

**UNIVERZA V LJUBLJANI  
EKONOMSKA FAKULTETA**

**MAGISTRSKO DELO**

**ANDREJ ZAPLOTNIK**



UNIVERZA V LJUBLJANI  
EKONOMSKA FAKULTETA

MAGISTRSKO DELO

**REŠEVANJE RAZLIČNIH POSLOVNIH PROBLEMOV S POMOČJO  
NEVRONSKIH MREŽ**

Ljubljana, junij 2015

ANDREJ ZAPLOTNIK

## IZJAVA O AVTORSTVU

Spodaj podpisan Andrej Zaplotnik, študent Ekonomske fakultete Univerze v Ljubljani, izjavljam, da sem avtor magistrskega dela z naslovom Reševanje različnih poslovnih problemov na področju managementa s pomočjo nevronske mreže, pripravljenega v sodelovanju s svetovalcem dr. Vladom Dimovskim.

Izrecno izjavljam, da v skladu z določili Zakona o avtorski in sorodnih pravicah (Ur. l. RS, št. 21/1995 s spremembami) dovolim objavo zaključne strokovne naloge/diplomskega dela/specialističnega dela/magistrskega dela/doktorske disertacije na fakultetnih spletnih straneh.

S svojim podpisom zagotavljam, da

- je predloženo besedilo rezultat izključno mojega lastnega raziskovalnega dela;
- je predloženo besedilo jezikovno korektno in tehnično pripravljeno v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, kar pomeni, da sem
  - poskrbel(-a), da so dela in mnenja drugih avtorjev oziroma avtoric, ki jih uporabljam v zaključni strokovni nalogi/diplomskem delu/specialističnem delu/magistrskem delu/doktorski disertaciji, citirana oziroma navedena v skladu z Navodili za izdelavo zaključnih nalog Ekonomske fakultete Univerze v Ljubljani, in
  - pridobil(-a) vsa dovoljenja za uporabo avtorskih del, ki so v celoti (v pisni ali grafični obliki) uporabljena v tekstu, in sem to v besedilu tudi jasno zapisal(-a);
- se zavedam, da je plagiatstvo – predstavljanje tujih del (v pisni ali grafični obliki) kot mojih lastnih – kaznivo po Kazenskem zakoniku (Ur. l. RS, št. 55/2008 s spremembami);
- se zavedam posledic, ki bi jih na osnovi predložene zaključne strokovne naloge/diplomskega dela/specialističnega dela/magistrskega dela/doktorske disertacije dokazano plagiatstvo lahko predstavljalo za moj status na Ekonomski fakulteti Univerze v Ljubljani v skladu z relevantnim pravilnikom.

V Ljubljani, dne

Podpis avtorja: \_\_\_\_\_

# KAZALO

UVOD.....	1
1 NEVRONSKE MREŽE .....	3
1.1 Kaj so nevrnske mreže.....	4
1.1.1 Definicija in delovanje nevrnske mreže.....	4
1.1.2 Razvoj nevrnskih mrež .....	5
1.2 Vrste nevrnskih mrež.....	6
1.2.1 Model nevrona .....	10
1.2.2 Usmerjena nevrnska mreža (perceptron) .....	14
1.2.3 Hopfieldova nevrnska mreža .....	16
1.3 Nevronske mreže in napovedovanje.....	17
1.4 Učenje nevrnskih mrež .....	18
1.4.1 Hebbovo pravilo .....	19
1.4.2 Pravilo delta .....	19
1.4.3 Posplošeno delta pravilo .....	20
1.4.4 Kohonenovo pravilo oziroma tekmovalno pravilo .....	23
1.4.5 Pravilo protitočnega razširjanja .....	23
1.5 Prednosti in slabosti nevrnskih mrež .....	24
2 NEVRONSKE MREŽE NA PODROČJU MANAGEMENTA .....	25
2.1 Inovacijski managment .....	26
2.1.1 Inovacija in invencija .....	27
2.1.2 Uvajanje inovacijskega poslovanja .....	30
2.2 Aplikacije nevrnskih mrež v managementu .....	34
2.3 Stroškovni pregled uporabe nevrnskih mrež .....	36
3 EMPIRIČNA ANALIZA .....	38
3.1 Namen in cilji raziskave uporabe nevrnskih mrež.....	38
3.2 Praktična uporaba nevrnskih mrež .....	39
3.2.1 Odobritev posojil s pomočjo nevrnskih mrež .....	40
3.2.2 Uporaba nevrnskih mrež pri poslovanju z vrednostnimi papirji.....	42
3.2.3 Uporaba nevrnskih mrež pri načrtovanju poslovanja .....	45
3.3 Temeljno raziskovalno vprašanje .....	47
3.4 Preverjanje zastavljenih hipotez .....	48
3.5 Uporabnost pridobljenih podatkov in rezultatov .....	51
SKLEP.....	52
LITERATURA IN VIRI.....	53

## KAZALO SLIK

SLIKA 1: IZGLED BIOLOŠKEGA NEVRONA IN NEVRONSKE MREŽE.....	5
SLIKA 2: DELOVANJE ASOCIATIVNEGA POMNILNIKA .....	7
SLIKA 3: ENOPLASTNA USMERJENA NEVRONSKA MREŽA .....	8
SLIKA 4: DVOPLASTNA USMERJENA NEVRONSKA MREŽA .....	8
SLIKA 5: VEČPLASTNE USMERJENE NEVRONSKE MREŽE .....	9
SLIKA 6: REKURZIVNA NEVRONSKA MREŽA .....	9
SLIKA 7: PRAGOVNA ALI BINARNA PRENOSNA FUNKCIJA .....	12
SLIKA 8: ODSEKOMA LINEARNA PRENOSNA FUNKCIJA .....	13
SLIKA 9: SIGMOIDNA PRENOSNA FUNKCIJA .....	13
SLIKA 10: PRIMER VEČPLASTNEGA PERCEPTRONA PO OZNAČBI.....	16
SLIKA 11: HOPFIELDOVA NEVRONSKA MREŽA .....	17
SLIKA 12: ISKANJE ABSOLUTNEGA MINIMUMA FUNKCIJE NAPAKE $E(w)$ .....	21
SLIKA 13: PRIMER TIPOLOGIJ KOHONENOVIH NEVRONSKIH MREŽ.....	23
SLIKA 14: STRATEŠKI INOVACIJSKI PROCES.....	32
SLIKA 15: VIDIKI IN VLOGE V EKSPLOTACIJSKEM PROCESU NEVRONSKIH MREŽ.....	37

## KAZALO TABEL

TABELA 1: DELITVE NEVRONSKIH MREŽ .....	6
TABELA 2: PRIMERI ZAPISOV USMERJENIH NEVRONSKIH MREŽ .....	15
TABELA 3: FAZE POSAMEZNIH NOVOSTI .....	27
TABELA 4: VRSTE INOVACIJ GLEDE NA TRI MERILA .....	28
TABELA 5: INAČICE SMISELNOSTI INVENCije .....	30
TABELA 6: UPORABA NEVRONSKIH MREŽ NA PODROČJU MANAGEMENTA .....	46

## UVOD

Tehnološki razvoj in modernizacija življenja, vse to nas vodi po poti, ko si želimo, da bi bilo naše delovanje in reševanje problemov čim enostavnejše. Ker bijemo nenehno bitko s časom si seveda želimo, da bi bile rešitve naših težav hitre in kolikor toliko stabilne, če že ne kar dokončne. Omenjeni razvoj zahteva tudi vedno nove rešitve, sodobnejše in seveda ustreznejše. Slednje se odražajo tudi v poslovanju, kjer je ena izmed, če se lahko tako izrazi, tegob, konkurenčnost drugih podjetij in odjemanje našega dela tržnega deleža, kar lahko niha celo iz dneva v dan. Toda s konkurenco se ne moremo spopasti, če nimamo novih zamisli in inovacij, ki nas vodijo naprej in nam obetajo nov razvoj. Želja po prevladanju in biti najboljši nas žene, da posežemo po virih, ki bodo zeleno tudi izpolnili. Eno izmed področij, kjer se opisano še posebej dobro odraža je tudi področje managementa. Gre za vse bolj razvijajoče se področje, kjer je boj s konkurenco težak, vse hitrejši in celo nujen.

Kot dobra inovacija, primerna za področje managementa, se je med drugim izkazala uporaba t.i. nevronske mreže. Res smo se v preteklosti že spoznavali z umetno inteligenco, toda le preko filmov. Medtem ko danes na njej temelji skorajda celoten realni svet. Brez nje, pa četudi temelji na čisto osnovnih funkcijah, si ne moremo več predstavljati sveta in življenja. Ne glede na kratko zgodovino je bil razvoj umetne inteligence, temelječ na različnih področjih, v zadnjih nekaj letih hiter in predvsem uspešen. Že omenjene nevronske mreže, ki temeljijo na delovanju bioloških možganov, so bile sicer v matematični obliki predstavljene že leta 1943. Toda raziskovanje je v naslednjih letih nekoliko zastalo, nadaljnji razvoj pa se je nekoliko pospešil v sedemdesetih in osemdesetih letih prejšnjega stoletja, precej pa v zadnjih dveh desetletjih dvajsetega stoletja in danes smo priča najizrazitejšemu napredku (Mramor, 2007).

Vendar pa je razvoj nevrološkega sistema, ki posnema delovanje biološkega živčnega sistema oziroma človeških možganov, trenutno najbolj uporaben na področjih, kjer nas zanimajo predvsem končni rezultati in rešitve, ne pa tudi vmesni koraki. Kljub drugačni strukturi obdelave informacij in iskanja rešitev je Mramorjeva (2007) prepričana, da gre za proces, ki je zelo uporaben pri reševanju poslovnih problemov. V današnjem času bi torej ta metoda, seveda v primeru, da ima res tako velik potencial, predstavljala precej konkurenčno orodje v primerjavi s tradicionalnimi pristopi.

Učinkovitost nevronske mreže, da lahko posnemajo delovanje človeka in njegovega razmišljanja ter posledično rešujejo probleme, nakazuje na dejstvo, da gre najverjetneje za velik potencial reševanja tudi v primeru poslovnih problemov na področju managementa. Vendar smo v našem okolju naleteli na precejšnjo težavo. Manjka domača literatura, ki bi se ukvarjala z informacijami in rešitvami problemov na obravnavanem področju, s pomočjo nevronske mreže. Tega nismo ugotovili samo mi, vedno več je avtorjev, ki priznava, da pri nas tematike in raziskav na to temo primanjkuje. Tudi Ljubič (2008), ki

poudarja uporabnost nevronske mreže kot dobrodošel pripomoček v poslovnem svetu, se opira na navedeno. Sam poskuša to razjasniti z morebitnim odporom proti pogosto formalizirani statistiki oziroma celo proti pomanjkanju znanja.

Raznolikost poslovanja v managementu vodi do potreb in želja in do povpraševanja na trgu, iz česar je mogoče sklepati, da je na tem področju prisotna potreba po novih in različnih metodah oziroma modelih. Nevronske mreže predstavljajo eno izmed rešitev, ki v sklopu svojih raznovrstnih metod ponujajo pomoč na področju povpraševanja ali pa npr. na področju napovedovanja prihodnje poslovne situacije. Iz slednjega izhaja tudi temeljno vprašanje magistrskega dela.

Namen magistrske naloge je predstavitev nevronske mreže na splošni ravni, medtem ko se osrednje raziskovanje osredotoča na analiziranje ugotovitev, ali gre za model, ki bo v pomoč kot nov pristop reševanja problemov na področju managementa. V sklopu tega se delo posveča tudi vprašanju, ki se pojavi ob tovrstnem preučevanju in se dotika finančne plati. Ugotovitve o smiselnosti uporabe so pomembne, saj je dobro vedeti, ali gre za metodo, ki je smiselna, kljub stroškom, ki nam jih predstavlja (predvsem potrebna oprema in znanja, ki jih je treba nadgraditi oz. uporabiti). Glede na pomanjkanje slovenske literature, magistrsko delo preučene podatke in rezultate predstavlja na enem mestu. Kot tako je dober pripomoček ali vsaj vodnik k lažjemu iskanju, razumevanju in pridobivanju informacij s področjem managementa in uporabe nevronske mreže za reševanje določenih problemov na tem področju.

V teoretičnem delu so s pomočjo metode deskripcije in metode komparacije opisana dejstva in definicije o nevronske mreže, njihovi vrsti ter uporabnosti. Predstavljeni so tudi temelji inovacijskega managementa in praktična uporaba nevronske mreže na tem področju. Z metodo kompilacije so spoznanja in sklepi posameznih domačih in tujih avtorjev povzeti in združeni v celoto. Uporabljeni so primarni in sekundarni viri podatkov ter dostopne raziskave z obravnavanega področja.

Ker gre v primeru nevronske mreže za pripomoček, ki posnema človeške možgane, in je torej mogoče sklepati, da se lahko z njim rešujejo vsi poslovni problemi, magistrsko delo temelji na vprašanju: "Ali se nevronske mreže kažejo kot ustrežnejši način za reševanje poslovnih problemov?"

Iz vprašanja izhajajo naslednje temeljne hipoteze, ki so preverjane v magistrskem delu:

- Nevronske mreže so zmožne posnemanja delovanja bioloških možganov, ki so zmogljiv naravni organ. Torej gre v tem primeru za zelo zmogljivo konkurenčno orodje, sposobno rešiti tudi vse poslovne probleme.



- Nevronske mreže so sposobne same najti pravilo, ki povezuje izhodne podatke z vhodnimi. Na podlagi tega so očitno sposobne delovati tudi v situacijah, ki jih še ne poznajo.
- Glede na to, da so nevrnske mreže primerljive z biološkimi možgani, lahko v njihovem primeru prav tako pričakujemo nepredvidljivo delovanje.

Magistrsko delo zajema tri poglavja: prvo poglavje opredeljuje, kaj v splošnem so nevrnske mreže ter kakšna je razlika med biološkimi in umetnimi nevrnskimi mrežami, ki so podrobneje obravnavane. Na kratko je predstavljena zgodovina razvoja, vrste nevrnskih mrež, model nevrona ter podrobneje usmerjena nevrnska mreža oziroma perceptron in Hopfieldova nevrnska mreža. Prav tako so povzete teorije o nevrnskih mrežah in napovedovanju, učenju le-teh po pravilih, med katerimi je poudarjeno: Hebbovo pravilo, pravilo delta, pravilo vzratnega razširjanja napake, Kohonenovo pravilo in pravilo protitočnega razširjanja ter ugotovljene prednosti in slabosti nevrnskih mrež. Drugo poglavje je namenjeno analiziranju nevrnskih mrež na področju managementa in njihovi aplikaciji na tem področju. Na kratko so predstavljeni nekateri pojmi, povezani s spoznavanjem nevrnskih mrež, ki so pomembni za temeljitejše razumevanje obravnavanega področja.

Zadnje poglavje predstavlja empirično analizo, ki se posveča raziskavi uporabe nevrnskih mrež in njeni praktični uporabi. V tem poglavju je zajeto tudi preverjanje zastavljenih hipotez, podani so tudi komentarji glede uporabnosti pridobivanja podatkov in rezultatov s pomočjo nevrnske mreže. V sklepnem delu so na kratko povzete ugotovitve magistrskega dela ter priporočilo za nadaljnje raziskave na obravnavanem področju.

## 1 NEVRNSKE MREŽE

Pravzaprav gre za dokaj mlado področje, katerega razvoj še vedno poteka. Posnemanje principa bioloških možganov pa ima široko uporabno vrednost na različnih področjih. Zidar (2010) opredeljuje, da nevrnske mreže rešujejo probleme podobno kot biološki možgani, kar jih v tem primeru postavlja kot zelo zmogljivo orodje.

Peruš (2001, str. 19) meni, da so: »Nevronske mreže [...] splošno priznано najboljši model možganov na mikroskopski stopnji.« Če zanemarimo zavest in kvalije<sup>1</sup> gre pravzaprav za najuspešnejši model duševnih procesov.

---

<sup>1</sup> Kvalije so tisto, kar dejansko neposredno doživljamo oziroma občutimo. Kvalije ali kvalitativna doživetja/občutki so sinonimi za fenomenalna stanja. Gre za doživetja, ki so prvinska, osnovna, dostopna le v prvi osebi (subjektivna), neanalizabilna, v bistvu neopisljiva. Povezane so s pojmi zaznanih, sekundarnih ali akcendenčnih kvalitiet, kot so zvoki, okusi, barve in vonji. Čeprav niso omejene na vizualizacijo (angl.

## 1.1 Kaj so nevronske mreže

Raziskovanje možganov in njihovega delovanja je pripeljalo do ugotovitve, da delujejo s pomočjo t.i. nevronov, ki so osnovni, med seboj povezani gradniki, ki si pošiljajo električne oz. živčne signale. Povezanost osnovnih enot, nevronov, je privedla do uporabe izraza nevronska mreža. Danes ta izraz uporabljamo za kompleksne sisteme, ki delujejo podobno. Tako so lahko formalni nevroni katerikoli elementi določenega sistema, s pogojem, da izvajajo podobne procese, kot jih izvaja biološka mreža (Peruš, 2001). Med drugim tudi umetna nevronska mreža, ki je podrobno obravnavana v pričujočem magistrskem delu.

Umetna nevronska mreža (angl. *artificial neural network*), v nadaljevanju magistrskega dela nevronska mreža (izraz je najpogosteje v uporabi), je grajena iz gradnikov, imenovanih nevroni. Gradniki imajo medsebojno povezavo, ki pa se lahko od enega do drugega razlikuje glede na moč ali strukturo. Glavna značilnost nevronske mreže je njena sposobnost učenja in povezovanja vhodnih podatkov z izhodnimi. S pomočjo tega razvije določene učne vzorce, ki so sestavljeni iz parov vhodnih in izhodnih vzorcev, ter se na tej podlagi nauči določene funkcije oz. določenega znanja, ki ga nato shrani v povezavah (sinapsah) v obliki uteži, med nevroni. Slednje se v procesu učenja spreminjajo tako, da dosežejo optimalno stanje uteži v celotni nevronske mreži. V takšnem stanju je nevronska mreža naučena, da poveže še neznan vhodni vzorec s izhodnim vzorcem, ki ga želimo in je obenem tudi pravilen. Ker nevronske mreže pravzaprav posnemajo princip delovanja bioloških možganov, lahko govorimo o njihovi uporabni vrednosti na širšem področju.

### 1.1.1 Definicija in delovanje nevronske mreže

Za temeljitejše razumevanje se vrnimo na začetek in definirajmo najprej biološko nevronska mrežo oziroma mrežo pravih nevronov.

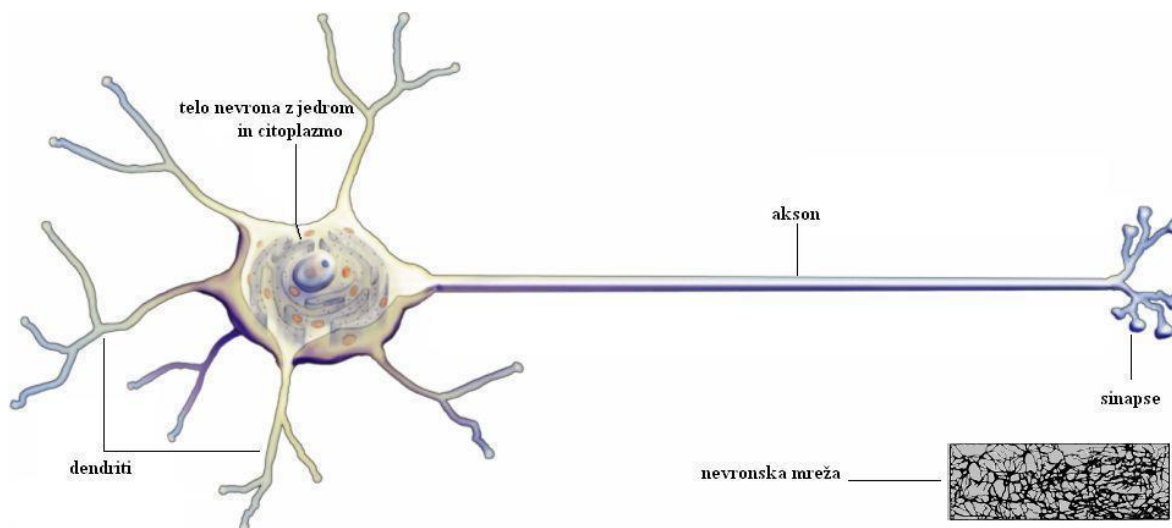
Nevronov je v osnovi več vrst, običajno imajo daljšo drevesasto razvejano izrastlino, ki se imenuje akson ter več krajših, imenovanih dendriti. Med daljšo in krajšo izrastlino enega nevrona je stik oziroma sinapsa (slika 1). S pomočjo posebnih kemičnih snovi, imenovanih neurotransmitorji, se signal prenaša iz enega nevrona na drugega preko sinaptične špranje. V vezeh se nalagajo vzorci, moč in prepustnost sinaptične vezi pa ima odločilno vlogo pri spominu. Izmenjava vzorcev med nevroni in sistemom sinaps poteka neprestano. Vzorec, ki je v obdelavi, je tako v tistem trenutku v ospredju in aktiven. Vzorci, ki niso aktivni oziroma jim v določenem trenutku ni namenjena pozornost, ostanejo v mirovanju v sinaptičnih vezeh, kjer so zakodirani, glede na potrebo pa se jih lahko priključijo.

---

*imagery*) pa predhodijo kognitivni interpretaciji ali proporcionalizaciji. Kvalije se najprej občutijo in šele nato dojamejo, glede na predhodno znanje in okoliščine (Hubbard, 1996).

Ena mreža nevronov, povezanih preko sinaps, lahko hkrati shrani več primerov, ki so zapisani vzporedno-razpršeno in zastopani v vseh sinaptičnih vezeh. Ena sinaptična vez ima shranjene sledi vseh primerov, obenem pa je en primer zakodiran v vsaki posamezni sinapsi.

