

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*



Univerzitetni program Geodezija,  
smer Geodezija

Kandidat:

**Bogdan Jančič**

# **Napovedovanje plazjenja zemljin z umetnimi nevronskimi mrežami**

**Diplomska naloga št.: 767**

**Mentor:**

izr. prof. dr. Tomaž Ambrožič

**Somentor:**

izr. prof. dr. Janko Logar

Ljubljana, 8. 10. 2008

## **STRAN ZA POPRAVKE, ERRATA**

**Stran z napako**

**Vrstica z napako**

**Namesto**

**Naj bo**

**IZJAVA O AVTORSTVU**

Podpisan **BOGDAN JANČIČ** izjavljam, da sem avtor diplomske naloge z  
naslovom: »**Napovedovanje plazenja zemljin z umetnimi nevronskimi mrežami**«.

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

Ljubljana, ..... ..

## **BIBLIOGRAFSKO – DOKUMENTACIJSKA STRAN IN IZVLEČEK**

<b>UDK:</b>	<b>004:528:551.3.053(043.2)</b>
<b>Avtor:</b>	<b>Bogdan Jančič</b>
<b>Mentor:</b>	<b>doc. dr. Tomaž Ambrožič</b>
<b>Somentor:</b>	<b>doc. dr. Janko Logar</b>
<b>Naslov:</b>	<b>Napovedovanje plazenja zemljin z umetnimi nevronskimi mrežami</b>
<b>Obseg in oprema:</b>	<b>105 str., 9 preg., 26 sl., ___ en.</b>
<b>Ključne besede:</b>	<b>Macesnikov plaz, umetna nevronska mreža, geodetske meritve, premiki, padavine, analiza</b>

### **Izvodček:**

Diplomsko delo obravnava problem napovedovanja plazenja zemljin z umetnimi nevronskimi mrežami. V njem najprej predstavimo plazove na splošno, ter posebej Macesnikov plaz. V nadaljevanju opišemo geodetske metode za spremljanje premikov zemeljskih plazov od referenčnih geodetskih metod do geodetskih metod za masovni zajem. Naštejemo vsebine projekta, ki naj bi ga uporabljali izvajalci geodetskih opazovanj na Macesnikovem plazu. Sledi opis vseh dosedanjih opazovanj na Macesnikovem plazu in analiza vpliva padavin na plazenje. V petem delu predstavimo umetne nevronske mreže, pravila učenja umetnih nevronskih mrež ter podrobno razložimo umetno nevronske mrežo z vzratnim razširjanjem napake. V eksperimentalnem delu je prikazana uporaba umetnih nevronskih mrež pri napovedovanju plazenja zemljin. Predvidevamo, da njihova uporaba predstavlja alternativo klasičnim prognoznim metodam, ki jih pridobimo z geološkimi, hidrološkimi in geomehanskimi meritvami. Za plazove je značilno, da noben vplivni dejavnik ne more zanesljivo razložiti obnašanja plazenja zemljine, prav tako je s statističnimi orodji težko pravilno ugotoviti odvisnosti med posameznimi vplivnimi dejavniki. Za uporabo umetnih nevronskih mrež ne potrebujemo poznavanja vseh vplivnih dejavnikov, prav tako ne potrebujemo poznavanja odvisnosti med njimi. Umetna nevronska mreža se nauči teh relacij iz dovolj velikega števila vhodno – izhodnih parov. Za vhodne podatke smo uporabili meritve padavin, za izhodne pa premike plazenja zemljine. V sedmem delu podamo zaključek, ki vsebuje kratek povzetek vseh glavnih ugotovitev.

**BIBLIOGRAPHIC – DOCUMENTALISTIC INFORMATION**

**UDC:** 004:528:551.3.053(043.2)  
**Author:** Bogdan Jančič  
**Supervisor:** assist. prof. dr. Tomaž Ambrožič  
**Cosupervisor:** assist. prof. dr. Janko Logar  
**Title:** The prediction of landslide movements with artificial neural networks  
**Notes:** 105 p., 9 tab., 26 fig., \_\_\_ eq.  
**Key words:** Macesnik's landslide, artificial neural network, geodetic measurements, movements, rainfall, analysis

**Abstract**

The thesis deals with the problem of the prediction of landslide movements with artificial neural networks (ANN). At the beginning of the thesis the landslides are introduced in general and especially the Macesnik landslide. Later on geodetic methods for observing movements of landslides are described from referential geodetic methods to geodetic methods for mass collection. The list of content of the project is proposed, which should be used for geodetic observations of the Macesnik slide. The description of all past geodetic observations of the Macesnik slide is given and analysis of the effect of rainfall on the landslide movements is presented. In the fifth part artificial neural networks are presented, the training principles of artificial neural networks and a detailed explanation of artificial neural network with error back propagation algorithm. In the experimental part we have presented the use of artificial neural networks for the prediction of landslide movements. It is shown that the use of ANN can be a successful alternative to other methods, which require thorough geological, hydrological and geomechanical evaluation. It is usual for landslides that none of influential factors alone can reliably explain the sliding mechanism of the slope. Also, with statistical tools it is difficult to correctly determine dependency between individual influential factors. To use artificial neural networks we do not need to know all influential factors and we also do

not need to study the relationships between them. Artificial neural network is trained to capture these relations from a large enough number of input and output data sets. For input and output data we have used the measurements of rainfall and measured movements of the landslide, respectively. At the end conclusions are given, which include a short summary of all major findings.

## ZAHVALA

Za pomoč, strokovne nasvete, pripombe in predvsem za potrpežljivost in spodbujanje pri nastajanju diplomske naloge se iskreno zahvaljujem mentorju doc. dr. Tomažu Ambrožiču in somentorju doc. dr. Janku Logarju.

Posebna zahvala gre T. Hribarju, ki mi je posredoval vse potrebne podatke o meritvah na Macesnikovem plazu in B. Jelenu, direktorju Inštituta za rudarstvo, geotehnologijo in okolje, ki je dovolil njihovo uporabo v študijske namene.

Hvala Nataši Kovač iz Agencije Republike Slovenije za okolje za posredovanje vseh podatkov o padavinah na meteorološki postaji Solčava.

Za pomoč, razumevanje in motivacijo med pisanjem diplomske naloge se zahvaljujem prijatelju Primožu, puncu Nini in sodelavcem iz podjetja Nivo d.d.

Zahvala gre tudi mojim staršem in sestri, ki so mi skozi vsa leta študija nudili pomoč.

.

## KAZALO VSEBINE

<b>1 UVOD</b>	<b>1</b>
<b>2 SPLOŠNO O PLAZOVIH IN PREDSTAVITEV MACESNIKOVEGA PLAZU</b>	<b>3</b>
2.1 Plazenje zemljin	3
2.2 Vrste plazenj	3
2.3 Opis Macesnikovega plazu	5
2.5 Vpliv padavin na plazenje	7
2.6 Vpliv naklona terena na plazenje	8
<b>3 GEODETSKE METODE ZA SPREMLJANJE PREMICOV ZEMELJSKIH PLAZOV</b>	<b>9</b>
3.1 Referenčne geodetske metode	10
3.1.1 Klasične geodetske meritve	10
3.1.2 Meritve GPS	15
3.1.2.2 Sprejemniki GPS	19
3.1.2.3 Planiranje izmere GPS	19
3.2 Geodetske metode za masovni zajem	20
3.2.2 Lasersko skeniranje	22
3.3 Druge geodetske metode	25
3.3.1 Uporaba satelitskih posnetkov	26
3.3.2 Uporaba radarja z umetno odprtino (SAR) za določanje modela reliefa	26
3.4 Vidiki pri izbiri merske metode	28
3.4.1 Metode za določitev stanja pred nastankom plazu	28
3.4.2 Metode za določitev premikov plazu	29
3.4.3 Metode za izdelavo posnetka stanja plazu	31
<b>4 OPAZOVANJE MACESNIKOVEGA PLAZU</b>	<b>32</b>
4.1 Merjenje premikov	32
4.1.1 Izvedba meritev premikov	33
4.2 Opis vsebin projekta, ki bi ga naj uporabljali izvajalci geodetskih opazovanj na Macesnikovem plazu	37
4.2.1 Projekt geodetske mreže	37
4.2.2 Izdelava projekta geodetskega opazovanja premikov tal in objektov	38



<b>4.3 Merjenje višine padavin</b>	<b>40</b>
<b>4.3.1 Vpliv padavin na nastanek plazov</b>	<b>40</b>
<b>4.3.2 Analiza vpliva padavin na gibanje plazov</b>	<b>40</b>
<b>5 UMETNE NEVRONSKE MREŽE</b>	<b>46</b>
<b>6. EKSPERIMENTALNI DEL</b>	<b>52</b>
<b>6.1 Uporabljena programska oprema</b>	<b>52</b>
<b>6.2 Vhodno-izhodni pari pri učenju umetnih nevronske mrež</b>	<b>53</b>
<b>6.3 Učenje umetne nevronske mreže z enim podatkom v vhodnem sloju - časovnim intervalom od ničelne meritve</b>	<b>54</b>
<b>6.3.1 Geometrije uporabljenih umetnih nevronske mrež</b>	<b>54</b>
<b>6.3.2 Določitev uteži</b>	<b>55</b>
<b>6.3.3 Rezultati</b>	<b>55</b>
<b>6.4 Učenje umetne nevronske mreže z dvema vhodnima podatkom</b>	<b>58</b>
<b>6.5 Učenje umetne nevronske mreže s tremi vhodnimi podatki</b>	<b>58</b>
<b>6.5.1 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in enim v izhodnem sloju</b>	<b>59</b>
<b>6.5.2 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in tremi v izhodnem sloju</b>	<b>61</b>
<b>6.5.3 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in štirimi v izhodnem sloju</b>	<b>67</b>
<b>6.5.4 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in petimi v izhodnem sloju</b>	<b>70</b>
<b>6.5.5 Učenje umetne nevronske mreže s štirimi nevroni v vhodnem in petimi v izhodnem sloju</b>	<b>76</b>
<b>7 ZAKLJUČEK</b>	<b>82</b>
<b>VIRI</b>	<b>86</b>

## KAZALO PREGLEDNIC

<b>Preglednica 1: Mesečna količina padavin izmerjena v padavinski postaji Solčava (ARSO, 2005)</b>	<b>41</b>
<b>Preglednica 2: Oblika datoteke, ki vsebuje splošne podatke</b>	<b>53</b>
<b>Preglednica 2: Oblika datoteke, ki vsebuje splošne podatke</b>	<b>53</b>
<b>Preglednica 3: Rezultati testiranja naučene umetne nevronske mreže za primer točke 803 pri enem vhodnem (število dni od ničelene meritve) in treh izhodnih (X, Y, in H koordinata) podatkih</b>	<b>56</b>
<b>Preglednica 4: Rezultati testiranja naučene umetne nevronske mreže za primer točke 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in enim izhodnim (hitrost premika točke po prostoru) podatkom</b>	<b>59</b>
<b>Preglednica 5: Rezultati testiranja naučene umetne nevronske mreže za primer točke 602 pri treh vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih (hitrosti v smereh osi - <math>v_x</math>, <math>v_y</math> in <math>v_H</math>) podatkih</b>	<b>61</b>
<b>Preglednica 6: Rezultati testiranja naučene umetne nevronske mreže za primer točke 604 pri 3 vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih (hitrosti po osi <math>v_H</math>, ravnini - <math>v_{XY}</math> in prostoru - <math>v_{XYH}</math>) podatkih. Imeli smo 18 učnih in 2 testna vhodno-izhodna para</b>	<b>65</b>
<b>Preglednica 7: Rezultati testiranja naučene umetne nevronske mreže za primer točke 602 pri treh vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in štirih izhodnih podatkih (hitrosti po oseh <math>v_x</math>, <math>v_y</math>, <math>v_H</math> in hitrost premika po prostoru <math>v_{XYH}</math>)</b>	<b>68</b>
<b>Preglednica 8: Rezultati testiranja naučene umetne nevronske mreže za primer točke 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih (hitrosti po oseh <math>v_x</math>, <math>v_y</math>, <math>v_H</math>, hitrost premika po ravnini) in hitrost premika po prostoru. Imeli smo 24 učnih in 2 testna vhodno-izhodna para</b>	<b>71</b>
<b>Preglednica 9: Rezultati testiranja naučene umetne nevronske mreže za primer točke 603 pri štirih vhodnih podatkih (časovni interval v dnevih od (prve) ničelne meritve in padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih (Gauß – Krügerjeve koordinate Y, X, H, 2D premik v ravnini XY in 3D premik v prostoru XYH) in pri 19 učnih vhodno-izhodnih parih in 2 testnih</b>	<b>77</b>

**KAZALO SLIK**

<b>Slika 1: Klasifikacija gravitacijskega gibanja mas po vlažnosti materiala in hitrosti gibanja (Park, 1997)</b>	<b>4</b>
<b>Slika 2: Lega Macesnikovega plazu</b>	<b>5</b>
<b>Slika 3: Spodnji del Macesnikovega plazu pod Olševo (foto: M. Zorn)</b>	<b>6</b>
<b>Slika 4: Stabilizacija z betonskim stebrom (Vodopivec, Kogoj, 2005)</b>	<b>12</b>
<b>Slika 5: Stabilizacija z uporabo prenosljivih kovinskih stebrov (Vodopivec, Kogoj, 2005)</b>	<b>13</b>
<b>Slika 6: Talna stabilizacija merske točke in ekscentrično stojišče (Vodopivec, Kogoj, 2005)</b>	<b>14</b>
<b>Slika 7: Grafični prikaz postavitve merskih profilov za območje Macesnikovega plazu</b>	<b>34</b>
<b>Slika 8: Primer analize meritev in izračun pomikov</b>	<b>35</b>
<b>Slika 9: Grafični prikaz pomikov z vektorji</b>	<b>36</b>
<b>Slika 10: Koeficient korelacije med zapoznelim vplivom 30 dnevnih padavin na hitrost plazanja (Križnič, 2006)</b>	<b>42</b>
<b>Slika 11: Koeficient korelacije med padavinami in hitrostjo premikanja ob upoštevanju širšega intervala padavin ter 30 dnevnega zamika vpliva padavin (Križnič 2006)</b>	<b>44</b>
<b>Slika 12: Sestava biološkega nevrona</b>	<b>46</b>
<b>Slika 13: Večslojna usmerjena umetna nevronska mreža (Ambrožič, 2001)</b>	<b>47</b>
<b>Slika 14: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mreže</b>	<b>60</b>
<b>Slika 15: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mreže</b>	<b>63</b>
<b>Slika 16: Prikaz datoteka z 18 vhodno-izhodnimi pari podatkov za učenje umetne nevronske mreže</b>	<b>64</b>

<b>Slika 17: Prikaz testne datoteke z 19-im in 20-im vhodno-izhodnim parom za testiranje nevronske mreže</b>	<b>65</b>
<b>Slika 18: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mrežo</b>	<b>67</b>
<b>Slika 19: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mrežo</b>	<b>70</b>
<b>Slika 20: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mrežo</b>	<b>73</b>
<b>Slika 21: Grafični prikaz relativne razlike med izračunanimi (napovedovanje 1. naslednje meritve) in izmerjenimi premiki na Macesnikovem plazu. Gre za profil 6, točko 602</b>	<b>74</b>
<b>Slika 23: 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</b>	<b>75</b>
<b>Slika 24: 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</b>	<b>75</b>
<b>Slika 25: Prikaz učne datoteke z 19-imi učnimi pari (prvih 19 meritev) za učenje umetne nevronske mreže v profilu 6 v točki 603</b>	<b>77</b>
<b>Slika 26: Grafični prikaz napovedovanja premikanja z naučeno umetno nevronske mrežo</b>	<b>80</b>



## 1 UVOD

Plaz Macesnik sodi med zemljinske tokove, ki sčasoma rastejo (se širijo) in katerih čelo napreduje navzdol, kakor tudi vsak del plazeče mase. V diplomski nalogi predstavljamo možnost uporabe umetnih nevronskih mrež pri napovedovanju plazenja zemljin na plazovitih območjih. Obstajajo metode za napovedovanje plazenja, ampak pretežno za nastanek plazu, ali pa za analizo izteka hitrih drobinskih in blatnih tokov. Praktično pa ni metode, ki bo uspešno napovedala hitrost plazenja (velikost premika) ob naslednjem deževju. Z delom želimo posegati 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. Opisanih je več možnih geodetskih merskih metod za spremljanje premikov in celoten projekt, ki bi moral biti narejen za njihovo spremljanje na Macesnikovem plazu.

Pri meritvah količine padavin se lotimo analize vpliva padavin na gibanje plazu in njihove soodvisnosti oz. povezave. Tu naletimo na zanimive rezultate, saj se plaz premika s časovnim zamikom glede na trenutne padavine in različno hitro glede na velikost večmesečnih padavin.

Za določanje stabilnosti plazu se danes uporabljajo različne analitične in numerične metode. Vsaka izmed metod ima svoje prednosti in slabosti. Za vse metode je značilno, da v izračunu upoštevajo le omejeno število vhodnih parametrov. Glavna prednost uporabe umetnih nevronskih mrež je, da pri napovedovanju plazenja zemljin ni potrebno poznati vseh lastnosti zemljine (geomehanskih meritev, nivo podtalnice, inklinometriških meritev,..) in ni potrebno poznati funkcijskih zvez med posameznimi različnimi merjenji, ki so nepogrešljive pri klasičnih metodah napovedovanja, da z ustrezno natančnostjo napovemo plazenje. Poznati moramo le vzroke in posledice za nastanek plazov. Glavni vzrok je količina padavin, posledica pa je z različnimi merskimi metodami izmerjen premik plazu.

Preprosti elementi, imenovani nevroni, ki so v mreži predstavljeni kot spremenljivke in imajo vrednost trenutne vsote vseh signalov in so med sabo povezani s povezavami, sestavljajo

umetno nevronske mreže. Povezave med nevroni so določene z utežmi in preko njih nevron sprejme signal od drugih nevronov. Signal se lahko oslabi ali ojača in se odda naprej drugim nevronom. Osnovna značilnost umetne nevronske mreže je tudi, da jo moramo najprej naučiti, če jo želimo v nadaljevanju uporabiti za napovedovanje plazenja zemljin. Samo učenje pa dejansko predstavlja določanje uteži povezav.

