

Univerza
v Ljubljani
Fakulteta
*za gradbeništvo
in geodezijo*

*Janova 2
1000 Ljubljana, Slovenija
telefon (01) 47 68 500
faks (01) 42 50 681
fgg@fgg.uni-lj.si*



26207099

Kandidat:

Matjaž Mlakar

Napovedovanje premikov pri plazenju tal z umetnimi nevronskimi mrežami RBF

Diplomska naloga št.: 851

Mentor:

izr. prof. dr. Tomaž Ambrožič

Somentor:

izr. prof. dr. Janko Logar

Ljubljana, 2010

STRAN ZA POPRAVKE, ERRATA

Stran z napako	Vrstica z napako	Namesto	Naj bo
-----------------------	-------------------------	----------------	---------------

IZJAVA O AVTORSTVU

Podpisani **MATJAŽ MLAKAR** izjavljam, da sem avtor diplomske naloge z
naslovom: »**Napovedovanje premikov pri plazenju tal z umetnimi nevronskimi mrežami
RBF**«.

Izjavljam, da se odpovedujem vsem materialnim pravicam iz dela za potrebe elektronske
separatoteke FGG.

Ljubljana,

.....

BIBLIOGRAFSKO – DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK:

Avtor: Matjaž Mlakar

Mentor: izr. prof. dr. Tomaž Ambrožič

Somentor: izr. prof. dr. Janko Logar

Naslov: Napovedovanje premikov tal pri plazenju z umetnimi nevronskimi mrežami RBF

Obseg in oprema: 72 str., 7 preg., 44 sl., ___ en.

Ključne besede: Macesnikov plaz, umetna nevronska mreža, RBF, geodetske meritve, premiki, padavine, analiza

Izveček:

Diplomska naloga predstavlja možnost uporabe umetnih nevronskih mrež pri napovedovanju premikov pri plazenju tal. Premiki plazov so odvisni od mnogih dejavnikov (padavine, topografija, geologija, materialne lastnosti, ...), zato jih je težko napovedati. Povezave med premiki, padavinami, temperaturami in inklinacijo terena so preveč kompleksne, da bi jih opisali z matematičnimi formulami. Zato jih poskusimo opisati z umetnimi nevronskimi mrežami. V nalogi najprej predstavimo Macesnikov plaz, kjer so bile izvedene meritve. V nadaljevanju opišemo dosedanja opazovanja Macesnikovega plazu in analiziramo vpliv padavin na plazenje zemljin. Sledi predstavitev umetnih nevronskih mrež, razdelitev umetnih nevronskih mrež, kriteriji razdelitve umetnih nevronskih mrež in podrobna razložitev radialnih bazičnih umetnih nevronskih mrež. V eksperimentalnem delu je prikazana uporaba radialnih bazičnih umetnih nevronskih mrež pri napovedovanju plazenja zemljin. Za vhodne podatke smo uporabili meritve padavin, za izhodne pa premike plazenja zemljine. Cilj je dobiti naučeno umetno nevronska mrežo, ki bi jo lahko uporabili za napovedovanje premikov v praksi. Za izračun uporabimo dve različni programski opremini – Matlab R2007b in Neurosolutions, katerih rezultate primerjamo med seboj. Na koncu podamo zaključek, ki vsebuje kratek povzetek vseh glavnih ugotovitev.

BIBLIOGRAPHIC – DOCUMENTALISTIC INFORMATION

UDC:

Author: Matjaž Mlakar

Supervisor: assist. prof. dr. Tomaž Ambrožič

Cosupervisor: assist. prof. dr. Janko Logar

Title: The prediction of landslide movements with RBF artificial neural networks

Notes: 72 p., 7 tab., 44 fig., ___ eq.

Key words: Macesnik's landslide, artificial neural network, RBF, geodetic measurements, movements, rainfall, analysis

Abstract

The thesis deals with the problem of the prediction of landslide movements with artificial neural networks (ANN). Landslide movements are dependent on many parameters (rainfall, topography, geology, material, ...), what makes them hard to predict. The links between movements, rainfall, temperature and surface inclination are too complex to define them with mathematical equations. That is why we use artificial neural networks. In the beginning we describe the Macesnik landslide, where the observations took place. We continue with the description of previous observations on the Macesnik landslide and we analyze the influence of rainfall on movements of the landslide. Next, we describe artificial neural networks, distribution of the artificial neural networks, the criteria of distributing artificial neural networks and present a detail description of the radial basis function (RBF) neural networks. In the experimental part we have presented the use of artificial neural networks for the prediction of landslide movements. For input and output data we have used the measurements of rainfall and measured movements of the landslide, respectively. Our goal is to find a artificial neural network, which could be used for landslide movement prediction in the future. For the calculation we used two different softwares – Matlab R2007b and Neurosolutions. At the end conclusions are given, which include a short summary of all major findings.

ZAHVALA

Iskreno se zahvaljujem mentorju izr. prof. dr. Tomažu Ambrožiču in somentorju izr. prof. dr. Janku Logarju za spodbudo, pomoč in strokovne nasvete pri nastajanju diplomske naloge.

Posebna zahvala gre Bogdanu Jančiču, ki mi je posredoval vse potrebne podatke o meritvah na Macesnikovem plazu in rezultate predhodnih raziskav.

Za motivacijo med pisanjem diplomske naloge se zahvaljujem puncu Naji, sodelavcem iz podjetja Nivo d.d ter mojim staršem, ki so me podpirali v času študija.

KAZALO VSEBINE

1 UVOD	I
2 PREDSTAVITEV MACESNIKOVEGA PLAZU	2
2.1 Opis Macesnikovega plazu	2
2.2 Vpliv padavin na plazenje	5
2.3 Vpliv naklona terena na plazenje	2
2.4 Terminski plan meritev	6
2.5 Način meritev	7
3 MERJENJE KOLIČINE PADAVIN	11
4 UMETNE NEVRONSKE MREŽE	16
4.1 Zgodovina umetnih nevronske mrež	17
4.2 Sestava biološkega nevrona	18
4.3 Sestava umetnega nevrona	19
4.4 Umetna nevronska mreža	23
4.4.1 Kriteriji razdelitve umetnih nevronske mrež	23
4.4.1.1 Tip vhodnih podatkov	24
4.4.1.2 Arhitektura umetnih nevronske mrež	24
4.4.1.3 Usmerjenost povezav	25
4.4.1.4 Tehnike učenja umetnih nevronske mrež	26
4.4.1.5 Pravila učenja umetnih nevronske mrež	27
4.4.2 Razdelitev umetnih nevronske mrež	28
4.4.3 Prednosti in slabosti umetnih nevronske mrež	29
4.4.4 Podatki umetnih nevronske mrež	31
4.5 Ocenjevanje kakovosti rezultatov umetnih nevronske mrež	31

4.6 Radialne bazične umetne nevronske mreže RBF	32
4.6.1 Arhitektura radialne bazične umetne nevronske mreže	32
4.6.2 Algoritem učenja radialne bazične umetne nevronske mreže	34
5 EKSPERIMENTALNI DEL	16
5.1 Uporabljena programska oprema	36
5.1.1 RBF.m	36
5.1.2 Neurosolutions	37
5.2 Vhodno-izhodni podatki	41
5.3 Učenje umetne nevronske mreže z enim podatkom v vhodnem sloju - časovnim intervalom od ničelne meritve	44
5.4 Učenje umetne nevronske mreže z dvema vhodnima podatkom	46
5.5 Učenje umetne nevronske mreže s tremi vhodnimi podatki	48
5.5.1 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in enim v izhodnem sloju	48
5.5.2 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in tremi v izhodnem sloju	49
5.5.3 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in štirimi v izhodnem sloju	55
5.5.4 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in petimi v izhodnem sloju	58
5.5.5 Učenje umetne nevronske mreže s štirimi nevroni v vhodnem in petimi v izhodnem sloju	63
6. ZAKLJUČEK	70
VIRI	74

KAZALO PREGLEDNIC

Preglednica 1: Osnovni podatki Macesnikovega plazju (Majes, 2000)	2
Preglednica 2: Čas meritev in merjeni profili sklopa 1	6
Preglednica 3: Čas meritev in merjeni profili sklopa 2	7
Preglednica 4: Mesečna količina padavin izmerjena v padavinski postaji Solčava (ARSO, 2005)	11
Preglednica 5: Nekaj vrstic datoteke s podatki o padavinah	42
Preglednica 6: Nekaj vrstic datoteke s podatki o točki 602	43
Preglednica 7: Tabelarični prikaz spreminjanja nadmorske višine točke 603 v odvisnosti od količine padavin	73

KAZALO SLIK

Slika 1: Lega Macesnikovega plazu (Google maps 2010)	3
Slika 2: Državna, tako imenovana Panoramska cesta prečka Macesnikov plaz pod Olševo (foto: M. Zorn)	4
Slika 3: Macenikov plaz, čelni del (www.gore-ljudje.net)	4
Slika 4: Grafični prikaz postavitve merskih profilov za območje Macesnikovega plazu (IRGO consulting d.o.o.)	8
Slika 5: Primer analize meritev in izračun pomikov (IRGO consulting d.o.o.)	9
Slika 6: Grafični prikaz pomikov z vektorji (IRGO consulting d.o.o.)	10
Slika 7: Grafični prikaz mesečne količine padavin	12
Slika 8: Koeficient korelacije med zapoznelim vplivom 30 dnevni padavin na hitrost plazanja (Križnič, 2006)	12
Slika 9: Koeficient korelacije med padavinami in hitrostjo premikanja ob upoštevanju širšega intervala padavin ter 30 dnevnega zamika vpliva padavin (Križnič 2006)	14
Slika 10: Shematski prikaz nevrona (Culverco, 2002)	18
Slika 11: Sestava splošnega umetnega nevrona (http://slo-tech.com/forum/t304089)	19
Slika 12: Stopničasta aktivacijska funkcija (http://slo-tech.com/forum/t304089)	20
Slika 13: Sigmoidna aktivacijska funkcija (http://slo-tech.com/forum/t304089)	21
Slika 14: Radialna aktivacijska funkcija (http://slo-tech.com/forum/t304089)	22
Slika 15: Nevroni z radialno aktivacijsko funkcijo (http://slo-tech.com/forum/t304089)	23
Slika 2: Dvoslojna umetna nevronska mreža (Derenda, 2007)	25
Slika 37: Trislojna umetna nevronska mreža (Derenda, 2007)	25
Slika 18: Prikaz Gaußove in linearne aktivacijske funkcije (Derenda, 2007)	33
Slika 19: Arhitektura radialne bazične umetne nevronske mreže (Derenda, 2007)	33
Slika 20: Prikaz večje in manjše vrednosti parametra »spread« na Gaußovi aktivacijski funkciji (Derenda, 2007)	35
Slika 21: Programsko okolje Neurosolutions	38
Slika 22: Programsko okolje Neurosolutions for matlab	39
Slika 23: Vhodno-izhodni pari podatkov	40
Slika 24: Graf uspešnosti testiranja	40

Slika 25: Vhodno–izhodna para učenja in odgovarjajoča rezultata testiranja	41
Slika 26: Grafični prikaz napovedovanja koordinate Y z naučeno umetno nevronske mrežo za točko 803 pri enem vhodnem podatku (število dni od dneva meritev) in treh izhodnih podatkih (Y, X, H)	44
Slika 27: Grafični prikaz napovedovanja koordinate X z naučeno umetno nevronske mrežo za točko 803 pri enem vhodnem podatku (število dni od dneva meritev) in treh izhodnih podatkih (Y, X, H)	45
Slika 28: Grafični prikaz napovedovanja koordinate H z naučeno umetno nevronske mrežo za točko 803 pri enem vhodnem podatku (število dni od dneva meritev) in treh izhodnih podatkih (Y, X, H)	45
Slika 29: Grafični prikaz napovedovanja koordinate Y z naučeno umetno nevronske mrežo za točko 803 pri dveh vhodnih podatkih (število dni od dneva meritev, padavine za 90 dni nazaj) in treh izhodnih podatkih (Y, X, H)	46
Slika 30: Grafični prikaz napovedovanja koordinate X z naučeno umetno nevronske mrežo za točko 803 pri dveh vhodnih podatkih (število dni od dneva meritev, padavine za 90 dni nazaj) in treh izhodnih podatkih (Y, X, H)	47
Slika 31: Grafični prikaz napovedovanja koordinate H z naučeno umetno nevronske mrežo za točko 803 pri dveh vhodnih podatkih (število dni od dneva meritev, padavine za 90 dni nazaj) in treh izhodnih podatkih (Y, X, H)	47
Slika 32: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in enem izhodnem podatku (hitrost premika točke v prostoru – v_{XYH})	49
Slika 33: Grafični prikaz napovedovanja hitrosti premikanja točke po koordinatnih oseh z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih podatkih (hitrost premika točke po smereh v_Y, v_X in v_H)	51
Slika 34: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 604 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih podatkih (hitrosti po osi – v_H , ravnini – v_{XY} in prostoru – v_{XYH}). Uporabljena programska oprema je bila Neurosolutions	53

Slika 35: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 604 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih podatkih (hitrosti po osi – v_H , ravnini – v_{XY} in prostoru – v_{XYH}). Uporabljena programska oprema je bila Matlab R2007b 54

Slika 36: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in štirih izhodnih podatkih (hitrosti po oseh v_X , v_Y , v_H in prostoru – v_{XYH}). Uporabljena programska oprema je bila Neurosolutions 56

Slika 37: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in štirih izhodnih podatkih (hitrosti po oseh v_X , v_Y , v_H in prostoru – v_{XYH}). Uporabljena programska oprema je bila Matlab R2007b 58

Slika 38: Grafični prikaz napovedovanja hitrosti premikanja točke z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih (hitrosti po oseh v_X , v_Y , v_H , ravnini – v_{XY} in prostoru – v_{XYH}). Uporabljena programska oprema je bila Neurosolutions 60

Slika 39: Grafični prikaz napovedovanja hitrosti premikanja točke z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih (hitrosti po oseh v_X , v_Y , v_H , ravnini – v_{XY} in prostoru – v_{XYH}). Uporabljena programska oprema je bila Matlab 62

Slika 40: Grafični prikaz napovedovanja hitrosti premikanja točke z naučeno umetno nevronske mrežo za točko 603 pri štirih vhodnih podatkih (časovni interval od ničelne meritve, padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih (Gauß-Krügerjeve koordinate y , x , H , premik v ravnini d_{xy} in premik v prostoru d_{xyH}). Uporabljena programska oprema je bila Neurosolutions 64

Slika 41: Grafični prikaz napovedovanja hitrosti premikanja točke z naučeno umetno nevronske mrežo za točko 603 pri štirih vhodnih podatkih (časovni interval od ničelne meritve, padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih (Gauß-Krügerjeve koordinate y , x , H , premik v ravnini d_{xy} in premik v prostoru d_{xyH}). Uporabljena programska oprema je bila Matlab R2007b 66

Slika 42: Grafični prikaz 2D (ravnina XY) položaja točke oz. premika točke, dobljenega iz koordinat, merjenih na Macesnikovem plazu in premika točke dobljenega iz koordinat, izračunanih z učeno umetno nevronske mreže. Premike smo napovedovali za 1. in 2. naslednjo meritev po učnih vhodno–izhodnih parih. Primerjava je narejena za profil 6 in točko 603 67

Slika 43: Grafični prikaz višinskega premika točke v smeri osi H, dobljenega iz koordinat, merjenih na Macesnikovem plazu in višinskega premika točke, dobljenega iz napovedi z naučeno umetno nevronske mreže. Premike smo napovedovali za 1. in 2. naslednjo napoved po učnih vhodno–izhodnih parih. Primerjava je narejena za profil 6 in točko 603 68

Slika 44: Grafični prikaz višinskega premika točke v smeri osi H, dobljenega iz koordinat, merjenih na Macesnikovem plazu in višinskega premika točke, dobljenega iz napovedi z naučeno umetno nevronske mreže. Zadnja meritev predstavlja nihanje nadmorske višine točke v odvisnosti od količine padavin. Količino padavin smo predstavili z intervalom od 30 do 300 mm padavin. Primerjava je narejena za profil 6 in točko 603. Uporabljena programska oprema je bila Matlab 72

Slika 44: Primerjava rezultatov umetne nevronske mreže RBF in umetne nevronske mreže z vzvratnim razširjanjem napake. Primerjava je narejena za profil 6 in točko 603 70

1 UVOD

Diplomska naloga predstavlja možnost uporabe umetnih nevronskih mrež pri napovedovanju plazenja zemljin. V praksi bi pravilno napovedovanje premikov omogočalo pravočasno ukrepanje odgovornih za reševanje ljudi in njihovega premoženja. Podatki v nalogi se nanašajo na Macesnikov plaz, ki se stalno giba in širi. Hitrost gibanja plazov je odvisna od intenzitete padavin na vplivnem območju. V tej nalogi posegamo na področje interpretacije podatkov, pridobljenih z dvema različnima vrstama meritev na plazovih in sicer kontrolne meritve premikov točk na površini in količina padavin, ter jih prikažemo kot vhodno–izhodne pare pri učenju umetnih nevronskih mrež, saj običajno padavine odločilno vplivajo na obnašanje plazu.

Premiki plazov so odvisni od mnogih dejavnikov (padavine, topografija, geologija, materialne lastnosti,...), zato jih je težko napovedati. Povezave med premiki in padavinami, temperaturami in inklinacijo terena so preveč kompleksne, da bi jih opisali z enostavnimi matematičnimi zvezami. Zato uporabimo umetne nevronske mreže. Z znanimi vhodnimi (padavine) in izhodnimi (koordinate, premiki, hitrosti) podatki umetno nevronske mreže naučimo napovedovati premike, ne da bi poznali vse vplivne dejavnike in odvisnosti med njimi.

Vsebinsko se diplomska naloga deli na naslednje sklope:

1. uvod, ki zajema kratek opis in vsebino naloge;
2. predstavitev Macesnikovega plazu;
3. merjenje količine padavin;
4. umetne nevronske mreže;
5. eksperimentalni del;
6. zaključek, ki vsebinsko povzema vse glavne ugotovitve diplomske naloge.

2 PREDSTAVITEV MACESNIKOVEGA PLAZU

2.1 Opis Macesnikovega plazu

V naslednji Preglednici podajamo nekaj osnovnih podatkov o Macesnikovem plazu.

Preglednica 1: Osnovni podatki Macesnikovega plazu (Majes, 2000)


Višinsko območje	1040 – 800 m.n.v.
Dolžina	2500 m
Širina	do 80 m
Debelina plazine	10 – 30 m
Prostornina	> 2.000.000 m ³

Macesnikov plaz se intenzivneje spremlja od leta 1990, ko se je v jesenskih poplavah sprožilo veliko število plazov v Savinjski dolini, med njimi tudi Macesnikov plaz. V letu 1992 so se pričele geološke preiskave in študije sanacije. Predlagano je bilo površinsko odvodnjavanje na robovih plazu in geodetsko spremljanje premikov. Novembra leta 2000 se je premikanje plazu pospešilo.

Leta 1992 je bila dolžina plazu okrog 1100 m, povprečna širina 50 m, površina plazu 5,5 ha, volumen okrog 600.000 m³. Leta 2000 so se dimenzije občutno povečale, kar je razvidno iz zgornje preglednice. Plaz se premika na površini okoli 100 m letno. Zgornji del plazu je relativno plitek, spodnji del pa globok okoli 20 m (Majes, 2000).

Macesnikov plaz predstavlja del starejšega, precej večjega fosilnega plazu, ki je nastal pred več kot 100 leti. Aktivni plaz predstavlja le zgornji del mnogo večjega fosilnega plazu (širina do 350 m). Plazina je sestavljena iz gline z več ali manj grušča, v spodnjih legah iz zaglinjenega grušča. V zgornjem delu se pojavljajo številni izviri in zamočvirjene cone. Voda se vzdolž plazu združuje v potoke. Nivo podtalnice je blizu površine. (Majes, 2000).