*Slika 1: Videz biološkega nevrna in nevronske mreže*



*Vir: Prirejeno po M. Peruš, Biomreže, mišljenje, zavest, 2001, str. 23.*

Bistvo nevronske mreže se kaže tudi v spetosti nevronov s sinaptičnimi vezmi, ki niso nespremenljive, saj se njihova moč venomer izboljšuje in popravlja itd. (Peruš, 2001).

### 1.1.2 Razvoj nevronske mreže

S posnemanjem principa delovanja živčnega sistema sta Warren S. McCulloch in Walter Pitts, leta 1946, razvila prvo nevronske mreže. Osnovo jima je predstavljal biološki nevron. Z njegovo pomočjo sta razvila umetni nevron, ki je deloval kot preklopna linearna enota oziroma logična funkcija. Tako sta vzpostavila matematični model nevrna, ki se z manjšimi, a ne tako pomembnimi spremembami uporablja še danes. Nekoliko več kot desetletje kasneje (1958) je Frank Rosenblatt zasnoval in izdelal perceptron, ki je deloval na učenju povezave med vhodnimi in izhodnimi podatki. Dve leti kasneje (1960) sta Bernard Widrow in Marcian E. Hoff izdelala sistem adaline (angl. *adaptive linear element*), ki se je učil z metodo najmanjših kvadratov. Razvoj inovativnih rešitev bi se gotovo nadaljeval že v tistem času, če ne bi leta 1969 Marvin Minsky in Seymour Papert, izdala knjigo o omejitvah enoplastnega perceptrona in tako za nekaj časa zavrlaraziskovanje. Osemindvajset let po razvoju prve nevronske mreže pa je Paul Werbos oblikoval še danes najpogosteje uporabljeno učno metodo povratne zanke. Napredek je ponovno zagnal razvoj nevronske mreže, vendar je do pospešenega razvoja prišlo šele v devetdesetih letih. Zaradi ekonomske zanimivosti ideje so nevronske mreže tudi v zadnjih dveh desetletjih doživele velik razvoj in številne uporabe (Dobnikar, 1990; Mramor, 2007; Guid & Strnad, 2007).

## 1.2 Vrste nevronske mreže

Nevronske mreže imajo za natančnejšo definicijo vrste le-te, določena imenovanja, ki navadno izhajajo iz imena avtorja, ki jo je opredelil ali pa je uporabljeno bolj splošno poimenovanje. Najpogosteje so v uporabi naslednja poimenovanja:

- asociativne nevronske mreže;
- usmerjene večplastne nevronske mreže;
- samoorganizirajoče nevronske mreže.

Vendar nekateri avtorji uporabljajo tudi druge izraze. Tako so asociativne nevronske mreže poimenovane tudi kot Hopfieldove nevronske mreže, večplastne nevronske mreže kot perceptroni in samoorganizirajoče nevronske mreže kot Kohonenova nevronska mreža. Med drugim obstajajo še nevronske mreže, kot so Bayeseva nevronska mreža, Elmanova nevronska mreža, Boltzmanova nevronska mreža itd., katerih je v literaturi manj zaslediti. Tabela 1, predstavlja nevronske mreže oziroma njihovo običajno delitev glede na najuporabnejše lastnosti, ki zajemajo: namen, topološke značilnosti, načela in primere učenja ter linearne ali zvezne funkcije oziroma kombiniranja prenosnih funkcij (Kononenko, 1997).

*Tabela 1: Delitve nevronske mreže*


NAMEN	TOPOLOGIJA	UČENJE	PRENOSNE FUNKCIJE
avtoasociativni pomnilnik	usmerjene enoplastne	<b>NAČELA:</b>	<b>BINARNE:</b>
heteroasociativni pomnilnik	usmerjene dvoplastne	pravilo delta	pragovna funkcija
časovni asociativni pomnilnik	usmerjene večplastne	Hebbovo pravilo	funkcija signuma
klasifikacija	dvosmerni asociativni pomnilnik	tekmovalno pravilo	<b>ZVEZNE:</b>
grupiranje	neplastne	Boltzmanovo pravilo	logistična funkcija
samoorganizacija in urejanje	rekurzivne	<b>PARADIGME UČENJA:</b>	funkcija hiperbolični tangens
	statične in dinamične	nadzorovano/vodeno	odsekoma linearna funkcija
		nenadzorovano ali samoorganizirajoče	
		okrepitveno	

*Vir: Prirejeno po N. Guid & D. Strnad, Umetna inteligenca, 2007; I. Kononenko, Strojno učenje, 1997.*

**Nevronske mreže glede na namen** (Kononenko, 1997, str. 201-203):

- **avtoasociativni pomnilnik:** nevroni so v tem primeru hkrati vhodni in izhodni. Na vходу se predstavi vzorec (slika 2, a), navadno s pomočjo šumov in mreže. Nato se s ponovitvami oziroma cikličnim matematičnim postopkom, ki se nazadnje lahko uravnovesi v določeni mejni vrednosti, popravljajo šumi oziroma napačni ali pomanjkljivi deli vhodnega vzorca (slika 2, b). Po določenem številu ponovitev se mreža umiri, na izhodu pa predstavi popravljen vhodni vzorec (slika 2, c). Obstaja možnost, da je pri preveč popačenem vzorcu na izhodu le-ta napačno popravljen. Zato je treba mrežo naučiti pravih vzorcev, da bo lahko prav delovala. V tem primeru najbolj znana in največkrat uporabljena je Hopfieldova nevronska mreža;

*Slika 2: Delovanje asociativnega pomnilnika*




*Vir: Povzeto po I. Kononenko, Strojno učenje, 1997, str. 201.*

- **heteroasociativni pomnilnik:** gre za različico asociativnega pomnilnika s tem, da je ta sestavljen iz več podvzorcev. To pomeni, da če se na vходу predstavi eden ali več podvzorcev, se na izhodu predstavi celoten vzorec z vsemi podvzorcji;
- **časovni asociativni pomnilnik:** deluje po principu heteroasociativnega pomnilnika, s tem, da na vходу nastopi vzorec iz določenega časovnega intervala, na tej osnovi se na izhodu napove vzorec za naslednji časovni interval. Mreža iz danega položaja napove naslednjega;
- **klasifikacija:** pomeni razvrščanje vzorcev v razrede, ki temeljijo na posebni vrsti heteroasociativnega pomnilnika z določenim vходом (določajo število razredov) in izhodom nevronov. Pri učenju se vhodni vzorci razvrščajo v določene razrede, kar pomeni, da pri uporabi mreže, le-ta neznane oziroma pomanjkljive vhodne vzorce klasificira v opredeljene razrede;
- **grupiranje:** mreža vhodne vzorce samostojno razvršča v določeno število razredov, ki je lahko že prej določeno;
- **samoorganizacija in razvrščanje:** urejanje nevronov temelji na odgovarjanju posameznega nevrona na določeno vrednost vhodnega parametra, na primer frekvenco. S primerno topologijo nevronov je mogoče, da se le-ti sami uredijo tako, da sosednji ležeči nevroni odgovarjajo na podobne vhodne signale. Takšen primer je dvoplastna mreža, v kateri so izhodni nevroni še vedno povezani z bližnjimi, in sicer s pomočjo povratnih vezi. Bližje ležeči nevroni imajo vzbujevalne vezi, dalje ležeči pa zaviralne vezi.

**Nevronske mreže glede na topologijo/arhitekturo**, s pomočjo katerih označimo organiziranost nevronov in število nevronov v nevronske mreži, delimo na (Guid & Strnad, 2007, str. 220-223; Kononenko, 1997, str. 197-200):

- **enoplastne usmerjene nevronske mreže:** grajene so tako, da imajo samo eno plast nevronov, ki pa so hkrati vhodni in izhodni (slika 3). Njena značilnost je, da lahko rešuje samo linearne probleme v smislu polravnine;

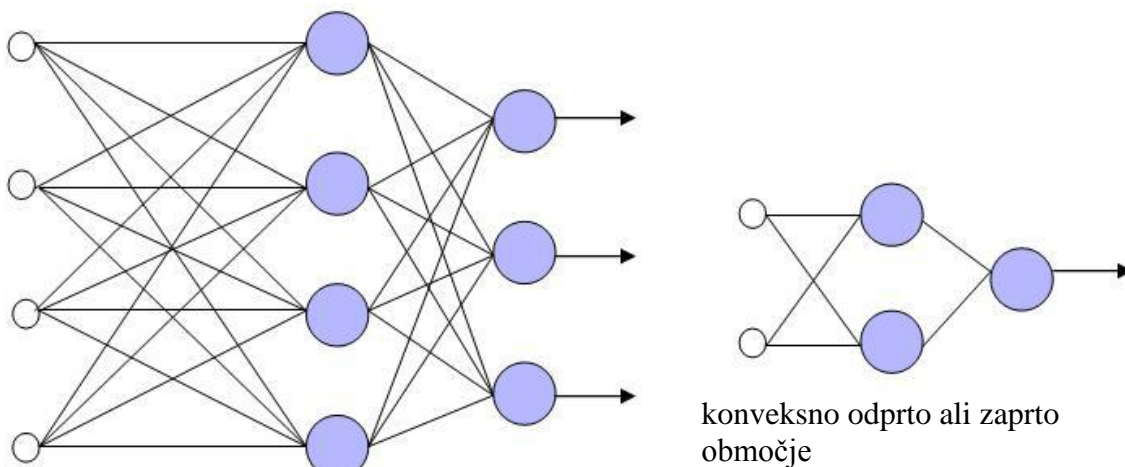
Slika 3: Enoplastna usmerjena nevronska mreža



Vir: Prirjeno po N. Guid & D. Strnad, *Umetna inteligenca*, 2007, str. 220-224; A. Dobnikar, *Nevronske mreže: teorija in aplikacije*, 1990, str. 45.

- **dvoplastne usmerjene nevronske mreže:** grajene so iz skupine vhodnih in izhodnih nevronov. Od enoplastne usmerjene nevronske mreže je razširjena za eno skrito plast nevronov (slika 4). Njena značilnost je, da lahko rešuje samo linearne probleme v smislu konveksno odprtih ali zaprtih področij;


Slika 4: Dvoplastna usmerjena nevronska mreža



Vir: Prirjeno po N. Guid & D. Strnad, *Umetna inteligenca*, 2007, str. 220-224; A. Dobnikar, *Nevronske mreže: teorija in aplikacije*, 1990, str. 45.

- **večplastne usmerjene nevrnske mreže:** grajene so enako kot dvoplastne usmerjene nevrnske mreže, le da se širijo z dodajanjem skritih plasti nevronov (slika 5). Njihova značilnost je, da so sposobne reševati nelinearne probleme v smislu poljubnih področij;


*Slika 5: Večplastne usmerjene nevrnske mreže*



*Vir: Prirejeno po N. Guid & D. Strnad, Umetna inteligenca, 2007, str. 220-224; A. Dobnikar, Nevronske mreže: teorija in aplikacije, 1990, str. 45.*

- **rekurzivne nevrnske mreže:** mreže so grajene iz ene plasti nevronov in nimajo skritih plasti, niti lastnega izhoda nevrna k sebi povezanega na vhod (slika 6). Njena značilnost je, da mora imeti vsaj eno povratno zanko;

*Slika 6: Rekurzivna nevrnska mreža*



*Vir: Prirejeno po A. Dobnikar, Nevronske mreže: teorija in aplikacije, 1990, str. 45.*

- **neplastne nevronske mreže:** so brez plasti in v splošnem delujejo na principu medsebojne povezanosti vseh nevronov v obeh smereh, kar pomeni, da je nevron hkrati voden in izhoden.

**Nevronske mreže glede na pravila in paradigme učenja:** učenje predstavlja proces, v katerem se prosti parametri nevronske mreže, zaradi določene spodbude iz okolja, prilagodijo. Način, kako se bodo parametri spreminjali, pa določa vrsta učenja oziroma pravila, ki zajemajo (Guid & Strnad, 2007, str. 223):

- **delta pravilo:** temelji na popravljanju napake s prizadevanjem minimuma le-te, s pomočjo metode padajočega gradienta;
- **Hebbovo pravilo:** temelji na nevrobiologiji;
- **tekmovalno pravilo:** prav tako temelji na nevrobiologiji;
- **Boltzmanovo pravilo:** temelji na idejah termodinamike in teorije informacij.

Obstajajo tudi paradigme učenja (Guid & Strnad, 2007, str. 223):

- **nadzorovano ali vodeno učenje,** ki ga nadzira učitelj;
- **nenadzorovano ali samoorganizirajoče učenje,** kjer ni potrebe po učitelju;
- **okrepitveno učenje,** s pomočjo katerega vsakemu učnemu vzorcu določimo številčno vrednost, ki obenem predstavlja vrednost funkcije obnašanja mreže.

### 1.2.1 Model nevrona

Tako kot živčna celica v bioloških možganih, je umetni nevron s pomočjo dendritov in aksonomov povezan z drugimi, umetnimi nevroni. Kot takšen je tudi najboljši približek biološkemu nevronu (Dobnikar, 1990).

Model umetnega nevrona je sestavljen iz treh osnovnih elementov: množice sinaps, seštevalnika in prenosne funkcije z izhodom. Množica sinaps oziroma povezav na vhodu, vsaka s svojo utežjo, ki jo označujemo z  $w_{kj}$ , je prvi osnovni element nevrona. Sinapse so označene s simbolom  $j$ , posamezen nevron v nevronske mreži pa s  $k$ . S simbolom  $x_j$  označujemo vhodne podatke, ki jih nato množimo z utežmi ( $w_{kj}x_j$ ). Sinaptična vez lahko zavira prenos signalov (negativen predznak) ali pa ga spodbuja (pozitiven predznak),  $+w_{kj}$  ali  $-w_{kj}$ .

Kot pravi Peruš (2001, str. 34) si lahko pri tem pomagamo s primerjavo človeka v družbi: »Človek tako kot nevron širi vpliv na druge, dokler ima za to podporo velikega števila ljudi. Vpliva z vrsto zaporednih akcij.« Vendar mora v primeru, ko nima več podpore, vsaj za nekaj časa potihniti. Od same narave odnosa pa je odvisno, kako tovrsten vpliv deluje na drugega človeka, lahko gre za vzpodbujevalno ali za zaviralno vez.



Seštevalnik je drugi osnovni element nevrona. V tem primeru gre za seštevanje vseh produktov vhodnih signalov in uteži  $w_{k1}x_1 + w_{k2}x_2 + \dots + w_{ks}x_s$ , katerih vsota se označuje s simbolom  $u_k$  in se imenuje aktivacija na izhodu seštevalnika. V tem primeru je vhod aktivacija, od katere se odšteje vrednost praga  $u_k - \theta_k$ . Slednji določa mejo proženja nevrona, ki se označi s simbolom  $\theta_k$ . Po določitvi meje je odvisno, kako se dobljene vrednosti praga in proženje nevrona obravnavajo ter katera prenosna funkcija bo uporabljena. Značilne izhodne vrednosti nevrona so v intervalu  $[0,1]$  ali intervalu  $[-1,1]$ , ki pa so lahko tudi binarni, torej ena ali nič (Guid & Strnad, 2007, str. 214-215; Peruš, 2001, str. 33-34).

**Matematični zapis nevrona** (Guid & Strnad, 2007, str. 213-215): model nevrona matematično zapišemo z dvema enačbama, od katerih prva (1) ponazarja prvi in drugi element nevrona, druga enačba (2) pa ponazarja tretji element, modela nevrona:

$$u_k = \sum_{j=1}^s w_{kj} x_j \quad (1)$$

k – indeks nevrona v nevronski mreži

s – število vseh vhodnih spremenljivk

$$y_k = \varphi(u_k - \theta_k) \quad (2)$$

Model nevrona je možno pripraviti matematično učinkovito s prenosom praga na vhod nevrona. Vendar je treba ob tem vhodne spremenljivke  $x_j$  razširiti za eno dodatno spremenljivko z vrednostjo minus ena  $x_0 = -1$ . Tudi uteži je treba razširiti za dodatno utež, ki mora biti enaka pragu  $w_{k0} = \theta_k$ . Enačbe (3), (4) in (5) ponazarjajo pripravo učinkovitosti modela nevrona s pomočjo dodajanja nove sinapse, ki je vstavljena na položaj z indeksom nič  $j=0$ .


$$v_k = u_k - \theta_k \quad (3)$$

$$v_k = \sum_{j=0}^s w_{kj} x_j \quad (4)$$

$$y_k = \varphi(u_k - \theta_k) \quad (5)$$

Treba je opredeliti tudi vrednost izhoda nevrona  $\gamma_k$  v zaprtem intervalu  $[0, 1]$  ali  $[-1, 1]$  glede na vrednost  $v_k$  po enačbi (4). V ta namen je treba vpeljati pravila in prenosne funkcije, ki bodo v teh intervalih tudi delovale. V modelu nevrona se uporabljajo prenosne funkcije za proženje nevrona oziroma za ustvarjanje izhodnega signala, kar je odvisno od vrste prenosne funkcije. V osnovi obstajajo tri tipične prenosne funkcije, ki so prikazane s slikami 7 (pragovna ali binarna), 8 (odsekoma linearna) in 9 (sigmoidna, ki se opredeljuje kot logistična funkcija, funkcija signum in funkcija hiperbolični tangens). V nadaljevanju bodo na kratko predstavljene njihove glavne značilnosti in enačbe.

Slika 7: Pragovna ali binarna prenosna funkcija




Vir: Prirejeno po N. Guid & D. Strnad, *Umetna inteligenca*, 2007, str. 213-215.

Značilnost pragovne ali binarne prenosne funkcije  $\varphi(v)$  je, da deluje po pravilu (6), če je vrednost  $v$  po enačbi (4) večja ali enaka nič, potem je izhod  $y$  ena, če je vrednost  $v$  manjša od nič, potem je izhod  $y$  nič. To pomeni, če je vrednost razlike med vrednostjo aktivacije in vrednostjo praga pozitivna ali enaka nič, potem je izhod 1, če je vrednost razlike negativna, potem je izhod 0.

$$\gamma = \varphi(v) = \varphi(u - \theta) = \begin{cases} 1, & \text{če je } v \geq 0 \\ 0, & \text{če je } v < 0 \end{cases} \quad (6)$$

Slika 8: Odsekoma linearna prenosna funkcija




Vir: Prirjeno po N. Guid & D. Strnad, Umetna inteligenca, 2007, str. 213-215.

Značilnost odsekoma linearne funkcije  $\varphi(v)$  je, da deluje po pravilu (7), če je vrednost  $v$  po enačbi (4) večja ali enaka od  $1/2$ , potem je izhod  $\gamma$  ena, če je vrednost  $v$  večja od  $-1/2$  in manjša od  $1/2$ , potem je izhod  $\gamma$  vrednost aktivacije  $v$ , če je vrednost  $v$  manjša od  $-1/2$ , potem je izhod  $\gamma$  nič.

$$\varphi(v) = \begin{cases} 1, & \text{če je } v \geq 1/2 \\ v, & \text{če je } -1/2 < v < 1/2 \\ 0, & \text{če je } v \leq -1/2 \end{cases} \quad (7)$$

Slika 9: Sigmoidna prenosna funkcija



Vir: Prirjeno po N. Guid & D. Strnad, Umetna inteligenca, 2007, str. 213-215.

Značilnost sigmoidne logistične funkcije  $\varphi(v)$  je, da deluje zvezno v zaprtem intervalu  $[0, 1]$  in je odvedljiva. V matematični obliki je predstavljena z enačbo (8), kjer simbol,  $a$  predstavlja parameter naklona krivulje. Vloga parametra naklona je, da naredi krivuljo bolj sploščeno (majhne vrednosti  $a$ ) ali strmo (večje vrednosti  $a$ ).

$$\varphi(v) = \sigma(v) = \frac{1}{1 + e^{-av}} \quad (8)$$

Značilnost sigmoidne funkcije signum  $\varphi(v)$  je, da deluje po pravilu (9), če je vrednost  $v$  po enačbi (4) večja od nič, potem je izhod  $y$  ena, če je vrednost  $v$  enaka nič, potem je izhod  $y$  nič in če je vrednost  $v$  manjša od nič, potem je izhod  $y$  minus ena.

$$\varphi(v) = \text{sgn}(v) \begin{cases} 1, & \text{če je } v > 0 \\ 0, & \text{če je } v = 0 \\ -1, & \text{če je } v < 0 \end{cases} \quad (9)$$

Značilnost sigmoidne funkcije hiperbolični tangens  $\varphi(v)$  je, da deluje zvezno v zaprtem intervalu  $[-1, 1]$ , ki je v bistvu modificirana logistična funkcija za razliko, da je v spodnjem intervalu razširjena do vrednosti minus ena, kar daje večji razpon izhodnih vrednosti. V matematični obliki je predstavljena z enačbo (10).

$$\varphi(v) = \tanh \frac{v}{2} = \frac{1 - e^{-v}}{1 + e^{-v}} \quad (10)$$

### 1.2.2 Usmerjena nevronska mreža (perceptron)

T. i. usmerjena nevronska mreža oziroma perceptron je dobila svoje poimenovanje že v šestdesetih letih, ob samem raziskovanju uporabe nevronske mreže glede smisla njenega zaznavanja. Tako so jo poimenovali njeni raziskovalci Rosenblatt, Minsky in Papert.

V splošnem lahko perceptron opredelimo kot nadgradnjo logične enote (angl. *threshold logic limit*), sposobne naučiti se in reševati nezahtevne ali pa težavnejše probleme. Zaradi različnega poimenovanja nevronskih mrež, je treba poudariti, da je lahko perceptron, glede na vsebino, binarna ali zvezna, eno ali večplastno usmerjena nevronska mreža. Perceptron lahko ima poljubno število plasti in nevronov po plasteh. Nevroni pa lahko imajo poljubne prenosne funkcije, čeprav se običajno izbere ena, ki potem velja za vse nevrone. Pogoj perceptrona je le, da so nevroni povezani enosmerno naprej iz ene plasti v drugo, čeprav ni nujno, da so vsi izhodi nevronov povezani z vsemi vhodi nevronov v naslednji plasti.

