Dušan Dobrila,
kapetan I klase, dipl. inž.,

Mr Nenad Parčina,
major, dipl. inž.

Neuralne mreže

Uvod

Na svakodnevnu upotrebu računara u raznim oblastima već smo navikli. Međutim, na ono što je novo u toj oblasti i na što još nismo navikli — to su pojmovi »vještačka inteligencija« i »neuralne mreže«. Ovi pojmovi i ono šta oni podrazumjevaju izazivaju veliko zanimanje kod ljudi. Timovi naučnika se sa manje ili više uspjeha bave ovom problematikom, a veliki je broj ljudi koji na razne načine (u bankama, na aerodromima) dolaze sa njima u dodir, često i ne znajući to [1].

Ovaj članak ukratko obrađuje pojam neuralnih mreža, te daje primjer kako se jednim softverskim paketom koji simulira rad sa neuralnom mrežom može napraviti jednostavna primjena mreže. Jasno je da je primjer odabran tako da je svima dostupan. Mogu se uočiti neke zakonitosti koje se javljaju u radu mreže, a prava primjena ovih mreža se u zrakoplovstvu ogleda kroz prepoznavanje komandi koje izgovara pilot složenim situacijama pri komandiranju glasom i pri pomoći pilotu kod donošenja odluka.

Osnovni pojmovi o vještačkoj inteligenciji i neuralnim mrežama

Široka upotreba računara u nauci, tehnici i u svakodnevnim životnim si-

tuacijama, dovodi do daljeg povećanja zahtjeva prema njima. U početku, računari su korišćeni isključivo kao sredstvo za brzo rješavanje složenih matematičkih problema, no uz porast brzine rada i kapaciteta memorije počele su se praviti usporedbe računara sa nervnim sistemom bioloških bića, te su se pojavili termini vještačka inteligencija, neuralne mreže i sl. [2]. Ukoliko se zanemare pretjerivanja koja su se pri tome pojavljivala, može se smatrati da je prikazivanje određenih oblika znanja pomoću računara otvorilo nove oblasti njihove primjene u nenumeričke svrhe.

Ono što je zajedničko vještačkoj inteligenciji i neuralnim mrežama je njihova polazna osnova, a to je reprezentacija ljudskog iskustva, odnosno određenih oblika znanja u računarima. Pojmovi kao što su adaptacija, inteligencija, iskustvo i znanje vezani su uz nervne mreže i živa bića, a nastali su kroz evoluciju živih bića i nervnih mreža. Nasuprot tome, računarima se mogu prikazivati samo ona znanja koja se mogu opisati matematičkim aparatom. Računar je, stoga, ograničen na sasvim određene segmente reprezentacije ljudskog znanja, s obzirom na to da obrađuje matematičke izraze koji su po svojoj prirodi samo okvir za spoznaju.

Neuralne mreže su oblast koja se naglo razvija poslednjih godina i pred

njima se nalazi široko polje za razvoj i usavršavanje, a neuroračunarstvo je oblast koja je, istovremeno, izbila u prvi plan zbog brojnih primjena koje su postale moguće zahvaljujući neuralnim mrežama [3]. U primjene o kojima se sada već može govoriti svakako spadaju problemi raspoznavanja i sinteze govora, problemi prepoznavanja jasnih i zamagljenih oblika na slikama, roboti i rješavanje problema njihovog kretanja pomoću senzora, pronalaženje eksplozivnih naprava u prtljagu na aerodromima, klasifikacija kvaliteta proizvoda, prepoznavanje, identifikacija i klasifikacija radarskih odraza ciljeva aviona i raketa, te još mnogo drugih primjena.

Neuralne mreže

Pod pojmom neuralna mreža podrazumijeva se mreža sastavljena od elemenata koji se nazivaju neuroni. Kao i ime, tako je i razvoj neurona inspiriran biološkim neuronima, ali u neuroračunarstvu neuroni nemaju striktnu povezanost sa biološkim neuronima.

Sl. 1 Neuron

Osnovni element neuralne mreže je neuron, prikazan na slici 1, koji obrađuje više ulaza i daje jedan izlaz. Ulazi i izlazi obično su numeričke vrijednosti između nule (0) i jedinice (1), gdje vrijednosti blizu jedinice predstavljaju pozitivne stimulacije, a vrijednosti blizu nule negativne stimulacije ili stanje bez stimulacije. Ulazi u neuron mogu biti iz drugih neurona, ili iz »vanjskog svijeta«, a izlazi mogu biti povezani sa drugim neuronima ili sa »vanjskim svijetom«. Proces pomoću

kojega neuron obrađuje svoje ulaze i proizvodi izlaz obično je suma ulaza obrađena linearnom funkcijom koja se naziva izlazna funkcija.