Vsebinsko smo diplomsko delo razdelili na sedem glavnih sklopov in sicer:

1. Uvod, ki zajema kratek opis in vsebino naloge.
2. Splošno o plazovih in predstavitev Macesnikovega plazua.
3. Opis geodetskih metod za spremljanje premikov zemeljskih plazov.
4. Opazovanja Macesnikovega plazua, kjer smo na kratko opisali opazovanje premikov na plazua in višine padavin, ter analizirali njihovo soodvisnost.
5. Teoretični del umetnih nevronske mrež, v katerem smo na kratko predstavili zgodovinski razvoj umetnih nevronske mrež, biološki in umetni nevron ter podobnost med njima, podali nekaj možnih delitev umetnih nevronske mrež in podrobneje razložili programe CTR-1 do CTR-5, ki so sestavljeni iz NTRAIN in NTEST, ki smo jih uporabili v našem primeru za napovedovanje plazenja plazov.
6. V eksperimentalnem delu opisujemo primere, s katerimi smo bolj ali manj uspešno napovedali plazenje zemljin.
7. Zaključek, ki vsebinsko povzema vse glavne ugotovitve diplomske naloge.

## **2 SPLOŠNO O PLAZOVIH IN PREDSTAVITEV MACESNIKOVEGA PLAZU**

### **2.1 Plazenje zemljin**

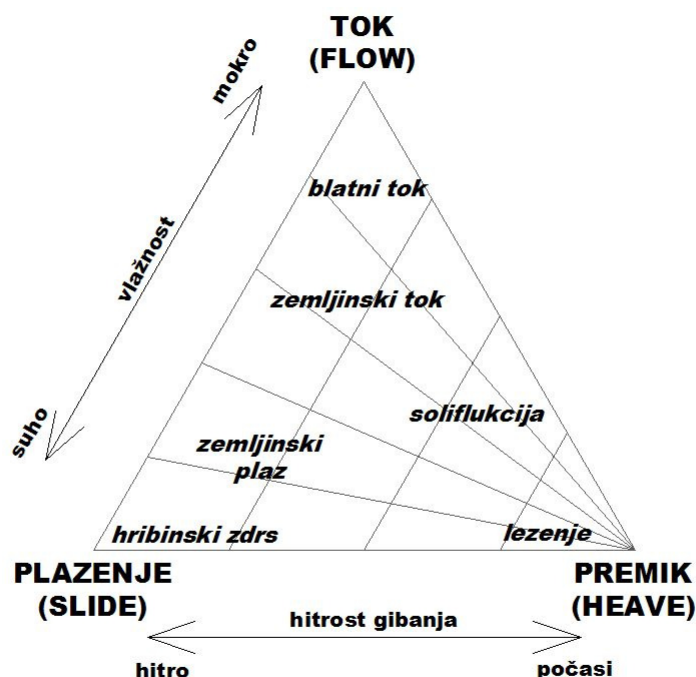
Plazenje pojmuje kot naravni pojav gibanja zemljin in kamnin po pobočju navzdol, ki nastane zaradi delovanja gravitacije potresnih sil, strujanja talne vode, antropogenih dejavnikov in sprememb strižnih lastnosti v tleh (Park, 1997, Komac, 2003). Podobno se med plazenje uvrščajo tudi pojavi padanja kamnov in pojavi blatnih tokov (Ribičič, 2002). Dodatno pa lahko povemo, da lahko poteka gibanje po pobočju kot plazenje, tečenje, polzenje, padanje in prevračanje.

### **2.2 Vrste plazenj**

Pri plazenju se hribinske, sedimentne in preperinske mase gibljejo po eni ali več jasno izoblikovanih drsnih ploskvah ali plazinsko porušeni conah. Le-te so lahko ravne oblike (translacijsko plazenje) ali pa krožne oblike (rotacijsko plazenje) (Skaberne, 2001). Rečemo, da rotacijsko plazenje navadno nastopi v homogenih materialih, translacijsko plazenje pa nastopi po naprej pogojenih drsinah npr. na kontaktu zemljine in hribine ali pa po diskontinuiteti v sami hribini. Poznamo pa tudi kombinirano plazenje, ki se lahko pojavi v nehomogenem plastovitem materialu, kjer je drsna ploskev nepravilne oblike, na prehodih iz rotacijske v translacijsko cono prihaja do velikih deformacij. Plazenje pa je lahko tudi posledica nastanka in rasti razpok, iz katerih se izoblikuje drsina. Nastane lahko tudi z reaktivacijo starih drsin ali pa kot posledica duktilnih procesov, ki nastanejo v coni osnovnih deformacij (Petley et al., 2002). Znano je tudi, da se lahko pri plazenju material notranje sorazmerno malo deformira. Kot definicijo termina tečenje povemo, da je le-to zvezna, nepovratna deformacija materiala, izzvanega s težnostjo. Material, ki teče, je zmes trdnih delcev oziroma sedimenta ter vode in/ali zraka (Skaberne, 2001). Definicija polzenja je: polzenje je zelo počasen neutekočinjen tok, ki je v večini primerov zelo plitek in je povezan s cikli zmrzali ali s padavinami. V primeru, da nastane globoko v hribini, zaradi teže same hribine - govorimo o globokem plazenju (Ribičič, 2002).



Plazenje oziroma gravitacijsko gibanje mas delimo na različne načine: na podlagi globine in oblike drsne ploskve, po hitrosti premikanja in po vlažnosti plazečega materiala. Na sliki 1 je podana klasifikacija na podlagi vlažnosti materiala in hitrosti, s katero se plaz giblje po pobočju navzdol.




Slika 1: Klasifikacija gravitacijskega gibanja mas po vlažnosti materiala in hitrosti gibanja (Park, 1997)

Plazenje povzročijo tako naravni dejavniki, kot tudi človek. Naravni dejavniki povzročajo plazenje tako, da skozi daljše časovno obdobje vplivajo na stabilnostne razmere nekega pobočja. Sprožilci plazov pa so trenutni dogodki (potresi, neurja, vulkanski izbruhi ipd.), ki intenzivno vplivajo na razmere nekega območja. S tem za stalno spremenijo njegovo stanje in s tem povzročijo splazitev mase. Povzročitelj in sprožitelj plazov je lahko tudi človek, ki s svojo aktivnostjo skozi daljše časovno obdobje in/ali pa trenutno spremeni stabilnostne razmere na nekem območju (Komac, 2003), ter s tem povzroči plazenje in /ali sprožitev plazov.

### 2.3 Opis Macesnikovega plazu

V praktičnem delu naloge poskušamo z umetno nevronske mreže napovedati dogajanj na Macesnikovem plazju nad vasjo Solčava. Macesnikov plaz z 2400 m dolžine in 18 ha površine sodi med največje plazove v Sloveniji, ki so se sprožili v zadnjem času. Plaz se je aktiviral ob močnejših padavinah ob koncu 80 tih let prejšnjega stoletja in se je do začetka sanacijskih del leta 2001 stalno širil in premikal navzdol proti Solčavi. 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 2: Lega Macesnikovega plazju (google maps 2008)

Od čela plazju so najbližji objekti oddaljeni le približno 250 m, vas Solčava pa je oddaljena le 1 km. Macesnikov plaz je zaradi obsežnih raziskav in relativno dolgega obdobja opazovanja

zelo primeren za obravnavo z umetnimi nevronskimi mrežami. Rezultati opazovanja plazu so pokazali nihanje hitrosti plazenja vzdolž plazu ter sezonska nihanja. Vzdolž plazu se spreminja tudi globina drsine ter nivo podzemne vode.



Slika 3: Spodnji del Macesnikovega plazu pod Olševo (foto: M. Zorn)

## **2.4 Gibanje materiala**

Gibanje materiala vzdolž plazu poteka na različne načine: kot translacijsko plazenje ter kot viskozni tok. Opravljene analize so pokazale zapleteno interakcijo med posameznimi vplivnimi dejavniki. Noben dejavnik ne more samostojno zanesljivo razložiti obnašanja plazu po njegovi celotni dolžini. Razlogi so v velikih dimenzijah plazu, vplivu skalnega osamelca, ki ovira plazenje v spodnjem delu ter v treh različnih tipih poteka deformacij plazine (Križnič, 2006).

Navkljub velikim dimenzijam pa se določena območja plazu podobno obnašajo. Analiza gibanja je pokazala tri podobna območja: prvo v zgornjem delu plazu, drugo v okolici montažnega mostu ter tretje v spodnjem delu plazu. V gibanju po celotni dolžini plazu se občasno pojavljajo trendi, kjer se pospešeno gibanje iz zgornjega dela plazu sčasoma prenese na nižja območja plazu. To potrjujejo rezultati inklinometriških meritev ter delno tudi meritve vertikalnih premikov, ki so pokazale v enem obdobju premikanje materiala v zgornjem delu plazu ter kopičenje v spodnjem delu (Križnič, 2006).

## **2.5 Vpliv padavin na plazenje**

Padavine zagotovo vplivajo na hitrost plazenja v določenih delih plazu. V zgornjem delu plazu imajo največji vpliv dvomesečne količine padavin. V spodnjem delu plazu je vpliv padavin manjši. V določenih območjih je očiten 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 (Križnič, 2006).

## 2.6 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 plazenje se je razvilo v zgornjem delu plazu, kjer je večji delež grušča in tanjša plazina (Križnič, 2006).

### **3 GEODETSKE METODE ZA SPREMLJANJE PREMIKOV ZEMELJSKIH PLAZOV**

Nabor tehnik, s katerimi izračunamo koordinate objektov v prostoru, predstavljajo geodetske merske metode. Na osnovi meritev z geodetskimi merskimi metodami pa izračunavamo premike v določenih časovnih obdobjih. V zvezi z meritvami aktivnosti plazov delimo geodetske metode v tri skupine (Majes, B., Ribičič, M., Komac, M., et. al. 2005).

- Referenčne geodetske metode - uporabljamo jih za ugotavljanje koordinat manjšega števila posameznih točk, koordinate teh točk lahko izmerimo z visoko natančnostjo. Med referenčne geodetske metode uvrščamo:
  - klasične geodetske meritve (tahimetrične meritve - meritve horizontalnih in vertikalnih kotov ter razdalj) in
  - meritve GPS.
  
- Geodetske brezkontaktno metode za masovne zajeme - pomembne so zato, ker lahko z njimi na terenu v kratkem času izmerimo veliko število točk. Mednje uvrščamo:
  - fotogrametrične metode in
  - metodo laserskega skeniranja.
  
- Druge geodetske metode - lahko jih uporabljamo kot dopolnilne metode, kamor uvrščamo:
  - satelitska snemanja ipd.

Skupna značilnost geodetskih metod je, da so:

- površinske - točke, ki jih merimo so namreč na površju plazu,
- direktne, saj merimo direktno položaje točk, s tem pa premike plazu.

### 3.1 Referenčne geodetske metode

Za ugotavljanje koordinat manjšega števila posameznih točk uporabljamo referenčne geodetske metode. Za to določeno manjše število posameznih točk pa koordinate lahko določimo z visoko natančnostjo. V to skupino sodijo:

- klasične geodetske meritve in
- meritve GPS.

Zaradi njihove natančnosti uporabljamo referenčne geodetske metode na plazovih v treh primerih:

- za direktne meritve položaja izbranih točk, ki jih merimo v različnih časovnih obdobjih in na osnovi katerih določamo premike plazov,
- za umeščanje (lociranje, orientacijo) ostalih vrst meritev (masovnih in drugih) v prostor in
- za kontrolo drugih vrst meritev.

#### 3.1.1 Klasične geodetske meritve

Dandanes za merjenje horizontalnih kotov uporabljamo praktično le še elektronske teodolite. Le-ti so najpogosteje kombinirani z elektronskimi razdaljmeri. Govorimo o elektronskih tahimetrih. Elektronski teodolit je optično mehanični in elektronski inštrument za merjenje horizontalnih in vertikalnih kotov oziroma zenitnih razdalj (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

Elektronski tahimeter je elektronski teodolit z vgrajenim razdaljmerom, tako da lahko hkrati merimo kote in dolžine. Današnji sodobni elektronski tahimetri imajo vgrajen elektrooptični razdaljmer (EDM) in elektronsko določevanje odčitkov horizontalnih in vertikalnih kotov. Na zaslonu prikaže odčitane vrednosti horizontalnega in vertikalnega kota ter dolžino. Horizontalna dolžina, višinska razlika in koordinate se samodejno izračunajo ter shranijo skupaj z meritvami in dodatnimi informacijami.

Povsod, kjer je potrebno določiti položaj ali pa položaje in višine točk, se uporabljajo elektronski tahimetri. Terenska izmera z elektronskim tahimetrom predstavlja najnatančnejšo, hkrati pa tudi najzamudnejšo in najdražjo metodo merjenja objektov v prostoru. Za zagotavljanje absolutnega položaja, ponovljivosti meritev ali dodatnih meritev pri vzdrževanju, je potrebno poleg samih meritev zagotoviti na vsakem delovišču izhodiščno in navezovalno točko (trigonometer, poligonska točka ipd). V ta namen uporabimo obstoječo državno mrežo, v določenih primerih pa si to mrežo vzpostavimo z meritvami GPS.

Določeni modeli elektronskih razdaljemerov omogočajo merjenje razdalj brez prizme. Tak način meritev se uporablja povsod, kjer je težko ali nemogoče postaviti prizmo. To je za določevanje koordinat vogalov, nedostopnih objektov, nevarnih objektov, fasad, skalnih sten, predorov, znotraj stavb ipd.


Pri ugotavljanju premikov zemljin in umetno zgrajenih novih objektov je potrebno definirati premike reda 1-2 mm. Da lahko s tako natančnostjo določimo tako majhne premike, je poleg precizne izmere in izravnave prav gotovo izredno pomembna lastna stabilnost merskih točk, s pomočjo katerih opišemo premike. To velja tako za osnovne točke, stabilizirane na stabilnem terenu, kot tudi za kontrolne točke na objektu – terenu, ki ga opazujemo. V praksi srečujemo vrsto različnih načinov stabilizacije geodetskih točk, od najenostavnejših načinov pa vse do masivnih temeljev z betonskimi stebri in mehanizmom, ki omogoča prisilno centriranje.

#### 3.1.1.1 Stabilizacija z betonskim stebrom

To je klasični način stabilizacije (slika 4). Običajno so to okrogli armirani betonski stebri, premera od 30 cm do 40 cm, nadzemne višine od 130 cm do 150 cm. Steber je dodatno zaščiten z betonsko cevjo in vmesnim praznim prostorom, ki ga zapolnjuje temperaturni izolator. To daje stebri veliko temperaturno odpornost, saj predstavlja zaščito pred zunanjimi vplivi, predvsem soncem, ki povzroča velika temperaturna nihanja. Nosilec stebra je masiven, kompakten betonski temelj, katerega dimenzije so odvisne od vrste podlage. Temelj stebra lahko predstavlja tudi naravna skala, v katero je steber sidran. V gornjo ploskev stebra je vžidan sistem, ki omogoča prisilno cenriranje. Običajno je to posebna centrirna kovinska



plošča, ki ima vgrajen srčni vijak, na katerega privijemo trinožni podstavek instrumenta izbranega proizvajalca. Prisilno centriranje je lahko prirejeno uporabi posebnih vmesnikov za instrumente nekaterih proizvajalcev (Vodopivec, Kogoj 2005).



Slika 4: Stabilizacija z betonskim stebrom (Vodopivec, Kogoj, 2005)

Dobri lastnosti tega načina stabilizacije sta predvsem:

- velika lastna stabilnost točke ob kvalitetni izvedbi stabilizacije in
- zagotovljeno natančno prisilno centriranje (pogrešek manjši od 0.1 mm).

Slabe lastnosti pa so:

- velika masa – možnost lokalnega premika,
- možnost nagiba, ki se odraža kot premik točke,
- poseg v okolje, točka lahko predstavlja fizično oviro in je vizualno moteča,
- stalna višina, ki jo glede na višino opazovalca ni mogoče spreminjati, in
- večji materialni stroški in stroški izdelave stabilizacije.

### 3.1.1.2 Talna stabilizacija z uporabo prenosljivih kovinskih stebrov

Na sliki 5 je prikazan drugačen sistem, ki zadrži nekaj dobrih in tudi slabih lastnosti prejšnje stabilizacije. Osnova je uveljavljeni švicarski način, ki ga je izpopolnil prof. dr. Manzoni. Točko predstavlja temeljena talna stabilizacija bistveno manjših dimenzij kot v primeru betonskega stebra. Talna stabilizacija ima sistem za prisilno centriranje stativa in preciznega togega grezila. Na talno stabilizacijo pritrdimo z vijaki steber kovinske palične konstrukcije, višine približno 150 cm. S pomočjo cevne libele ga približno verikaliziramo. Podnožna plošča, na katero prisilno centriramo instrument (sistem Kern), ali trinožni podstavek instrumenta, je vpet na precizno togo grezilo. Ta je s spodnjim koncem prisilno centrirana na center talne stabilizacije. Grezilo ima namesto običajne dozne libele precizno cevno libelo (Vodopivec, Kogoj 2005).



Slika 5: Stabilizacija z uporabo prenosljivih kovinskih stebrov (Vodopivec, Kogoj, 2005)


Ta način stabilizacije odpravlja večino slabosti klasične stabilizacije z betonskim stebrom, in sicer:

- točka je bistveno manj masivna,
- stroški izdelave, če ne upoštevamo izdelave posebnih stativov, so manjši,

- možnosti nagiba ni, saj kovinski stativ vedno na novo vertikaliziramo,
- stabilizacija v okolju ni moteča in
- ostaja problem stalne višine instrumenta.

