

SVEU ILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ODJEL ZA FIZIKU



GORAN PINTARI

**UMJETNE NEURONSKE MREŽE I MOGU NOSTI
NJIHOVE PRIMJENE U OBRAZOVANJU**

DIPLOMSKI RAD

Osijek, 2013.

SVEU ILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

ODJEL ZA FIZIKU



GORAN PINTARI

**UMJETNE NEURONSKE MREŽE I MOGU NOSTI
NJIHOVE PRIMJENE U OBRAZOVANJU**

DIPLOMSKI RAD

Osijek, 2013.

"Ovaj diplomski rad je izrađen u Osijeku pod vodstvom doc.dr.sc. Darka Dukić u sklopu Sveučilišnog preddiplomskog studija fizike i tehničke kulture s informatikom na Odjelu za fiziku Sveučilišta Josipa Jurja Strossmayera u Osijeku".

Predgovor

Diplomski rad pod nazivom "Umjetne neuronske mreže i mogunosti njihove primjene u obrazovanju" pojašnjava mogunosti napretka obrazovnih tehnika te lakše usvajanje gradiva od strane učenika ili studenata. U radu obrazlažem mogunosti usvajanja novih injenica i spoznaja putem komunikacije s inteligentnim sustavom temeljenim na neuronskim mrežama te spoznajama proizašlim iz proučavanja biološke i kognitivne strukture ljudskog mozga kao mnoštva zasebnih jedinica koje tvore racionalni sustav spremjan za velik broj neovisnih i međusobno nevezanih zadataka. Interdisciplinarni pristup proučavanju onoga što je svakom pojedincu omogućeno rođenjem po etničkoj pretpostavki u kreiranju umjetnih neuronskih mreža pomoći u kojih se u skoroj budućnosti izmijeniti načini na koji vršimo bilo kakvu interakciju sa okolinom.

Zahvaljujem se doc.dr.sc. Darku Duki na razumijevanju i potpori u radu te smjernicama koje su mi neizmjerno pomogle prilikom kreiranja istog. Također zahvaljujem i roditeljima na potpori prilikom studija te ovaj rad posvećujem nedavno preminulom ocu.

SADRŽAJ

1. UVOD U UMJETNE NEURONSKE MREŽE	1
2. NEURONSKE MREŽE	2
2.1. Koncept neuronske mreže	2
2.2. Razlika između neuronskih mreža i računala	6
2.2.1. Funkcija praga	10
2.2.2. Djelomična linearna funkcija	11
2.2.3. Sigmoidalna funkcija	11
2.3. Dizajn neuronskih mreža	12
2.4. Mehanizam učenja neuronskih mreža	14
2.5. Primjena neuronskih mreža	18
2.6. Kako najbolje upotrijebiti neuronsku mrežu	20
2.7. Povijest neuronskih mreža, trenutno stanje i budući razvoj	21
2.7.1. Genetski algoritmi	24
2.7.2. Fuzzy logika	25
3. PRIMJENA NEURONSKIH MREŽA U OBRAZOVANJU	27
3.1. Zakoni učenja	28
3.2. Budućnost učenja kroz umjetnu inteligenciju	29
4. ZAKLJUČAK	33
5. LITERATURA	34
6. POPIS SLIKA	39
7. ŽIVOTOPIS	40

UMJETNE NEURONSKE MREŽE I MOGU NOSTI NJIHOVE PRIMJENE U OBRAZOVANJU

GORAN PINTARI

Sažetak

U radu „Umjetne neuronske mreže i mogu nosti njihove primjene u obrazovanju“ pojašnavamo pojam neuronskih mreža, pratimo procese koji se događaju u biološkim neuronima, pojašnavamo strukturu i način kreiranja mreža sa injenih od umjetnih neurona kao načinalnih konstrukcija, te se bavimo metodologijom rada ovakvih sustava. Isto tako, promatramo povijesni razvoj neuronskih mreža, navodimo nekoliko glavnih pravaca u učenju neuronskih mreža te pojašnavamo na koji način se ovakve mreže mogu implementirati unutar edukacijske djelatnosti u školama. Dotičemo se i inteligentnih sustava koji danas egzistiraju, te mogu nositi njihovog napretka u budućnosti.

Rad je pohranjen u knjižnici Odjela za fiziku

Ključne riječi: umjetne neuronske mreže, svojstva neuronskih mreža, sustavi učenja, analiza govora, model učenika, prepoznavanje uzoraka, prepoznavanje teksta.

Mentor: doc.dr.sc. Darko Dukić

Ocenjivači: prof.dr.sc. Branko Vuković, mr.sc. Stjepan Hrpka

Rad prihvaten: 26.03.201

University of Josip Juraj Strossmayer Osijek
Department of Physics

Bachelor of Physics
Thesis

ARTIFICIAL NEURAL NETWORKS AND POSSIBILITIES OF THEIR APPLICATION IN EDUCATION

GORAN PINTARI

Abstract

In this work titled "Artificial neural networks and possibilities of their applications in education," we are explaining the concept of neural networks; during the following of the processes that occur in biological neurons, we are explaining the structure and the creation of a computer network composed of artificial neurons. This work also deals with the methodology of such systems. As well as observing the historical development of neural networks, we follow a few of the main directions in neural networks. After the previously mentioned, we describe how can these networks be implemented within the educational activities in schools. Furthermore, the work describes the intelligent systems that exist today and their ability to progress in the future.

Thesis deposited in Department of Physics library

Keywords: artificial neural networks, properties of neural network, learning system, speech analysis, student model, pattern recognition, text recognition.

Supervisor: Darko Duki , PhD, Assistant Professor

Reviewers: Branko Vukovi , PhD, Associate Professor, Stjepan Hrpka, MSc

Thesis accepted: March 26th 2013.

1. UVOD U UMJETNE NEURONSKE MREŽE

Motivacija za kreiranje novih tehnologija koje su u odre enom trenutku promijenile tijek ljudskog napretka je oduvijek bila prisutna u svim dijelovima znanosti, no, do sada, bez obzira na napredak tehnologije, nismo bili u mogu nosti kreirati zbir elektroni kih komponenti, matemati kih funkcija ili objekata koji bi u potpunosti postigli ono što je svakom ljudskom bi u uro eno, inteligencija. U ovom radu definiramo elemente koji takav sustav mogu generirati. Umjetne neuronske mreže svoj za etak pronalaze u prou avanju neurona, kao gra evnih jedinica ljudskog mozga, te na osnovu funkcija i sposobnosti skupa takvih jedinica kreiraju pravac prema ostvarenju dugo o ekivanog cilja, kreiranja umjetne inteligencije koja premašuje mogu nosti modela po kojem je kreirana. Kao sjajan model, umjetna inteligencija se zasniva na jednostavnim dijelovima koje em razmotriti te utvrditi na koji na in interakcija takvih komponenti može dovesti do „stroja“¹ koji ima osobine sli ne ljudskima. Ideja o sustavima koji mogu razmišljati, u iti, kreirati svoje okruženje, rješavati probleme, pa ak i prepoznavati emocije za ljude može biti iznimno uznemiruju a, te su u samom za etku razvoja ovog smjera znanosti definirana tri Asimova zakona robotike². Prou avamo dobrobiti takvog sustava na mogu nosti podu avanja u enika, ostvarivanja bolje interakcije s okolinom, te upravljanja pojedinim elementima ve e cjeline u kojoj se takav sustav integrira. Doti em se i implementacije ovakvih sustava, ili tek malenih dijelova istog u velike cjeline, do sada isklju ivo vo enih od strane strojeva kontroliranih pomo u ljudskog operatora, što se u potpunosti gubi integracijom neuronske mreže, bilo da se radilo o superviziranoj ili nesuperviziranoj umjetnoj neuronskoj mreži. Do danas su intelligentni sustavi postali neizostavan dio industrijskih procesa, upravlja kih sustava te istraživa kih alata, a to sve je omogu eno napretkom u raznim dijelovima uspješnih tehnologija poput elektroni kih sklopova, transporta i skladištenja energije te komunikacije. Napredak u podru ju telekomunikacija posebice je bitan, jer omogu ava umjetnom sustavu, koji svoje osobine poboljšava i usavršava interakcijom s okolinom, da sa ve im brojem upita, kreira što to nije i „pametnije“ odgovore, neiziskivaju i pritom posebno vrijeme za definiranje po etnih varijabli sustava ili dodatnu korekciju vanjskog ljudskog operatora. Sve ve a integracija sustava umjetnih neuronskih mreža je injenica o svijetu koji nas okružuje, ali, do sada nažalost nismo imali prilike iskoristiti sve dobrobiti takve okoline.

¹ Asimov I., *I, Robot*, New York: Doubleday & Company, 1950., str. 5-92.

² Anissimov M., *Deconstructing Asimov's Laws*, Berkley: Singularity Institute for Artificial Intelligence, 2010., str. 10-40.

1. NEURONSKE MREŽE

1.1.Koncept neuronske mreže

“Neuronska mreža je me usobno povezana nakupina jednostavnih elemenata obrade, jedinica ili vorova, iji se na ini djelovanja temelje na neuronima kod životinja. Sposobnost obrade mreže posljedica je ja ine veze me u tim jedinicama,a postiže se kroz proces adaptacije ili u enjem iz skupa primjera za uvježbavanje.” Prema Gurney-u, neuronska mreža je me usobno povezan sklop jednostavnih elemenata obrade, jedinica ili vorova, ija funkcionalnost je temeljena na biološkom neuronu. Sposobnost obrade podataka u mreži temelji se na jakosti poveznica same mreže, osobini koja se kreira prilikom procesa u enja od, ili prilagodbe ka odre enom setu parametara treniranja.³

Umjetne neuronske mreže su raunalni modeli obrade informacija koje funkcioniraju na sličan način kao i ljudski mozak ili kao neke druge biološke neuronske mreže. Neuron, kao osnovni građevni element neuronskih mreža, zbog svoje jednostavnosti posebno je pogodan za integraciju u raunala. Umjetne neuronske mreže⁴ pogodne su za korištenje zbog svoje jednostavnosti rada, te mogu nositi obavljanja velikog broja operacija u isto vrijeme. Iako daleko sporije od digitalne elektroničke logike⁵, biološke neuronske mreže imaju sposobnost koju umjetni sustavi ne posjeduju, a to je mogunost rješavanja složenih problema, koji zahtijevaju upotrebu velikog broja različitih veza me u pod-sustavima kako bi se zadatak uspješno riješio. Neki od primjera ovakvih situacija su razumijevanje ljudskog govora, prepoznavanje ekspresija ljudskog lica ili predviđanje događaja promatranog sustava na osnovu iskustva, te finalno, kao najzanimljivija od svih mogunosti, sposobnost u enja. Najsloženiji sustav u prirodi, pod kojim definiramo ljudski mozak isto tako ostvaruje visok stupanj paralelizma i nelinearnosti. Ipak, treba biti oprezan prilikom opisivanja funkcije ljudskog mozga. Isto se da se mozak kroz povijest uspoređiva sa u tom trenutku najsloženijim mehanizmima koji su postojali. Tako se u davna vremena mozak uspoređiva sa pneumatskim strojem, u renesansi sa satom, a krajem prošlog stoljeća sa telefonskom

³ Gurney K., *An Introduction to Neural Networks*, London: UCL Press, 1997., str. 7-33.

⁴ U nastavku teksta: neuronske mreže

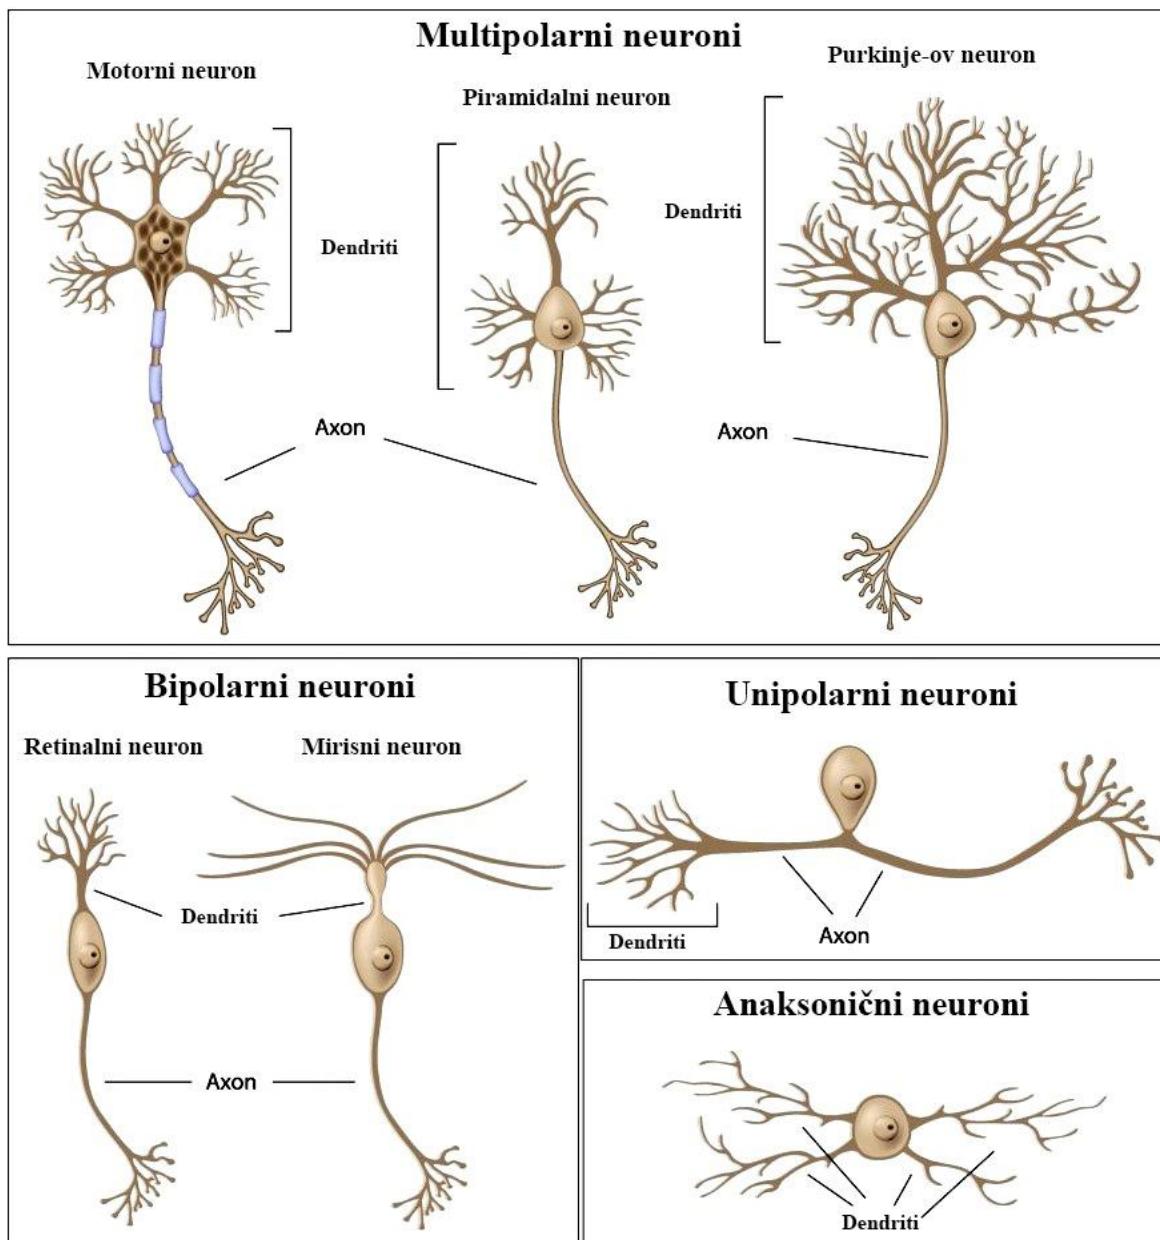
⁵ U tipičnom ljudskom mozgu nalazi se 10^{10} neurona te 10^{14} sinapsi što nam govori o veličini procesa koji se kontinuirano odvija u mozgu