Nezavisni neuron je od male koristi i zato je interesantan za razmatranje samo kada je povezan u mrežu, a neuroni povezani u mrežu čine čvorove. Slika 2 prikazuje neuralnu mrežu sa dva sloja čvorova, pri čemu su čvorovi u prvom sloju ulazni čvorovi (njihov ulaz je iz »vanjskog svijeta«), a tri čvora u drugom sloju su izlazni čvorovi (njihovi izlazi su u »vanjski svijet«).

Sl. 2 Dvoslojna neuralna mreža

Svaki od ulaznih čvorova šalje svoje izlaze na izlazne čvorove na završnu obradu. Prvi sloj prosljeđuje svoje vrijednosti na drugi sloj sa nekim težinskim koeficijentom, koji predstavlja jačinu sprege. Tako za pojačavanje sprege treba povećati težinski koeficijent, i obrnuto.

Sl. 3 Binarna neuralna mreža

Neuronska mreža obrađuje podatke tako što prima ulazne veličine (u rasponu između 0 i 1) u ulazne čvorove,

a na izlaznim čvorovima daje oblik izlaza koji ovisi o vrsti mreže. Na slici 3 prikazana je binarna neuralna mreža koja daje binarni oblik (0; 1; 0) iz binarnog ulaza (0; 1), a na slici 4 prikazana je analogna neuralna mreža koja obrađuje analogne vrijednosti (0,2; 0,75) i daje izlaz (0,1; 0,9; 0,3). Pogledaju li se ove dvije mreže malo bolje, može se uočiti da obje, u stvari, imaju isti algoritam. U analognoj verziji kaže se da su izlazi u uključenom stanju ako su iznad nekog zadatog praga (na primjer 0,5).

Sl. 4 Analogna neuralna mreža

Vanjska povratna sprega određuje kolika će biti veza između neurona. Povratna sprega stvara se onda kada je oblik koji treba da se nauči priključen na ulazne čvorove. Svaki ulazni oblik ima poznati izlazni oblik koji se očekuje na izlazu. Takav par oblika naziva se primjer. Greška između predviđenog i stvarnog izlaza se mjeri (ukupna greška je suma zbir kvadrata razlika). Sprege, odnosno težine koje vode ka izlaznim čvorovima se mijenjaju, tako da dovode do smanjenja greške kada se dovede isti oblik na ulaz. Ponavljanje oblika na ulazu, odnosno promjena težina, tj. sprega između čvorova, naziva se učenje. Ono se ponavlja sve dok greška ne padne ispod praga koji se unaprijed postavlja.

Poslije učenja, ili bolje rečeno treniranja mreže, ona je sposobna da reproducira ispravan izlazni oblik, kada je na ulazu oblik sa kojim je mreža trenirana. Štaviše, mreža je u stanju da prepozna ulazni oblik, koji je sličan obliku kojim je trenirana. Može se reći da ona može razvrstati dva slična ulaza kao da su isti, ako su svi izlazni

čvorovi iznad ili ispod izlaznog praga jednog slučaja respektivno iznad ili ispod praga u drugom slučaju.

Nerealne mreže sa prostiranjem unazad

Problem koji se javlja kod mreža sa dva sloja ogleda se u tome što one nisu pogodne za rješavanje složenijih problema. Neuralne mreže sa prostiranjem unazad riješavaju ovaj problem sa ubacivanjem još jednog sloja čvorova između ulaznog i izlaznog (sl. 5) nivoa. Čvorovi koji se nalaze u ovom sloju nazivaju se skriveni čvorovi. Pod uslovom da mreža ima dovoljan broj skrivenih čvorova, tri sloja su dovoljna za rješavanje složenijih problema. Kod ove vrste neuralnih mreža prenosna funkcija je nelinearna.

Sl. 5 Neuralne mreže sa prostiranjem unazad

Sa tri sloja, promena koeficijenata težine mora se obaviti ne samo između drugog i trećeg sloja, već se mora prostirati i unazad između prvog i drugog sloja. Zato se ova mreža i naziva mreža sa prostiranjem unazad.