Zaradi Macesnikovega plazju je neposredno ogrožena regionalna cesta Solčava – Črna. Z možnim nadaljnjim širjenjem pa bi ogrozil tudi nižje ležeče stanovanjske in gospodarske objekte ter infrastrukturo.



Slika 1: Lega Macesnikovega plazju (Google maps, 2010)

Od čela plazju so najbližji objekti oddaljeni le približno 250 m, vas Solčava pa je oddaljena le 1 km. Macesnikov plazju je zaradi obsežnih raziskav in relativno dolgega obdobja opazovanja zelo primeren za obravnavo z umetnimi nevronskimi mrežami. Rezultati opazovanja plazju so pokazali nihanje hitrosti plazenja vzdolž plazju ter sezonska nihanja. Vzdolž plazju se spreminja tudi globina drsine ter nivo podzemne vode.



Slika 2: Državna, tako imenovana Panoramska cesta prečka Macesnikov plaz pod Olševo (foto: M. Zorn)



Slika 3: Macenikov plaz, čelni del (www.gore-ljudje.net)

2.2 Vpliv padavin na plazenje

Glavni povodi za nastanek pobočnih procesov so vremenska dogajanja, med katere štejemo ekstremne padavine, nenaden dvig podtalnice in poplave (Križnič, 2006).

Problem je spremenjeni vzorec razporeditve padavin, ko v sicer povprečnem hidrološkem letu prihaja do zelo intenzivnih kratkotrajnih neviht, toplih zim z malo snežnimi padavinami in vmesnih dolgotrajnih obdobj deževja ob sicer ne bistveno spremenjeni letni količini padavin. Povprečna letna količina padavin zato neposredno ne vpliva na plazenje oziroma vpliva le v kombinaciji s kratkotrajnimi intenzivnimi padavinami.

Obilica vode premoči preperino, to povzroča vzgonski tlak in zmanjša medzrnske sile vzdolž drsne ploskve. Zaradi tega se poruši ravnovesje na pobočju in poveča možnost zdrsa. Začetna lega podtalnice ima pomembno vlogo, saj vpliva na potrebno mejno količino padavin.

V zgornjem delu plazu imajo največji vpliv dvomesečne količine padavin. V spodnjem delu plazu je vpliv padavin manjši. V določenih območjih je očiteno vpliv zamika padavin, kar kaže na dotok vode iz podzemnih dotokov v plazino. Vpliv spremembe količine padavin na spremembo hitrosti je manjši. Razlog so padavine, ki delujejo kot sprožilec premikanja plazu, nadaljnji razvoj pa je odvisen tudi od drugih vplivnih dejavnikov.

2.3 Vpliv naklona terena na plazenje

Le v zgornjem delu plazu, kjer največje hitrosti plazenja sovpadajo z največjimi nakloni, naklon odločujoče vpliva na hitrost plazenja. Podobno velja tudi za najnižje hitrosti in najmanjše naklone. V ostalih delih plazu pa naklon ni več odločilen dejavnik (Križnič, 2006).

Gibanje plazu je v veliki meri odvisno od same oblikovanosti terena, kjer poteka plazenje. Primerjava masnih pretokov plazine je pokazala manjše razlike v spodnjem delu plazu, kot so kazale hitrosti gibanja. Naraščanje masnega pretoka v zgornjem delu plazu je posledica pritoka materiala iz številnih stranskih krakov plazu. Kjer je plaz najožji in teren najbolj strm, se je razvila največja hitrost plazenja.

Generalno gledano se material v plazini vzdolž plazu veliko ne razlikuje. Manjše razlike pa so, v kombinaciji z drugimi dejavniki, verjeten vzrok različnim tipom deformacij. Viskozno plastične deformacije prevladujejo v debelejši plazini z več glinene komponente. Klasično plazanje se je razvilo v zgornjem delu plazu, kjer je večji delež grušča in tanjša plazina (Križnič, 2006).

2.4 Terminski plan meritev

Meritve je izvajalo podjetje IRGO CONSULTING d.o.o. Naročnik meritev je bila Agencija Republike Slovenije za okolje (ARSO). Meritve so bile izvedene v petih sklopih med letoma 2000 in 2006.

Sklop 1: meritve so se izvajale od 13. nov. 2000 do 21. feb. 2001 in sicer:

Preglednica 2: Čas meritev in merjeni profili sklopa 1

Začetek meritev	Konec meritev	Profili
13. 11. 2000	30. 11. 2000	P1 – P6
30. 11. 2000	11. 01. 2001	P1 – P7
11. 01. 2001	21. 02. 2001	P1 – P8

V tem sklopu meritev so izvedli 10 meritev, v štirih mesecih. Pogostost meritev je narekovala večja dinamika gibanja plazu.

Sklop 2: meritve so se izvajale od 21. 02. 2001 do 21. 12. 2001 in sicer:

Preglednica 3: Čas meritev in merjeni profili sklopa 2

Začetek meritev	Konec meritev	Profili
21. 02. 2001	22. 03. 2001	P1 – P8
22. 03. 2001	23. 07. 2001	P1 – P9
23. 07. 2001	20. 12. 2001	P1 – P10

V tem sklopu meritev so izvedli 10 meritev, enkrat mesečno.

Sklop 3: meritve so se izvajale od 21. 01. 2002 do 28. 09. 2002 v profilih od 1 do 10

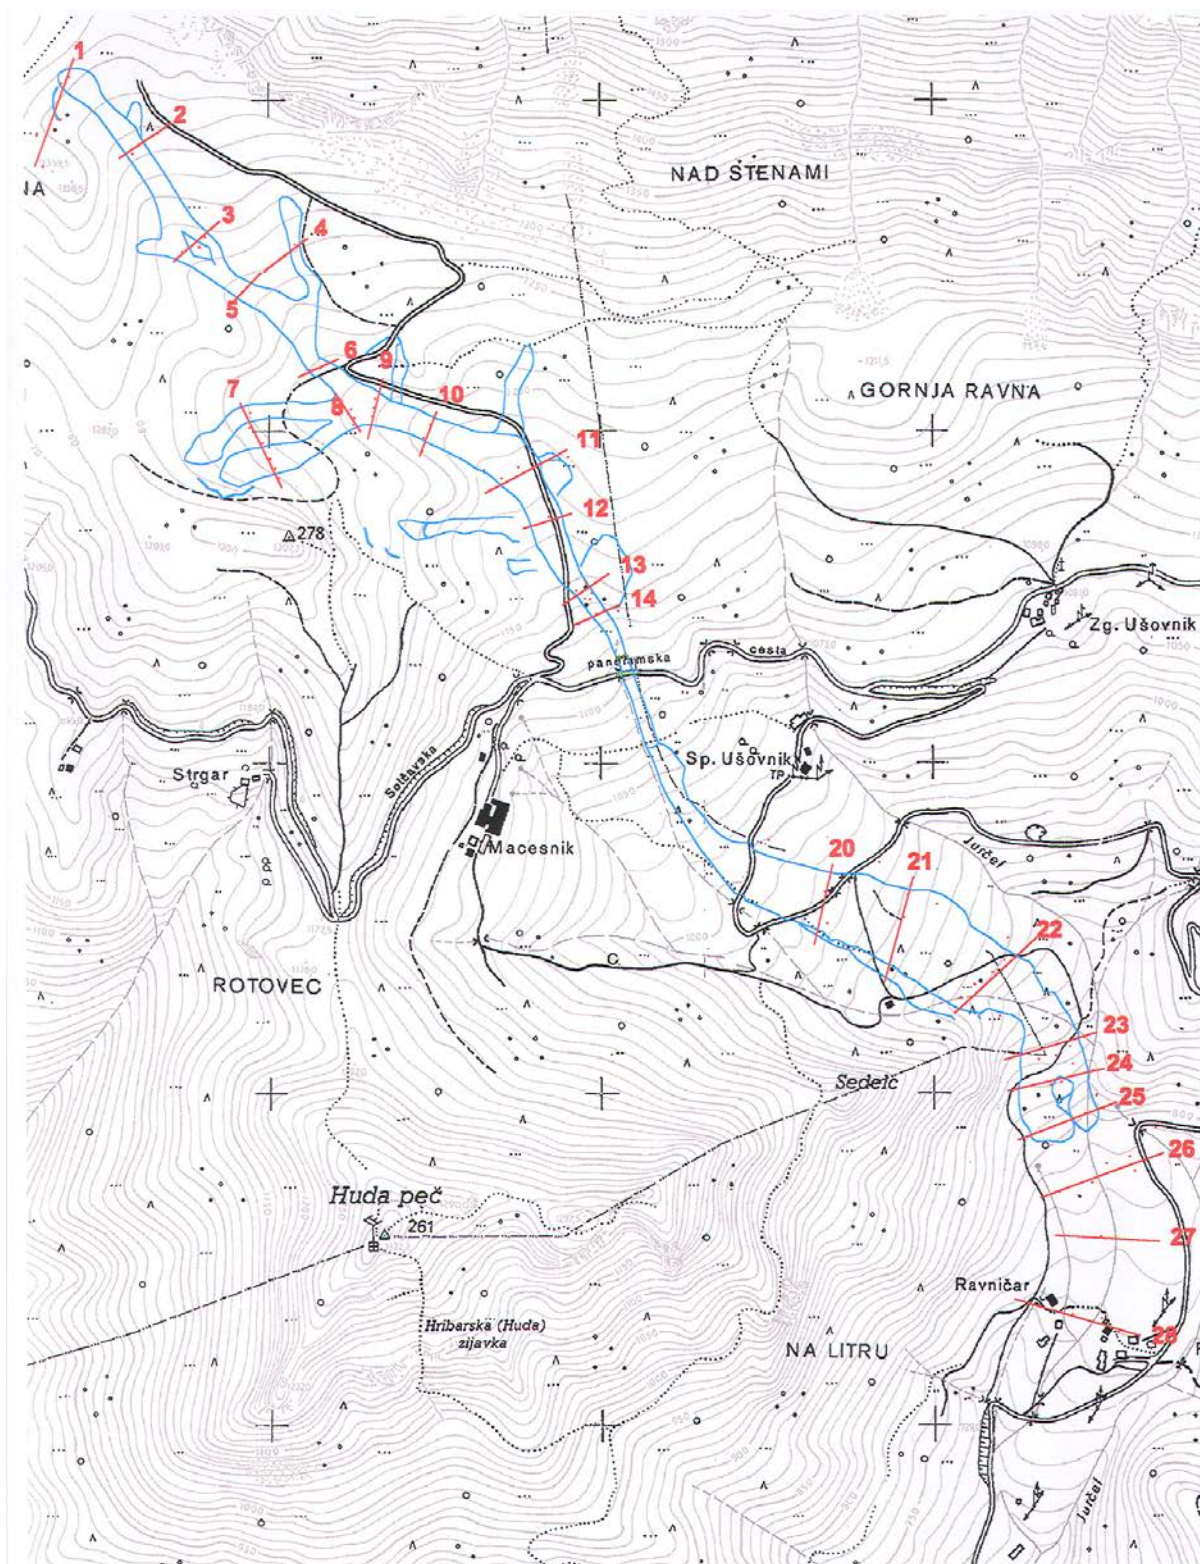
V tem sklopu meritev so izvedli 9 meritev, enkrat mesečno.

Sklop 4: meritve so se izvajale od 18. 11. 2002 do 19. 12. 2003 v profilih od 1 do 10 in sicer je bilo izvedenih 14 meritev.

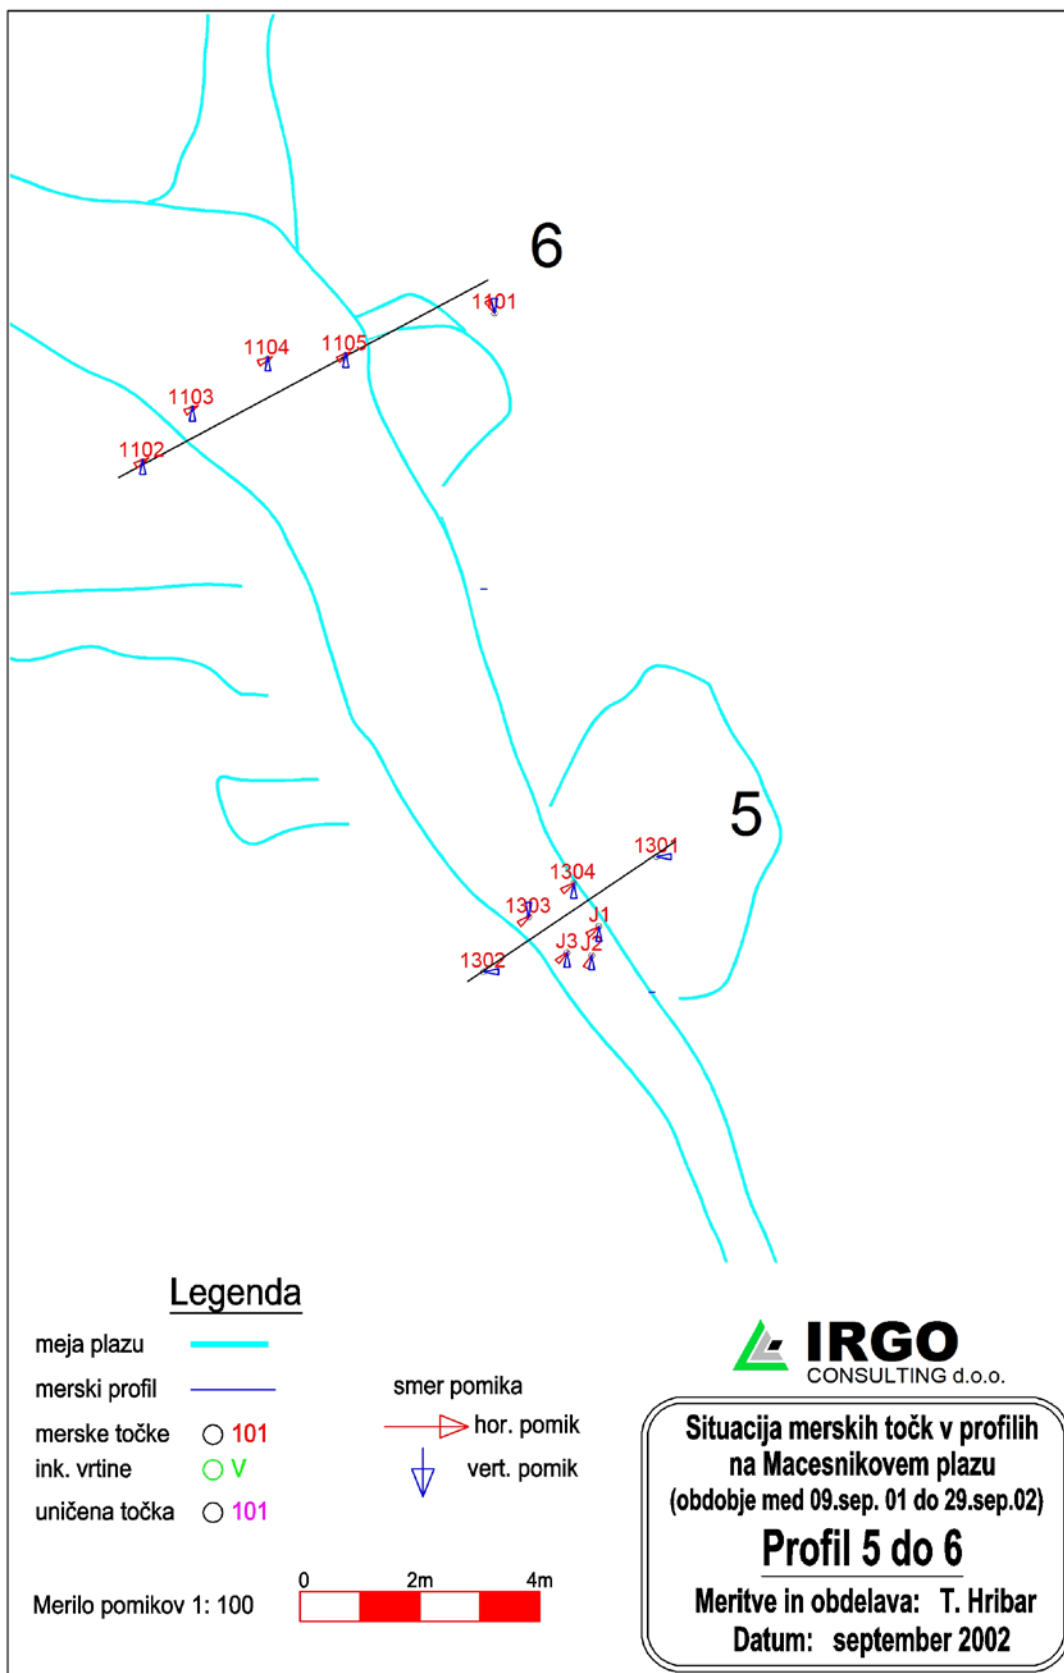
Sklop 5: meritve so se izvajale od septembra 2004 do decembra 2004 in so se nadaljevale do septembra 2006

2.5 Način meritev

Meritve so se izvajale po profilih v različnih terminih. Meritve v vsakem profilu so bile izvedene v lokalnem koordinatnem sistemu, katerega osnovni izhodišči pri vsaki seriji meritev sta bila zunanji merski točki v profilu. Predpostavili so, da so točke izven območja plazenja stabilne in se ne premikajo. Za vsak profil sta bili izhodiščni točki navezani na državni koordinatni sistem.



Slika 4: Grafični prikaz postavitve merskih profilov za območje Macesnikovega plazu (IRGO consulting d.o.o.)




Slika 6: Grafični prikaz pomikov z vektorji (IRGO consulting d.o.o.)

3 MERJENJE KOLIČINE PADAVIN

Primerjane so hitrosti premikanja kontrolnih točk, ki so bile ugotovljene z meritvami merskih profilov od novembra 2000 do decembra 2003, s količino padavin, izmerjeno v istem obdobju v padavinski postaji Solčava. Obravnavani podatki so podani v preglednici 4.


Preglednica 4: Mesečna količina padavin, izmerjena v padavinski postaji Solčava (ARSO, 2005)

Mesec	Mesečna količina padavin (mm)			
	2000	2001	2002	2003
Januar	3	129	6	69
Februar	14	17	65	29
Marec	101	203	51	5
April	121	139	177	86
Maj	148	78	81	79
Junij	130	183	148	82
Julij	191	79	139	99
Avgust	81	17	247	100
September	111	239	131	171
Oktober	289	57	150	155
November	518	55	167	241
December	109	20	61	107



Slika 7: Grafični prikaz mesečne količine padavin

V območju posameznih merskih profilov obstaja linearna povezava med mesečno količino padavin in hitrostjo plazenja (Križnič, 2006). Močna povezava je v profilih 6, 8 in 9. V ostalih profilih je povezava slabša, oziroma je sploh ni. Padavine s površinskim napajanjem plazine le v nekaterih delih plazu vplivajo na hitrost plazenja. V ostalih delih plazu pa se plazina lahko napaja iz podzemnih dotokov, kar pomeni posledično zakasnitev vpliva padavin. Na sliki 8 je prikazana analiza zamika vpliva padavin na hitrost plazenja (Križnič, 2006).



Slika 8: Koeficient korelacije med zapoznelim vplivom 30 dnevnih padavin na hitrost plazenja (Križnič, 2006)

V posameznem obdobju meritev se velikost vpliva padavin na hitrost premikanja kontrolnih točk razlikuje. Največja pozitivna povezava je v večini profilov v prvem letu meritev, v nekaterih profilih pa v drugem letu meritev. Negativna povezava pa se v skoraj vseh profilih pokaže v zadnjem letu meritev (nižje padavine vplivajo na višje hitrosti plazenja), kar je posledica vpliva sanacije plazu v drugi polovici leta 2003. Navkljub večji količini padavin v drugi polovici leta je izdelava globokih drenaž zmanjšala hitrost plazenja.

Količine 30 dnevni padavin vpliva na hitrost plazenja (slika 8). Največji, relativno močan vpliv, je v profilih 4, 5, 6, 7, 8 in 9. V ostalih profilih pa ni večje povezave med padavinami in hitrostjo.

