: *Determination of the relationship between sewage odour and BOD by neural networks*; Modelling & Software **20** (2005) 843-850
52. H. R. Maier, G. C. Dandy: *Neural Network Based Modelling of Environmental Variables: A Systematic Approach*; Mathematical and Computer Modelling **33** (2001) 669-682
53. C. K. Kim, I. S. Kwak, E. Y. Cha, T. S. Chon: *Implementation of wavelets and artificial networks to detection of toxic response behavior of chironomids (Chironomidae: Diptera) for water quality monitoring*; Ecological Modelling **195** (2006) 61-67
54. [13]M. Scardi, S. Cataudella, P. Di Dato, E. Fresi, L. Tancioni: *An expert system based on fish assemblages for evaluating the ecological quality of streams and rivers*; Ecologica Informatica **3** (2008) 55-63
55. M. Pandey, A. K. Pandey, A. Mishra, B. D. Tripathi: *Application of chemometric analysis and self Organizing Map – Artificial Neural Network as source receptor modeling for metal speciation in river sediment*; Environmental Pollution **204** (2015) 64-73
56. D. B. May, M. Sivakumar: *Prediction of urban stormwater quality using artificial neural networks*; Environmental Modelling & Software **26** (2009) 296-302
57. S. Palani, S. Y. Liong, P. Tkalic: *An ANN application for water quality forecasting*; Marine Pollution Bulletin **56** (2008) 1586-1597

58. B. Şengörür, E. Dogan, R. Koklu, A. Samandar: *Dissolved oxygen estimation using artificial neural network for water quality control*; Fresenius Environmental Bulletin **15** (2006) 1064-1067
59. F. Karaca, B. Özkaya: *NN-LEAP: A neural network-based model for controlling leachate flow-rate in municipal solid waste landfill site*; Environmental Modelling & Software **21** (2006) 1190-1197
60. M. N. Almasri, J. J. Kaluarachchi: *Modular neural networks to predict the nitrate distribution in ground water using the on-ground nitrogen loading and recharge data*; Environmental Modelling & Software **20** (2005) 851-871
61. C. Ray, K. Klindworth: *Neural networks for agrichemical vulnerability assessment of rural private wells*; Journal of Hydrologic Engineering **5** (2000) 162-171
62. J. W. Kaluli, C. A. Madramootoo, Y. Djebbar: *Modeling nitrate leaching using neural network*; Water Science and Technology **38** (1998) 127-134
63. J. H. W. Lee, Y. Huang, M. Dickman, A. W. Jayawardena: *Neural network modelling of coastal algal blooms*; Ecological Modelling **19** (2003) 179-201
64. A. M. Melesse, S. Ahmad, M. E. McClain, X. Wang, Y. H. Lim: *Suspended sediment load prediction of river systems: An artificial neural network approach*; Agricultural Water Management **98** (2011) 855-866
65. K. P. Singh, S. Gupta: *Artificial intelligence based modeling for prediction the disinfection by-products in water*; Chemometrics and Intelligent Laboratory Systems **114** (2012) 122-131
66. G. Iglesias, A. Castro, J. A. Fraguera: *Artificial intelligence applied to floating boom behavior under waves and Currents*; Ocean Engineering **37** (2010) 1513-1521
67. S. L. Pandharipande, A. R. Deshmukh: *Artificial neural network for modeling of adsorption of Ni(II) i Cr(VI) ions simultaneously present in Aqueous solution using adsorbent synthesized from aegel marmels fruit ahell and syzygium cumini seed*; International Journal of Advances in Engineering & Technology **6** (2013) 114-127
68. A. Kardam, K. R. Raj, J. K. Arora, M. M. Srivastava, S. Srivastava: *Artificial Neural Network Modeling for Sorption of Cadmium from Aqueous System by Shelled Moringa Oleifera Seed Powder as an Agricultural Waste*; J. Water Resource and Protection **2** (2010) 339-344