### 3.1.1.3 Novi načini stabilizacije

Pri postavitvi triangulacijsko-trilateracijske mreže za potrebe najnatančnejšega določevanja premikov smo skušali obdržati prednosti obeh načinov. Na sliki 6 je prikazan osnovni princip stabilizacije. Vidimo, da so merske točke definirane z dvema fizično stabiliziranimi točkama. Merske točke, na katere prisilno centriramo reflektor, predstavljajo točke, katerih premike ugotavljamo. Vse meritve opravimo na točkah, ki so glede na merske točke postavljene ekscentrično. Govorimo lahko o ekscentričnih stojiščih. Oddaljenost ekscentra od centra točke je od 10 m do 20 m. Merske točke lahko stabiliziramo na način, ki je kombinacija zgoraj obravnavanih načinov. Izvedba pa je poenostavljena in cenejša. Uporabimo serijsko izdelano betonsko cev z zunanjim premerom  $\varphi = 0.25$  m in dolžine 1 m. Z ustreznim strojem izvrtamo luknjo enakega premera, v katero spustimo betonsko cev. Cev zalijemo z betonom in nanj vgradimo nastavek za prisilno centriranje. Cev je na vrhu pokrita s serijsko izdelanim pokrovom, tako da je točka popolnoma zaščitena (Vodopivec, Kogoj, 2005).



Slika 6: Talna stabilizacija merske točke in ekscentrično stojišče (Vodopivec, Kogoj, 2005).

Stojišče instrumenta je stabilizirano z običajno talno stabilizacijo z betonskim kvadrom z vgrajenim čepom. Nad stojiščem instrumenta postavimo stativ, ki ga centriramo in

horizontiramo. Natančnost centriranja ne vpliva na končne rezultate, saj ne operiramo s koordinatami stojišča instrumenta, ampak so bistvene koordinate merske točke, na katero je prisilno centriran reflektor. Pomembno je le to, da je stativ med merjenjem stabilen.

Mreža je kombinirana triangulacijsko-trilateracijska mikromreža. Po programu merimo smeri in dolžine. Na vsakem stojišču izmerimo tudi smer in dolžino proti merski točki – centru točke. V izravnavo vključimo tako merske točke kot tudi ekscentrična stojišča. Če je le mogoče (če je omogočena vidnost med točkami), izmerimo tudi iz drugih stojišč smeri in dolžine proti merskim točkam.

Klasični način stabilizacije je ob pravilni izvedbi odlična izbira. Kvaliteta je pogojena z vrsto podlage, na kateri je točka postavljena, najboljši je skalnati teren. Velika prednost je tudi prisilno centriranje. Postavitev točke je v nedostopnih terenih lahko zelo zahtevna. Ta način stabilizacije pa je lahko zelo moteč zlasti v urbanem ali kmetijskem okolju, slabost pa je tudi stalna višina instrumenta. Z uporabo talne stabilizacije z uporabo kovinskih stativov se izognemo nekaterim slabostim klasičnega načina. Izdelava take stabilizacije je bistveno enostavnejša in cenejša ob predpostavki, da imamo na voljo posebne kovinske stative. Točka ne predstavlja ovire v okolju, saj poseben kovinski stativ po končanih meritvah odstranimo. Slaba stran pa je še vedno stalna višina stativa in le deloma prisilno centriranje, saj je to izvedeno s preciznim togim grezilom. Z izbiro merske točke kot stojišča signala – reflektorja in stojišča instrumenta kot pripadajočega ekscentra smo odpravili pomankljivost predhodnih načinov. Stabilizacija je hitra in enostavna – v vrtino vstavimo betonsko cev in jo zalijemo z betonom. Točka ne moti okolice. Zagotovljeno je prisilno centriranje in možnost izbrane višine instrumenta. Edina dodatna zahteva je velika natančnost izmere elementov ekscentricitete. Teoretično se pri tem nekoliko poslabša natančnost »centriranja«.

### 3.1.2 Meritve GPS

Metoda GPS izmere temelji na signalih, ki jih oddajajo sateliti GPS in jih sprejme ter obdela sprejemnik GPS. Ne glede na čas in vremenske razmere lahko sistemom GPS določimo položaj kjerkoli na Zemlji. Sama dosežena natančnost pa je odvisna od vrste in zmogljivosti

sprejemnika, od načina opazovanja in od izbrane merske metode. Tehnologija GPS ponuja danes celo množico merskih tehnik, ki omogočajo pridobivanje položajev od milimetrske do nekaj metrske natančnosti. Tehnologija GPS ima pred klasičnimi geodetskimi merskimi postopki sledeče prednosti (Majes, B., Ribičič, M., Komac, M., et. al., 2005):

- visoka produktivnost,
- vremenski pogoji za izvedbo meritev niso pomembni,
- za določitev položaja točke ne potrebujemo medsebojne vidnosti med točkami in jih lahko zato postavljamo na enostavno dostopnih mestih,
- nižja cena izmere, ki temelji na visoki produktivnosti tehnologije GPS in
- z vzpostavitvijo permanentnih postaj GPS je cena tovrstnega položaja še nižja.

Tehnologija GPS pa ima glede na klasične merske postopke poleg prednosti tudi nekaj slabosti:

- v okolici opazovane točke ne sme biti ovir, ki bi onemogočale sprejem signala,
- višina točke, ki jo pridobimo na osnovi opazovanj GPS, je elipsoidna. Višine točk v državnem koordinatnem sistemu pa so podani z ortometrično višino točke. To pomeni, da je potrebno za vključitev podatkov izmere GPS v državni koordinatni sistem, poznati obliko geoida na obravnavanem območju,
- za določitev praktično uporabne ortometrične višine točke moramo poznati obliko ploskve geoida in
- sistem GPS je last ZDA, ki s sistemom prosto razpolaga.

GPS omogoča pridobivanje položajev različne natančnosti. V splošnem omogoča višjo natančnost položaja GPS:

- višja cena instrumentarija,
- dolgotrajnejše meritve in
- obsežnejši postopki obdelave opazovanj.

Različne metode izmere GPS se nanašajo na različne koordinatne sisteme. Sam sistem GPS pa se nanaša na globalne koordinatne sisteme. Prav tako pa je sam postopek transformacije koordinat v državni koordinatni sistem zadnji in za sedaj še obvezni korak projekta izmere GPS.

Rezultate izmere GPS lahko preračunamo v državni/lokalni koordinatni sistem le s transformacijo izmere GPS. Le-to izvedemo na osnovi danih položajev točk v obeh koordinatnih sistemih v tridimenzionalnem pravokotnem koordinatnem sistemu (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

### 3.1.2.1 Metode izmere GPS primerne za merjenje premikov plazov

Vse metode izmere GPS, ki jih uporabljamo v geodeziji, temeljijo na faznih opazovanjih. Vse metode so metode za določanje relativnega položaja, ker le-te omogočajo doseganje natančnosti položaja, ki je primerna za uporabo v geodeziji. Po drugi metodologiji pa lahko delimo metode izmere GPS tudi glede na način izvedbe meritev. Sprejemnik lahko med izmero miruje (je ves čas izmere na istem mestu) ali pa ugotavljamo položaje točk tako, da se sprejemnik giblje po določenem območju. Po tej delitvi obstajata dve metodi izmere GPS, in sicer statična in kinematična metoda izmere GPS. V obdobju od začetkov prve praktične uporabe opazovanj GPS do danes pa se je razvilo nekaj metod izmere, ki v večji meri povzemajo značilnosti ene ali druge osnovne metode izmere GPS (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

Direktno v izbranem koordinatnem sistemu za ugotavljanje položaja podaja koordinate absolutna metoda. Relativna metoda določa koordinate točke glede na točko z že znanimi koordinatami, na kateri se prav tako izvajajo meritve GPS. Pri relativni metodi lahko s hkratnim izvajanjem meritev na znanem položaju modeliramo določene vplive na opazovanja GPS. S tem dobimo boljši podatek kot pri absolutni določitvi položaja (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

#### 3.1.2.1.1 Statična izmera GPS

Osnovna metoda za določanje relativnega položaja je statična izmera GPS. Pri tej metodi trajajo opazovanja navadno od 30 do 120 minut in temeljijo na spremembi geometrijske razporeditve satelitov v času opazovanj. Statično izmero običajno izvedemo v več serijah.

Samo izmero pa izvajamo s številom sprejemnikov, ki je manjše od števila točk. Število serij, potrebnih za izmero, je odvisno od števila sprejemnikov, števila točk in od števila neodvisnih izmer posamezne točke. Vsaka točka naj bi bila neodvisno opazovana vsaj dvakrat. Rezultat statične izmere so bazni vektorji med pari točk. Matematični modeli za modeliranje ionosferske refrakcije ter zanesljivi algoritmi za določitev neznanega začetnega števila celih valov omogočajo ob izvedbi statičnih opazovanj GPS pridobitev baznih vektorjev dolžin  $D$ , z relativno natančnostjo do  $10^{-6} * D$ , ki pa je lahko v primeru uporabe natančnih efemerid satelitov tudi do  $10^{-7} * D$ . Poleg kakovostne izvedbe opazovanj in uporabe natančnih tirnic satelitov ustrezne kakovosti pa je za doseganje tako visoke natančnosti potrebno ustrezno izvesti tudi obdelavo opazovanj. Z izravnavo baznih vektorjev v mreži GPS običajno pridobimo končne rezultate statične izmere (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

#### 3.1.2.1.2 Hitra statična metoda izmere GPS

Hitra statična metoda izmere GPS (proizvajalci opreme GPS jo imenujejo tudi Rapid Static™ in Fast Static™) je v vseh bistvenih lastnostih enaka statični metodi izmere. Izjema je krajši čas trajanja opazovanj. Ta metoda izmere se je pojavila z razvojem algoritmov za učinkovito določitev neznanega začetnega števila celih valov ob uporabi različnih tipov opazovanj in različnih kombinacij teh opazovanj. Vse to omogoča hitro in zanesljivo določitev začetnih neznanih vrednosti števila celih valov. Določitev teh neznank je najučinkovitejša ob sprejemanju signalov iz petih ali več satelitov (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

### 3.1.2.2 Sprejemniki GPS

Trenutno je na tržišču več tisoč sprejemnikov GPS, namenjenih različnim potrebam merjenja oz. doložitve položaja (navigacija, geodetska izmera, sprejemniki GPS za neprekinjeno delovanje ipd), zato je zelo pomembno, da izberemo sprejemnik, ki bo lahko zadovoljil naše potrebe po natančnosti določitve položaja ali časa na osnovi opazovanj GPS. Sprejemniki so v osnovi zelo različni, vendar imajo vsi naslednje sestavne dele: anteno, radio frekvenčni del, mikroprocesor, kontrolno enoto, zaslon in tipkovnico, pomnilniško enoto in vir energije. Običajno so vse komponente, razen antene, zbrane v skupnem ohišju - sprejemniku GPS (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

Sprejemnike GPS lahko po uporabnosti v grobem delimo na dva nivoja: geodetske in navigacijske sprejemnike. Geodetski sprejemniki omogočajo dosego največjih natančnosti. Te se gibljejo od nekaj milimetrov pri relativni statični metodi, do nekaj centimetrov pri metodi RTK. Geodetski inštrumenti GPS uporabljajo izključno fazne meritve v čemer se razlikujejo od navigacijskih sprejemnikov GPS, ki uporabljajo samo kodne meritve. S slednjimi pa lahko dosežemo natančnosti okoli 0.5 m z uporabo relativne metode (DGPS) oz. od 3 do 25 m pri absolutnih meritvah.

### 3.1.2.3 Planiranje izmere GPS

Tehnologija GPS omogoča izvedbo opazovanj brez upoštevanja nekaterih pomembnih dejavnikov, kot so predvsem vremenski pogoji in medsebojna vidnost točk, ki so desetletja usmerjali delo geodetov. Nadalje tudi ne moremo trditi, da je izvedba opazovanj GPS neodvisna od razmer na nebu in Zemlji. Tako je pri izdelavi projekta izmere GPS potrebno upoštevati splošne zahteve za opazovanja GPS, kar pomeni, da v bližini točk naj ne bi bilo fizičnih ovir (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

Rekognosciranje terena nove izmere, čeprav gre samo za površen ogled terena, je lahko zelo dobrodošlo (pridobiti informacije o topografskih značilnostih terena, možnostih prevoza na terenu, gostota zgradb in sploh ovir, ki lahko otežujejo ali onemogočajo izvedbo izmere GPS, informacije o danih točkah...). V planiranju izmere je potrebno pridobiti podatke o obstoječih



točkah v območju izmere, ki so potrebne za transformacijo iz globalnega v državni/lokalni koordinatni sistem. Pri rekognosciranju je potrebno predvideti najbolj primerno mesto za postavitev referenčne postaje (ta mora v času izmere ostati nepremaknjena).

### 3.2 Geodetske metode za masovni zajem

Kakor pove že ime omogočajo geodetske metode za masovne zajeme zajem velikega števila točk na terenu. Med te metode sodijo (Majes, B., Ribičič, M., Komac, M., et. al., 2005):

- fotogrametrične metode in
- laserska skeniranja.

Skupne značilnosti teh metod so, da so (Majes, B., Ribičič, M., Komac, M., et. al., 2005):

- direktne - z njimi merimo pozicije posameznih točk,
- brezkontaktno - dostop do posamezne točke, ki jo merimo, ni potreben in
- hitre - za izvedbo terenskih meritev je potreben le krajši čas, dobljene podatke pa lahko nadalje obdelujemo v pisarni.

Geodetske metode za masovni zajem uporabimo:

- kadar želimo izdelati posnetek večjih območij ali pa celotnega plazu (po večjih zdrsih, v različnih fazah sanacije ipd.) in
- kadar je samo gibanje na območju plazu nevarno in z indirektnimi metodami lahko zajamemo z varnega mesta stanje na plazu brez ogrožanja operaterja oz. drugih udeležencev.

#### 3.2.1 Fotogrametrična izmera

Fotogrametrija je interdisciplinarna panoga in ena od vej geodezije, ki se ukvarja s pridobivanjem metričnih podatkov iz fotografij (v nadaljevanju posnetkov), posnetih iz zraka ali s tal. Metrični podatki, ki so prikazani na posnetku, so predvsem podatki o položaju, obliki in velikosti pojavov in objektov. Visoko stopnjo kakovosti iz posnetkov izvedenih podatkov

zagotavljajo računalniško podprti fotogrametrični postopki, saj v celoti temeljijo na matematičnih zakonitostih. Fotogrametrija pa poleg omenjenih metričnih podatkov omogoča pridobivanje tudi nemetričnih oziroma t.i. opisnih podatkov o prostorskih pojavih in objektih. Gre predvsem za podatke, ki podajajo lastnosti, stanje in vrsto izbranega pojava oziroma objekta (Gvozdanovič in Smole, 2003).

Fotogrametrične tehnike so ena izmed najbolj učinkovitih metod masovnega zajema in umestitve v prostor posameznih objektov v naravi. Prav tako pa je pomembno dejstvo pri fotogrametrični izmeri, da je terenskega dela razmeroma malo in se opravi v relativno kratkem časovnem obdobju. Po opravljenem terenskem delu, se v pisarni prične pridobivanje mase poljubnih geolociranih in metričnih podatkov.

Tipični izdelki fotogrametrije so:

- digitalni ortofoto,
- digitalni model reliefa,
- topografski načrti in
- 3D modeli objektov.

Navidez različne fotogrametrične tehnike pa imajo več skupnih točk. Najbolj reprezentativen je analogen oziroma digitalen posnetek, ki je rezultat vseh zgoraj omenjenih fotogrametričnih snemalnih postopkov (rezultat terenskega dela). Le-ta je odvisen od uporabljene snemalne naprave, ki je lahko:

- analogen fotogrametrični aparat,
- umerjen digitalni fotoaparat ali
- umerjena digitalna video kamera.

Eden od pogojev, ki morajo biti izpolnjeni za uspešno izvedbo geolokacije objektov v naravi, so pravilno v prostor umeščeni (običajno v državni koordinatni sistem) izvorno digitalni oziroma v digitalno obliko naknadno pretvorjeni analogni posnetki. Aerotriangulacija pa se imenuje fotogrametričen postopek, s katerimi se izvede umestitev aeroposnetka v prostor. V okviru omenjenega postopka je potrebno razpolagati z znanimi parametri uporabljenega snemalnega sistema. Prav tako pa postopek aerotriangulacije zahteva tudi izvedbo

identifikacije t.i. oslonilnih točk na nekaj posnetkih. To so dobro opredeljive točke v naravi, ki so vidne na posnetku, hkrati pa razpolagamo s koordinatami teh točk v državnem koordinatnem sistemu. Število potrebnih oslonilnih točk, ki jih je z geodetsko izmero (tahimetrična izmera ali izmera GPS) potrebno določiti, je v splošnem odvisno od velikosti delovišča. Delovišče se smatra kot zaključena enota ali območje, ki je zajeto na posnetkih in je vključeno v postopke fotogrametričnega iz vrednotenja (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

Fotogrametrično snemanje lahko izvajamo iz zraka (letalo, helikopter) ali terestrično (stojišča na tleh). Glede na oddaljenost od objekta snemanja ločimo bližnjelikovne aplikacije (bliže od 150 m) in topografske aplikacije (razdalje nad 150 m). Potrebno pa je tudi prilagoditi uporabljeno kamero glede na oddaljenost snemanja.

### 3.2.2 Lasersko skeniranje

Za geodete je zelo uporabno orodje trirazsežno (3D) lasersko skeniranje. Lasersko skeniranje kot nova tehnologija, zahteva delo z novim tipom podatkov. Elektronski razdaljemer daje kot rezultat elektronsko reducirane horizontalne razdalje, rezultat opazovanj GPS pa so bazni vektorji. Tako zajem s 3D laserskim skeniranjem pa daje popolnoma nov tip podatkov - oblake točk (Fakulteta za gradbeništvo in geodezijo, 2005). V primerjavi s klasičnimi geodetskimi metodami zagotavljajo oblaki točk višjo stopnjo geometrične popolnosti in detajla terena oziroma objekta. Vse to zmanjša stroške ponovnih vračanj na teren in dodatnih izmer. Prav tako pa uporabljamo 3D lasersko skeniranje za celovito zajemanje prostorskih podatkov. V kratkem časovnem intervalu pridobimo veliko število prostorskih koordinat točk, ki predstavljajo površino skeniranega objekta. Pri tehniki laserskega skeniranja uporabimo laserski žarek za potrebe ugotavljanja:

- oblike,
- velikosti in
- položaja objektov v prostoru.