Binarni večplastni perceptroni se navadno uporabljajo za prepoznavanje in razvrstitev. To pomeni, da bomo ob uporabi binarnega dvoplastnega perceptrona z enim izhodnim binarnim nevronom dobili razvrstitev v le dva razreda. Razvrščanje v več razredov lahko dosežemo s povečanjem števila izhodnih binarnih nevronov. Uporabiti moramo enoznačno razvrščanje z le enim prižganim binarnim nevronom na izhodu, ali pa binarno kodiran izhod, kjer je prižgana kombinacija nevronov. Medtem, ko enoznačna razvrstitev potrebuje le toliko izhodnih linearnih nevronov, kot je razredov, pa binarno kodiranje za doseganje enakega števila razredov objektov razvrščanja zahteva manj izhodnih binarnih nevronov. Vendar tovrstna mreža ni primerna za napovedovanje z realnimi števili, saj je potrebno veliko število pretvarjanj (Zidar, 2009).

Zvezni večplastni perceptron je primeren za izdelavo napovedovalnih modelov, saj je z njim možno aproksimirati poljubno zvezno funkcijo. Prav tako lahko poljubno zvezno funkcijo aproksimiramo z dvoplastnim zveznim perceptronom s sigmoidnimi prenosnimi funkcijami v nevronih, v prvi plasti in eno linearno izhodno funkcijo v nevronu v drugi plasti. Kot pravi Potočnik (2007, str. 126):»Vsako funkcijo, ki se lahko poljubno dobro aproksimira z odsekoma linearnih funkcij [...], je mogoče uresničiti s troplastnim zveznim perceptronom, ki ima na izhodu v nevron linearno prenosno funkcijo.«


Za označevanje usmerjene nevronske mreže oziroma perceptrona uporabljamo enačbo, ki vsebuje informacije o številu vhodnih signalov v nevronske mreži, številu morebitnih skritih plasti v nevronske mreži, številu nevronov v posamezni skriti plasti in številu izhodnih plasti nevrona. Vhod označimo s simbolom  $s$ , skrite plasti s simbolom  $h$  in izhod s simbolom  $q$ . Primeri zapisov nevronske mreže so na ogled v tabeli 2.

*Tabela 2: Primeri zapisov usmerjenih nevronske mreže*

<b>FORMAT ZAPISA</b>	<b>PONAZORITEV NEVRONSKE MREŽE</b>
$s-q$	primer enoplastne usmerjene nevronske mreže
$s-h_1-q$	primer dvoplastne usmerjene nevronske mreže
$s-h_1-h_2-q$	primer troplastne usmerjene nevronske mreže
$s-h_1-h_2-...-q$	primer $n$ -plastne usmerjene nevronske mreže

*Vir: Prirejeno po N. Guid & D. Strnad, Umetna inteligenca, 2007, str. 211.*

Slika 10: Primer večplastnega perceptrona po označbi



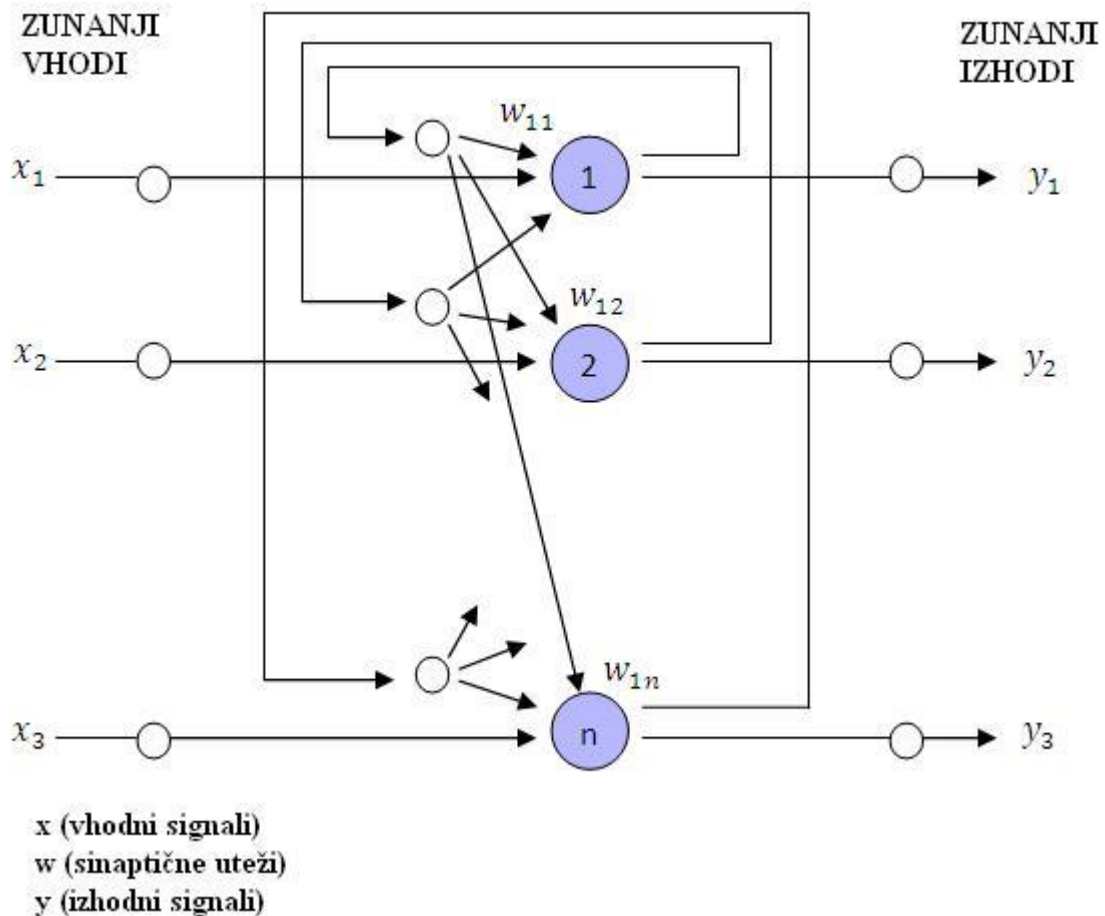
Vir: Prirejeno po N. Guid & D. Strnad, *Umetna inteligenca*, 2007, str. 221.

Z enačbo se lahko zapiše poljubna tipologija usmerjene nevronske mreže. Tako bi na primer označba 5-4-3-2 ( $s-h_1-h_2-q$ ), ki je slikovno ponazorjena s sliko 10, pomenila, da ima mreža pet vhodnih signalov, dve skriti plasti nevronov, v prvi štiri nevrone in v drugi tri ter da sta v izhodni plasti dva nevrona.

### 1.2.3 Hopfieldova nevronska mreža

Hopfieldova nevronska mreža ima samo en nivo, ki je povratno polno povezan. Kot prikazuje slika 11, so izhodi vsakega nevrona vezani na vhod vseh nevronov. Njena glavna značilnost je, da lahko shrani veliko število vzorcev kot množico stabilnih stanj. Mreža ob novem vzorcu, ki ga damo na vhod, konvergira k enemu od stabilnih stanj, ki je novemu vzorcu najbližje.

Slika 11: Hopfielddova nevrnska mreža



Vir: Prirejeno po D. Kokol, B. Š. Hleb, v. Podgorelec & M. Zorman, *Inteligentni sistemi*, 2001.

Ta vrsta nevrnske mreže lahko iz danes situacije napove prihodnjo situacijo, kar pomeni, da je pomembna predvsem na področjih, kjer so potrebna predvidevanja sprememb. Učenje Hopfielddove nevrnske mreže spada med pristope nadzorovanega učenja. Potrebno je nastavljanje uteži povezavam, ki pa jih nastavimo (vrednost uteži) le enkrat in se kasneje ne spreminjajo (Kokol, Hleb, Podgorelec & Zorman, 2001; Kononenko, 1997).

### 1.3 Nevronske mreže in napovedovanje

Uporaba nevrnske mreže v primeru napovedovanja je odvisna od uporabljene tehnike in pojava, ki ga želimo analizirati. Kako natančna bo napoved, je odvisno od vnosa potrebnih podatkov (od njihovega števila, naše potrebe po stopnji točnosti napovedi) ter od stroškov napovedovanja in časovnega obdobja. Prav tako moramo vedeti, kaj napovedujemo in kdo bo uporabnik napovedi (Hanke & Reitsch, 1995).

V takšnem primeru običajno uporabimo dvoplastno ali troplastno usmerjeno nevrnsko mrežo (perceptron), ki je zmožna reševati linearne in nelinearne probleme. Za prenosne

funkcije se običajno uporabijo zvezne sigmoidne funkcije, v izhodni plasti pa, zaradi neposredne napovedi, lahko uporabimo tudi linearne prenosne funkcije.

Izhodna plast je grajena iz enega ali več nevronov, kar je odvisno od namena napovedovanja. Za učenje se uporablja algoritem vzratnega razširjanja. Za optimizacijo učenja pa metoda prečnega vrednotenja. Vhodne podatke lahko transformiramo na interval  $[0,1]$  ali  $[-1,1]$ , odvisno od vrste prenosne funkcije, ni pa nujno. Enako velja za izhodne dejanske podatke in izhodne želene oziroma ciljne podatke. Popolnoma natančnega pravila oziroma postopka za učinkovito modeliranje napovedovalnega modela na osnovi nevronske mreže v literaturi ni zaslediti. Avtorji, katerih prispevke je mogoče najti, poudarjajo, da gre predvsem za izkušnje in neposredno eksperimentiranje ter teoretično poznavanje nevronskih mrež ne pa za konkretno reševanje nekega problema, kakor je na primer napovedovanje (Zidar, 2009).

## 1.4 Učenje nevronskih mrež

Za delovanje nevronske mreže najprej potrebujemo podatke, ki so v osnovi najprej učni in testni, oziroma podatke, s katerimi se nevronska mreža uči in približuje ustreznejšemu izhodu. Na podlagi vhodnih podatkov mreža postavi uteži na povezavah, le te pa se nato primerjajo s pragom nevrona. Na nadaljnji ravni je odločitev o postavitvi uteži odvisna od odločitve posameznega nevrona v prejšnjem nivoju. S pomočjo tega načina lahko pridobimo dokončne odločitve na izhodu, nato pa pridobljene rezultate primerjamo s tistimi, ki jih je predvidel učni model. Ob rešitvi, ki je znotraj določenega predvidevanja, mreža razporeditve uteži in pragov shrani kot ustrezne. Če le-te niso v področju, ki je še dovoljeno, se izvajanje ponavlja dokler se ne doseže želeni rezultat (Jamšek, 2000).

Večplastni perceptroni se učijo z algoritmom vzratnega razširjanja (angl. *back propagation*), ki temelji na učnem pravilu, učenju s popravljanjem napake oziroma učnem pravilu delta. Algoritem vzratnega razširjanja deluje v dveh korakih, prvega imenujemo prehod naprej, drugega pa prehod nazaj. Prehod naprej deluje tako, da se na vhodu večplastnega perceptrona vstavijo vhodni podatki  $(x_1 \dots x_s)$ , to je vhodni vektor  $x^T$ , ki se razširja od vhoda proti izhodu oziroma iz ene plasti v drugo. S tem dobimo množico stanj v mreži in dejansko stanje na izhodu mreže. Sledi korak, prehod nazaj, ki deluje tako, da se od dejanskega stanja izhoda odšteje želeni izhod mreže. Razlika oziroma napaka se razširja po pravilu delta v obratni smeri od izhoda proti vhodu, od plasti do plasti. Uteži se popravljajo na prehodu nazaj po vzorčnem ali paketnem načinu. Vzorčni način, ki je pogostejši v zaporedju, popravlja uteži po vsakem vhodnem vzorcu, paketni način pa popravlja uteži tako, da se najprej predstavijo vsi vzorci in šele nato popravijo uteži (Guid & Strnad, 2007).

Pravila, pomembna za delovanje umetnih nevronskih mrež, ki bodo v nadaljevanju na kratko opredeljena, zajemajo:



- Hebbovo pravilo;
- pravilo delta;
- pravilo vzvratnega razširjanja napake;
- Kohonenovo pravilo oziroma tekmovalno pravilo;
- pravilo protitočnega razširjanja.

#### 1.4.1 Hebbovo pravilo

Leta 1949 je Donald O. Hebb definiral pravilo, ki temelji na načelu delovanja možganov na ravni nevronov - Hebbovo pravilo (angl. *generalized Hebb rule*). Gre za spreminjanje povezav bioloških možganov med posameznimi nevroni po načelu med seboj aktivnih nevronov. Kot rezultat je predvideno pojačanje vezi med dvema aktivnima nevronoma. Danes je Hebbovo pravilo uporabno pri učenju v različnih oblikah nevronske mreže.

Hebbovo pravilo v splošnem govori o ojačitvi vezi med dvema nevronoma, v primeru, da sta oba hkrati aktivna ali pasivna. Tako si nevronska mreža zapomni povezanost med dejavnostjo dveh povezanih nevronov (Kononenko, 1997).

#### 1.4.2 Pravilo delta

Pravilo delta (angl. *delta rule*) je poimenovano po Minsky-u in Papert-u, ki sta ga leta 1969 definirala. Gre za primer omogočanja učenja v dvoslojni nevronske mreže. O njem smo sicer že nekaj zapisali, a opredelimo ga bolj podrobno:

Dvoslojna umetna nevronska mreža ima v prvem sloju vhodne nevrone, v drugem izhodne, vsi pa so medsebojno povezani. Preden mreža začne učenje, uteži izbere naključno, samo učenje pa deluje na podlagi znanih parov vhodnih in izhodnih vzorcev. Proces se izvaja s pridobitvijo vhodnega vzorca, z vhodnim nevronom, ob čemer se izračuna izhodna vrednost pri danem vhodu. Izračuna se tudi razlika med izhodno (angl. *outputs*) najavljeno in ciljno (angl. *targets*) pričakovano oziroma željeno vrednostjo na izhodu. Glede na razliko med izhodno in ciljno vrednostjo sledi zmanjšanje ali povečanje uteži povezav med vhodnimi in izhodnimi nevroni. S ponavljanjem prikazovanja znanih parov dosežemo, da se nevronska mreža nauči pravilno odgovarjati na vhode. Vendar dvoslojna nevronska mreža ne more reševati nelinearnih problemov. Že Minsky in Papert sta namreč utemeljila, da se algoritem približuje fiksni točki, katero se mora nevronska mreža naučiti le, če je funkcija linearna (Kononenko, 1997).

### 1.4.3 Posplošeno delta pravilo

Pravilo vzratnega razširjanja napake (angl. *back propagation of errors*) omogoča učenje umetne nevronske mreže, ki je sestavljena iz poljubno izbranega števila slojev. Leta 1986 ga je s pomočjo sodelavcev razvil David E. Rumelhart. Poznamo ga tudi pod imenovanjem posplošeno delta pravilo (angl. *generalized delta rule*). Osnovni princip slednjega je pravzaprav enak kot pri navadnem pravilu delta (predstavljeno v podpoglavju 1.4.2).

Na začetku učenja so uteži naključne, z dobljenim vhodnim vzorcem s pomočjo razširjanja pa nevronska mreža po slojih izračuna izhod do izhodnega sloja. V nadaljevanju je potreben izračun razlike med izhodno oziroma predvideno in ciljno oziroma predpostavljeno vrednostjo na izhodu. Uteži se med zadnjim in predzadnjim slojem spremenijo. Sledi ključni korak algoritma in sicer izračun vrednosti nevronov na predzadnjem sloju (izračun razlike med izhodnimi in ciljnim vrednostmi). Vse do vhodnega sloja nevronov se nadaljuje rekurzivno spreminjanje uteži.

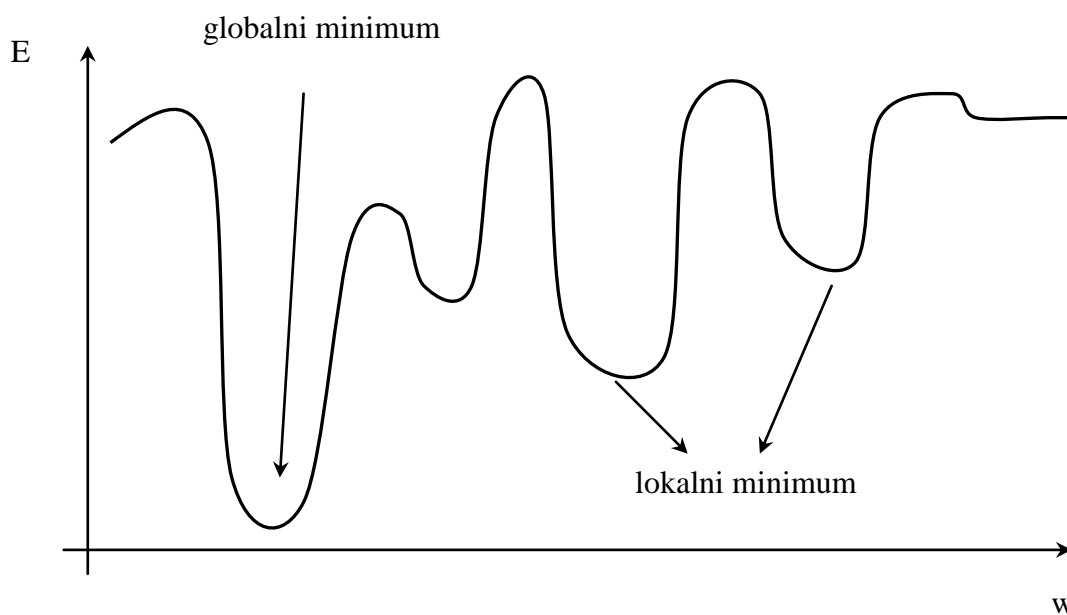
Omeniti je treba tudi slabosti tega pravila. Pogosto je namreč treba število skritih slojev in število nevronov v posameznem sloju določiti s pomočjo že pridobljenih izkustev. V tem primeru gre za dokaj zamuden proces učenja nevronske mreže, saj je za učinkovito iskanje minimuma napake potrebno veliko število prehodov preko niza učnih podatkov. Prav tako v splošnem za pravilo delta velja, da približek ni vedno možen. Obični namreč lahko v lokalnem minimumu in ne globalnem, saj algoritem funkcije napake ( $E$ ) v procesu učenja oziroma določevanja uteži  $w$  minimizira napako (slika 12). Reševanje te težave s stoddostno vrednostjo, ki bi zagotovila absolutni minimum napake, pa ne obstaja.

Kljub navedenemu pa obstajajo dobre raziskovalne metode za reševanje problemov, ki se z nizom približnih izidov približajo sprejemljivemu končnemu izidu (na primer z vodenim poskušanjem in odpravljanjem napak). To so hevristične metode, s pomočjo katerih lahko problem lokalnih minimumov nekoliko omilimo na naslednje načine (Kononenko, 1997, str. 232):

- Z dodajanjem trenutka pri preoblikovanju uteži, kjer pri vsaki trenutni spremembi v določeni meri upoštevamo tudi predhodno. Na podlagi tega učno pravilo pri manjših lokalnih optimumih ne odneha takoj, ampak obstaja še določen čas v smeri, ki je bila določena s preteklimi ponavljajočimi se spremembami. Obstaja možnost, da se lahko s tem izkoplje iz lokalnega minimuma.
- Z uporabo stohastičnega gradientnega pravila lahko problem rešimo tako, da se za vsak niz učnih podatkov uporabi drugačna ploskev funkcije. Pri tem se nasloni na njihovo povprečno vrednost in išče najnižjo. Ker so ploskve funkcij med seboj drugačne, imajo prav tako neenake lokalne minimume, kar zmanjša vrednost ustavitve procesa, v kateri od njih.

- Z možnostjo, da več posameznih nevronske mreže učimo s pomočjo uporabe enake množice učnih podatkov s tem, da inicializiramo uteži v umetni nevronske mreže z različnimi naključnimi vrednostmi. V primeru, da postopki učenja pri posamezni nevronske mreže vodijo do različnih minimumov, lahko izberemo tisto, ki ima najuspešnejše rezultate pri preizkusu na preizkusni množici.

Slika 12: Iskanje absolutnega minimuma funkcije napake  $E(w)$



Vir: Prirejeno po R. Morton v D. Šmigič, *Uporaba strojnega učenja pri analizi vrednostnih papirjev*, 2006, str. 21.

V sklopu preučevanja učenja nevronske mreže s pomočjo pravila vzratnega razširjanja napake smo zasledili preučevano modeliranje večslojnega perceptrona, ki ga v svoji raziskavi (*Forecasting whit artificial neural networks*) predstavlja Zhang (V Zhang, Patuwo & Hu, 1998, str. 35-62):

- **Število in vrsta vhodnih podatkov:** sta pomembna dejavnika s pomočjo katerih se modelu predstavi kompleksnost pojava. Raziskovalci si na tem področju niso enotni, nekateri namreč zagovarjajo večje število vhodnih podatkov, drugi manjše. Najpomembnejše je predvsem, da so vhodni podatki reprezentativni v zvezi s problemom modeliranja.
- **Način priprave in predstavitve podatkov modelu:** pred začetkom modeliranja je treba podatke, glede na potrebo, ustrezno pripraviti. V nadaljevanju se jim odvzame trendno gibanje, tako da se lahko model lažje uči generalizacije pojava. Predstavljeni podatki morajo zajemati vrednosti, ki jih sicer zajema aktivacijska funkcija. V primeru sigmoidne aktivacijske funkcije med 0 in 1, v primeru hiperboličnega tangensa med -1 in 1. Nekateri raziskovalci normalizirajo podatke v mejah od 0,2 do 0,8 oziroma -0,8

do 0,8, saj se na tak način izognejo ekstremnim vrednostim, ki jih aktivacijska funkcija zajema.