Plazina Macesnikovega plazu je sestavljena iz slabo prepustnega materiala, podzemna voda je blizu površine in v glavnem ne niha. Pri plazovih iz takšnega materiala padavine le počasi pronicajo v globino, zato lahko pride do zapoznelega vpliva ali pa do prekrivanja vpliva večmesečnih padavin.

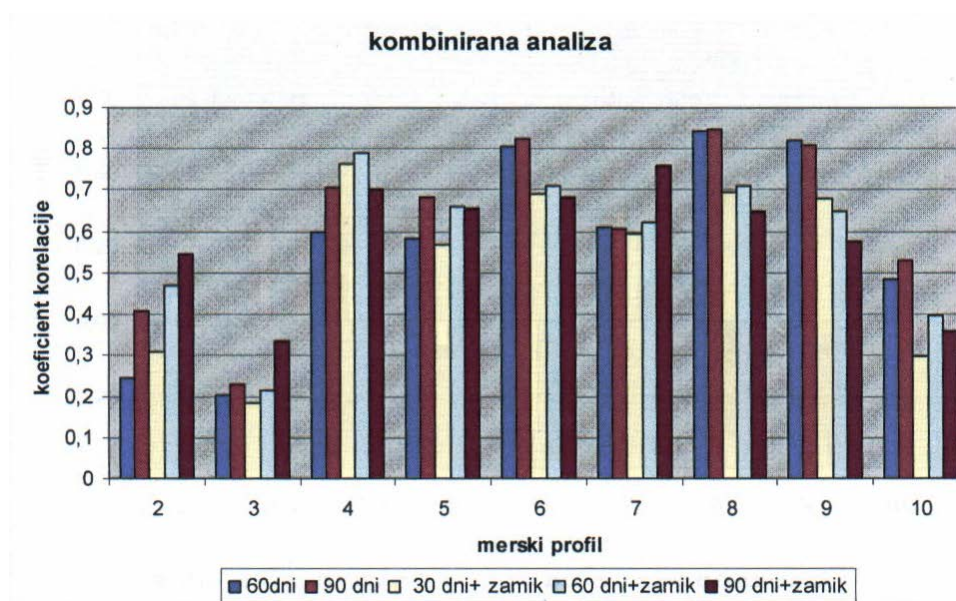
Ob upoštevanju mesečnega zamika se vpliv padavin poveča skoraj v vseh profilih. Najbolj se poveča v profilih 2, 4, 5 in 7. Upoštevanje večjega zamika ni smiselno, ker se zmanjšuje velikost vpliva v skoraj vseh profilih. Ob upoštevanju mesečnega zamika vpliva obstaja močna linearna povezava med padavinami in hitrostjo plazenja v profilih 4, 6, 8 in 9. Nekoliko šibkejša povezava je v profilih 5 in 7. V ostalih profilih je povezava zelo slaba.

Z upoštevanjem širšega intervala padavin se povečuje povezava med padavinami in hitrostjo. Največja razlika je med 30 dnevni in 60 dnevni intervalom, ko je v vseh profilih opazna večja linearna povezava. 90 dnevni interval padavin pokaže še večjo povezavo, a razlika ni tako velika. Intervalov, daljših od 90 dni, ni več smiselno upoštevati, ker so v večini profilov le minimalne spremembe velikosti vpliva, v nekaterih pa se vpliv celo zmanjša.

V določenih območjih plazu obstaja linearna povezava med količino padavin in hitrostjo premikanja plazu. Ob upoštevanju daljšega dvo- ali trimesečnega intervala padavin je povezava še močnejša in v profilih 6, 8 in 9 doseže korelacijski koeficient vrednost prek 0.8. V profilih 4, 5 in 7 je povezava nekoliko manj izrazita, korelacijski koeficient se giblje med

0.6 in 0.7. V profilih 2, 3 in 10 ni močne povezave med količino padavin in hitrostjo plazenja. Da je dvomesečni interval verjetno najdaljše sprejemljivo obdobje za računanje vpliva padavin, pove majhna razlika med koeficientom dvo- in trimesečnega intervala padavin v večini merskih profilih.

Analiza vpliva padavin na hitrost je pokazala, da se vpliv povečuje bodisi z upoštevanjem 30 dnevnega zamika ali pa z upoštevanjem daljšega, 60 ali 90 dnevnega časovnega intervala količine padavin. Na sliki 9 je predstavljena kombinirana analiza. Korelacijski koeficienti so računani ob upoštevanju 30 dnevnega zamika in 60 ter 90 dnevnih intervalov padavin (Križnič, 2006).



Slika 9: Koeficient korelacije med padavinami in hitrostjo premikanja ob upoštevanju širšega intervala padavin ter 30 dnevnega zamika vpliva padavin (Križnič, 2006).

Vzdolž plazu se spreminja vpliv padavin na hitrost plazenja. V zgornjem območju plazu je vpliv večji ob daljšem intervalu padavin brez zamika. V spodnjem območju plazu pa je vpliv večji ob upoštevanju, poleg časovnega intervala, tudi zamik vpliva. Ne glede na uporabljeno metodo pa je vpliv padavin podoben v profilih 4, 5 in 7.

Poleg vpliva padavin na hitrost plazenja, je pomembno tudi ugotoviti njihov vpliv na spremembo hitrosti. Z ugotavljanjem tega vpliva je možno določiti potrebno količino padavin, ki povzroči spremembo v hitrosti plazenja.

Količina padavin ima manjši vpliv na spremembo hitrosti premikanja plazu, kot na samo hitrost plazenja (slika 9). Tako imajo 60 dnevne padavine v profilu 4 in 7 največji vpliv na spremembo hitrosti. V istih merskih profilih je tudi največji vpliv ob upoštevanju 30 dnevnega zamika padavin.

Vpliv je sicer manjši v vseh merskih profilih, posebno očitna pa je razlika v profilih 5, 6, 8 in 9, kjer so bili ugotovljeni največji vplivi med količino padavin in hitrostjo plazenja. Količina padavin pa ni odločilen dejavnik, ki vpliva na spremembo hitrosti plazenja.

Sprememba količine padavin ima večji vpliv na spremembo hitrosti, kot pa sama količina padavin. Kar pomeni, da na gibanje plazu vplivajo tako dnevne (ali kratkotrajne) padavine, kakor tudi komulativne padavine preko več tednov ali mesecev. Tako imajo največji vpliv 60 dnevne padavine v profilih 6, 7, 8 in 9, 30 dnevni zamik padavin pa ima največji vpliv v profilih 4 in 5. Vendar pa so ugotovljeni vplivi še vedno manjši, kot so bili pri primerjavi količine padavin in hitrosti. Tako lahko rečemo, da je sprememba količine padavin odločilen dejavnik za spremembo hitrosti samo v določenih primerih. Padavine lahko sprožijo plazenje vendar pa na razvoj hitrosti plazenja po sprožitvi vplivajo tudi drugi dejavniki.

4 UMETNE NEVRONSKE MREŽE

Nevronske mreže so sistemi za obdelavo informacij, ki se zgledujejo po bioloških vzornikih, in sicer po bioloških nevronske mrežah (možganih) in naravni evoluciji. Nevronska mreža je vzporedni procesor, ki lahko zbira, shranjuje in posreduje eksperimentalne podatke (Haykin, 1994) in ima naslednje lastnosti:

- zbiranje podatkov poteka z učenjem;
- podatki se shranjujejo v povezavah med nevroni, ki jih imenujemo povezave;
- posredovanje podatkov z nevronske mreže izkazuje posplošitveno zmožnost.

Nevronske mreže so kljub preprosti zgradbi dovolj kompleksne za reševanje zahtevnih tehničnih problemov. Nevronske mreže se z možnostjo učenja iz primerov, zmožnostjo posploševanja in splošno aproksimacijsko zmožnostjo uporabljajo za razvrščanje, modeliranje, napovedovanje, optimizacijo in vodenje na številnih področjih v znanosti in tehniki (Sarle, 1999).

Nevronske mreže se danes uspešno uporabljajo na številnih področjih – bančništvo, medicina, tehnika, geologija, biologija, fizika, elektrotehnika, robotika... Uspeh umetnih nevronske mrež je pripisati sledečim faktorjem:

- zmožne so modelirati ekstremno kompleksne sisteme; lahko se uporabijo tam, kjer linearnost (običajna statistika npr.) odpove;
- ni težav z dimenzionalnostjo problema – le ta je lahko poljubna;
- preproste za uporabo; metode strojnega učenja nam omogočajo uporabo nevronske mrež kot uporabo črne ali pa sive skrinjice.

4.1 Zgodovina umetnih nevronskih mrež

Prvi začetki umetnih nevronskih mrež segajo v zgodnja štirideseta leta prejšnjega stoletja, ko sta McCulloch in Pitts predstavila matematični model živčne celice oziroma nevrona (Dobnikar, 1990). Ta model predpostavlja, da ima vsak vhodni signal svojo utež, sestavljeni signal pa je vsota produktov vhodnih signalov in uteži. Kadar vhodni signal preseže neko posebno vrednost, ki je označena kot prag (angl. bias), se sproži izhodni signal, sicer pa ne. S to bistveno preprosto preklopno funkcijo in s spremembo uteži je možno obdelovati velike količine podatkov in prilagajati sistem novim razmeram – ga učiti. Takšen model se vse do danes ni bistveno spremenil in še vedno predstavlja osnovno izhodišče pri najrazličnejših raziskavah. Kmalu pa se je pojavilo vprašanje, kako spreminjati oziroma določevati uteži in prag, da je zadoščalo zahtevam posameznega problema. Enega prvih odgovorov v tej smeri je podal Hebb z učnim pravilom, ki omogoča postopno iskanje vrednosti za uteži in praga tako, da ustrezajo našim zahtevam. S tem je model nevrona postal zanimiv za številne raziskovalce, saj je bilo očitno, da je mogoče z njim reševati zelo zahtevne probleme, za katere ni bilo determinističnih rešitev.

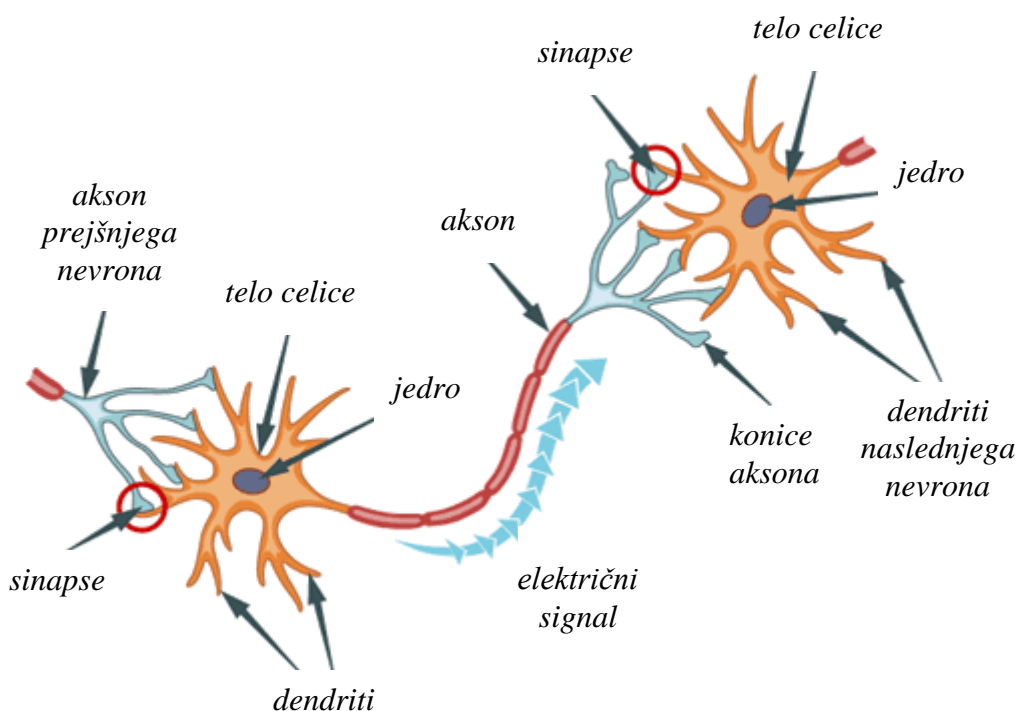
Leta 1959 je Rosenblatt predstavil koncept Perceptrona kot enega prvih adaptivnih sistemov (Dobnikar, 1990). Osnova je bil privzeti model nevrona, ki mu je dodal povratno zanko za adaptacijo uteži. Podoben model je bil Adaline, ki ga je leta 1961 razvil Widrow, omogočal pa je tudi adaptacijo praga. Leta 1969 sta avtorja Minsky in Papert dokazala nemoč dotlej poznanih adaptivnih sistemov na bazi nevrona. Na preprostem primeru preklopne funkcije ekskluzivni ali (angl. EX–OR) sta dokazala, da je ni moč rešiti s tedaj poznanimi sistemi, tudi če poljubno spreminjamo uteži in prag. Čeprav so že takrat razmišljali o večslojnih nevronskih strukturah, pa še ni bil znan učni algoritem za adaptacijo uteži vseh nevronov za želene vrednosti. Le–tega so objavili Rumelhart, Hinton in Williams leta 1968. S tem je bil takoj rešen problem EX–OR, ki so ga reševali z vpeljavo vsaj dveh slojev nevronov. Od tedaj so se umetne nevronske mreže hitro razvijale, pričeli so jih uporabljati na različnih področjih in pri številnih aplikativnih problemih, zlasti za razpoznavanje vzorcev, klasifikacije vzorcev, procesiranje kompleksnih signalov, diagnosticiranje, informacijskega inženirstva.

4.2 Sestava biološkega nevrona

Ocenjuje se, da ima človek približno 10^{11} živčnih celic oz. nevronov, ki so osnovne celice živčnega sistema živih organizmov. Med njimi obstaja približno 10^{15} povezav, ki imajo vsaka svojo utežno funkcijo (Dobnikar, 1990). Ta funkcija se spreminja skladno z razvojem človekove osebnosti, kar pomeni, da je osnovna lastnost nevronskih mrež učenje, opravljajo pa tudi vse računske in komunikacijske funkcije v telesu.

Biološki nevron sestavljajo trije glavni deli (Zupan, Gasteiger, 1999) :

- telo celice,
- dendriti (sprejemniki) ter
- akson (glavna prenosna pot).



Slika 10: Shematski prikaz nevrona (Culverco, 2002).

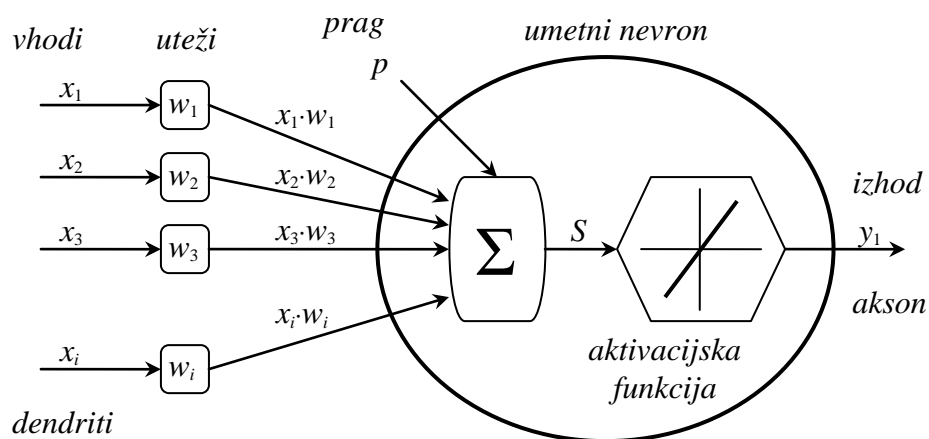
Vhodni signali se v celici seštevajo v kratkih časovnih obdobjih. Kadar je skupni signal v celici dovolj velik (večji kot prag v vrhu aksona), se sproži izhodni signal, ki ga akson prenese naprej. Jakost izhodnega signala je vedno enaka ne glede na to, ali je vhodni signal komaj

presegel prag ali pa je stokrat močnejši. Akson predstavlja glavno prenosno pot v celici. Blizu konca se razcepi na množico končičev, ki se zaključijo s sinapsami, kjer signal prehaja na dendrite ali na telo druge celice. Tako lahko en sam nevron generira impulz, ki bo aktiviral ali zavrl na tisoče drugih nevronov, ti pa spet vplivajo na svoje naslednike in ta postopek se ponavlja.

Delovanje biološkega živčnega sistema temelji torej na preprosti obdelavi signalov v nevronu, na izjemni povezanosti brezštevilnih nevronov in na dejstvu, da lahko spreminjamo jakost signalov pri prehodu iz enega nevrna v drugega. Te značilnosti so tudi osnova zasnove umetnih nevronske mrež.

4.3 Sestava umetnega nevrna

Vsak umetni nevron je, podobno kot živčna celica v možganih z dendriti in aksonom, povezan z več drugimi umetnimi nevroni (Dobnikar, 1990).



Slika 11: Sestava splošnega umetnega nevrna (<http://slo-tech.com/forum/t304089>).


Lastnosti vsake take povezave so podane s sinaptično utežjo (Haykin, 1999). Označimo z x_i signal, ki ga sprejme i -ti dendrit, z w_i pa sinaptično utež, s katero so določene lastnosti stika nekega sosednega nevrna z i -tim dendritom opazovanega nevrna.

Seštevalnik opravlja funkcijo povprečenja signalov čez neko časovno obdobje. V realnem svetu je ta čas točno določen, pri modeliranju pa je to čas, ki ga računalnik potrebuje za dva zaporedna izračuna na istem umetnem nevronu. Rezultat seštevanja je aktivacijska vsota S , to je vsota uteženih signalov w_i iz vseh dendritov x_i :

$$S = \sum_{i=1}^n x_i \cdot w_i. \quad \dots(1)$$

Z aktivacijsko funkcijo določimo odziv nevrona – velikost signala, ki ga pošljemo na akson. Enostavna aktivacijska funkcija je na primer stopničasta funkcija (slika 12), imenovana tudi McCulloch–Pittsov model, ki vrne 1 (vzburi nevron), če je vsota večja ali enaka pragu p , in 0 (zavre nevron), če je vsota manjša od p (<http://slo-tech.com/forum/t304089>). Matematično jo zapišemo z enačbo (2):

$$f_1(S) = \begin{cases} 1 & S \geq p \\ 0 & \text{šicer} \end{cases} \quad \dots(2)$$




Slika 12: Stopničasta aktivacijska funkcija (<http://slo-tech.com/forum/t304089>).

Izboljššan model umetnega nevrona predstavlja nelinearen model. Mnogo pogosteje uporabljamo za aktivacijske funkcije razvlečene stopničaste funkcije, ki so monotono naraščajoče, omejene, zvezne in zvezno odvedljive. Take funkcije imenujemo sigmoidne. Za razliko od stopničaste funkcije, kjer je nevron lahko ali popolnoma vzburljen ali pa popolnoma zavrt, nam opisane sigmoidne funkcije omogočajo, da je nevron lahko tudi samo malo

vzbujen oziroma zavrt, podobno kot velja za živčne celice v možganih. Funkcija preslika vhodne vrednosti med $-\infty$ in $+\infty$ v izhodne, s tem, da jih zgladi na vrednosti med 0 in 1. Definirana je z enačbo (3):

$$f_2(S) = \frac{1}{1 + e^{-\alpha(S-p)}}.$$

...(3)



Slika 13: Sigmoidna aktivacijska funkcija (<http://slo-tech.com/forum/t304089>).


Naklon aktivacijske funkcije je izražen z recipročno širino intervala $[1/\alpha]$, prag pa z vrednostjo p .