Lasersko skeniranje omogoča izdelavo 3D numeričnega modela objekta. Na tržišču se pojavljajo številni modeli skenerjev, ki omogočajo izvajanje:

- aero in/ali
- terestričnega laserskega skeniranja.

Laserski skener je v primeru aero laserskega skeniranja prirejen za uporabo v letalu. Takšen način skeniranja je izjemno primeren predvsem za določevanje geometrije linijskih objektov, v tujini pa ga med drugim uspešno uporabljajo tudi za ugotavljanje:

- modela reliefa zemeljskega površja in
- geometrije poljubnih linijskih objektov.

Nasprotno je terestrično lasersko snemanje določevanje lastnosti objektov s pomočjo laserskega skenerja, ki se nahaja na tleh. Ta metoda je primerna predvsem za določevanje geometričnih lastnosti objektov, ki tvorijo zaključeno celoto. Objekti, primerni za lasersko skeniranje, so lahko veliki nekaj deset cm ali pa nekaj 100 m. Glede na to se ločijo tudi terestrični skenerji, saj so ponavadi zahteve po natančnosti skeniranja manjših objektov višje (manjši objekti se tudi skenirajo iz precej krajših razdalj).

Kjer imamo na voljo površine, od katerih se laserski žarek odbija, lahko uporabljamo metodo laserskega skeniranja. Laserski impulz je voden s pomočjo vrtljivih zrcal, ki so upravljana s servomotorjem. Natančnost določitve posameznih točk je odvisna od:

- oddaljenosti skenerja od objekta in
- inklinacije žarka.

Skeniranje je izvedeno z enim ali dvema gibljivima zrcaloma, ki omogočata zelo majhne spremembe v odklonskem kotu laserskega žarka, projeciranega na površino objekta. Skener je vrtljiv okoli  $X$  in  $Z$  osi. Vsebuje laser in različne optične naprave (zrcala). Laserski impulz potuje po objektih v vidnem polju skenerja po stolpcih in vrsticah. Skener meri čase oddaje in sprejema laserskega impulza ter na podlagi tega izračuna oddaljenost do izbrane točke na objektu. Skener nato zabeleži odklonska kota zrcal ter poševno razdaljo med 3D laserskim skenerjem in skeniranim objektom (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

3D laserski skener zajame objekt s pomočjo odčitkov laserskega žarka v obliki mreže z izbrano gostoto točk. Pri vsakem zasuku smeri laserskega žarka se shrani njegova prostorska usmerjenost (glede na koordinatni sistem instrumenta) kot horizontalni in vertikalni kot ter poševna razdalja do ciljne točke. V nekaj minutah dobimo tako tisoče prostorskih vektorjev, ki se začnejo v instrumentu in končajo v točkah. Konci teh vektorjev pa predstavljajo površino skeniranega objekta v obliki 3D koordinat točk mreže.

Rezultat skeniranja je množica točk, ki imajo določene koordinate v 3D koordinatnem sistemu. Z oblakom točk zagotovimo visoko stopnjo geometrične popolnosti in detajla terena oz. objekta in zmanjšajo stroške ponovnih vračanj na teren in dodatnih izmer. Vse točke v oblaku točk imajo pripadajoče 3D koordinate ( $X, Y, Z$ ) v skenerjevem koordinatnem sistemu z izhodiščem v skenerjevem centru. Včasih pa je potrebno skenirati večje objekte, kot so npr. kamnolomi, deponije, plazovi, ipd, kjer je rezultat laserskega skeniranja več skenogramov. Le-te je potrebno v fazi obdelave združiti v eno celoto - en 3D model. Več različnih oblakov točk združimo na osnovi najmanj treh identičnih veznih točk, označenih s posebnimi tarčami. Če želimo, da imajo točke v prostorskem oblaku točk podane koordinate v državnem koordinatnem sistemu, moramo uporabiti oslonilne točke, ki imajo določene skenerjeve in državne koordinate. Le-te ugotovimo z geodetskimi metodami. Rezultat obdelave oblakov točk so 2D načrti ter prostorski modeli objektov. Tudi takšen način zbiranja podatkov zahteva naknadno obdelavo terenskega dela v pisarni. Zato je potrebno imeti izkušenega operaterja, ki lahko glede na postavljene zahteve s pomočjo posebne programske opreme hitro zajame relevantne podatke o objektih. Programska oprema sama pa omogoča tudi detajlnejše modeliranje posameznih elementov (npr. znaki prometne signalizacije), vendar to zahteva več časa. Rezultate terenskega dela (množica 3D točk) pa lahko neposredno prenesemo tudi v poznana okolja CAD. To pomeni, da lahko obdelavo podatkov izvajamo z znanimi programskimi orodji.

Prednosti 3D laserskega skeniranja (Fakulteta Majes, B., Ribičič, M., Komac, M., et. al., 2005):

- hiter zajem podatkov - velika hitrost delovanja (100 do 1000 točk/sek),
- cenejši zajem podatkov o objektih in topografiji glede na druge metode,
- zajem podatkov brez dotikanja (primerno za skeniranje nevarnih objektov),

- pridobitev koordinat poteka samodejno in v sistematičnem vzorcu,
- koordinate skeniranega objekta pridobimo skoraj v realnem času,
- dodatne meritve niso potrebne, saj so vsi objekti v vidnem polju 3D laserskega skenerja,
- oblake točk lahko uporabimo večkrat in za različne namene,
- zmožnost delovanja v popolni temi,
- večja varnost pri zajemu podatkov in
- upravljanje skenerja možno z enim samim operaterjem.

Slabosti 3D laserskega skeniranja:

- razmerje med porabljenim časom za skeniranje in pisarniško obdelavo 1:3 do 1:5,
- kakovostna programska oprema,
- skenirana površina vedno ne zagotavlja zadostnega odboja laserske svetlobe in
- skenogram vključuje šume, zaradi odboja od drugih objektov.

Možnosti uporabe oblaka točk so ogromne in sicer:

- oblake točk lahko poljubno obdelujemo in sicer ustvarjamo najboljše prilegajoče elemente, izdelamo trikotniške mreže ter izrišemo 2D prereze objektov,
- oblak točk lahko med skeniranjem obračamo in gledamo z različnih perspektiv in oddaljenosti,
- točke, ki smo jih zajeli na motečih objektih, lahko enostavno odstranimo in
- med različnimi točkami v oblaku lahko izvajamo meritve.

### **3.3 Druge geodetske metode**

Poleg referenčnih metod in metod za masovni zajem točke obstajajo še druge metode, ki jih lahko koristno uporabimo pri evidentiranju plazov. Te metode so sicer manj primerne za natančne meritve na plazu. Navedimo dve geodetski metodi, katerih osnova je daljinsko zaznavanje:

- uporaba satelitskih posnetkov in
- uporaba radarja z umetno odprtino (SAR) za določanje modela reliefa.

### 3.3.1 Uporaba satelitskih posnetkov

Kadar nimamo na voljo klasičnih aeroposnetkov za pridobitev informacije o prostoru, lahko uporabimo satelitske podobe, ki so pridobljene z multispektralnimi senzorji na satelitih. Ti omogočajo snemanje terena v različnih valovnih dolžinah. S primerjanjem podob, narejenih v različnih spektralnih razredih, lahko z različnimi tipi klasifikacije izvemo veliko o posnetem terenu. Večina metod klasifikacije je avtomatskih ali polavtomatskih. V program za klasifikacijo vnesemo parametre objektov, ki jih bomo na celotni sliki iskali. Program nato sam s pomočjo primerjave večspektralnih posnetkov poišče iskane objekte. Najbolj primeren način iskanja objektov je klasifikacija objektov na osnovi učenja algoritma na učnem vzorcu (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

### 3.3.2 Uporaba radarja z umetno odprtino (SAR) za določanje modela reliefa

Radarsko daljinsko zaznavanje ima veliko ugodnih lastnosti, kot so neobčutljivost za vremenske pojave, možnost snemanja ponoči ter veliko število delujočih radarskih, predvsem satelitskih sistemov. Pri snemanju z radarjem obsevamo (z mikrovalovnim elektromagnetnim valovanjem) območje na zemeljskem površju ter sprejemamo odboj elektromagnetnega valovanja s površja Zemlje. Na radarskih posnetkih tako zaznamo samo elektromagnetno valovanje, ki se je odbilo nazaj v smeri antene. Radar je torej aktivni inštrument, ki s pomočjo antene, ki jo obrnjena proti površju Zemlje, pošlje mikrovalovni signal. Signal se na površju zemlje razprši v vse smeri. Antena nato zazna odbito valovanje. Na jakost odbitega valovanja vplivajo: krajevni vpadni kot, razgibanost ter prevodnost in dielektričnost zemeljskega površja (Majes, B., Ribičič, M., Komac, M., et. al., 2005).

Radar bočnega pogleda pravimo radarju, ki opazuje površje Zemlje nekoliko vstran od nadirja. Dolžina antene vpliva na azimutno ločljivost, torej ločljivost v smeri leta. Čim daljša je antena, boljša je ločljivost v tej smeri. Zato je tako imenovani radar z umetno odprtino (Ang. Synthetic Aperture Radar, SAR) posebej cenjen, saj s posebno tehniko iz sorazmerno kratke antene ustvari navidezno zelo dolgo anteno. SAR pri tem sestavi več zaporednih signalov (odbojev), ki jih radar sprejme med premikanjem v smeri leta. »Odprtina« v tem

primeru predstavlja celotno razdaljo, na kateri radar zaznava energijo, odbito z zemeljskega površja, in jo sestavlja v posnetek.

Postopek izdelave interferograma in digitalnega modela višin InSAR 25 (25 x 25 m) je razmeroma zapleten, kljub dokaj preprosti teoretični podlagi. Razdelimo ga lahko na približno naslednje korake (Fakulteta Majes, B., Ribičič, M., Komac, M., et. al., 2005):

- izbira parov posnetkov,
- natančna medsebojna poravnava posnetkov,
- priprava zunanjega modela višin,
- računanje interferograma,
- izboljšanje interferograma,
- razvijanje faze,
- ustvarjanje digitalnega modela višin,
- geokodiranje,
- združevanje interferogramov in
- ovrednotenje kakovosti.

Za kompleksne posnetke satelitov lahko podatke o orbitah in ugodnih parih dobimo kar na internetu na straneh Evropske vesoljske agencije (Ang. European Space Agency, ESA). Pri izbiri para posnetkov se moramo zavedati tako teoretičnih kot tudi praktičnih omejitev. Osnovna razdalja ne sme biti niti premajhna niti prevelika. Posnetka pa se morata prekrivati v delu, ki nas zanima. Vendar kljub navidez dobri izbiri lahko naletimo na težave, ki so posledica močno različnih vremenskih razmer v času zajetja posnetkov. Lahko rečemo, da izbira parov posnetkov zelo vpliva na zmožnost obdelav. Čas brez vegetacije zgodaj spomladi se je izkazal za najugodnejši čas za snemanje.

Kakovost izdelanega digitalnega modela višin InSAR 25 je ovrednotena z nekaj neodvisnimi metodami (Stančič et al., 2000), in sicer:

- s primerjavo raznih raztresenih točk na manjših, a morfološko različnih testnih območjih,
- s primerjavo s točkami, zajetimi z analitično fotogrametrično metodo ter



- s primerjavo z obstoječim DMR 100, delom obstoječega DMR 25 in najboljšo kombinacijo podatkov za testiranje.

Glede na omenjene metode so pridobljene naslednje vrednosti ocene višinske natančnosti:

- ravninska območja 2 m,
- gričevnata območja 5 m in
- gorata območja 13 m.

### 3.4 Vidiki pri izbiri merske metode

Geodetske merske metode zagotavljajo kakovosten prostorski podatek pri določevanju topografije in spremljanju aktivnosti zemeljskih plazov. Glede na nalogo oziroma stanje plazu smo geodetske merske metode, uporabne pri opazovanju plazov, razdelili za:

- določitev stanja pred nastankom plazu,
- določitev premikov plazu in
- izdelavo posnetka stanja plazu.

#### 3.4.1 Metode za določitev stanja pred nastankom plazu

Le na osnovi razlike med začetnim in trenutnim stanjem lahko kvalitativno ugotovimo, za kakšne in kolikšne spremembe gre, zato nas pri vsakem plazu nas zanima, kakšno je bilo stanje pred nastankom plazu. Ker lahko predvidimo lokacijo novega plazu le izjemoma, je izvedba naloge težavna in tudi pogostokrat posnetek terena pred nastankom plazu ne obstaja. V takem primeru si lahko pomagamo z merskimi metodami, ki uporabljajo za druge namene zajete podatke v času pred nastankom plazu, to pa so (Majes, B., Ribičič, M., Komac, M., et. al., 2005):

- satelitski posnetki, ki so nastali v času pred nastankom plazu,
- InSAR DMR, izdelan pred nastankom plazu in
- fotogrametrični posnetki cikličnih ali posebnih aerosnemanj.

Satelitski posnetki, posneti v času pred nastankom plaz, so lahko zaradi pogostokrat preslabe ločljivosti (več kot 0.5 m) le osnova za določitev prvotnega stanja, zato jih uporabimo samo, če ni drugega boljšega vira.

InSAR DMR, izdelan pred nastankom plaz, je zaradi relativno redkega grida (25 m) le deloma uporaben vir za 3D model stanja pred nastankom plaz. Tako ima tudi ta omejeno uporabnost in ga uporabimo le, če ni drugega boljšega vira.

Najpogosteje so uporabni fotogrametrični posnetki cikličnega ali posebnega aerosnemanja, na osnovi katerih lahko izvedemo fotogrametrične meritve. Te tvorijo niz zaporednih postopkov, ki so sami po sebi dokaj kompleksni in zahtevajo obsežno pripravo. Med te postopke štejemo:

- izmero oslonilnih točk,
- skeniranje posnetkov,
- izračun notranje in zunanje orientacije posnetkov ter
- stereo izvrednotenje.

Rezultat postopka so podatki, geolocirani v prostoru. Končni produkt fotogrametričnih produkcijske linije so lahko topografski podatki, podani v vektorski obliki (točke, linije, poligoni), digitalni model reliefa in pa ortorektificirani posnetki (ortofoto načrt). Fotogrametrične metode štejemo med dirketne, površinske metode merjenja, zaradi poljubnega števila točk, ki jih lahko zajamemo iz posnetkov, pa jih prištevamo med masovne.

### 3.4.2 Metode za določitev premikov plaz

Plaz od nastanka naprej ne miruje, ampak se pod različnimi vplivi spreminja. Pri izboru merske metode moramo upoštevati predvsem naslednje kriterije (Majes, B., Ribičič, M., Komac, M., et. al., 2005):

- topografske lastnosti plaz (lokacija, lega, velikost, konfiguracija terena, dostopnost, ...) in
- dinamiko sprememb na plaz (počasni majhni premiki, konstantno drsenje, enkratni podori ali zdrsi,...).

Za zelo majhne premike (velikosti red nekaj mm/letno) so najprimernejše geomehanske inklinometrijske metode. Geodetske merske metode bomo uporabili, kadar so pričakovani premiki med posameznimi opazovanji več kot 5 mm. Na počasi premikajočih se plazovih, kjer se lahko brez nevarnosti gibljemo tudi po območju plazu, lahko uporabimo klasične geodetske metode kot so tahimetrija in meritve GPS. V tem primeru opazujemo premike le na posameznih točkah plazišča, ki pa morajo biti na terenu ustrezno signalizirane (tahimetrija) oziroma stabilizirane in varno dostopne (GPS).

V primeru velike ogroženosti objektov je možno izvajati tudi on-line opazovanja, pri čemer si pomagamo z motoriziranim elektronskim tahimetrom, ki samodejno neprestano opazuje eno ali več signaliziranih točk in lokacije sporoča v center za obdelavo. Tam jih ustrezna programska oprema obdeluje in v primeru večjih premikov sproži alarm. Sistem zahteva le enkratno signalizacijo točk na plazišču, s čimer se izognemo nevarnosti gibanja po plazovitem terenu.

Na plazovih, kjer so premiki večji, pride pri uporabi klasičnih metod praviloma do uničenja stabiliziranih in signaliziranih točk, kar onemogoča nadaljnja merjenja. V tem primeru je idealna metoda laserskega merjenja. Pri nas za namene plazov ta metoda še ni bila testirana in uporabljena, izkušnje iz tujine pa kažejo na njeno veliko uporabnost. Laserski skener je izredno uporaben zaradi nekontaktnosti metode in s tem varnosti. Prav tako stabilizacija in dostop do merjenih točk niso potrebni, samo stojišče pa je izven samega plazišča. Zaradi velike količine točk, ki jih lahko zajamemo v kratkem času in iz katerih naredimo zelo gost 3D model plazu, omogoča, poleg določitve premikov, tudi bistveno prednost pred klasičnimi geodetskimi meritvami, ki so omejene na manjše število točk. Gre za možnost natančnega izračun volumnov zemljine, ki se premika in navadno predstavlja glavni problem pri plazovih. Zaradi vseh omenjenih lastnosti je merjenje z laserskim skenerjem primerno tudi za pogostejše meritve, kvartalno mesečno ali pa celo tedensko.

### 3.4.3 Metode za izdelavo posnetka stanja plazu

Posnetek stanja celotnega plazu lahko izvedemo v različnih časovnih presekih. Običajno je najbolje to storiti po večjih spremembah na plazu (nastanek plazu, večji premiki, posamezne faze sanacije, ipd), lahko pa ga izvajamo tudi periodično. Za posnetek stanja plazu so primerne metode za masovni zajem točk (Majes, B., Ribičič, M., Komac, M., et. al., 2005):

- klasične geodetske metode,
- fotogrametrične metode in
- uporaba laserskih skenerjev.