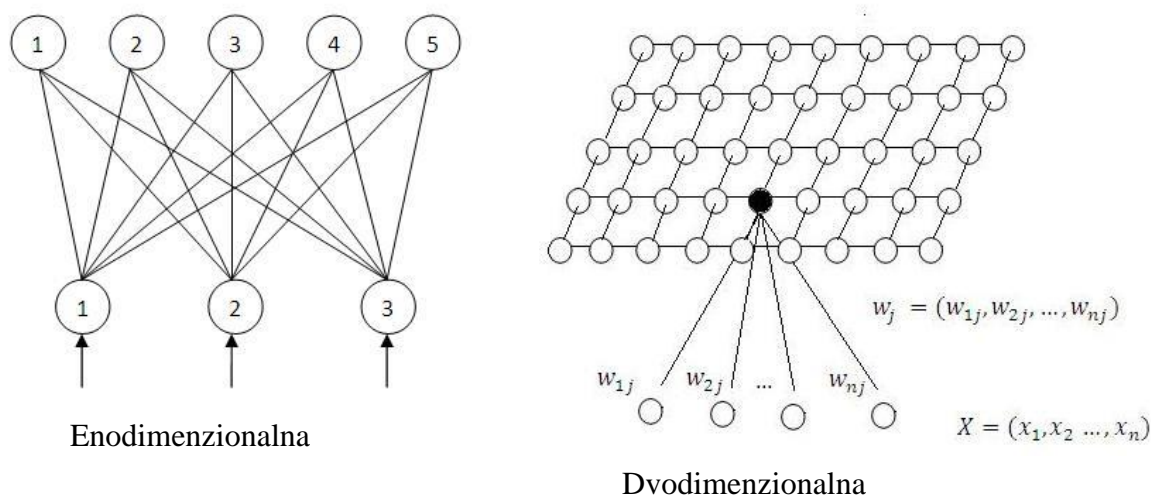
- **Arhitektura nevronske mreže (število skritih slojev in število nevronov v posameznem skitem sloju):** kljub kompleksnim metodam za določanje arhitekture, le-te ne zagotavljajo optimalne arhitekture. Kljub temu so na podlagi eksperimentiranja znana nekatera pravila. Tako naj bi bil za probleme napovedovanja zadosti en skrit sloj z majhnim številom nevronov. Večje število skritih slojev in večje število nevronov v skitem sloju namreč poveča čas učenja modela in poslabša sposobnost generalizacije. Za določanje števila nevronov z enim skitim slojem se pogosto uporablja formula  $2n+1$ ,  $2n$  ali  $n/2$ , kjer  $n$  pomeni število vhodnih podatkov. Določene raziskave so pokazale, da naj bi se nevronske mreže s številom nevronov v skitem sloju, enakemu številu vhodnih podatkov, zelo dobro izkazale.
- **Količina podatkov za učno, validacijsko in testno množico:** navadno se podatke, ki predstavljajo vhod v model razdeli na tri navedene množice, pri čemer moramo upoštevati količino in tip podatkov, ki jih imamo na razpolago, problemsko področje itd. Če nimamo težav s količino podatkov se najpogosteje uporablja razmerje, sedemdeset odstotkov učnih podatkov, dvajset odstotkov validacijskih podatkov in deset odstotkov testnih podatkov.
- **Vrsta aktivacijske funkcije:** kot pojasnjuje teorija bi lahko bila vsaka odvedljiva funkcija aktivacijska funkcija. Toda v večini primerov se je najbolje izkazala sigmoidna aktivacijska funkcija. Aktivacijske funkcije lahko uporabimo tudi v posameznih skritih slojih. Zhang (V Zhang, Patuwo & Hu, 1998, str. 47) predlaga uporabo hiperboličnega tangensa v skritih slojih in linearno aktivacijsko funkcijo v izhodnem sloju modela.
- **Vrsta funkcijske napake:** najbolj pogosta funkcija napake, ki jo v postopku učenja minimiziramo je vsota kvadratov napak. Programski paketi za delo z nevronskimi mrežami vključujejo še druge, kot na primer povprečno napako ali povprečno absolutno napako. Izbor funkcije napake je odvisen predvsem od ciljev modeliranja.
- **Število izhodnih podatkov:** pri napovedovanju in analizi časovnih vrst poznamo dve vrsti napovedovanja. Prvo zajema napovedovanje za eno obdobje naprej (angl. *one step ahead*), kjer imamo le en nevron na izhodnem sloju. Drugo pa napovedovanje za več obdobji vnaprej (angl. *multi step ahead*), kjer imamo več nevronov na izhodnem sloju. Načeloma je napovedovanje za eno obdobje naprej bolj natančno.
- **Število ciklov učenja modela:** cilj učenja nevronske mreže je doseči minimum funkcije napake. Toda pri vsakem novem učenju z enakimi vhodnimi podatki in nastavitvami modela bo konvergenca modela vselej različna. Razlog tiči v utežeh, ki so pred vsakim postopkom učenja naključno generirane. Zaradi tega je zeleno število ciklov učenja prepuščeno eksperimentiranju. Večje število ciklov učenja zahteva več časa, ni pa nujno, da bo konvergenca modela zato boljša.

#### 1.4.4 Kohonenovo pravilo oziroma tekmovalno pravilo

V primerjavi z biološkim nevronom se temu najbolj približa t.i. Kohonenova učna shema, ki je poimenovana po avtorju Teuvo Kohonenn-u in prikazana s primerom na sliki 13.

Temeljni nevronske mreže so postavljeni na enem sloju nevronov, organiziranih v dvodimenzionalno ravnino z dobro opredeljeno topologijo. Vsak posamezni nevron ima toliko uteži, kot je sestavin vhodnega vektorja. Sistem se organizira sam in je namenjen učenju, ki ga ni treba nadzorovati. Kohonenovo pravilo (angl. *Kohonen rule*) oziroma tekmovalno pravilo zapoveduje dejavnost le enega nevrona v skupini naenkrat, kar se lahko doseže s primerno topologijo povezanosti posameznega nevrona z drugimi, s pomočjo zaviralne vezi. Ob dejavnosti enega nevrona, z zaviralno vezjo le-ta zavre dejavnost preostalih nevronov. Navedeno pravilo tako opredeljuje učenje samo zmagovalnega nevrona, ki posledično poveča uteži vezem, ki so mu pomagale do "uspeha" (zaradi tega tudi poimenovanje tekmovalno pravilo) in zmanjša uteži preostalim vezem (Kohonen, 1996; Zupan, 1994).

Slika 13: Primer tipologij Kohonenovih nevronske mreže



Vir: Prirejeno po G. M. Rakočević, *Mašinsko učenje u bežičnim senzorskim mrežama*, 2014, str. 88.

#### 1.4.5 Pravilo protitočnega razširjanja

Pravilo protitočnega razširjanja podatkov oziroma vnos podatkov z nasprotne strani (angl. *counter propagation*) je podobno Kohonenovemu pravilu. Razlikujeta se le v dodatnem izhodnem sloju. Pravzaprav lahko govorimo o nadgradnji Kohonenovega pravila pri reševanju nadzorovanih problemov. Bistvena razlika med njima je v popravljanju uteži glede na ciljne vrednosti, namesto glede na vhodne vrednosti. Prav tako se osrednji nevron ne določi z razdaljo, ki je najbližje tarči, ampak glede na položaj centralnega nevrona v

Kohonenovem sloju. Izhodni sloj nevronov pa ima toliko slojev uteži, kolikor je podatkov v izhodnem vektorju.

Po zaključenem učenju so nevroni v Kohonenovem sloju razporejeni tako, da za vsak vhod določajo položaj v izhodnem sloju, v katerem je shranjen odgovor. Med samim učenjem se ciljne vrednosti razporedijo preko vseh nevronov izhodne plasti. Posledično odgovor vsebujejo vsi izhodni nevroni, čeprav med učenjem morda niso bili izbrani. S pomočjo tovrstne rešitve lahko tudi za vhodne podatke, ki jih med učenjem ne spoznamo, določimo ustrezne izhodne vrednosti (Zupan, 1994).

## 1.5 Prednosti in slabosti nevronske mreže

Kljub temu, da so tudi umetne nevronske mreže sposobne reševati probleme, pa na kratko, pri njih nimamo pojasnjevalnih rezultatov, ki bi jih prejeli. Prednosti in slabosti umetnih nevronske mreže je na obeh straneh kar nekaj. Sledi nekoliko podrobnejši pregled teh informacij.

Prednosti umetne nevronske mreže se odražajo skozi (Kononenko, 1997):

- **Biološko podobnost:** nevronska mreža poskuša oponašati človeške možgane in želi doseči boljše rezultate pri reševanju težavnejših problemov.
- **Visoko stopnjo vzporednosti:** vsak nevron pravzaprav deluje dokaj neodvisno od drugih nevronov, zaradi česar je mogoče prilagajanje v zapletenem okolju v ustreznem času.
- **Večsmerno izvedbo:** vsak nevron je povezan z drugim in je tako obenem voden in izhoden.
- **Trdnost:** tudi ob okvari določenih nevronov in sinaps ne moremo nobenega podatka izgubiti v celoti. Točnost pada v sorazmerju s številom uničenih nevronov. Tudi ob pomanjkljivih vhodnih podatkih se manjkajoči podatki aproksimirajo z razpoložljivimi vhodnimi podatki in s pomočjo naučenega znanja. To pomeni odpornost proti napakam v podatkih ali v primeru pomanjkljivih podatkov, saj je lahko napoved ob pravilnem učenju kljub temu pravilna.
- **Učenje:** ki poteka s pomočjo nenačrtovanega spreminjanja uteži na sinapsah. Ko je nevronska mreža enkrat naučena, lahko vsak nevron napove stanje svoje odvisnosti z drugimi povezanimi nevroni.
- **Relacijo med strojno in programsko opremo:** mreža pravzaprav nima klasične programske opreme. Algoritem, po katerem deluje, je namreč posamezen nevron, preostalo delovanje je nenačrtovano.
- **Matematično podlago:** delovanje je nenačrtovano.

Slabosti umetne nevronske mreže pa se kažejo predvsem v tem, da:

Učenje nevronskih mrež je lahko uspešno le ob večjem številu kakovostnih vhodnih podatkov. Več jih je, bolj kakovostna bo naša rešitev. Obenem moramo pogosto poiskati optimalno nevronske mreže, saj je njeno učenje lahko zelo dolgotrajen proces.

Vendar točno določenih načel za nastavitve parametrov, ki bi pomagali pri optimalnem modeliranju nevronskega modela ni. Vse temelji na naši iznajdljivosti ter naših izkušnjah pri delu z nevronskimi mrežami. Zaradi tega se pri gradientnih učnih algoritmov pojavlja tudi problem lokalnih minimumov.

Navadno dobimo nejasne rešitve oziroma takšne, da je nemogoče ugotoviti, kakšne so njihove zakonitosti oziroma s čim lahko privedejo sistem do pravilnega delovanja. Iz tega sledi, da jih mnogokrat primerjajo s črno skrinjico, podatki vstopajo na eni strani, izstopajo na drugi, medtem ko o notranjih mehanizmih ne vemo ničesar. Ker mora biti namen določen vnaprej, so priporočljive predvsem v primeru, ko želimo le model, ki bo deloval pravilno, vendar ni treba vedeti, kako delujejo mehanizmi. V primeru, ko želimo postopke preučiti in ugotoviti, kakšna so njihova pravila, pa so nevronske mreže za nas neustrezen pripomoček.

Težave se lahko pojavijo tudi glede pretiranosti. Procesno učenje pomeni čim ustrežnejšo prilagoditev učnim podatkom. S spreminjanjem uteži v nevronske mreže skušamo delovanje modela pripeljati tako daleč, da ima čim manj napak. Naš cilj je torej izdelava modela, ki ne deluje le na učnih podatkih, ampak je uspešen tudi drugih podatkih, kar lahko dosežemo le, če v postopkih učenja nenehno izvajamo postopke testiranja. Vendar testni podatki ne smejo biti enaki učnim podatkom. Obenem se nam lahko zgodi, da se napake na učnih in testnih podatkih ne bodo zmanjševale enako hitro. Medtem ko se lahko pri testnih podatkih napaka povečuje, se lahko na učnih zmanjšuje. V tem primeru pride do t.i. pretreniranosti, predolg postopek učenja ima za posledico posplošitev podatkov, izgubo sposobnosti učenja mreže ter pričetek procesa memoriranja učnih podatkov, zaradi česar je učenje treba ustaviti. Napako nad učnimi podatki bi sicer lahko zmanjšali s povečanjem števila nevronov, toda s tem bi izgubili zmožnost posploševanja (Hafner, 1999).

## **2 NEVRONSKE MREŽE NA PODROČJU MANAGEMENTA**

Glede na to, da nevronske mreže posnemajo delovanje bioloških možganov, so sposobne reševanja različnih problemov. Slednje pa jim omogoča delovanje na različnih področjih, med katerimi je tudi področje trženja, ekonomija in seveda management.

Management danes opredeljuje področje, ki zajema predvsem načrtovanje, organiziranje, vodenje in nadziranje nalog oziroma dejavnosti, ki jih opravljajo zaposleni v podjetju, da bi se dosegli vnaprej postavljeni cilji, poslanstvo in razvoj. Kot pravi Možina (V Možina,

Jaklič, Kovač, Ivanko & Šek-Mertük, 2006, str. 137) gre za proces spoznavanja in analiziranja težav, za ugotavljanje vzrokov, opredeljevanje in izbiro alternativnih rešitev, načrtovanje izvedbe ter spremljanje in ugotavljanje doseženega. V postopku urejanja posameznih dejavnosti management uporablja posamezna orodja, ki so že razvita ali pa glede na potrebe oblikuje nova. Nevronske mreže spadajo med novitete, ki si utirajo pot na tem področju.

## **2.1 Inovacijski management**

Inovacijski management se ukvarja z inovacijami, hitrimi reakcijami na okolje, soočanjem z nesoglasji ter strateško naravnanimi procesi koordiniranja, vodenja in izvajanja inovacijskih projektov, temelječ na medsebojni komunikaciji in uspešnem usklajevanju.

Kos (1999) ugotavlja, da pri inovacijskem managementu izstopa osredotočenost na poslovanje ter organizacijska povezanost, ki vključuje notranje povezovanje ter občasno notranje in zunanje prenavljanje procesov, tehnologije, kulture podjetja in kadra. Ob tem ne smemo pozabiti omeniti celovitosti in predvidevanja vseh stopenj določenega inovacijskega projekta in procesov, ki ga spremljajo. Pomembni dejavniki zajemajo še področje dinamike in sprememb v podjetju, ki se nanašajo na izogibanje stagnaciji ter pripravljenost na hitre spremembe in podjetniško kulturo.

V svojih opredelitvah inovacijski management razdeli na dve vrsti, in sicer na (Kos, 1999, str. 111):

- Inovacijski management, usmerjen v rezultat in temelji na strategijah posnemanja inovacij drugih podjetij. Sredstva pridobiva s pomočjo tržnih raziskav, podjetniških analiz, iskanja patentov in analize konkurence. Hitre reakcije in odločitve pa zahtevajo prosto razpoložljiv kapital.
- Inovacijski management, usmerjen v delovanje in temelji na strategiji lastnega inoviranja v podjetje. Navadno lahko hkrati vodi tudi več inovacijskih projektov, za strokovno mnenje pa so zadolženi zunanji strokovnjaki in agencije.

Dobnikar (2006, str. 25-26) meni, da inovacijski management oziroma inovacija, z določenim tveganjem, pripomore k zavzetju določenega trga ter obenem prinese dobiček in omogoči ponovno vlaganje v rast in razvoj. Prav tako omogoča prisotnost na novih trgih ter možnost prodaje novim uporabnikom. Toda zgolj prodor podjetja še ne omogoča ohranitev konkurenčnosti. Pozornost je s pomočjo spremljanja dogajanja in sprememb v okolju, nadziranju značilnosti okolja in izvajanju sprememb, potrebno nameniti odjemalcem, konkurentom ter navsezadnje spremembam.



### 2.1.1 Inovacija in invencija

Na prvi pogled se nam pojma inovacija in invencija morda zdita precej podobna. Pogosto jo poimenujemo s skupnim izrazom inovacija, toda invencija je nekaj, kar šele ima potencial, da postane inovacija. V tabeli 3 so za preprostejše razumevanje navedene opredelitve posameznega pojma (Mulej v Vadnjal, 2009):

Tabela 3: Faze posameznih novosti

FAZE NOVOSTI	KOMENTAR
<b>IDEJA</b>	Izkušnje, znanje in razmišljanje privedejo do ideje, ki pa je v osnovi le še zamisel, ki še ne more rešiti problema. Prav tako na podlagi le-te še ne vemo ali je ustrezna za rešitev.
<b>INVENCIJA</b>	Nova obetavna zamisel, ustvarjena s pomočjo raziskovanja, ki je morebiti vredna zaščite.
<b>INOVACIJA S POTENCIALOM</b>	V tem primeru gre za uporabno invencijo, ki pa še ni koristna. Do nje pridemo z podobnimi postopki, kot do pri sami osnovni invenciji.
<b>INOVACIJA</b>	Gre za koristno n uporabno novo zamisel, ki jo navadno imenujemo tudi podjetniška ideja. Kaj točno je inovacija pa bodo določili njeni uporabniki.

*Vir: Prirejeno po Mulej, 2000 v Vadnjal, Invencija, inovacija, potencial inovacij, nič od naštetega?, b.l.*

**Inovacijo** posamezni avtorji različno opredeljujejo, čeprav gre pogosto za medsebojno podobne razlage. Dobre (2004) meni, da beseda izhaja iz latinske besede *inovatio*, kar pomeni novost oziroma spreminjanje obstoječega.

Kot smo prikazali že v tabeli končna inovacija izhaja iz invencije, ki je pokazala potencial. Njena uporabnost in obstoj se pokaže s sprejetjem odjemalcev in kupovanjem, ki avtorju, izdelovalcu in prodajalcu prinese zaslužek, menita Mulej in Ženko (2002). Medtem, ko je Krošlin (2004) prepričan, da inovacija ni zgolj pomembna novo razvita novost, nova tehnološka novost, nov izdelek ali storitev, temveč katera koli novost ali izboljšava, ki je sprejeta kot koristna. Torej gre pravzaprav za nov oziroma izboljšan izdelek/proces/storitev, ki jo trg in odjemalci sprejmejo, obenem pa prinaša korist tako odjemalcu kot ponudniku.

Mulej et al. (2008, str. 123) loči inovacije glede na tri merila, kot je prikazano s tabelo 4:

Tabela 4: Vrste inovacij glede na tri merila

MERILO	VRSTA	KOMENTAR
<b>GLEDE NA VSEBINO</b>	programske	uspešen nov predmet poslovanja
	tehnično-tehnološke	uspešne nove lastnosti izdelkov, storitev in postopkov izdelave
	organizacijske	uspešne nove organizacijske oblike dela in sodelovanja
	upravljaljske	uspešni novi slogi vodenja, ki sproščajo, spodbujajo in aktivirajo več ustvarjalnosti
	metodijske	uspešne nove metode vodenja in sodelovanja
<b>GLEDE NA POSLEDICE</b>	korenite	dejansko po Schumpetru <sup>2</sup> spremenijo svet
	drobne	manjše izboljšave, ki jih uporabniki zaznajo ali pa ne
<b>PO SLUŽBENIH DOLŽNOSTIH</b>	znotraj redne službe	Inoviranje - raziskave in razvoj so naloga posameznika oziroma skupine v podjetju, na fakultetah, inštitutih itd.
	zunaj redne službe	najpogosteje kot ljubiteljska dejavnost določenih posameznikov

Vir: Povzeto po Mulej et al., *Invencijsko-inovacijski management z uporabo dialektične teorije sistemov*, 2008, str. 123.

Navedene inovacije niso edine, razlag in podrobnosti o merilih in vrstah je še veliko, toda vse vključujejo enake oziroma vsaj podobne pogoje za njeno vzpostavitev, ki zajemajo predvsem naslednje faktorje (Mulej et al., 2008, str. 22):

- **Invencijo:** (podrobneje je opredeljena v naslednjem poglavju, 2.1.2).
- **Podjetnost in podjetništvo:** podjetnost je lastnost človeka, ki se trudi inovativno preoblikovati invencije v inovacije s pomočjo presoje, predvidevanjem tveganja in pogumom. Podjetništvo pa zajema pravno (lastništvo podjetja) ali ekonomsko (življenje od inoviranja z razumnim tveganjem) vsebino.
- **Celovitost:** pogoj s pomočjo katerega izpolnjujemo vse pomembne vsebine, sestavine in povezave v procesu oblikovanja/ustvarjanja invencij oziroma njihovega spreminjanja v inovacije.

<sup>2</sup> Joseph A. Schumpeter je bil avstrijski evolucijski ekonomist, ki je inovacijo opredelil, kot izvajanje nove kombinacije produkcijskih faktorjev in med drugim kot prvo uporabo invencije v gospodarske namene (Blas, 2002).

- **Vodenje:** v tem primeru gre za celotno in dobičkonosno izrabo zmogljivosti, ki jih lahko ustvari podjetnost iz posamezne invencije.
- **Sodelavce:** gre za tehten dejavnik, saj podjetnik oziroma vodja vsega ne zmore ustvariti in urediti sam, zato potrebuje kakovostne sodelavce.
- **Kulturo:** ustvarja merila o tem o tem, kaj je prav in kaj ne. V inovacijskih družbah kultura spodbuja inovativnost.
- **Dobavitelje:** ustvarjajo vhodne vplive na vse procese.
- **Odjemalce:** to so tisti, ki morajo sprejeti novosti, da sploh lahko govorimo o inovacijah.
- **Konkurenti:** spodbujajo tržni oziroma zunanji pritisk na podjetja, da se le-ta nenehno trudijo z inovacijami.
- **Družbeno okolje:** zajema vplive, ki jih določajo posamezniki ali organizacija ter razmere, ki jih prav tako posamezniki ali organizacija doživljajo, čeprav nanje neposredno ne gre vplivati.
- **Naravno okolje:** se prav tako šteje med zunanje vplive in pogoje, na katere prav tako ni mogoče vplivati.
- **Naključne dogodke oziroma srečo:** z eno besedo gre za naključja, saj moramo tudi pri najboljšem informiranju in odločanju (četudi je podprto z različnimi metodami) o inovacijah in njihovem uspehu pravzaprav uganjevati.

