

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ODJEL ZA FIZIKU

SUZANA DUMANČIĆ

NEURONSKE MREŽE

Diplomski rad

Osijek, 2014

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ODJEL ZA FIZIKU

SUZANA DUMANČIĆ

NEURONSKE MREŽE

Diplomski rad

predložen Odjelu za fiziku Sveučilišta J.J. Strossmayera u Osijeku
radi stjecanja zvanja profesora fizike i informatike

Osijek, 2014

Ovaj diplomski rad izrađen je u Osijeku pod vodstvom izv.prof.dr.sc. Darka Dukića u sklopu Sveučilišnog diplomskog studija Fizike i informatike na Odjelu za fiziku Sveučilišta Josipa Jurja Strossmayera u Osijeku.

SADRŽAJ

1. UVOD	1
2. INTELIGENCIJA	3
3. UMJETNA INTELIGENCIJA	4
3.1. POVIJEST RAZVOJA UMJETNE INTELIGENCIJE	5
3.1.1. Povijest razvoja umjetne inteligencije u 21. stoljeću – Wolfram Alpha	7
4. NEURONSKE MREŽE	11
4.1. PRIMJENA UMJETNIH NEURONSKIH MREŽA	14
4.1.1. Prezentacija primjene umjetnih neuronskih mreža u nastavi	15
4.2. OSNOVNA SVOJSTVA UMJETNIH NEURONSKIH MREŽA	16
4.3. VRSTE UMJETNIH NEURONA	18
4.4. USPOREDBA TRADICIONALNOG I NEURONSKOG RAČUNALSTVA	20
5. STVARANJE NEURONSKIH MREŽA	21
5.1. VIŠESLOJNI PERCEPTRON (MULTILAYER PERCEPTRON), ALGORITAM MREŽE ŠIRENJA UNATRAG	26
5.2. MREŽA S RADIJALNO ZASNOVANOM FUNKCIJOM (RADIAL BASIS FUNCTION)	28
6. PRIMJER PRIMJENE UMJETNIH NEURONSKIH MREŽA	29
7. ZAKLJUČAK	33
8. LITERATURA	34
ŽIVOTOPIS	36

NEURONSKE MREŽE

SUZANA DUMANČIĆ

Sažetak

Umjetna inteligencija bavi se izgradnjom sustava čije bi se ponašanje moglo okarakterizirati kao intelligentno, a nastavno na ljudsko ponašanje. Znanstvena tražilica Wolfram Alpha jedan je od uspješnih primjera primjene umjetne inteligencije u 21. stoljeću koji izaziva zanimanje ne samo stručnjaka prirodnih znanosti, nego i ostalih korisnika interneta. Neuronske mreže predstavljaju jednu od metoda umjetne inteligencije, a prilikom analize podataka koriste se matematičkim alatima te strukturon ljudskog mozga. Uspješna primjena neuronskih mreža pokriva mnoga različita područja poput zdravstva, obrazovanja, elektrotehnike, poslovanja itd. Neuronske mreže karakterizira visok stupanj tolerancije na pogreške, što se očituje uspješnom analizom nejasnih i manjkavih podataka, no još uvijek nisu u potpunosti prihvatljiv način analize podataka zbog nemogućnosti standardiziranja primjene u različitim situacijama.

Rad je pohranjen u knjižnici Odjela za fiziku

Ključne riječi: Umjetna inteligencija/neuronske mreže/učenje/sloj/signal/prepoznavanje

Mentor: izv.prof.dr.sc. Darko Dukić

Ocenjivači: izv.prof.dr.sc. Ramir Ristić, izv.prof.dr.sc. Branko Vuković

Rad prihvaćen: 20. listopada 2014. godine

NEURAL NETWORK

SUZANA DUMANČIĆ

Abstract

Artificial intelligence is concerned with creating systems whose behavior could be characterized as intelligent, like human behavior. Wolfram Alpha is a successful example of artificial intelligence in 21st century that raises interest of science experts and others. Neural network is an artificial intelligence method which uses the analogy of human brain activities. Implementation of neural network is recognized in health care system, education, electrical engineering, business activities etc. Neural network is characterized with high level of error tolerance when using incoherent data. However, lack of inability in standardizing implementation in various situations prevents it from being completely acceptable method.

Thesis deposited in Department od Physics library

Keywords: Artificial intelligence/neural networks/learning/layer/signal/recognition

Supervisor: Darko Dukić, PhD, Associate Professor

Reviewers: Ramir Ristić, PhD, Associate Professor, Branko Vuković, PhD, Associate Professor

Thesis accepted: October 20, 2014

1. UVOD

Neuronske mreže možemo opisati kao relativno novi koncept korišten u analizi podataka, čija se široka primjena očituje u društvenim znanostima, tehničkim znanostima, ekonomiji i mnogim drugim područjima. Pod pojmom „neuronske mreže“ podrazumijevat ćemo umjetne neuronske mreže. U radu su opisani osnovni pojmovi te metode neuronskih mreža, kao i pojave te razvoj zanimanja za umjetnu inteligenciju. Također, opisani su i noviji primjeri uspješne primjene umjetne inteligencije u 21. stoljeću. Kao „najsvježiji“ primjer razvoja umjetne inteligencije u radu je navedena Wolfram Alpha, znanstvena tražilica javnosti predstavljena 2009. godine, koja odgovor na postavljeni upit daje pomoću ugrađenih algoritama na način da upite povezuje s dosadašnjim spoznajama.

Iako razvoj neuronskih mreža ne seže daleko u prošlost, izrazito visoka uspješnost njihove primjene odražava se u području predviđanja i klasifikacije. Istraživanja i razvoj umjetnih neuronskih mreža zasnovani su na postojećim saznanjima o načinu funkciranja ljudskog mozga. Neuronski se sustav razvija pomoću treninga na velikom broju primjera te za dobivanje rješenja nije potrebno utvrđivanje na pravilima već definiranog znanja. Većina uspješnih aplikacija, razvijenih za primjenu neuronskih mreža, dolazi od grupa s iskustvom u akademskoj i industrijskoj okolini te je za očekivati kako će se daljnji razvoj kretati u istom smjeru. Stalan teorijski razvoj, kao i velik broj zainteresiranih istraživača diljem svijeta, omogućio je da neuronske mreže postanu tehnologija primjerena za primjenu u raznim područjima. Zajednička osobina svih neuronskih mreža je primanje određenih ulaznih informacija te transformiranje istih u izlazne rezultate. Neuronske mreže mogu se prikazati modelom podražaj – reakcija, pri čemu je područje između navedenih ispunjeno formalnim modelima.

Ciljevi istraživanja umjetnih neuronskih mreža usmjereni su na razvoj struktura novih mreža koje bi funkcionirole analogno ljudskom mozgu (ili makar djelomično oponašale njegove funkcije) u svrhu rješavanja praktičnih problema. Ponašanje računala smatra se intelligentnim ukoliko posjeduje sposobnost donošenja zaključaka na temelju određenih činjenica. Operacije poput uočavanja i klasificiranja objekata iz svakodnevnog života, kao i ostale slične radnje koje čovjek obavlja intuitivno, računalima predstavljaju prepreku. S obzirom da neuronske mreže karakterizira visok stupanj tolerancije grešaka, čak i u slučaju analize nejasnih i manjkavih podataka, moguće je doći do zadovoljavajućeg rješenja.

Svrha ovog diplomskog rada je ukazati na mogućnosti primjene neuronskih mreža u analizi podataka, a poglavito u području predviđanja i klasificiranja.

2. INTELIGENCIJA

Riječ „inteligencija“ ima korijen u latinskoj riječi „intelligere“ sa značenjem razabirati, shvaćati, razumijevati (Grgin, 2004.). Ne postoji jedinstvena definicija ovog pojma, nego mnoštvo njih koje uključuju koncepte poput apstraktnog rasuđivanja, razumijevanja, samosvijesti, komunikacije i učenja.

Neke od definicija inteligencije su:

- Svojstvo uspješnog snalaženja jedinke u novim situacijama (Šverko et al., 2011.).
- Opća sposobnost zaključivanja pri rješavanju problema (Šverko et al., 2011.).
- Svrsishodno i prilagodljivo ponašanje u danim okolnostima (Šverko et al., 2011.).

Inteligencija je kombinacija urođenih karakteristika i iskustvenog učenja. Možemo ju opisati kao potencijal koji se ne mora nužno razviti u sposobnost te ju možemo povezati s brzinom učenja. Učenje omogućuje razvoj inteligencije, dok inteligencija olakšava učenje.

Postoji više vrsta inteligencije (Posavec, 2010.):

- lingvistička;
- logičko – matematička;
- prostorna;
- tjelesno – kinestetička;
- glazbena;
- interpersonalna;
- intrapersonalna;
- prirodna.

Iako su inteligencije anatomski odvojene jedna od drugih, vrlo rijetko djeluju samostalno, tj. koriste se istovremeno i međusobno se nadopunjavaju.

3. UMJETNA INTELIGENCIJA

Promatrajući čovječanstvo kroz duže vremensko razdoblje, mogli bismo zaključiti kako ideja o konstrukciji inteligentnih strojeva, koji bi samostalno obavljali određene vrste poslova umjesto ljudi, seže daleko u prošlost. Svi su dosadašnji oblici umjetne inteligencije ograničeni samo na određene vrste problema, nemajući razumijevanje i vlastitu svijest. Predmetom mnogih filozofskih rasprava upravo je mogućnost kreiranja svjesne umjetne inteligencije, tj. pitanje je li inteligenciju moguće reproducirati računalom.