V primeru, da želimo pridobiti topografijo celotnega plazu s klasičnimi geodetskimi metodami, je neizogibno gibanje po samem plazu, saj je potrebno vse detajlne točke sproti signalizirati s prizmo oz. nanje postaviti anteno GPS. Te metode so najnatančnejše, vendar so tudi časovno in stroškovno potratne pri zajemu velikega števila točk. Prav tako pa so zaradi potencialnega zdrsa nevarne za operaterja, kar še dodatno manjša njihovo praktično vrednost. Zaradi tega so za izdelavo posnetka celotnega plazu manj primerne.

Fotogrametrične metode delimo na aero in terestrične. Pri aerosnemanjih so stroški zaradi organizacije snemanja ter izvrednotenja relativno visoki, zato metoda za pogosto periodično snemanje ni primerna. Pri terestričnih snemanjih so stroški bistveno manjši, se pa pogostokrat pojavi problem vidnosti plazu s stojišča.

Terestrično lasersko skeniranje se izkaže tudi za posnetke stanja kot najprimernejša metoda. Glavna prednost pred ostalimi metodami je v tem, da lahko v kratkem času pridobimo prostorske podatke za relativno velika območja, ne da bi se omejili na končno število diskretnih točk. Podatek, ki pridobimo s skeniranjem, predstavlja oblak točk, iz katerega lahko tvorimo ploskve (digitalni model terena) v različnih časovnih obdobjih. Iz oblaka točk lahko izvajamo tudi poljubne meritve objektov, ki jih v oblaku lahko identificiramo. Prav tako pa je z namestitvijo digitalnega fotoaparata na ogrodje laserskega skeniranja možno enostavno kombiniranje posnetkov z oblakom točk. Tako lahko znatno zmanjšamo čas za pripravo digitalnega ortofota oz. drugih vizualizacij, saj se izognemo vsem vmesnim stopnjam med samo terensko izmero in končnim produktom, ki so potrebni pri fotogrametričnih tehnikah.

## 4 OPAZOVANJE MACESNIKOVEGA PLAZU

### 4.1 Merjenje premikov

Kontrolne meritve deformacij na Macesnikovem plazu, katerih naročnik je bilo RS Ministrstvo za okolje, prostor in energijo, Agencija RS za okolje, je izvajalo podjetje IRGO CONSULTING d.o.o. Meritve so se izvajale v petih sklopih (IRGO, 2001).

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

- od 13. 11. 2000 do 30. 11. 2000 v profilih 1-6
- od 30. 11. 2000 do 11. 01. 2001 v profilih 1-7
- od 11. 01. 2001 do 21. 02. 2001 v profilih 1-8

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:

- od 21. 02. 2001 do 22. 03. 2001 v profilih 1-8
- od 22. 03. 2001 do 23. 07. 2001 v profilih 1-9
- od 23. 07. 2001 do 20. 12. 2001 v profilih 1-10

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

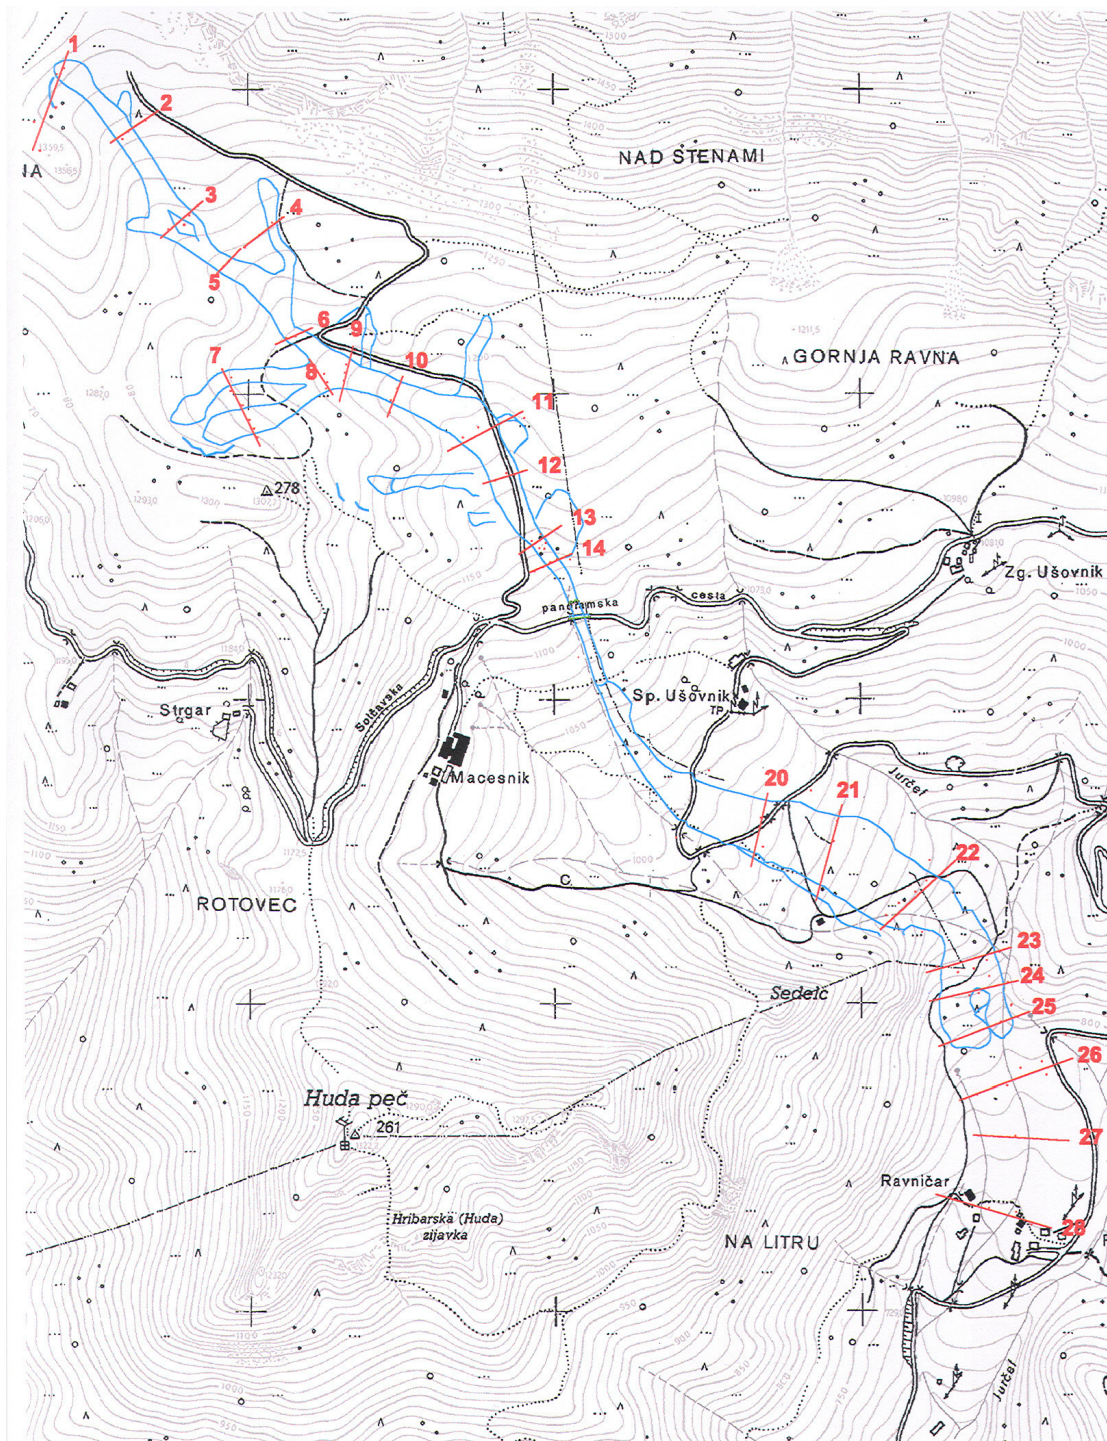
V tem sklopu meritev so izvedli 9 meritev, enkrat mesečno.

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

#### 4.1.1 Izvedba meritev premikov

Trigonometrično so večkrat (tedensko, kasneje mesečno) izmerili premike točke v profilih, ki so jih sprti dodajali. Nekateri profili so se kasneje prenehali meriti, ker so bili uničeni zaradi sanacijskih del. Izhajali so iz predpostavke, da so merske točke, ki so bile stabilizirane deset metrov in več izven območja plazine, stabilne. Posamezno meritev v profilu so izvedli v lokalnem koordinatnem sistemu, katerega osnovni izhodišči pri vsaki seriji meritev sta bila zunanji merski točki v profilu. Izhodiščne točke so naknadno tudi navezali na državni koordinatni sistem.



Slika 7: Grafični prikaz postavitve merskih profilov za območje Macesnikovega plazu

**Deformacije površine na Macesnikovem plazu**  
Rezultati merjenih deformacij po profilih



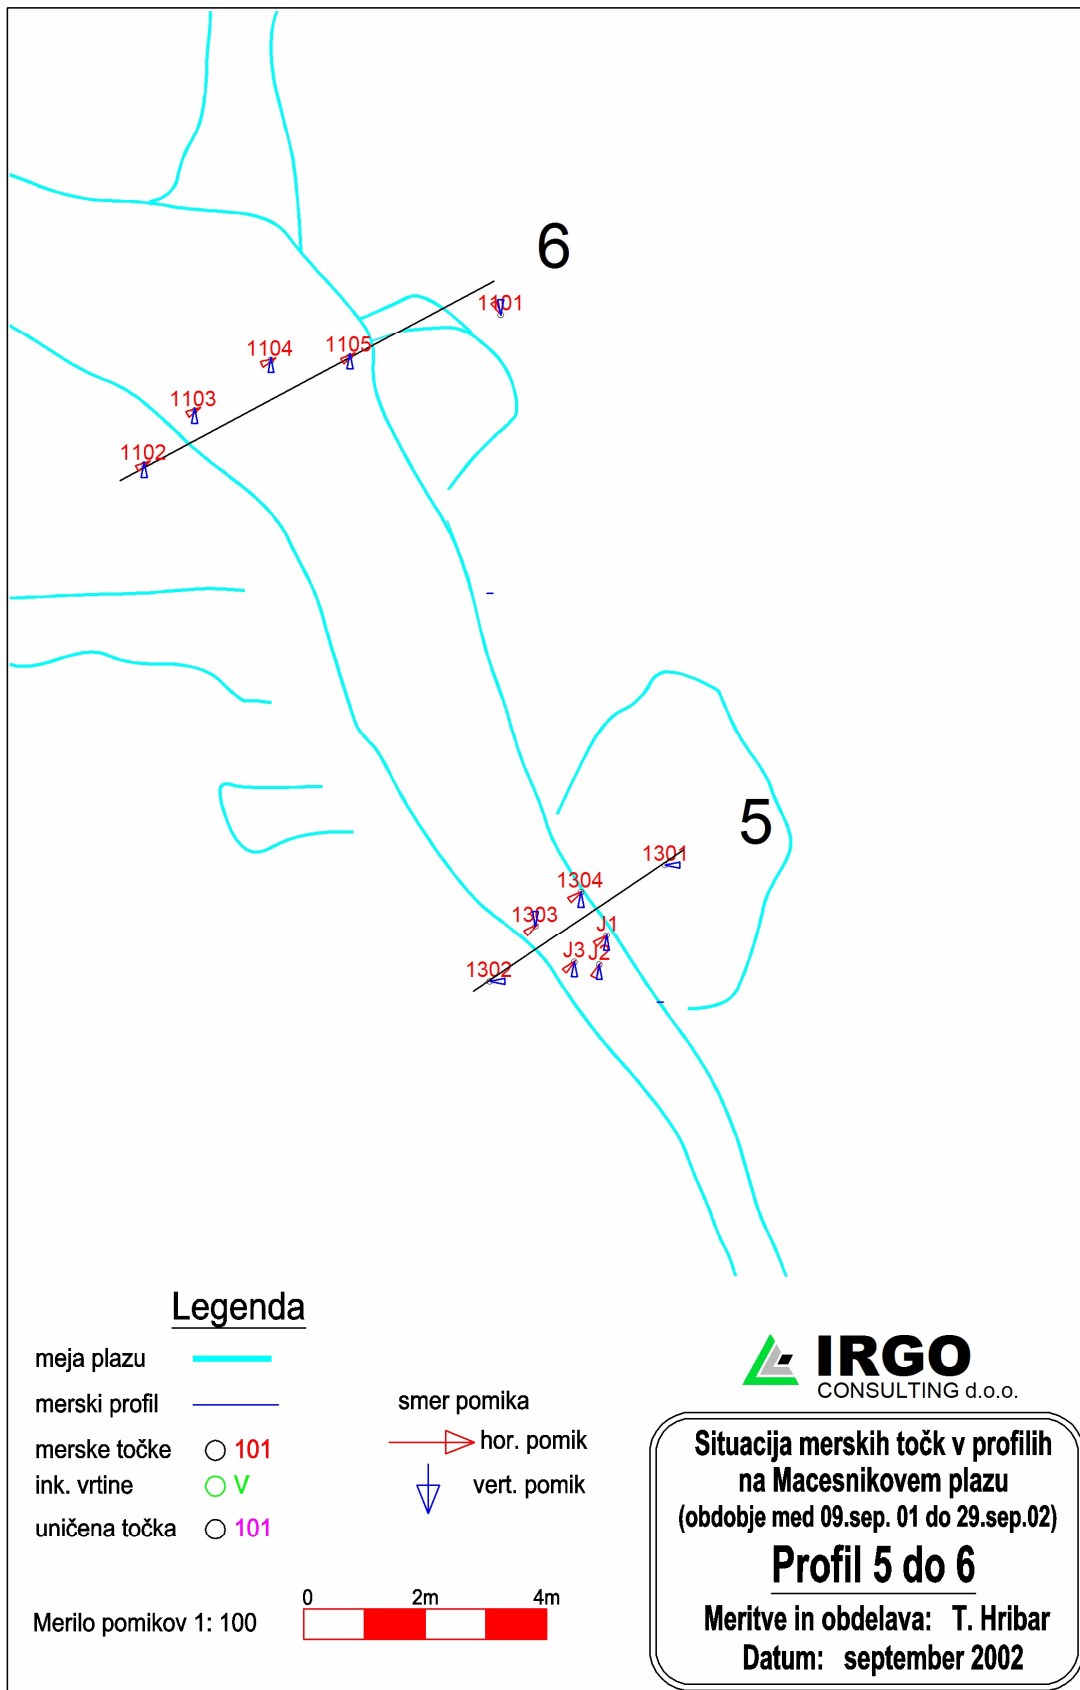
Vgradnja profilov: 13. In 14. nov. 2000  
Ničelna meritve: 20. nov. 00  
Prva meritve: 23. nov. 00  
Druga meritve: 27. nov. 00  
Tretja meritve: 30. nov. 00  
Četrta meritve: 09. dec. 00  
Peti meritve: 13. dec. 00

Šesta meritve: 18. dec. 00  
Sedma meritve: 22. dec. 00  
Osma meritve: 11. jan. 01  
3. jan. 01