mrežom⁶. Neuronske mreže, od svojih za etaka do sada promatraju se kao sustavi koji će potaknuti budućnost, te kreirati nove prilike za napredak u velikom broju područja, u kojima dakako postoji mogućnost implementacije. Velika prednost sustava neuronskih mreža je u tome što se praktično u bilo kojem segmentu tehnologije ili razvoja iste, može integrirati jedan ili nekoliko parcijalnih sustava neuronskih mreža. Kako se radi o jednostavnim sustavima koji ne zahtjevaju dodane korekcije od strane računalnog programera kako bi u ile, primjena je zbilja svestrana. Neuronske mreže samostalno imaju mogućnost korekcije na ina prijenosa informacija od jednog neurona, do drugog tako da se određeni signali pojavljuju, dok se drugi signali slabe, te se dobiva jedna vrijednost koja se prenosi na sljedeći neuron. Ja sam veza između neurona, te njihovim intenzivnjim korištenjem dolazimo do procesa u enja. Paralela između ljudskog mozga, po kojem je ovaj model definiran je vrlo jasna, ukoliko određenu informaciju, skladistično u dugoročnom pamćenju ne koristimo kroz duži vremenski period, eksponencijalno se povećava mogućnost da istu u potpunosti zaboravimo, jer, veze koje vode do takve informacije se koriste za druge procese i svakim ponavljanjem ja aju. Računalni programeri⁷, u svojim osvrtima na neuronske mreže do sada su dolazili do različitih zaključaka o iskoristivosti ovakvog modela na zadatke koje trebaju ostvariti, primarno zbog velikih očekivanja, u ovom stupnju razvoja. Neuronske mreže su moći sustavi, pomoći u kojih se mogu učiniti veliki poduhvati, no, njihov pravi potencijal se ostvaruje kontinuiranim razvojem. Većina trenutno aktivnih sustava predstavlja samo model, koji se razvija u laboratorijskim te je potrebna iznimna kolичina rada i razvoja kako bi sustav ugledao svjetlo dana. Biološki neuron specijalizirana je stanica za obradu informacija u živim bićima. Informacije u živim animi sustavima su elektrokemijski podražaji. Neuron prima informacije od drugih neurona putem dendrita. Dendriti najprije oslabljaju ili pojavljuju neke ulazne informacije te ih onda zbrajaju. Rezultat je impuls koji se šalje putem aksona i sinapsi drugim neuronima u mreži. U enje se odvija promjenom jedne sinaptičke veze. Milijuni neurona u mreži paralelno obrađuju informacije, gdje svaki neuron obrađuje samo infinitezimalno malen dio problema koji je potrebno riješiti ili naučiti. Najbitnija razlika u radu neuronskih mreža i u realu je u paralelizmu te suvišnosti neurona za pojedini proces. Uz to, biološke neuronske mreže su samostalni sustavi u kojima je svaki pojedini neuron samostalna jedinica sposobna za obradu podataka na mnogo različitih načina.

⁶ Rojas R., *Neural Networks*, Berlin Heidelberg: Springer-Verlag, 1996., str. 3-38.

⁷ Anderson D., McNeill G., *Artificial Neural Networks Technology*, NY: Kaman Sciences Corporation, 2009. str. 10-22.

Promotriti smo mogu nosti obrade informacija kompleksnih mreža sa injenih od jednostavnih građevnih djelova. U drugom dijelu rada promatramo sustave ići je rad samo djelomično ograničen.



Izvor: The Neuron – External Structure and Classification, www.interactive-biology.com/3247/the-neuron-external-structure-and-classification/

Slika 1. Jednostavni neuron

Ukoliko neurone klasificiramo, možemo definirati i preko stotinu različitih vrsta neurona, sve u ovisnosti o metodi klasifikacije⁸ koju koristimo. Svi neuroni zajedno, te njihove međusobne veze tvore sustav koji nije binaran, stabilan niti sinkroniziran. Stanice neurona se ne izmjenjuju kroz vrijeme, te posjeduju zabilješku o svim akcijama, iskustvima i događajima koji su se dogodili. Neuroni ulazne signale primaju pomoć u dendrita koji mogu biti smirujući (negativni) ili pobudjujući (pozitivni). Ukoliko takav neuron dođe u stanje dovoljne pobude, to jest, ukoliko je sumiranje signala koji dolaze do njega pozitivno, te prelazi prag pobude neurona, tada on putem aksona ispaljuje impuls. Sinaptički terminali koji izlaze iz neurona obično dodiruju tijelo drugog neurona, ili akson drugog neurona, no nisu u potpunom dodiru. Među njima postoji maleni razmak koji se zove sinapsa. Unutar svakog neurona komunikacija se odvija električnim signalima, a komunikacija preko sinapsi odvija se kemijskim podražajima. Mnoštvo neurona, koji u isto vrijeme komuniciraju kreiraju električno polje, to jest razliku električnih potencijala u različitim točkama lubanje. uređaj koji detektira takve podražaje⁹ naziva se EEG: ElectroEncephaloGraph, koji mjeri razlike u potencijalu te MEG: MagnetoEncephaloGraph koji mjeri slaba magnetna polja kreirana strujom elektrona u neuronskim sustavima.¹⁰ Na ovaj način su po prvi put vizualizirani procesi koji se događaju u neuronskim sustavima, pa nakon toga i u ljudskom mozgu. Ukoliko model neuronskih mreža direktno usporedimo sa modelom ljudskog mozga, zamjećujemo da procesi u mozgu nisu niti približno slični radu trenutno aktivnih neuronskih mreža. Razlike pri ovoj usporedbi nastaju u razvojnim mogućnostima tehnologije. Naime, trenutno možemo implementirati samo male sustave neuronskih mreža, koji su u usporedbi sa sustavom kao što je ljudski mozak poprilično primitivni. Računalni programeri, kreatori aplikacija, zbog toga nisu željeli kreirati tako kompleksan sustav kao ljudski mozak, već su definirali novi način rješavanja kompleksnih zadataka pomoću matematičkog modela neurona. Kod matematičkog modela neurona, slično kao i kod biološkog uzora, neuron prima signale od susjednih neurona, te takve signale sumira u jednu vrijednost koju nakon toga predaje aktivacijskoj funkciji. Ovakvi umjetni neuroni koji su međusobno spojeni formiraju neuronsku mrežu. U ovisnosti o vrijednosti izlazne varijable, aktivacijska funkcija određuje da li će doći do aktivacije pojedinog neurona ili će signal biti ugašen.

⁸ Najjednostavnija klasifikacija struktura: Multipolarni, Bipolarni, Unipolarni, Anaksoni

⁹ Električni događaji pojedinog elektrona traju desetke milisekundi, što zahtjeva da tisuće neurona ispaljuju u isto vrijeme kako bi se struja detektirala

¹⁰ Ben-Amar Baranga A., *Brain's Magnetic Field: A Narrow Window to Brain's Activity*, Negev: Nuclear Research Center – Department of Electrical Eng., 2010., str. 23-26.

1.1. Razlike između neuronskih mreža i računala

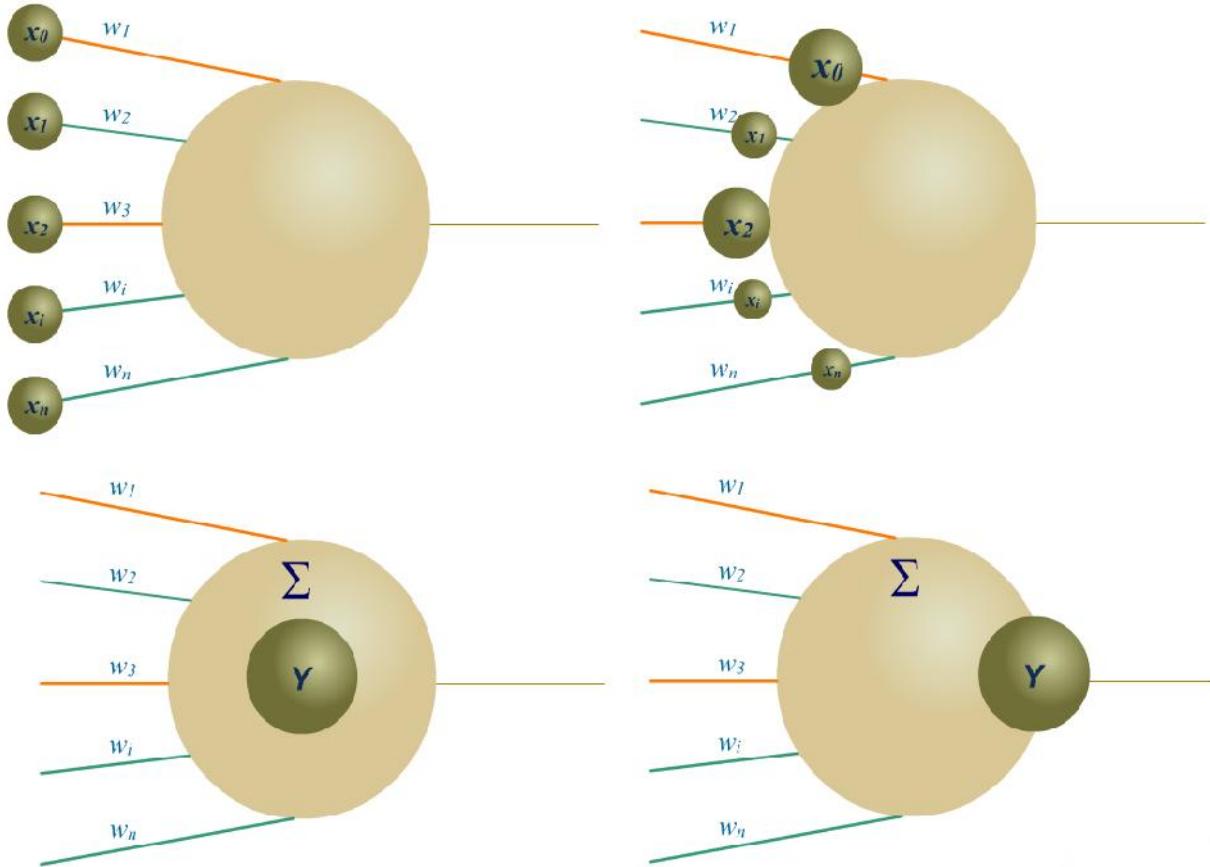
Konvencionalna računala su iznimno dobra prilikom brzih aritmetičkih te programa sa direktnim naredbama, no nisu u mogućinosti uspješno realizirati zadatke u kojima imamo podatke sa šumovima, ili podatke iz okoliša, pa tako i kada se potrebno prilagoditi okruženju iz vrlo jednostavno razloga, klasice no računalo ne može mijenjati svoju rutinu, svoj rad ukoliko u radu naiđe na prepreku koja prethodno nije predviđena programiranjem. Ukoliko takva prepreka nije predviđena, hodogram programa se zaustavlja, te se javlja greška u radu. No, neuronske mreže su sasvim drugačiji modeli od ovoga. Neuronske mreže mogu pomoći u radu bilo kojeg sustava za koji rad imamo mnoštvo primjera ili gdje ne možemo formulirati rješenje u odnosu na trenutne varijable, odnosno gdje se okolina sustava uvijek mijenja, te prepreke u radu ne možemo uvrstiti u početno programiranje s obzirom na to da nemamo informaciju kakve su sve prepreke postojati. Neuronske mreže su model multiprocesorskog računalnog sustava ali sa:

- Jednostavnim građevnim elementima
- Iznimno dobrim povezivanjem međusobnih elemenata
- Jednostavnim brojem izlaznih vrijednostima
- Mogu nositi promjene veza među pojedinim elementima

„Prilikom obrade informacija umjetni neuron prima ulazne vrijednosti od drugih neurona ili vanjskih varijabli. Ulazne vrijednosti su određeni realni brojevi x_i . Svakoj ulaznoj vrijednosti dodjeljuje se ponder „težina“ koje su ekvivalent snagu sinapsi kod biološkog neurona, w_i .¹¹ Sumiraju se ponderirane ulazne vrijednosti prema odoj formuli, funkciji prijenosa, šalje se izlazna vrijednost Y drugim neuronima.