Neke od definicija umjetne inteligencije su:

- Znanstvena disciplina koja se bavi izgradnjom računalnih sustava čije se ponašanje može tumačiti kao intelligentno (Dalbelo Bašić et al., 2013.).
- Znanost o tome kako postići da strojevi izvode zadatke koji bi, kada bi ih radio čovjek, iziskivali inteligenciju (Dalbelo Bašić et al., 2013.).

„Umjetna inteligencija“ je pojam kojim se podrazumijeva svaki neživi sustav koji pokazuje sposobnost snalaženja u novim situacijama. S obzirom da takav pristup zahtjeva visok stupanj računalne obrade, njegova realizacija bila je neuspješna do početka 1980.-ih godina.

Umjetnu inteligenciju moguće je podijeliti na slabu i jaku. Zagovornici slabe umjetne inteligencije posvećuju se razvijanju intelligentnih sustava kojima se samo pridodaju određena svojstva ljudskog ponašanja, dok zagovornici jake umjetne inteligencije pokušavaju stvoriti sustav sa sposobnošću potpunog repliciranja svih svojstava ljudskog ponašanja (koji se smatraju intelligentnim).

Inteligencija je vještina koja karakterizira ljudska bića, iako se ne ponašaju uvijek intelligentno (Eletter; Yaseen, 2010.).

3.1. POVIJEST RAZVOJA UMJETNE INTELIGENCIJE

Razvoj umjetne inteligencije, od njenih početaka do danas, možemo podijeliti u 5 faza:

- fazu inkubacije (od 1943. godine do 1956. godine);
- fazu ranog entuzijazma s velikim očekivanjima (od 1952. godine do 1969. godine);
- fazu sustava temeljenih na znanju (od 1969. godine do 1979. godine);
- fazu u kojoj umjetna inteligencija postaje industrija (od 1980. godine do danas);
- fazu povratka neuronskih mreža (od 1986. godine do danas).

Povijest razvoja umjetne inteligencije obilježena je brojnim usponima i padovima. Početkom razvoja smatra se 1943. godina kada je predstavljen prvi modela umjetnog neurona (Warren Sturgis McCulloch, Walter Pitts) koji je nastao istraživanjem neurofizioloških karakteristika živih bića (Žalac, 1997.). Model je funkcionirao kao aritmetičko-logički element i uključivao je sve sastavnice potrebne za provođenje logičkih operacija. Važnost implementacije modela umjetnog neurona u početku nije bila prepoznata s obzirom da je u to vrijeme računalna tehnologija bila na počecima svog razvoja, a procesna moć računala još nije bila primjerena implementaciji umjetnih neuronskih mreža.

Očekivanja postavljena neuronskim mrežama u drugoj fazi nisu ispunjena te, unatoč velikom napretku umjetne inteligencije, dio znanstvenika smatra kako istinska umjetna inteligencija nikada neće biti ostvarena. Do velikog napretka u području iste došlo je razvojem neuronskih mreža.

Razvoj umjetne inteligencije možemo podijeliti na 2 smjera:

- psihološko i fiziološko proučavanje ljudskog uma;
- tehnološki razvoj sofisticiranih računalnih sustava.

Neuronske mreže obilježile su pedesete godine 20.-og stoljeća. Na konferenciji Dartmouth Summer Research Project and Artificial Intelligence predviđena je vizija računalnog modela čiji je temeljni princip oponašanje funkcioniranja mozga. Neuronsko računalstvo pojavljuje se kao alternativa Von Neumannovim računalima te nastoji simulirati paralelnu obradu informacija (poput obrade informacija koju koristi ljudski mozak). Prvi jednostavni model neuronskih mreža nazvan je perceptron.

Neki od presudnih događaja za razvoj neuronskih mreža (Žalac, 1997.):

- 1943. godine Warren Sturgis McCulloch i Walter Pitts postavili su temelje za razvoj neuronskih mreža ukazujući na to da neuroni mogu imati dva stanja (pobuđujuće i umirujuće) te da njihova aktivnost ovisi o nekom pragu vrijednosti.
- 1949. godine Donald Olding Hebb predložio je pravilo kojim se opisuje proces učenja (njegovo se pravilo smatra prvim važnijim doprinosom razvoja teorije neuronskih mreža).
- 1956. godine Nathaniel Rochester i skupina autora na konferenciji Dartmouth Summer Conference predstavili su prvu simulaciju Hebb-ovog modela koja je preteča modela neuronskih mreža.
- 1958. godine John von Neuman istaknuo je važnost činjenice kako u središnjem živčanom sustavu postoje različite logičke strukture u odnosu na one koje čovjek koristi u logici i matematici.
- 1958. godine Frank Rosenblatt izmio je perceptron (element sličan umjetnom neuronu) te razvio prvu dvoslojnou neuronsku mrežu pod nazivom Perceptron.
- 1960. godine Bernard Widrow i Marcian Hoff razvili su pravilo učenja (Widrow-Hoff pravilo) koje omogućuje minimiziranje sume kvadrata odstupanja tijekom treniranja mreže, a za potrebe klasificiranja uzorka.
- 1969. godine objavljena je knjiga Marvina Minskog i Seymonra Poperta u kojoj je izražena sumnja o mogućnosti ostvarenja većih potencijala „slojnih mreža“ u budućnosti.
- 1974. godine razvijena je višeslojna Perceptron mreža (engl. Multilayerer perceptron – MLP).
- 1980. godine Kunihiko Fukushima razvio je klasu arhitekture neuronskih mreža pod nazivom neocognitor (model koji omogućuje prepoznavanje uzorka).
- 1986. godine David Rumelhart, Geoffrey Hinton i Stephen Williams usavršili su Backpropagation mrežu te vratili „ugled“ neuronskim mrežama (omogućeno aproksimiranje većine funkcija te rješavanje praktičnih problema).

1997. godine računalo Deep Blue (IBM) pobijedilo je svjetskog šahovskog prvaka Garryja Kasparova, što je nametnulo pitanje inteligencije računala. Deep Blue ima mogućnost pripreme 200 000 šahovskih pozicija u sekundi, što ne zahtijeva inteligenciju, dok Kasparov za isto vrijeme može pripremiti samo tri šahovske pozicije. Iako računalo Deep Blue posjeduje izrazito

malo znanja o samoj igri, ima visoku sposobnost izračunavanja, što je upravo suprotno od Kasparovih karakteristika. Računalo Deep Blue svoju umjetnu inteligenciju ne može iskoristiti da nauči od Kasparova, dok Kasparov uči na temelju svojih uspjeha i neuspjeha. Međutim, potrebno je uzeti u obzir ljudska stanja poput umora i gubitka koncentracije, što strojevima nije svojstveno (Deep Blue, <http://www-03.ibm.com/ibm/history/ibm100/us/en/icons/deepblue/>).

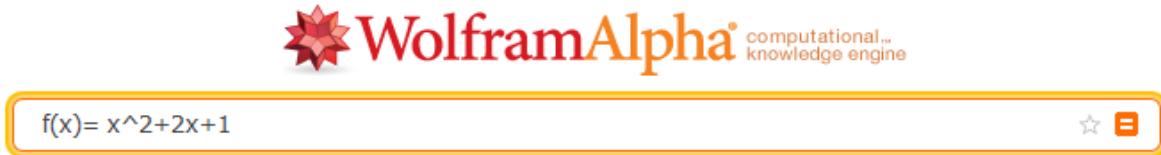
3.1.1. Povijest razvoja umjetne inteligencije u 21. stoljeću – Wolfram Alpha

Wolfram Alpha je znanstvena tražilica, razvijena od kompanije Wolfram Research, koja ne radi poput klasičnih tražilica, već odgovor na postavljeni upit daje pomoću ugradenih algoritama, tj. upite povezuje s dosadašnjim spoznajama, a rezultat daje računanjem pomoću tisuća procesora. Radi se o relativno novom djelu javnosti predstavljenom u mjesecu svibnju 2009. godine, na kojem možemo zahvaliti Stephenu Wolframu. S obzirom da je primarno bila zamišljena kao znanstvena tražilica, broj posjeta stranici <https://www.wolframalpha.com> nije uvijek rastao tijekom vremena. Velik broj posjeta u mjesecu svibnju i lipnju 2009. godine možemo pripisati zainteresiranosti šireg dijela korisnika interneta nakon javnog predstavljanja tražilice (Wolfram Alpha, <http://www.wolframalpha.com/about.html>).