**Invencija:** beseda invencija naj bi izvirala iz latinske besede *inventio*, kar opredeljuje iznajdbo, odkritje nečesa novega oziroma sposobnost odkriti nekaj novega. Dobro (2004, str. 24) meni, da ta pojem združuje domišljijo, iznajdljivost, izumiteljski dar in kreativnost. Devetak (2000, str. 365) invencijo opredeljuje kot posledico pojava novih idej pri opravljanju določenih aktivnosti. Po njegovem mnenju gre za postopek, kjer poteka razvoj novih znanj s pomočjo opazovanja in razmišljanja. Likar (2001, str. 17) je mnenja, da invencija kaže na zmožnost odkrivanja novih vidikov ali odnosov med stvarmi, pojavi ali pojmi. Medtem, ko Mulej in Ženko (2004, str. 8) menita, da invencija pomeni vsako novo zamisel ali domislek, ki kaj obeta in bi v prihodnosti predstavljal korist za odjemalca in avtorja. Za Pretnarja (1995, str. 79) pa je invencija vsakršno spoznanje, rešitev, zamisel ali dosežek.

Omeniti je treba, da kljub podrobnemu preučevanju invencije, raziskave kažejo, da je prehodov iz invencije do inovacije pravzaprav malo. Če to poskušamo pretvoriti v številke, to pomeni, da je od sto idej selekcioniranih le okoli četrtnina, v fazo razvoja jih nato pride okrog petnajst, od tega se jih osem začne uvajati na trgu, a le približno dve na koncu tudi uspeša. Zato je že v sami fazi izbora invencije pomembno, da smo določili kakovostna merila, ki nam bodo v pomoč pri izbiri invencij, ki res nekaj obetajo.

Temelj vsakega predloga, nove zamisli ali zgolj izboljšave je poslovni načrt s finančnim predračunom oziroma ocena pričakovanih stroškov in dohodkov. V poslovnem načrtu je tako nujno predvideti stroške, ki jih bomo imeli z določenim projektom oziroma naložbo.

Seveda pa mora biti vsak projekt ekonomsko upravičljiv že v osnovi, kar pomeni, da podjetju omogoča presežek prihodkov nad odhodki. Za samo ovrednotenje podjetje potrebuje kakovostne informacije. Poleg tega je treba upoštevati tudi tiste elemente, ki jih ni mogoče finančno ovrednotiti. Pomemben je kakovosten kader, saj je v nasprotnem primeru še tako dobra ideja brez prihodnosti (Likar et al., 2002).

Mulej (2007, str. 117) navaja nekaj različic smiselnosti, ki bi jih mogla nuditi invencija. Predstavljene so v tabeli 5:

*Tabela 5: Inačice smiselnosti invencije*

UPORABA	PRIMER	MOŽNI VPLIVI
Boljša rešitev za star problem	Radialne avtomobilске gume z jeklenimi trakovi	Okrepitev dane tržišne sposobnosti
Boljša rešitev za star problem in hkrati za nove	Osebni računalnik, ki je nadomestil pisalni stroj in razrešil še druge probleme	Uničenje dane tržišne sposobnosti
Rešitev, a le za nov problem	Pogoni osempalčnega diska, ki so rešili sekundarni spomin miniračunalnika	Uničenje dane tržišne sposobnosti

*Vir: Povzeto po M. Mulej, Inovacije navad države in manjših podjetji z invencijami iz raziskovalnih organizacij, 2007, str. 117.*

Če želimo ugotoviti, katera izmed zgornjih verzij pride v poštev v določenem primeru, potrebujemo določene informacije. Najprej moramo informacije poiskati, nato jih moramo pokazati v obliki podatkov, ki povedo vse bistveno v skladu z informacijskimi potrebami ter jim nazadnje določiti ceno. Vse dileme prinesejo odločanje, od prevladujočega mnenja managerjev pa je odvisno upoštevanje pridobljenih podatkov pri: preučevanju konkurentov, dobaviteljev in odjemalcev ter z njimi povezanih dejavnosti; smernic in hitrosti razvoja tehnike in tehnologije, ki jo uporabljamo; preučevanju kadra, strukture, invencijsko-inovacijske politike, strategije, taktike in operative podjetja (Mulej, 2007).

### **2.1.2 Uvajanje inovacijskega poslovanja**

Glede na tesno povezanost invencije in inovacije v poslovanju lahko govorimo o invencijsko-inovacijskem managementu, ki je pravzaprav kompleksen proces. Ta je opredeljen kot "ustvarjalec" invencij, novih ali izboljšanih in morebitno obetavnih zamisli. Kot management inoviranja temelji na procesu spreminjanja invencij v koristne za odjemalce oz. avtorje, kot management inovacij pa proces, v katerem je že ustvarjena inovacija, ki se širi med ljudmi (Mulej & Ženko, 2002).

V današnjem času je inovacijsko poslovanje oz. inovacijski management že nujnost. Seveda ni treba, da je inovativnost glavni razlog podjetja, vendar mora politika podjetja ustvarjati miselnost o načrtovanju inovativnosti, ki spodbuja željo po spremembah in iskanju priložnosti.

V procesu invencijsko-inovacijskega managementa oziroma procesa znotraj podjetja so potrebni naslednji ključni procesi (Mulej et al., 2008, str. 11):

- usposabljanje, namenjeno strokovnosti in ustvarjalnosti, ki vključuje ustvarjalno sodelovanje;
- poslanstvo, ki temelji na nadpovprečnem doseganju sistemskih kakovosti celotnega poslovanja, ki ne zajema samo izdelkov;
- strategija kakovosti, ki ustreza standardu ISO 9000<sup>3</sup> (danes je v uporabi nadgradnja ISO 9001:2008<sup>4</sup>) in evropski nagradi za kakovost;
- taktika spodbujanja ustvarjanja invencij in potencialnih inovacij, ki lahko postanejo inovacije, tako pri posameznikih kot tudi znotraj delovnih skupin;
- spremljanje in posredovanje, ki se nanaša na vodstvo, ki spremlja, ocenjuje, koordinira in usmerja invencijsko – inovacijske dejavnosti;
- nagrajevanje, tako finančno kot nefinančno.

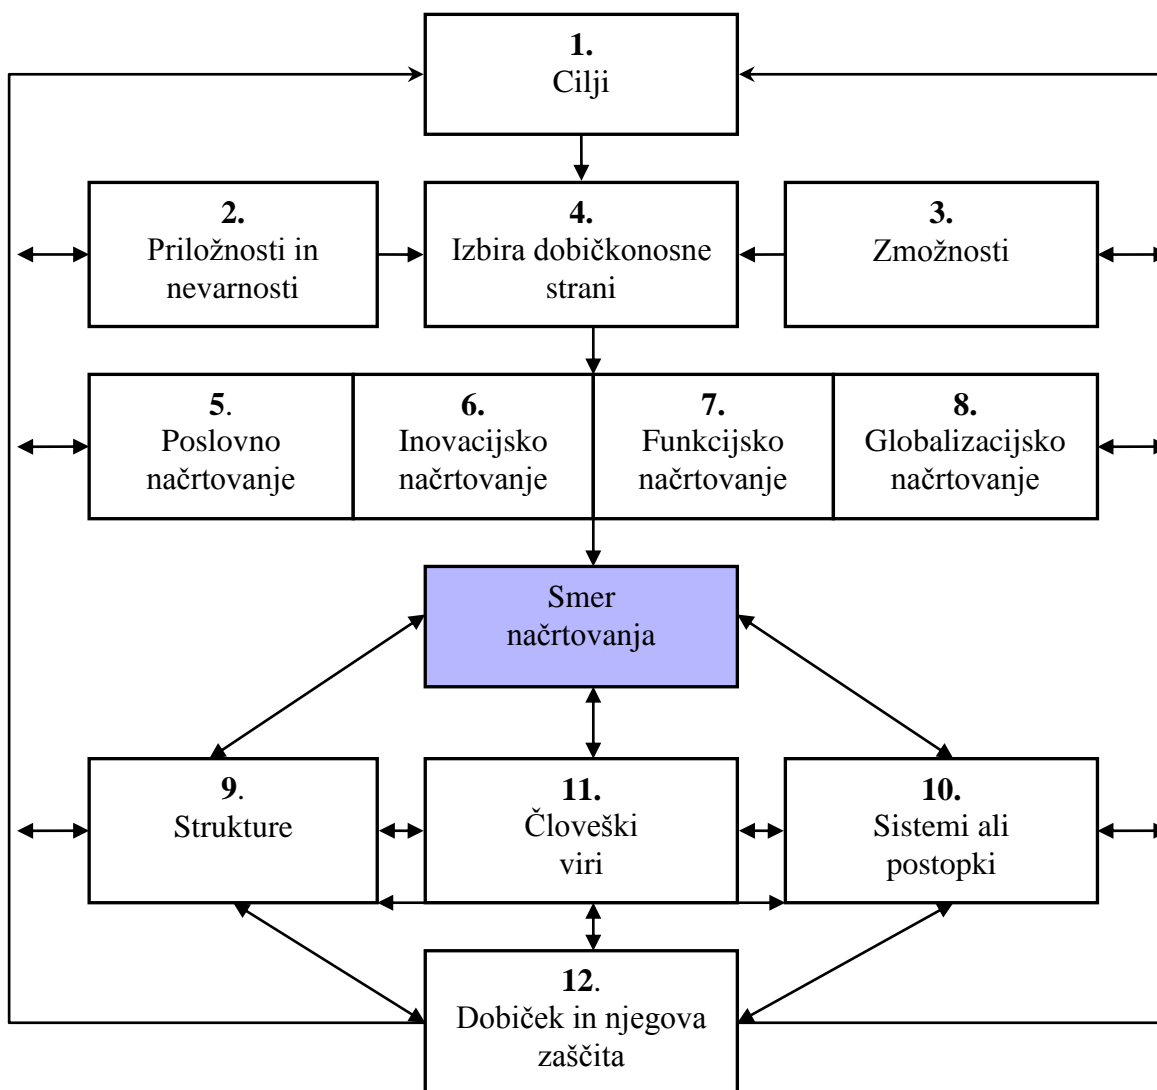
Uvedba inovacijskega poslovanja je zapleten proces, saj ni dovolj, da ima podjetje zastavljen načrt in cilje. Nujna je tudi strategija, ki zajema preučevanje okolja, možnosti za invencije ter ugotovitve za priložnosti in morebitne nevarnosti. Podroben inovacijski proces je podal Afuah (1998, str. 336). Poimenoval ga je strateški inovacijski proces, predstavljen je s sliko 14. Povzel je tudi korake, ki naj bi bili vključeni v oblikovanju strategije in so predstavljeni v nadaljevanju.

---

<sup>3</sup> Serija standardov EN ISO 9000 je rezultat temeljitega posvetovanja z uporabniki, ki so pripomogli k njegovi preprostejši uporabi in prožnejšemu privzemanju. Posvetovanja so prav tako pripomogla k bolj jasni in dostopni obliki novih standardov. Standard zajema naslednje glavne dele: sistem vodenja kakovosti, odgovornost vodstva, vodenje virov, izvedba proizvoda ter merjenje, analize in izboljševanje (SIST, 2014).

<sup>4</sup> Standard ISO 9001 je bil že večkrat prenovljen. V uporabi je ISO 9001:2008, obnovljen leta 2008, letos (2015) pa prihaja peta izdaja.

Slika 14: Strateški inovacijski proces



Vir: Prirejeno po A. Afuah, *Innovation management: Strategies, Implementation and Profits*, 1998, str. 336.

Koraki za oblikovanje strategij (Afuah, 1998, str. 335):

- V primeru poslovnega načrtovanja podjetje odloči, ali bo proizvod inovacijskega procesa nizko stroškovni, diferencialni ali oboje.
- V primeru inovacijskega načrtovanja podjetje določi, ali bo prvo dalo inovacijo na trg ali bo sledilo konkurenci, kar pomeni, da bo na trg dalo izboljššan obstoječ izdelek.
- V primeru funkcijskega načrtovanja (pri oblikovanju katere sta v pomoč poslovna in inovacijska strategija) gre za odobritev virov, dajanje pravic do uporabe ter nabavo in razporeditev sredstev.
- V primeru globalizacijskega načrtovanja pa gre za predvidevanje direktiv, ki določajo razpoložljivost zalog pri inovaciji in njeno uvajanje na trg.

Pred vpeljavo moramo najprej preveriti, ali gre za rastoč trg, ali je dovolj povpraševanja po izbrani inovaciji ter kakšna je donosnost za podjetje (ta mora biti takšna, da opravičuje naložbo in razvoj inovacije). Pomembno je, da predvidimo tveganja, ki se odražajo predvsem preko zaloge sredstev, nejasnega dostopa do nekaterih virov, zagotovitve ustrezne in sposobne delovne sile, dostopa do tržnih poti, nepričakovano konkurenco, poslabšanje tržnih pogojev in tehnološko okolje, ki je bolj zahtevno od pričakovanega. Ravno zaradi tega so še zlasti pomembni naslednji dejavniki: notranji (kadrovska organizacija), zunanji (svetovalci, okoliščine trga in dobavitelji) ter notranji dejavniki, ki so usmerjeni navzven (marketing in strategije trženja).

Dober inovacijski management razume potrebe uporabnika, ima odlično znanje o trgih delovanja, se posveča tržnim in prodajnim strategijam, učinkovito izvaja razvoj, aktivno uporablja tehnologije in nasvete ter skrbi za multidisciplinarnost in prilagodljivost. Sestavljen mora biti iz ključnih, vodilnih in sposobnih posameznikov, ki so ob dobrem načrtu in usklajevanju procesa novega proizvoda pozorni tudi na pravočasen vstop na trg. Kombinacija notranjih in zunanjih dejavnikov poteka s strani strokovnjakov trženja, ki poskrbijo za posamezne značilnosti izdelka. Tisti, ki so zadolženi za proizvodnjo in dobavo izdelka, pa naj bi poskrbeli za značilnosti samega procesa (Dobnikar, 2006; Kos, 1999).

Ko podjetje pridobi novo inovacijo se prične delo, ki obsega vlogo inovacije na trgu. Podjetje oziroma management, zadolžen za trženje inovacije, se lahko vživi v vlogo kupca, lahko pa na testni skupini potencialnih potrošnikov opravi raziskavo ter inovacijo predstavi kot enkraten in kakovosten proizvod, ki ima dobro tehnično in strateško podporo in je uspešen na trgu. Prav tako lahko inovacijo preizkusimo z ugotavljanjem željenih in morebitnih neželjenih lastnosti inovacije preden se pojavi na trgu. Inovacija mora biti čim bolj ustrezna za kupca, saj ima le tako pravo možnost za prodajo in uspeh na trgu. Svojo vlogo ob tem opravijo tudi distributerji, ki imajo neposreden stik s kupci in dogajanjem na trgu. Z nasveti so lahko v pomoč pri izpopolnjevanju produkta, izdelavi le-tega ali drugih neposrednih dejavnikov. S svojimi znanji in izkušnjami lahko pomagajo tudi neposredni tržni partnerji, ki poznajo trg in tržne razmere. Imajo namreč posebna znanja o tehnologiji in njeni difuziji na trgu. Proces odločanja in izvajanja je zanje rutinsko opravilo, za podjetje pa mnogokrat zapleten in kompleksen proces.

Zgodi se lahko, da pride do problemov zaradi pomanjkanja strokovnega znanja o vpeljevanju nove inovacije, težav pri doseganju zastavljenega cilja, nezaupanju in dvomih ali nezmožnosti objektivne presoje. V tem primeru potrebujemo zunanjega svetovalca, ki ima nevtraln in objektivno presojo in poskuša odpraviti ovire, nastale po izvedbi inovacijske strategije. Dobro strokovno podkovan svetovalec namreč posreduje informacije in izkušnje, poišče rešitve in predlaga poslovne odločitve (Kos, 1996).

## 2.2 Aplikacije nevronske mreže v managementu

O uporabi nevronske mreže na področju managementa, trženja in ekonomije je moč razpravljati z vidika aplikativne vrednosti. Njihovo uporabnost lahko obravnavamo tako z vidika posameznih metod in modelov (nekatero pomembnejše sem v prehodnih poglavjih podrobno opisal), kot z vidika orodja, ki nam je v pomoč pri reševanju raznih poslovnih problemov. Upoštevati pa je treba tudi, da se lahko različno obnašajo (npr. zvezno ali binarno), kar pomeni, da so posledično podatki zveni, binarni ali pa tudi kombinirani. Tako je lahko nevronske mreže tudi hibridne. Iz slednjega je smiselno izhajati, kadar preučujemo reševanje poslovnih problemov s pomočjo nevronske mreže.

Glede na to, da nevronske mreže posnemajo princip delovanja bioloških možganov, ki so sposobni reševati različne probleme, lahko sklepamo, da je z njihovo uporabo na poslovnem področju mogoče reševati v glavnem vse poslovne probleme. Vendar na tem mestu ne smemo pozabiti na pomemben dejavnik, to je kakovostno učenje. Tako kot to velja za posameznika, če želi reševati različne probleme, to velja za nevronske mreže.

Uporaba nevronske mreže je prisotna tudi v proaktivnem managementu. Spremembe v zunanjem in notranjem okolju posameznega podjetja se namreč odražajo tudi z njegovim odzivom na te spremembe. V glavnem pa gre za odzive na proaktivno delovanje (vplivanje) drugih podjetij. Proaktivno oziroma pobudno delovanje je pomembno tudi v kriznih situacijah, ko je potrebno glede na okoliščine izpeljati določene potrebne ukrepe, predvideti spremembe v podjetju, itd. Management, ki razpolaga z določenimi dejavniki in nepopolnimi podatki, bi slednje vstavil v izbrani nevronske mreže, ki bi lahko napovedal prihodnje (verjetno) poslovno stanje (Tavčar, 2002; Zidar & Biloslavo, 2010).

Z uporabo nevronske mreže tako lahko rešujemo različne vrste problemov. Krapež in Rajkovič (2003, str. 80) jih razvrščata glede na:

- **Klasifikacija:** tukaj gre za učenje mreže iz primerov in vhodnih podatkov oziroma rešitev. Naše pričakovanje je, da bodo med delovanjem naučeni vhodni podatki prepoznani, četudi bi morebiti vsebovali napake.
- **Generalizacija:** od nevronske mreže pričakujemo, da bo v primeru generalizacije napovedala rezultate za vhodne podatke, ki se razlikujejo od podatkov v procesu učenja.
- **Razvrstitev:** v tem primeru pričakujemo, da bo naučena nevronske mreže niz vhodnih podatkov razporedila v primerno skupino.

Z uporabo določenih programskih paketov, ki posnemajo delovanje nevronske mreže, so te lahko na osebnih računalnikih ali ostalih računalniških sistemih. Specializirani koprocesorji nevronske mreže za osebne računalnike spadajo med zmogljivejše, saj zagotavljajo večjo procesorsko moč. V tem primeru gre namreč za dodatno računsko moč



glavnemu mikroprocesorju, če le-ta ne zmore dovolj hitro izvesti zahtevnih računskih operacij, kot so npr. seštevanje, odštevanje, množenje, deljenje, trigonometrične in logaritmične funkcije itd. Med najzmogljivejše spadajo mikroprocesorski čipi za nevronske mreže, ki so v pomoč pri aplikacijah na določenih področjih, kot je na primer: vojaški oborožitveni sistem, procesiranje slik ali prepoznavanje govora (O'Brien, 1999).

Uporaba nevronske mreže na poslovnem področju je raznolika. Njihova primernost se kaže predvsem na naslednjih področjih (Turban, Mclean & Wetherbe, 1996, str. 605):

- **Finančne službe:** za pomoč pri ugotavljanju istovetnosti borznih trendov ter načrtovanju prometa z delnicami;
- **Posojila:** pri ocenjevanju prošelj za posojila s pomočjo primerov preteklih podatkov o uporabnikih.
- **Napovedovanje solventnosti:** za ocenjevanje finančnega stanja podjetja in napovedovanje morebitne nesolventnosti.
- **Posojilne kartice:** za informiranje glede posojilnih kartic predvsem v primerih morebitnih zlorab.
- **Ocenjevanje delovne sile in kandidatov za določeno delovno mesto:** za pomoč pri primerjavi sposobnosti glede na zahteve.
- **Alokaciji zalog na osnovi statistike in izkušenj:** za pomoč pri iskanju optimalnih alokacij zalog, ki bodo zagotovile največjo možno produktivnost.

Povzetih je le nekaj področij poslovanja, kjer je uporaba nevronske mreže smiselna. Sicer gre, glede na današnji tehnološki razvoj za podatke, ki so stari že kar nekaj let, vendar gre za tuj vir informacij. Če se opredelimo zgolj na slovensko tržišče in poslovanje, glede na dostopnost informacij in raziskav, menimo, da so področja uporabe vsekakor še vedno dokaj nova. S tem ne opredeljujemo našega tržišča kot zastarelega, pač pa je moč ugotoviti, da je pri nas razvoj tehnologije s pomočjo nevronske mreže morda nekoliko počasnejši. Kar pomeni, da so našta področja v nekaterih državah verjetno že bolj vpeljana, kot pri nas. Vsekakor so se tako v tujini kot pri nas vidiki poslovanja z uporabo nevronske mreže do danes razširili. Vprašanje je le v kolikšni meri jih pri nas že vpeljujemo in uporabljamo.