¹¹ ERIS: *Educational Repository for Intelligent Systems*, 2003., <http://eris.foi.hr/11neuronske/nm-uvod.html>

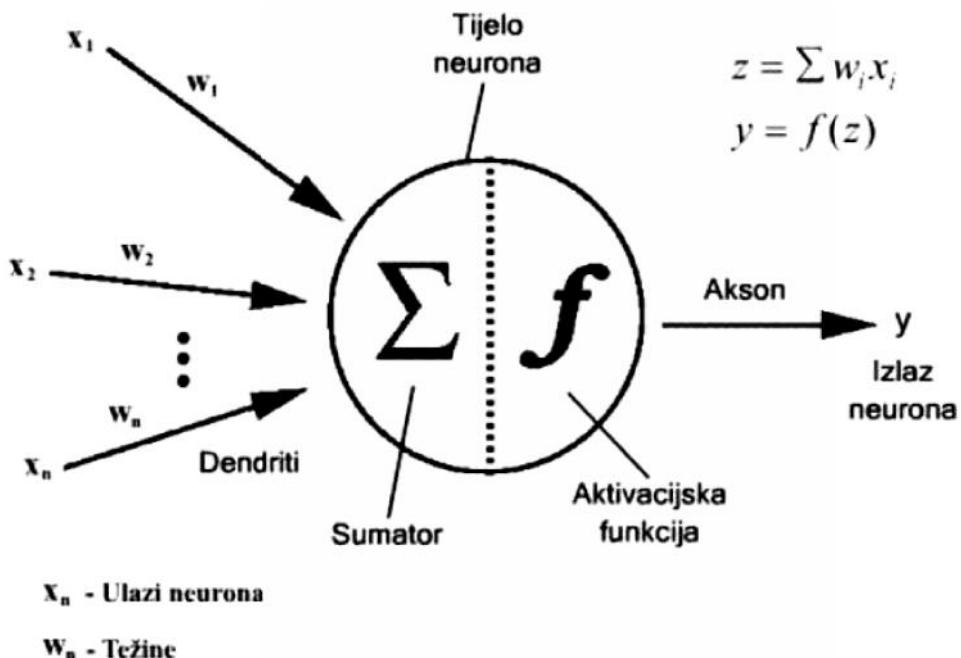
Ukoliko reprezentiramo ulazne vrijednosti te njihovu obradu, dolazimo do vizualnog slijeda udesno:



Izvor: ERIS: Educational Repository for Intelligent Systems, <http://eris.foi.hr/11neuronske/nn-uvod.html>

Slika 2. Sumiranje ponderiranih ulaznih vrijednosti

Ukoliko umjetni neuron predstavimo vrijednostima grafi ki možemo vidjeti sve sastavne elemente koji omogu avaju rad neurona. Promatramo perceptron – najjednostavniji oblik umjetnog neurona. S obzirom na to da su umjetni neuroni kreirani po uzoru na biološke neurone, dijelove opisujemo u usporedbi sa biološki neuronima.



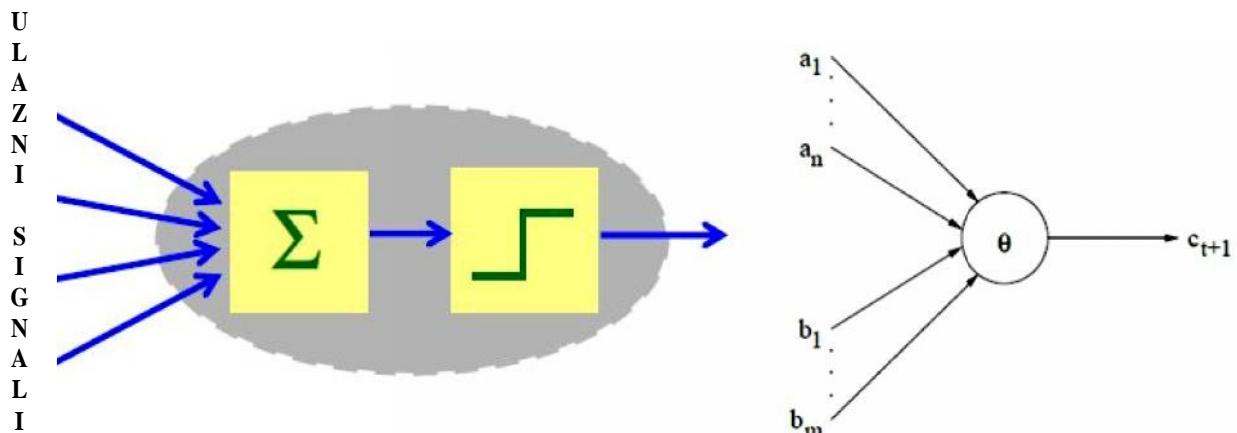
Izvor: Anderson D., McNeill G., Artificial neural networks technology, NY: Kaman Sciences Corporation, 2009.

Slika 3. Jednostavni umjetni neuron - perceptron

Aktivacijska funkcija koja određuje da li neuron prenosi informaciju prema drugim neuronima može se pojasniti na jednostavnom primjeru McCulloch-Pitts-ova neurona predloženom 1943. godine, koji se podrazumijeva kao prvi pokušaj kreiranja neuronske mreže. U ovom slučaju, vidimo sve nedostatke aktivacijske funkcije koja je kasnije uvedena. Radi se o jednostavnoj funkciji koja se naziva logička funkcija praga.¹² Neuronu se dodjeljuju binarne funkcije (1) „aktiviran“ te (0) „neaktiviran“. Definiramo dvije vrste signala koji dolaze do neurona, a to su signali pobude a_n i signali gašenja pobude b_n . Skraćeno, signali do neurona dolaze u obliku podražaja. Signali se gomilaju u stanici. Ukoliko je takav podražaj veći od praga stanice, stanica se prazni tako da podražaj prenosi drugoj stanici putem izlaza. Nakon toga, stanica ponovno može sakupljati podražaje.

$$C_{t+1} = \begin{cases} 1, & \text{ako } \sum_{i=0}^n a_{i,t} \geq \theta \text{ te } b_{1,t} = \dots = b_{m,t} = 0 \\ 0, & \text{inače} \end{cases}$$

¹² Chakraborty R. C., *Fundamentals of Neural Networks: AI Course*, NY, 2010., Lecture 37-38, www.myreaders.info/html/artificial_intelligence.html



Izvor: Anderson D., McNeill G., Artificial neural networks technology, NY: Kaman Sciences Corporation, 2009.

Slika 4. Grafi ki prikaz McCulloch-Pitts Neurona

Iako umjetni neuron sam za sebe ima određenih nedostataka, ti se nedostatci umanjuju povezivanjem neurona u mrežu na odgovarajući način. Specifična korištenja zahtijevaju „crno – bijele“ ili binarne odgovore. Ova korištenja uključuju prepoznavanje teksta, identifikaciju govora, te dešifriranje slike iz scena. Ovi načini korištenja su potrebni kako bi pretvorili realne ulazne podatke u diskretne vrijednosti. Te potencijalne vrijednosti su ograničene na neke poznate serije, kao ASCII znakovi ili najviše ih 50.000 engleskih riječi. Zbog tog ograničenja izlaznih opcija, te aplikacije ne koriste uvek mreže sastavljene od neurona koji se jednostavno zbroje, a time i imaju jednostavne ulazne vrijednosti. Te mreže mogu koristiti binarna svojstva OR¹³ i AND¹⁴ ulaza.

Najviše aktivacijske funkcije s kojima se modelira da li je neuron aktiviran ili ne na osnovu ulaznih signala su:

- Linearna funkcija
- Funkcija praga
- Djelomična linearna funkcija
- Sigmoidalna funkcija (S funkcija)
- Tangentna hiperbolna funkcija

¹³ White R., Downs T., *How Computers Work (9th edition)*, NY: Que Publishing, 2007., str. 48-62.

¹⁴ Ibid. str. 52-62.

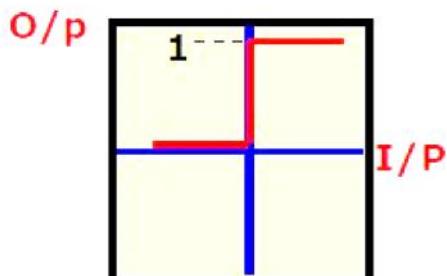
Aktivacijske funkcije se odabiru u ovisnosti o problemu koji mreža treba rješiti. Tijekom godina znanstvenici su testirali nekoliko funkcija koje oblikuju ulazne signale u izlazne signale. Najčešće korištene funkcije su funkcija praga, djelomična linearna funkcija te sigmoidalna funkcija.

- I/P – na x os nanosimo vrijednosti suma ulaznih signala
- O/P – na y os nanosimo vrijednosti izlaznih signala
- Sve funkcije dizajnirane su tako da kreiraju vrijednosti između 0 i 1

2.2.1 Funkcija praga

Funkcija praga može biti binarna ili bipolarna¹⁵.

- **binarni prag**



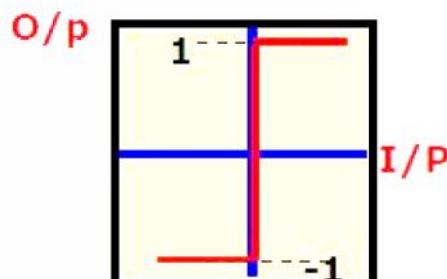
- 1** Ukoliko je suma ulaznih signala pozitivna
- 0** Ukoliko je suma ulaznih signala negativna

ako je suma ulaznih signala pozitivna
ako je suma ulaznih signala negativna

$$Y = f(I) = \begin{cases} 1 & \text{ako } I \geq 0 \\ 0 & \text{ako } I < 0 \end{cases}$$

Slika 5. Funkcija binarnog praga

- **bipolarni prag**



- 1** Ukoliko je suma ulaznih signala pozitivna
- 1** Ukoliko je suma ulaznih signala negativna

ako je suma ulaznih signala pozitivna
ako je suma ulaznih signala negativna

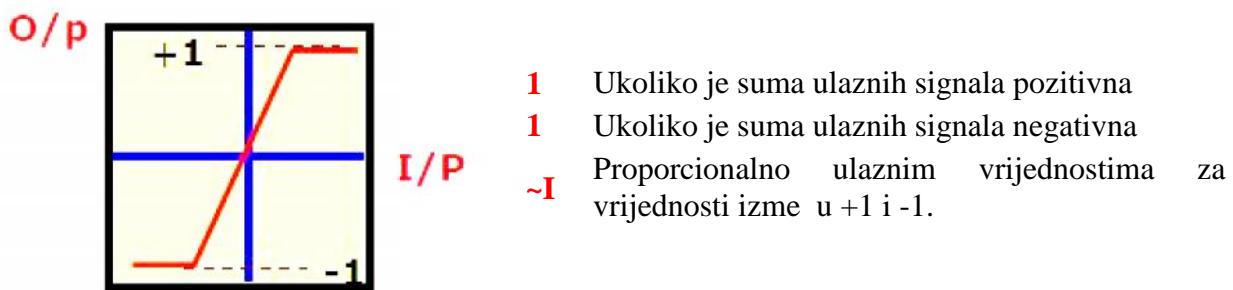
$$Y = f(I) = \begin{cases} 1 & \text{ako } I \geq 0 \\ -1 & \text{ako } I < 0 \end{cases}$$

Slika 6. Funkcija bipolarnog praga

¹⁵ Chakraborty R.C., *Fundamentals of Neural Networks: AI Course*, NY, 2010., Lecture 37-38, www.myreaders.info/html/artificial_intelligence.html

2.2.2. Djelomi na linearna funkcija¹⁶

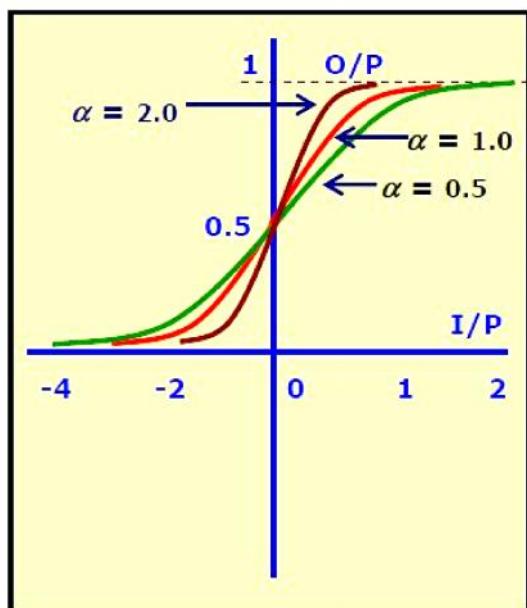
Ova funkcija se naziva još i funkcija zasi enja, te može imati ili binarni, ili bipolarni rang u ovisnosti o ulaznim vrijednostima. Radi se o nagnutoj funkciji koja poprima vrijednosti kako je opisano.



Slika 7. Djelomi na linearna funkcija

2.2.3. Sigmoidalna funkcija

Nelinearna zakriviljena S funkcija naziva se sigmoidalna funkcija.¹⁷ Ovakva funkcija je naj eš i tip funkcije korištene za kreiranje neuronskih mreža. Ona je matemati ki uredna diferencijabilna te strogo rastu a funkcija.



Sigmoidalna funkcija transfera može se napisati u obliku:

$$Y = f(I) = \frac{1}{1 + e^{-\alpha I}}, 0 \leq f(I) \leq 1$$

$$= \frac{1}{(1 + \exp(-\alpha I))}, 0 \leq f(I) \leq 1$$

- 0** Za velike pozitivne vrijednosti
- 1** Za velike negativne vrijednosti sa blagim prijelazom izme u

Slika 8. Sigmoidalna funkcija

¹⁶ Chakraborty R. C., *Fundamentals of Neural Networks: AI Course*, NY, 2010., Lecture 37-38, www.myreaders.info/html/artificial_intelligence.html

¹⁷ Op.cit., str. 10

- je parametar nagiba koji se naziva i parametar oblika; simbol θ se isto tako koristi kako bi se opisao ovaj parametar.

Ostale mreže rade na problemima gdje odgovor nije samo jedan od poznatih vrijednosti. Takav na in rada može dati neograni eno mnogo rezultata. Ove funkcije, kao i mnoge druge, mogu biti ugra ene u zbrajanje i transfer signala u mreži. Primjena ovog tipa uklju uje "inteligenciju"¹⁸, odnosno fluidnost iza robotskih pokreta. Ovakve mreže žele glatke vrijednosti ulaznih signala, koji zbog ograni enja senzora dolaze u prekidanim signalima. Kako bi realizirali glatki prijelaz na osnovu signala koji nisu kontinuiranih vrijednosti, generiraju izlazne vrijednosti pomo u hiperboli ke tangens funkcije kao funkcije prijelaza.

Na ovaj na in, izlazne vrijednosti iz ovakvih mreže su kontinuirane, te zadovoljavaju više sustava u stvarnom svijetu. Prilikom konstruiranja mreže postavlja se pitanje odabira najbolje funkcije koja e odgovarati potrebama sustava. Ova "inteligencija" obra uje ulazne vrijednosti, a zatim stvara izlazne vrijednosti koje zapravo uzrokuju pomicanje odre enog ure aja, gašenje stroja, dodavanje boje, pomicanje spremnika i tako dalje. Takav pokret može obuhvati neograni en broj vrlo preciznih pomaka.