profil točka	Datum		Ničelna meritve		Datum		Sedma meritve		Razlika od ničelne meritve: 52 dni		Razlika od prejšnje meritve: 20 dni		Razlika od prejšnje meritve [mm]						
	Y	X	H	X	Y	X	H	dY	dX	d	dY	dX	d	d					
<b>Profil 1</b>																			
101	20. nov. 00	859.670	1038.227	104.065	11. jan. 01	859.691	1038.237	104.068	21	10	3	23	101	26	15	11	30	1	2
102	20. nov. 00	865.974	1034.766	103.810	11. jan. 01	865.997	1034.770	103.813	23	4	3	23	102	17	12	-5	21	0	1
103	20. nov. 00	896.421	1025.575	101.127	11. jan. 01	896.427	1025.577	101.124	6	2	-3	6	103	10	7	4	12	0	1
104	20. nov. 00	926.696	1011.952	97.505	11. jan. 01	926.709	1011.958	97.504	13	6	-1	14	104	-1	7	1	7	0	0
105	20. nov. 00	964.939	1020.638	98.014	11. jan. 01	964.925	1020.613	98.010	16	-25	-4	30	105	4	-14	-5	15	0	1
106	20. nov. 00	1000.000	1022.927	103.708	11. jan. 01	1000.000	1022.896	103.703	0	-31	-5	31	106	0	-39	-5	39	0	2
<b>Profil 2</b>																			
201	20. nov. 00	1000.039	868.109	216.847	11. jan. 01	999.999	868.121	216.857	-10	12	10	16	201	0	2	-1	2	0	0
202	20. nov. 00	1006.021	908.198	206.891	11. jan. 01	1007.580	908.832	206.452	1559	634	-439	1683	202	592	239	-160	638	-8	32
203	20. nov. 00	998.559	951.721	204.099	11. jan. 01	1000.616	952.517	203.430	2057	796	-669	2206	203	764	322	-248	829	-12	41
204	20. nov. 00	991.982	973.720	202.580	11. jan. 01	993.060	974.272	202.237	1078	552	-343	1211	204	413	198	-127	458	-6	23
205	20. nov. 00	1000.000	1000.000	200.000	11. jan. 01	1000.000	1000.000	200.000	0	0	0	0	205	0	0	0	0	0	0
<b>Profil 3</b>																			
301	20. nov. 00	999.999	877.424	295.866	11. jan. 01	1000.000	877.405	295.863	1	-19	-3	19	301	2	-17	0	17	0	1
302	20. nov. 00	998.213	898.497	295.259	11. jan. 01	998.189	898.497	295.258	-24	0	-1	24	302	5	2	1	5	0	0
303	20. nov. 00	998.527	929.635	299.202	11. jan. 01	1000.927	929.199	298.677	2400	-436	-525	2439	303	902	-161	-196	916	-10	46
304	20. nov. 00	999.083	973.089	297.439	11. jan. 01	1000.408	973.112	297.092	1325	23	-347	1325	304	487	10	-123	487	-6	24
305	20. nov. 00	1000.000	1000.000	300.000	11. jan. 01	1000.000	1000.000	300.000	0	0	0	0	305	0	0	0	0	0	0
<b>Profil 4</b>																			
401	20. nov. 00	1000.000	1000.000	400.000	11. jan. 01	1000.000	1000.000	400.000	0	0	0	0	401	0	0	0	0	0	0
402	20. nov. 00	999.684	1013.399	398.986	11. jan. 01	999.680	1013.414	398.987	-4	15	1	16	402	-4	-2	9	4	0	0
403	20. nov. 00	1004.351	1024.543	397.016	11. jan. 01	1029.861	1027.271	389.266	25500	2728	-7750	25646	403	8550	115	-2420	8551	-121	428
404	20. nov. 00	1000.077	1031.912	398.727	11. jan. 01	1000.073	1031.926	398.730	-4	14	3	15	404	5	10	7	11	0	1
405	20. nov. 00	1000.000	1044.191	398.508	11. jan. 01	1000.000	1044.192	398.509	0	1	1	1	405	0	4	8	4	0	0
406	11. jan. 01	999.676	1022.173	398.441															
<b>Profil 5</b>																			
501	20. nov. 00	1000.030	1000.000	500.000	11. jan. 01	1000.000	1000.000	500.000	0	0	0	0	501	0	0	0	0	0	0
502	20. nov. 00	999.480	1013.899	498.943	11. jan. 01	999.793	1014.438	498.563	313	539	-380	623	502	108	204	-140	231	-7	12
503	20. nov. 00	1001.229	1035.258	494.169	11. jan. 01	1013.598	1035.306	492.327	12369	48	-1842	12369	503	4728	-110	-779	4729	-39	236
504	20. nov. 00	1000.001	1056.847	500.041	11. jan. 01	1000.000	1056.756	500.009	-1	-91	-32	91	504	3	-53	-35	53	-2	3
<b>Profil 6</b>																			
601	20. nov. 00	1000.001	1112.260	596.719	11. jan. 01	999.999	1112.243	596.714	-2	-17	-5	17	601	-2	-10	-6	10	0	1
602	20. nov. 00	1000.199	1091.381	594.985	11. jan. 01	997.436	1090.417	594.550	-2733	-964	-435	2898	602	-998	-354	-185	1059	-9	53
603	20. nov. 00	1000.033	1065.279	594.995	11. jan. 01	997.486	1064.243	594.796	-2547	-1036	-199	2750	603	-943	-380	-82	1017	-4	51
604	20. nov. 00	999.755	1037.515	594.537	11. jan. 01	999.029	1037.458	594.381	-736	-57	-156	738	604	-266	-43	-65	269	-3	13
605	20. nov. 00	1000.000	1000.000	600.000	11. jan. 01	1000.000	1000.000	600.000	0	0	0	0	605	0	0	0	0	0	0
<b>Profil 7</b>																			
701	30. nov. 00	1000.000	1079.112	152.184	11. jan. 01	1000.000	1079.106	152.188	0	-6	4	6	701	-1	-5	2	5	0	1
702	30. nov. 00	1001.599	1047.496	148.560	11. jan. 01	1000.581	1047.542	148.207	-1008	46	-353	1009	702	-224	-1	-79	224	-10	28
703	30. nov. 00	995.199	997.890	142.678	11. jan. 01	995.210	997.909	142.681	41	19	3	45	703	3	4	-2	5	0	1
704	30. nov. 00	1000.000	1000.000	150.000	11. jan. 01	1000.000	1000.000	150.000	0	0	0	0	704	0	0	0	0	0	0
705	30. nov. 00	1016.653	971.666	144.428	11. jan. 01	1014.788	970.632	143.226	-1865	-1034	-1202	2132	705	-161	-118	-390	200	-49	25
706	30. nov. 00	1024.856	954.820	144.727	11. jan. 01	1024.852	954.832	144.730	-4	12	3	13	706	-2	7	-4	7	-1	1

Slika 8: Primer analize meritev in izračun pomikov





Slika 9: Grafični prikaz premikov z vektorji

Meritve premikov (slika 8), njihova analiza, izračuni ter grafični prikaz premikov (slika 9) na Macesnikovem plazu so potekale dokaj redno in zahtevam, potrebam in namenu najbrž tudi dovolj natančno. Vendar bi morala izvedba takšnih meritev za potrebe natančnejšega in časovno daljšega vrednotenja premikov plazin, potekati nekoliko drugače. Seveda pa to ni vedno možno, kakor tudi v tem primeru, ko so se merjenja morala začeti takoj ob začetku premikanja plazu. Kako naj bi potekale takšne meritve predstavljamo v poglavju 4.2 projekt izvedbe meritev premikov na Macesnikovem plazu in njegovo vsebino.

## **4.2 Opis vsebin projekta, ki bi ga naj uporabljali izvajalci geodetskih opazovanj na Macesnikovem plazu**

Najprej je opisan projekt geodetske mreže, ki je osnova za vsa nadaljnja merjenja na določenem območju. Sledi projekt geodetskega opazovanja premikov tal in objektov in njegovo tehnično poročilo.

### 4.2.1 Projekt geodetske mreže

Za uspešno razvitje projekta geodetske mreže je potrebno, na osnovi projektne naloge, ki jo poda investitor:

- izdelati projekt geodetske mreže,
- projekt realizirati in
- izdelati elaborat o realizaciji.

Da bi bila dosežena zahtevana kvaliteta geodetske mreže, mora projekt geodetske mreže zagotoviti vse potrebne podatke, pogoje in navodila, ki jih je potrebno upoštevati.

Projekt geodetske mreže naj bi vseboval (Plankl, 2006):

- splošne podatke o projektu - to so predvsem podatki o vrsti, namenu, velikosti in lokaciji projektiranega objekta,
- projektno nalogo - v projektni nalogi se opredeli obseg, natančnost, velikost in vrsto geodetske mreže, ki jo je potrebno razviti,

- tehnično poročilo - v tehničnem poročilu so opisane predvsem metode, postopki in načini stabilizacije, izmere, izračuna, izravnave itd. Sestavni del tehničnega poročila je običajno tudi predračun in planirani čas za izvedbo,
- numerične podatke in dokumentacijo - tu so zbrani predvsem podatki o obstoječi mreži, predhodnih meritvah, podatki o izvedenih simulacijah meritev itd.,
- grafične podatke in dokumentacijo in
- spremljajočo dokumentacijo (geodetsko, geološko in drugo).

Pri izvedbi samega projekta geodetske mreže pa je potrebno opraviti naslednja geodetska dela:

- kontrola in testiranje obstoječe mreže,
- stabilizacija novih točk (vkopavanje, topografije, ipd),
- merjenje elementarnih količin (dolžin, kotov, višinskih razlik in drugih količin),
- izdelava analize rezultatov meritev,
- izravnava in ocena natančnosti in
- izdelava numeričnih, grafičnih in tabelarnih prilog.

Po končanih terenskih meritvah in obdelavi rezultatov meritev se izdelava elaborat o realizaciji projekta, v katerem se opišejo geodetska dela, ki so bila izvedena. Prav tako se opiše in opredeli natančnost terenskih meritev in obdelave rezultatov meritev z vsemi prilogami in izračuni, s katerimi se dokazuje korektnost in natančnost vzpostavitve geodetske mreže.

#### 4.2.2 Izdelava projekta geodetskega opazovanja premikov tal in objektov

Za potrebe geodetskega opazovanja premikov in deformacij objektov je potrebno na osnovi investitorjeve zahteve izdelati projekt geodetskega opazovanja premikov objekta, ga realizirati in izdelati elaborat o realizaciji in ugotovitvah.

Projekt geodetskega opazovanja premikov mora vsebovati predvsem tehnično poročilo, pogoje za izvedbo ter predračun.

Tehnično poročilo naj bi vsebovalo naslednje oporne točke (Plankl, 2006):

- osnovni podatki o objektu,
- načrt opazovanja in planirana natančnost kontrolne geodetske mreže,
- določevanje komponent vektorjev premikov karakterističnih točk objekta,
- izbira instrumentarija in metode opazovanja,
- analiza metod opazovanja in določitev kriterijev nesoglasij meritev,
- način stabilizacije osnovnih točk mreže,
- način stabilizacije kontrolnih točk na opazovanem objektu,
- modeli za testiranje opazovanj, izravnave in ocene natančnosti,
- modeli za testiranje stabilnosti točk osnovne mreže,
- modeli za testiranje premikanja kontrolnih točk mreže na objektu,
- evidentiranje premikov kontrolnih točk na objektu,
- terminski plan izvajanja opazovanj,
- način predstavitve rezultatov in
- vsebina elaborata o realizaciji projekta.

### 4.3 Merjenje višine padavin

#### 4.3.1 Vpliv padavin na nastanek plazov

Voda sodi med naravne sprožilce plazov. Voda namreč s svojo prisotnostjo v porah poveča maso zemljine in s tem obremenjuje zemljino s silami strunjanja ali pa zmanjša strižno trdnost materiala. Plazenje lahko povzroči ali dvig podzemne vode ali intenzivne padavine. V Sloveniji so intenzivne kratkotrajne padavine v zadnjih nekaj letih sprožile številne plazove (Komac, 2005). Rezultati analize pojavljanja plazov na območju Slovenije v odvisnosti od padavin so pokazali, da kratkotrajne padavine z intenziteto med 100 in 150 mm, najverjetneje pa nekje nad 130 mm v enem dnevu močno vplivajo na povečanje pojavljanja plazov (Komac, 2005). Pri povprečnih letnih padavinah je mejna vrednost nad 1000 mm, čeprav ni jasnih dokazov o neposrednem vplivu povprečnih letnih padavin na pojavljanje plazov.

Padavine sodijo med časovno spremenljive dejavnike, saj se njihova količina spreminja sezonsko in letno. Količina padavin se spreminja tudi vzdolž plazu, vendar pa natančnejše meritve na Macesnikovem plazu potekajo le od sredine leta 2004. V naši raziskavi - nalogi smo uporabili le meritve na padavinski postaji Solčava in jih privzeli enake za celoten plaz.


#### 4.3.2 Analiza vpliva padavin na gibanje plazu

V tem poglavju je obdelan vpliv količine padavin na hitrost plazenja. 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 1.

Preglednica 1: 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

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 10 je prikazana analiza zamika vpliva padavin na hitrost plazenja (Križnič, 2006).



Slika 10: Koeficient korelacije med zapoznelim vplivom 30 dnevni padavin na hitrost plazanja (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 plazanja), 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 plazanja.

Količine 30 dnevni padavin vpliva na hitrost plazanja (slika 10). 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. Plazina se lahko napaja iz podzemni dotokov, kar tudi pomeni posledično zakasnitev vpliva (Križnič, 2006). Na sliki 10 je pokazana analiza zamika vpliva 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 profilov.

Analiza vpliva padavin na hitrost je pokazala, da se vpliv povečuje bodisi z upoštevanjem 30 dnevnega zamika ali pa upoštevanjem daljšega, 60 ali 90 dnevnega časovnega intervala količine padavin. Na sliki 11 je predstavljena kombinirana analiza. Korelacijski koeficienti so računani ob upoštevanju 30 dnevnega zamika in 60 ter 90 dnevnih intervalov padavin (Križnič, 2006).





Slika 11: 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 plazanja. 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 plazanja, je pomembno tudi ugotoviti njihov vpliv na spremembo hitrosti. Z ugotavljanjem tega vpliva je možno določiti potrebno količino padavin, ki povzroči spremembo v hitrosti plazanja.

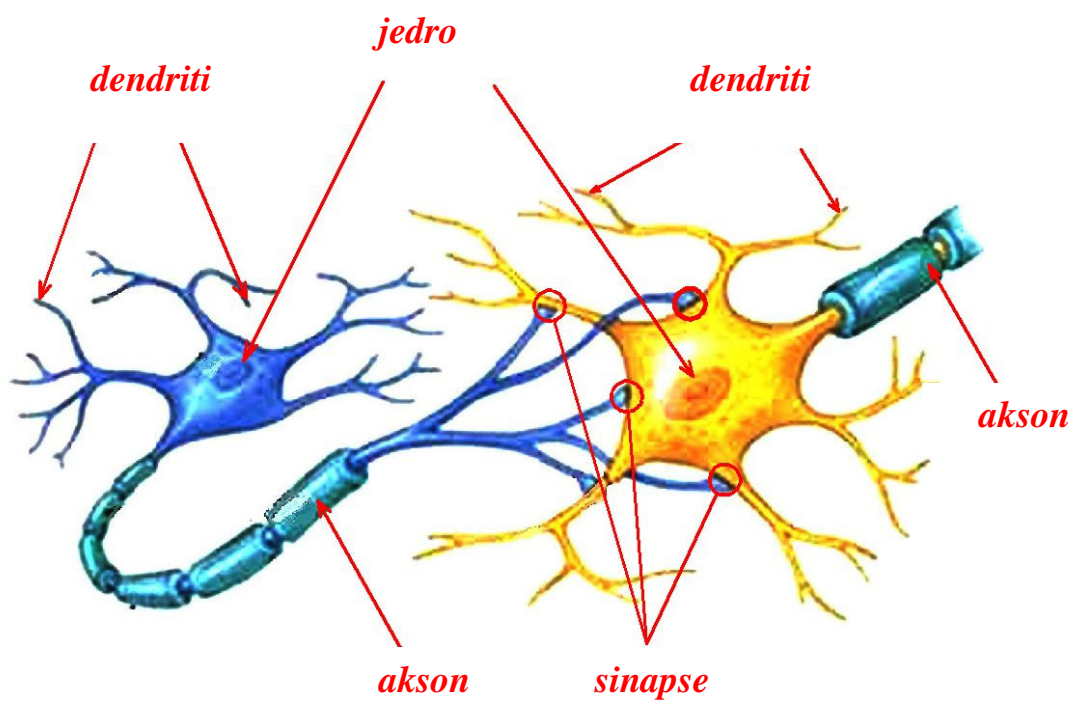
Količina padavin ima manjši vpliv na spremembo hitrosti premikanja plazu, kot na samo hitrost plazanja (slika 11). Tako imajo 60 dnevne padavine v profilu 4 in 7 največji vpliv na spremembo hitrosti. V istih merskih profilih je tudi največji vpliv ob upoštevanju 30 dnevnega zamika padavin.

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 plazanja. Količina padavin pa ni odločilen dejavnik, ki vpliva na spremembo hitrosti plazanja.

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.

## 5 UMETNE NEVRONSKE MREŽE

Razvoj in raziskovanje umetnih nevronskih mrež je bilo motivirano na podlagi spoznanj o delovanju človeških možganov, ter njegovih sposobnosti reševanja zapletenih problemov. Ta raziskovanja imajo dva osnovna cilja: prvi cilj predstavlja razvoj novih struktur umetnih nevronskih mrež, ki bi funkcionirale na podoben način kot delujejo človeški možgani in ki bi zmogle oponašati vsaj nekatere njegove funkcije.



Slika 12: Sestava biološkega nevrona

Na podlagi raziskovanj je bilo razvitih mnogo različnih struktur umetnih nevronskih mrež, ki jih uporabljamo za reševanje različnih problemov.

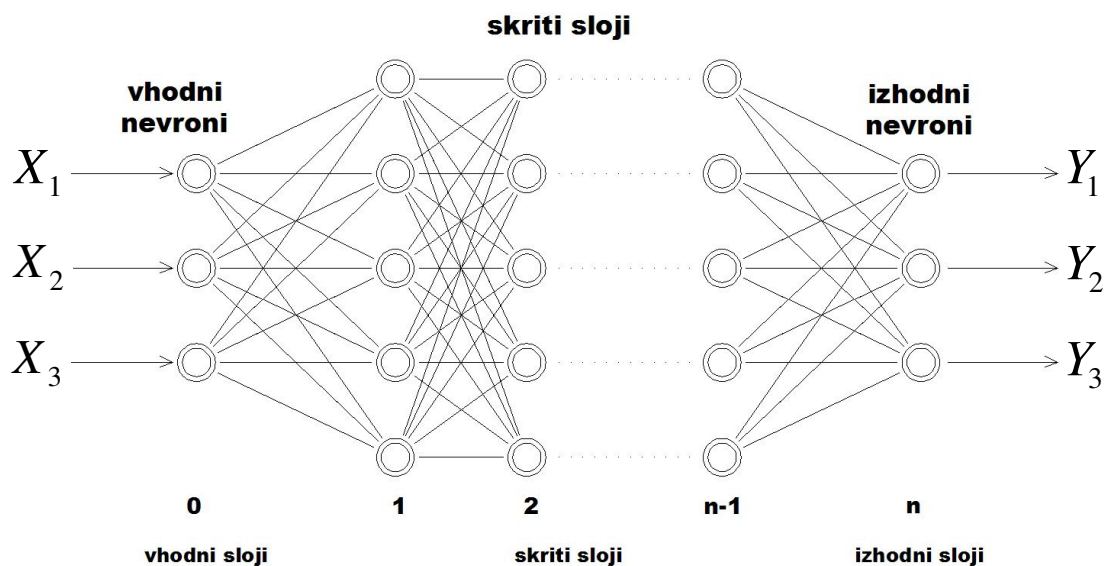
V splošnem se umetne nevronske mreže delijo na statične in dinamične. V diplomski nalogi je bila raziskana uporaba statične umetne nevronske mreže, ki bi omogočala napovedovanje premikov, zato je le-ta kasneje podrobneje opisana. Za statične umetne nevronske mreže je značilno, da imajo sposobnost dobre aproksimacije zveznih funkcij.

Umetne nevronske mreže se uči z ustreznim nastavljanjem uteži tako, da mreža izračuna oz. aproksimira željeno funkcijo. Postopek je iterativen in se zaključi, ko umetna nevronska mreža deluje tako kot želimo. Če je to v končnem času pravimo, da mreža konvergira (Kononenko, 1997).

