


7. Neuronske mreže

M. Zekić- Sušac

1

Pojam neuronskih mreža

Neuronske mreže (NM) su metoda umjetne inteligencije (UI) inspirirane i strukturirane prema ljudskom mozgu.




M. Zekić- Sušac

2

Biološka neuronska mreža

Biološki neuron - stanica koja prima informacije od drugih neurona putem dendrita, obrađuje ih, a zatim šalje impuls putem aksona i sinapsi drugim neuronima u mreži. Učenje se odvija promjenom jačine sinaptičkih veza. Milijuni neurona u mreži mogu paralelno obrađivati informacije. (NeuroBook2, Artificial NN)




M. Zekić- Sušac

3

Veza između biološke i umjetne NM

BIOLOŠKA NM	UMJETNA NM
biološki neuroni	umjetni neuroni su jedinice obrade (varijable)
ulazni i izlazni impulsi (dendriti, aksoni)	ulazne i prijenosne funkcije između neurona
učenje ?	promjenom vrijednosti težina (pondera) neurona, mreža nastoji naučiti vezu između ulaza i izlaza

Umjetna neuronska mreža



Umjetni neuron - jedinica za obradu podataka (varijabla) koja prima ponderirane ulazne vrijednosti od drugih varijabli, prema nekoj formuli transformira primljenu vrijednost, te šalje izlaz drugim varijablama. Učenje se odvija promjenom vrijednosti "težina" među varijablama (**težine** w_j su ponderi kojima se množe ulazne vrijednosti u neki "neuron").

M. Zekić- Sušac

5


Definicija NM

Neuronske mreže su programi ili hardverski sklopovi koji iterativnim postupkom iz prošlih podataka nastoje pronaći vezu između ulaznih i izlaznih varijabli modela, kako bi se za nove ulazne varijable dobila vrijednost izlaza (ili drugim riječima, uče na primjerima).

M. Zekić- Sušac

6

Struktura umjetne NM



Slika 1. Struktura mreže "širenje unatrag" (Backpropagation mreže)

M. Zekić- Sušac

7

Povijest razvoja NM

- 1958. **Perceptron** - prva neuronska mreža (Frank Rosenblatt), učenje se odvija samo u dva sloja, nije mogla rješavati probleme klasifikacije koji nisu linearno djeljivi (npr. XOR problem)
 - 1969. **Minsky i Papert** objavljuju rad u kojem oštro kritiziraju nedostatke Perceptrona, što uzrokuje prestanak ulaganja u istraživanja neuronskih mreža.
- 1974. **višeslojna perceptron mreža - MLP** (Paul Werbos)- prva verzija Backpropagation mreže, prevladava nedostatak perceptrona uvođenjem učenja u skrivenom sloju
- 1986. **Backpropagation mrežu usavršuju** Rumelhart, Hinton, Williams, i ona vraća ugled neuronskim mrežama, jer omogućuje aproksimiranje gotovo svih funkcija i rješavanje praktičnih problema
- ... - otada se razvijaju **brojni algoritmi** za NM koji s pomoću različitih pravila učenja, ulaznih i izlaznih funkcija rješavaju probleme predviđanja, klasifikacije i prepoznavanja uzoraka.

M. Zekić- Sušac

8

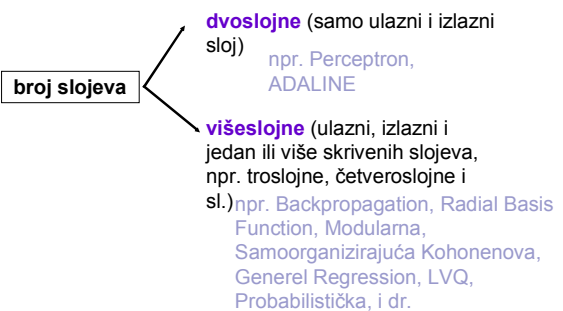
Kriteriji za razlikovanje algoritama NM

- broj slojeva,
- tip učenja,
- tip veze između neurona,
- veza između ulaznih i izlaznih podataka,
- ulazne i prijenosne funkcije,
- sigurnost ispaljivanja,
- vremenske karakteristike,
- vrijeme učenja.