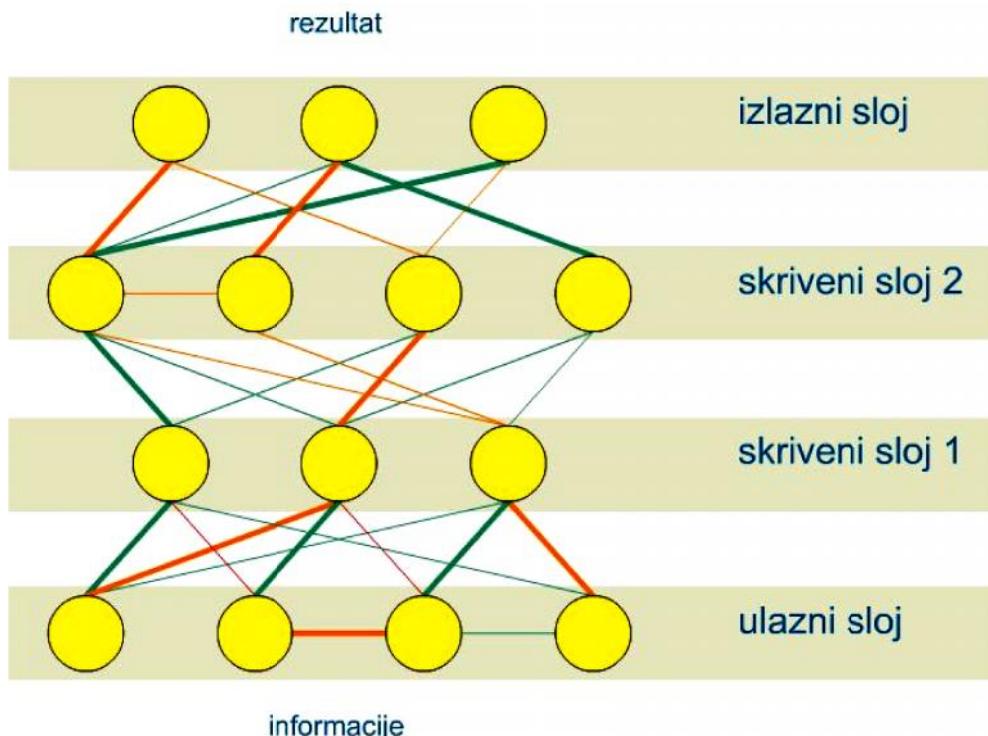
2.3. Dizajn neuronskih mreža

„Živ ani sustav ovjeka neuronska je mreža kod koje je me usobno povezano desetak milijardi neurona. Neuroni izmjenjuju i paralelno obra uju informacije, a kao rezultat ljudsko bi e u i, prepoznaće, sje a se i rješava probleme. Kod umjetne raunalne mreže neuroni su me usobno organizirani u slojeve. Ulazni sloj prima informacije iz okoline, me uslojevi ili skriveni slojevi obra uju informacije, dok izlazni sloj prikazuje rezultat mreže.“¹⁹

¹⁸ Self J., *Artificial Intelligence and Human Learning: Intelligent Computer-Aided Instruction*, London: Chapman and Hall, 1988., str. 62-73.

¹⁹ ERIS: *Educational Repository for Intelligent Systems*, 2003., <http://eris.foi.hr/11neuronske/nv-uvod.html>

Svaki neuron jednog sloja može biti povezan sa svakim neuronom istog i drugog sloja.



Izvor: ERIS: Educational Repository for Intelligent Systems, <http://eris.foi.hr/11neuronske/nm-uvod.html>

Slika 9. Organizacija neurona kod umjetnih neuronskih mreža

Dizajn umjetne neuronske mreže zapo injemo kreiranjem modela, biranjem ulaznih i izlaznih varijabli te pripremanjem ulaznih podataka. Izabire se najprikladniji algoritam, npr. *back propagation*. Neuroni se nakon toga raspore uju u slojeve. Nakon toga izabiremo broj slojeva koji će nam biti potreban za rješavanje odre enog zadatka te broj neurona u svakom pojedinom sloju. Zatim se odre uje tip veze među neuronima te ulazne i prijenosne funkcije. Finalno se izabire pravilo u enja mreže, te mjerilo za ocjenjivanje mreže. Nakon toga se provodi postupak u enja. Možemo razlikovati unaprijedne (*feed-forward*) i povratne (*feedback* ili *recurrent*) mreže. Analogno, unaprijedne mreže dopuštaju signalima da putuju od ulaza prema izlazu neurona, dok povratne veze dopuštaju da signali putuju u oba smjera. Neuronske mreže isto tako razlikujemo i po broju slojeva, te unutar ove podjele imamo jednoslojne i višeslojne mreže. Postoje različite arhitekture neuronskih mreža, a neke od njih su mreža perceptron, ADALINE/MADALINE²⁰, Hopfieldova mreža²¹, Boltzmanov stroj, višeslojna unaprijedna mreža, Kohonenova mreža i slične. Neuronske mreže su najefikasnije

²⁰ Arbib M. A., *The Handbook of Brain Theory and Neural Networks*, Cambridge: MIT PRESS, 1990., str. 13-48.

²¹ John Hopfield uvodi dvosmjerne veze u mrežu kako bi poboljšao efikasnost mreže

u rješavanju onih problema za koje nemamo definiran algoritam. One se ne programiraju za obavljanje specifičnog zadatka poput rada unala, već u putem primjera. Iako ovaj pristup ima mnogobrojne prednosti, nedostatak je taj što funkcioniranje neuronske mreže može biti nepredvidivo upravo zato što mreža sama uči kako riješiti problem²².

Algoritamski pristup²³ koji se koristi prilikom rada rada unala zahtjeva poznavanje svih relevantnih elemenata na osnovu kojih će rješavati problem, a također i svi podaci moraju biti ispravni kako bi dobilo ispravno rješenje. Neuronska mreža je u prednosti i zahvaljujući paralelnom procesiranju podataka te suvišnosti ima mogućnost lakše i jednostavnije riješiti zadani problem, zbog toga jer ne postoji kraj u hodogramu, neuronska mreža svaku prepreku prepoznaće kao novu varijablu s kojom može dalje raditi. Za razliku od nje, klasično von Neumannovo²⁴ rada unalo podatke procesira serijski, odnosno dok ne završi s jednom sekvencom rada unanja, ne može preći na drugu. Kao primjer definiramo višeslojni perceptron²⁵.

2.4. Mehanizam učenja neuronske mreže

Neuronske mreže kreiraju se učenjem. Učenje se odvija promjenom vrijednosti težina među neuronima. Usporeduju se tražene i dobivene vrijednosti te se pomoći u njih radi unašanja greška. Greška služi za korekciju težine veza među neuronima. Težinu veza možemo vizualizirati debljinom linije koja povezuje dva neurona u različitim slojevima na slici 9. Ukoliko je težina između dva neurona veća, to znači da će linija biti deblja, tećeći da dva neurona komunicirati bolje, brže i kvalitetnije. Proses učenja odvija se po jednom od pravila učenja, sa tim se korigiraju težine veza kako bi se javila što manja greška. Najmanja moguća greška znači da su težine između neurona dobro odabrane, te da su ulazne i izlazne vrijednosti najbolje određene. Metode učenja koje smo do sada spomenuli su:

- supervizirano učenje
- nesupervizirano učenje
- potkrijepljeno učenje

²² Zurada J.U., *Introduction to Artificial Neural Systems*, NY: West Publishing Company, 1992., str. 3-26.

²³ Freeman J.A., Skapura D.M., *Neural Networks - Algorithms, Applications, and Programming Techniques*, London: Addison-Wesley Publishing Company, 1991., str.43.

²⁴ Norton R.H., *The von Neumann Architecture of Computer Systems*, Pomona: California State Polytechnic University, 1987., str. 43.

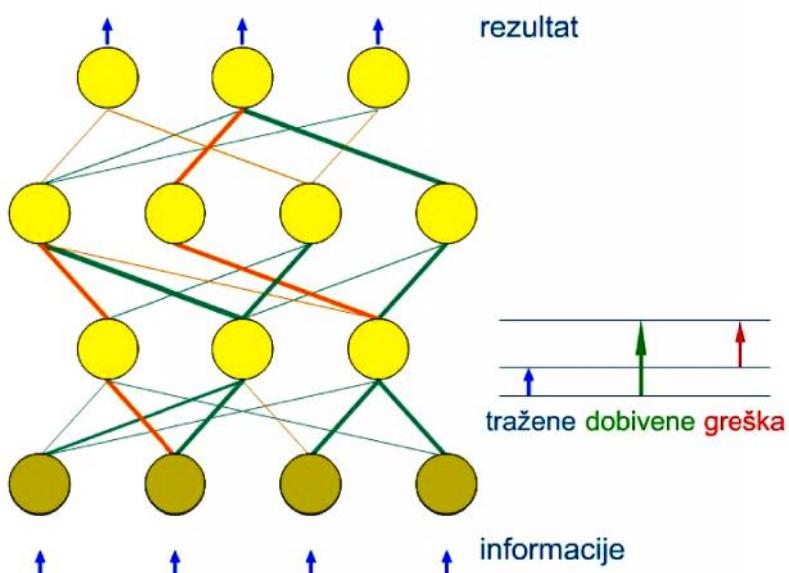
²⁵ Anderson D., McNeill G., *Artificial Neural Networks Technology*, NY: Kaman Sciences Corporation, 2009. str. 18-49.

Ova tri načina učenja potkrijepljena su:

- prisustvom ili odsutnošću profesora/programera
- informacijama ponuđenima sustavu kako bi učio

Nadalje, metode učenja segmentirane su po pravilima za učenje koja su korištena na²⁶:

- Hebbianovo učenje
- Radikalno učenje
- Kompetitivno učenje
- Stohastičko učenje



Izvor: ERIS: Educational Repository for Intelligent Systems, <http://eris.foi.hr/11neuronske/nm-uvod.html>

Slika 10. Proces učenja neuronskih mreža

Tri spomenuta algoritma učenja neuronskih mreža pojašnjavamo pomoću jednostavnih primjera. Od algoritama supervizornog učenja najčešće je u upotrebi algoritam povratnog propagiranja²⁷ (*back-propagation algorithm*). Potrebno je razlikovati arhitekturu neuronske mreže i njezin algoritam učenja, prvo se odnosi na opis određene arhitekture i postupka kojim neuronska mreža radi svoj izlaz na osnovu skupa ulaza. Drugo je opis algoritma učenja koji

²⁶ Chakraborty R.C., *Fundamentals of Neural Networks: AI Course*, NY, 2010., Lecture 37-38, www.myreaders.info/html/artificial_intelligence.html

²⁷ Wiener R., *Neural Networks*, Sydney: The University of Sydney, 2003., str. 10-14.

se koristi za podešavanje mreže kako bi postala uspješnija u produciranju željenog izlaza.²⁸ Prilikom postupka povratnog propagiranja, sustav nastoji smanjiti pogrešku koja je kreirana tijekom u enja, što direktno utje e na promjenu težine veza izme u neurona. S obzirom na to u kojem smjeru treba podešavati težinu veza, polagano se smanjuje greška u dobivenom rezultatu kao na slici 10. Ipak, algoritam e više puta prona i lokalni minimum,ime neuronska mreža nije postigla optimalne rezultate, odnosno u enje nije u potpunosti efektivno. Koji od minimuma algoritam pronalazi ovisi i o po etnim vrijednostima težina. Zbog svega navedenog možemo zaklju iti da uvježbavanje iste mreže daje druga ije rezultate. Kako se algoriram ne bi zadržavao na lokalnom minimumu, razvijen je postupak simuliranog kaljenja (simulated annealing)²⁹. Ono što se doga a kod ovakvog procesa je kontinuirano smanjenje veli ine koraka u enja. Ako je veli ina koraka u enja konstanta, tada se može dogoditi da mreža mijenja stanja iz max u min, no, ukoliko smanjujemo veli inu koraka u enja, tada postoji trend kretanja prema globalnom minimumu. Na isti na in koriste se i genski algoritmi.

Daleko zanimljivija situacija doga a se kod procesa nesuperviziranog u enja za što je primjer Kohonenova neuronska mreža³⁰. Glavno obilježje ovakve mreže je samoorganizacija, to jest mogu nost u enja bez vanjskog u itelja. Ono što je bitno jest da mreža na osnovu ulaznih uzoraka mijenja vrijednosti težina izme u neurona prema odre enom algoritmu, sve dok se ne uspostavi stanje ravnoteže koje se o ituje u nemogu nosti dalnjih promjena težina. Procjena rezultata ovakvih mreža je prakti no nemogu a jer za vrijeme u enja nije odre en željeni izlaz. Ovakve mreže koriste se u situacijama u kojima nismo sigurni što je potrebno klasificirati. Od slu aja nesuperviziranog u enja izdvajamo Kohonenovu mrežu. Radi se o kompetitivnom u enju. Ovakav pristup u enju zasnovan je na ideji da ako „ispravni izlaz „pobjedi“, ak i tjesnom pobjedom, tada e porast vrijednosti težina neurona isti rezultat u initi vjerojatnjim, ako do e do sli nih okolnosti.“ Neuroni se me usobno natje u za dobivanje prava na promjenu vrijednosti težina. Pritom postoje dvije izvedbe algoritma u enja. U jednoj samo neuron pobjednik ima pravo mijenjati vrijednosti težina, dok u drugoj i okolni neuroni koji ga okružuju tako er mijenjaju vrijednosti težina, samo je ta promjena manja. Ovakav pristup u enju zasnovan je na ideji da ako „ispravni izlaz „pobjedi“, ak i

²⁸ Toulouse G., *Statistical Physics, Neural Networks, Brain studies*, Paris: Laboratoire de physique, 1999., str. 46 -113.

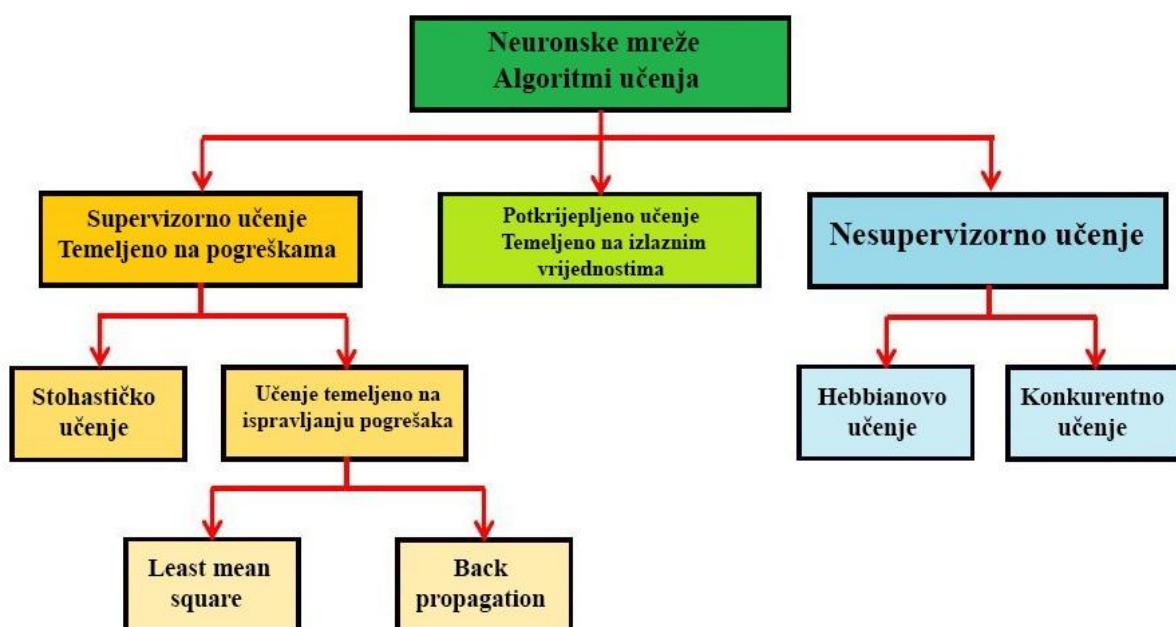
²⁹ Bertsimas D., Tsitsiklis J., *Simulated Annealing*, Cambridge: MIT, 1993., str. 8-36.