Naj na kratko omenimo tudi računalniške programe, imenovane inteligentni agenti. Gre za programe, ki skrbijo za pomoč uporabnikom računalnikov pri različnih računalniških aplikacijah. V tem primeru ni v uporabi zgolj nevronska mreža, temveč gre za skupek različne oblike umetne inteligence. Njihova uporaba sega na področje preproste uporabe programskih paketov, brskanja po spletu, avtomatiziranja iskanja in dostave točno določenih informacij uporabnikom in opravljanje preprostih opravil. Prav tako so določeni inteligentni agenti zmožni učenja na osnovi primerov in preteklih izkušenj, s pomočjo katerih lahko zvišujejo možnost opravljanja zadanih nalog. Vrste programskih inteligentnih agentov, ki jih v svojem zborniku opisuje inštitut Jožefa Štefana (1999, str. 88) zajemajo:

- **Informacijske agente:** ki omogočajo dostop do podatkov in so glede na zahteve uporabnika zmožni pregledati večje število podatkovnih virov ter iz njih pridobiti uporabne podatke in jih ustrezno predstaviti.
- **Kooperacijski agenti:** ki naloge rešujejo s pomočjo komunikacije. Zaradi tega so uporabni v situacijah, ko je problem nemogoče rešiti samo z enim agentom. Tako več agentov rešuje posamezne dele naloge, skupaj pa rešijo celotno nalogo, ki jim je bila zadana.
- **Transakcijski agenti:** ki so uporabni pri izvajanju in nadzoru transakcij, predvsem v primeru elektronskega trgovanja in podatkovnih baz, ki zahtevajo strog nadzor nad samo izvedbo ter zanesljivost in ustrezno zaščito podatkov.

Glede na njihovo vsestransko uporabnost so lahko nepogrešljivi pri poslovanju podjetij, predvsem tistih, ki uporabljajo kakršne koli sisteme poslovnega obveščanja.

### 2.3 Stroškovni pregled uporabe nevronske mreže

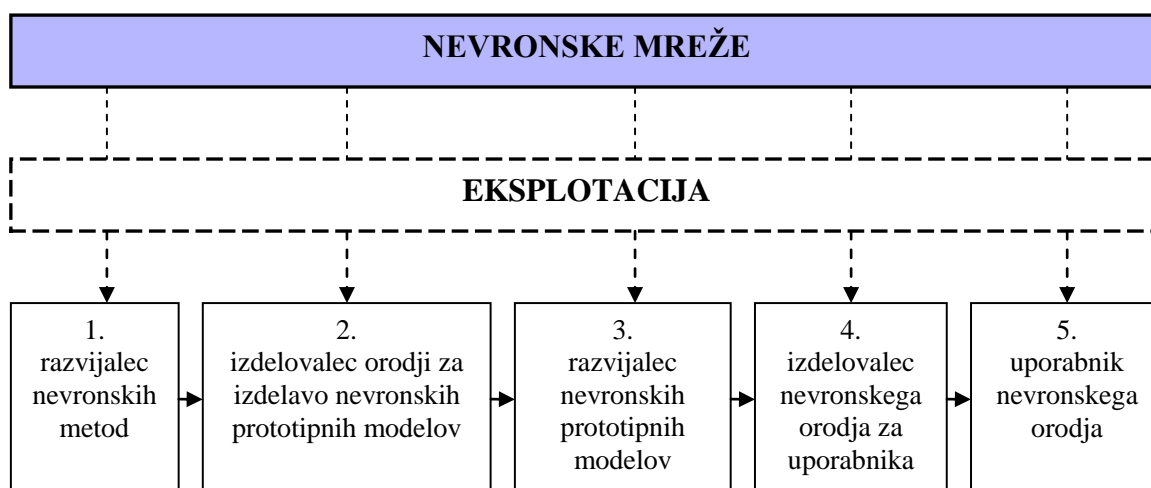
Za uporabo nevronske mreže je najprej potrebno določeno znanje, ki je odvisno od vloge, ki jo zavzamemo v procesu eksploatacije<sup>5</sup> nevronske mreže. Kot prikazuje slika 15, je ključnih znanj in vlog pet. Za management je tovrsten vidik razumevanja nevronske mreže pomemben, saj se pri uvajanju projektov, ki so povezani z nevronske mreže določijo jasne ločnice med tem, kdo je za kaj odgovoren, kar daje managementu transparenten vpogled v sam proces eksploatacije nevronske mreže.

V primeru razvijalca nevronske metode (1.) je potrebno največ poglobljenega znanja o nevronske mreže; v primeru vloge izdelovalca orodij, ki so namenjena za izdelavo prototipnih modelov (2.) in v primeru izdelovalca nevronske orodij za uporabnika (4.) je potrebno poglobljeno znanje o nevronske metodah in znanje s področja računalniškega področja oziroma kakšnega drugega področja; v primeru razvijalca nevronske prototipov (3.) je potrebno splošno znanje o nevronske mreže, znanje za razumevanje nevronske metode in njihovo reševanje problemov, ki so jim namenjene, ter znanje uporabe programskega paketa, ki omogoča izdelovanje nevronske prototipov; v primeru uporabnika nevronskega orodja (5.) pa je potrebno le osnovno razumevanje nevronske mreže.

---

<sup>5</sup> Izraz eksploatacija predstavlja več pomenov, odvisno od okoliščin uporabe besedne zveze. V našem primeru gre po pravilih SSKJ-ja za uporabljane nečesa v gospodarske namene oziroma po Zidar-ju (2009), črpanje znanja in podjetniških priložnosti.

Slika 15: Vidiki in vloge v eksploatacijskem procesu nevronske mreže



Vir: Prirejeno po Zidar, *Nevronske mreže kot modeli za napoved prodaje prehrambnih dobrin*, 2009, str. 127.

Za delo z nevronske mreže v glavnem najprej potrebujemo različna programska orodja. Nekatera so zelo kompleksna in omogočajo delo z velikanskimi mrežami, ta so namenjena delu z močnimi »superračunalniki«. Seveda pa obstaja tudi mnogo orodij za delo z nevronske mreže, ki delujejo na osebnih računalnikih. Razlikujejo se predvsem po izbiri različnih mrež, ki jih podpirajo in po namenu uporabe. Danes je tako uporabo nevronske mreže zaslediti že na mnogih področjih. Mnogokrat gre za integrirane sisteme, ki so del kompleksnih sistemov in jih uporabljamo, vsakodnevno pa se tega morda niti ne zavedamo. Nevronske mreže uporabljajo spletni brskalniki (za razvrščanje podatkov), meteorologom pomagajo pri napovedovanju vremena, najdemo pa jih na primer tudi v novejših menjalnikih avtomobilov. Vse bolj pa se razvija tudi njihova uporaba v poslovnem svetu, kot del sistemov za odločanje ali pa v kompleksnih informacijskih sistemih.

Če jih želimo uporabiti za reševanje poslovnih problemov potrebujemo le računalniško in programsko opremo, čeprav ne gre zgolj za edino opremo, ki omogoča uporabo nevronske mreže za reševanje poslovnih problemov. Načeloma je odvisno od tega, za kakšno okoliščino gre oziroma področje eksploatacije nevronske mreže. Na trgu tako obstaja več vrst programske opreme za modeliranje nevronske modelov in izdelavo nevronske prototipov, ki imajo običajno že vgrajene razne standarde (nabore) nevronske mreže. So pa tovrstni programi bolj namenjeni raziskovanju in poskusnemu delu oziroma izdelavi prototipov. Za praktično uporabo je namreč bolj priporočljivo izdelati namensko aplikacijo (Zidar, 2009).

Že, če zanemarimo človeški dejavnik in se osredotočimo zgolj na omenjeno uporabo programov pri upravljanju z nevronske mreže, je težko predstaviti stroškovni pregled. Za podrobnejšo analizo bi namreč najprej potrebovali konkreten primer, ki bi mu lahko

predlagali uporabo določenega tehničnega oziroma programskega orodja in na podlagi tega predvideli stroške. V splošnem bi sicer lahko rekli, da gre za metodo, za katero je potrebna določena oprema, za njeno uporabo pa določena znanja, kar prinaša stroške, toda v marsikaterem procesu je danes slednje pravzaprav nepogrešljivo.

Če bi želeli podati konkretne podatke, bi morali preučiti tudi konkreten primer. Tako pa lahko govorimo zgolj na podlagi preučevanja tuje strokovne literature. Kot smo že ugotovili gre pravzaprav za vse bolj hitro razvijajoče se in perspektivno področje, ki omogoča reševanje raznovrstnih problemov tudi na področju managementa in poslovnih problemov, kjer samo človeški faktor ni dovolj perspektiven. Nevronske mreže so, tako kot ugotavljajo strokovnjaki, velik potencial podjetniških področij in kot je razvidno iz empiričnega preučevanja v magistrskem delu, uporabne na mnogih področjih, kjer so zaradi svojega visokega potenciala in zmožnosti pravzaprav nezamenljive. V končni fazi je treba paziti predvsem na to, da so koristi uporabe večje kot stroški. Četudi gre morda najprej za večje začetne stroške (na primer nakup programske opreme) se morajo ti sčasoma povrniti oziroma preseči vloženo.

### **3 EMPIRIČNA ANALIZA**

Empirična analiza temelji na kvalitativnem raziskovanju s pomočjo kvalitativne metode zbiranja podatkov in analize podatkov. Osnovno gradivo, zbrano v raziskovalnem procesu, je bilo obdelano in analizirano s pomočjo besednega načina. Posamezni primeri sekundarnih podatkov pri raziskovanju, so bili medsebojno primerjani in analizirani, z njihovo pomočjo pa so bile pridobljene ustrezne informacije. Slednje omogočajo vpogled v področje praktične uporabe nevronske mreže in njihovo interpretacijo.

S pomočjo deskripcije so bili zbrani sekundarni viri, ki so bili analizirani, medsebojno primerjani in obravnavani v sklopu teorije in metod kot neločljivih elementov. Primarni viri so bili pridobljeni s pomočjo znanstvenih monografij, znanstvenih in strokovnih člankov ter zbornikov znanstvenih konferenc. Uporabljene so bile tudi nekatere bibliografske baze, kot sta COBISS in GOOGLE, kjer sem uporabil ključne besede v slovenskem jeziku: nevronske mreže, uporaba nevronske mreže, učenje nevronske mreže, management in inovacijski management in v angleškem: neural networks, use of neural network, learning neural networks, management and innovation management.

#### **3.1 Namen in cilji raziskave uporabe nevronske mreže**

Empirična analiza predstavlja različne probleme uporabe nevronske mreže, ki se nanašajo na področje managementa in reševanje poslovnih problemov. Predstavljeni primeri so s pomočjo različne literature in raziskovanj analizirani tako, da prinašajo vpogled in razumevanje ter pridobitev informacij v povezavi s posameznimi primeri. Cilji raziskave se

nanašajo na prikaz predstavitve uporabe nevronske mreže na področju managementa in ugotovitve, ki so v pomoč kot nov pristop reševanja poslovnih problemov na tem področju.

### **3.2 Praktična uporaba nevronske mreže**

S pomočjo zbranih raziskav in obstoječih uporab nevronske mreže na področju managementa sem preučil njihovo uporabo, vpliv in rezultate ter jih predstavil v nekaterih pogostejših primerih oziroma tistih, kjer je bilo zaslediti relevantne podatke.

V okviru raznih poslovnih procesov se institucije, kot so banke, zavarovalnice, trgovine, poskušajo zavarovati pred različnimi prevarami in tveganji. Glede na to, da imajo binarne usmerjene nevronske mreže lastnosti razvrščanja oziroma klasificiranja podatkov (v navedenih primerih so torej primerne za odkrivanje morebitnih prevar in tveganj itd.) bi lahko pripomogle pri pregledovanju nepreglednih podatkov v različnih podatkovnih zbirkah in skladiščih, ki jim je človeški dejavnik težko kos. Prav tako bi bila uporaba binarnih usmerjenih nevronske mreže primerna na področju managementa človeških virov. Zajema namreč poznavanje različnih lastnosti in vedenjskih vzorcev ljudi oziroma podobno, kot v prejšnjem primeru, opraviti razne vrste klasificiranja.

Zvezna ali binarna usmerjena nevronska mreža je lahko uporabna na področju denarnega gospodarstva, pri gospodarjenju z zalogami, v primeru terjatev itd., saj gre za področja, kjer je treba napovedovati in ugotavljati stopnje tveganja. Na poslovnem področju se pojavlja mnogo problemov, povezanih z napovedovanjem prihodnjih pojavov in tveganj. Predvsem gre izpostaviti oskrbovalne verige, trženjske sisteme in preostale trženjske poti ter logistiko. V ta namen bi bila najbolj uporabna dvoplastna ali triplastna usmerjena nevronska mreža oziroma perceptron, ki je zmožna reševanja linearnih in nelinearnih problemov, kar v managementu ni izjema.

Nevronske mreže oziroma njihova uporaba se torej dobro obnesejo v aplikacijah poslovnih problemov med katere spada na primer: napovedovanje finančne uspešnosti podjetja; napovedovanje in pravočasno ugotavljanje finančne nestabilnosti in nevarnosti stečaja oziroma bankrota; analiza potrošnikov in ugotavljanje njihovega obnašanja; svetovanje pri nakupu in prodaji delnic ter napovedovanje cen delnic, indeksov in drugih finančnih instrumentov; tržno segmentiranje; napovedovanje tržnih deležev in ugotavljanje tržnih trendov; napovedovanje makroekonomskih indikatorjev (rast BDP, inflacija, brezposelnost); upravljanje zalog; napovedovanje onesnaževanja okolja ter vremenske napovedi; napovedovanje povpraševanja po izdelkih oziroma storitvah; napovedovanje prodaje po izdelkih; optimizacija in upravljanje projektov; ocenjevanje vrednosti nepremičnin; kontrola prometa; napovedovanje v primerih odobritve kreditov; nadzor strojev v tovarnah in prepričan sem, da bi se še kaj našlo.

Med raziskovanjem smo našli tudi na nekaj učinkovitih implementacijskih sistemov, ki jih izpostavlja Kamruzzaman (Kamruzzaman, Sarker & Rezaul, 2006, str. 26):

- **Falcon:** je sistem za kontrolo transakcij s posojilnimi karticami, v izogib morebitnim prevaram.
- **Inspector:** je sistem za kontrolo deviznih transakcij.
- »**Falcon Asset management, John Deere and Co., Hyman Beck and Company, Multiverse Systems, Advanced Investment Technology, Ward System**«: so sistemi za finančno modeliranje.
- **Areas:** je sistem za ocenjevanje vrednosti nepremičnin.

V nadaljevanju je predstavljen nekoliko bolj podroben prikaz primerov nekaterih izpostavljenih problemov v praksi, za katere sem uspel pridobiti podatke. V Sloveniji pravzaprav ni podjetja oziroma institucije, ki bi, vsaj javno, poudarila uporabo nevronske mreže na svojih področjih. Uporaba le-teh pa se je v tujini v zadnjih letih precej razširila. Zagotovo tudi pri nas podjetja uporabljajo te napredne sisteme, vendar je pri nas že teoretično področje o osnovnih informacijah glede nevronske mreže na področju managementa dokaj skopo, tako da se težjemu dostopu informacij o praktični uporabi nevronske mreže navsezadnje ni čuditi.

### 3.2.1 Odobritev posojil s pomočjo nevronske mreže

Pri odobritvi posojila oziroma kredita gre pravzaprav za zapleten proces tveganja, saj ni za nobeno pogodbenico (tistega, ki posoja in tistega, ki jemlje posojilo) popolnoma sigurno, da bodo pričakovanja v povezavi s posojilom izpolnjena. Banka se o posojilu denarja odloča na podlagi različnih podatkov o prejemniku posojila oziroma kreditorejalcu, s pomočjo potrjenih dokumentov, posojilnim točkovanjem in primerjavo. Kot opredeljuje Kendall (1998) gre v primeru posojila za tveganje z verjetnostjo, da posel, ki je bil sklenjen s stranko zaradi nezmožnosti poravnave njenih finančnih obveznosti ne bo izveden. Joiron (1997) pa posojilo pojmuje celo kot tveganje finančne izgube, ki povzroči stranko v primeru, ko svoje obveznosti ne izpolni. Tudi pretekli podatki finančnih institucij dokazujejo, da je posojilo nevarnost, ki je daleč bolj pomembna kot na primer tržno tveganje.

Prejemniki posojil so pripravljene plačati obresti in preostale stroške, saj jim je s tem omogočen nakup določene dobrine oziroma storitev za zadovoljevanje potrošniških potreb oziroma za donosne naložbe. Cene, ki se ob najemu posojila plačujejo, obsegajo obrestne mere in stroške za odobritev. Empirične študije pa potrjujejo, da je povpraševanje po denarju občutljivo na obrestne mere. Pri višjih obrestnih merah se povpraševanju po denarju zmanjšuje (Samuelson & Nordhaus, 2002).

Banka mora v primeru odločanja o odobritvi najprej izračunati sposobnost prejemnika posojila. Gre za finančno sposobnost dolžnika na podlagi, katere se presodi, kako bo v skladu z dogovorom omogočeno vračilo posojila in plačilo pripadajočih obresti. Posamezna banka navadno sposobnosti ocenjuje s pomočjo prihodkov dolžnika v določenem obdobju, ki jih izrazi v določenem deležu (Cekin, 2009).

V primeru nevronske mreže gre za model, ki omogoča na primer napovedovanje stanja plačilne discipline prejemnika posojilojemalca. V začetku je morda model glede na priučene podatke manj sposoben, kot kasneje ko se njegove napovedi izboljšajo, saj pri preučevanju podatkov odkrijejo specifične vzorce iz katerih se naučijo primerov in kasneje enostavneje povezujejo.

Praktični primer uporabe nevronske mreže za prepoznavanje tveganja zasledimo v raziskavi, izvedeni na določenih preiskovanih podjetjih za namene bančnih posojil, ki je bila opravljena na Poljskem. Avtorica (Witkowska, 2006) je za vsako izbrano podjetje uporabila trinajst finančnih kazalnikov, ki jih vsebujejo finančni in računovodski dokumenti ter jih razvrstila v štiri razrede. Svojo razvrstitev je primerjala s tisto, ki so jo pripravili bančni uslužbenci. Uporabila je nevronske mreže z radialno osnovno funkcijo sestavljeno iz treh plasti: vhodne plasti nevronov, ki vpeljujejo obliko vektorjev v nevronske mreže, skrite plasti radialnih nevronov mreže, ki računajo izide osnovnih funkcij ter plasti izhodnih nevronov, ki računajo linearno kombinacijo osnovnih funkcij in s pomočjo katere je bila klasiifikacijska napaka sicer najmanjša, vendar je bil delež pravilno identificiranih podjetij najmanjši. Največ pravilno identificiranih podjetij je uspela pridobiti z uporabo nevronske mreže z večslojnim perceptronom. Končni rezultat je bila ugotovitev, da so nevronske mreže sposobne generaliziranja znanja in da lahko podpirajo vrednotenje bonitete prejemnikov posojil.

Raziskavo o posojilnem tveganju na podlagi obstoječih prejemnikov posojil s pomočjo nevronske mreže sta izvedla tudi Kim in Sohn (2004). Z uporabo klasificiranja vzorcev sta s pomočjo nevronske mreže prejemnike oziroma posojilojemalce, glede na njihov posojilni status, razvrstila v dve skupini: na dobre in slabe plačnike. S pomočjo segmentacije sta ti dve skupini razdelila na štiri podskupine in ugotovila najpomembnejše lastnosti posamezne skupine ter na podlagi tega priporočila primerne strategije upravljanja za posamezno skupino, ki so naslednje:

- **Skupina 1:** v tem primeru gre za kratek odlog plačila ter manjši delež odprtih računov v primerjavi s preostalimi. Dobro jih je dolgo zadržati, saj njihova dobra bonitetna ocena kaže na to, da nimajo težav s plačili. Za kontinuirani dobiček jih je treba spodbuditi za večja posojila in dolgotrajno interakcijo.
- **Skupina 2:** njihov odlog plačila je nekoliko daljši, kot pri skupini 1. Gre za nekoliko bolj nestabilne stranke. Imajo nekoliko slabšo bonitetno oceno, kar nakazuje na malce slabšo izpolnitev obveznosti. O njih je nujno zbirati informacije in jih vztrajno

preverjati, saj se lahko zaostanek plačila redno pojavlja. Pri zamudi plačila jih moramo na njihovo obveznost opomniti.

- **Skupina 3:** gre za skupino podobno skupini 1. Njihova bonitetna ocena ni slaba, zato se ocenjuje, da bodo sposobni izpolnjevati obveznosti, toda lahko pozabijo na plačilo. V tem primeru prejmejo spoštljivo opozorilo o zapadlosti njihovih obveznosti. Če se pojavijo kratkotrajne težave s plačili, lahko privolimo v delna plačila in njihov odlog plačila podaljšamo.
- **Skupina 4:** prejemniki posojil v tej skupini imajo slabo bonitetno oceno, zato jih bolj resno obravnavamo, saj imajo status slabega plačnika. Navadno imajo velik in dolgotrajen dolg, ki se ga nadzoruje. V tem primeru je treba izgubo čim bolj zmanjšati, kar lahko storimo z ponudbo o daljšem odplačevanju. Izgubo moramo pri njih minimizirati tako, da jim ponudimo daljše odplačevanje ali pa se jim odpovedati, njihov dolg pa izbrisati.

Leta 2001 sta avtorja Rems in Škrjanc ugotavljala, da v naših bankah metode za odobravanje posojil s pomočjo nevronske mreže še ne uporabljajo in da so le-te v fazi nastajanja. Ugotovila sta, da je problem v preučevanju in analiziranju velikega odstotka podatkov o prisotnih karakternih parametrih potencialnih prejemnikov posojil.