Rezultati na postavljeni upit korisnicima su predočeni nakon detaljne analize i proučavanja baze sadržaja pregledanih i odobrenih od strane stručnjaka određenih tematika. Osnovni je cilj ovog projekta skupiti saznanja iz svih područja te pružiti sigurnost da su predstavljene informacije u cijelosti točne, što je jedan od velikih problema informacija dostupnih na internetu. Ono što Wolfram Alpha razlikuje od ostalih pretraživača je to što u vrlo kratkom vremenskom razdoblju daje rješenje različitih problema, osobito matematičkih. Iz navedenog je razloga stranica najposjećenija od strane osoba s obrazovanjem stečenim u području prirodnih znanosti. Tijekom 2009. godine, kada je tražilica javno predstavljena, reakcije su bile izrazito podijeljene. Na mnogim su se forumima mogli pronaći komentari kako je Wolfram Alpha najbliže umjetnoj inteligenciji od svega dosada napravljenog. Kako bi bila pristupačnija većini korisnika interneta, stranica se sve više posvećuje sportu, glazbi, zdravlju itd. Njenu veliku popularnost pokazuje i učestalost preuzimanja Wolfram Alpha aplikacije na mobilnim uređajima novih generacija.

Niže je naveden jedan od jednostavnih primjera matematičkog zadatka srednjoškolske razine, u kojem je prepoznato kako se zadana kvadratna jednadžba može napisati i u kraćem

obliku (kvadrat zbroja) te je pomoću navedenog prikazan graf funkcije, njena domena, ekstrem i derivacija funkcije.



Izvor: Wolfram Alpha,

<http://www.wolframalpha.com>

Slika 1: Postavljen upit (zadatak)

Input:

$$f(x) = x^2 + 2x + 1$$

Izvor: Wolfram Alpha,

<http://www.wolframalpha.com>

Slika 2: Prepoznavanje upita (zadatka)

Geometric figure:

parabola

Izvor: Wolfram Alpha,

<http://www.wolframalpha.com>

Slika 3: Prepoznavanje geometrijskog oblika

Properties as a real function:

Domain:

\mathbb{R} (all real numbers)

Range:

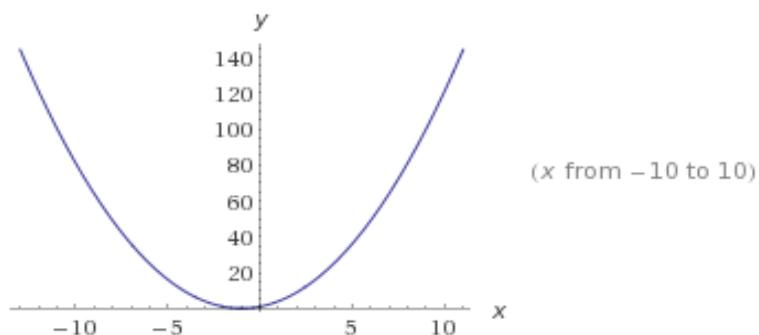
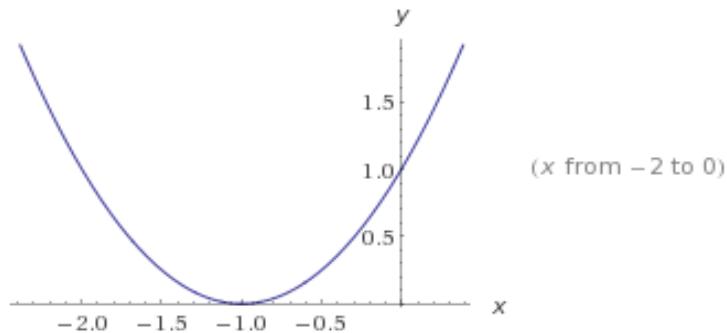
$\{f \in \mathbb{R} : f \geq 0\}$ (all non-negative real numbers)

Izvor: Wolfram Alpha,

<http://www.wolframalpha.com>

Slika 4: Određivanje domene funkcije

Plots:



Izvor: Wolfram Alpha,

<http://www.wolframalpha.com>

Slika 5: Graf funkcije predočen u dvama različitim mjerilima

Global minimum:

$$\min\{f(x) = \underline{x^2 + 2x + 1}\} = 0 \text{ at } x = -1$$

Izvor: Wolfram Alpha,
<http://www.wolframalpha.com>

Slika 6: Određivanje minimuma funkcije

Alternate form:

$$(x + 1)^2 = \underline{f(x)}$$

Izvor: Wolfram Alpha,
<http://www.wolframalpha.com>

Slika 7: Prepoznavanje formule za kvadrat zbroja

Derivative:

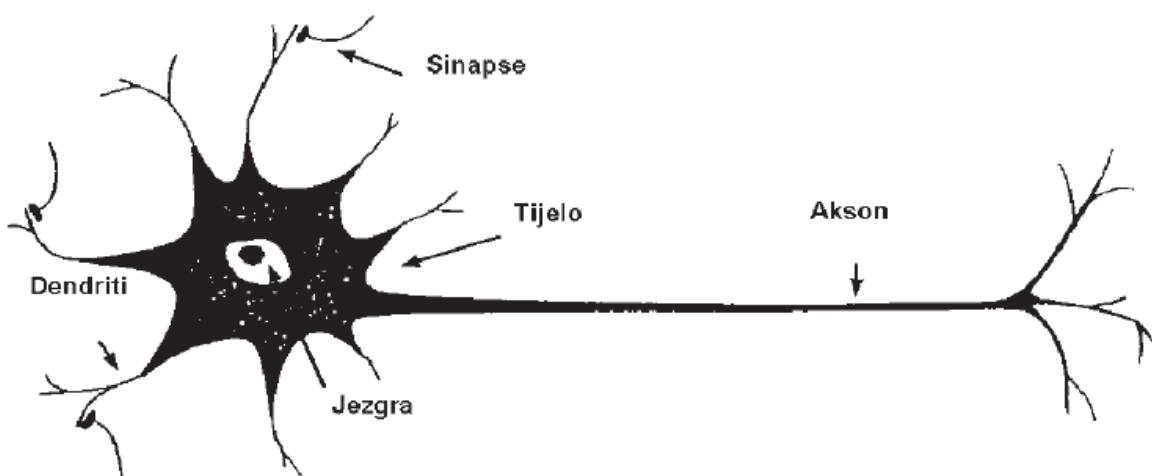
$$\frac{d}{dx}(x^2 + 2x + 1) = 2(x + 1)$$

Izvor: Wolfram Alpha,
<http://www.wolframalpha.com>

Slika 8: Određivanje derivacije funkcije

4. NEURONSKE MREŽE

Pojam „neuronske mreže“ ima dvojako značenje. Tradicionalno, ovaj se pojam odnosi na biološku (prirodnu) neuronsku mrežu građenu od bioloških neurona koji su povezani u periferni ili središnji živčani sustav. Neuron (živčana stanica) osnovna je jedinica živčanog sustava, a ujedno je i najsloženija jedinica ljudskog organizma. Živčani se sustav sastoji od približno 10^{11} međusobno povezanih neurona. Neurona ima više od 100 vrsta i, shodno svojoj funkciji, raspodijeljeni su prema točno definiranom rasporedu. Svaki je neuron u prosjeku povezan s 10^4 drugih neurona (Domijan, 2000.). Neuron je građen od tijela stanice te mnoštva dendrita i aksona. Dendriti su kraći produžeci koji prenose živčane impulse s osjetilnih organa do tijela stanice, dok aksone možemo predočiti kao tanke cjevčice čiji je jedan kraj povezan s tijelom neurona, dok se drugi kraj dijeli na niz grana. Razmak između završetka aksona prethodnog neurona i dendrita (ili tijela sljedećeg neurona) naziva se sinapsa. Neuron prima impulse kroz dendrite, a signale koje proizvodi tijelo predaje preko aksona. Zahvaljujući paralelnom radu neurona, ljudski mozak postiže izrazito visoku brzinu i sposobnost realiziranja više raznovrsnih zadataka istovremeno.



Izvor: Bolf, Jerbić (2006)

Slika 9: Biološke neuronske mreže

Signalni preko sinapse prelaze s jedne stanice na drugu električnim ili kemijskim putem. U slučaju električne sinapse, impuls koji je nastao na završecima presinaptičkog neurona aktivira kanale na membrani postsinaptičkog neurona, dok u slučaju kemijske sinapse postoji sinaptička

pukotina (prostor između završetka presinaptičkog neurona i membrane postsinaptičkog neurona) koja onemogućava direktno širenje električnih impulsa. Iz navedenog razloga završeci presinaptičkog neurona izlučuju neurotransmiter koji se veže na receptore postsinaptičke membrane. Ionski kanali (receptorske strukture) otvaraju i propuštaju ione kada se neurotransmiter veže na receptor, što uzrokuje promjenu u količini naboja unutar stanice te vodi do promjene samog membranskog potencijala.

Pod pojmom neuronskih mreža također se podrazumijevaju i umjetne neuronske mreže, kojima je ovaj rad posvećen, a koje su građene od međusobno povezanih umjetnih neurona. Umjetne neuronske mreže služe za razumijevanje bioloških neuronskih mreža i za rješavanje problema na području umjetne inteligencije. Koriste se strukturonom ljudskog mozga kako bi razvile primjerenu strategiju analize podataka. Neuronske mreže nalaze široku primjenu u društvenim i tehničkim znanostima. Slijedom prethodno pojašnjenog, mogli bismo zaključiti da umjetni neuron idejom oponaša osnovne funkcije biološkog neurona. Tijelo biološkog neurona predočeno je sumatorom, dendriti su predočeni ulazima sumator, dok izlaz sumatora predstavlja akson umjetnog neurona.