Dokazali so (Hornik s sodelavci in Funahashi – leta 1989), da lahko z večslojno usmerjeno umetno nevronske mrežo aproksimiramo poljubno zvezno funkcijo poljubno natančno (Ambrožič, 2001).

Zato uporabljamo za napovedovanje plazenja zemljin večslojno usmerjeno umetno nevronske mrežo, saj želimo aproksimirati neznano zvezo med vhodnimi in izhodnimi podatki.

Kot nam že ime pove, je večslojna usmerjena umetna nevronska mreža razširjena dvoslojna umetna nevronska mreža s skritim slojem ali sloji nevronov. Sestavljajo jo torej najmanj trije sloji nevronov. Skriti sloj ali več skritih slojev dodamo med vhodni ali izhodni sloj nevronov.



Slika 13: Večslojna usmerjena umetna nevronska mreža (Ambrožič, 2001)

Nevroni vhodnega sloja so povezani z nevroni prvega skritega sloja. Ti so nadalje povezani z nevroni naslednjega skritega sloja in tako naprej. Nevroni zadnjega skritega sloja so tako povezani z nevroni izhodnega sloja. Povezani so torej le nevroni dveh sosednjih slojev. Prav tako ni povezav nevronov v posameznem sloju.

V večslojni usmerjeni umetni nevronske mreži pa vedno velja pravilo usmerjenosti. Le-to določa, da mora izhodni signal iz nevronov prejšnjega sloja vstopiti kot vhodni signal v nevrone naslednjega – sosednjega sloja. Pri tem signali potujejo le v eni smeri, torej od vhodnega sloja preko skritih slojev do izhodnega sloja in zato takšni mreži pravimo enosmerna. Tako vsak nevron vhodnega sloja pripada enemu vhodnemu podatku, vsak nevron izhodnega sloja pa eni odvisni spremenljivki, katere vrednost želimo določiti (Ambrožič, 2001).

V vsak nevron skritega sloja in v vsak nevron izhodnega sloja vstopa še signal iz tako imenovanega slepega (fiktivnega) nevrone. Ta signal je prag.

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

- niz učnih podatkov,
- niz verifikacijskih podatkov in
- niz testnih podatkov.

Na nizu verifikacijskih podatkov moramo torej poiskati "optimalno" geometrijo umetne nevronske mreže, ki se na nizu učnih primerov pravilno nauči in na nizu testnih podatkov pravilno aproksimira neznan funkcijo (Kononenko, 1997).

Vrednost signala nevrone  $i$  sloja  $k$  označimo z  $y_i^k$ . To vrednost dobimo tako, da pomnožimo vrednost signalov iz sloja  $k-1$  z utežmi med slojema  $w_{ij}^k$  in dobljene delne vsote seštejemo ter prištejemo vrednost praga  $\theta_i^k$

$$y_i^{nk} = \sum_{j=1}^{n_k-1} w_{ij}^k y_j^{k-1} + \theta_i^k$$

ter transformiramo z izhodno funkcijo in dobimo

**enačba 1:**

$$y_i^k = f(y_i^{nk}) = f\left(\sum_{j=1}^{n_k-1} w_{ij}^k y_j^{k-1} + \theta_i^k\right)$$

Učiti mrežo pomeni določiti vrednost uteži  $w_{ij}^k$  in praga  $\theta_i^k$  oziroma njihove popravke  $\Delta_p w_{ij}^k$  in  $\Delta_p \theta_i^k$  tako, da je vrednost napake na izhodnem sloju  $E_p$  minimalna. Napako na izhodnem sloju za  $p$ -ti vhodni vzorec (vhodno-izhodni par) definiramo kot vsoto kvadratov odstopanj

**enačba 2:**

$$E_p = \frac{1}{2} \sum_{i=1}^{n_o} (t_{pi} - y_{pi}^{nl})^2,$$

kjer je:

- $t_{pi}$  ... želena vrednost spremenljivke oziroma izhodnega nevrona  $i$  za vhodno-izhodni par  $p$ ,
- $y_{pi}^{nl}$  ... z umetno nevronske mreže izračunana vrednost izhodnega nevrona  $i$  za vhodno-izhodni par  $p$ ,
- $n_o$  ... število nevronov v izhodnem sloju  $n_i$

V našem primeru smo za napovedovanje plazenja zemljin izbrali učenje s posplošenim delta pravilom, ki so ga leta 1986 prvi opisali Rumelhart, Hinton in Williams, avtorji večslojne usmerjene umetne nevronske mreže (Ambrožič, 2001). To je v bistvu gradientna metoda.

Če želimo, da se napaka aproksimacije v vsakem koraku zmanjšuje, morajo biti popravki uteži in slepih nevronov sorazmerni z odvodom napake na izhodnem sloju po utežeh

**enačba 3:**

$$\Delta_p w_{ij}^k \propto \frac{\partial E_p}{\partial w_{ij}^k} \text{ in } \Delta_p \theta_i^k \propto \frac{\partial E_p}{\partial \theta_i^k} \text{ oziroma}$$

**enačba 4:**

$$\Delta_p w_{ij}^k = -\eta \frac{\partial E_p}{\partial w_{ij}^k} \text{ in } \Delta_p \theta_i^k = -\eta \frac{\partial E_p}{\partial \theta_i^k},$$

kjer je:

$\eta$  ...dolžina koraka, ki določa hitrost spreminjanja uteži, ta pa hitrost konvergence iskanja minimuma funkcije  $E_p$  oziroma hitrosti učenja.

Parcialni odvod v enačbah 3 in 4 izračunamo s posrednim odvajanjem

**enačba 5:**

$$\frac{\partial E_p}{\partial w_{ij}^k} = \frac{\partial E_p}{\partial y_{pi}^k} \frac{\partial y_{pi}^k}{\partial w_{ij}^k} \text{ in } \frac{\partial E_p}{\partial \theta_i^k} = \frac{\partial E_p}{\partial y_i^k} \frac{\partial y_{pi}^k}{\partial \theta_i^k}.$$

Odvod  $\partial y_{pi}^k / \partial w_{ij}^k$  in  $\partial y_{pi}^k / \partial \theta_i^k$  izračunamo z odvajanjem enačbe 1

**enačba 6:**

$$\frac{\partial y_{pi}^k}{\partial w_{ij}^k} = \frac{df(y_{pi}^k)}{dy_{pi}^k} \frac{\partial y_{pi}^k}{\partial w_{ij}^k} = \frac{df(y_{pi}^k)}{dy_{pi}^k} y_{pi}^{k-1} \text{ in } \frac{\partial y_{pi}^k}{\partial \theta_i^k} = \frac{df(y_{pi}^k)}{dy_{pi}^k} \frac{\partial y_{pi}^k}{\partial \theta_i^k} = \frac{df(y_{pi}^k)}{dy_{pi}^k}$$

Glede na sloj nevronov, ki ga trenutno računamo, moramo  $\partial E_p / \partial y_{pi}^k$  izračunati na dva načina.

Ko računamo odvode za nevrone izhodnega sloja  $n_l$  odvajamo enačbo 2.

**enačba 7:**

$$\frac{\partial E_p}{\partial y_{pi}^{nl}} = (t_{pi} - y_{pi}^{nl}).$$

Popravke za nevrone izhodnega sloja dobimo, če v enačbi 4 upoštevamo enačbe 5, 6 in 7:

**enačba 8:**

$$\Delta_p w_{ij}^{nl} = \eta (t_{pi} - y_{pi}^{nl}) \frac{df(y_{pi}^{nl})}{dy_{pi}^{nl}} y_{pi}^{nl-1} \text{ oziroma}$$

$$\Delta_p w_{ij}^{nl} = \eta \delta_{pi}^{nl} y_{pi}^{nl-1}.$$

Ko računamo odvode za nevrone drugih slojev, z odvajanjem enačbe 1 dobimo

**enačba 9:**

$$\frac{\partial E_p}{\partial y_{pi}^{k-1}} = \sum_{j=1}^{n_k} \frac{\partial E_p}{\partial y_{pj}^k} \frac{\partial y_{pj}^k}{\partial y_{pi}^{k-1}}$$

Popravke za nevrone drugih slojev dobimo, če v enačbi 4 upoštevamo enačbo 5, 6 in 9

**enačba 10:**

$$\Delta_p w_{ij}^{k-1} = \eta \left( \sum_{l=1}^{n_k} \frac{\partial E_p}{\partial y_{pl}^k} \frac{\partial y_{pl}^k}{\partial y_{pi}^{k-1}} \right) \frac{df(y_{pi}^{k-1})}{dy_{pi}^{k-1}} y_{pi}^{k-2}.$$

Popravljamo uteži od izhodnega sloja proti vhodnemu. Najprej popravimo uteži med izhodnim slojem in zadnjim skritim slojem. Nato popravimo uteži od zadnjega skritega sloja zaporedno proti prvemu. Na koncu popravimo uteži med prvim skritim slojem in vhodnim slojem. Tej metodi pravimo tudi metoda z vzratnim razširjanjem napak, saj ta odvod računamo postopoma od izhodnega sloja proti vhodnem sloju in v tej smeri določamo tudi popravke vrednosti uteži.

Vzratno razširjanje napake ponavljamo toliko časa, da je izračunana napaka za vse vhodno-izhodne pare manjša od predpisane napake. Če je predpisana napaka premajhna, pa se lahko zgodi, da umetno nevronska mrežo predobro naučimo na danem nizu učnih podatkov. Že za malo spremenjene vrednosti testnih podatkov lahko dobimo veliko napako med izračunanimi in pričakovanimi vrednostmi. Rečemo, da mreži zmanjšamo sposobnost posploševanja.



## 6. EKSPERIMENTALNI DEL

V eksperimentalnem delu smo s pomočjo umetnih nevronskih mrež poskušali napovedati premikanje Macesnikovega plazju. Za vhodni del podatkov za učenje umetnih nevronskih mrež smo uporabili čas oz. interval od prvega merjenja, kasneje količine padavine, za izhodni del pa kontrolne meritve premikov točk na površini.

### 6.1 Uporabljena programska oprema

Pri napovedovanju plazenja plazju Macesnik smo uporabili programe CTR-1 do CTR-5, ki so združitev programov NTRAIN in NTEST domače izdelave (Ambrožič, 2001). S programom NTRAIN učimo umetno nevronsko mrežo in s programom NTEST jo testiramo. CTR1, CTR2, CTR3, CTR4 in CTR5 so oznake za programe, ki povedo za koliko podatkov v izhodnem sloju, je program narejen (CTR1 – 1 izhodni, CTR2 – 2 izhodna,...) .

Pred izvajanjem programov NTRAIN in NTEST moramo pripraviti datoteke, ki vsebujejo:

- splošne podatke,
- vhodno-izhodne pare niza učnih podatkov in
- vhodno-izhodne pare niza testnih podatkov.

Obliko datoteke s splošnimi podatki prikazujemo in razložimo pomen parametrov v preglednici 2. Obliko datoteke vhodno-izhodnih parov niza učnih in testnih podatkov pa si bomo pogledali pri vsakem primeru izračuna napovedovanja dogajanja na plazju posebej, saj je ta oblika odvisna od primera, ki ga obravnavamo (odvisna od števila vhodnih nevronov, števila izhodnih nevronov, vrste vhodnih in vrste izhodnih podatkov).

Preglednica 2: Oblika datoteke, ki vsebuje splošne podatke.

0.5	step size	dolžina koraka, glej enačbo 4
0.05	error limit	vrednost še dopustne relativne napake na izhodnem sloju za p-ti vhodno izhodni par v %, glej enačbo 2
35000	maximum number of reruns	maksimalno število interacij
4	number of input neurons	število nevronov v vhodnem sloju
3	number of output neurons	število nevronov v izhodnem sloju
2	number of hidden layers	število skritih nevronov
15 15	number of neurons in hidden layer	število skritih nevronov v posameznem skritem sloju
0.1	range of starting weights	zgornja meja generiranih, začetnih vrednosti uteži – uporabljeno, ko program sam določi začetne vrednosti uteži
1963	seed for random number generator	začetna vrednost za generator slučajnih spremenljivk
'ucne.dat'	name of training set file	ime datoteke, ki vsebuje vhodno-izhodne pare niza učnih podatkov
'test.dat'	name of test set file	ime datoteke, ki vsebuje vhodno-izhodne pare niza testnih podatkov
'1515.out'	name of output file '1515.wgt'	ime datoteke z utežmi med nevroni

## 6.2 Vhodno-izhodni pari pri učenju umetnih nevronskih mrež

Umetno nevronska 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 nevronska mrežo 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 umetno nevronska mrežo učili na podatkih štirinajstih merjenj količine 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 za 26. in 27. meritve.

### 6.3 Učenje umetne nevronske mreže z enim podatkom v vhodnem sloju - časovnim intervalom od ničelne meritve

Najprej smo poizkusili napovedovanje premikanja plazju z umetnimi nevronskimi 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  $X$ ,  $Y$  in  $H$ .

Podatke smo dobili iz merjenja premikov točk na Macesnikovem plazju.

Merjenja so bila izvedena v 10 profilih. Posamezna meritev v profilu je bila izvedena v lokalnem koordinatnem sistemu, katerega osnovni izhodišči pri vsaki seriji meritev sta bila zunanji točki v profilu.

#### 6.3.1 Geometrije uporabljenih umetnih nevronskih mrež

Za učenje umetnih nevronskih mrež smo uporabili naslednje geometrije umetnih nevronskih mrež:

- **Z enim skritim slojem: 1-X-1, 1-X-2, 1-X-3**

To pomeni, da imamo 1 nevron v vhodnem sloju,  $X$  nevronov v enem skritem sloju in 1 ali 2 ali 3 nevrone v izhodnem sloju. Umetno nevronska mrežo smo učili na več različnih načinov in sicer tako, da smo za izhodni sloj imeli samo premik po osi  $X$ , ali samo premik po osi  $Y$  ali samo premik po osi  $H$ . Poskusili smo tudi, če imamo v izhodnem sloju 2 nevrona, in sicer premik po osi  $X$  in premik po osi  $Y$ , in če imamo v izhodnem sloju 3 nevrone in sicer premik po osi  $X$ , premik po osi  $Y$  in premik po osi  $H$ . V skritem sloju smo učili mrežo z  $X = 5, 10, 15, 20$  in 30 nevroni. Učenje smo torej opravili na petih različnih geometrijah umetne nevronske mreže z enim skritim slojem.

- **Z dvema skritima slojema: 1-X-Y-1, 1-X-Y-2, 1-X-Y-3**

Uporabili smo naslednje kombinacije umetni nevronske mreže s številom nevronov v obeh skritih slojih **X-Y**: 10-10, 15-15, 20-20, 20-25, 25-20, 25-25, 30-30. Učenje smo tako opravili na sedmih različnih geometrijah umetnih nevronske mreže z dvema skritima slojema.

Skupaj smo vse naše primere učenja umetnih nevronske mreže na vhodno-izhodnih parih Macesnikovega plazua opravili na dvanajstih različnih geometrija umetnih nevronske mreže.

### 6.3.2 Določitev uteži

Pred začetkom učenja določimo uteži naključno z generatorjem slučajnih števil. Število uteži za primer geometrije z dvema skritima sloja je naslednje  $\mathbf{1} \times \mathbf{X} + \mathbf{X} \times \mathbf{Y} + \mathbf{Y} \times \mathbf{1}$ , če je v vhodnem in izhodnem sloju samo en nevron.

Umetno nevronska mrežo učimo na vhodno-izhodnih parih niza učnih podatkov tako, da iterativno določamo uteži s posplošenim delta pravilom. Iteracije ponavljamo toliko časa, dokler je relativna napaka na vseh vhodno-izhodnih parih manjša od 5%. Relativno napako dobimo kot razliko med želeno in z umetno nevronska mrežo izračunano vrednostjo, deljeno z velikostjo želene vrednosti izhodnega podatka – koordinate premika.

### 6.3.3 Rezultati

Umetno nevronska mrežo smo poizkusili učiti na profilu 5 (točka 502), profilu 6 (točke 602, 603 in 604), profilu 7 (točka 702 in 704), profilu 8 (točka 803 in 804) in profilu 9 (točka 902 in 903) za vsako točko posebej.

Rezultati so bili zelo različni. V nekaterih profilih je bilo učenje umetnih nevronske mreže uspešno tako z enim kot s tremi nevroni v izhodnem sloju. V nekaj primerov pa učenja niti z eno od 12 možnih geometrij mreže ni bilo uspešno. Pri podrobnejši analizi merjenj premikov smo ugotovili, da nekatere meritve vsebovale grobe pogreške, zato smo jih odstranili iz učenja in dobili boljše rezultate.

Opazili smo, da so se umetne nevronske mreže z dvema skritima slojema bolj naučile, kot umetne nevronske mreže z enim skritim slojem, posebej velja to za primer s tremi nevroni v izhodnem sloju.

Preglednica 3: Rezultati testiranja naučene umetne nevronske mreže za primer točke 803 pri enem vhodnem (število dni od ničelene meritve) in treh izhodnih (X, Y, in H koordinata) podatkih. Imeli smo 12 učnih in 1 testni vhodno-izhodni par.