M. Zekić- Sušac

9

Algoritmi NM prema broju slojeva



M. Zekić- Sušac

10

Algoritmi NM prema tipu učenja

tip učenja u mreži

Usporedba: učenje za ispit s točnim odgovorima i bez njih

nadgledano (supervised) - poznate su vrijednosti izlaznih varijabli na skupu podataka za učenje mreže (Backpropagation, Radial Basis Function, Modularna, General Regression, LVQ, Probabilistička)

nenadgledano (unsupervised) - nisu poznate vrijednosti izlaznih varijabli na skupu podataka za učenje mreže (Kohonenova samoorganizirajuća, ART mreža)

Primjeri problema:

- predviđanje bankrota poduzeća sa znanjem da li je neko poduzeće bankotiralo u prošlosti ili bez tog znanja,
- ocjena kreditne sposobnosti sa znanjem da li je kredit u prošlosti vraćen ili nije,
- ponašanje kupaca u odnosu na neki proizvod s poznatim prošlim akcijama kupaca ili bez poznatih akcija

11

Ulazne funkcije u NM


Kada neki neuron prima ulaz iz prethodnog sloja, vrijednost njegovog ulaza računa se prema ulaznoj funkciji (tzv. "sumacijskoj" funkciji).

Opci oblik ulazne funkcije **kod nadgledanih mreža**, ako neuron i prima ulaz od neurona j :

$$input_i = \sum_{j=1}^n (w_{ji} \cdot output_j)$$

gdje je w_{ji} težina veze od neurona j do neurona i , n broj neurona u sloju koji šalje svoj izlaz.

Drugim riječima, $input_i$ nekog neurona i je suma svih vaganih izlaza koji pristižu u taj neuron.



M. Zekić- Sušac

12

Izlazne (prijenosne) funkcije u NM

Izlaz neurona računa se prema tzv. prijenosnoj funkciji (transfer function). Nekoliko najčešće korištenih prijenosnih funkcija su:

- funkcija koraka (step funkcija),
- signum funkcija,
- sigmoidna funkcija,
- hiperboličko-tangentna funkcija,
- linearna funkcija,
- linearna funkcija s pragom.

Najčešće korištene funkcije su **sigmoidna i hiperboličko-tangentna, jer najbliže oponašaju stvarne nelinearne pojave.**

M. Zekić- Sušac

13


Sigmoidna prijenosna funkcija

Sigmoidna (ili logistička) funkcija jedna je od najčešće upotrebljivanih prijenosnih funkcija u neuronskim mrežama.

Formula sigmoidne funkcije:

Graf sigmoidne funkcije:

$$\text{output}_i = \frac{1}{1 + e^{-g \cdot \text{input}_i}}$$



gdje je g doprinos funkcije izračunat kao $g = 1/T$, a T je prag. Doprinos određuje zaobljenost funkcije oko nule. Funkcija rezultira kontinuiranim vrijednostima u intervalu $[0,1]$.

M. Zekić- Sušac

14

Tangens-hiperbolna prijenosna funkcija

je poseban oblik sigmoidne funkcije, pomaknute tako da izlaznim vrijednostima pokriva interval $[-1,1]$.


Formula hiperboličko-tangentne funkcije:

$$\text{output}_i = \frac{e^u - e^{-u}}{e^u + e^{-u}}$$

gdje je $u = g \cdot \text{input}_i$,

Zbog svoje mogućnosti mapiranja vrijednosti u pozitivna kao i u negativna područja, ova funkcija upotrebljava se u mnogim eksperimentima.