³⁰ Žalac N., *Poslovna analiza i upravljanje - Neuronske mreže – ju er, danas, sutra*, Zagreb: INTUS BIT, 1999., str. 3-13.

tijesnom pobjedom, tada je porast vrijednosti težina neurona isti rezultat u inicijalnoj vjerovatnijim, ako dođe do sličnih okolnosti.“³¹

Finalno dolazimo do zadnjeg algoritma što definiramo kao učenje potkrepljenjem. Ovakav način učenja je prethodno poznat iz psihologije, prilikom proučavanja procesa učenja kod pasa. Naime, radi se o principu učenja neuronskih mreža kod kojega inteligentni stroj temeljen na neuronskoj mreži djeluje u okolini. Za bilo koju kreiranu akciju ili radnju stroj dobiva povratnu informaciju iz okoline, a cilj učenja je porast broja uspješnih akcija. Na osnovu povratne informacije iz okoline stroj mijenja težinu veza među neuronima. Kada se postigne stanje ravnoteže, tada mijenjanje težina više nije moguće, a samim time i proces učenja završava.

Definiramo još online pristup pri kojem mreža uči kroz rad, što je još jedan opis nesupervizornog učenja te offline pristup gdje se učenje odvija u zasebnoj fazi što je primjer supervizornog učenja. Ukoliko pokušamo vizualno predstaviti hijerarhijski poredak prvotno spomenutih algoritama dolazimo do klasifikacije³²:



Izvor: Chakraborty, R. C., Fundamentals of Neural Networks,
www.myreaders.info/html/artificial_intelligence.html

Slika 11. Klasifikacija algoritama učenja

³¹ Mullier D. J., *The Application of Neural Network and Fuzzy Logic Techniques to Educational Hypermedia*, Boston: British Journal of Educational Technology, 2005., str. 43-55.

³² Chakraborty R.C., *Fundamentals of Neural Networks: AI Course*, NY, 2010., Lecture 37-38, www.myreaders.info/html/artificial_intelligence.html

2.5. Primjena neuronskih mreža

Vjerujem kako bi bez dodatnog znanja o neuronskim mrežama i njihovim integracijama u raznolike sustave ve na prvo pitanje o upotrebi neuronskih mreža nakon itanja dosadašnjih poglavlja uspješno odgovorili. Neuronske mreže su svugdje oko nas, bilo da se radi o robotskom usisava u koji na pametan na in isti ku u bez intervencije ili da se radi o Vašem pametnom telefonu koji prepoznačuje tekstu koji upišete pomo u dodirnog zaslona. Ukoliko prepostavimo da svaki ure aj koji u nazivu posjeduje kriлатicu „pametan/pametno“ ima odre eni dio neuronske mreže u sebi, neemo pogriješiti. Trenutno je mobilna industrija prepoznala napredak te u primjenu preuzela umjetne neuronske mreže u *cloud* sustavima, što možemo iskusiti iz prve ruke putem aplikacije SIRI³³ a kasnije i procvat usluga putem iste tehnologije koje e uskoro dominirati svim proizvodima koji budu komercijalno dostupni. Neki od njih su: „SKYVI, IRIS, ROBIN, VLINGO, MALUUBA.³⁴ Iako neuronske mreže imaju velik broj primjena te je iznimno teško nabrojati ili klasificirati sve od njih, krenuti emo od najraširenije tehnologije³⁵ prema specifi nim situacijama:

- **Prepoznavanje govora³⁶** - neuronske mreže imaju iznimnu sposobnost, koja e sa nadolaze im vremenom biti zna ajno iskorištena, a to je prepoznavanje ljudskog govora. Trenutno postoje komercijalni sustavi koji nude razne mogu nosti prepoznavanja govora, bilo da se radi o pomo i invalidnim osobama, do sustava sigurnosti gdje je potrebna glasovna verifikacija. Ono što se doga a u pozadini mogu nosti prepoznavanja govora je vrlo jednostavna obrada ulaznih signala na osnovu glasovnih podražaja te obrada istih kako bi se dobila vrijednost koja se podudara sa odre enom, sustavno odabranom abecedom. U ovom slu aju, radi se o sustavu koji je treniran, nau en, te u trenutnom stadiju razvoja, sustav koji pokazuje najviše potencijala, no, isto tako je potrebno uložiti najviše rada. Ukoliko uzmemo u obzir broj jezika na zemlji, te broj dijalekata odre enog jezika, vrlo lako možemo do i do zaklju ka da e sustav prepoznavanja govora morati pro i kroz velik broj ina ica kako bi pravilno razumijevao govor.

³³ Apple, Inteligentni osobni pomo nik, te navigator koji koristi govor za interakciju te u i na osnovu vremena koje provede u istoj sa osobom koja koristi samu uslugu, prvi put komercijalno dostupan 2010. godine

³⁴ Komercijalno dostupne aplikacije koje na osnovu upravljanja glasom mogu ostvariti interakciju sa pojedincem, trenutno dostupne na mobilnim ure ajima, za svoj rad koriste CLOUD tehnologiju te umjetne neuronske mreže.

³⁵ Anderson D., McNeill G., *Artificial Neural Networks Technology*, NY: Kaman Sciences Corporation, 2009. str. 30-48.

³⁶ Vigliocco G., Warren J., Siri S., Arciuli J., Scott S., Wise R., *The Role of Semantics and Grammatical Class in the Neural Representation of Words*, London: University College., 2006., str. 1791-1796.

- **Prepoznavanje uzorka** – u ovom sluaju postoji veliki broj potencijalnih industrijskih načina da se iskoristi sposobnost mreže da prepozna uzorke, no, ono što možemo upotrijebiti u praksi prilikom podučavanja ili prenošenja znanja je most prepoznavanja upisanih znakova putem senzora, bilo da se radi o infracrvenom ili dodirnom senzoru. Ukoliko pokušamo prenijeti svoj napisan na pametnu plohu ili eventualno dodirni zaslon, ubrzo ćemo zamjetiti kako se prepoznavanje pisanja sve više poboljšava što više koristimo takav sustav. Proces u enja s ponavljanjima podražaja iz okoline vrlo jasno definira željene vrijednosti izlazne varijable u odnosu na unesenu vrijednost.
- **Obrada signala** – kod ovog korištenja neuronske mreže, vrlo rano smo došli do spoznaje da neuronska mreža ima mogućnost smanjenja šuma u izobličenim električnim signalima putem postupka segmentacije. Ukoliko promatramo krivulju električnog signala, MADALINE³⁷ mreža ima mogućnost izgладити takvu krivulju kako bi se šum u telefonskoj liniji, za što je ovakva mreža prvi put korištena, iznimno smanjio. Prvu ovakvu mrežu izgradio je Widrow.³⁸
- **Servo kontrole** - kontrola složenih sustava je jedan segment u kojem neuronske mreže imaju naviše mogućnosti za rast. Za upravljanje sustavom koristi se set formulacija koje su prethodno odredene. Ukoliko se okruženje sustava promijeni, ili se sustav nađe pred novom zaprekom u radu, set formula koje upravljaju sustavom moraju biti ručno izmjenjene. Takav posao je intenzivan do te mjeru da je svaki parametar koji utječe na rad sustava potrebno posebno podešiti kako bi rad istog bio fluidan. Statistički model umjetnih neuronskih mreža je mnogo kompleksniji od seta formula koji sustavu omogućavaju rad u razliitim okolnostima bez izmjena na upravljačkom skupu formulacija. Unutar naftne industrije, neuronske mreže koriste se prilikom upravljanja protoka fluida, te to nije tako da protok uvijek bude optimalan održavajući bitne varijable sustava u normalnim razinama. NASA³⁹ je neuronske mreže upotrijebila kako bi kontrolirala space shuttle prilikom uzlijetanja ili spajanja sa ISS⁴⁰-om. Sustav se

³⁷ Arbib M.A., *The Handbook of Brain Theory and Neural Networks*, Cambridge: MIT PRESS, 1990., str. 23-37.

³⁸ Widrow B., Lehr M. A., *Perceptrons, Madaline, and Backpropagation*, Cambridge: MIT PRESS, 1990., str. 13-96.

³⁹ NASA, National Aeronautics and Space Administration, Houston: Huntsville AL te Canaveral FL

⁴⁰ ISS, Međunarodna svemirska postaja (eng. International Space Station - ISS), međunarodno je razvijena istraživačka postaja koja se trenutačno sastavlja u Zemljinoj nižoj orbiti

- naziva Martingale's Parametric Avalanche⁴¹. Drugi sustav koji se koristi prilikom rada je ALVINN⁴², za samostalni putuju i rover sa neuronskom mrežom.

Neuronske mreže koriste se još i kod kontrole i optimizacije procesa, kompresija slikovnih sadržaja, u medicini, te imaju iznimno značajnu poslovnu primjenu u bankama, telekomunikacijama te u marketinške svrhe, ali, kako smo napomenuli, ukoliko se u bilo kojem trenutku, bez obzira na to gdje se nalazite osvrnete oko sebe, postoji velika vjerojatnost da ćete ugledati sustav koji u svom sastavu ima dio neuronske mreže.

2.6. Kako najbolje upotrijebiti neuronsku mrežu

Kao što se vidi po prethodno navedeni poglavljima, neuronske mreže se uspješno primjenjuje u brojnim područjima. Svaku od tih aplikacija može se svrstati u dvije kategorije⁴³. Ove kategorije nude mogunosti za svakoga tko razmišlja o upotrebi umjetnih neuronskih mreža. Potencijalna primjena treba biti ispitana za sljedeća dva kriterija: Može li neuronska mreža zamijeniti postojeće tehnologije u području gdje mala poboljšanja u performansama mogu rezultirati velikim ekonomskim uinkom? Primjeri aplikacija koje zadovoljavaju taj kriterij su:

- Odobrenja kredita
- Odobrenja kreditnih kartica
- Predviđanja u segmentu financijskih tržišta
- Stvaranje popisa kontakata na osnovu potencijalne mogunosti korištenja raznih usluga

Može li se neuronska mreža moći koristiti u području gdje su se trenutne tehnologije dokazale kao nedovoljne kako bi održale sustav u optimalnim vrijednostima? Primjeri aplikacija koje zadovoljavaju taj kriterij su:

- Prepoznavanje govora
- Prepoznavanje teksta

⁴¹ Dawes R., *The Parametric Avalanche Control Module Prototype Development*, Austin: Martingale Research Corporation, 1992., str. 1045-1057.

⁴² Pomerleau D.A., *Alvinn, An Autonomous Land Vehicle in a Neural Network*, Pittsburgh: Carnegie Mellon University, 1989., str. 56-68.

⁴³ Anderson D., McNeill G., *Artificial Neural Networks Technology*, NY: Kaman Sciences Corporation, 2009. str. 50-68.

- Meta analiza (Primjer gdje druga tehnologija nije bila u mogunosti otkriti prisutnost eksploziva u zravim lukama. Prethodni sustavi nisu mogli postići FAA⁴⁴ propisanu razinu izvedbe, ali dodavanjem neuronskih mreža, sustav je ne samo premašio o ekivanja, nego i dopustio zamjenu, to jest isključio komponenti vrijednih 200 000 dolara.)

Najuspješnije aplikacije umjetnih neuronskih mreža usmjerene su samo ka jednom dijelu, jednom problemu, u velikom volumenu ili velikom sustavu. Najlakša implementacija neuronskih mreža kreira se u sustavima gdje one mogu biti kreirane tako da se samo uključuju u određene dijelove, bez bitnijih preinaka u osnovnom modelu sustava.

2.7. Povijest neuronskih mreža, trenutno stanje i budući razvoj

Proučavanje ljudskog mozga staro je stotinama godina. Napretkom novih tehnologija, bilo je u potpunosti prirodno pokušati zauzdati proces razmišljanja. Prvi korak prema svijetu neuronskih mreža napravljen je 1943. godini kada su Warren McCulloch⁴⁵, neuropsiholog, te mladi matematičar Walter Pitts⁴⁶ napisali članak o tome kako bi mozak mogao raditi. Kreirali su jednostavan model neuronske mreže sa električnim krugovima. U vršaju i ovaj koncept o neuronima te kako oni rade Donald Hebb napisao je rad „Organizacija ponašanja“⁴⁷ („The Organization of Behavior“) u kojem je istaknuo da veze među neuronima jačaju svaki put kada se koriste, što je ujedno temelj ljudskog učenja. Prilikom napretka radijalna u 1950-tim godinama prošlog stoljeća, bilo je moguće kreirati rudimentarne modele ljudske misli. Nathaniel Rochester iz istraživačkog laboratorija IBM-a poveo je do prvog pokušaja izrade neuronske mreže u kojoj je neurone posložio u jedan sloj, te je nasumice spojio izlaze neurona na ulaze drugih neurona. Prvi pokušaj je propao. No kasnije je uspio te je prilagodio Hebbianovo pravilo vršeći i normalizaciju svih vrijednosti težina kako bi uvijek iznosile konstantnu vrijednost. Prilagodba je izvršena s ciljem uklanjanja mogućnosti da sve vrijednosti težina veza koje se još ne upotrebljavaju s vremenom narastu do svoje maksimalne vrijednosti.

Rochester je nastojao postići da vrijednosti težina veza za koje je porast vrijednosti jedne težine bude proporcionalan smanjenju vrijednosti drugih težina za ekvivalentni iznos.

⁴⁴ FAA, Federal Aviation Administration, Washington, DC

⁴⁵ McCulloch W., Pitts W., *A Logical Calculus of the Ideas Immanent in Nervous Activity*, Berlin Heidelberg: Springer Verlag, 1943., str. 13-43.

⁴⁶ Ibid

⁴⁷ Hebb D.O., *The organization of Behavior*, Oxon: Psychology Press, 2012., str. 125-144.