„Uspjesi koje su neuronske mreže postigle u modeliranju različitih oblika ljudskog ponašanja navele su neke autore na pomisao da su ti modeli svemoćni, tj. da predstavljaju sveobuhvatnu teoriju o kognitivnom funkcioniranju“ (Domijan, 2000.).

Neuronske mreže pokušavaju pronaći vezu između aktivnosti neurona i promjena na sinapsama s mišljenjem, pamćenjem i percepcijom. Neuronskim se mrežama, na najbolji mogući način, pokušava povezati spoznaja o radu živčanog sustava sa zahtjevima koje okolina predstavlja pred pojedinca. Živčani je sustav evolucijom oblikovan na način da rješava probleme ključne za preživljavanje. Umjetna neuronska mreža može se opisati kao umjetna preslika ljudskog mozga kojom se nastoji simulirati postupak učenja. Važno je napomenuti da je analogija s pravim biološkim uzorom kreirana uz mnoga pojednostavljenja. Još uvijek postoje mnogi fenomeni živčanog sustava koji nisu (uspješno) modelirani umjetnim neuronskim mrežama. S druge strane, postoje i karakteristike umjetnih neuronskih mreža koje se ne slažu s prirodnim neuronskim mrežama. Neuronska mreža je skup međusobno povezanih jednostavnih elemenata, jedinica ili čvorova, čija se funkcionalnost temelji na biološkom neuronu. Moć analize pohranjena je u snazi veza između pojedinih neurona, tj. težinama do kojih se dolazi postupkom prilagodbe (učenjem iz skupa podataka).

Neuronske su mreže interdisciplinarno područje nastalo združenjem istraživačkih napora iz psihologije, neurobiologije, matematike i informatike. Osnovni cilj tog povezivanja je razumijevanje odnosa neuralne aktivnosti i kognitivnog funkcioniranja korištenjem matematičkih koncepata poput linearne algebre, diferencijalnih jednadžbi i dinamičkih sustava (Domijan, 2000.).

4.1. PRIMJENA UMJETNIH NEURONSKIH MREŽA

Neuronske mreže uspješno se primjenjuju u brojim područjima poput zdravstva, obrazovanja, elektrotehnike, poslovanja, vojske, financije, kontrole kvalitete, sigurnosti poslovanja itd.

Neki od primjera su:

- otkrivanje eksploziva u prtljazi na aerodromu;
- određivanje problema kod rada avio-motora;
- određivanje tipova oblaka temeljem postojećih satelitskih snimki;
- obrada signala (npr. za otkrivanje radara);
- prepoznavanje govora;
- pretvaranje teksta u govor;
- financije (procjene rizika, krediti, burze i dr.);
- marketing (segmentiranje kupaca).

Na području financija neuronske se mreže uglavnom koriste za predviđanje kretanja određenih ekonomskih kategorija poput valutnog tečaja, prihoda od obveznica itd. Primjer za navedeno je tvrtka Simens – Nixdorf koja je neuronske mreže upotrijebila za predviđanje tečaja njemačke marke i američkog dolara (Žalac, 1997.). Tvrta Siemens razvila je neuronske mreže za detekciju pogrešnih memorijskih čipova, što pokazuje uspješnu primjenu i na području kontrole kvalitete (Žalac, 1997.). Tvrta je također razvila i uspješan model na području kontrole procesa koji je koristila portugalska tvrtka Cellulose de Carima (Žalac, 1997.). Model je omogućavao predviđanje vremena reakcije potrebnog za proizvodnju željene kvalitete voćne kaše te se pokazao 30% preciznijim od prethodno korištenog sustava, što je rezultiralo znatnom uštedom. Problem sigurnosti plaćanja kreditnim karticama značajno se smanjio primjenom neuronskih mreža. Kako bi se utvrdila i potvrdila zlouporaba kreditne kartice prosječno je bilo potrebno od 60 do 90 dana. Prepoznavanjem ekstremnih odstupanja isto se može smanjiti na samo nekoliko dana i to kreiranjem sustava koji uči iz uzorka proizvoda koje kupuje vlasnik određene kartice. Jedan od primjera prethodno navedenog je kartična kuća Visa. Američka tvrtka Iriscan za potrebe američke vlade neuronske mreže uspješno je primjenila na području identifikacija osoba temeljem šarenice oka (Žalac, 1997.).

4.1.1. Prezentacija primjene umjetnih neuronskih mreža u nastavi

Primjena neuronskih mreža u radu s učenicima srednjih škola nije praktična prvenstveno zbog nedostatka znanja i vještina u programiranju. Međutim, navedeno ne sprječava prezentaciju neuronskih mreža kroz jednostavne primjere iz svakodnevnog života. Kao jedan od najzanimljivijih primjera bilo bi primjereno prezentirati Google pretraživač kojim se, u vrlo kratkom vremenskom razdoblju, učenicima može demonstrirati rad neuronskih mreža. Upisivanjem pojma (o kojem želimo saznati više informacija) u pretraživač, u slučaju tiskarske pogreške dolazi do prepoznavanja da pojam nije ispravno unesen te nam je istovremeno ponuđen pojam kojeg (u većini slučajeva) zaista tražimo. Ova metoda učenicima pomaže da u kratkom vremenu posvjedoče rezultatima rada umjetnih neuronskih mreža, no nažalost bez dubljeg razumijevanja samog principa njihovog rada.



Slika10: Primjena UNM u nastavi

4.2. OSNOVNA SVOJSTVA UMJETNIH NEURONSKIH MREŽA

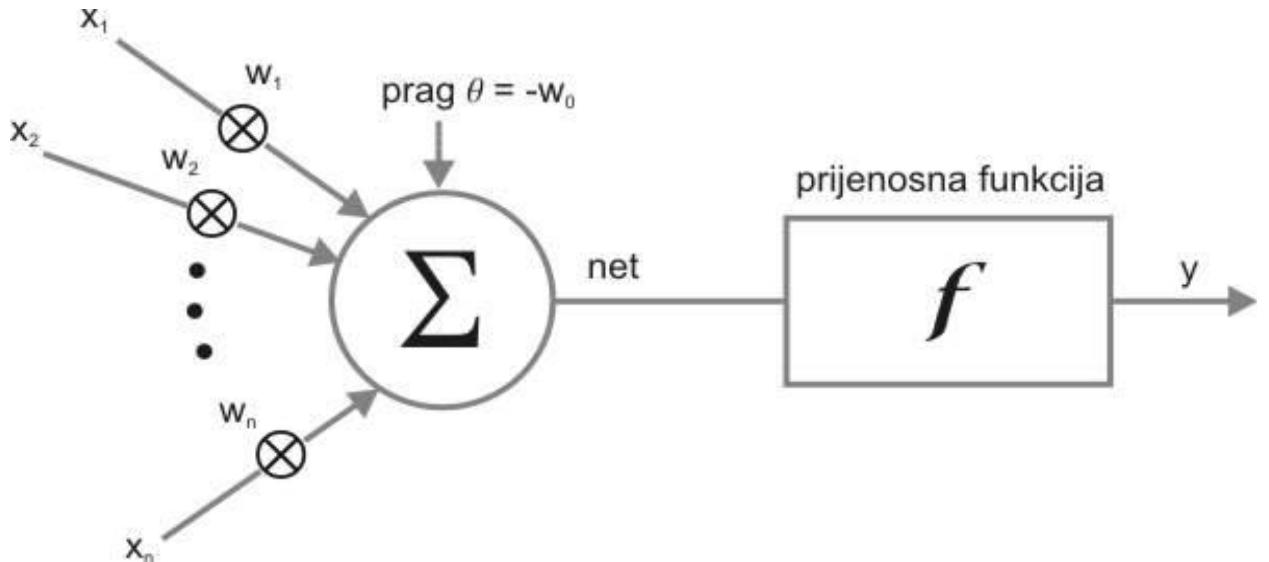
Najvažnija svojstva neuronskih mreža su:

- paralelna obrada informacija (informacije spremljene u neuronsku mrežu raspodijeljene su na više jedinica);
- svojstvo redundantnosti, tj. svojstvo otpora na kvar (neuronska mreža raditi čak i ako se uništi jedan njen dio);
- učenje i adaptacija koje neuronsku mrežu čine sposobnom obrađivati neprecizne podatke u nestrukturiranom i neodređenom okruženju (navedeno možemo opisati kao svojstvo poopćivanja);
- viševarijabilni sustavi (neuronske mreže karakterizira laka primjena za modeliranje i upravljanje viševarijabilnim procesima);
- univerzalni aproksimator (neuronske mreže imaju mogućnost aproksimiranja proizvoljne kontinuirane nelinearne funkcije do željene točnosti).

Model umjetnog neurona, osmišljen od strane Sturgis McCullocha i Walter Pittsa, imitira funkcionalnost biološkog neurona (tzv. Threshold logic unit – TLU).

Pojašnjenje modela umjetnog neurona:

- Svakom je signalu pridodan numerički iznos.
- Na ulazu u neuron signali se množe težinskim faktorom koji opisuje jakost sinapse.
- Rezultati dobiveni množenjem signala i težinskih faktora zbrajaju se. U slučaju da je dobiveni iznos iznad definiranog praga, neuron daje izlazni signal.
- Umjesto funkcije praga umjetni neuron može imati i neku drugu funkciju, npr. prijenosnu funkciju (aktivacijsku funkciju, transfer funkciju).