Graf funkcije:



M. Zekić- Sušac

15

Pravila učenja u NM

Pravilo učenja je formula koja se upotrebljava za prilagođavanje težina veza među neuronima (w_{ij}). Najčešće korištena su naredna četiri pravila:

- Delta pravilo (*Widrow/Hoff-ovo pravilo*),
- Poopćeno Delta pravilo,
- Delta-Bar-Delta i Prošireno Delta-Bar-Delta pravilo,
- Kohonen-ovo pravilo (koristi se za nenadgledane mreže).

Prošireno-Delta-Bar-Delta pravilo je najnaprednije među prva tri nabrojana, jer težine prilagođava lokalno za svaku vezu u mreži, a uključuje i momentum koji sprječava saturaciju. (Saturacija je ekstremno kretanje težina koje dovodi do blokade učenja).

M. Zekić- Sušac

16

Delta pravilo učenja u NM

poznato je i kao pravilo najmanjih srednjih kvadrata, budući da ima za cilj minimizirati ciljnu funkciju određivanjem vrijednosti težina. Cilj je minimizirati sumu kvadrata grešaka, gdje je greška definirana kao razlika između izračunatog i stvarnog (željenog) izlaza nekog neurona za dane ulazne podatke. Jednadžba za Delta pravilo je:

$$\Delta w_{ji} = \eta \cdot y_{cj} \cdot \varepsilon_i \quad \text{gdje je} \quad \Delta w_{ji} = w_{ji}^{\text{nova}} - w_{ji}^{\text{stara}}$$

y_{cj} je vrijednost izlaza izračunatog u neuronu j , ε_i je sirova greška izračunata prema:

$$\varepsilon_i = y_{ci} - y_{di}$$

y_{cj} je vrijednost stvarnog (željenog) izlaza neurona j , a η je koeficijent učenja (learning rate).

Nova težina između neurona se, dakle, računa tako da se stara težina korigira za vrijednost greške pomnožen s vrijednošću izlaza neurona j , te sa koeficijentom učenja.

M. Zekić- Sušac

17

Nedostaci Delta pravila

1. **Problem lokalnog minimuma** pojavljuje se kada je najmanja greška funkcije pronađena samo za lokalno područje te je učenje zaustavljeno bez dostizanja globalnog minimuma.

2. **Problem pretreniranja** pojavljuje se jer nije moguće unaprijed odrediti koliko dugo treba učiti mrežu da bi ona mogla naučeno znanje generalizirati na novim podacima.

Koliko dugo onda trenirati mrežu? Što duže!??? **NE!!!**

predugo treniranje \implies mreža će naučiti i neke nebitne veze među podacima za učenje, te ih primjenjuje na podacima za testiranje i tako proizvodi veliku grešku

rješenje = optimirati duljinu treniranja

M. Zekić- Sušac

18


Kako radi Backpropagation (MLP) mreža?

- 1. od ulaznog sloja prema skrivenom sloju:** ulazni sloj učitava podatke iz ulaznog vektora X , i šalje ih u prvi skriveni sloj,
- 2. u skrivenom sloju:** jedinice u skrivenom sloju **primaju vagani ulaz** i prenose ga u naredni skriveni ili u izlazni sloj koristeći neku **prijenosnu funkciju**.
Kako informacije putuju kroz mrežu, računaju se sumirani ulazi i izlazi za svaku jedinicu obrade (neuron),
- 3. u izlaznom sloju:** za svaki neuron, računa se skalirana lokalna greška koja će se upotrebljavati za povećanje ili smanjenja težina pri daljnjem računanju ulaza u neurone,
- 4. propagiranje unazad od izlaznog sloja do skrivenih slojeva:** skalirana lokalna greška, te povećanje ili smanjenje težina računa se za svaki sloj unazad, počevši od sloja neposredno ispod izlaznog sve do prvog skrivenog sloja, i težine se podešavaju.
- 5. Ponavljanje koraka 3 i 4** sve dok se ne dostigne željena greška ili određeni broj iteracija učenja

M. Zekić- Sušac

19

Tri faze rada NM



U fazi treniranja mreža uči na prošlim slučajevima, a rezultat u fazi treniranja se ne uzima kao ocjena mreže jer je dobiven na uzorku za učenje. Ova faza traje najdulje, provodi se u tisućama iteracija na istom uzorku.