Međutim, u okviru ovog modela dolazi do navikavanja kojeg objašnjava kao „zamor“ neurona u kojeg drugi neuron esto ispaljuje impulse. U tom neuronu dolazi do povećanja praga, te on stoga po inje rječi slati odgovore. Rezultat je bila mreža koja nije tvorila skupine. Kako bi ipak postigli da mreža tvori skupine, formirali su mrežu u kojoj skupine mogu nastati ako je većina sinapsi u skupini izlazno, dok su one među skupinama stanica inhibitorne. Rezultat toga bilo je stvaranje skupina isključivo oko ulaznih područja. Model su nazvali F.M.⁴⁸ jer su se umjesto binarnim impulsima koristili frekvencijama ispaljivanja impulsa. No, tih godina računalna industrija je procvjetala te je s tim ostavila neuronske mreže u sjeni. Ipak, 1958. godine Frank Rosenblatt uvodi promjene u model službenih neuronskih mreža, napuštajući i ideju samostalnog formiranja skupine neurona. Izrađuje neuronsku mrežu sa sposobnošću nesupervizornog učenja. U njoj su veze nasumice spojene jedino među različitim slojevima neurona. Umjesto memorije koristi promjene u odnosu između odredenog ulaza i odredenog izlaza do kojih dolazi uobičajenom upotrebom. S godinama koje dolaze, zagovornici „razmišljaju ih strojeva“ kontinuirano su se pokušavali boriti za svoje ideje. 1956. godine Dartmouth Summer Research Project on Artificial Intelligence pružio je potreban pomak i neuronskim mrežama i umjetnoj inteligenciji. Jedan od ishoda ovakve situacije bio je stimulacija istraživanja i UI-a, te u mnogo manjoj mjeri neuronske procese u mozgu.

U godinama koje dolaze nakon toga, John von Neumann predlaže imitaciju funkcija jednostavnog neurona pomoću telegrafskih releja ili vakumskih cijevi. Isto tako, Frank Rosenblatt, neurobiolog sa Cornell-a počinje raditi na svom projektu perceptron. Bio je oduševljen operacijom oka mušice. Naime, većina procesa koji govore mušici da leti nalazi se u oku. Perceptron, koji je proizašao iz ovog istraživanja bio je ugrađen u sučelje te se smatra najstarijim neuronskim uređajem još uvek u upotrebi do danas. Jednoslojni perceptron koristan je kao uređaj za klasificiranje kontinuiranih vrijednosti ulaznih varijabli u jednu od dvije klase. Nažalost, ovi prvi uspjesi neuronskih mreža nisu bili dovoljni kako bi potaknuli znanstvenike na bavljenje neuronskim mrežama pogotovo u svjetlu ograničenja elektronike koja su tada postojala. Isto tako, pojavio se strah zbog nekoliko pisaca koji su postavili pitanje što bi se dogodilo kada bi „strojevi koji razmišljaju“⁴⁹ preuzele vlast nad čovjekom. Asimova serija o robotima otkrila je efekte na ljudski moral i vrijednosti kada su strojevi mogli u inicijativi poslove koji su bili dostupni na zemlji. Takvi strahovi, u kombinaciji sa neispunjenošću, drskim tvrdnjama rezultirali su mnogim kritikama na razvoj neuronskih mreža.

⁴⁸ Tomabechi H., Kitano H., *Beyond PDP: The Frequency Modulation Neural Network Architecture*, Pittsburgh: Carnegie Mellon University, 2008., str. 69-88.

⁴⁹ Asimov I., *I, Robot*, New York: Doubleday & Company, 1950., str. 63-92.

Takav doga aji prouzrokovao je povlaenje sredstava iz istraživanja, a takva je situacija trajala do 1981. godine.

Godine 1982. nekoliko doga aja prouzrokovalo je poveanje interesa za neuronske mreže. John Hopfield sa sveučilišta Caltech predstavio je svoj rad nacionalnoj akademiji znanosti. Hopfield-ov pristup nije bio samo modeliranju ljudskog mozga i misaonih procesa, već je svrhu rada posvetio kreiranju korisnih strojeva. Jasno om iskaza i matematičkom analizom, pokazao je kako neuronske mreže mogu raditi, te što sve mogu u initi. Ipak, Hopfield-ova najveća sposobnost bila je njegova karizma. Bio je artikuliran, zanimljiv te je prvi pokrenuo do tada već uspavanu tehnologiju. Iste su godine Reilly i Cooper upotrijebili hibridnu višeslojnu mrežu⁵⁰ u kojoj je svaki sloj koristio drugačiju strategiju rješavanja problema. U isto vrijeme, drugi doga aji je ponukao znanstvenike na rade o neuronskim mrežama. Konferencija u Kyotu, u Japanu, gdje je Japan objavio svoju petu generaciju neuronskih mreža te trenutne rezultate. SAD je periodično pratilo doga aje, ali, sada je došlo do zabrinutosti oko napretka tehnologije u rukama suparnika. Nakon takvog doga aja velike količine novca dodijeljene su istraživanju i proučavanju neuronskih mreža. Do 1985. godine američki institut za fiziku krenuo je organizirati svoje godišnje sastanke – Neural Networks for Computing.⁵¹ 1986. godine pojavile se intenzivno razmatrati problem prilagodbe Widrow-Hoff pravila višeslojnim mrežama⁵². Tri nezavisne istraživačke skupine došle su do sličnih zamisli, tj. da neuronske mreže zasnovane na algoritmu povratnog propagiranja. Dok je hibridna mreža bila sastavljena od samo dva sloja, mreža zasnovana na algoritmu povratnog propagiranja imala je više slojeva. Do 1987. Institut za elektroniku i elektronički inženjerstvo (IEEE) privukao je na svoja godišnja okupljanja više od 1800 sudionika. 1989. godine na sastanku neuronskih mreža za obranu, Bernard Widrow rekao je svojim kolegama da su bili sudionici 4. svjetskog rata, jer se 3. svjetski rat nikada nije dogodio, gdje su bojna polja bila svjetska kapitalna tržišta i proizvodnja. 1990. godine ministarstvo obrane SAD-a definiralo je 16 poglavljaja posebno usmjerenih na razvoj neuronskih mreža sa dodatnih 13 u kojima se spominje korištenje istih.

Danas se rasprave o neuronskim mrežama odvijaju svugdje. Obe strane koje se mogu uti u korist nove tehnologije su blistava, ali imaju kredibilitet jer potiču u iz prirodnih procesa koji jamči da ovakvi sustavi imaju budućnost te da mogu egzistirati. Ipak, sama budućnost

⁵⁰ Perrone M.P., Cooper L.N., *When Networks Disagree: Ensemble Methods for Hybrid Neural Networks*, Rhode Island: Brown University, 1992., str. 42-65.

⁵¹ Anderson D., McNeill G., *Artificial Neural Networks Technology*, NY: Kaman Sciences Corporation, 2009. str. 72-96.

⁵² Ibid

ovog tipa tehnologije leži isključivo u razvoju hardvera. Trenutno, većina neuronskih mreža samo dokazuje principijelno kako neuronske mreže uspješno rade, dokazujući i time naelo, ali ne i potpununost integracije ili preuzimanje cjelokupnih sustava. Zbog ograničenja u smislu tehnologije, određeni postupci, pa i oni relativno složeni mogu trajati tjednima, pa i mjesecima kako bi se neuronska mreža ponašala na odgovarajući način. Kako bi se ovi prototipovi mogli isključiti u laboratoriju, te aktualizirati u realnom okruženju, potrebni su specijalizirani optički te mnogo procesorske snage. Nekoliko tvrtki radi na razvoju tri tipa neuro-procesora, digitalnom, analognom te optičkom. Određene tvrtke rade na kreiranju silikonskog množitelja⁵³ kako bi generirali neuronsku mrežu u kojoj će moći egzistirati (ASIC) ili Application Specific Integrated Circuit⁵⁴. Ovi procesori koji rade poput neurona pokreću novi val koji ubrzano ide prema bliskoj budnosti. Optički ipovi izgledaju iznimno obe avajuće, iako mogu proći godine prije nego se i jedan od njih pojavi u komercijalno dostupnim strojevima ili u upotrebi u raznim elementima elektroničkih krugova.

2.7.1. Genetski algoritmi

U enje u neuronskim mrežama je proces optimizacije u kojem je funkcija greške funkcija po kojoj je greška mreže minimalizirana. Bilo koja valjana numerička metoda može biti korištena za optimizaciju. Zbog toga je potrebno provjeriti sve mogućnosti koje su dostupne. Genetske algoritme⁵⁵ osmislio John Holland 1975.g., temeljeći ih na idejama sa područja evolucijske biologije. Osnovna ideja koja stoji iza genetskih algoritama je odabir najodrživijeg rješenja problema, što je ekvivalent prezivljavanju najsposobnijih i najprilagođenijih jedinki u prirodi. Proces evolucije je simuliran na računalu u smislu odabira parametara koji daju minimum ili maximum funkcije. Pomoći u genetskog algoritma⁵⁶ odabiremo najodrživije rješenje te dolazimo do iterativnog postupka koji se odvija kroz nekoliko koraka:

- Odabir populacije rješenja
- Evaluacija svakog pojedinog rješenja
- Izbor najboljih rješenja
- Genetsko manipuliranje rješenjima kako bismo dobili novu populaciju rješenja

⁵³ Denyer P.B., Renshaw D., Bergmann N., *A Silicon Compiler for VLSI Signal Processors*, Brussels: European Solid-State Circuit Conference (ESSCIRC), 1982., str. 215–218.

⁵⁴ Smith M.J., *Application of Specific Integrated Circuits*, Boston: Addison-Wesley, 1997., str. 13-25.

⁵⁵ Booker L., Kaufman M., editor, *Improving Search in Genetic Algorithms*, Los Altos: Morgan Kaufmann Publishers, 1987., str. 61–73.

⁵⁶ Whitley D., *A Genetic Algorithm Tutorial*, Colorado: Colorado State University, 1989. str. 42-62.

Ponavljamo korake sve dok ne pronađemo zadovoljavajuće rješenje. Pritom se u terminologiji genetskih algoritama rješenja nazivaju „kromosomima“, a kromosomi se pak sastoje od gena, odnosno od parametara koji karakteriziraju to rješenje.⁵⁷ Ako na kromosom gledamo kao na niz bitova, geni predstavljaju dijelove tog niza. Populacija je skupina kromosoma, a unutar populacije svaki se pojedini kromosom evaluira, pri čemu se svakom kromosomu pridodaje ocjena njegove iskoristivosti kao rješenja problema. Zatim se nad kromosomima vrše operacije selekcije, križanja i mutacije. Selekcijom se biraju kromosomi s većom ocjenom iskoristivosti. Postupak se nastavlja, no primarna iznimno dobra strana ovog procesa je što može biti paraleliziran bez dodatnog truda, što znači da se može odvijati brže i kvalitetnije. Selektirani se kromosomi zatim križaju, odnosno odabire se mjesto između dva susjedna gena kromosoma na kojem će se kromosomi prelomiti, a odlomljeni se dio zatim zamjenjuje genima partnerskog kromosoma. Tako će se nad kromosomima moći vršiti i operacija mutacije koja služi da mijenja jedan ili više bitova u kromosomu, tj. 0 pretvoriti u 1, odnosno 1 u 0. Novonastali kromosomi tada popunju kromosoma potomaka, te se cijelokupni postupak odabira ponovo.

2.7.2. Fuzzy logika

Ukoliko promatramo algoritme u enja, možemo zaključiti da će im biti potreban eksponencijalan broj iteracija kako bi se pronašlo rješenje problema. Fuzzy logiku⁵⁸ je utemeljio je Lotfi Zadeh sredinom 1960-tih godina. Fuzzy logika može se konceptualizirati kao klasi na logika. Njome nastoji opisati tzv. „nesigurno“ znanje. Nesigurno je znanje predstavljeno fuzzy skupom⁵⁹ koji se sastoji od stupnjeva istinitosti, odnosno vjerojatnosti. Kod fuzzy logike promatramo ne samo dvije alternative nego i takav skup rješenja koja su dostupna, te u ovom slučaju odabireno ono koje će biti valjano. Stupnjevi istinitosti mogu poprimiti bilo koju vrijednost između 0 i 1, uključujući i 0 i 1.⁶⁰ Pritom 0 kao i 1 u klasi noj logici podrazumijeva da se npr. događaj nije dogodio ili pak da element ne pripada skupu, dok 1 podrazumijeva da se događaj dogodio, odnosno da neki element pripada skupu.

⁵⁷ Holland J.H., *Adaptation in Natural and Artificial Systems*, Cambridge: The University of Michigan Press, 1975., str. 56-82.

⁵⁸ Zadeh L.A., *Fuzzy Sets, Information and Control*, Berkley: Department of Electrical Engineering and Electronics Research Laboratory, 1965., str. 15-63.

⁵⁹ Zadeh L.A., *Making computers think like people* Berkley: Department of Electrical Engineering and Electronics Research Laboratory, 1984., str. 26-32.

⁶⁰ Jain L.C., Martin N.M.; *Fusion of Neural Networks, Fuzzy Systems and Genetic Algorithms: Industrial Applications*, Boca Raton: CRC Press, 1998., str. 45-68.

Ukoliko pomo u pravila klasi ne logike promatramo temperaturu vode tada možemo re i da je voda hladna ili pak da je topla. Me utim, ako uzmemo u obzir fuzzy logiku tada voda može biti npr. mrzla, vrlo hladna, prili no hladna, mlaka, prili no topla, vrlo topla, vrela.⁶¹ Ukratko, umjesto dva stanja imamo mnoštvo sli nih, no ne i istih stanja koji mogu biti konta no rješenje. 1980-tih godina sustavi bazirani na fuzzy logici smatrani su eksperimentalnom tehnologijom zbog svoje posebnosti. Me utim, ve 1990-tih godina zapelo se s njihovom upotrebom u komercijalne svrhe. Fuzzy logika se u praksi pokazala vrlo efikasnom za opisivanje sustava koji nisu jasno definirani, sustava koji su vrlo složeni ili ih se pak ne može adekvatno matematički analizirati.

⁶¹ Baldwin J.F., *Fuzzy logic and fuzzy reasoning*, in *Fuzzy Reasoning and Its Applications*, London: Academic Press, 1981., str. 82-86.

3. PRIMJENA NEURONSKIH MREŽA U OBRAZOVANJU

Ukoliko promatramo mogu nosti primjene neuronskih mreža u obrazovanju, možemo zaklju iti da ovakav zbir mogu nosti zbilja ima šaroliku upotrebu. S obzirom na mogu nosti, to jest, neuronsku mrežu možemo upotrijebiti prilikom obrazovanja kako bi sam proces olakšali, te kako bi uspješno prevladali prepreke savladavanja novih injenica te informacija, koje za podru je fizike ne moraju nužno biti jednostavne ili op e shvatljive.

U nekoliko grana psihologije kreirao se pokret pod nazivom konstuktivizam, koji drži kako je skup informacija na okupu poseban za svaku osobu koja se takvim skupom pozabavi. U ovom slu aju mogli bi smo re i da svaka osoba generira znanje i skladišti injenice na svoj i poseban na in. Uz svaku injenicu, svaki doga aj ili svaku pojavu vežu se odre eni atributi koji postaju jedinstveni samo za tu osobu. Mogli bi smo re i kako je svaka osoba u potpunosti adaptabilna⁶², s im uspore ujemo nesupervizorne neuronske mreže koje posjeduju takvo svojstvo. Objasnijene pojma adaptibilnosti možemo potražiti na primjeru Kohonenove mreže.