Izvor: Dalbelo, Bašić, Čupić, Šnajder (2008),
<http://materijali.fer2.net/Search.aspx?query=neuronske+mre%C5%BEe>

Slika 11: Općeniti model umjetnog neurona

Ulazne signale označavamo s x_1, x_2, \dots, x_n .

Težine označavamo s $\omega_1, \omega_2, \dots, \omega_n$.

Ulazni signali općenito su brojevi u intervalu [-1,1], [0,1] ili samo elementi iz {0,1} (Booleov izlaz). Težinska suma (net) definirana je izrazom:

$$net = \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n - \theta.$$

Često se dogovorno uzima da je vrijednost praga $\theta = -\omega_0$ uz dodavanje ulaznog signala x_0 s fiksiranom vrijednošću 1 pa se gornje navedeni izraz zapisuje u jednostavnijem obliku:

$$net = \omega_0 x_0 + \omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n = \sum_{i=0}^n \omega_i x_i .$$

Prijenosna funkcija y definirana je izrazom:

$$y = f(\sum_{i=1}^n \omega_i x_i) = f(net) .$$

4.3. VRSTE UMJETNIH NEURONA

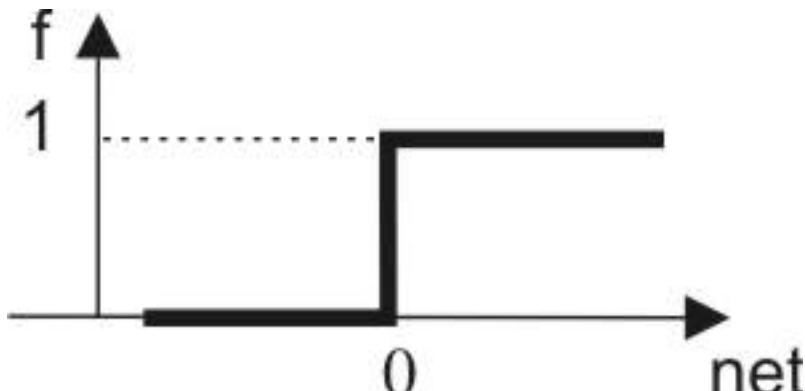
Najjednostavnija aktivacijska funkcija opisana je u poglavlju Osnovna svojstva umjetnih neuronskih mreža, a svojstvena je ADALINE modelu umjetnog neurona (engl. Adaptive linear element). Izlaz iz takve jedinice jednak je težinskoj sumi njegovih ulaza:

$$f(\text{net}) = \text{net} .$$

Osim prethodno navedene, moguće je koristiti i funkciju skoka ili praga (engl. Threshold function, gard-limiter). Navedenim se dobiva procesna jedinica koju daje Booleov izlaz (engl. Threshold logic unit, TLU).

Prijenosna funkcija definirana je kako slijedi:

$$f(\text{net}) = \begin{cases} 0, & \text{net} \leq 0 \\ 1, & \text{net} > 0 \end{cases}$$

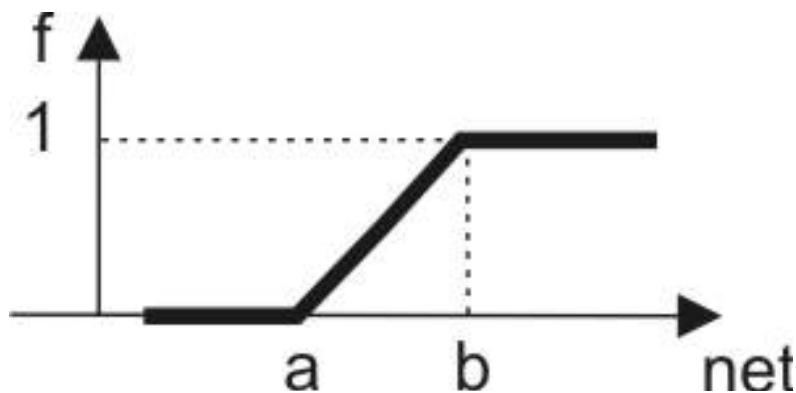


Izvor: Dalbelo, Bašić, Čupić, Šnajder (2008),
<http://materijali.fer2.net/Search.aspx?query=neuronske+mre%C5%BEe>

Slika 12: Funkcija skoka

Prijenosna funkcija može biti linearna po dijelovima te je definirana kako slijedi:

$$f(\text{net}) = \begin{cases} 0, & \text{net} \leq a \\ \text{net}, & a < \text{net} < b \\ 1, & \text{net} \geq b \end{cases}$$



Izvor: Dalbelo, Bašić, Čupić, Šnajder (2008),
<http://materijali.fer2.net/Search.aspx?query=neuronske+mre%C5%BEe>

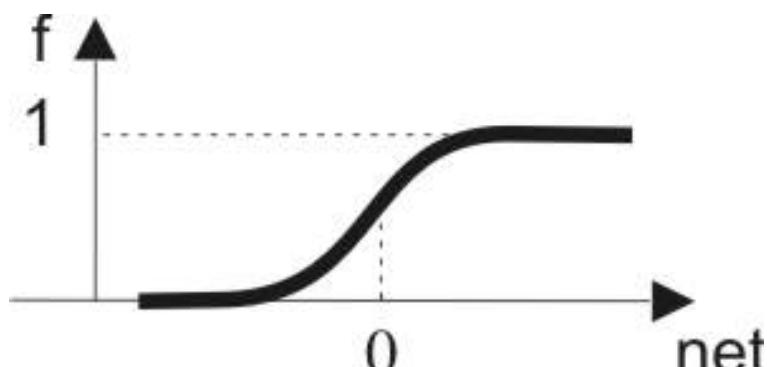
Slika 13: Djelomično linearna prijenosna funkcija

Najčešći oblik prijenosne funkcije je sigmoidalna (logistička) funkcija. Za razliku od dvaju prethodno navedenih funkcija, ova je funkcija derivabilna, što je bitna prednost pri postupku učenja umjetne neuronske mreže.

Sigmoidalna funkcija definirana je kako slijedi:

$$f(\text{net}) = \frac{1}{1 + e^{-a \cdot \text{net}}},$$

gdje parametar a određuje nagib funkcije.



Izvor: Dalbelo, Bašić, Čupić, Šnajder (2008),
<http://materijali.fer2.net/Search.aspx?query=neuronske+mre%C5%BEe>

Slika 14: Sigmoidalna prijenosna funkcija

4.4. USPOREDBA TRADICIONALNOG I NEURONSKOG RAČUNALSTVA

Razlike tradicionalnog i neuronskog računalstva:

- kod tradicionalnog računalstva obrada je uzastopna, dok je kod neuronskog računalstva obrada paralelna;
- neuronske mreže imaju distribuiranu asocijativnu memoriju (njihova memorija predstavljena je težinama među neuronima, a vrijednost težina predstavlja trenutno stanje „znanja“ u mreži);
- neuronske mreže karakterizira sposobnost prepoznavanja uzoraka u većem stupnju od tradicionalnih statističkih sustava;
- neuronske mreže karakterizira visok stupanj tolerancije grešaka te se do zadovoljavajućeg rješenja može doći čak i u slučaju kada je dio neurona iz određenih razloga onesposobljen i ne sudjeluje u analizi;
- neuronske mreže mogu raditi s nejasnim i manjkavim podacima tipičnim za podatke iz različitih senzora poput kamere, mikrofona i sl.;
- neuronske mreže mogu sintetizirati složene kontinuirane funkcije (analogno biološkim sustavima koji imaju mogućnost koordiniranja više pokreta, primjerice u sportu - zamahnuti reketom i baciti lopticu u isto vrijeme);
- neuronske mreže stvaraju vlastite odnose među podacima;
- neuronske mreže oblikuju znanje učeći na primjerima (iskustveno učenje).

Nedostaci neuronskih mreža:

- uspješno učenje neuronskih mreža zahtjeva izrazito velik broj podataka;
- neuronske mreže nisu u mogućnosti dati zadovoljavajuće rješenje izvan raspona vrijednosti iz kojih uče;
- generalizacija naučenih primjera uspješna je kod „neprekidnih“ pojava.

5. STVARANJE NEURONSKIH MREŽA

Slojevi u mreži, u kojima su raspodijeljeni neuroni, mogu biti ulazni, skriveni i izlazni. Ulagani sloj ima funkciju primanja podataka te slanja istih u skrivene slojeve. U skrivenim se slojevima informacije obrađuju te se, po realizaciji navedenog, šalju u neurone izlaznog sloja. Nakon toga informacije putuju unazad kroz mrežu, a vrijednosti težina između neurona prilagođavaju se željenom izlazu. Opisani se proces u mreži ponavlja onaj broj puta koliko je potrebno da se dobije izlaz najbliži željenom (stvarnom) izlazu (koji se na kraju prezentira). Snaga veze između dva neurona predstavljena je težinom veze, dok se proces pronalaženja vrijednosti težina veza među neuronima naziva učenjem.

Faze rada umjetnih neuronskih mreža moguće je podijeliti na:

- fazu učenja (treniranja);
- fazu selekcije (unakrsne validacije);
- fazu testiranja;
- operativnu fazu (fazu opoziva).