Predpostavljala pa, da bodo banke uporabljale kombinacijo dveh ali treh metod, saj so že gradile modele za pomoč pri odločanju z različnimi učnimi metodami. Uporabljene so bile posamezne metode nevronske mreže ter drugi posamezni tehnološki programi za napovedovanje. Pri uporabljeni metodi nevronske mreže, so za izhodne podatke uporabili plačnik oziroma neplačnik, vhod pa so predstavljali podatki o komitentih in njihovo finančno stanje. Nevronske mreže so v povprečju komitente pravilno razvrstile v 75,9 %.

Kako je danes, več kot deset let kasneje po navedenih ugotovitvah, težko razpravljamo, saj podatkov o morebitnih uporabah nevronske mreže glede odobravanja posojil pri bankah nisem uspel pridobiti. Banke so zaradi poslovne politike in posredovanja informacij, ki nimajo status javnega značaja, sodelovanje zavrnilo. Stik sem najprej skušal vzpostaviti preko dopisa, vendar se od štirih, ena banka ni odzvala, tri pa so odgovorile podobno, med drugim, da gre za podatke, ki so za njihovo dobro poslovanje zaupni.

Raziskav kasneje, po omenjeni, na tem področju ni moč zaslediti. Morda ne gre slednje pripisati zgolj majhnemu interesu glede sodelovanja oziroma nepripravljenosti, pač pa počasnemu razvoju na področju nevronske mreže pri nas in težki dostopnosti informacij ter po tem takem majhnem interesu javnosti za razumevanje in informiranje s tega področja.

### **3.2.2 Uporaba nevronske mreže pri poslovanju z vrednostnimi papirji**

Vrednostni papirji so v sodobnem svetu pridobili pomen, danes so v uporabi kot posojilno sredstvo, kot orodje za negotovinsko plačevanje, kot podlaga za kopičenje oziroma



zbiranje denarnih sredstev, kot pospeševalec cirkulacije blaga, kot orodje financiranja in med drugim tudi za urejanje količine denarja v obtoku. Vrednostni papir predstavlja določeno terjatev (vrsta terjatve je navedena) imetnika papirja do izdajatelja, ki je zavezan, da obveznost iz papirja izpolni v odrejenem roku. Obveznosti, terjatev in pravic iz vrednostnega papirja ne moremo opravljati brez listine, saj po načelu inkorporacije vrednostni papirji vsebujejo pravico, ki je inkorporirana v listini. Tako pravic iz vrednostnega papirja ne moremo uveljaviti ali jih prenesti brez dokazila o obstoju pravnega temelja določenega vrednostnega papirja. Njihova poglobljena značilnost pa je, samostojna pravna narava in ločenost od posla, za katerega so bili izdani, saj je le-ta pomemben le s stališča razmerja med dolžnikom in prvim pridobitnikom le-tega (Puharič, 1995).

Glede na pravico delimo vrednostne papirje na (Puharič, 1995, str. 184):

- **obligacijsko-pravne:** vsebujejo konkretno obligacijsko pravico oziroma terjatev upnika, terjatev za denar ali katero drugo storitev (ček, menica, certifikat, blagajniški zapis, itd.);
- **stvarnopravne:** zajemajo stvarno pravico in predstavljajo stvar ali samo blago. Upravičenec ima s takšnim papirjem pravico do izročitve stvari, ki so v papirju navedene, ter možnost izročitve papirja na novega upravičenca in s tem tudi stvarno pravico za samo blago (skladiščnica, nakladnica, itd.);
- **korporacijske:** vsebujejo krog članskih pravic v določeni pojavnih oblikah kapitalskih družb (na primer delnica).

Opredelimo se na korporacijske vrednostne papirje oziroma delnice. Te predstavljajo del osnovnega kapitala delniške družbe, kar pomeni, da gre za lastnino dela kapitala, vloženega v neko podjetje, zaradi česar imetniku tega vrednostnega papirja pripisujejo tudi pravice, ki izhajajo iz lastnine. Delimo jih na materializirane in nematerializirane delnice, odvisno do tega v kakšni obliki se pojavljajo.

Nakup vrednostnega papirja lahko enačimo z naložbo. Pri začetni nakupni vrednosti imamo preko določenega obdobja določene donose. Zaradi tega naložbe v vrednostne papirje ocenjujemo po metodah za ocenjevanje investicij. Kadar govorimo o vrednostnih papirjih, je pomembno predvideti tudi tveganje, ki je pri posameznih oblikah vrednostnih papirjev različno. Najbolj tvegane so naložbe v delnice, najmanj pa v državne obveznice, saj predstavljajo terjatev do države. Razlike med trajanjem določene investicije se prav tako razlikujejo glede na vrednostni papir. Pri delnicah je ta enaka življenjski dobi družbe (če jih prej ne prodamo), pri obveznicah pa do prihoda. Če vrednostne papirje prodamo pred prihodom nam razlika med prodano in nabavno ceno daje določen donos, lahko pa tudi izgubo.

Glede na navedeno je pomembno, da se kar najbolj racionalno odločimo za naložbe v vrednostne papirje, pri čemer je dobro, da poznamo obrestne mere in njihove cene v

prihodnosti. Pomagamo si lahko s sistemi za napovedovanje, s katerimi poskušamo napovedati cene vrednostnih papirjev in s tem pretehtati uspešnost naložbe.

Nevronske mreže so eden izmed zelo primernih sistemov za napovedovanje tečajev vrednostnih papirjev. Pham in Liu (1995) navajata, da se uporabljajo tako preproste mreže kot so večplastni perceptroni, kot tudi bolj kompleksne. Vendar, kot vsi sistemi za napovedovanje, so tudi nevrnske mreže zmožne napovedati zgolj deterministične pojave. Zato jih pogosto uporabljajo bolj kot pomoč pri napovedovanju ekonomskih dejavnikov.

Pri uporabi nevrnske mreže za napovedovanje vrednosti delnic imamo možnost uporabe časovne vrste vrednosti delnice na določen dan. Najprej določimo število vhodov in izhodov, število plasti in nevronov ter transformacijske funkcije. Nevronska mreža omogoča pridobitev dokaj uspešnih predvidenih rezultatov, kot je npr. vrednost delnice za približno pet dni vnaprej. Medtem ko je daljše napovedovanje odvisno od uspešnosti načrtovanja nevrnske mreže. Če je le-to zelo uspešno lahko pridobimo predikcijo tudi za do petdeset dni vnaprej. Toda pri nas je slednje nekoliko težje, saj je slovenski finančni trg zaradi svoje majhnosti manj učinkovit. To pomeni, da lahko na ceno naložb vplivajo že posamezne transakcije in povzročijo odstopanje, tržne od notranje vrednosti vrednostnih papirjev. Ker gre za spremembe, ki so navadno naključne, se jih mreža ne more priučiti in posledično je rezultat slabša predikcija. V takšnem primeru je za uspešne rezultate primeren krajši vzorčni čas, krajši kot en dan.

Analiza dosedanjega raziskovanja v zvezi z napovedovanjem s pomočjo nevrnskih mrež na področju poslovanja z vrednostnimi papirji je pokazala, da je bilo izvedenih že kar nekaj poskusov. Prav tako so bile narejene raziskave s pomočjo drugih metod napovedovanja, ki so jih nato primerjali z uporabo nevrnskih mrež. Med temi so:

- Hann in Steuner sta primerjala nevrnske mreže in linearne modele za napovedovanje tedenskega in mesečnega deviznega tečaja med nemško marko in ameriškim dolarjem. Ugotovila sta, da se nevrnske mreže bolje izkažejo v primeru napovedovanja tedenskega deviznega tečaja. V primeru mesečnih podatkov glede deviznega tečaja pa sta metodi enakovredni (Hann & Steuner, 1996).
- Primerjava med učinkovitostjo napovedovanja med nevrnskimi mrežami in ARIMA<sup>6</sup> metodologijo je bila narejena tudi za primer učinkovitosti napovedovanja cen živine in pšenice. Tudi tukaj so raziskave pokazale, da je uporaba nevrnskih mrež za napovedovanje takšne časovne vrste, uspešnejša (Zhang, Patuwo & Hu, 1998).

---

<sup>6</sup> ARIMA (angl. autoregressive integrated moving average) so modeli, ki so bili v sredini 20. stoletja zelo preučevani in so se uporabljali izključno za napovedovanje časovnih vrst. Razvili so jih zaradi potrebe statističnih raziskav, pri katerih so raziskovalci pri napovedovanju časovnih vrst, ki so vsebovale določen trend ali sezonsko gibanje, imeli težave. Največ sta prispevala George Box in Gwilyn Jenkins, ki sta do podrobnosti preučila težave napovedovanja omenjenih časovnih vrst (Batagelj, 2003).

- Študije, ki kažejo, da so nevronske mreže bistveno uspešnejše pri napovedovanju dnevnega deviznega tečaja kot pa tradicionalne statistične metode (Zhang, Patuwo & Hu, 1998).
- Model nevronske mreže je bil primerjan tudi s tehnikami eksponentnega glajenja in metodo ARIMA, za urne podatke deviznih tečajev. Ugotovljeno je bilo, da so rezultati bistveno boljši z uporabo nevronske mreže (Zhang, Patuwo & Hu, 1998).
- Študija modela nevronske mreže s pomočjo katere se napoveduje gibanje deviznih tečajev med petimi denarnimi enotami. Kot vhodni podatki so bili uporabljeni nekateri tehnični kazalniki. Pridobljeni rezultati so bili primerjani z rezultati ARIMA tehnike. Ugotovitve so, da so se nevronske mreže bistveno bolje izkazale (Jingtao, 2000).
- Poleg finančnih časovnih vrst so študije pokazale, da so nevronske mreže primerne tudi za napovedovanje ekonomskih časovnih vrst (na primer BDP). F. Aminian, Squarez, M. Aminian in Walz (2006) ugotavljajo, da so napovedi rasti BDP na podlagi nevronske mreže boljše kot klasične tehnike linearne regresije.

Uporaba nevronske mreže na področju poslovanja z vrednotnimi papirji se kaže za uporabnejšo od preostalih kompleksnih statističnih modelov. Definira se jo enkrat, potem pa se poljubno uči na določenih intervalih in je sposobna ugotavljanja nihanja, napovedovanja, obenem pa posnemanja že naučenega. Kljub zapletenemu delovanju nevronske mreže in nerazumevanju njenih notranjih procesov pa so podatki zadovoljivi. Vendar pa se z večanjem kompleksnosti problema, večja tudi zapletenost delovanja nevronske mreže. Zaradi tega je treba natančno predvideti, kakšni so naši vhodni podatki, ki so nam na voljo in jih bomo vnesli in za kakšen trg bi mrežo uporabili. Predstavljeni primeri pa dokazujejo, da so rezultati različnih študij dobri, kar potrjuje uporabnost modelov za napovedovanje, ki temeljijo na nevronske mreže.

### **3.2.3 Uporaba nevronske mreže pri načrtovanju poslovanja**

Načrtovanje poslovanja poteka na podlagi potreb in želja na trgu oziroma na podlagi povpraševanja. Vsekakor je pomembno, da poznamo vedenjske vzorce potrošnikov, se posvetimo upravljanju odnosov s strankami, načrtovanju poslovanja itd. Na podlagi tega se lahko oblikujejo razni napovedovalni modeli, s pomočjo katerih lahko natančneje opredelimo povpraševanje na trgu. Slednje je dobrodošlo predvsem za prilagoditve delovnih procesov, natančneje predvidevanje storitev oz. dejavnike, ki so značilni za celostni predračun podjetja. Kljub temu pa lahko nevronska mreža zgolj oceni dejanske vrednosti. Tudi uporaba določene vrste metode, ki se izkaže boljše v teoriji, ne pomeni, da bo tako tudi v praksi in da je zaradi tega res sprejemljivejša.

Potočnik (2002) izpostavlja, da gre pri napovedovanju povpraševanja pravzaprav za sposobnost predvidevanja, kakšno bo porabnikovo povpraševanje v danih razmerah. Ker je na večini trgov povpraševanje po izdelkih oziroma storitvah zelo spremenljivo, meni, da

postaja dobro ocenjevanje in napovedovanje prihodnjega povpraševanja bistven dejavnik za uspešno poslovanje.

Zapleteno je tudi nakupno vedenje potrošnikov in prepoznavanje njihovih vedenjskih vzorcev, ki so pomembni za podjetje in njegovo poslovanje. Potočnik (2005, str. 107) meni, da gre za proces odločanja, ki združuje postopke izbire in ocenjevanja alternativ, ko potrošniki kupujejo izdelke ali storitve. Potrošnikovo odločevanje temelji na vrednotah, ki so mu pomembne in na njegovih željah. Oboje je lahko zelo različno od tistega, kar predvideva podjetje. Zaradi tega mora podjetje dobro preučiti posamezne dejavnike nakupnega vedenja, saj se bo lahko le tako čim bolj približalo željam in potrebam ciljnih potrošnikov.

Zidar in Biloslavo (2010) ugotavljata, da bi se za predvidevanje povpraševanja na trgu lahko uporabila zvezna usmerjena nevronska mreža oziroma perceptron, ki lahko napoveduje tudi večkanalno oziroma napove povpraševanje za več obdobji vnaprej (za teden dni, mesec in za eno četrletje naprej). V primeru prepoznavanja vedenjskih vzorcev pa bi se lahko uporabila binarno usmerjena nevronska mreža, Hopfieldova nevronska mreža pa tudi Kohonenova nevronska mreža, ki je samoorganizirajoča. Slednja bi bila uporabna tudi na področju odnosov s strankami, v smislu razporejanja kupcev. Če povzamemo podatke, ki smo jih pridobili s pomočjo različne literature in raziskav in jih obdelali, lahko vsaj okvirno uporabo nevronskih mrež na področju managementa (zavedamo se, da niso navedena čisto vsa področja uporabe) strnemo s tabelo 6:

*Tabela 6: Uporaba nevronskih mrež na področju managementa*

<b>FINANCE</b>	<ul style="list-style-type: none"> <li>• svetovanje pri nakupu in prodaji delnic;</li> <li>• napovedovanje cen delnic;</li> <li>• odobravanje posojilov;</li> <li>• napovedovanje stečaja oziroma stečaja podjetja;</li> <li>• napovedovanje prevzema podjetja;</li> <li>• napovedovanje finančne usmerjenosti podjetja;</li> <li>• napovedovanje makroekonomskih kazalnikov</li> </ul>
<b>ORGANIZACIJA</b>	<ul style="list-style-type: none"> <li>• razporejanje dela;</li> <li>• določanje optimalnih poti procesa;</li> <li>• optimizacija in upravljanje projektov</li> </ul>
<b>ČLOVEŠKI VIRI</b>	<ul style="list-style-type: none"> <li>• izbiranje kandidatov za določena delovna mesta;</li> <li>• določanje potreb po osebju;</li> <li>• segmentiranje zaposlenih</li> </ul>

(nadaljevanje tabele)

<b>TRŽENJE</b>	<ul style="list-style-type: none"><li>• napovedovanje prodaje;</li><li>• klasifikacija potrošnikov;</li><li>• analize inovacij;</li><li>• napovedovanje povpraševanja;</li><li>• prepoznavanje vedenjskih vzorcev;</li><li>• upravljanje odnosov s strankami;</li><li>• načrtovanje poslovanja;</li><li>• napovedovanje tržnih deležev;</li><li>• ugotavljanje tržnih trendov</li></ul>
----------------	---

### 3.3 Temeljno raziskovalno vprašanje

Kot sem predvidel že v začetku gre v primeru nevronske mreže za pripomoček, ki posnema človeške možgane. Na tej podlagi je torej mogoče sklepati, da se lahko z nevronskimi mrežami rešujejo vsi poslovni problemi. Temeljno vprašanje, ki sem ga zastavil v magistrskem delu je naslednje: **“Ali se nevronske mreže kažejo kot ustrežnejši način za reševanje poslovnih problemov?”**

Glede na preučevano literaturo, ki je na področju managementa še posebej skopa, je vseeno moč ugotoviti, da gre v primeru reševanja poslovnih problemov z uporabo nevronske mreže za visok potencial. Slednje se lahko podkrepiti z dejstvi o uporabi nevronske mreže, ki pričajo o tem kako uspešne so ter delitev le-teh po namenu uporabe in seveda nenazadnje zaradi posnemanja bioloških možganov, ki so zelo zmogljiv organ. Če se zavemo, kam smo z razmišljanjem in uporabo naših možganov ljudje uspeli priti, kakšen je naš tehnološki razvoj oziroma v tem primeru razvoj poslovnih procesov, bi lahko podobnemu sistemu prav tako uspelo. Ta trditev bi pravzaprav lahko obveljala za ustrezno, toda ne smemo pozabiti, da moramo pri napovedovanju takšnih trditev v sklop potrjevanja zajeti tako prednosti kot tudi slabosti uporabljenega sistema. In kot sem že ugotovil imajo nevronske mreže sicer kar nekaj prednosti, toda tudi slabosti je nekaj in to takšnih, ki lahko v določenih primerih igrajo odločilno vlogo.

Če vzamemo primer bioloških možganov in njihovo reševanje poslovnih problemov lahko ugotovimo, da v določenih situacijah pride do težav. Slabost bioloških možganov se izrazi npr. pri miselnem procesu, ki se čez čas utruje in potrebuje počitek. V primeru umetnih nevronske mreže pa gre za stroj, ki ne potrebuje počitka. V tem primeru gre za prednost umetnih nevronske mreže pred biološkimi. Vendar pa so naši možgani zmožni ustvarjalnosti, sklepanja novih kompromisov in idej ob morebitnih nastalih težavah, ki jih premore le človeški dejavnik. Tehnologija pa je le priučena in ob nepričakovanih težavah se ne more preprosto za trenutek ustaviti in odločiti o novi rešitvi ali pa v rezultate vnesti vmesno idejo, ki se porodi pri človeku, čeprav se umetne nevronske mreže novim

situacijam znajo prilagoditi. Toda če ob tem naleti na kompleksnejši problem, na katerega vpliva kvaliteta podatkov pa so lahko rezultati nepravilni oziroma navsezadnje nekoristni. Iz tega je mogoče sklepati, da je uporaba nevronske mreže primerna zgolj za uporabo določenih podatkov ali na primer za obdelavo statističnih podatkov, od katerih ne potrebujemo drugega, kot zgolj točno določene formalne podatke oziroma informacije. Navedeno je zgolj razmišljanje, ki se je porodilo preko teoretičnega preučevanja izbranega področja. Nekateri raziskave sicer dokazujejo, da gre pri uporabi nevronske mreže za reševanje določenih poslovnih problemov za boljše rezultate, torej bi lahko zgolj na tem dejstvu predvidevali, da je odgovor na temeljno vprašanje pritrđen. Vendar ne smemo pozabiti, da je raziskava glede uporabe vseeno malo. Sklepamo lahko zgolj na podlagi nekaj rezultatov in tega, da so nevronske mreže, vsaj v tujini, v uporabi na vse širšem področju managementa.

### 3.4 Preverjanje zastavljenih hipotez

Na podlagi preučevanja reševanja različnih poslovnih problemov na področju managementa s pomočjo nevronske mreže in zastavljenem temeljnem vprašanju sem v magistrskem delu zastavili tudi tri temeljne hipoteze, ki so v nadaljevanju preverjene skozi raziskavo teoretičnega, kot tudi empiričnega dela. Rezultati so naslednji:

- **Nevronske mreže so zmožne posnemanja delovanja bioloških možganov, ki so zmogljiv naravni organ. Torej gre v tem primeru za zelo zmogljivo konkurenčno orodje, sposobno rešiti tudi vse poslovne probleme.**

Že predhodno sem ugotavljal, da gre v primeru nevronske mreže za precej sposoben sistem glede na primerjavo z biološkimi možgani. Morda bi lahko v primerjavi poudaril nekatere lastnosti nevronske mreže, ki sem jih med preučevanjem spoznal. Zelo kakovostna nevronska mreža se na primer ne ukvarja samo z vrsto informacij, ampak hkrati tudi z obdelavo podatkov. Znane so kot univerzalni aproksimatorji, saj lahko aproksimirajo poljubno zvezno funkcijo poljubno natančno, če le imamo dovolj učnih podatkov in dovolj kompleksno mrežo; zaradi dodelanih algoritmov strojnega učenja in hitrih procesorjev so izjemno lahke in priročne za uporabo; nevronske mreže lahko obdelajo tudi podatke, ki so pomanjkljivi, podvrženi šumu ali napakam; lahko klasificirajo podatke, ko običajna statistika odpove; povratne povezave omogočajo simulacijo zelo kompleksnih dinamičnih sistemov ali pa napovedovanje časovnih vrst. Vendar se tudi pri pravilno naučenih nevronske mrežah lahko pojavijo težave. Premalo zmogljiva nevronska mreža na primer ne bo mogla obdelati večjih in kompleksnejših problemov, zelo zmožna pa se je sicer sposobna naučiti učnih primerov, vendar nima sposobnosti generalizacije oziroma njene rešitve morda ne bodo pravilne. Prav tako pri samem učenju nevronske mreže ne moremo vedeti, ali smo mrežo dovolj naučili ali pa morda celo preveč, prav tako ne vemo ali smo dosegli minimalno možno napako.

Vsekakor se je treba zavedati, da nevrnske mreže gotovo ne morejo biti vsemogočen pripomoček, saj jih poleg omejevanja učnih podatkov, najbrž omejujejo tudi to, da ne morejo biti kos problemom, ki jim tudi naši možgani niso. Vsekakor so konkurenčno orodje, saj so sposobne določenih procesov in obdelave podatkov, pri katerih obvladovanje s strani človeškega dejavnika, predstavlja težave. A bolj v smislu počasnosti, torej nekonkurenčnega pristopa in ne nezmožnosti. Glede na preučevane primere s poslovnega področja je zagotovo kar nekaj takih, ki smo jim ljudje težko kos, na primer zaradi izdatne količine podatkov, ki potrebujejo obdelavo, kar pa, kot smo že ugotovili vseeno ni nemogoče in nezmožno za nas. Torej da, v delu, kjer hipoteza navaja, da gre za konkurenčno orodje jo lahko, potrdim. Vendar kljub temu ne morem trditi, da je tako na vseh področjih. Iz tega izhajam tudi pri drugem delu hipoteze, ki pa je ne morem potrditi, saj ni ne zadostnih dokazov, niti podatkov, ki bi lahko potrjevali, da so nevrnske mreže sposobne rešiti tako rekoč vsak poslovni problem. Potrebni bi bilo več raziskav na tem področju in čeprav se nevrnske mreže vse bolj uveljavljajo tudi na področju managementa je to vseeno premalo preučevano, da bi podatki zadostovali za analizo s pomočjo katere bi lahko pridobili rezultate, ki bi tovrstne trditve dokazovali. Hipoteza je torej **le delno potrjena**.