Radi se o samoorganiziraju im mrežama. Jedina razlika izme u njih i konvencionalnih modela je u tome što to an odgovor ne može biti definiran odmah. Kada se ovakva samoorganiziraju a mreža koristi, ulazni vektor prezentiran je na svakom koraku. Ovi vektori predstavljaju okolinu mreže. Svaka nova ulazna vrijednost prouzrokuje prilagodbu na nove parametre. Ako se takve modifikacije to no kontroliraju, tada mreža može vrlo uspješno izgraditi unutrašnju reprezentaciju okoline. S obzirom na to da se u ovim mrežama procesi u enja i kreiranja vrijednosti o okolini preklapaju, slika okoline može biti kontinuirano osvježavana. Kohonenova mreža, predložena od strane Teuvo-a Kohonen, preuzela je odre ene ideje Rosenblatt-a, von der Malsburg-a te ostalih istraživa a. Ukoliko se ulazni prostor procesuira neuronском mrežом, prvo pitanje je važnost strukture takvog prostora. Neuronska mreža sa realnim ulaznim vrijednostima A koje prolaze kroz funkciju f do izlaznih vrijednosti B definiraju se kao proces Kohonenove mreže. Kohonenov model ima biološku i matemati ku pozadinu. Dobro je poznato u neurobiologiji da mnoge strukture u mozgu imaju linearu ili planarnu topologiju, to jest, one se protežu u dvije dimenzije. Senzorni podražaji su suprotno tome multidimenzionalni.

Jednostavan doga aj, kao što je percepcija boje, predstavlja suradnju tri razli ita svjetlosna receptora. O i tada bilježe dodatne informacije o strukturi, poziciji, te teksturi objekta. Neuronske mreže uvelike nadmašuju ostale sustave kod problema predvi anja, svrstavanja u skupine te prepoznavanja uzorka ili pisanih tragova. „Najvažnije pitanje u ovoj

⁶² Rojas R., *Neural Networks*, Berlin Heidelberg: Springer-Verlag, 1996., str. 42-58.

fazi je koliko dugo trenirati mrežu kako bi ona dala što bolji rezultat, odnosno najmanju grešku. Ne postoje egzaktna pravila za dužinu treniranja, te odgovor na ovo pitanje treba potražiti vlastitim eksperimentiranjem ili primjenom optimizacijskih tehnika kao npr. tehnika unakrsnog testiranja. Ova se tehnika može opisati u nekoliko koraka: mreža se najprije trenira na određenom broju iteracija (npr. 10000), tako da se mreža testira na uzorku za testiranje, i pohrani dobiveni rezultat i mreža. Mreža se zatim nastavlja trenirati na još tolikom broju iteracija (npr. još 10000), te se dobiveni rezultat uspore uje s prethodno pohranjenim. Ukoliko je u ponovnom učenju dobiven bolji rezultat, pohranjuje se novi rezultat i nova mreža. Postupak se ponavlja sve dok se rezultat prestane poboljšavati, a najbolja pohranjena mreža ulazi u daljnji postupak validacije.⁶³

3.1. Zakoni učenja

Mnogi zakoni učenja su trenutno u širokoj upotrebi. Većina tih zakona su varijacija najstarijeg poznatog zakona učenja, Hebb-ova pravila. Proučavanje unutar različitih funkcija učenja nastavlja se kako se nove ideje pojavljuju u objavljenim lancima. Neki istraživači bave se samo modeliranjem biološkog učenja, te su takav zadatak postavili kao svoj glavni cilj. Ostali eksperimentiraju sa prilagodbom svoje percepcije o tome kako se priroda u cjelini nosi sa učenjem. Bilo kako bilo, ovjekovo razumijevanje o tome kako neuronske mreže zbilja rade je u nekoj mjeri ograničeno. Učenje je svakako kompleksnije od pojednostavljenja pravilima učenja koji su trenutno u upotrebi. Nekoliko važnijih zakona navodimo:

- **Hebbovo pravilo:** Prvo, te neosporenog najpoznatije pravilo učenja uvedeno je od strane Donalda Hebba. Opis pravila pojavljuje se u njegovoj knjizi „The Organization of Behavior“ (1949). Njegovo osnovno pravilo je: ako neuron primi ulazni signal od drugog neurona, te ako su oba jako aktivna (matematički imaju isti predznak), tada će veza među tim neuronima biti ojačana.
- **Hopfieldovo pravilo:** Slično kao za Hebbovo pravilo sa iznimkom da se definira iznos ojačanja ili slabljenja veze među neuronima. Navodi se: ako su obje željene vrijednosti izlaza i ulaza aktivne ili neaktivne, pojavljuje se pojačanje u vezi među neuronima, to jest, smanjenje u vezi među neuronima po iznosu učenja.
- **Delta pravilo:** Ovo pravilo je dodatna varijacija na Hebbovo pravilo. Ovo je jedno od najčešće korištenih pravila. Pravilo je temeljeno na jednostavnoj ideji o kontinuiranoj

⁶³ ERIS: *Educational Repository for Intelligent Systems*, 2003., <http://eris.foi.hr/11neuronske/nm-uvod.html>

- promjeni ja ine ulaznih veza kako bi se smanjila razlika (delta) izme u željene izlazne vrijednosti te stvarne izlazne vrijednosti elementa koji procesира. Ovo pravilo mijenja jakost sinapti ke veze na na in koji minimalizira razinu pogreške mreže. Na in na koji delta radi je takav, da grešku iz jednog sloja u izlaznoj vrijednosti automatski integrira u ulaznu vrijednost sljede eg sloja kako bi se kreirala to na jakost veze. Ukratko, radi se o kreiranju veza sloj po sloj te kontinuiranom ispravljanju greške u radu.
- **Kohonenovo pravilo u enja:** Ovo pravilo, koje je svoje temelje pronašlo u biološkim sustavima temelji se na natjecanju nekoliko procesnih elemenata za svoju priliku za u enjem ili ka poboljšanju svojih veza. Procesni element sa najve im izlazom proglašava se pobjednikom te ima mogu nost inhibirati svoje protivnike, te uzbuditi svoje susjede. Samo pobjednik ima pravo na izlaznu vrijednost, te samo pobjednik uz svoje susjede ima pravo podesiti ja inu me usobnih veza.

3.2. Budu nost u enja kroz umjetnu inteligenciju

Do sada smo obradili velik broj na ina u enja te mogu nosti prikupljanja informacija te njihovu interpretaciju sa ili bez dodatne korekcije od strane programera. Poznavanjem elementarnih pravila te na ina djelovanja neuronskih mreža možemo iste zakonitosti upotrijebiti na prenošenje informacija u enicima te ra unalima ustrojenima kao neuronske mreže. Ukoliko postavimo hipotezu da je proces u enja samostalno definiran od strane svakog pojedinca možemo na jednostavniji na in do i do zadovoljavaju e izlazne vrijednosti. Konstruktivizam u procesu u enja definira da se što više odmaknemo od standardnog na ina prenošenja znanja; predava i slušatelj, te da informacije, u ovom slu aju u enicima ili studentima predstavimo kao skup me usobno povezanih injenica na osnovu kojih e oni samostalno kreirati svoje zaklju ke te osnažiti veze me u neuronima. Postupak u enja neuronskih mreža, koji proizlazi iz prirode daje nam mogu nost uvida u najjednostavnije procese koji se doga aju prilikom shva anja novih spoznaja. Mada se definira potreba da se umjetno stvoreno rješenje može mjeriti sa ljudskim, ne misli se na vrijeme koje je potrebno da se ispiše velik broj stranica ili da se matemati ki izra una vrijednost odre ene varijable na bezbroj decimala, ve se želi posti i na in na koji bi ra unalo riješilo problem, te došlo do rješenja koje je bolje ili istovjetno onom do koje bi došao ovjek. Samim time, ra unalo bi našlo novu tehniku za obavljanje odre ene radnje što mu tada daje sposobnost inteligencije. Ukoliko razmotrimo osnovne uvjete da sustav bude intelligentan; svojstvo uspješnog

snalaženja u novim situacijama, u enje na temelju iskustva, sposobnost razmišljanja pri rješavanju problema, svrshodno i prilagodljivo ponašanje u zadanim okolnostima te sposobnost u enja, prilago avanja, odlu ivanja, prepoznavanja, zaklju ivanja i predvi anja, možemo do i do zaklju ka da su umjetno kreirani strojevi ve u odre enom pogledu autonomni, no, da do sada nije kreiran takav stroj koji bi mogao objediniti sve mogu nosti ljudskog mozga kako je to priro eno svakom ljudskom bi u. Kroz povijest postojalo je nekoliko strojeva koji su bili iznimno dobri u zadacima koji su pred njih postavljeni, DART – planiranje složenih logisti kih zadataka u zaljevskom ratu, IBM Deep Blue koji je odigrao partiju šaha sa Kasparovim, ALVINN – vidni sustav – NavLab – raunalom upravljano vozilo iz 1998. godine, PROVERB – stroj koji rješava križaljke, NASA Remote Agent – stroj za samostalno planiranje i raspore ivanje poslova svemirske letjelice iz 2000. godine, no, radi se o isklju ivo pojedinim sposobnostima za koje su ovakvi ure aji specifi no gra eni. Ukoliko se trenutni napredak tehnologije nastavi u ovom smjeru, te ukoliko raunalna mo poraste na tu razinu, mogu e je da smo u skoroj budu nosti svjedo iti stroju, UI, koji e biti u mogu nosti razmišljati inteligentno. Trenutno ve postoji nekoliko za etaka takvog napretka, ukoliko uzmememo u obzir mogu nosti trenutnih mobilnih telefona, te prepostavimo da se u srcu komunikacije telekomunikacijske mreže nalazi neuronska mreža koja je sposobna obra ivati infomacije, možemo zaklju iti kako je takvoj mreži samo potreban pristup informacijama kako bi nau ila mnogo potrebnih informacija o ljudima. Ukoliko svakom korisniku dodijelimo jedan jedinstven komunikacijski kanal sa takvim strojem, to jest, mobilni telefon, ubrzno imamo sustav koji u i od nekoliko milijuna razli itih osoba u svakom trenutku, te asimilira ogromnu koli inu podataka svakim novim trenutkom. Smatram da se period do ostvarenja zna ajne interakcije sa bilo kojim strojem oko nas izrazito smanjuje. Ukoliko bi takav intelligentni sustav postavili kao tutorski sustav koji je u mogu nosti u iti druge sustave, strojeve ili ljude, te na osnovu ponu enih informacija prilago avati svoj na in rada, imali bi smo mogu nost veliku koli inu znanja prenijeti na velik broj ljudi u kratkom vremenskom periodu, jer bi nam takav sustav omogu io integraciju u prakti no bilo koji dom, bilo koje ra unalo te bilo koji ure aj. Zamisao o mogu nostima razvoja je zbilja uzbudljiva, no samo pod prepostavkom da bi takav sustav bio u skladu sa ljudskom vrstom. Intelligentni tutorski sustavi ili ITS, su sustavi koji trenutno egzistiraju na globalnoj razini te omogu avaju lakšu i ekonomi niju distribuciju znanja, bez monotonog upijanja injenica. Ovakvi intelligentni sustavi preuzeli su sposobnost mimike, facialne ekspresije u ovisnosti o

raspoloženju ili povratnoj informaciji dobivenoj od učenika/studenta te su se na taj način još jedan korak približili mogućinosti potpune intelligentne edukacije.

Neuronske mreže i stabla odlučivanja uspješno se koriste za predviđanje uspješnosti studiranja i na Osječkom sveučilištu. Zeki -Sušac, Frajman-Jakšić i Drvenkar su provele istraživanje na Ekonomskom fakultetu u Osijeku, pomoći u kreiranju modela za predviđanje uspješnosti studiranja, te analizom imbenika koji utječe na uspješnost pojedinog studenta. Klasifikacija studenata odvijala se tako da se pojedini student trebao svrstati u jednu od dvije kategorije uspješnosti. Uspješnost je mjerena prosjekom ocjena prilikom studiranja. Prilikom ovog istraživanja korištena je višeslojna perceptronska mreža koja je prethodno objašnjena u radu. Analiza osjetljivosti izlaznih varijabli na ulazne provedena kod neuronskih mreža ukazuju na to da su kolokviranje, prisustvo na vježbama, važnost ocjene za studenta te stipendije među najznačajnijim imbenicima uspješnosti studiranja. Algoritam mreže „širenje unatrag“ bio je presudan za široku komercijalnu upotrebu ove metodologije⁶⁴, te je neuronske mreže učinio široko upotrebljavanom i popularnom metodom u različitim područjima. Standardni algoritam mreže „širenje unatrag“ uključuje optimizaciju greške koristeći deterministički algoritam gradijentnog opadanja.⁶⁵ Jedan od glavnih nedostataka ovog algoritma je esto pronalaženje lokalnog minimuma greške, stoga nova istraživanja uključuju druge metode rada. S obzirom na korišteni broj varijabli te ulaznih podataka, to jest mjerena je bila ograničena, ali, moguće je da će u budućnosti to jest biti povećana ukoliko se ovakav model primjeni na druge studije na sveučilištu. Kreiranje sustava sa visokom točnošću predviđanja uspješnosti studiranja od velike je važnosti, jer može doprinijeti većoj uspješnosti studenata i kvaliteti studiranja u cjelini.⁶⁶

Sljedeći rad na temu neuronskih mreža na Sveučilištu odnosi se na model neuronskih mreža za predviđanje matematičke darovitosti u djece. Do sada se ovakav postupak provodio pomoći u Ravenovih progresivnih matrica upotrebljavanih u procesima psihološke evaluacije darovitosti. Međutim, s obzirom na to da se radi o postupku koji je provodio psiholog, no, svaka škola nema psihologa, javila se potreba za konstrukcijom intelligentnog alata koji bi zadatku obavio to nužno i brzo. Prilikom istraživanja uočeno je kako se najbolji rezultati mogu ostvariti pomoći u radikalno zasnovane funkcije i vjerojatnosne neuronske mreže. Sposobnosti koje pokazuje metodologija neuronskih mreža u otkrivanju darovitosti djece mogu se dalje

⁶⁴ Moody J., Darken C.J., *Neural Computation, 1: Fast Learning in Networks of Locally Tuned Processing Units*, Cambridge: MIT PRESS, 1989., str. 89-99.

⁶⁵ Masters T., *Advanced algorithms for neural networks: A C++ Sourcebook*. NY: John Wiley & Sons, 1995.