Prednost te funkcije je, da zna preslikati poljubno vhodno vrednost na interval med 0 in 1 tako, da je vsaka od vhodnih vrednosti v izhodnem signalu predstavljena s svojo lastno vrednostjo. Drugače rečeno, vsaka izhodna vrednost je slika natanko ene vhodne vrednosti. Prav ta lastnost jo naredi za idealno funkcijo pri aproksimaciji želenega izhodnega signala. Druga pomembna lastnost te funkcije je, da je mnogo bolj natančna pri vhodnih vrednostih, ki so okrog sredine intervala. Vrednosti, ki so na robovih vhodnega signala, pa obravnavamo bolj površno. Zato je že sama po sebi zmožna omejiti pretiran vpliv skrajnih vhodnih vrednosti na izhod.

Radialna aktivacijska funkcija preslika vhodne vrednosti v izhodne po enačbi normalne porazdelitve (4):

$$f_4(d) = e^{-d^2}.$$

...(4)

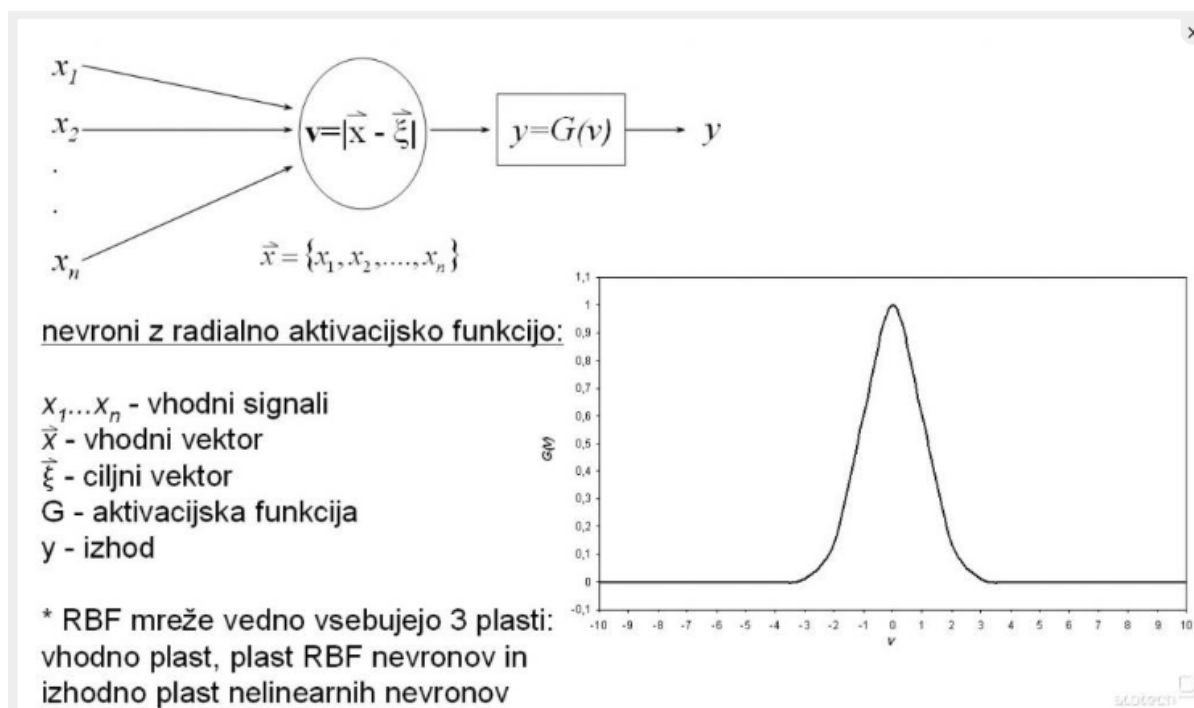


Slika 44: Radialna aktivacijska funkcija (<http://slo-tech.com/forum/t304089>).

Njegovo delovanje je rahlo drugačno, saj vhode obravnava kot vektor v prostoru. Izhod tega nevrona pa se izračuna na podlagi razdalje med vhodnim vektorjem in izhodnim vektorjem, ki je "shranjen" v nevronu. Razdalja je lahko evklidska ali pa katera neevklidska. Aktivacijska funkcija na koncu pretvori razdaljo v aktivacijo na način, da bližje kot je vhodni vektor ciljnemu, višja je aktivacija. Mreže, ki vsebujejo radialne nevrone, se imenujejo mreže RBF (angl. radial basis function networks).

Vhod d je pri tej funkciji, namesto produkta med utežjo in vhomom, praviloma razdalja med utežjo in vhodnim signalom. Izhod iz takšnega nevrona nam torej pokaže, v kolikšni meri je vhodni signal poznan nevronu oziroma koliko se vhodni signal ujema s signalom, s katerim smo nevron učili. Takšni nevroni se pogosto uporabljajo za glajenje kompleksnih funkcij.

Vrsta aktivacijske funkcije se med učenjem ne spreminja in je enaka za vse nevrone v umetni nevronske mreže RBF, ne glede na položaj nevrona in vrsto povezave s sosednjimi nevroni. Med učenjem se spreminjajo le uteži in parametri, ki določajo prag in naklon funkcije.



Slika 15: Nevroni z radialno aktivacijsko funkcijo (<http://slo-tech.com/forum/t304089>).

4.4 Umetna nevronska mreža

Če te osnovne gradnike povežemo v mrežo, dobimo nevronska mrežo (slika 18). Le-te se delijo na dva osnovna tipa: na mreže brez povratnih zank in na mreže s povratnimi zankami. Pri prvih teče signal vedno od vhodnih nevronov proti izhodnim. Vsak vhodni podatek se obravnava kot ločena entiteta. Predhodni podatki na delovanje mreže nimajo vpliva. Drugi tip mrež pa vsebuje t.i. povratne povezave. Pri njih je delovanje odvisno od zaporedja vhodnih signalov oz. od predhodnih vhodnih podatkov.

4.4.1 Kriteriji razdelitve umetnih nevronskih mrež

V poglavju opisujemo različne kriterije, po katerih lahko razdelimo umetne nevronske mreže:

- tip vhodnih podatkov;
- arhitektura umetnih nevronskih mrež;
- usmerjenost povezav;

- tehnika učenja umetnih nevronskih povezav;
- pravila učenja umetnih nevronskih mrež.

4.4.1.1 Tip vhodnih podatkov

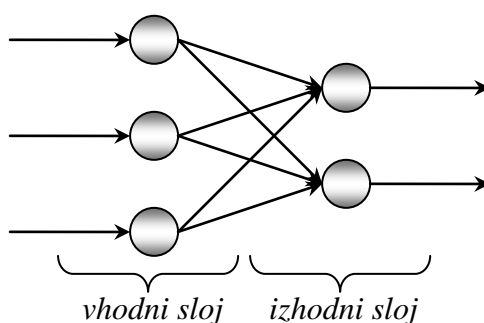
V splošnem ločimo dva tipa vhodnih podatkov:

- diskretne: binarni (0 ali 1), bipolarni (–1 ali 1) ter
- zvezni vhodni podatki (uporabljeni v nalogi).

4.4.1.2 Arhitektura umetnih nevronskih mrež


Arhitektura umetne nevronske mreže je ena izmed osnovnih lastnosti nevronske mreže in predstavlja vzorec povezav med nevroni (Kononenko, 1997).

- Umetna nevronska mreža brez slojev (angl. nolayer networks) je najbolj splošna oblika mreže, pri kateri je vsak nevron hkrati voden in izhoden. Vsak nevron je povezan z vsakim nevromom v obeh smereh. Umetna nevronska mreža deluje tako, da se na začetku nevromom vsilijo vrednosti komponent vhodnega vzorca, zatem pa nevromi paralelno sinhrono ali asinhrono spreminjajo svoja stanja toliko časa, dokler se izhod celotne umetne nevronske mreže ne ustali.
- Dvoslojna usmerjena umetna nevronska mreža (angl. twolayer network) je sestavljena iz skupine vhodnih in skupine izhodnih nevromov. Vsak vhodni nevron je z enosmerno vezjo povezan z vsakim izhodnim nevromom. Izračun take umetne nevronske mreže poteka tako, da se vhodnim nevromom vsilijo vrednosti komponent vhodnega vzorca in zatem v enem koraku vsi izhodni nevromi paralelno izračunajo izhodne vrednosti. Včasih pravijo takim umetnim nevronskim mrežam tudi enoslojne, ker so vhodni nevromi samo senzorji. Primer take umetne nevronske mreže je perceptron. Dvoslojne umetne nevronske mreže lahko rešijo samo linearne probleme.



Slika 5: Dvoslojna umetna nevronska mreža (Derenda, 2007).

- Večslojno usmerjeno umetno nevronske mrežo (angl. multilayer networks) dobimo, če dvoslojni umetni nevronske mreži med vhodni in izhodni sloj dodamo še enega ali več skritih slojev. Večslojne umetne nevronske mreže delujejo podobno kot dvoslojne, le da je število korakov za eno večje od števila skritih slojev. Z večslojnimi umetnimi nevronske mrežami lahko rešimo tudi nelinearne probleme.



Slika 67: Trislojna umetna nevronska mreža (Derenda, 2007).

4.4.1.3 Usmerjenost povezav

Glede na usmerjenost povezav ločimo dva tipa umetnih nevronske povezav (Kokol et al., 2000).

- Umetne nevronske mreže brez povezav nazaj – nerekurentne (angl. feed–forward) umetne nevronske mreže, kjer izhodi enega nevrona pomenijo vhode v druge nevrone, vrednost se vedno prenašajo od vhodov proti izhodom.
- Umetne nevronske mreže s povezavami nazaj – rekurentne (angl. feed–backward) umetne nevronske mreže, so še najbližje biološkemu sistemom, saj dovoljujejo povezave v obe smeri. Najbolj znana tipa umetnih nevronske mreže s povratno zanko sta Elmanova in Hopfieldova mreža.

4.4.1.4 Tehnika učenja umetnih nevronske mreže

Poznamo nekaj tehnik učenja umetnih nevronske mreže (Zupan, 1994).

- Nadzorovano učenje (angl. supervised learning) je tisto, pri katerem moramo med učenjem pri vsakem vhodu podati še želen oziroma pravilen izhod umetne nevronske mreže. Tako za vse učne točke natančno določimo preslikavo vhodov na izhode, ki jo mora umetna nevronska mreža opravljati. Ko je umetna nevronska mreža dovolj naučena, da vsak vhod preslika v pravilen izhod z dovolj majhno napako, lahko menimo, da tudi vhode, ki nimajo poznanih rešitev, preslika na ustrezne izhode.
- Ocenjevano učenje (angl. appreciated learning) ne zahteva poznavanja pravilnega izhoda umetna nevronska mreže, ampak postopke, s katerimi lahko ocenimo približne vrednosti, h katerim mora umetna nevronska mreža težiti.
- Nenadzorovano učenje (angl. unsupervised learning) se razlikuje od prejšnjih načinov po tem, da ne potrebuje nobenih želenih izhodov ali ocen, ampak samo vhode v umetno nevronska mrežo. Pri tem učenju ni potrebno določiti preslikave z vhoda na izhod, ampak jo določa umetna nevronska mreža sama. Takšna pravila se imenujejo tudi pravila samoorganizacije. Primerna so zlasti za naloge na področju razpoznavanja vzorcev in razvrščanje podatkov v skupine.

4.4.1.5 Pravila učenja umetnih nevronskih mrež

Ločimo več pravil učenja umetnih nevronskih mrež:

- Hebbovo pravilo: Pravilo pravi, da se vez med dvema aktivnima nevronoma ojača (utež se poveča) (Kononenko, 1997). To pravilo zadostuje, da si mreža zapomni frekvenco (in s tem verjetnost), s katero sta dva sosednja nevrona hkrati aktivna.
- Pravilo delta: V dvoslojni umetni nevronske mreži je prvi sloj nevronov vhodni in drugi izhodni. Vsak vhodni nevron je povezan z vsakim izhodnim nevronom. Pred začetkom učenja so uteži izbrane naključno. Učenje poteka z znanimi pari vhodnih in izhodnih vzorcev. Proces učenja poteka tako, da vhodni nevroni dobijo vhodni vzorec. Zatem se v enem koraku izračuna izhodna vrednost pri danem vhodu. Izračuna se razlika med izhodno (angl. outputs) (napovedano – z umetnimi nevronskimi mrežami izračunano) in ciljno (angl. targets) (pričakovano – željeno) vrednostjo na izhodu. Nato se uteži povezav med vhodnimi in izhodnimi nevroni zmanjšajo ali povečajo sorazmerno razliki med izhodno in ciljno vrednostjo.
- Pravilo vzratnega razširjanja napake: Le to omogoča učenje umetne nevronske mreže, sestavljene iz poljubnega števila slojev. Na začetku učenja so uteži naključne. Na vhodu umetna nevronska mreža dobi vhodni vzorec in z razširjanjem po slojih izračuna izhod do izhodnega sloja. Zatem se izračuna razlika med izhodno (napovedano) in ciljno (pričakovano) vrednostjo na izhodu. Nato se spremenijo uteži med zadnjim in predzadnjim slojem kot pri osnovnem pravilu delta. Zatem se izračunajo izhodne vrednosti nevronov na predzadnjem sloju (to je ključni korak algoritma). Izračuna se razlika med izhodnimi in ciljnimi vrednostmi nevronov na predzadnjem sloju in rekurzivno se nadaljuje spreminjanje uteži vse do vhodnega sloja nevronov.
- Kohonenovo pravilo: Sama umetna nevronska mreža temelji na enem sloju nevronov, ki so organizirani v dvodimenzionalni ravnini z dobro definirano topologijo. Vsak nevron pa ima toliko uteži, kolikor je komponent vhodnega vektorja x . Sistem se organizira sam in je namenjen nenadzorovanemu učenju.

4.4.2 Razdelitev umetnih nevronskih mrež

Poznamo več variacij umetnih nevronskih mrež. Razlikujejo se po učnih pravilih in kako ta pravila modificirajo tipično arhitekturo (topologijo) umetnih nevronskih mrež. V splošnem delimo umetne nevronske mreže na 5 kategorij (Anderson, McNeill, 1992):

- Umetne nevronske mreže namenjene napovedovanju (angl. prediction): uporabljajo vhodne podatke za napovedovanje izhodnih podatkov:
 - umetne nevronske mreže z vzratnim razširjanjem napake (angl. back-propagation of errors),
 - umetne nevronske mreže z algoritmom delta bar delta (angl. delta bar delta),
 - umetne nevronske mreže z razširjenim algoritmom delta bar delta (angl. extended delta bar delta),
 - umetne nevronske mreže z naključnim direktnim iskanjem (angl. directed random search),
 - višje ureditvene umetne nevronske mreže (angl. higher order artificial networks),
 - samoorganizirajoče umetne nevronske mreže z vzratnim razširjanjem napake (angl. self-organizing map into back-propagation) ter
 - umetne nevronske mreže radialnih bazičnih funkcij (angl. radial basis function).
- Umetne nevronske mreže za klasifikacijo (angl. classification) uporabljajo vhodne podatke za določitev klasifikacije:
 - umetna nevronska mreža za vektorsko kvantizacijo (angl. learning vector quantization),
 - umetna nevronska mreža z vnosom podatkov iz nasprotne smeri ali protitočna umetna nevronska mreža (ang. counter-propagation) ter
 - statistične umetne nevronske mreže (angl. probabilistic artificial networks).

- Umetne nevronske mreže za podatkovno asociiranje (angl. data association) so podobne klasifikacijskim, pri čemer pa prepoznajo še podatke, ki vsebujejo napake:
 - Hopfieldova umetna nevronska mreža (angl. Hopfield network),
 - Boltzmannov stroj (angl. Boltzmann machine),
 - Hammingova umetna nevronska mreža (angl. Hamming network) ter
 - umetne nevronske mreže z dvakratnem direktnim asociacijskim spominom (angl. bidirectional associative memory).
- Umetne nevronske mreže za podatkovni konceptualizem (angl. data conceptualization) analizira vhodne podatke, tako da so lahko odnosi skupin povezani:
 - umetne nevronske mreže adaptivne resonančne teorije (angl. adaptive resonance network) ter
 - samoorganizirajoče umetne nevronske mreže (angl. self-organizing map).
- Umetne nevronske mreže za podatkovno filtriranje (angl. data filtering), kjer algoritem zgladi (angl. smoth) vhodne podatke:
 - recirkulacijska umetna nevronska mreža (angl. recirculation).

V nadaljevanju je podrobneje razložena umetna nevronska mreža radialnih bazičnih funkcij (angl. radial basis function), s katero smo izvedli izračune v eksperimentalnem delu naloge.

4.4.3 Prednosti in slabosti umetnih nevronskih mrež

Prednosti umetnih nevronskih mrež so (Kononenko, 1997):

- Biološka podobnost: z oponašanjem človeških možganov pri čemer skuša doseči večjo učinkovitost pri reševanju zahtevnih problemov.
- Visoka stopnja paralelizma: posledica dejstva, da vsak nevron deluje relativno neodvisno od ostalih, zato so zmožne prilagajanju zapletenemu okolju v realnem času.
- Večsmerno izvajanje: kjer je vsak nevron povezan z vsakim, je vsak nevron hkrati vreden in izhoden.

- Robustnost: glede na okvaro posameznih nevronov in sinaps ne izgubimo nobenega podatka v celoti, pri čemer točnost pada sorazmerno s številom uničenih nevronov. Robustna pa je tudi glede na pomanjkljive vhodne podatke, kar izvira iz načina delovanja, ko se manjkajoči podatki aproksimirajo z razpoložljivimi vhodnimi podatki in naučenega znanja.
- Učenje: poteka s spontanym spreminjanjem uteži na sinapsah. Ko je umetna nevronska mreža naučena, je vsak nevron sposoben napovedati svoje stanje v odvisnosti od danih stanj z njim povezanih nevronov.
- Relacija med strojno in programsko opremo: v mreži ni programske opreme v klasičnem pomenu besede. Edini algoritem, po katerem deluje, je individualni nevron, vse ostalo delovanje je spontano.
- Matematična podlaga: temelji v linearni algebri.

Slabosti umetnih nevronskih mrež so (Hafner, 1999):

- Za uspešno učenje potrebujemo veliko število kvalitetnih vhodnih podatkov. V primeru, da podatki niso kvalitetni, je taka tudi rešitev.
- Iskanje optimalne umetne nevronske mreže, ker je njeno učenje lahko zelo dolgotrajen proces.
- Pri gradientnih učnih algoritmi se pojavlja problem lokalnih minimumov.
- Rešitve, ki jih pridobimo, so ponavadi nejasne. V večini primerov je nemogoče ugotoviti kakšne so zakonitosti, ki privedejo sistem do pravičnega delovanja. Umetne nevronske mreže pogosto primerjajo s črno skrinjico – na eni strani podatki vstopajo, na drugi izstopajo, kakšni so notranji mehanizmi, pa ostaja očem skrito. Vnaprej moramo določiti namen našega dela. Če želimo postaviti le model, ki bo deloval pravilno in nas mehanizmi ne zanimajo, so umetne nevronske mreže vsekakor priporočljive. Nasprotno pa v primeru, ko želimo analizirati postopke in dognati zakonitosti, pridejo umetne nevronske mreže le redkokdaj v poštev.
- Težave zaradi »pretreniranosti«. Cilj procesa učenja je doseči čim boljše prilagajanje učnim podatkom. S spreminjanjem uteži v umetni nevronske mreži skušamo delovanje modela privedi do čim manjše napake. Glavni cilj je izdelati model, ki ne bo deloval

le na učnih podatkih, ampak se bo enako dobro obnesel tudi na katerihkoli drugih podatkih. Zato je potrebno v postopku učenja neprenehoma izvajati tudi postopke testiranja. V ta namen je potrebno uporabiti testne podatke, ki niso enaki učnim. Napaka se za učne in testne podatke ne zmanjšuje enako hitro. V neki točki se napaka na testnih podatkih začne povečevati kljub temu, da se nad učnimi podatki še naprej zmanjšuje. V tej prevojni točki je dosežen trenutek, ko rečemo, da je od tu naprej mreža »pretrenirana«. Predolg proces učenja vodi k slabemu posploševanju, mreža izgubi sposobnost posploševanja, prične pa se proces memoriranja učnih podatkov. Učenje je potrebno v prevojni točki prekiniti. Načeloma bi napako nad učnimi podatki lahko poljubno zmanjšali s povečanjem števila nevronov, vendar pa bi s tem izgubili sposobnost posploševanja.