Kao dvije temeljne faze rada umjetnih neuronskih mreža najčešće se navode faza učenja i faza testiranja. U fazi selekcije mreža nastoji optimizirati duljinu treniranja te broj skrivenih neurona, nakon čega se dobivena mreža pohranjuje i testira. Operativna faza ili faza opoziva odnosi se na primjenu neuronske mreže na novim slučajevima s nepoznatim rezultatima i fiksiranim težinama.

Učenje je proces mijenjanja težina u mreži. Podaci predstavljeni u izlaznom sloju željene su vrijednosti izlaznih varijabli. Prije samog učenja potrebno je definirati model (ulagane i izlazne varijable) te pripremiti podatke na kojima će se primijeniti mreža. Podaci se najčešće dijele u dva poduzorka: uzorak za treniranje i uzorak za testiranje. Ne postoji točno određeno pravilo za podjelu podataka u uzorke, no preporučljivo je najveći dio podataka ostaviti za treniranje mreže. Nakon što je definiran model te pripremljeni ulagani i izlazni podaci i pravilo učenja, mrežu je potrebno učiti ili trenirati u svrhu prepoznavanja veze među podacima i predviđanja izlaznih vrijednosti na temelju ulaganih. Faza učenja zapravo je proces podešavanja težina u mreži koja se odvija u više ponavljanja (prolaza kroz mrežu). Mreža se najčešće trenira u nekoliko tisuća ponavljanja, a najvažnije je ustanoviti koliko dugo je potrebno trenirati mrežu kako bi rezultat

bio što bolji, tj. kako bi greška bila što manja. Kao ni za podjelu podataka u uzorke za treniranje i testiranje, ne postoji egzaktno pravilo ni za dužinu treniranja.

Druga faza rada neuronske mreže je testiranje mreže te ju možemo opisati kao odlučujuću fazu za ocjenjivanje same mreže. U fazi testiranja mreža više ne uči, tj. vrijednosti težina su fiksirane na vrijednostima dobivenima u fazi učenja. Takvoj se mreži predstavljaju nove ulazne vrijednosti (koje nisu sudjelovale u procesu učenja), a od mreže se očekuje da za predstavljenu novu ulaznu vrijednost proizvede pripadajuću izlaznu vrijednost. Ocjenjivanje mreže vrši se izračunavanjem greške ili nekog drugog mjerila točnosti (npr. stope točnosti), na način da se izlazna vrijednost mreže uspoređuje sa stvarnim izlaznim vrijednostima.

Uspješnost tj. neuspješnost mreže, kao i njena korisnost, tumači se pomoću dobivene greške na uzorku za validaciju. Najčešća je greška koja se računa kod neuronskih mreža korijen iz srednje kvadratne pogreške (root mean square error), prema formuli:

$$\sigma = \sqrt{\frac{\sum_{i=1}^{n-1} (t_i - o_i)^2}{n}},$$

gdje je:

- t_i izračunati izlaz koji daje mreža;
- o_i željeni (stvarni) izlaz za slučaj i ;
- n broj slučajeva u uzorku.

Kao mjerila se, osim navedene, koriste i srednja kvadratna pogreška (mean square error), srednja apsolutna pogreška (mean absolute error) te koeficijenti korelacije. Kod finansijskih problema koriste se finansijska mjerila kao što su prosječni profit, simulacijski profit i sl.

U slučaju korištenja više algoritama, na osnovi dobivenih rezultata potrebno je donijeti odluku o tome koji je model najbolji. Kao što je prethodno pojašnjeno, mjerila nisu standardizirana, već ovise o tipu problema, prirodi problema i sl.

Sam proces dizajniranja neuronske mreže sastoji se od više faza te su te se iste razlikuju ovisno o literaturi. Najčešće su nabrojane kako slijedi:

- definiranje modela (određivanje ulaznih i izlaznih varijabli);
- izabiranje najprikladnijeg algoritma;
- raspoređivanje neurona u slojeve;
- određivanje tipa veze među neuronima;
- određivanje funkcija među slojevima;
- izabiranje pravila učenja;
- izabiranje mjerila za ocjenjivanje mreže;
- provođenje postupka učenja.

Kao što postoje različiti algoritmi neuronskih mreža, ovisno o temeljnim formulama koje se koriste za učenje, također postoji i širok spektar arhitektura neuronskih mreža koje se međusobno razlikuju prema nekoliko kriterija.

Arhitekture neuronskih mreža mogu biti:

- dvoslojne (samo s ulaznim i izlaznim slojem bez dodatnih slojeva);
- višeslojne (s ulaznim i izlaznim slojem te jednim ili više dodatnih slojeva).

Veze među neuronima mogu biti:

- interslojne (veze među neuronima koji se nalaze u različitim slojevima);
- intraslojne (veze među neuronima koji se nalaze u istom sloju).

Veze između ulaznih i izlaznih podataka mogu biti:

- autoasocijativne (ulazni podatak i izlazni podatak istog su sastava);
- heteroasocijativne (izlazni podatak razlikuje se od ulaznog podatka).

Prema vremenu učenja neuronske mreže dijele se na:

- skupno ili batch učenje (mreža uči samo u fazi učenja, dok su u ostalim fazama težine fiksirane);
- sekvencijalno ili on-line učenje (mreža prilagođava svoje težine).

Prema prostiranju signala kroz mrežu neuronske mreže dijele se na:

- statičke mreže (primaju ulazne podatke u jednom prolazu kroz mrežu - viši slojevi ne vraćaju informacije u niže slojeve);
- dinamičke mreže (primaju ulazne podatke u vremenskim intervalima, a viši slojevi vraćaju informacije unazad u niže slojeve).

Porastom uporabe neuronskih mreža razvili su se brojni algoritmi. Neki su univerzalni za sve tipove problema, dok su neki specijalizirani.

Algoritme možemo podijeliti na:

- nadgledane (algoritmi za koje su potrebne poznate ulazne i izlazne vrijednosti);
- nenadgledane (algoritmi za koje su potrebne samo ulazne vrijednosti).

U nadgledane algoritme ubrajaju se:

1) za probleme predviđanja:

- mreža širenja unatrag (engl. backpropagation);
- modularna mreža (engl. modular network);
- mreža s radijalno zasnovanom funkcijom (engl. radial-basis function network);
- mreža opće regresije (engl. general regression network);

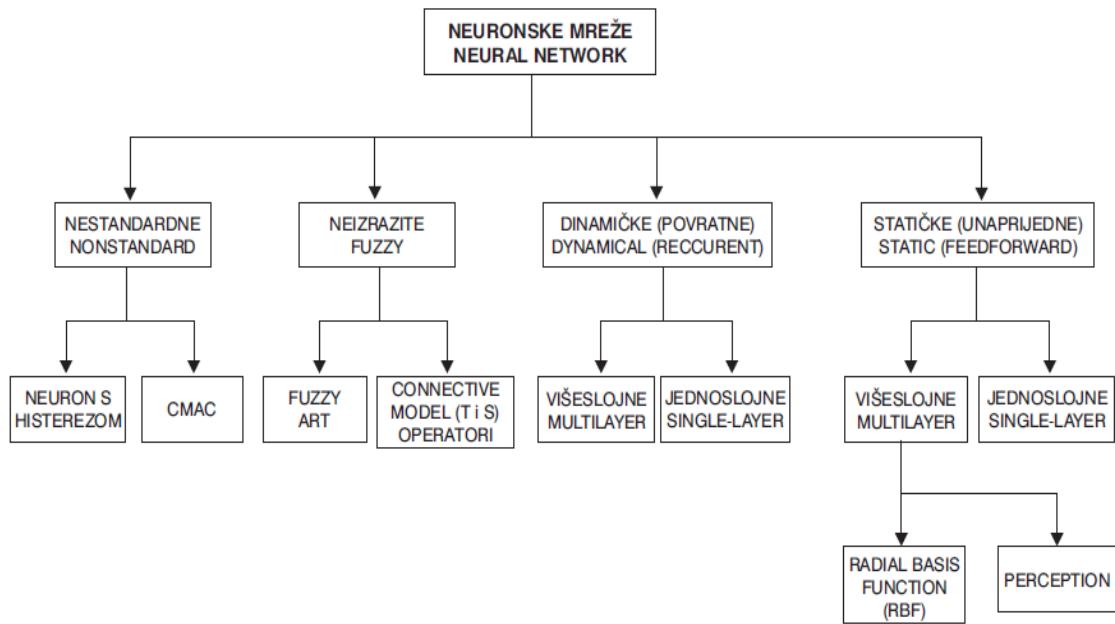
2) za probleme klasifikacije:

- vjerojatnosna mreža (engl. probabilistic network);
- mreža učeće vektorske kvantizacije (engl. linear vector quantization).

U nenadgledane algoritme ubrajaju se:

- Kohenova mreža;
- mreža adaptivne rezonantne teorije (engl. adaptive resonance theory network).

Niže je prikazana podjela neuronskih mreža prema prethodno pojašnjenim kriterijima.