U fazi unakrsne validacije mreža nastoji optimirati duljinu treniranja, broj skrivenih neurona i parametre (stopu učenja i momentum). Najbolja dobivena mreža se pohranjuje i testira u sljedećoj fazi.

U fazi testiranja naučena mreža se konačno testira na uzorku koji nije do sada vidjela, i taj se rezultat uzima kao ocjena mreže. Mreža s najboljim test rezultatom se koristi u praksi.

M. Zekić- Sušac

20

Dizajn NM

- izabrati **algoritam** - npr. Backpropagation (MLP), RBFN, Kohonen-ova mreža ili dr.)
- odrediti **strukturu mreže** (topologiju)
 - broj slojeva (da li jedan skriveni sloj ili više),
 - broj neurona u skrivenom sloju (proizvoljno ili korištenjem nekih od metoda optimizacije broja skrivenih neurona (pruning, cascading i dr.)
- izabrati **funkcije i parametre** u mreži
 - pravilo učenja (npr. Delta ili Delta-Bar-Delta)
 - prijenosnu funkciju (npr. sigmoidnu)
 - parametre: koeficijent učenja i momentum (veći koeficijent učenja znači brže učenje, ali i mogućnost gubitka informacije o finijim vezama, momentum je najčešće 0.5)
- izabrati **mjerilo za ocjenjivanje mreže** (kod problema predviđanja koristi se npr. srednja kvadratna greška (RMS), korelacija između željenog i izračunatog outputa, a kod problema klasifikacije koristi se stopa klasifikacije, matrica konfuzije ili dr.)
- izabrati željeni **max. broj iteracija** za učenje (npr. 100 000 ili više)

M. Zekić- Sušac

21

Koraci u izgradnji NM

- 1. definirati model** (ulazne i izlazne varijable)
- 2. prikupiti i urediti podatke** (kodirati varijable koje nisu numeričke u kategorije i klase (npr. 1=NSS, 2=SSS, 3=VSS, itd.), izvršiti statističko preprocesuiranje podataka (detalji u pomoćnim materijalima)
- 3. uzorkovanje** - odrediti koliki će se dio podataka koristiti za treniranje, validaciju i testiranje (npr. 70% za treniranje, 10% za validaciju, 20% za testiranje)
- 4. dizajniranje mreže** - ako u programu koji se koristi ne postoji automatsko dizajniranje neuronske mreže, potrebno je odrediti dizajn mreže (detalji su na prethodnoj stranici)
- 5. odrediti željeni broj iteracija za učenje mreže** (npr. 10000, može biti proizvoljan, a i optimiziran posebnim metodama)

Mreža je spremna za učenje. Pokrenite je!!!

M. Zekić- Sušac

22

Koraci u izgradnji NM

6. treniranje mreže – na uzorku za treniranje

7. testiranje mreže – na uzorku ostavljenom za testiranje

8. analiza rezultata dobivenih testiranjem (analiza veličine greške i grafičkog prikaza).

Ako je greška neprihvatljiva, vraćanje na neki od prethodnih koraka. Ako je prihvatljiva, slijedi primjena mreže: **faza opoziva (recall)**, a kod nekih mreža i **on-line učenje** (stalno dodavanje novih podataka u uzorak za učenje)

M. Zekić- Sušac

23

Izbor mjerila ocjenjivanja NM

- Ako se radi o problemu **predviđanja**, najčešće mjerilo za ocjenjivanje uspješnosti mreže je **RMS greška**

$$RMS \text{ ERR} = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (t_i - o_i)^2}$$

RMS greška govori kolika su odstupanja između željenog outputa i outputa mreže. Raspon greške je (0,1). Cilj je dobiti što manju grešku (blizu 0).