4.4.4 Podatki umetnih nevronske mrež

Glede na uporabo razdelimo podatke na (Ambrožič, 2001):

- niz učnih podatkov (angl. training set),
- niz verifikacijskih podatkov (angl. validation set) ter
- niz testnih podatkov (angl. test set).

Umetno nevronske mrežo učimo na nizu učnih podatkov. Na nizu verifikacijskih podatkov določimo »optimalno« geometrijo oziroma topologijo umetne nevronske mreže. Naučeno umetno nevronske mrežo z optimalno geometrijo nato uporabimo na nizu testnih podatkov za preverjanje, ali je izbrana mreža res dobro naučena. Niz verifikacijskih in niz testnih podatkov pogosto združimo v enega.

4.5 Ocenjevanje kakovosti rezultatov umetnih nevronske mrež

Kakovost učenja in napovedovanja ocenjujemo s korenem srednjih kvadratov napak – *RMSE* (angl. root mean square error), ter njegovimi kombinacijami (*MSE*, *SSE*, *MAE* in *MSEREG*; glej Derenda, 2007, str. 60). *RMSE* je vsota kvadratov razlik med ciljnim (pričakovanimi –

želenimi) t_i in izhodnimi (napovedanimi – z umetno nevronske mrežo izračunanimi) vrednostimi y_i , deljenimi s številom izhodnih oziroma ciljnih vrednosti n :

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (t_i - y_i)^2}{n}}. \quad \dots(5)$$

Vrednost $RMSE$ se spreminja glede na obliko umetne nevronske mreže, kot tudi glede na število podatkovnih nizov učnih oziroma testnih podatkov, zato je ne moremo uporabiti kot primerjavo med različnimi modeli umetnih nevronske mrež, ampak le za optimiranje parametrov posamezne umetne nevronske mreže.

V primeru RBF umetnih nevronske mrež, s katerimi so izračunani rezultati eksperimentalnega dela, je cenilka kakovosti vsota kvadratov napake (angl. Sum squared error):

$$SSE = \sum_{i=1}^n (t_i - y_i)^2 \quad \dots(6)$$

4.6 Radialne bazične umetne nevronske mreže RBF

Za razvoj radialnih bazičnih umetnih nevronske mrež (angl. radial basis functions) so zaslužni predvsem Moody in Darken (1989), Powell (1985) ter Niranjana in Fallsida (1988) (Hafner, 1999).

4.6.1 Arhitektura radialne bazične umetne nevronske mreže

Umetno nevronske mrežo poleg vhodnega sloja sestavljata dva sloja. Prvi skriti sloj vsebuje Gaußovo aktivacijsko funkcijo f_1 , drugi izhodni sloj pa linearno aktivacijsko funkcijo f_2 (Matlab, 1997).

Uporabljeni aktivacijski funkciji:

- Gaußova aktivacijska funkcija:

$$f_1(d) = \text{radbas} \left(\underbrace{\|w_{1,i} - x_i\|}_{d_i} \cdot p_1 \right) \quad \dots(7)$$


- linearna aktivacijska funkcija:

$$f_2(x) = \text{purelin}(w_{2,i} \cdot f_1 + p_2), \quad \dots(8)$$

kjer so:


- $x_i, y_i \dots$ vhodni in izhodni podatki,
- $w_{1,i}, w_{2,i} \dots$ uteži v prvem in drugem sloju,
- $p_1, p_2 \dots$ prag oziroma pragovna vrednost, glede na katero se ravna izhod po zmnožku vhodov z utežmi.

Aktivacijski funkciji vizualno prikazujemo na sliki 18.



Slika 18: Prikaz Gaußove in linearne aktivacijske funkcije (Derenda, 2007).

Na sliki 19 prikazujemo arhitekturo radialne bazične umetne nevronske mreže. Prikazan je potek od vhodnega sloja – vhodnih podatkov x_i , preko skritega sloja do izhodnega sloja in izhodnih podatkov y_i .



Slika 19: Arhitektura radialne bazične umetne nevronske mreže (Derenda, 2007).

4.6.2 Algoritem učenja radialne bazične umetne nevronske mreže

Da bi razumeli delovanje radialne bazične umetne nevronske mreže, moramo slediti vhodu x skozi umetno nevronske mrežo do izhoda y (Matlab, 1997, Potočnik, 2007). Ko mreži damo vhodni signal, bo vsak radialni nevron nanj reagiral glede na to, kako blizu je ta vhodni signal njegovi uteži. Torej bodo signali, ki se močno razlikujejo od vhodnih uteži, imeli vrednost blizu nič in bodo bolj opazni v sloju z linearnimi nevroni. Nasprotno bodo signali, ki so po vrednosti zelo blizu uteži nevronov, zelo opazni po linearni transformaciji.

Nevroni v skritem sloju radialno simetrično pokrivajo prostor, definiran z vhodnimi podatki. Podobnost med vhodnim podatkom x in utežjo w je določena z evklidsko razdaljo d :

$$d_i = \sum_{i=1}^n \|w_{1,i} - x_i\|. \quad \dots(9)$$

Učni algoritem v skritem sloju predvideva Gaußovo radialno simetrično aktivacijsko funkcijo (*radbas*):

$$f_1(d_i) = e^{-\frac{d_i^2}{E_i^2}}, \quad \dots(10)$$


kjer je:

- E_i ...vsota kvadratov napake (*SSE*, enačba (6)), ki določa širino aktivacijske funkcije, in je v programu imenovana *spread*.

V izhodnem sloju pa učni algoritem predvideva linearno aktivacijsko funkcijo (*purelin*):

$$f_2(x_i) = x_i. \quad \dots(11)$$

Omenjeni parameter *spread* določa širino območja vhodnih podatkov, na katerega je občutljiv posamezen nevron v vhodnem sloju. Če je vrednost parametra velika, je občutljivost funkcije manjša na izbiro nevrona $f_1^1(d)$, če pa je vrednost parametra majhna, pa je občutljivost aktivacijske funkcije na izbiro nevronov $f_1^2(d)$ večja.



Slika 20: Prikaz večje in manjše vrednosti parametra »*spread*« na Gaußovi aktivacijski funkciji (Derenda, 2007).

Umetna nevronska mreža se uči na način, da iterativno dodaja nevrone v skritem sloju, dokler vsota kvadratov odstopanj *SSE* med ciljnimi (pričakovanimi) in izhodnimi (napovedanimi) podatki ne doseže določene vrednosti. Prav tako pa se učenje konča, ko je število nevronov v skritem sloju enako številu vhodnih podatkov (če je 25 vhodnih podatkov pomeni, da je to tudi maksimalno število nevronov v skritem sloju).

5. EKSPERIMENTALNI DEL

V eksperimentalnem delu smo s pomočjo umetnih nevronske mrež poskušali napovedati premikanje Macesnikovega plazju. Za vhodni del podatkov za učenje umetnih nevronske mrež smo uporabili čas oz. interval od prvega merjenja in količine padavine, za izhodni del pa koordinate, premike točk na površini in iz njih izvedene hitrosti premikov.

5.1 Uporabljena programska oprema

Pri napovedovanju plazenja plazju Macesnik smo uporabili dve različni programski orodji. Prvo predstavlja Matlabova knjižnica ukazov RBF.m, medtem ko je drugo programsko orodje delo podjetja Neurodimensions in se imenuje Neurosolutions. Želeli smo uporabiti še Membrain (Avtor: Thomas Jetter) in SNNS (University of Stuttgart), vendar smo se zaradi težav odločili, da ju ne bomo uporabili. Program Membrain nismo uporabili, ker ne podpira radialnih bazičnih umetnih nevronske mrež. S programom SNNS pa smo imeli težave že z inštalacijo programa.

5.1.1 RBF.m

Program radialne bazične umetne nevronske mreže je izdelan le s pomočjo programskih funkcij iz osnovne Matlabove knjižnice.

Program je sestavljen iz dveh delov, ki pa sta združena v isto matlabovo datoteko, saj se nanašata drug na drugega. Tako se v prvem delu programa izmed večjega števila iteracij izračuna tista, v kateri je vrednost SSE (sum of squared errors), glej podpoglavje 4.6, najmanjša. Program v drugem delu izračuna napovedovane vrednosti za izbrani niz podatkov v isti iteraciji, kjer je SSE najmanjša.

Osnovne programske funkcije programa:

Priprava podatkov:

- *load*: funkcija prebere vse podatke iz datoteke,
- *mapstd*: funkcija normira vhodne in ciljne podatke na vrednosti, ki imajo enotno standardno deviacijo in povprečje enako nič,
- razdelitev podatkov na niz testnih (*iitst*) ter niz učnih (*iitr*),
- normirane vrednosti za niz testnih (*tts*) in učnih: vhodnih (*ptr*) in ciljnih (*ttr*) podatkov,
- *reverse*: funkcija po končanem učnem procesu denormira izhodne in ciljne vrednosti.

Kreiranje umetne nevronske mreže:

- *newrb*: funkcija kreira novo radialno bazično (angl. radial based) umetno nevronske mrežo

Algoritem ne predvideva posebne programske funkcije za učenje umetne nevronske mreže. Celotna procedura radialne bazične umetne nevronske mreže je ustvarjena v programski funkciji kreiranja umetne nevronske mreže (*newrb*), pri čemer funkcija ne zahteva dodatnega definiranja aktivacijske funkcije v skritem oziroma izhodnem sloju, prav tako se število nevronov v slojih posebej ne definira. Tudi pri nadzoru kakovosti izhodnih podatkov ni potrebno posebej definirati statistik, ampak je statistika vsota kvadratov napake *SSE* neposredno definirana v algoritmu umetne nevronske mreže.

Eksperimentalno lahko spreminjamo samo dva učna parametra:

- *goal*: definira maksimalno vrednost statistike *SSE* ter
- *spread*: določuje širino območja vhodnih podatkov, na katero je občutljiv posamezen nevron v skritem sloju.

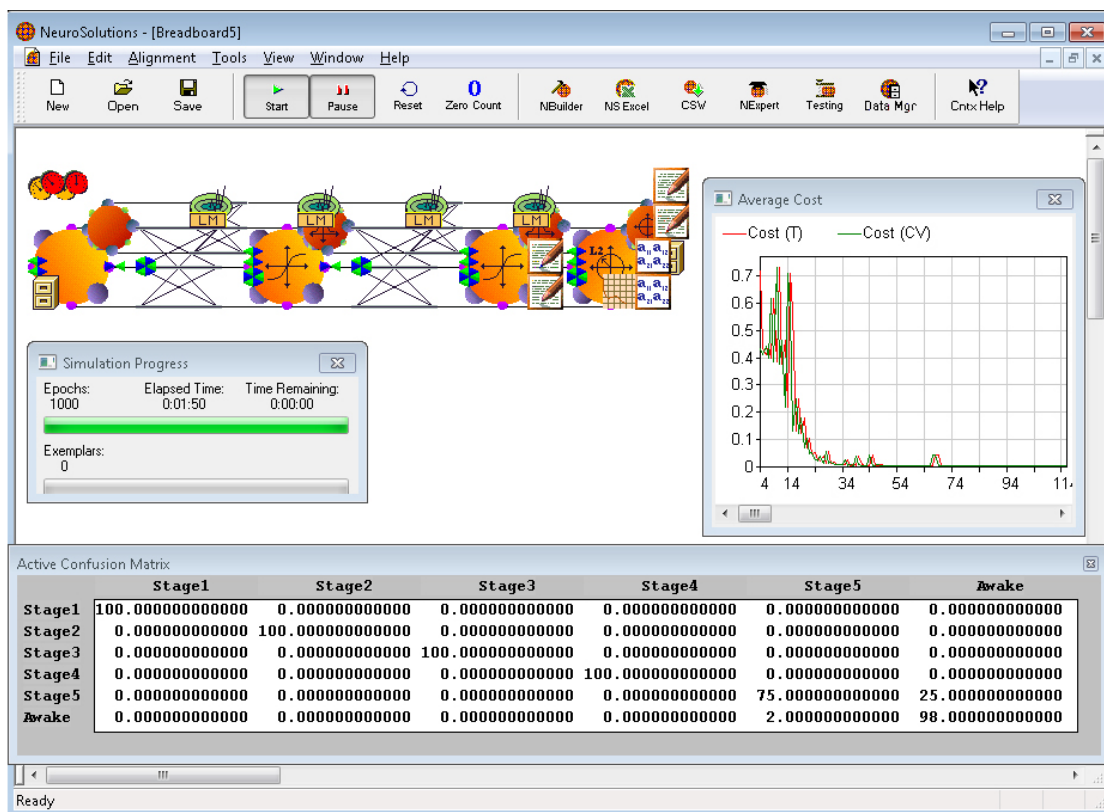
5.1.2 Neurosolutions

Neurosolutions je trenutno najbolj sofisticirano programsko orodje za nevronske mreže na trgu. Izdelalo ga je podjetje Neurodimensions. Prednosti pred ostalimi programi so predvsem

hitrejše delovanje, boljša preglednost, preglednejši izpisi rezultatov, učinkoviti grafični prikazi ...

Neurosolutions ponuja več različnih programskih okolij. Tako imamo na voljo:

- Neurosolutions: grafično orodje za izdelavo nevronske mreže, kjer dodajamo posamezne nevrone in jih povezujemo z drugimi. Na podoben način delujejo tudi druga programska orodja na trgu, kot je npr. Membrain. Prikaz okolja Neurosolutions je na sliki 21.



Slika 21: Programsko okolje Neurosolutions (Neurosolutions).

- Neurosolutions for matlab: Neurosolutions okolje, prirejeno za matlab. Prijaznejše okolje kot zgoraj omenjeni Neurosolutions, saj ni potrebno povezovati nevronov med seboj. Vhodno-izhodne pare podamo v ASCII datoteki, ki jo program prebere, uporabnik spreminja samo nastavitve. Slabost je v tem, da ne podpira vseh modelov nevronske mreže in tehnik učenja. Zaradi tega ni bilo mogoče uporabiti radialnih

bazičnih umetnih nevronske mrež v tem programskem okolju. Programsko okolje je prikazano na sliki 22.

```
Command Window

NeuroSolutions Neural Network Toolbox
Version 2.0 (Release 2) August-2005

NeuroSolutions for MATLAB is a neural network toolbox for Matlab.
The toolbox features 15 neural models, 5 learning algorithms and
a host of useful utilities.

Creating Neural Networks
  nsNN           - Create Default Neural Network
  nsMLP          - Multi Layer Perceptron
  nsGFF          - Generalized Feed Forward
  nsMODULAR      - Modular neural network
  nsSVM          - Support Vector Machines
  nsPRNN         - Partially Recurrent Neural Network
  nsFRNN         - Fully Recurrent Neural Network
  nsTDFRNN       - Time-Delay Partially Recurrent Neural Network
  nsTDFRNN       - Time-Delay Fully Recurrent Neural Network
  nsGFRNN        - Gamma Partially Recurrent Neural Network
  nsGFRNN        - Gamma Fully Recurrent Neural Network
  nsLFRNN        - Laguarre Partially Recurrent Neural Network
  nsLFRNN        - Laguarre Fully Recurrent Neural Network
  nsFTDNN        - Focused Time-Delay Neural Network
  nsFGAMMA       - Focused Gamma neural network
  nsFLAGUARRE    - Focused Laguarre neural network
  nsModels       - Models available in the toolbox

Training, Testing and Production
  nsTrain        - Train a neural network
  nsTest         - Test a neural network
  nsProduction   - Test a neural network on production data

Utility Functions
  nsGetPerformanceMeasures - Compute neural network performance
  nsTranslateSymbolicData  - Translate symbolic data to numeric data
  nsBackTranslateSymbolicData - Translate numeric data back to symbolic data
  nsFlatten              - Flatten images
  nsDemos                - Run the NeuroSolutions for MATLAB demos
  nsActivate             - Activate software

Bookkeeping Functions
  nsHelpDoc          - Open Help Documentation
  nsShortcuts        - nsmn object shortcuts
  getnsroot          - Get NeuroSolutions for MATLAB root folder

>>
```


Slika 22: Programsko okolje Neurosolutions for matlab

- Neurosolutions for excel: Neurosolutions okolje, prirejeno za Microsoft excel. To je najbolj primerno okolje za umetne nevronske mreže, saj delamo v poznanem okolju in imamo vhodno–izhodne pare podatkov razporejene v preglednici. Po vrsticah in

stolpcih lahko podajamo vhodne podatke, izhodne podatke, učni niz in testni niz. Rezultati so prikazani pregledno v grafu, prav tako lahko izvajamo razne podatkovne analize, tako na vhodnih kot tudi izhodnih podatkih. Neurosolutions for excel podpira vse modele nevronske mreže, zato smo lahko tudi v tem okolju učinkovito uporabljali radialne bazične mreže. Programsko okolje je prikazano na slikah 23, 24 in 25.

w90	w10	w5	vh	vxy	vxyh
905.1	195.7	68	-3.33	22.75	22.99
927.4	128.1	26.6	-7.75	24.14	25.35
912.2	77.5	9.4	-1.33	17.97	18.02
862.4	0	0	-3.33	12.62	13.05
868.6	6.2	6.2	0.75	8.56	8.59
878.2	42.7	36.5	-1.2	12.28	12.34
859.5	37.1	0.6	-3.25	17	17.31
720.4	67	63.5	-3.25	13.47	13.86
706.5	1.4	1.4	-1.45	7.17	7.31
273.1	0	0	-1.32	4.21	4.42
346.3	59.1	8.3	-0.54	5.93	5.95
394	53	44.2	-3.36	14.71	15.09
409.8	14.4	14.4	-3.21	10.59	11.06
422.5	76.6	53.6	-2.5	9.96	10.27
345.2	50.1	31.9	-0.23	4.55	4.55
293.9	0.9	0.9	-1.79	6.64	6.88
368.4	91.4	44.3	-0.47	2.85	2.89
382.9	12.2	1.5	-1.53	5.22	5.44
401.9	4.6	0	-1.15	2.04	2.35
208.7	5	0	-0.62	1.51	1.63
80.4	0.8	0	0.07	0.63	0.63
90.4	44.8	1.9	-0.44	2.66	2.7
132.6	0	0	-0.39	1.68	1.72
263.8	102.3	52.7	-0.37	1.19	1.25
272.1	32.8	24.3	-0.04	2.18	2.18
314.1	41.8	0.1	-0.81	2.25	2.39

Slika 23: Vhodno–izhodni pari podatkov



Slika 24: Graf uspešnosti testiranja

w90	w10	w5	vh	vxy	vxyh	vh Output	vxy Output	vxyh Output
272.1	32.8	24.3	-0.04	2.18	2.18	0.32322582	7.38289334	6.3572089
314.1	41.8	0.1	-0.81	2.25	2.39	-1.5300742	3.55994921	3.9344183

Slika 25: Vhodno–izhodna para učenja in odgovarjajoča rezultata testiranja

5.2 Vhodno–izhodni podatki

Umetno nevronske mrežo smo učili s pomočjo znanih podatkov (vhodno–izhodnih parov), ki so se zgodili v nekem obdobju. Ti so povezani med seboj preko nevronov z utežmi, ki se spreminjajo v procesu učenja tako dolgo, dokler izhodni podatki ustrezajo vhodnim podatkom. Ko je ta pogoj izpolnjen, se z umetno nevronske mrežo lahko izračuna oz. napove izhodne podatke tudi za vhodne podatke, ki niso sodelovali v procesu učenja.

Podatkovno osnovo nam je predstavljala Excelova datoteka s padavinske postaje v Solčavi, ki je vsebovala:

- v prvem stolpcu datum (dan v letu),
- v drugem stolpcu pa količina padavin, ki je padla tisti dan.