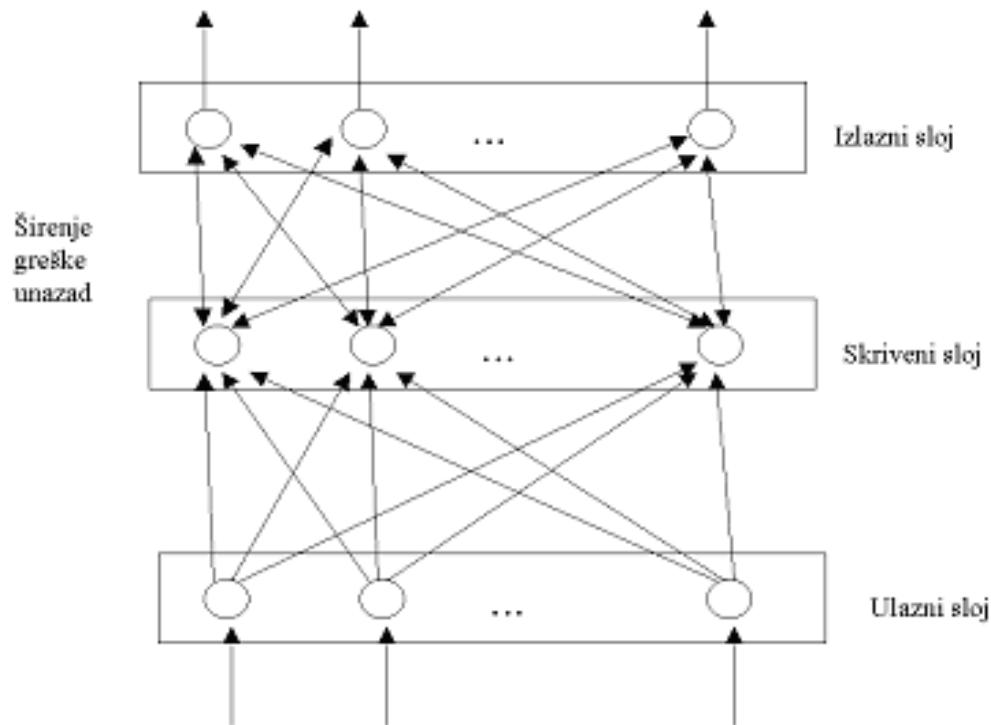


Izvor: Bolf, Jerbić (2006)

Slika15: Podjela umjetnih neuronskih mreža

5.1. VIŠESLOJNI PERCEPTRON (MULTILAYER PERCEPTRON), ALGORITAM MREŽE ŠIRENJA UNATRAG

Višeslojni perceptron (engl. multilayer perceptron) jedna je od najraširenijih primijenjenih neuronskih mreža. Učenje se u navedenoj mreži odvija pomoću algoritma „širenje unatrag“. Algoritam mreže „širenje unatrag“ bio je od iznimne, mogli bismo reći i presudne, važnosti te je neuronske mreže učinio široko upotrebljavanom i vrlo popularnom metodom u različitim područjima. Ovu je mrežu 1974. godine kreirao Paul Werbos, a 1986. godine proširili su ju David Rumelhart, Geoffrey Hinton i Stephen Williams (Žalac, 1997.). Mreža širenja unatrag bila je prva neuronska mreža s jednim ili više skrivenih slojeva. Mreža funkcioniра na način da se ulazne vrijednosti šire kroz skriveni sloj do izlaznog sloja, nakon čega se određuje greška koja se širi unatrag do ulaznog sloja i ugrađuje u formulu za učenje. Arhitektura mreže "širenje unatrag" s jednim skrivenim slojem prikazana je na Slici 16.



Izvor: Kliček (2013),
<http://eris.foi.hr/11neuronske/nn-predavanje58.html>

Slika 16: Mreža širenja unatrag

Tijek podataka kroz mrežu može se ukratko opisati u nekoliko koraka:

- podaci se šire od ulaznog sloja prema skrivenom sloju (ulazni sloj učitava podatke te ih šalje u prvi skriveni sloj);
- jedinice u skrivenom sloju primaju vrijednost i prenose ju u naredni skriveni (ili u izlazni) sloj pomoću prijenosne funkcije;
- prilikom prolaska informacija kroz mrežu računaju se ukupne (sumirane) ulazne i izlazne vrijednosti za svaku jedinicu analize;
- u izlaznom se sloju za svaku jedinicu analize računa lokalna greška (u svrhu određivanja povećanja ili smanjenja težina);
- podaci se šire unatrag od izlaznog sloja do skrivenih slojeva.

U mreži su prisutne dvije vrste signala:

- ulazni signal (počinje na ulaznom dijelu mreže te se širi prema naprijed neuron po neuron, a na izlazu mreže javlja se kao izlazni signal);
- signal greške (javlja se na izlaznom dijelu mreže i širi se unatrag sloj po sloj, a računa se kao razlika između željenog i stvarnog izlaza).

Mreža „širenja unatrag“ primjenjuje se za predviđanje vrijednosti jedne ili više izlaznih varijabli, no koristi se i za probleme klasifikacije.

5.2. MREŽA S RADIJALNO ZASNOVANOM FUNKCIJOM (RADIAL BASIS FUNCTION)

Mrežu s radijalno zasnovanom funkcijom (engl. radial basis function) moguće je upotrebljavati u istim situacijama kao i mrežu „širenje unatrag“, tj. prikladno ju je upotrebljavati za probleme predviđanja i za probleme klasifikacije. Važno je istaknuti kako ova mreža prevladava neke nedostatke mreže "širenje unatrag", poput problema sporog učenja.

Algoritam učenja kroz slojeve moguće je opisati kako slijedi:

- učenje započinje u skrivenom sloju s nenadgledanim algoritmom u svrhu određivanja središta;
- učenje se nastavlja u izlaznom sloju s nadgledanim algoritmom u svrhu izračunavanja greške;
- istovremeno se primjenjuje nadgledani algoritam u skrivenom i izlaznom sloju u svrhu podešavanja težine u mreži.

Najvažnije prednosti mreže s radijalno zasnovanom funkcijom:

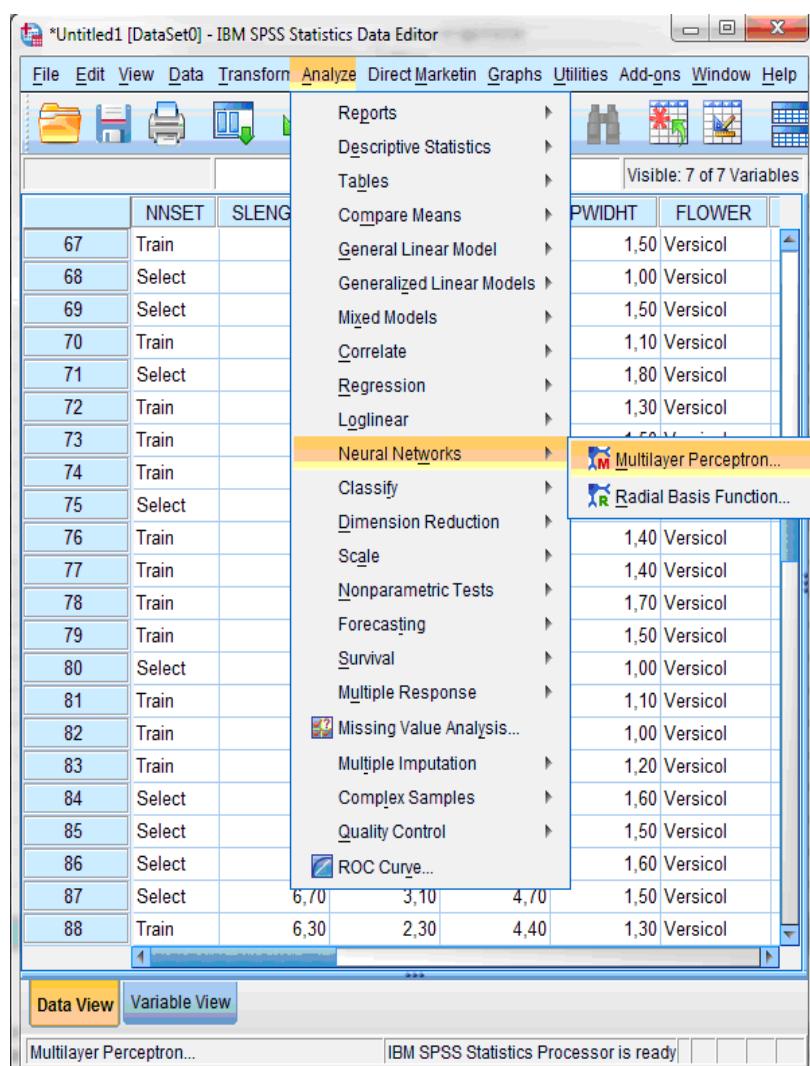
- brzo treniranje;
- bolje granice odluke nego kod mreže "širenje unatrag" (u slučaju upotrebljavanja mreže za probleme klasifikacije);
- skriveni sloj mreže može se opisati kao funkcija gustoće za ulazne vrijednosti te može mjeriti vjerojatnost da je neka nova ulazna vrijednost član iste distribucije kao i ostale ulazne vrijednosti.

Nedostaci mreže s radijalno zasnovano funkcijom:

- unatoč brzom učenju, u fazi opoziva mreža može biti sporija od mreže „širenja unatrag“;
- određene informacije mogu se izgubiti u fazi klasteriranja (početnoj fazi učenja);
- optimalan broj prototip jedinica teško je odrediti.