Druga korisna mjerila su npr. MSE (srednja kvadratna greška), korelacija između željenog i stvarnog outputa, ostvaren profit itd.

M. Zekić- Sušac

24

Izbor mjerila ocjenjivanja NM

- Ako se radi o problemu **klasifikacije**, najčešće se koristi Stopa klasifikacije (% ili udio slučajeva koje je mreža dobro klasificirala). Stopa klasifikacije se izražava kroz matricu konfuzije.
- U matrici se nalazi po jedan stupac i redak za svaku izlaznu klasu, podaci u recima su željene klase, a podaci u stupcima dobivene klase. Brojevi na dijagonali govore o % dobro klasificiranih slučajeva iz svake klase. Cilj je dobiti što veću ukupnu stopu klasifikacije.

Act. 0.8000	0.0000	0.2000	0.8000
Desired	0.0000	0.0000	0.0000
Classification Rate	1.0000	0.8000	0.2000

M. Zekić- Sušac

25

Primjer 1

Problem:

Predviđanje stope povrata na dionice IBM-a za naredni dan trgovanja.

Cilj je predvidjeti koliki će biti povrat na dionicu IBM-a narednog dana ako se dionica proda po današnjoj cijeni zatvaranja (close price), a u svrhu OSTVARIVANJA PROFITA trgovanjem tim dionicama.

Povrat na dionicu računa se kao razlika u cijeni u odnosu na prošlo razdoblje uvećana za dividendu.

Pretpostavka je da se povrat na dionicu IBM-a može predvidjeti na temelju cijene dionice, financijskih pokazatelja tvrtke, makroekonomskih varijabli, i tržišnih varijabli.

Podaci su prikupljeni s pomoću i-Soft Inc.(cijene dionica), te iz baza podataka na Internet mreži (Value Line i Economagic.com).

M. Zekić- Sušac

26

Definiranje modela za Primjer 1

IZLAZNA VARIJABLA (1):

- povrat na dionicu IBM-a za naredni dan

ULAZNE VARIJABLE (20):

Volumen dionice, Nepostojanost dionice, Beta, Povrat na ulaganje (ROI), Intenzivnost kapitala (CI), Financijska snaga (FL), Intenzivnost nenaplaćenih računa (RI), Intenzivnost zaliha (II), Tekući omjer (CR), Stanje novca (C), Stopa 30-godišnjeg hipotekarnog kredita (MR), Stopa 3-mjesečnog povećanja državnog trezora (TBR), Stopa primarnog zajma banke (BPLR), Stopa valutnog tečaja japanskog jena u odnosu na US dolar (ER), Stopa federalnih fondova (FFR), Stopa ukupnog povrata na S&P 500 indeks (S&P500 TRR), Indeks industrijske proizvodnje (IPI), Stopa nezaposlenosti (UR), Indeks vodećih indikatora (ILI), Indeks potrošačkih cijena (CPI)

M. Zekić- Sušac

27

Priprema ulaznih podataka za Primjer 1

Ukupan uzorak sastoji se od 849 slučajeva (dnevni podaci).

Uzorak za treniranje i validaciju

prvih 594 slučajeva (70%)

pokrivajući razdoblje od 18. siječnja 1996. do 18. rujna 1998.

Uzorak za testiranje

ostalih 255 slučajeva (30%)

pokrivajući ostalo razdoblje sve do 1. srpnja 1999.

M. Zekić- Sušac

28

Priprema ulazne datoteke za Primjer 1

Potrebno je kreirati ASCII datoteku (ili xls kod nekih mreža) u obliku slogova baze podataka, gdje će jedan red predstavljati jedan dan na trgovanja tom dionicom (najprije se u redu navode ulazne, a zatim izlazne varijable).

	x1	x2	x3	x4	x5	x6	x7	...	x32	y1	y2	y3	y4	y5
	1.53	1.99	2.1	2.52	1.45	0	0	1	1	...	1	0	0	0
....													