V to datoteko smo dodali izračun količine skupnih padavin, ki je padla do določenega dne (do dneva merjenja premikov). Tako smo:

- v tretjem stolpcu izračunali seštevek količine padavin za 90 dni do dneva merjenja premikov (w_{90}),
- v četrtem stolpcu izračunali seštevek količine padavin za 10 dni do dneva merjenja premikov (w_{10}),
- v petem stolpcu pa seštevek količine padavin za 5 dni do dneva merjenja premikov (w_5).

Preglednica 5: Nekaj vrstic datoteke s podatki o padavinah

Dan v letu	Količina padavin [mm/dan]	w_{90} [mm/90 dni]	w_{10} [mm/10 dni]	w_5 [mm/5 dni]
⋮	⋮			
10.11.2000	0.0			
11.11.2000	0.0			
12.11.2000	0.0			
13.11.2000	0.0			
14.11.2000	22.3			
15.11.2000	18.4			
16.11.2000	36.1			
17.11.2000	17.3			
18.11.2000	33.6			
19.11.2000	9.2	⋮	⋮	⋮
20.11.2000	7.8	857.2	144.7	104.0
21.11.2000	33.0	890.2	177.7	100.9
22.11.2000	17.9	905.0	195.6	101.5
23.11.2000	0.1	905.1	195.7	68.0
24.11.2000	0.0	905.1	173.4	58.8
25.11.2000	17.1	922.2	172.1	68.1
26.11.2000	9.2	931.4	145.2	44.3
27.11.2000	0.2	927.4	128.1	26.6
⋮	⋮	⋮	⋮	⋮

Koordinate kontrolnih točk nam je posredovalo podjetje IRGO consulting d.o.o. Iz koordinat točk v posamezni epohi smo izračunali premike in hitrosti premikov točk. Rezultate smo dodali v Excelovo datoteko:

- v prvem stolpcu ime profilne točke (point),
- v drugem stolpcu dan meritve,
- v tretjem, četrtem in petem stolpcu pa Y , X in H koordinate profilne točke.

V to datoteko smo dodali izračun premikov in hitrosti posamezne točke med dvema epohama in sicer:

- v šesti stolpec zaporedno številko dneva od ničelne meritve do dneva merjenja premikov (day),
- v sedmi stolpec horizontalni premik merske točke od predhodnega merjenja do dneva merjenja premikov (d_{yx}),
- v osmi stolpec prostorski premik merske točke od predhodnega merjenja do dneva merjenja premikov (d_{yxH}),
- v deveti, deseti in enajsti stolpec hitrost premika merske točke po koordinatah med dvema izmerama (v_y, v_x, v_H),
- v dvanajsti stolpec hitrost horizontalnega premika merske točke med dvema izmerama ($v_{yx} = v_d$),
- v trinajsti stolpec pa hitrost prostorskega premika merske točke med dvema izmerama (v_{yxH}).

Preglednica 6: Nekaj vrstic datoteke s podatki o točki 602

Točke	Dan meritve	Y [m]	X [m]	H [m]	day	d_{yx} [m]	d_{yxH} [m]	v_y [m/dan]	v_x [m/dan]	v_H [m/dan]	v_{yx} [m/dan]	v_{yxH} [m/dan]
602	20.11.2000	1000.169	1091.381	594.985	0							
	23.11.2000	999.909	1091.308	594.956	3	0.270	0.272	-86.67	-24.33	-9.67	90.02	90.54
	27.11.2000	999.597	1091.245	594.894	7	0.318	0.324	-78.00	-15.75	-15.50	79.57	81.07
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮


V naši raziskavi smo obravnavali šesti in osmi profil, predvsem točko 602, pa tudi točki 603 in 604 ter točko 803.

Pred izračunom smo pripravili vhodno datoteko. Ta je bila sestavljena iz vhodno–izhodnih parov podatkov. Datoteka je vsebovala v vrsticah vse meritve v časovnem obdobju meritev za

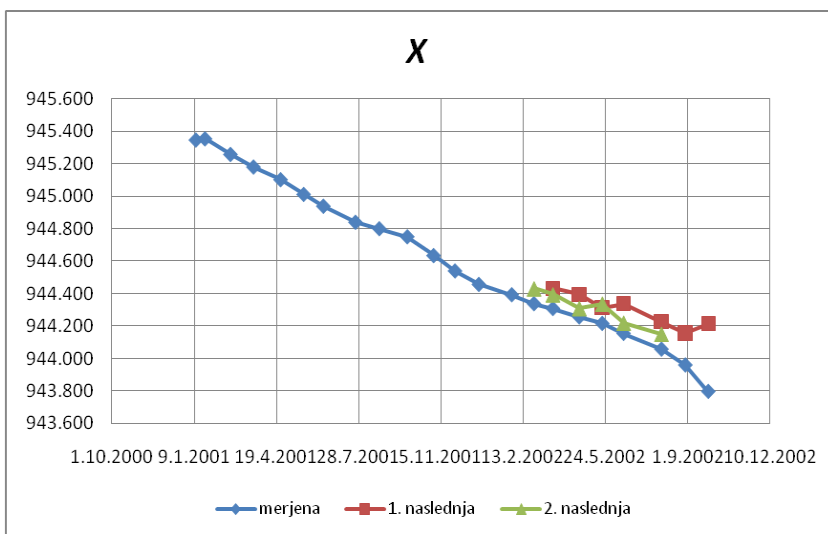
posamezno točko. V izračunu smo uporabljali vedno isto vhodno datoteko za posamezno točko, spreminjali smo samo število učnih podatkov. Mrežo smo začeli učiti s štirinajstimi vhodno–izhodnimi pari podatkov, nato pa smo število vhodno–izhodnih parov večali za en vhodno–izhodni par. Napovedovali smo vedno za dve naslednji meritvi. Tako je bilo maksimalno število vhodno–izhodnih parov za učenje nevronske mreže 24, saj smo lahko napovedali 25. in 26. meritev. V datoteki smo imeli za posamezno točko torej 26 vrstic vhodno–izhodnih parov podatkov.

5.3 Učenje umetne nevronske mreže z enim podatkom v vhodnem sloju–časovnim intervalom od ničelne meritve

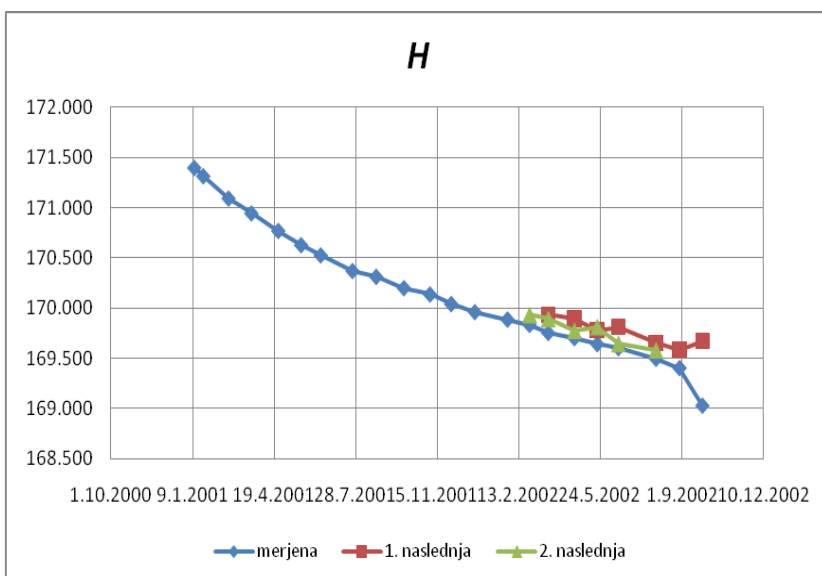
Najprej smo poizkusili napovedovanje premikanja plazu z umetnimi nevronske mrežami, kjer smo za vhodne podatke imeli čas (ničelna meritev je imela enoto 0, vsaka naslednja meritev pa število dni od dneva ničelne meritve), za izhodne pa lokalne koordinate Y , X in H . Mrežo smo učili na točki 803.



Slika 26: Grafični prikaz napovedovanja koordinate Y z naučeno umetno nevronske mrežo za točko 803 pri enem vhodnem podatku (število dni od dneva meritev) in treh izhodnih podatkih (Y , X , H).



Slika 27: Grafični prikaz napovedovanja koordinate X z naučeno umetno nevronske mrežo za točko 803 pri enem vhodnem podatku (število dni od dneva meritev) in treh izhodnih podatkih (Y , X , H).



Slika 28: Grafični prikaz napovedovanja koordinate H z naučeno umetno nevronske mrežo za točko 803 pri enem vhodnem podatku (število dni od dneva meritev) in treh izhodnih podatkih (Y , X , H).


Iz grafičnih prikazov na slikah 26, 27 in 28 vidimo, da se je mreža dobro naučila ter tudi dobro napovedovala rezultate. Rezultati so lahko varljivi, saj imamo premalo vhodnih nevronov, zato smo se odločili povečati število vhodnih nevronov.

5.4 Učenje umetne nevronske mreže z dvema vhodnima podatkom


Odločili smo se, da želimo napovedovanje še izboljšati. V nadaljevanju smo vhodnim podatkom s časom meritve dodali tudi količine padavin, ki so bile izmerjene na meteorološki postaji Solčava. Tako smo imeli dva vhodna nevrona:

- čas posamezne meritve od ničelne meritve za prvi nevron in
- količino devetdeset dnevni padavin za drugi nevron.


Izhodni podatki so bili isti kot v prejšnjem poskusu – to so bile lokalne koordinate Y , X , H točke 803.



Slika 29: Grafični prikaz napovedovanja koordinate Y z naučeno umetno nevronske mreže za točko 803 pri dveh vhodnih podatkih (število dni od dneva meritev, padavine za 90 dni nazaj) in treh izhodnih podatkih (Y , X , H).



Slika 30: Grafični prikaz napovedovanja koordinate X z naučeno umetno nevronske mrežo za točko 803 pri dveh vhodnih podatkih (število dni od dneva meritev, padavine za 90 dni nazaj) in treh izhodnih podatkih (Y , X , H).



Slika 31: Grafični prikaz napovedovanja koordinate H z naučeno umetno nevronske mrežo za točko 803 pri dveh vhodnih podatkih (število dni od dneva meritev, padavine za 90 dni nazaj) in treh izhodnih podatkih (Y , X , H).

Z dvema vhodnima in tremi izhodnimi nevroni dobimo slabše rezultate kot v prejšnjem primeru. Umetna nevronska mreža naredi pri predzadnji meritvi za Y in X nenaden skok. To je

posledica nenavadne količine padavin ob tem času. Z namenom, da bi izboljšali rezultate, smo nadaljnje umetne nevronske mreže učili s tremi vhodnimi podatki.

5.5 Učenje umetne nevronske mreže s tremi vhodnimi podatki

Predvidevamo, da je hitrost plazenja neodvisna od količine vode in od višine padavin, ki je padla v bližnji preteklosti. Zato smo v nadaljevanju učenja umetnih nevronske mreže padavine, ki so bile izmerjene na meteorološki postaji Solčava, uporabili kot tri različne vhodne podatke in sicer:

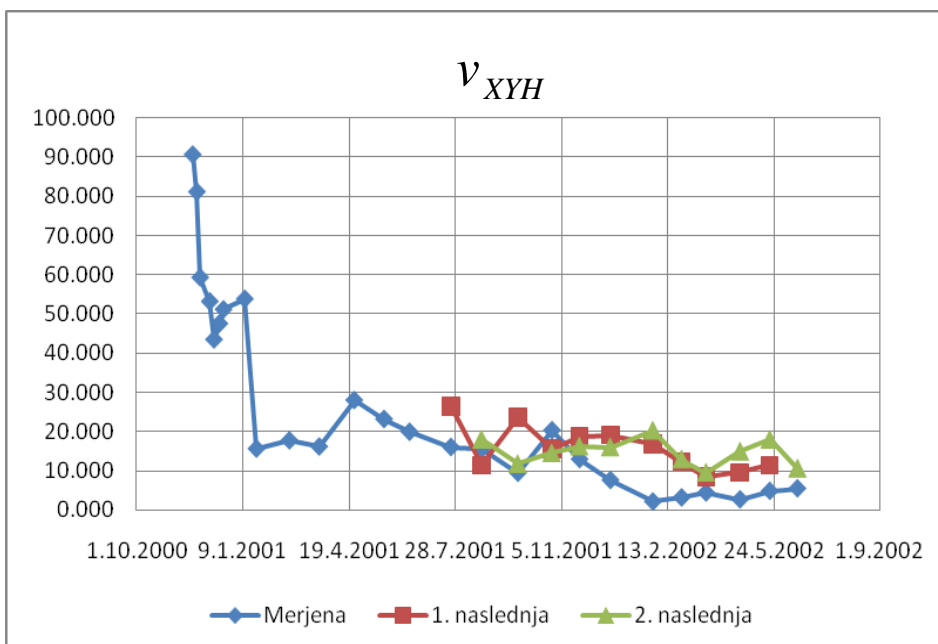
- seštevek padavin za devetdeset dni nazaj od dneva merjenja premikov,
- seštevek padavin za deset dni nazaj od dneva merjenja premikov in
- seštevek padavin za pet dni nazaj od dneva merjenja premikov.

Izhodne podatke smo izračunali iz lokalnih koordinat (vsak profil svoje izhodišče) merjenja premikov in časovnih intervalov med merjenji. Ker je med posameznimi izmerami minilo različno število dni, smo bili primorani, da izhodne podatke »damo na skupni imenovalec«. Tako smo se odločili, da uporabimo za izhodne podatke različne hitrosti. Ti izhodni podatki so bili:

- hitrost premika točke po oseh Y , X , in H (v_Y , v_X in v_H),
- hitrost premika točke po ravnini XY (v_{XY}) in
- hitrost premika točke po prostoru XYH (v_{XYH}).

5.5.1 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in enim v izhodnem sloju

V naslednji fazi smo umetno nevronske mrežo učili s tremi vhodnimi podatki. Uporabili smo seštevek padavin za devetdeset, deset in pet dni nazaj od dneva merjenja premikov. Izhodni podatki so bili v tem primeru hitrosti premika točke po prostoru (v_{XYH}).


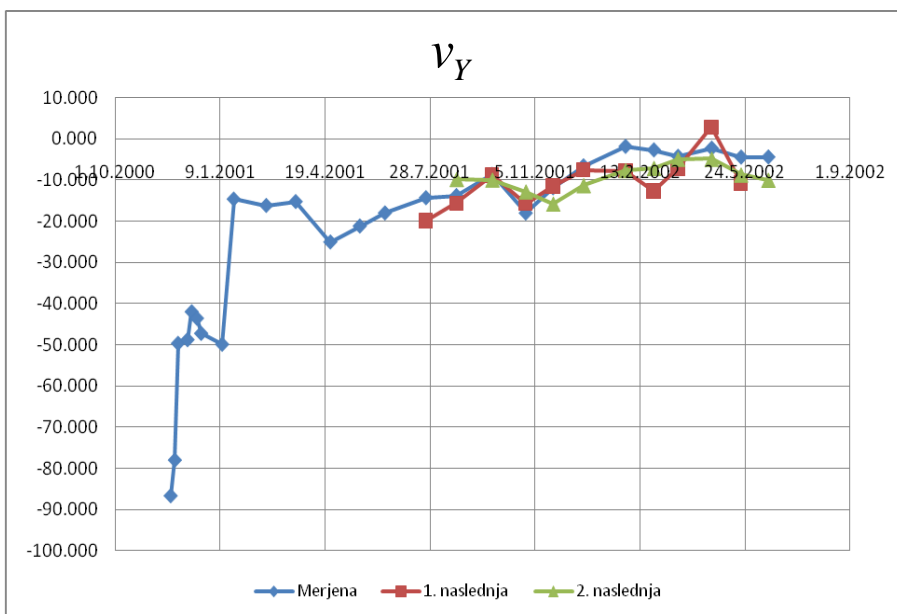



Slika 32: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in enem izhodnem podatku (hitrost premika točke v prostoru – v_{XYH}).

Vidimo, da učenje mreže ni bilo posebej uspešno, zato smo se odločili povečati število izhodnih nevronov.

5.5.2 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in tremi v izhodnem sloju

Ker z rezultati z enim nevromom v izhodnem sloju nismo bili zadovoljni, smo poskusili izhodne podatke razdeliti na več različnih podatkov, potrebnih za napovedovanje plazenja. Mnenja smo bili, da so hitrosti premikov po osi H slabših višinskih meritev in močno vplivajo na skupno prostorsko hitrost premika, zato je bolje, da hitrosti premikov razdelimo po oseh (v_Y, v_X in v_H) in nato učimo umetno nevronske mrežo.

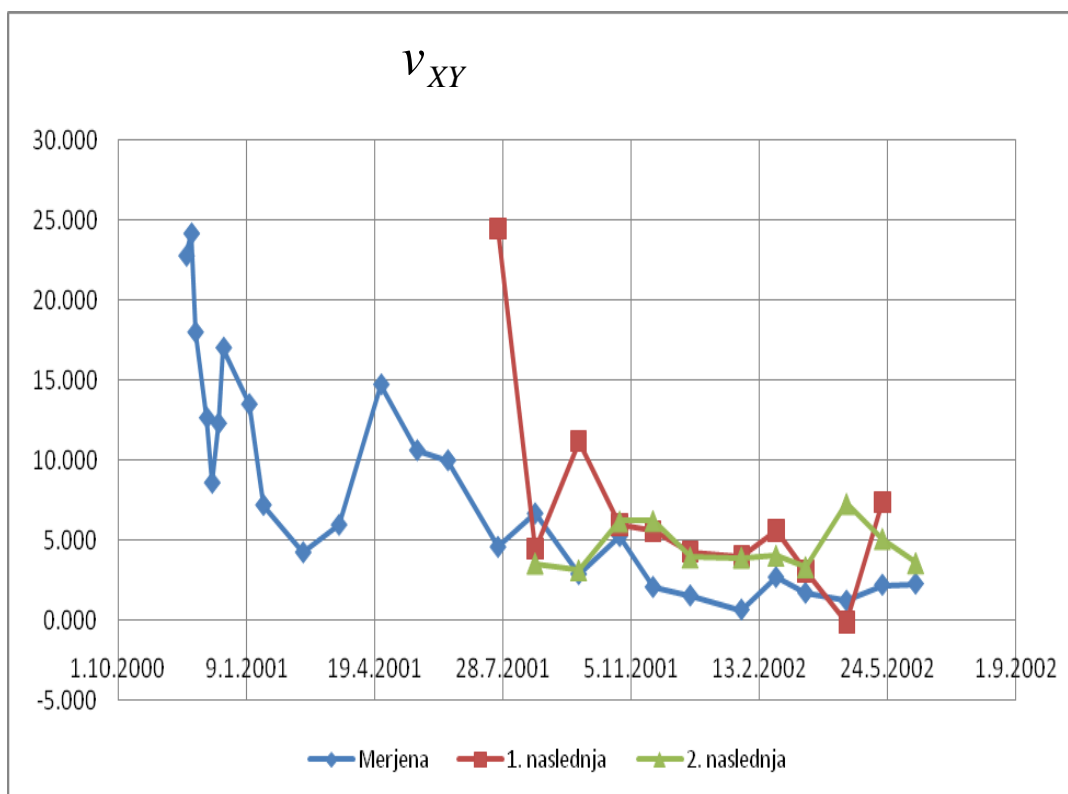
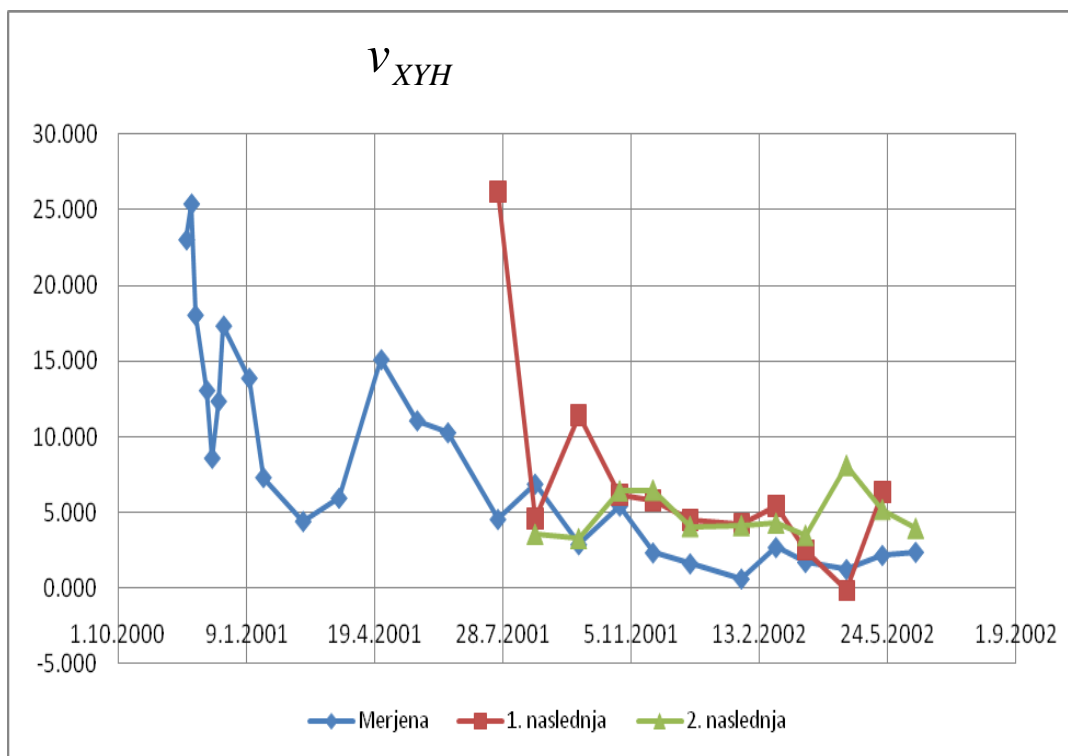