69. S. Mandal, S.S. Mahapatra, M. K. Sahu, R. K. Patel: *Artificial neural network modelling of As(III) removal from water by novel hybrid material: Process Safety and Environmental Protection* **93** (2015) 249-264
70. M. Goodarzi, A. C. Olivieri, P. F. Matheus: *Principal component analysis-adaptive neuro-fuzzy inference systems (ANFISs) for the simultaneous spectrophotometric determination of three metals in water samples; Spectrochimica Acta Part A* **73** (2009) 608-614
71. R. Gholami, A. Kamkar-Rouhani, F. Doulati Ardejani, Sh. Maleki: *Prediction of toxic metals concentration using artificial intelligence techniques; Applied Water Science* **1** (2011) 125-134
72. K. P. Moustris, I. C. Ziomas, A. G. Paliatsos: *3-Day-Ahead Forecasting of Regional Pollution Indeks for the Pollutants NO₂, CO, SO₂, and O₃ Using Artificial Neural Networks in Athens, Greece: Water, Air & Soil Pollution* **209** (2010) 29-43
73. J. J. Carbajal-Hernández, L. P. Sánchez-Fernández, J. A. Carrasco-Ochoa, J. F. Martínez-Trinidad: *Assessment and prediction of air quality using fuzzy logic and autoregressive models; Atmospheric Environment* **60** (2012) 37-50
74. R. Noori, G. Hashyaripour, K. Ashrafi, B. N. Araabi: *Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration; Atmospheric Environment* **44** (2010) 476-482
75. M. Kolehmainen, H. Martikainen, J. Ruuskanen: *Neural networks and periodic components used in air quality forecasting; Atmospheric Environment* **35** (2001) 815-825
76. W. Z. Lu, W. J. Wang, X. K. Wang, S. H. Yan, J. C. Lam: *Potential assessment of a neural network model with PCA/RBF approach for forecasting pollutant trend in Mong Kok urban air, Hong Kong; Environmental Research* **96** (2004) 79-87
77. Y. Yildirim, M. Bayramoglu: *Adaptive neuro-fuzzy based modelling for prediction of air pollution daily levels in city of Zonguldok; Chemosphere* **63**, (2006) 1575-1582
78. S. A. Abdul-Wahab, S. M. Al-Alawi: *Assessment and prediction of tropospheric ozone concentration levels using artificial neural networks; Environmental Modelling and Software* **17** (2002) 219-228
79. S. M. Al-Alawi, S. A. Abdul-Wahab, C. S. Bakheit: *Combining principal component regression and artificial neural networks for more accurate*

- predictions of ground-level ozone*; Environmental Modelling and Software **23**, (2008) 396-403
80. A. Coman, A. Ionescu, Y. Candau: *Hourly ozone prediction for a 24-h horizon using neural networks*; Environmental Modelling and Software **27** (2008) 1407-1421
81. P. Perez, J. Reyes: *An integrated neural network model for PM₁₀ forecasting*; Atmospheric Environment **40** (2006) 2845-2851
82. P. Perez, J. Reyes, A. Trier: *Prediction of PM_{2,5} concentration several hours in advance using neural network in Santiago, Chile*; Atmospheric Environment **34** (2000) 1189-1196
83. D. Jiang, Y. Zhang, X. Hu, Y. Zeng, J. Tan, D. Shao: *Progress in developing an ANN model for air pollution index forecast*; Atmospheric Environment **38** (2004) 7055-7064
84. X. Feng, Q. Li, Y. Zhu, J. Hou, L. Jin, J. Wang: *Artificial neural networks forecasting of PM_{2,5} pollution using air mass trajectory based geographic model and wavelet transformation*; Atmospheric Environment **107** (2015) 118-128
85. L. A. Díaz-Robles, J. C. Ortega, J. S. Fu, G. D. Reed, J. C. Chow, J. G. Watson, J. A. Moncada-Herrera: *A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco, Chile*; Atmospheric Environment **42** (2008) 8331-8340
86. A. K. Baareh: *Solving the Carbon Dioxide Emission Estimation Problem: An Artificial Neural Network Model*; Journal of Software Engineering and Applications **6** (2013) 338-342

ŽIVOTOPIS

Emerik Leaković rođen je 28. srpnja 1993. godine u Vinkovcima. Osnovnu školu fra Bernardina Tome Leakovića u Bošnjacima završava 2008. Potom upisuje Gimnaziju Županja, u kojoj 2012. godine odličnim uspjehom završava opći smjer. Po završetku srednjoškolskog obrazovanja sudjeluje na projektu razmjene mladih, naziva "Creating better world through connecting our diversities", a iste godine upisuje i preddiplomski studij Primijenjena kemija na Fakultetu kemijskog inženjerstva i tehnologije Sveučilišta u Zagrebu. Nakon druge godine studija dobiva priliku odraditi stručnu praksu u tvrtki Zagrebačke otpadne vode – upravljanje i pogon d.o.o u kojoj stječe iskustvo u radu i snalaženju u poslovnom okruženju, a godinu dana nakon toga odobreno mu je i stručno usavršavanje u istoj tvrtki.