Zatim se ta datoteka dijeli na 3 poduzorka: uzorak za **treniranje**, uzorak za unakrsno **testiranje** (kod optimizacije mreže) i uzorak za konačnu **validaciju** mreže.

M. Zekić- Sušac

29

Izbor parametara NM za Primjer 1

- Backpropagation algoritam
- 20 ulaznih, 1 izlazni neuron, 4 skrivena neurona (prema Masters-ovoj formuli)
- Delta pravilo učenja, sigmoidna prijenosna funkcija
- koeficijent učenja 0.2, momentum 0.5
- epoha 10,
- RMS greška kao mjerilo ocjenjivanja mreže
- pokrećemo mrežu na 10 000 iteracija učenja
- testiramo mrežu, i analiziramo rezultat

M. Zekić- Sušac


30

Analiza rezultata mreže

Budući da ne postoji pravilo po kojem je neka veličina greške minimalna kod neuronskih mreža, **uspješnim rezultatom** smatra se greška koja zadovoljava trenutne potrebe korisnika.

Kako protumačiti veličinu greške? Npr. ako je $RMS=0.09$, to znači da je razlika između stvarnog (željenog) i izračunatog outputa 0.09 ako se outputi normaliziraju na interval $[0,1]$, ili drugim riječima, odstupanje od stvarne vrijednosti outputa je 9%.

Na primjeru 1, to bi značilo da je razlika između stvarne i izračunate stope povrata na dionicu IBM-a oko 9%.



Grafička analiza rezultata kod predviđanja se provodi promatranjem kretanja stvarnog outputa i vrijednosti outputa dobivenog mrežom.

31

Na koje se vrste problema NM mogu primijeniti?

- gdje postoji mnogo prošlih reprezentativnih primjera (barem oko 100, a poželjno je što više)
- gdje nisu poznata pravila dolaženja do odluke (black box), tj. eksperata nema ili nisu dostupni
- gdje se varijable mogu kvantitativno izraziti (što je gotovo uvijek moguće)
- gdje standardne statističke metode nisu pokazale uspjeh, tj. pojava se ne može predstaviti nekim linearnim modelom
- gdje je ponašanje pojave često neizvjesno, podaci nepotpuni, te traže robustan alat

M. Zekić- Sušac

32

Na koje se vrste problema NM ne mogu primijeniti?

- kada nam je važno s matematičkom sigurnošću objasniti povjerenje u izlazni rezultat, jer NN ne daju podatak o pouzdanosti sustava

Primjeri:

- NN može izračunati da će sutrašnja cijena dionica porasti za 10%, ali ne može reći s kojom sigurnošću to tvrdi.
- NN može reći da kupci koji su vitki više jedu zdravu hranu, i da je greška u njezinoj procjeni 10% bila na podacima za testiranje, ali ne može reći kolika je greška na novim, budućim podacima.
- NN može reći da potrošač koji se bavi sportom pripada u skupinu koji će trošiti više deterdženta za iskuhavanje rublja, ali ne može reći koja je vjerojatnost

M. Zekić- Sušac

33

Najčešća područja primjene NM u poslovanju

Prema Wong, B.K., Bodnovich, T.A., Selvi, Y., *Neural Network Applications in Business: A Review and Analysis of the literature (1988-95)*, *Decision Support Systems*, vol. 19, 1997, pp. 301-320. najčešća područja primjene neuronskih mreža u posljednjih 10 godina su:

1. proizvodnja i operacije (53.5%)
2. financije i ulaganje (25.4%).
3. marketing i trgovina

M. Zekić- Sušac

34

Primjena u financijama i ulaganju

Procjena zajmova:

hipotekarni krediti, prognoziranje kategorije rizika, potpisivanje zajmova i hipotekarnih kredita

Tržište dionica i obveznica:

određivanje povoljnog trenutka kupovine i prodaje dionica, problem narudžbi za kupovanje i prodavanje, otkrivanje trokutatih uzoraka u cijenama dionica na tržištu dionica, prepoznavanje uzoraka za kupovinu i prodaju žive stoke na tržištu budućih roba