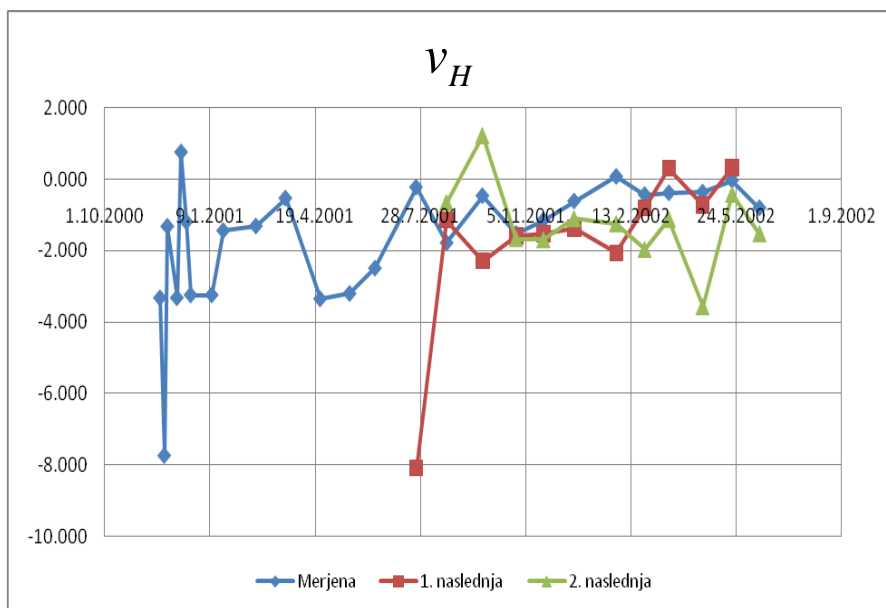


Slika 33: Grafični prikaz napovedovanja hitrosti premikanja točke po koordinatnih oseh z naučeno umetno nevronske mreže za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih podatkih (hitrost premika točke po smereh v_Y , v_X in v_H).

Napovedani rezultati se najboljše prilegajo ciljnim do sedaj. Geometrija umetne nevronske mreže z tremi vhodnimi in izhodnimi nevroni dobro napoveduje rezultate, zato smo s tako geometrijo še nadgrajevali z drugačnimi kombinacijami vhodno-izhodnih parov. Za izhodne podatke izračunamo iz premikov in časovnih intervalov med meritvami tri različne hitrosti premikanja. To so hitrost premika po osi H (v_H), hitrost premika po ravnini XY (v_{XY}) in hitrost premika po prostoru XYH (v_{XYH}).


Rezultati dobljeni z Neurosolutions:

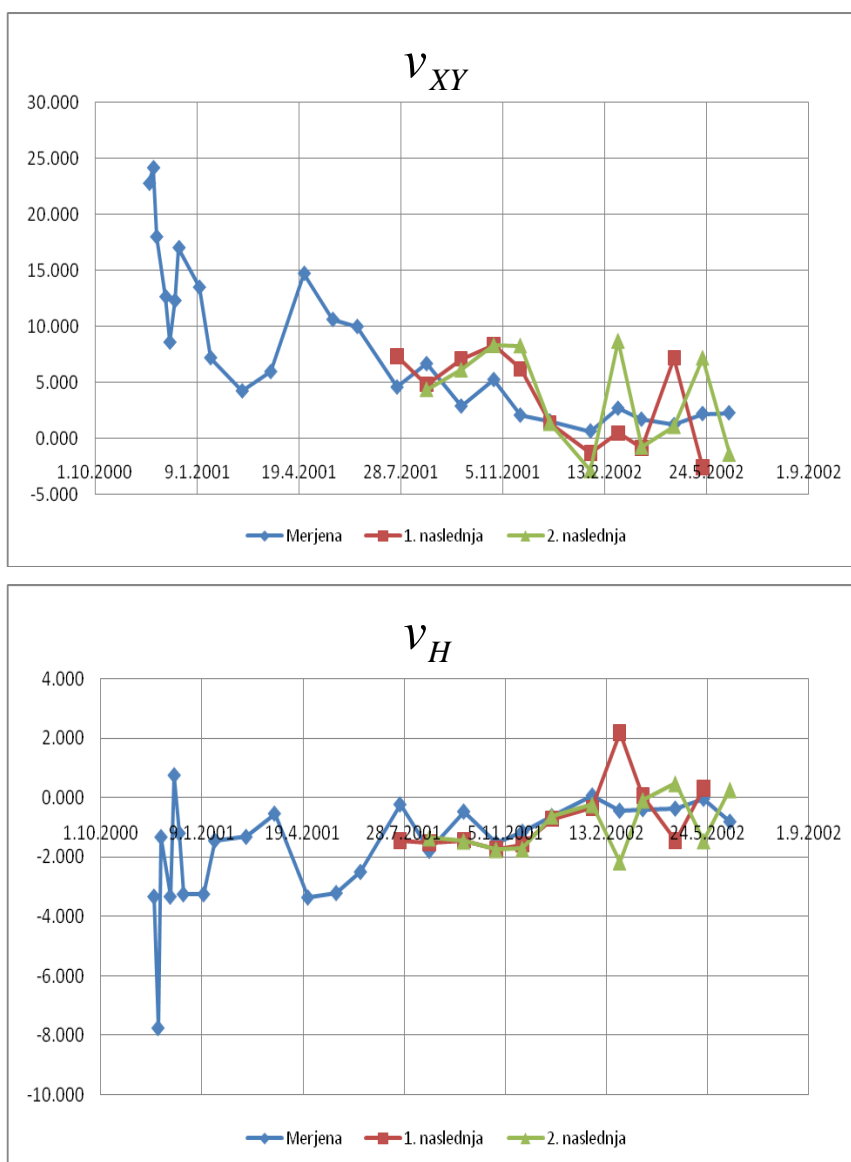




Slika 34: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 604 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih podatkih (hitrosti po osi – v_H , ravnini – v_{XY} in prostoru – v_{XYH}). Uporabljena programska oprema je bila Neurosolutions.

Rezultati dobljeni z Matlabom:






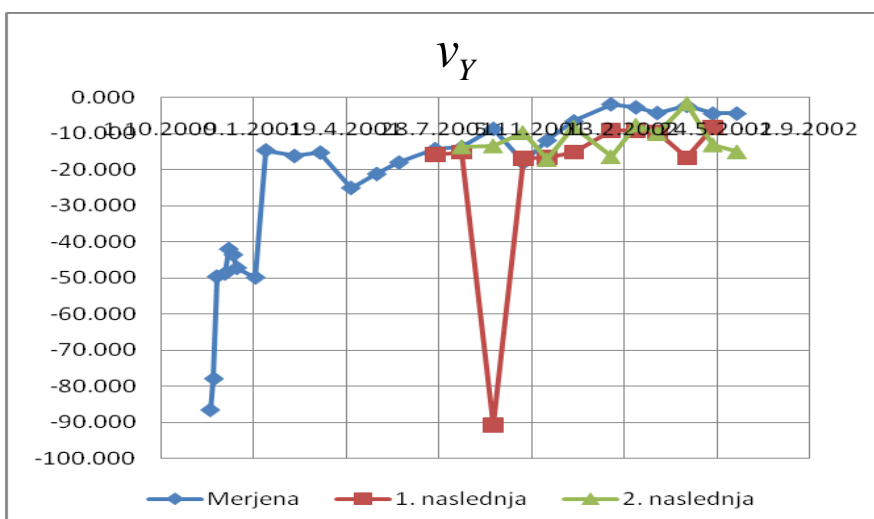
Slika 35: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mreže za točko 604 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih podatkih (hitrosti po osi – v_H , ravnini – v_{XY} in prostoru – v_{XYH}). Uporabljena programska oprema je bila Matlab R2007b.


Opazimo, da se je mreža v tem primeru učila slabše, kot če smo za izhodne podatke uporabili hitrost premika točke po smereh v_X , v_Y in v_H , kar nam je bila naslednja iztočnica. Vrednost cenilke natančnosti SSE znaša 1.95. Tako smo mreži s tremi vhodnimi in izhodnimi podatki, ki se je učila zelo dobro, postopno dodajali izhodne nevrone.

5.5.3 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in štirimi v izhodnem sloju

Glede na zelo dobre rezultate iz prejšnje faze učenja umetne nevronske mreže, kjer smo uporabili tri podatke v izhodnem sloju, smo se odločili poizkusiti še povečati število podatkov v izhodnem sloju, saj smo mnenja, da lahko mreža še lepše porazdeli uteži v povezavah med nevroni in lahko dobimo še boljše rezultate.




Rezultati dobljeni z Neurosolutions:






Slika 36: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in štirih izhodnih podatkih (hitrosti po oseh v_x , v_y , v_H in prostoru – v_{XYH}). Uporabljena programska oprema je bila Neurosolutions.

Rezultati dobljeni z Matlabom:








Slika 37: Grafični prikaz napovedovanja hitrosti premikanja točke po prostoru z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in štirih izhodnih podatkih (hitrosti po oseh v_X , v_Y , v_H in prostoru – v_{XYH}). Uporabljena programska oprema je bila Matlab R2007b.



Rezultate smo z dodanim izhodnim nevrom izboljšali, zato smo dodali še enega. Vrednost cenilke natančnosti SSE znaša 2.11.

5.5.4 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in petimi v izhodnem sloju

Zaradi vse boljših rezultatov učenja umetne nevronske mreže z večanjem števila podatkov na izhodnem sloju smo se odločili, da geometrijo umetne nevronske mreže povečamo še za en podatek. V izhodnem sloju smo podali še podatek za hitrosti premika v ravnini – v_{XY} .




Rezultati dobljeni z Neurosolutions:







Slika 38: Grafični prikaz napovedovanja hitrosti premikanja točke z naučeno umetno nevronske mreže za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih (hitrosti po oseh v_x , v_y , v_H , ravnini – v_{XY} in prostoru – v_{XYH}). Uporabljena programska oprema je bila Neurosolutions.

Rezultati dobljeni z Matlabom:





Slika 39: Grafični prikaz napovedovanja hitrosti premikanja točke z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih (hitrosti po oseh v_x , v_y , v_H , ravnini – v_{XY} in prostoru – v_{XYH}). Uporabljena programska oprema je bila Matlab.



Rezultate smo še izboljšali s tem, da smo dodali 5 izhodni nevron. Vrednost cenilke natančnosti SSE znaša 2.74. Kljub temu pa imamo še vedno lokalne koordinate, kar nas za geodetsko predstavitev plazenja in študije vplivov na okolje moti. Zato smo se odločili nevronske mrežo učiti na Gauß–Krügerjevih koordinatah.


5.5.5 Učenje umetne nevronske mreže s štirimi nevroni v vhodnem in petimi v izhodnem sloju

Za pregledno napovedovanje plazenja niso dovolj lokalne koordinate, ampak so za to potrebne Gauß-Krügerjeve koordinate, saj z njimi lahko bolj pregledno določimo položaj točke na plazu.

Mrežo smo učili s štirimi vhodnimi nevroni in 5 izhodnimi. Vhodnemu sloju smo k trem podatkom o padavinah dodali še časovni interval od ničelne meritve. Za podatke v izhodnem sloju smo uporabili Gauß-Krügerjeve koordinate y , x , H , premik v ravnini d_{xy} in premik v prostoru d_{xyH} .

Rezultati dobljeni z Neurosolutions:










Slika 40: Grafični prikaz napovedovanja hitrosti premikanja točke z naučeno umetno nevronske mrežo za točko 603 pri štirih vhodnih podatkih (časovni interval od ničelne meritve, padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih

(Gauß-Krügerjeve koordinate y , x , H , premik v ravnini d_{xy} in premik v prostoru d_{xyH}).

Uporabljena programska oprema je bila Neurosolutions.

Rezultati dobljeni z Matlabom:






Slika 41: Grafični prikaz napovedovanja hitrosti premikanja točke z naučeno umetno nevronske mrežo za točko 603 pri štirih vhodnih podatkih (časovni interval od ničelne meritve, padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih


(Gauß-Krügerjeve koordinate y , x , H , premik v ravnini d_{xy} in premik v prostoru d_{xyH}).

Uporabljena programska oprema je bila Matlab R2007b.

Ker so rezultati učenja umetnih nevronske mrež in napovedovanja premikov odlični, smo dobljene rezultate še nadalje obdelali. Iz napovedanih premikov, ki smo jih izračunali z naučeno umetno nevronske mrežo, smo izračunali koordinate in jih primerjali s koordinatami, merjenimi na Macesnikovem plazu. Vrednost cenilke natančnosti SSE znaša 0.98, kar potrjuje, da se je mreža dobro naučila. Razlike med izmerjenimi in izračunani koordinatami z umetnimi nevronske mrežami so prikazani na spodnjih grafih. Za nadaljnjo obdelavo so uporabljeni rezultati, dobljeni z Matlabom.



Slika 42: Grafični prikaz 2D (ravnina XY) položaja točke oz. premika točke, dobljenega iz koordinat, merjenih na Macesnikovem plazu in premika točke dobljenega iz koordinat, izračunanih z učeno umetno nevronske mrežo. Premike smo napovedovali za 1. in 2. naslednjo meritev po učnih vhodno–izhodnih parih. Primerjava je narejena za profil 6 in točko 603.

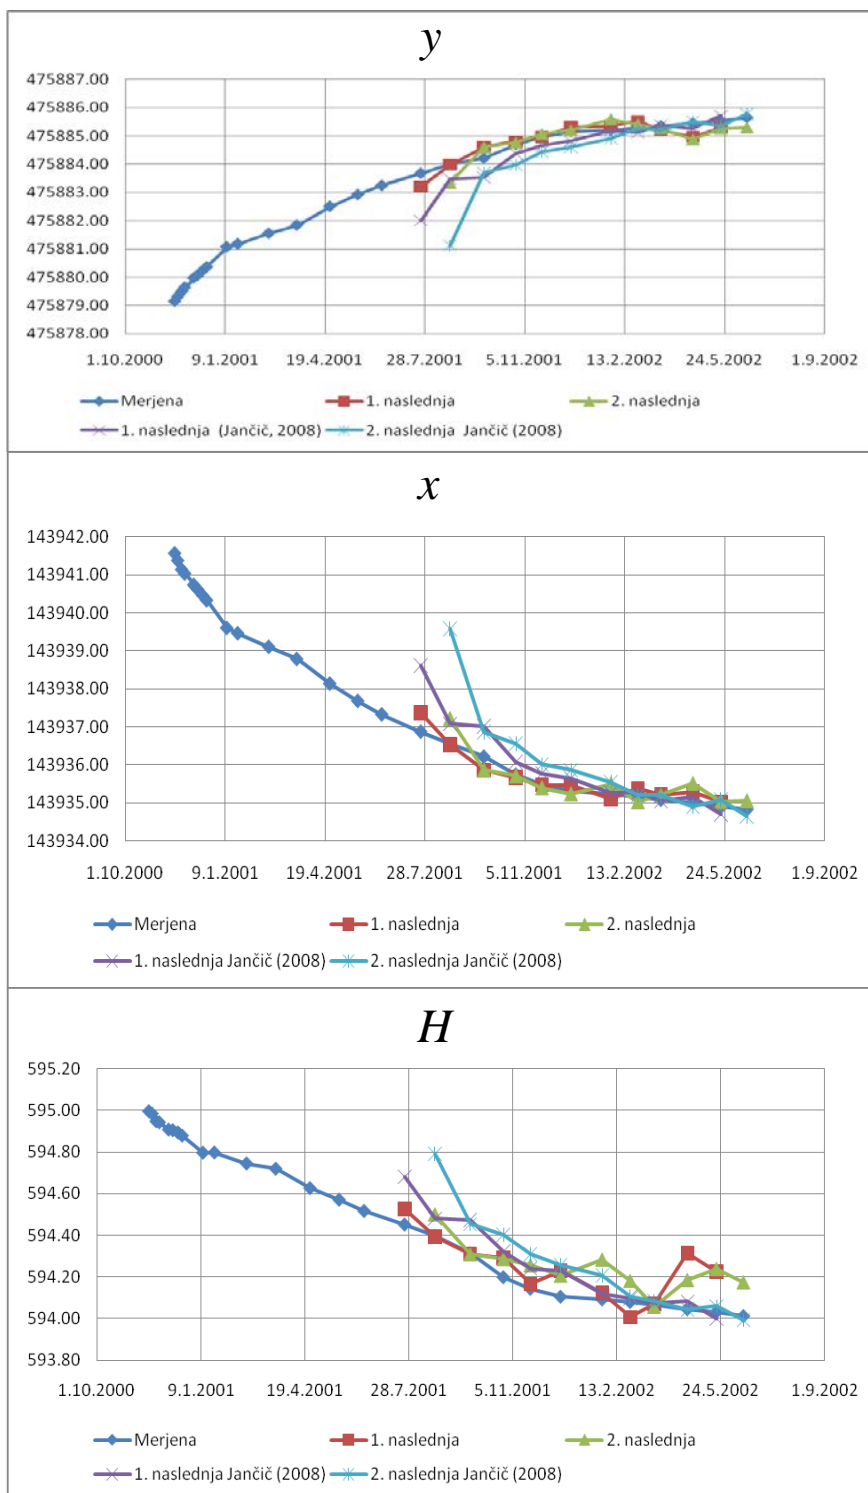


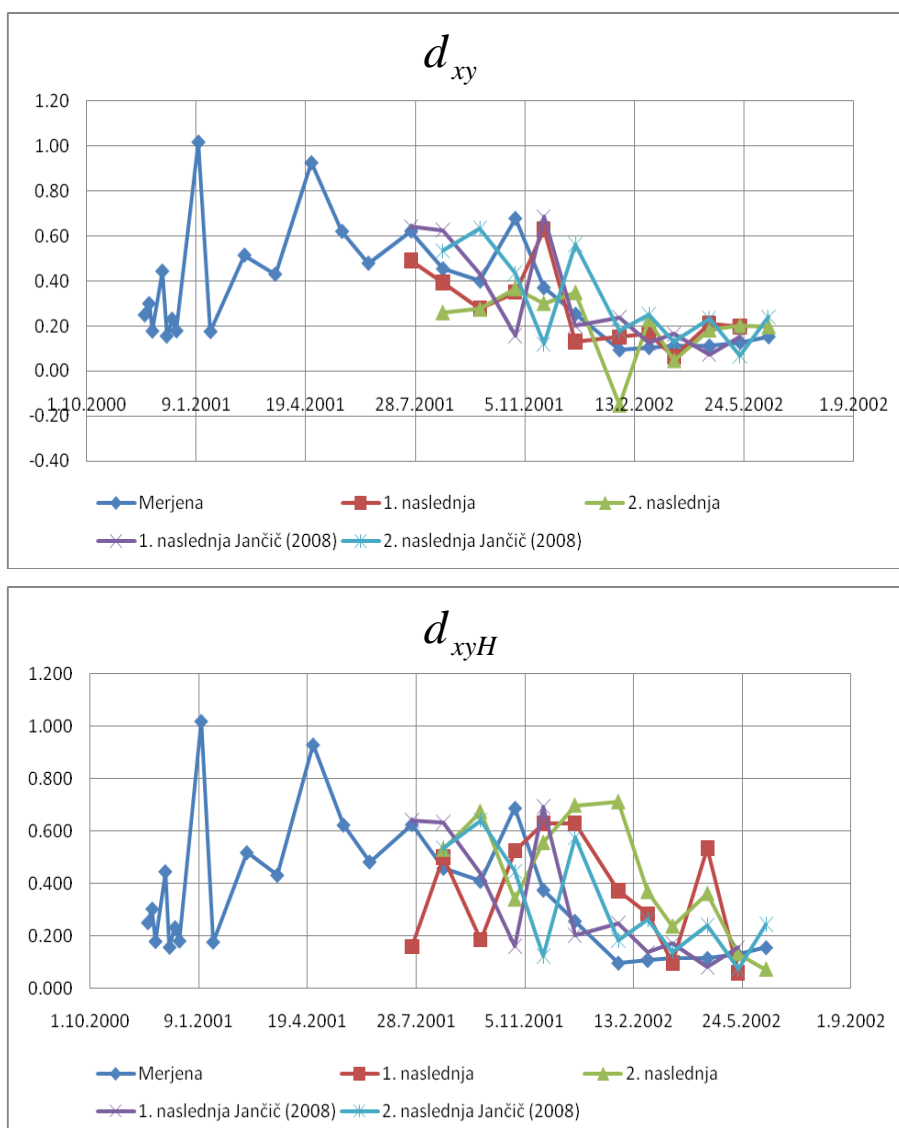
Slika 43: Grafični prikaz višinskega premika točke v smeri osi H, dobljenega iz koordinat, merjenih na Macesnikovem plazu in višinskega premika točke, dobljenega iz napovedi z naučeno umetno nevronske mreže. Premike smo napovedovali za 1. in 2. naslednjo napoved po učnih vhodno–izhodnih parih. Primerjava je narejena za profil 6 in točko 603.