Broj čvorova u ulaznim i izlaznim slojevima jasno je određen brojem ulaza i izlaza, dok broj skrivenih čvorova nije baš tako jasno određen i ne postoji gotova formula za izračunavanje broja ovih čvorova. Metod pokušaja i mjerenja grešaka najbolji je način da se odredi broj skrivenih čvorova. Ukoliko je broj skrivenih čvorova neodgovarajući — premalen, može se desiti da mreža neće biti sposobna da u sebi drži sve

situacije, pa će se pojaviti slučaj nemogućnosti treniranja mreže ili će greške pri klasifikaciji biti velike.

»Neuroshell« neuralna mreža

Jednostavna, ali veoma korisna neuralna mreža, jeste programski paket NeuroShell firme Ward System Group [4]. Ovaj softver je pisan za IBM PC XT/AT kompatibilne računare i simulira neuralnu mrežu sa prostiranjem unazad. Potrebno je da se definišu ulazne karakteristike, zadaju primjeri za učenje i posle učenja ili, bolje rečeno, treniranja mreže, a nakon postavljanja ranije nepoznatih slučajeva mreža ih klasificira prema modelu kojim je ranije bila istrenirana.

Kao ilustracija primene NeuroShell mreže može poslužiti primjer nazvan »Avioni«. Ovaj pojednostavljen opis i primjer primjene namijenjen je da unaprijedi razumijevanje neuralne mreže sa prostiranjem unazad upravo primjenom NeuroShell mreže.

Da bi se postavio primjer, potrebno je da se definiraju karakteristike za primjere sa kojima će se mreža trenirati. Karakteristike koje su, zapravo, ulazi u mrežu, jesu, kao prvo, razne osobine, a, kao drugo, razni avioni.

	A-10A
	Su-25
krila pravougaona	TORNADO
krila delta	MiG-25
krila promenjive geometrije	C-141B
krila strela	B-52G
krilo	F-117A
krila trapezna	B-2
jedan motor	SEA HARRIER
dva motora	TR-1A
četiri motora	JAK-38
osam motora	
vertikalno poletanje	
dva vertikalna stabilizatora	
jedan vertikalni stabilizator	

bez vertikalnog stabilizatora

posada jedan

posada dva

posada četiri

posada šest

top

dva topa

mitraljezi

rakete

bombe

Slijedeći korak je treniranje — učenje mreže, koje se obavlja unošenjem nekih od karakteristika vezanih za konkretan avion, tako da se postepeno savladava sve veći broj karakteristika po avionu. Ovdje postoji mogućnost kombiniranja karakteristike i aviona, unošenje jedne karakteristike koja je zajednička za više aviona, i tome slično, ali zbog pojednostavljenja primjera to ovdje nije urađeno.

Sample Case: 1

krila pravougaona
dva motora
dva vertikalna stabilizatora

A-10A

Sample Case: 2

krila pravougaona
dva motora
dva vertikalna stabilizatora
posada jedan

A-10A

Sample Case: 3

krila pravougaona
dva motora
dva vertikalna stabilizatora
posada jedan
top
rakete
bombe

A-10A

Sample Case: 4

krila delta
dva motora
jedan vertikalni stabilizator

Su-25

Sample Case: 5

krila delta
dva motora

jedan vertikalni stabilizator posada jedan Su-25 Sample Case: 6 krila delta dva motora jedan vertikalni stabilizator posada jedan top rakete bombe Su-25 Sample Case: 7 krila promenjive geometrije dva motora jedan vertikalni stabilizator TORNADO Sample Case: 8 krila promenjive geometrije dva motora jedan vertikalni stabilizator posada dva TORNADO Sample Case: 9 krila promenjive geometrije dva motora jedan vertikalni stabilizator posada dva dva topa rakete bombe TORNADO Sample Case: 10 krila delta dva motora dva vertikalna stabilizatora MiG-25 Sample Case: 11 krila delta dva motora dva vertikalna stabilizatora posada jedan rakete MiG-25 Sample Case: 12 krila strela četiri motora	C-141B Sample Case: 13 krila strela četiri motora jedan vertikalni stabilizator posada četiri C-141B Sample Case: 14 krila strela osam motora B-52G Sample Case: 15 krila strela osam motora jedan vertikalni stabilizator posada šest mitraljezi rakete bombe B-52G Sample Case: 16 krilo dva motora F-117A Sample Case: 17 krilo dva vertikalna stabilizatora F-117A Sample Case: 18 krilo dva motora dva vertikalna stabilizatora posada jedan bombe F-117A Sample Case: 19 krilo četiri motora B-2 Sample Case: 20 krilo bez vertikalnog stabilizatora B-2 Sample Case: 21 krilo četiri motora