Klasifikacija i rangiranje rizika:

rangiranje obveznica, klasifikacija obveznica, klasifikacija povrata na dionice na visok ili nizak povrat,

Prognoze tržišta:

predviđanje cijena dionica, prognoziranje cijena na tržištima budućih roba (futures), predviđanje mjesečnih kretanja cijena dionica, predviđanje povrata na tržištu dionica

M. Zekić- Sušac

35

Primjena u marketingu i trgovini

Segmentiranje potencijalnih kupaca u:

grupe koje će vjerojatno kupiti ili neće kupiti robu (proizvod), grupe koje se razlikuju po ponašanju pri kupnji (sklonosti), grupe koje se razlikuju po tipu kupovanja, grupe koje se razlikuju po sklonosti riziku

Identificiranje novih tržišta:

koje tržište odgovara našem tipu robe (proizvoda)

Veza kupac - prodavatelj:

koji čimbenici utječu na uspješniji poslovni odnos

Ciljanje na potrošače putem pošte (target marketing, direct marketing):

kojim potrošačima ovisno o njihovom profilu treba slati reklame putem pošte

M. Zekić- Sušac

36

Uspješnost NM

Usporedba sa statističkim metodama:

- kod većine radova točnost NN je veća od točnosti dobivene:

- **regresijskom analizom** (problemi predviđanja)
- **diskriminantnom analizom** (problemi klasifikacije)
- **cluster analizom** (problemi klasifikacije)
- **ARIMA modelom** (predviđanja vremenskih serija)

Mjerenje uspješnosti NN ostvarenim profitom:

- prosječan godišnji profit ostvaren trgovanjem na S&P500 s pomoću neuronskih mreža bio je više od 130% veći od trgovanja bez NN (Chenoweth, T., Obradovic, 1996)

- British Telecom je upotrebom NN i drugih metoda datamining-a unaprijedio odgovor od reklame poštom za 100%, a prodaja i marketing su dobili listu najprospektivnijih mušterija

Kako pronaći podatke na Webu za model NM?

■ Moguće opcije su:

- a) spojiti se na arhivu na University of California Irwine: <http://www.ics.uci.edu/~mlearn/MLSummary.html> i izabrati neku od javno raspoloživih baza podataka za istraživanja (ukoliko su podaci na gornjem linku neraspoloživi, ovo je alternativni način dolaska do tih podataka: <http://www.cs.sfu.ca/~wangk/ucidata/dataset/>), ili na Listu repozitorija o strojnom učenju na adresi: <http://www.ics.uci.edu/~mlearn/MLOther.html>, ili
- b) pronaći javno raspoložive podatke na nekim drugim lokacijama na Webu ili izvan Weba, ili
- c) iskoristiti podatke koje ste možda već prije prikupili za neki drugi predmet.

Literatura

- Bidgoli, H., Intelligent Management Support Systems, Quorum Book, 1998.
- Čerić, V., Varga, M. (ur.), Informacijska tehnologija u poslovanju, Element, Zagreb, 2004.
- Mišljenčević, D., Maršić, I., Umjetna inteligencija, Školska knjiga, Zagreb, 1991.
- S. Russel, P. Norvig, Artificial Intelligence - A modern approach, Prentice Hall, New York, 2003.

Web izvori

Elektroničke knjige, tutoriali

- <http://eris.foi.hr> – izabrati u izborniku Neuronske mreže
- <http://www.nd.com/products/nsbook.htm>
- <http://www.ii.com/internet/messaging/nn/>
- <http://www.best.com/~ii/internet/messaging/nn/>
- <http://www.ii.com/internet/faqs/launchers/usenet/software/nn/getting-started/>

Novosti na području NN

- <http://www.neural101.com>
- Učestalo postavljana pitanja o NN
- <ftp://ftp.sas.com/pub/neural/FAQ.html>