Opazimo lahko, da prihaja do razlik pri rezultatih, dobljenih z Neurosolutions in z Matlabom. Rezultati, dobljeni z Matlabom, se bolj približajo ciljnim vrednostim. Do razlik prihaja, ker je Neurosolutions programsko okolje, čigar namen je izračune umetnih nevronske mreže ponuditi uporabnikom za vsakodnevne probleme. Čeprav so rezultati z Matlabom bolj zanesljivi, pa so obdelava podatkov, izračun in prikaz rezultatov bistveno enostavnejši v Neurosolutions.

Rezultate lahko primerjamo tudi z rezultati prejšnjih raziskav, ki jih je v diplomski nalogi izračunal Bogdan Jančič (glej Jančič, 2008). Avtor je napovedoval premike na Macesnikovem plazu z vzratnim razširjanjem napake (ang. back-propagation). Čeprav so na začetku raziskav rezultati, izračunani z umetnimi nevronske mrežami RBF bili slabši kot rezultati, izračunani z vzratnim razširjanjem napake, so se s številom večanja izhodnih nevronov izboljšali ter se tudi bolj približali dejanskim ciljnim vrednostim.

Dobljeni rezultati so odlični, saj mreža napoveduje s točnostjo parih centimetrov. Na podlagi te mreže lahko napovedujemo dogajanje v prihodnje. To mrežo bi lahko uporabili za napovedovanje v praksi.





Slika 44: Primerjava rezultatov umetne nevronske mreže RBF in umetne nevronske mreže z vzratnim razširjanjem napake. Primerjava je narejena za profil 6 in točko 603.

Iz grafov razberemo, da se rezultati umetne nevronske mreže RBF točneje prilegajo pravim vrednostim. Vidimo, da se zveznici točk izračunani z umetno nevronske mreže RBF (1. naslednja in 2. naslednja) bolje prilegata izmerjenim vrednostim kot pa rezultati umetne nevronske mreže z vzratnim razširjanjem napake (Jančič, 2008).

6 ZAKLJUČEK

Premiki plazov so odvisni od mnogih dejavnikov (padavine, topografija, geologija, materialne lastnosti,...), zato jih je težko napovedati. Povezave med premiki, padavinami, temperaturami in inklinacijo terena so preveč kompleksne, da bi jih opisali z matematičnimi zvezami. Zato jih poskusimo opisati z umetnimi nevronskimi mrežami.

Ključno vlogo pri sprožanju in premikih plazov imajo padavine. Zato smo jih poleg meritev premikov na površju plazu uporabili pri učenju umetne nevronske mreže. V izračunih smo prevzeli, da je edini parameter, ki vpliva na premike, količina padavin. Pomembna je predvsem razporeditev padavin, zato smo podatke o padavinah, ki smo jih dobili od meteorološke postaje Solčava, obdelali in kot vhodne podatke pri učenju nevronskih mrež uporabili vsoto padavin za 90 dni, 10 dni in 5 dni nazaj. Umetne nevronske mreže so sistemi, ki omogočajo preslikavo niza vhodnih podatkov (v našem primeru so to bile količine padavin in čas) v niz izhodnih podatkov (premiki plazu) brez poznavanja vseh ostalih parametrov plazu in teorije odnosov med vhodnimi in izhodnimi podatki.

Umetno nevronske mreže učimo s pomočjo znanih podatkov (vhodno–izhodnih parov), ki so se zgodili v nekem obdobju. Ti so povezani med seboj preko nevronov z utežmi, ki se spreminjajo v procesu učenja tako dolgo, dokler izhodni podatki ustrezajo vhodnim podatkom. Ko je ta pogoj izpolnjen, se z umetno nevronske mreže lahko izračuna oz. napove izhodne podatke tudi za vhodne podatke, ki niso sodelovali v procesu učenja. V našem primeru je bilo to tako, da smo mrežo učili na primer na podatkih 14 merjenj padavin in premikov v obdobju od 20.11.2000 do 15.6.2001 in poskušali napovedati premike za naslednji dve meritvi. Število učnih parov smo povečevali do 25. meritve in z njimi napovedali premike v 26. in 27. meritvi.

V nalogi smo uporabili radialno bazično umetno nevronske mreže. Namen naloge je bil izboljšati rezultate prejšnjih raziskav, ki jih je v diplomski nalogi izračunal Bogdan Jančič. V diplomski nalogi z naslovom: Napovedovanje plazenja zemljin z umetnimi nevronskimi mrežami, je avtor napovedoval premike na Macesnikovem plazu z vzratnim razširjanjem

napake (ang. back-propagation). Predvidevali smo, da bomo z radialnimi bazičnimi mrežami dobili boljše rezultate.

V vseh primerih napovedovanja plazenja zemljin smo umetno nevronske mreže učili toliko časa, da je bil izpolnjen kriterij, ki predpisuje vrednost še dopustne napake na izhodnem sloju nevronov med želeno vrednostjo in z umetno nevronske mreže izračunano vrednostjo.


Pri izračunih je bilo potrebno veliko eksperimentiranja, saj nismo vedeli, katero geometrijo mreže naj izberemo. Tako smo poizkušali z različnimi kombinacijami vhodno-izhodnih parov, prav tako smo iz podatkov preračunavali nove podatke. Ko smo dobili dobre rezultate, smo poizkusili te rezultate še izboljšati s preračunom teh podatkov.

Med poskušanjem smo opazili, da se kvaliteta rezultatov izboljšuje. Vse dokler nismo našli geometrije, ki nam ustreza, smo z delom nadaljevali. Uspešnejše se je umetna nevronska mreža začela učiti, ko smo v vhodne podatke dodali padavine v treh nevronih (seštevek padavin za 90, 10 in 5 dni nazaj od dneva meritev). Najboljše rezultate pa smo dobili, ko smo še povečali število nevronov na izhodnem sloju. Mislimo, da so s tem uteži še lepše in pravilnejše razdelile med vse povezave, kar je posledično pripeljalo še do boljših rezultatov.

Pri analizi dobljenih rezultatov smo prišli do pomembne ugotovitve, da dobimo boljše rezultate, če uporabimo funkcije iz Matlabove knjižnice kot, če uporabimo programsko orodje Neurosolutions. S primerjavo rezultatov, dobljenih z umetno nevronske mreže z vzratnim razširjanjem napake (Jančič, 2008) in našimi rezultati ugotovimo, da dobimo z umetno nevronske mreže RBF točnejše napovedi gibanja pazu.

S transformacijo lokalnih koordinat v Gauß-Krügerjev koordinatni sistem smo dosegli cilj diplomske naloge. Z umetno nevronske mreže, ki se je naučila na primeru štirih vhodnih (časovni interval od ničelne meritve, padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih parametrov (Gauß-Krügerjeve koordinate y , x , H , premik v ravnini d_{xy} in premik v prostoru d_{xyH}), lahko napovedujemo premikanje zemljin ob poznani količini padavin. Naučena umetna nevronska mreža je uporabna neposredno v praksi, saj bi se lahko

civilna zaščita, glede na podatke o pričakovanih padavinah za naslednji teden ali mesec in z naučeno umetno nevronske mrežo, odločala o morebitnih evakuacijah ogroženih ljudi ali drugih ukrepih.



Slika 44: Grafični prikaz višinskega premika točke v smeri osi H, dobljenega iz koordinat, merjenih na Macesnikovem plazu in višinskega premika točke, dobljenega iz napovedi z naučeno umetno nevronske mrežo. Zadnja meritev predstavlja nihanje nadmorske višine

točke v odvisnosti od količine padavin. Količino padavin smo predstavili z intervalom od 30 mm do 300 mm padavin. Primerjava je narejena za profil 6 in točko 603. Uporabljena programska oprema je bila Matlab.

Preglednica 7: Tabelarični prikaz spreminjanja nadmorske višine točke 603 v odvisnosti od količine padavin.

Količina padavin [mm]	H [m]
30	594.028
60	594.027
90	594.025
120	594.024
150	594.023
180	594.023
210	594.017
240	594.016
270	594.015
300	594.013

Iz slike 44 in preglednice 7 vidimo, da je višinski premik točke v smeri osi H odvisen od količine padavin. Nadmorska višina H pada z naraščanjem količine padavin. To nam potrjujejo, da se je mreža dobro učila in da so napovedani rezultati logični in smiselni.

VIRI

Ambrožič, T. 2001. Aplikacija umetnih nevronskih mrež v napovedovanju ugrezanja zaradi podzemnega rudarjenja. Doktorska disertacija, Ljubljana, Univerza v Ljubljani, Naravoslovnotehniška fakulteta, Oddelek za geotehnologijo in rudarstvo: str. 47–62.

Avsenik, L. 2009. Uporaba umetnih nevronskih mrež za napovedovanje premikov zemeljskih plazov. Seminarska naloga, Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Oddelek za gradbeništvo. 57 str.

Bellerby, T., Todd, M., Kniveton, D., Kidd, C. 2000. Rainfall Estimation from a Combination of TRMM Precipitation Radar and GOES Multispectral Satellite Imagery through the Use of an Artificial Neural Network. American Meteorological Society, Journal of applied meteorology, Volume 39, str. 2115 – 2128.

Bors, A. 2000. Introduction of the Radial Basis Function (RBF) Networks. University of York, Department of Computer Science. 7 str.

Derenda, I. 2007. Aproksimacija višinske referenčne ploskve z umetnimi nevronskimi mrežami. Diplomaska naloga, Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Oddelek za geodezijo. 154 str.

Dobnikar, A. 1990. Nevronske mreže. Teorija in aplikacije. Radovljica, Didakta: 154 str.

Hafner, J. 1999. Integracija GIS-a in umetne inteligence v geologiji. Doktorska disertacija, Ljubljana, Univerza v Ljubljani, Naravoslovnotehniška fakulteta, Oddelek za geologijo: str. 67-91.

Haykin, S. 1999. Neural networks: a comprehensive foundation. 2nd. Edition. Upper Saddle River (New Jersey), Prentice Hall International: 842 str.

Jančič, B. 2008. Napovedovanje plazenja zemljin z umetnimi nevronskimi mrežami. Diplomatska naloga, Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Oddelek za geodezijo. 105 str.

Jelen, B., Hribar, T. 2000. Kontrolne meritve deformacij površine na Macesnikovem plazu. Poročilo ničelnih meritev: št.: ic 396/2000. Ljubljana: IRGO Consulting d.o.o.

Jelen, B., Hribar, T. 2000. Kontrolne meritve deformacij površine na Macesnikovem plazu. Poročilo prve serije meritev: št.: ic 397/2000. Ljubljana: IRGO Consulting d.o.o.

Jelen, B., Hribar, T. 2000. Kontrolne meritve deformacij površine na Macesnikovem plazu. Poročilo druge serije meritev: št.: ic 398/2000. Ljubljana: IRGO Consulting d.o.o.

Jelen, B., Hribar, T. 2001. Kontrolne meritve deformacij površine na Macesnikovem plazu. Poročilo šestnajste serije meritev: št.: ic 369/2001. Ljubljana: IRGO Consulting d.o.o.

Jelen, B., Hribar, T. 2002. Kontrolne meritve deformacij površine na Macesnikovem plazu. Poročilo sedemindvajsete serije meritev: št.: ic 424/2002. Ljubljana: IRGO Consulting d.o.o.

Križnič, A. 2006. Mehanizem plazenja in analiza gibanja Macesnikovega plazu. Magistrsko delo, Ljubljana, Univerza v Ljubljani, Naravoslovnotehniška fakulteta, Oddelek za geologijo: str. 2-92.

Kohonen, T. 1996. Self-Organizing Maps. 3rd. Edition. Berlin, Springer: 487 str.

Majes, B. 2000. Izvajanje postopne sanacije velikih plazov v Sloveniji. Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Katedra za mehaniko tal z laboratorijem. <http://www.sloged.si/LinkClick.aspx?fileticket=V809uvBBC%2BA%3D&tabid=125> (27.10.2010).

Matlab 5.3.0.10183, Release 11, Windows Version, MathWorks, 1997, Neural Network Toolbox, str. 46-418.

Meteorološki letopisi. Letopis 1999, Letopis 2000, Letopis 2001, Letopis 2002. Agencija Republike Slovenije za okolje, 2007

http://www.arso.gov.si/vreme/podnebje/meteorolo%C5%A1ki%20letopis/meteoroloski_letopisi.htm (7. 2. 2007)

Potočnik, P. 1999. Uporaba nevronske mreže in genetskih algoritmov pri modeliranju in prediktivnem vodenju procesov. Doktorsko delo, Ljubljana, Univerza v Ljubljani, Fakulteta za strojništvo. 105 str.

PRILOGE:

- Priloga A: Program radialne bazične umetne nevronske mreže

Priloga A: Program radialne bazične umetne nevronske mreže

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% RADIAL BASIC ARTIFICIAL NEURAL NETWORK (RBF)
%-----
% RADIALNE BAZIČNE UMETNE NEVRONSKE MREŽE
%-----
%
% ALGORITEM UČENJA: RADIALNE BAZIČNE FUNKCIJE
%-----
% VSEBINA PROGRAMA: namenjen pripravi podatkov, definiranju parametrov,
% učenju, simuliranju, kontroli rezultatov ter vizualnim in
% numeričnim prikazom rezultatov;
%-----
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Branje podatkov iz datoteke
clear
%
iteracij=100;
for i=1:iteracij
    data = load('602_4vh_5izh.dat');
%-----
%
% Razporeditev prebranih podatkov
%
p = data(1:4,:); % vhodni podatki (st.dni, w90, w10, w5)
tn = data(4:8,:); % izhodni podatki (Y, X, H, dyx, dyxz)
st_ucnih = 14; % stevilo ucnih podatkov
%-----
%
% Normiranje podatkov
%
pn = mapstd(p);
[tn,ts] = mapstd(tn);
%-----
%
% Testirani niz podatkov (uporabljeno za testiranje)
%
iitst = [1:26-st_ucnih]+st_ucnih; %st. testnih=st_vseh-st_ucnih
%-----
%
% Trenirani niz podatkov (uporabljeno za optimizacijo parametrov)
%
iitr = [1:st_ucnih];
%-----
```

```
%  
% Priprava normiranih testnih in učnih podatkov  
%  
tts = tn(:,iitst);  
ptr = pn(:,iitr);  
ttr = tn(:,iitr);  
-----  
%  
% Parametri pri treniranju  
%  
spread = i/iteracij;  
goal = 1.0e-3;  
-----  
%  
% Treniranje mreže  
%  
[net,tr] = newrb(ptr,ttr,goal,spread,99,1);  
-----  
%  
% Simuliranje mreže  
%  
an = sim(net,pn);  
-----  
%  
e0 = an(:,iitst)-tn(:,iitst); % Napaka = napovedane - pričakovane  
a0 = sse(e0); % Vrednost sse  
statistika = [a0]; % Vrednost izbrane funkcije pogreškov  
a = an(:,iitst); % Normirane testirane (napovedane)vrednosti  
-----  
%  
% Odnormirane napovedane in pričakovane vrednosti  
%  
a = mapstd('reverse',a,ts);  
tts = mapstd('reverse',tts,ts);  
-----  
%  
% Vrednost statistike  
%  
disp('vsota kvadratne napake')  
statistika;  
-----  
%  
% Napovedane in pričakovane vrednosti  
%  
disp('napovedane & pričakovane vrednosti za testni niz')  
i, spread  
[a' tts'];  
razlika=a-tts;  
tr=max(abs(razlika));  
vsotadveh(i)=tr(1)+tr(2);  
% min=min(razlika)  
end  
vsotadveh  
mala=min(vсотadveh)  
for i=1:iteracij  
    if vsotadveh(i)==mala  
        lega_mala=i  
    end  
end  
end
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% RADIAL BASIC ARTIFICIAL NEURAL NETWORK (RBF)
%-----
% RADIALNE BAZIČNE UMETNE NEVRONSKE MREŽE
%-----
%
% ALGORITEM UČENJA: RADIALNE BAZIČNE FUNKCIJE
%-----
% VSEBINA PROGRAMA: namenjen pripravi podatkov, definiranju parametrov,
% učenju, simuliranju, kontroli rezultatov ter vizualnim in
% numeričnim prikazom rezultatov;
%
% Program izracuna smo za podano vrednost spread (ki jo izracuna program
% iteracije) rezultate RBF.
%-----
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%
% Branje podatkov iz datoteke
%
data = load('602_4vh_5izh.dat');
%-----
%
% Razporeditev prebranih podatkov
%
p = data(1:4,:); % vhodni podatki (st. dni, w90, w10, w5)
tn = data(4:8,:); % izhodni podatki (Y, X, H, dyx, dyxz)
%-----
%
% Normiranje podatkov
%
pn = mapstd(p);
[tn,ts] = mapstd(tn);
%-----
%
% Testirani niz podatkov (uporabljeno za testiranje)
%
iitst = [1:26-st_ucnih]+st_ucnih; %st. testnih=st_vseh-st_ucnih
%-----
%
% Trenirani niz podatkov (uporabljeno za optimizacijo parametrov)
%
iitr = [1:st_ucnih];
%-----
%
% Priprava normiranih testnih in učnih podatkov
%
tts = tn(:,iitst);
ptr = pn(:,iitr);
ttr = tn(:,iitr);
%-----
%
% Parametri pri treniranje
%
spread = lega_mala/iteracij;
goal = 1.0e-3;
%-----
%
% Treniranje mreže
```