6. PRIMJER PRIMJENE UMJETNIH NEURONSKIH MREŽA

„The Iris problem“ primjer iz programskog paketa Statistica obrađen je u SPSS-u. U tablici su opisana 3 različita tipa cvijeta (Versicol, Virginica i Setosa) s podacima o izmjerenoj duljini i širini stabljike te duljini i širini latice. Rezultati prikazani u programu Statistica razlikuju se od rezultata dobivenih analizom podataka u SPSS-u. Razlog navedenom je što algoritmi neuronskih mreža koriste nasumične vrijednosti prilikom postavljanja početnih vrijednosti težina. Nastavno na prethodno pojašnjenje, lako je zaključiti kako bi se rezultati razlikovali prilikom obrate istih podataka u istom programu. Na rezultate također utječe broj varijabli korištenih u fazi treniranja, testiranja i validacije mreže. Prije same analize podataka potrebno je podesiti ispravan tip varijable (numerički ili tekstualni). Za analizu podataka korišten je višeslojni perceptron.



Izvor: SPSS

Slika 17: Višeslojni perceptron

Važno je napomenuti kako je 16 slučajeva isključeno iz analize.

Warnings

One or more cases in the testing or holdout sample have factor or dependent variable values that do not occur in the training sample. These cases are excluded from the analysis.

Izvor: SPSS

Slika 18: Slučajevi isključeni iz analize

U navedenom je primjeru 77,6% slučajeva korišteno za treniranje mreže, a 22,4% za testiranje mreže.

Case Processing Summary

		N	Percent
Sample	Training	104	77,6%
	Holdout	30	22,4%
Valid		134	100,0%
Excluded		16	
Total		150	

Izvor: SPSS

Slika 19: Broj slučajeva korištenih za treniranje i testiranje

Skriveni sloj podešen je na način da sadrži između 1 i 50 jedinica. Mreža sadrži 1 skriveni sloj te 10 jedinica u istom.

Network Information			
Input Layer	Factors	1 2 3 4	SLENGTH SWIDHT PLENHT PWIDHT
	Number of Units ^a		112
	Number of Hidden Layers		1
	Number of Units in Hidden Layer 1 ^a		10
Hidden Layer(s)	Activation Function		Hyperbolic tangent
	Dependent Variables	1	FLOWER
	Number of Units		3
	Activation Function		Softmax
Output Layer	Error Function		Cross-entropy

a. Excluding the bias unit

Izvor: SPSS

Slika 20: Podaci o mreži

Klasifikacijska tablica prikazuje praktične rezultate korištenja neuronskih mreža. Vrijednosti na dijagonali klasifikacije slučaja su ispravna predviđanja. Vrijednosti izvan dijagonale klasifikacije slučaja su neispravna predviđanja. Izvedba neuronske mreže određena je generalizacijom podataka koji nedostaju, kao i predviđanjem podataka koji nisu korišteni tijekom treniranja mreže.

Classification

Sample	Observed	Predicted			Percent Correct
		Setosa	Versicol	Virginic	
Training	Setosa	34	0	0	100,0%
	Versicol	0	34	0	100,0%
	Virginic	0	0	36	100,0%
	Overall Percent	32,7%	32,7%	34,6%	100,0%
Holdout	Setosa	11	0	0	100,0%
	Versicol	0	9	1	90,0%
	Virginic	0	0	9	100,0%
	Overall Percent	36,7%	30,0%	33,3%	96,7%

Dependent Variable: FLOWER

Izvor: SPSS

Slika 21: Klasifikacijska tablica

Uvidom u polje „training sample“ vidljivo je kako su sve vrijednosti izvan dijagonale 0, što ukazuje na 100%-tnu točnost predviđanja. U polju „holdout sample“ vidljiva je vrijednost izvan dijagonale koja ukazuje na neispravno predviđanje (za cvijet Versicol), no unatoč tome ukupan postotak je vrlo visok (96,7%). Za zaključiti je da predviđanja karakterizira visoka točnost.

7. ZAKLJUČAK

Umetna inteligencija, tj. neuronske mreže u užem smislu, mogu pridonijeti kvalitetnijoj analizi podataka. S obzirom da ne postoji standardiziran pristup kojim bi se problem mogao riješiti pomoću neuronskih mreža, prilikom ispitivanja svakog problema potrebno je isprobati veći broj neuronskih mreža, u svrhu dobivanja najkvalitetnije mreže, tj. mreže s najvećom pouzdanošću. Neuronske će mreže postati u potpunosti prihvatljiv alat kada se pristup rješavanja problema standardizira na način da se za svaku situaciju točno definira arhitektura mreže, pravila učenja, broj skrivenih slojeva te broj neurona u istima, kao i prijenosne funkcije koje je potrebno koristiti pri rješavanju.

Primjena neuronskih mreža pokazuje se vrlo uspješnom u društvenim znanostima, dok se u prirodnim znanostima i dalje češće koriste regresijski modeli. Razlog navedenom je najvećim dijelom sama struktura podataka koji se obrađuju. Unatoč tome, neuronske mreže su alat prilagođen za primjenu u analizi nepotpunih podataka. Njihova prednost je sposobnost generalizacije, odnosno mogućnost dobivanja zadovoljavajućih rezultata čak i kada neke ulazne vrijednosti nisu poznate ili potpune.

Jedan od najzanimljivijih aspekta neuronskih mreža je mogućnost dostizanja savršenstva biološke neuronske mreže, tj. oponašanje ljudske vrste. Ukoliko bi isto bilo ostvarivo, pitanje je bi li neuronske mreže u potpunosti zamijenile ljudsku vrstu? Štetimo li samima sebi stalnim ulaganjem napora u napredak tehnologije? Odgovor će dati vrijeme, no za pretpostaviti je da neuronske mreže nikada u potpunosti neće moći oponašati rad biološke neuronske mreže.

8. LITERATURA

- Bolf, N.; Jerbić, I. (2006). Primjena umjetnih neuronskih mreža pri identificiranju i vođenju procesa. *Kemija u industriji.* 55 (11), str. 457-466.
- Dalbelo Bašić, B. et al. Umjetna inteligencija,
<http://www.fer.unizg.hr/predmet/umjint/materijali>
- Dalbelo Bašić, B. et al. Umjetne neuronske mreže,
<http://materijali.fer2.net/Search.aspx?query=neuronske+mre%C5%BEe>
- Deep Blue, <http://www-03.ibm.com/ibm/history/ibm100/us/en/icons/deepblue/>
- Domijan, D. (2000). Uvod u neuronske mreže. *Metodički ogledi.* 7 (1/2), str. 101-127.
- Eletter, F.S.; Yaseen, G.S. (2010). Applying Neural Networks for Loan Decisions in the Jordanian Commercial Banking System. *International Journal of Computer Acience and Network Security.* 10 (1), str. 209-214.
- Google, <http://www.google.hr>
- Grgin, T. (2004). *Edukacijska psihologija.* 2. izd. Zagreb: Slap.
- Kliček, B. *Neuronske mreže,* <http://eris.foi.hr/11neuronske/nn-predavanje58.html>
- Mateljan, V. (2000). Unapređenje komunikacije korisnika s korisničkim sučeljem korištenjem neuronske mreže. *Suvremeni promet.* 20 (3/4), str. 318-321.
- Matešić, M. Hrvatska Mensa, <http://www.mensa.hr/glavna/misli-21-stoljeca/479-umjetna-inteligencija-uvod>
- Miljković, Z.; Gerasimović; M.; Stanojević, Lj.; Bugarić; U. (2011). Uporaba umjetnih neuronskih mreža u predviđanju profesionalnih kretanja maturanata. *Hrvatski časopis za odgoj i obrazovanje.* 13 (2), str. 117-141.
- Novaković, B. (1998). *Umjetne neuronske mreže.* Zagreb: Fakultet strojarstva i brodogradnje.
- Posavec, M. (2010). Višestruke inteligencije u nastavi. *Život i škola.* 24 (2), str. 55-64.
- Šverko, B. et al. (2011). *Psihologija: udžbenik za gimnazije.* 5. izd. Zagreb: Školska knjiga.
- Wolfram Alpha, <http://www.wolframalpha.com>
- Žalac, N. (1997). Neuronske mreže i poslovna prognostika. *Poslovna analiza i upravljanje.* 2 (11/12), str. 39-45.
- Žalac, N. (1997). Neuronske mreže: jučer, danas, sutra. *Poslovna analiza i upravljanje.* 2 (1), str. 35-41.

- Žalac, N. (1997). Primjer jednostavnog modela neuronske mreže. Poslovna analiza i upravljanje. 2 (10), str. 3-12.

ŽIVOTOPIS

Zovem se Suzana Dumančić. Rođena sam 2. studenog 1989. godine u Osijeku. Osnovnu školu „Tin Ujević“ pohađala sam od 1996. do 2000. godine te Osnovnu školu „Antun Mihanović“ od 2000. do 2004. godine. I. gimnaziju u Osijeku pohađala sam od 2004. do 2008. godine. Školu stranih jezika „Lanico“ pohađala sam od 2008. do 2011. godine te završila šest (6) stupnjeva španjolskog jezika. Odjel za fiziku Sveučilišta Josipa Jurja Strossmayera u Osijeku upisala sam 2008. godine.