- **Nevronske mreže so sposobne same najti pravilo, ki povezuje izhodne podatke z vhodnimi. Na podlagi tega so očitno sposobne delovati tudi v situacijah, ki jih še ne poznajo.**

Kot navaja literatura, je bistvena lastnost nevrnskih mrež, da so med postopkom učenja sposobne same najti pravilo, ki povezuje izhodne podatke z vhodnimi. Ko je nevrnska mreža naučena, lahko deluje tudi v situacijah s katerimi se v postopku učenja ni srečala. Ene do takšnih so samoorganizirajoče se mreže, ki jih med drugim opisuje tudi Jamšek (2000, str. 8). Gre za mreže, ki so se sposobne same naučiti predvidevanja zakonitosti in koleracije vhodnih signalov. Slednje so primerne predvsem takrat, ko potrebujemo samokategorizacijo vhodnih vektorjev, saj so se sposobne naučiti tudi topologije vhodnih vektorjev. Skupine podobnih vhodnih vektorjev spoznavajo na način, da nevroni, ki so si v plasti mreže fizično blizu, odgovorijo na podobne vhodne vektorje. Nevroni tekmovalne plasti so tako porazdeljeni, da spoznajo pogosto predstavljene vhodne vektorje.

Kot ugotavljajo študije so torej sposobne reševati probleme v katerih pravila niso poznana. Lahko se asimilirajo glede na informacije, prilagodijo dolžnostim, ki jih opredeljuje okolje in z učenjem še izpopolnijo delovanje. Sposobne so delovati kljub napakam oziroma nepopolnim in nepravilnim podatkom in obdelovati tudi takšne, ki jih še ne poznajo. In če se spet navežem na primerjavo z biološkimi možgani so tako kot ti, očitno zmogljive delovanja v situacijah, ki jih predhodno sicer še ne poznajo. Na podlagi preučevanja in podatkov lahko zastavljeno hipotezo **potrdim**. Še vedno pa menim, da kljub delovanju v neznanih situacijah, tako kot v primeru bioloških možganov vselej ne moremo pričakovati, da bodo rezultati povsem pravilni oziroma točno takšnih, kot jih iščemo. Vendar je slednje

verjetnejše v bolj zahtevnih primerih, kjer ne gre zgolj za obdelavo podatkov oziroma napovedovanje, ki je zajeto iz informacij, ki jih posredujemo.

- **Glede na to, da so nevronske mreže primerljive z biološkimi možgani, lahko v njihovem primeru torej prav tako pričakujemo nepredvidljivo delovanje.**

Če na kratko povzamemo zgradbo in sestavo bioloških možganov (Bresjanac, 2008) gre za: posebno zapleten del živčnega sistema, ki sprejema in obdeluje informacije o dražljajih iz zunanjega okolja in iz notranjosti telesa in zapoveduje naše usmerjanje in odzive nanje. Nenehno prihajajoče informacije so torej tiste, ki jih možgani pomnijo, na podlagi katerih se učijo in izoblikujejo našo idejo o sebi in zunanjem svetu, o odnosih, o svetu itd. Kot je že bilo izpostavljeno, so možgani sestavljeni iz celic, med katerimi so najpomembnejši nevroni, ki se združujejo v zapletene mreže, preko katerih se podatki delno prenašajo v obliki električnih impulzov (vzdolž posameznih nevronov) in delno prek kemijskih signalov oziroma živčnih prenašalcev (sinaps). Mnogi detajli o delovanju posameznih vrst nevronov in posameznih področjih v možganih so že dolgo znani. Razvoj pa je privedel do spoznanja, da lahko zdaj ugotovimo, kako se dejavnosti posameznih delov v možganih in njihove povezave, spreminjajo med našo dejavnostjo, med izvajanjem miselnih in fizičnih nalog, med močnim čustvovanjem ali spanjem.

Lahko se zgodi, da pride do kratkega stika, prekinitve ali motenega delovanja, kar ima za posledico nesposobnost ustvarjanja novih spominov in morebiti tudi do njihovega nerazumevanja. Neustrezna komunikacija znotraj možganov lahko povzroči, da sveta oziroma svoje okolice ne zaznamo tako kot prej. Zaradi preoblikovanja povezav pa na primer lahko razvijemo nekontrolirane oblike vedenja, h katerim se vedno znova vračamo. Ne glede na preučevanja in vse mogoče raziskave pa še vedno lahko govorimo o nepredvidljivosti. O tem kakšne so morebitni razlogi in posledice na tem mestu ne bom razpravljaj, bom pa s pomočjo navedenih dejstev poskušal vse to povezati z delovanjem umetnih nevronske mreže, ki delujejo po principu delovanja bioloških možganov. Torej, če so naši možgani tu in tam lahko nepredvidljivi, bi potem za nekaj kar deluje po istem principu slednje prav tako veljalo? Ali pa, ker gre za umetni proces, nepredvidljivost ni mogoča, ker jo lahko kratko malo pričakujemo in navsezadnje preprečimo?

Raziskovanje je pokazalo, da natančnega odgovora na zastavljeno vprašanje ni. Kljub temu, da sem mnenja, da gre za zanimivo filozofsko razpravljanje pa so dejstva navedena kratko in enostavno. Znanstveniki, raziskovalci in avtorji, ki preučujejo delovanje nevronske mreže, navajajo, da pravzaprav ni določenih načel oziroma pravil za nastavitev parametrov, ki bi zagotavljala optimalno modeliranje nevronskega modela. Posledično se lahko zgodi, da ne dosežemo globalnega minimuma oziroma delovanje nevronskega modela ni kakovostno in predvidljivo. Za modeliranje kakovostnejšega nevronskega modela, je potreben dolgotrajnejši proces učenja, toda vprašanje, ki se zastavlja je, ali je potem njegovo delovanje povsem predvidljivo?



Večina strokovnjakov skopo navaja tovrstne podatke, večjih razprav torej ni. Navedeno so le preprosta dejstva, ki temeljijo na ugotovitvah, da za manj kakovostnejše nevronske mreže oziroma za tiste, ki do rešitve prihajajo z večjim številom korakov, obstaja tudi večja nevarnost nepredvidljivega dogajanja. Prav tako je ena od slabosti nevronskih mrež ta, da o notranjih mehanizmih ne vemo ničesar, kar pomeni, da svojega dela vnaprej ne moremo popolnoma določiti. Vemo, kakšni so vhodni podatki, vemo, kakšni bodo izhodni, ne vemo pa ničesar o analizi postopka, zato vseh dogodkov ne moremo predvideti. Na podlagi preučevanih dejstev je hipoteza **potrjena**.

### **3.5 Uporabnost pridobljenih podatkov in rezultatov**

Na osnovi preučevanja teorije, raziskav in razprav je bilo ugotovljeno, da imajo nevronske mreže precejšnjo zmogljivost reševanja problemov na različnih področjih managementa. Torej jih lahko pojmujeemo kot vsestranski in produktiven konkurenčni pripomoček. Slednje velja predvsem v primerjavi z drugimi tradicionalnimi orodji, glede na to, da smo ugotovili tudi, da se v primerjavi z njimi tudi boljše obnesejo.

Vendar pa gre le za nekaj pridobljenih podatkov, predvsem zaradi pomanjkanja literature na področju managementa in poslovanja in nasploh v slovenskem prostoru. Nekaj teorij je objavljenih v posameznih učbenikih oziroma na kratko opredeljenih v nekoliko raziskavah, s pomočjo katerih si lahko pomagamo pri obravnavi nevronskih mrež v primeru reševanja poslovnih problemov. Toda večjih dognanj in raziskav v slovenskem jeziku ni. V pomoč nam je lahko sicer tudi tuja literatura, vendar ta obravnava tudi veliko dognanj, ki na področju našega poslovanja niso uporabna, predvsem zaradi majhnosti našega trga.

Z magistrskim delom sem želel pridobiti informacije o nevronskih mrežah in njihovo uporabnostjo ter jih predstaviti na enem mestu, glede na to, da tovrstnega učbenika ali raziskovalnega dela pravzaprav ni. Sam menim, da bi še kakšna raziskava oziroma učbenik, ki bi nevronske mreže na področju poslovanja bolje predstavil, bila več kot dobrodošla. Morda bi slednje predstavljajo tudi osnovo nadaljnjemu delovanju oziroma raziskavi s tega področja, ki bi prispevala k boljšemu razumevanju in k rezultatom, ki jih je sedaj ne samo težko najti, ampak jih praktično pravzaprav skoraj ni, vsaj točno določenih ne.

Kljub vsemu sem skušal skozi magistrsko delo predstaviti informacije na takšen način, da bodo dobro vodilo na nadaljnji poti pri raziskovanju uporabe nevronskih mrež na področju managementa. Poskušal sem pripraviti ustrezen pripomoček oziroma vsaj vodnik k lažjemu iskanju, razumevanju in pridobivanju informacij in navsezadnje morda spodbudo za pripravo dela, ki na tem področju manjka in je vsekakor gotovo zelo zaželeno.

## SKLEP

V primeru nevronske mreže gre pravzaprav za mlado področje, ki se še vedno razvija in izpopolnjuje. Glavni razmah se je, po vmesnem zatonu, začel šele v zadnjih dveh desetletjih dvajsetega stoletja. Ker gre za princip, ki posnema delovanje bioloških možganov, ima seveda veliko uporabno vrednost na marsikaterem področju. Tako se je za tovrstno delovanje začel zanimati tudi management, saj so se nevronske mreže izkazale kot zmogljivo orodje tudi na področju reševanja poslovnih problemov.

S preučevanjem in raziskavo v magistrskem delu sem poskušal zajeti osnovne informacije o nevronske mrežah, njihovem delovanju in najpogosteje uporabljenih vrstah. Kljub enakemu principu delovanja nevronske mreže, ki sicer posnemajo delovanje bioloških nevronov, ukaze izvajajo hitreje, a ne zmorejo obdelati enake količine podatkov, kot so jo sposobni obdelati naši možgani. Slednji so namreč sposobni obdelave, v katerem vzporedno deluje več kot milijarda nevronov, medtem ko so nevronske mreže omejene na nekaj tisoč nevronske celice. Toda zmogljiva programska oprema se z uporabo vzporedne obdelave vse bolj dokazuje in nevronske mreže so vse bolj uporabne za reševanje tudi na področjih, ki jim človek (na primer zaradi obsega podatkov) ni kos.

Njihova uporaba je, če pogledamo bolj posplošeno, dokaj preprosta, saj je treba vedeti le, za kakšen namen jih bomo uporabili in vnesti čim bolj točne vhodne podatke. Toda nadaljnje preučevanje je pokazalo, da vendarle ni vse tako preprosto. Na izbiro imamo precej vrst nevronske mreže, vendar moramo najprej podrobno preučiti, katera je tista, ki je namenjena našemu problemu oziroma takšna, da bo za nas pripravila ustrezne rezultate. Prav tako ne poznamo natančne analize njihovega delovanja, vemo za vhodne in izhodne podatke, kaj se dogaja v njihovem notranjem mehanizmu pa ne vemo. Prihaja lahko tudi do napak in nepredvidljivih situacij, zaradi česar ne moremo biti povsem prepričani, da so pridobljeni rezultati povsem pravilni. Vsekakor so zmogljiv pripomoček, ki ga tudi na področju poslovanja čaka razvijajoča se prihodnost.

Toda žal je v slovenskem prostoru še vedno premalo zanimanja zanje in vsekakor premalo literature in raziskav na to temo, vsaj na obravnavanem področju. Gre za perspektivno področje in njihova vrednost je velika, saj so lahko v pomoč pri reševanju raznih poslovnih problemov. Zato bi bilo škoda, da navkljub njihovem potencialu teh priložnosti ne bi izkoristili. Potreben je le konkretniji pristop, ki bi natančneje opredelil njihovo terminologijo in uporabo na tem področju ter obenem jasno opredelil postopke reševanja določenih problemov, kakor je to moč zaslediti v nekaterih drugih primerih. Magistrsko delo je na tem mestu vsaj malo pripomoglo k zboru potrebnih informacij, ki dajejo vpogled v reševanje različnih poslovnih problemov na področju managementa s pomočjo nevronske mreže.

## LITERATURA IN VIRI

1. Afuah, A. (1998). *Innovation management: Strategies, Implementation and Profits*. New York: Oxford University Press.
2. Aminian, F., Suarez, E. D., Aminian, M., & Walz, D.T. (2006). Forecasting Economic data with Neural Network. *Computational Economics*, 28(1), 71-88.
3. Batagelj, T. (2003). *Napoved porabe električne energije z nevronske mreže* (diplomsko delo). Ljubljana: Ekonomska fakulteta.
4. Blas, M. (2002). *Schumpetrova analiza kapitalističnega razvoja* (diplomsko delo). Ljubljana: Ekonomska fakulteta.
5. Bresjanac, M. (2008, 15. marec). Prirojeno in pridobljeno v razvoju in delovanju možganov. Najdeno 30. oktobra 2014 na spletnem naslovu <http://www.zrss.si/bzid/geni/pdf/bresjanac-clanek.pdf>
6. Cekin. (2009). Kreditna sposobnost. Najdeno 30. oktobra 2014 na spletnem naslovu <http://cekin.si/clanek/slovar/kreditna-sposobnost.html>
7. Devetak, G. (2000). *Temelji trženja in trženjska zasnova podjetja*. Koper: Visoka šola za management.
8. Dobnikar, A. (1990). *Nevronske mreže: teorija in aplikacije*. Radovljica: Didakta.
9. Dobre, R. (2004). *Inovacije i tehnološke strategije*. Šibenik: Visoka škola za turistički management.
10. Dubrovski, D. (2006). *Management mednarodnega poslovanja*. Koper: Fakulteta za management.
11. Guid, N., & Strnad, D. (2007). *Umetna inteligenca*. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko.
12. Hafner, J. (1999). *Integracija GIS-a in umetne inteligence v geologiji* (doktorska disertacija). Ljubljana: Naravoslovna tehniška fakulteta.
13. Hanke, E.J., & Reitsch, B.A. (1995). *Business forecasting* (5th ed.). Upper Saddle River: Prentice Hall.
14. Hann, T. H., & Steurer, E. (1996). Much ado about nothing? Exchange rate forecasting, Neural networks vs. Linear model using monthly and weekly data. *Journal of Neurocomputing*, 10(4), 323-339.
15. Hubbard, T. L. (1996). The importance of a consideration of qualia to imagery and cognition. *Consciousness & Cognition*, 5(3), 327-358.
16. Inštitut Jožef Štefan. (1999). *Informacijska združba 1999*. Ljubljana: Zbornik mednarodne multikonference.
17. Jamšek, J. (2000). *Predikcija vrednosti delnice z nevronske mreže* (diplomsko delo). Ljubljana: Ekonomska fakulteta.
18. Jingtao, Y. (2000). A case study on using neural networks to perform technical analysis of forex. *Journal of Neurocomputing*, 34(1), 79-98.
19. Joiron, P. (1997). *Comparison of Interest Rate Risk measurement models*. Praga: Charles University.

20. Kamruzzaman, J., Sarker, A. R., & Rezaul, B. (2006). *Artificial neural networks, applications in finance and manufacturing*. Hershey: Idea Group Inc.
21. Kendall, R. (1998). *Risk Management for Executives*. London: Pitman Publishing.
22. Kim, Y.S., & Sohn, Y.S. (2004). Managing loan customers using misclassification patterns of credit scoring model. *Expert System with Applications*, 26(4), 567-573.
23. Kokol, P., Hlebič, B. Š., Podgorelec, V., & Zorman, M. (2001). *Inteligentni sistemi*. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko.
24. Kononenko, I. (1997). *Strojno učenje*. Ljubljana: Fakulteta za računalništvo in informatiko.
25. Kos, M. (1999). *Razvoj modela za obvladovanje proizvodne dokumentacije* (diplomsko delo). Ljubljana: Fakulteta za strojništvo.
26. Krapež, A., & Rajkovič, V. (2003). *Tehnologije znanja pri predmetu informatika*. Ljubljana: Zavod Republike Slovenije za šolstvo.
27. Krošlin, T. (2004). *Vpliv dejavnikov invencijsko – inovacijskega potenciala na uspešnost podjetij* (magistrsko delo). Maribor: Ekonomsko –poslovna fakulteta.
28. Likar, B. (2001). *Inoviranje*. Koper: Visoka šola za management.
29. Likar, B., Antunovič, P., Berginc, J., Černjak D.S., Demšar, J., Fatur, P., Križaj, D., Mulej, M.M Pečjak, V., Sitar, S., Trček, D., Trunk-Širca, N., Ženko, Z., Kmecl, G., & Horjak, C. (2002). *Uspeti z idejo!. Tehnike in metode ustvarjanja, razvoja in trženja idej*. Ljubljana: Korona plus.
30. Ljubič, T. (2008). *Predvidevanje in napovedovanje v oskrbovalni verigi*. Kranj: Moderna organizacija.
31. Možina, S., Jaklič, M., Kovač, J., Ivanko, Š. & Šek-Mertük, P. (2006). *Menedžment znanja: znanje, kot temelj razvoja: na poti k učečemu se podjetju*. Maribor: Pivec.
32. Mramor, K. (2007). *Nevronske mreže* (interno gradivo). Ljubljana: Fakulteta za matematiko in fiziko.
33. Mulej, M., & Ženko, Z. (2002). Osnove za taktiko pospeševanja inventivnosti in inovativnosti v slovenskih regijah. *Od invencije do inovacije* (str. 12-40). Ljubljana: PCMG – Pospeševalni center za malo gospodarstvo.
34. Mulej, M., & Ženko, Z. (2004). *Dialektična teorija sistemov in invencijsko – inovacijski management*. Maribor: Ekonomsko-poslovna fakulteta.
35. Mulej, M. (2007). *Inoviranje navad države in manjših podjetij z invencijami iz raziskovalnih organizacij*. Koper: Fakulteta za management.
36. Mulej, M., Fatur, P., Knez-Riedl, J., Kokol, A., Mulej N., Potočan, V., Prosenak, D., Škafar, B., Ženko, Z., Likar, B., & Kajzer, Š. (2008). *Invencijsko-inovacijski management z uporabo dialektične teorije sistemov* (podlaga za uresničitev ciljev Evropske unije glede inoviranja). Maribor: Ekonomsko poslovna fakulteta.
37. O'Brien, J. (1999). *Introduction to information system*. Boston: Richard D. Irwin, a Times Mirror Higher Education Group.
38. Peruš, M. (2001). *Biomreže, mišljenje in zavest*. Maribor: Satjam.
39. Pham, D. C., & Liu, X. (1995). *Neural network for Identification Prediction and Control*. London: Springer.

40. Potočnik, V. (2002). *Nabavno poslovanje s primeri iz prakse*. Ljubljana: Ekonomska fakulteta.
41. Potočnik, V. (2005). *Temelji trženja: s primeri iz prakse*. Ljubljana: GV Založba.
42. Potočnik, B. (2007). *Osnove razpoznavanja vzorcev z nevronskimi mrežami*. Maribor: Fakulteta za elektrotehniko, računalništvo in informatiko.
43. Pretnar, B. (1995). *Osnove ekonomske tehnologije*. Ljubljana: Ekonomska fakulteta.
44. Puharič, K. (1995). *Gospodarsko pravo z osnovami prava*. Ljubljana: Uradni list Republike Slovenije.
45. Rakočević, G. M. (2014). *Mašinsko učenje u bežičnim senzorskim mrežama* (doktorska disertacija). Beograd: Elektrotehnički fakultet.
46. Rems, A., & Škrjanc, M. (2001). Inteligentni sistemi za odobravanje kreditov. *Zbornik desete Elektrotehniške in računalniške konference ERK* (str. 201-204). Ljubljana: IEEE Region 8.
47. Samuelson, P.A., & Nordhaus, W.D. (2002). *Ekonomija*. Ljubljana: GV Založba.
48. Tavčar, M. (2002). *Starteški management*. Koper: Visoka šola za management; Maribor: Ekonomsko-poslovna fakulteta.
49. Turban, E., Mclean, E., & Wetherbe, J. (1996). *Information Technology for Management*. New York: John Wiley & Sons Inc.
50. Vadnjal, J. (b.l.). Invencija, inovacija, potencialna inovacija, nič od naštetega? Najdeno 30. oktobra 2014 na spletnem naslovu <http://www.mestomladih.si/spodbujamo-inovativnost/invencija-inovacija-potencialna-inovacija-nic-od-nastetega/104>
51. Zidar, A. (2009). *Nevronske mreže kot modeli za napoved prodaje prehrambnih dobrin* (magistrsko delo). Koper: Fakulteta za management.
52. Zidar, A., & Biloslavo, R. (2010). Nevronske mreže kot nova metoda za reševanje poslovnih problemov in možnosti uporabe v managementu. *Management*, 5(3), 279-291.
53. Zhang, G., Patuwo, B.E., & Hu, M.Y. (1998). Forecasting whit articial neural networks: The state of art. *International Journal of Forecasting*, 14(1), 35-62.
54. Zupan, J. (1994). Introduction to artificial neural networks (ANN) methods: what they are and how to use them. *Acta chimica slovenica*, 41(3), 327-352.
55. Witkowska, D. (2006). Discrete Choice Models Application to the Credit Risk Evaluation. *International Advances in Economics Research*, 12(1), 33-42.