bez vertikalnog stabilizatora posada dva rakete bombe	
B-2	
Sample Case: 22	
krila strela vertikalno poletanje	
SEA HARRIER	
Sample Case: 23	
krila strela jedan motor posada jedan	
SEA HARRIER	
Sample Case: 24	
krila strela jedan motor vertikalno poletanje jedan vertikalni stabilizator posada jedan dva topa rakete bombe	
SEA HARRIER	
Sample Case: 25	
krila trapezna jedan motor	
TR-1A	
Sample Case: 26	
krila trapezna jedan motor jedan vertikalni stabilizator posada jedan	
TR-1A	
Sample Case: 27	
krila delta vertikalno poletanje	
JAK-38	
Sample Case: 28	
krila delta jedan motor	
JAK-38	
Sample Case: 29	
krila delta jedan motor vertikalno poletanje jedan vertikalni stabilizator posada jedan	

dva topa rakete bombe	
JAK-38	
Sample Case: 30	
krila delta jedan motor vertikalno poletanje	
JAK-38	
Sada, nakon obavljenog učenja, dolazi na red faza zadavanja svog, no- vog, računara do sada nepoznatog slu- čaja. Mreža će na izlazu dati verovat- noću kojom ga klasificira u do sada na- učene primjere.	
Classified Case: 1	
krila promenjive geometrije	
TORNADO 0,82	
Classified Case: 2	
krila delta	
JAK-38 0,70	
Classified Case: 3	
krila delta dva motora	
MiG-25 0,51	
Classified Case: 4	
krila delta dva motora jedan vertikalni stabilizator	
Su-25 0,89	
Classified Case: 5	
krilo bez vertikalnog stabilizatora	
B-2 0,89	
Classified Case: 6	
krila delta dva motora rakete	
MiG-25 0,76	
Classified Case: 7	
krila strela jedan vertikalni stabilizator	

SEA HARRIER 0,60

Classified Case: 8

krila strela
vertikalno poletanje
jedan vertikalni stabilizator

SEA HARRIER 0,91

Classified Case: 9

krila strela
jedan motor
vertikalno poletanje
jedan vertikalni stabilizator

SEA HARRIER 0,93

Analiziraju li se rezultati i usporede li se sa unesenim karakteristikama, tada se za primjer (1) uočava da je imao unesenu samo jednu ovu karakteristiku za samo jedan tip aviona, pa je i odgovor bio sa visokom vjerovatnoćom. Primjeri (2; 3 i 4) pokazuju da od broja unesenih karakteristika koje su zajedničke za više tipova aviona zavisi i odgovor i vjerovatnoća, dok primjeri (2 i 3) pokazuju da se sa dvije do tri pravilno odabrane karakteristike može doći do ispravnog rezultata sa visokom vjerovatnoćom pravilne klasifikacije.

Literatura:

- [1] Daniel W. Rasmus: »Putting the Experts to Work«, Byte, Jan. 1991, str. 281—287.
- [2] Rajko Tomović: »Reprezentacija znanja u računarima«, Neuronske mreže u računarskoj tehnici — zbornik radova, Beograd, 1990.

To naročito potvrđuju posljednji primjeri (7; 8 i 9), gdje vjerovatnoća pravilne klasifikacije nepoznatog slučaja u poznati »naučeni« oblik raste sa brojem poznatih karakteristika.

Zaključak

Na kraju ovog kratkog članka i prezentiranog primjera može se zaključiti da su mogućnosti primjene neuralnih mreža u životu i armiji praktično neograničene. Ovdje moramo spomenuti zrakoplovstvo i njegov visok tehničko-tehnološki nivo, koji zahtijeva od pilota borbenog aviona da u izuzetno kratkim vremenskim intervalima ostvaruje prave procjene i donese pravilne odluke. Uloga neuralnih mreža može se sagledati u pomoći pri donošenju odluke i u izvršavanju komandovanja glasom, što je dalja faza rastećenja pilota pri izvršavanju borbenih i drugih zadataka. Ovaj članak je imao za cilj upoznavanje sa neuralnim mrežama i upućivanje na softver kojim se one mogu simulirati.

- [3] Jozo Dujmović: »Primene neuronskih mreža«, Neuronske mreže u računarskoj tehnici-zbornik radova, Beograd, 1990.
- [4] Ward System Group »NeuroShell Program Reference Book«, Frederick, USA, 1990.