⁶⁶ Zeki -Sušac M., Frajman-Jakšić A., Drvenkar N., *Neuronske mreže i stabla odlučivanja za predviđanje uspješnosti studiranja*, http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=113044

istražiti uporabom više skupova podataka ili proširenjem istraživanja. Ukoliko bi se ovakav sustav implementirao u svaku školu, znatno bi pripomogao ranom otkrivanju nadarene djece te bio koristan i za njihov daljnji razvoj sa posebnim naglaskom na podruje nadarenosti te za zajednicu u globalu.⁶⁷

⁶⁷ Zeki -Sušac M., Frajman-Jakšić A., Drvenkar N., *Neuronske mreže i stabla odlučivanja za predviđanje uspješnosti studiranja*, http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=113044

4. ZAKLJU AK

Neuronske mreže su složeni sustavi koji su svoju primjenu kao neophodne komponente pronašli u velikom broju velikih mehanizama koji su trenutno komercijalno dostupni. Umjetne neuronske mreže su matematički sustavi koji su dizajnirani po uzoru na ljudski mozak što im daje iznimne mogunosti. Neuronske mreže su prilagodljive okruženju u kojem se nalaze, sustavu s kojim trebaju ostvariti interakciju, te informacijama, ili ulaznim signalima koji do njih dolaze. Za slavajuće nesuperviziranih mreža, javlja se svojstvo koje do tada nije bilo poznato, a to je mogućnost u enja za vrijeme rada mreže na osnovu određenog broja ponavljanja iste radnje ili iteracije. Budućnost umjetnih neuronskih mreža je značajna, no, s napredkom tehnologije, novih mogućnosti, snažnijih procesora, sve više i više sustava će makar i u minimalnom obimu koristiti mogućnosti neuronskih mreža. U radu su spomenute samo neke od komercijalno dostupnih mogućnosti kao što je recimo SIRI, koji u podlozi ima sustav prepoznavanja govora, sustav prepoznavanja teksta, sustav prepoznavanja simbola, te se veže na nekoliko baza podataka, iz čega proizlazi ogroman potencijal napretka koji će u jednom trenutku dovesti do velikih otkrića na ovom području. Kako bi se ovakvi pametni sustavi razvijali, te definirali novi smjer napretka tehnologije koja će podupirati iste, potrebno je mnoštvo informacija te vrijeme.

Neuronske mreže su trenutno iznimno zastupljene kao dijelovi sustava telekomunikacija, MADALINE, kao i uređaji za analizu govora, u bankarskoj industriji, to jest, praktično, svugdje gdje je potrebno obraditi veliku količinu podataka bez kontinuiranog ispravljanja rada sustava. Na konstruktivističkoj teorijskoj podlozi zasnovana je i ideja konstruktivnog učenja neuronskih mreža. U radu smo se dotakli i drugih modela neuronskih mreža koji se često implementiraju, a to su Kohonenove umjetne neuronske mreže. Ovakve nesupervizorne mreže omogućavaju prilagodbu inteligentnih tutorskih sustava u toku rada sa učenjem bez mijenjanja bilo koje od varijabli sustava.

Kada bi se radilo o supervizornoj mreži, bilo bi potrebno prikupiti nove podatke za uvježbavanje mreže te ih ponovno unijeti u sustav. Samim time, mreža ne bi mogla u potpunosti obaviti zadatak za koji je zadužena. Rad je zamišljen kao objašnjenje pojma umjetnih neuronskih mreža, upoznavanje sa povijesnim događajima koji su omogućili nastanak mreža kakve danas poznajemo, te opis implementacije sustava umjetnih neuronskih mreža u edukaciju, to jest, načine predviđanja uspješnosti studiranja te ranoj detekciji nadarenih učenika.

5. LITERATURA

1. Anderson D. and McNeill G., *Artificial Neural Networks Technology*, NY: Kaman Sciences Corporation, 2009.
2. Anissimov M., *Deconstructing Asimov's Laws*, Berkley: Singularity Institute for Artificial Intelligence, 2010.
3. Arbib M. A., *The Handbook of Brain Theory and Neural Networks*, Cambridge: MIT Press, 1995.
4. Asimov I., *I, Robot*, New York: Doubleday & Company, 1950.
5. Bain A., *Mind and Body: The Theories of Their Relation*, London: University of Dundee 1873.
6. Baldwin J.F., *Fuzzy Logic and Fuzzy Reasoning, in Fuzzy Reasoning and Its Applications*, London: Academic Press, 1981.
7. Beck J., Stern M., Haugsjaa E.; *Applications of AI in Education*, NY: ACM, 1996.
8. Ben-Amar Baranga A., *Brain's Magnetic Field: A Narrow Window to Brain's Activity*, Negev: Nuclear Research Center – Department of Electrical Eng., 2010.
9. Bertsimas D. and Tsitsiklis J., *Simulated Annealing*, Cambridge: MIT, 1993.
10. Booker L., Kaufman M., *Improving Search in Genetic Algorithms*, Los Altos: Morgan Kaufmann Publishers, 1987.
11. Brown E.R., Milner M.P., *The legacy od Donald O. Hebb: More Than the Hebb Synapse*, Boston: Nature Publishing group, 2003.
12. Brusilovsky P., Peylo C., *Adaptive and Intelligent Web-based Educational Systems*, International Journal of Artificial Intelligence in Education, Vol. 13, 2003.
13. Copeland B.J., Encyclopedia Britannica - *Artificial intelligence*
14. Chakraborty R. C., *Fundamentals of Neural Networks: AI Course*, NY, 2010.
15. Dawes R., *The Parametric Avalanche Control Module Prototype Development*, Austin: Martingale Research Corporation, 1992.
16. Denyer P.B., Renshaw D., Bergmann N., *A Silicon Compiler for VLSI Signal Processors*, Brussels: European Solid-State Circuit Conference (ESSCIRC), 1982.
17. Fahlman S.E., Lebiere C., *The Cascade-Correlation Learning Architecture in Touretzky*, London: Morgan Kaufmann, 1990.
18. Farley B., Clark W.A., *Simulation of Selforganizing Systems by Digital Computer*, Cambridge: MIT, 1954.

19. Fausett V.L., *Fundamentals of Neural Networks: Architecture, Algorithms and Applications*, New Jersey: Prentice Hall, 1993.
20. Feng M., Heffernan N., Koedinger K., *Looking for Sources of Error in Predicting Student's Knowledge*, Pittsburg: Worcester Polytechnic Institute, 2005.
21. Freeman J. A., Skapura D. M., *Neural Networks - Algorithms, Applications, and Programming Techniques*, Boston: Addison-Wesley Publishing Company, 1999.
22. Gardner J.W., Barelett P.N., *A Brief History of Electronic Noses, Sensors and Actuators*, Berlin Heidelberg: Springer-Verlag, Vol. 18–19, 1994.
23. Graham I., *Object-oriented Methods*, Boston: Addison-Wesley Publishing Company, 1994.
24. Gurney K., *An Introduction to Neural Networks*, London: UCL Press, 1997.
25. Hebb D.O., *The Organization of Behavior*, Boston: Psychology Press, 2012.
26. Hoda S., Zohdy, A-A., *Artificial Neural Network Electronic Nose For Volatile Organic Compounds*, Rochester: Department of electrical and system engeneering, 1998.
27. Holland H.J., *Adaptation in Natural and Artificial Systems*, Michigan: The University of Michigan Press, 1975.
28. Jain L.C., Martin N.M.; *Fusion of Neural Networks, Fuzzy Systems and Genetic Algorithms: Industrial Applications*, Boca Raton: CRC Press, 1998.
29. James W., *Principles of Psychology*, Toronto: York University, 1890.
30. Lapedes A.S., Farber R., *Nonlinear Signal Processing Using Neural Networks: Prediction and System Modeling*, Los Alamos: Los Alamos National Laboratory, 1987.
31. Mahoney M.J., *What is Constructivism and Why is it Growing?*, NY: St. Martin's Press, 2004.
32. Masters T., *Advanced algorithms for neural networks: A C++ Sourcebook*. NY: John Wiley & Sons, 1995.
33. Mark M. A., Greer J., *Evaluation Methodologies for Intelligent Tutoring Systems*, Journal of Artificial Intelligence and Education, Vol. 4, No. 2/3, 1993.
34. McCulloch W., Pitts W., *A Logical Calculus of the Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics, Vol. 5, 1943.
35. Moody J., Darken C.J., *Neural Computation, 1: Fast Learning in Networks of Locally Tuned Processing Units*, London: MIT PRESS, 1989.

36. Mulier D.J., Dixon M.B., *The Application of Neural Network and Fuzzy Logic Techniques to Educational Hypermedia*, Chania: Faculty of Informational and Engineering Systems, 1999.
37. Norton R.H., *The von Neumann Architecture of Computer Systems*, Pomona: California State Polytechnic University, 1987.
38. Novaković B., Majetić D., Široki M.; *Umjetne neuronske mreže*, Zagreb: Fakultet strojarstva i brodogradnje, 1998.
39. Perrone P.M., Cooper N.L., *When Networks Disagree: Ensemble Methods for Hybrid Neural Networks*, NY: Chapman-Hall, Brown University, 1992.
40. Pomerleau A.D., *Alvinn: An Autonomous Land Vehicle in a Neural Network*, Pittsburg: Carnegie Mellon University, 1989.
41. Rashevsky N., *Mathematical Biophysics: Physico-Mathematical Foundations of Biology*, Chicago: University of Chicago Press, 1938.
42. Rojas R., *Neural Networks*, Berlin Heidelberg: Springer-Verlag, 1996.
43. Rosić M., Stankov S., Glavinić V., *DTEX-Sys – A Web Oriented Intelligent Tutoring System*, EUROCON, Proceedings of Intelligent Conference On Trends in Communication, 2001.
44. Rumelhart D.E., McClelland J.L. and the PDP Research Group, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Cambridge: Press/Bradford Books, 1986.
45. Self J., *Artificial Intelligence and Human Learning: Intelligent Computer-Aided Instruction*, Chicago: Chapman and Hall, 1988.
46. Smith M.J., *Application of Specific Integrated Circuits*, Boston: Addison-Wesley, 1997.
47. Thomas E.; *Encyclopedia of Educational Technology - Intelligent Tutoring Systems (ITS)*, NY: Macmillan, 6th ed., 1992.
48. Tomabechi H., Kitano H., *Beyond PDP: The Frequency Modulation Neural Network Architecture*, Pittsburg: Marnege Mellon University, 2008.
49. Toulouse G., *Statistical Physics, Neural Networks, Brain studies*, Paris: Laboratoire de physique de L'Ecole Normale Supérieure, 1999.
50. Wenger E., *Artificial Intelligence and Tutoring Systems: Computational and cognitive Approaches to the Communication of Knowledge*, London: Morgan Kaufman, 1987.
51. White R., Down T., *How Computers Work (9th edition)*, London: Que Publishing, 2007.
52. Whitley D., *A Genetic Algorithm Tutorial*, Colorado: Computer Science Department, Colorado State University, 2004.

53. Widrow B., Lehr A.M., *Perceptrons, Madaline, and Backpropagation*, Cambridge: MIT PRESS, 1990.
54. Wiener R., *Neural Networks*, Sydney: The University of Sydney, 2003.
55. Vigliocco G., Warren J., Siri S., Arciuli J., Scott S., Wise R., *The Role of Semantics and Grammatical Class in the Neural Representation of Words*, Cereb. Cortex, 2006.
56. Wiener R., *Neural Networks*, Sydney: The University of Sydney, 2003.
57. Zadeh L.A., *Fuzzy Sets, Information and Control*, Berkley: Department of Electrical Engineering and Electronics Research Laboratory, 1965.
58. Zadeh L.A., *Making computers think like people*, Berkley: Department of Electrical Engineering and Electronics Research Laboratory, 1984.
59. Zell A., Mamier G., Vogt M., Mache N., Hübner R., Döring S. i dr., *Stuttgart Neural Network Simulator - The Algorithm*, Berlin Heidelberg: Springer-Verlag 1995.
60. Zeki -Sušac M., Frajman-Jakšić A., Drvenkar N., *Neuronske mreže i stabla odlučivanja za predviđanje uspješnosti studiranja*, Ekonomski vjesnik, br. 2, 2009.
61. Zurada J.U., *Introduction to Artificial Neural Systems*, NY: West Publishing Company, 1992.
62. Žalac N., *Poslovna analiza i upravljanje - Neuronske mreže – jučer, danas, sutra*, Zagreb: INTUS BIT, 1999.
63. Žalac N., *Poslovna analiza i upravljanje - Primjer jednostavne neuronske mreže*, Zagreb: INTUS BIT, 1997.

Web linkovi:

- http://www.dacs.dtic.mil/techs/neural/neural_ToC.html
- <ftp://ftp.sas.com/pub/neural/FAQ.html>
- <http://www.neurocomputing.org/>
- <http://www.statsoft.com/textbook/stneunet.html>
- <http://www.cs.stir.ac.uk/~lss/NNIntro/InvSlides.html>
- <http://rfhs8012.fh-regensburg.de/~saj39122/jfroehl/diplom/e-index.html>
- <http://www.shef.ac.uk/psychology/gurney/notes/11/11.html>
- <http://www-cse.stanford.edu/classes/sophomore-college/projects-00/neural-networks/index.html>
- http://courses.cs.tamu.edu/rgutier/cs790_w02/111.pdf
- <http://www2.psy.uq.edu.au/~brainwav/Manual/BackProp.html>
- http://www.ccs.fau.edu/~bressler/EDU/CogNeuro/Perceptrons_hbtnn.htm
- <http://www-ra.informatik.uni-tuebingen.de/SNNS/UserManual/node166.htm>
- http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=113044
- http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=113044
- <http://eris.foi.hr/11neuronske/nn-uvod.html>
- <http://www.apple.com>
- <http://www.faa.gov>
- <http://www.google.com/insidesearch/>

6. POPIS SLIKA

- Slika 1. Jednostavni neuron
- Slika 2. Sumiranje ponderiranih ulaznih vrijednosti
- Slika 3. Jednostavni umjetni neuron - perceptron
- Slika 4. Grafički prikaz McCulloch-Pitts Neurona
- Slika 5. Funkcija binarnog praga
- Slika 6. Funkcija bipolarnog praga
- Slika 7. Djelomična linearna funkcija
- Slika 8. Sigmoidalna funkcija
- Slika 9. Organizacija neurona kod umjetnih neuronskih mreža
- Slika 10. Proces učenja neuronskih mreža
- Slika 11. Klasifikacija algoritama učenja

7. ŽIVOTOPIS

Ro en sam 27.09.1985. godine u Virovitici. Osnovnu školu Davorina Trstenjaka završavam u a avici, srednju školu poha am u Slatini, te dobivam svjedodžbu o maturi Op e gimnazije, nakon ega upisujem studij Fizike i tehni ke kulture s informatikom na Odjelu za fiziku u Osijeku.