1	2	3	4	5	6	7	8	9	10
5.inp	50001( 2)	-0.4376	-0.4376	-0.4376	0.0000	0.0000	0.0000	-0.4376	-0.4376
		0.1091	0.1091	0.1091	0.0000	0.0000	0.0000	0.1091	0.1091
		0.0734	0.0734	0.0734	0.0000	0.0000	0.0000	0.0734	0.0734
10.inp	50001( 2)	-0.4235	-0.4235	-0.4235	0.0000	0.0000	0.0000	-0.4235	-0.4235
		0.1040	0.1040	0.1040	0.0000	0.0000	0.0000	0.1040	0.1040
		0.0714	0.0714	0.0714	0.0000	0.0000	0.0000	0.0714	0.0714
15.inp	50001( 2)	-0.4313	-0.4313	-0.4313	0.0000	0.0000	0.0000	-0.4313	-0.4313
		0.1052	0.1052	0.1052	0.0000	0.0000	0.0000	0.1052	0.1052
		0.0719	0.0719	0.0719	0.0000	0.0000	0.0000	0.0719	0.0719
20.inp	50001( 2)	-0.4018	-0.4018	-0.4018	0.0000	0.0000	0.0000	-0.4018	-0.4018
		0.1025	0.1025	0.1025	0.0000	0.0000	0.0000	0.1025	0.1025
		0.0673	0.0673	0.0673	0.0000	0.0000	0.0000	0.0673	0.0673
30.inp	50001( 2)	-0.4052	-0.4052	-0.4052	0.0000	0.0000	0.0000	-0.4052	-0.4052
		0.0936	0.0936	0.0936	0.0000	0.0000	0.0000	0.0936	0.0936
		0.0659	0.0659	0.0659	0.0000	0.0000	0.0000	0.0659	0.0659
1010.inp	50001( 1)	-0.3069	-0.3069	-0.3069	0.0000	0.0000	0.0000	-0.3069	-0.3069
		0.0718	0.0718	0.0718	0.0000	0.0000	0.0000	0.0718	0.0718
		0.0440	0.0440	0.0440	0.0000	0.0000	0.0000	0.0440	0.0440
1515.inp	46152( 0)	-0.3120	-0.3120	-0.3120	0.0000	0.0000	0.0000	-0.3120	-0.3120
		0.0728	0.0728	0.0728	0.0000	0.0000	0.0000	0.0728	0.0728
		0.0459	0.0459	0.0459	0.0000	0.0000	0.0000	0.0459	0.0459
2020.inp	50001( 1)	-0.2905	-0.2905	-0.2905	0.0000	0.0000	0.0000	-0.2905	-0.2905
		0.0678	0.0678	0.0678	0.0000	0.0000	0.0000	0.0678	0.0678
		0.0412	0.0412	0.0412	0.0000	0.0000	0.0000	0.0412	0.0412
2025.inp	48696( 0)	-0.2574	-0.2574	-0.2574	0.0000	0.0000	0.0000	-0.2574	-0.2574
		0.0606	0.0606	0.0606	0.0000	0.0000	0.0000	0.0606	0.0606
		0.0370	0.0370	0.0370	0.0000	0.0000	0.0000	0.0370	0.0370
2520.inp	37619( 0)	-0.3007	-0.3007	-0.3007	0.0000	0.0000	0.0000	-0.3007	-0.3007
		0.0682	0.0682	0.0682	0.0000	0.0000	0.0000	0.0682	0.0682
		0.0458	0.0458	0.0458	0.0000	0.0000	0.0000	0.0458	0.0458
2525.inp	33399( 0)	-0.3046	-0.3046	-0.3046	0.0000	0.0000	0.0000	-0.3046	-0.3046
		0.0701	0.0701	0.0701	0.0000	0.0000	0.0000	0.0701	0.0701
		0.0461	0.0461	0.0461	0.0000	0.0000	0.0000	0.0461	0.0461

3030.inp	35232( 0)	-0.2816	-0.2816	-0.2816	0.0000	0.0000	0.0000	-0.2816	-0.2816
		0.0657	0.0657	0.0657	0.0000	0.0000	0.0000	0.0657	0.0657
		0.0415	0.0415	0.0415	0.0000	0.0000	0.0000	0.0415	0.0415

V preglednici 3 imamo:

V stolpcu št.: 1 - geometrijo mreže (2020.inp je enako geometriji mreže 1-20-20-1)

V stolpcu št.: 2 – število iteracij, potrebnih za učenje umetne nevronske mreže pri pogoju, da je relativna napaka na vseh vhodno-izhodnih parih niza učnih podatkov manjša do 5% (v oklepaju podajamo število vhodno-izhodnih parov niza učnih podatkov z relativno napako večjo kot 5%, če v 50000 iteracijah učenje ni bilo uspešno, če pa je bilo učenje uspešno, pa je v tem stolpcu podano potrebno število iteracijskih korakov, da se je umetna nevronska mreža naučila).

V stolpcu št.: 3 – minimalno vrednost razlike med želeno in z umetno nevronske mrežo izračunano vrednostjo.

V stolpcu št.: 4 – maksimalno vrednost razlike med želeno in z umetno nevronske mrežo izračunano vrednostjo.

V stolpcu št.: 5 – srednjo vrednost razlike med želeno in z umetno nevronske mrežo izračunano vrednostjo.

V stolpcu št.: 6 – srednjo kvadratna vrednost razlike med želeno in z umetno nevronske mrežo izračunano vrednostjo.

V stolpcu št.: 7 – srednjo absolutna vrednost razlike med želeno in z umetno nevronske mrežo izračunano vrednostjo.

V stolpcu št.: 8 – standardno odstopanje srednje vrednosti razlike med želeno in z umetno nevronske mrežo izračunano vrednostjo.

V stolpcu št.: 9 in 10 – interval zaupanja srednje vrednosti razlike med želeno in z umetno nevronske mrežo izračunano vrednostjo, če je stopnja zaupanja  $1-\alpha = 95\%$

Iz preglednice 3 vidimo, da so minimalne, maksimalne, srednja vrednost razlike in interval zaupanja srednje vrednosti razlike med želeno in z umetno nevronske mrežo izračunano vrednostjo iste vrednosti, kar je v redu, saj imamo samo en testni vhodno-izhodni par. Tako so posledično srednje kvadratne vrednosti, srednje absolutne vrednosti in standardno odstopanje srednje vrednosti razlika med želeno in z umetno nevronske mrežo izračunane vrednosti

enake nič. Iz preglednice 3 tudi vidimo, da je najbolje napovedala premike točke 803 umetna nevronska mreža 1-20-25-3.

#### **6.4 Učenje umetne nevronske mreže z dvema vhodnima podatkom**

Odločili smo se, da želimo napovedovanje še izboljšati. V nadaljevanju smo za vhodnim podatkom dodali tudi mesečne padavine oz. količine padavin, ki so bile izmerjene na meteorološki postaji Solčava, v tistem mesecu, v katerem so bili izvedene meritve. Tako smo imeli dva vhodna nevrona:

- čas posamezne meritve od ničelne meritve za prvi nevron in
- količino mesečnih padavin v tistem mesecu, v katerem so bile izvedena meritve za drugi nevron.

Izhodni podatki, geometrija umetnih nevronskih mrež, kriteriji prekinitve iteracijskega procesa učenja umetnih nevronskih mrež so bili enaki kot v primeru, ki smo ga opisali v poglavju 6.3.

Rezultati učenja so bili zelo podobni prejšnjim, ko še nismo uporabili padavin, zato tega primera ne prikazujemo podrobneje.

#### **6.5 Učenje umetne nevronske mreže s tremi vhodnimi podatki**

Kot smo že v diplomski nalogi opisali in prikazali, je hitrost plazanja soodvisna od količine vode, ki se je nabrala v daljšem časovnem intervalu v preteklosti in količine vode, oz. višine padavin, ki je padla v bližnji preteklosti. Zato smo v nadaljevanju učenja umetni nevronskih mrež 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  $X$ ,  $Y$ , in  $H$  ( $v_X$ ,  $v_Y$  in  $v_H$ ),
- hitrost premika točke po ravnini  $XY$  ( $v_{XY}$ ) in
- hitrost premika točke po prostoru  $XYH$  ( $v_{XYH}$ ).

Najprej smo umetno nevronske mreže učili z dvema vhodnima podatkom in sicer padavine za 90 in 5 dni nazaj in padavine za 90 in 10 dni nazaj. Rezultati so bili boljši kot prej. Umetna nevronska mreža se je z razdelitvijo padavin na dva vhodna podatka še boljše naučila in nato bila sposobna napovedati premikanje analiziranih točk.

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

V naslednji fazi smo umetno nevronske mreže 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 ( $v_{XYH}$ ).


V tem primeru učenje umetne nevronske mreže ni bilo prav uspešno. V preglednici 3 je lepo razvidno, da je se je v tem primeru umetna nevronska mreža naučila samo v enem primeru in to v umetni nevronske mreži z geometrijo 3-15-15-1 za kar je potrebovala 8243 iteracij. Z rezultati nismo bili zadovoljni, zato smo v nadaljevanju še spreminjali število vhodnih in izhodnih nevronov.

Preglednica 4: Rezultati testiranja naučene umetne nevronske mreže za primer točke 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in enim izhodnim



(hitrost premika točke po prostoru –  $v_{xyH}$ ) podatkom. Imeli smo 18 učnih in 2 testna vhodno-izhodna para. Razporeditev stolpcev je enaka kot pri preglednici 3.

1	2	3	4	5	6	7	8	9	10
5.inp	15001(7)	-5.2007	9.8690	2.3341	56.7743	7.5349	7.5349	-8.1087	12.7769
10.inp	15001(3)	-0.5390	0.1540	-0.1925	0.1201	0.3465	0.3465	-0.6727	0.2877
15.inp	15001(4)	-0.5343	1.7473	0.6065	1.3015	1.1408	1.1408	-0.9746	2.1876
20.inp	15001(2)	1.5238	2.1324	1.8281	0.0926	0.3043	0.3043	1.4064	2.2499
30.inp	15001(1)	1.0332	5.9708	3.5020	6.0949	2.4688	2.4688	0.0804	6.9235
1010.inp	15001(4)	-12.1038	2.9348	-4.5845	56.5403	7.5193	7.5193	-15.0058	5.8368
1515.inp	8243(0)	-4.1649	10.1915	3.0133	51.5265	7.1782	7.1782	-6.9351	12.9618
2020.inp	15001(4)	-0.4514	3.4590	1.5038	3.8227	1.9552	1.9552	-1.2059	4.2135
2025.inp	15001(5)	-8.9142	20.6649	5.8753	218.7312	14.7896	14.7896	-14.6220	26.3726
2520.inp	15001(4)	2.0862	5.9281	4.0072	3.6901	1.9210	1.9210	1.3448	6.6695
2525.inp	15001(4)	-11.6164	2.0826	-4.7669	46.9156	6.8495	6.8495	-14.2598	4.7260
3030.inp	15001(4)	1.8716	5.5246	3.6981	3.3360	1.8265	1.8265	1.1667	6.2295



Slika 14: Grafični prikaz napovedovanja hitrosti premikanja 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 –  $v_{xyH}$ ).

Iz slike 14 vidimo, da še nobena umetna nevronska mreža ni uspela naučiti napovedovanje hitrosti premika po prostoru –  $v_{xyH}$  takrat, ko smo imeli v datoteki z učnimi podatki 21 vhodno-izhodnih parov. Tudi sicer učenje umetnih nevronske mreže ni bilo prav uspešno.


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

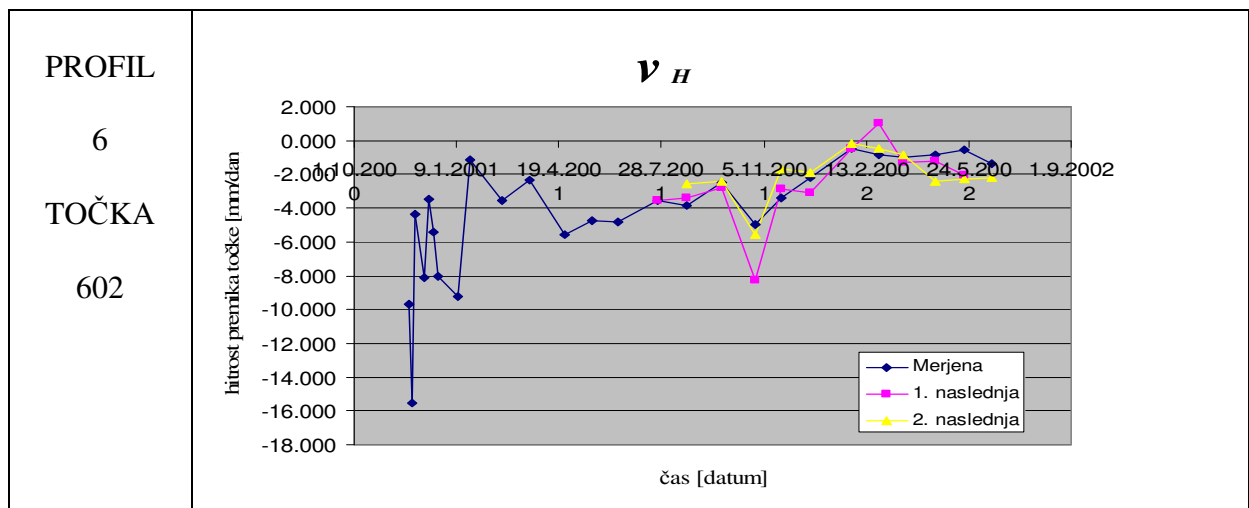
Ker z rezultati z enim nevronom v izhodnem sloju nismo bili zadovoljni, smo poskusili izhodne podatke razdeliti na več različnih podatkov, potrebnih za napovedovanje plazenja. Za to smo se odločili, ker smo v prejšnjih primerih učenja, kjer smo vsak premik (hitrost po oseh  $X$ ,  $Y$  in  $H$ ) učili posebej, dobili boljše rezultate kot sedaj, ko smo vse tri hitrosti združili v en podatek. Mnenja smo bili, da so hitrosti premikov po osi  $H$  grobo pogrešene (slabe višinske meritve) in močno vplivajo na skupno prostorsko hitrost premika, zato je bolje, da hitrosti premikov razdelimo po oseh ( $v_x$ ,  $v_y$  in  $v_H$ ) in nato učimo umetno nevronske mrežo.

Preglednica 5: Rezultati testiranja naučene umetne nevronske mreže za primer točke 602 pri treh vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih (hitrosti v smereh osi -  $v_x$ ,  $v_y$  in  $v_H$ ) podatkih. Imeli smo 20 učnih in 2 testna vhodno-izhodna para. Razporeditev stolpcev je enaka kot pri preglednici 3.

1	2	3	4	5	6	7	8	9	10
5.inp	35001( 19)	0.3356	3.1323	1.7340	1.9554	1.3984	1.3984	-0.2041	3.6720
		0.1766	1.4390	0.8078	0.3984	0.6312	0.6312	-0.0670	1.6826
		-0.3716	0.0921	-0.1397	0.0537	0.2318	0.2318	-0.4610	0.1816
10.inp	35001( 3)	-21.4355	-1.9344	-11.6849	95.0736	9.7506	9.7506	-25.1985	1.8287
		0.0185	0.7365	0.3775	0.1289	0.3590	0.3590	-0.1200	0.8751
		-2.2327	-0.0591	-1.1459	1.1811	1.0868	1.0868	-2.6521	0.3603
15.inp	35001( 2)	-1.9084	1.1147	-0.3969	2.2847	1.5115	1.5115	-2.4917	1.6980
		0.0401	0.6759	0.3580	0.1011	0.3179	0.3179	-0.0826	0.7986
		-0.3949	0.2918	-0.0516	0.1179	0.3434	0.3434	-0.5274	0.4243
20.inp	35001( 1)	-11.8204	0.3554	-5.7325	37.0620	6.0879	6.0879	-14.1698	2.7049
		0.3285	1.1722	0.7503	0.1780	0.4219	0.4219	0.1657	1.3350
		-2.1669	-0.0079	-1.0874	1.1654	1.0795	1.0795	-2.5836	0.4087
30.inp	35001( 2)	0.5698	3.7369	2.1534	2.5076	1.5836	1.5836	-0.0413	4.3481
		0.7060	0.8817	0.7939	0.0077	0.0878	0.0878	0.6721	0.9156
		0.8437	1.0275	0.9356	0.0084	0.0919	0.0919	0.8082	1.0629
1010.inp	7047( 0)	2.6311	2.9780	2.8046	0.0301	0.1735	0.1735	2.5642	3.0450
		0.2857	0.7694	0.5276	0.0585	0.2419	0.2419	0.1923	0.8628
		0.5280	0.7434	0.6357	0.0116	0.1077	0.1077	0.4864	0.7849
1515.inp	10333( 0)	1.6755	1.9626	1.8190	0.0206	0.1435	0.1435	1.6201	2.0180
		-0.1249	0.3666	0.1209	0.0604	0.2458	0.2458	-0.2197	0.4615
		-0.0089	0.3281	0.1596	0.0284	0.1685	0.1685	-0.0739	0.3931
2020.inp	10500( 0)	3.2906	4.0550	3.6728	0.1461	0.3822	0.3822	3.1431	4.2025

		0.7002	1.0614	0.8808	0.0326	0.1806	0.1806	0.6305	1.1311
		-0.6118	0.0065	-0.3026	0.0956	0.3092	0.3092	-0.7312	0.1259
2025.inp	18130( 0)	2.0928	3.3978	2.7453	0.4257	0.6525	0.6525	1.8410	3.6496
		0.1060	0.8484	0.4772	0.1378	0.3712	0.3712	-0.0372	0.9916
		-0.5534	0.0784	-0.2375	0.0998	0.3159	0.3159	-0.6753	0.2003
2520.inp	8978( 0)	-5.1206	-4.9128	-5.0167	0.0108	0.1039	0.1039	-5.1607	-4.8727
		-1.2680	-0.8306	-1.0493	0.0478	0.2187	0.2187	-1.3525	-0.7462
		-0.9887	-0.5824	-0.7855	0.0413	0.2031	0.2031	-1.0671	-0.5040
2525.inp	4303( 0)	-5.5327	-2.6584	-4.0955	2.0655	1.4372	1.4372	-6.0874	-2.1037
		-0.4364	-0.0525	-0.2445	0.0369	0.1920	0.1920	-0.5105	0.0216
		-0.5042	-0.2407	-0.3725	0.0173	0.1317	0.1317	-0.5550	-0.1899
3030.inp	10292( 0)	-1.1138	-0.0669	-0.5903	0.2740	0.5235	0.5235	-1.3159	0.1352
		-0.6165	-0.4433	-0.5299	0.0075	0.0866	0.0866	-0.6499	-0.4099
		-1.8077	-1.2371	-1.5224	0.0814	0.2853	0.2853	-1.9178	-1.1270





Slika 15: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mreže za točko 602 pri treh vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih (hitrost premika točke po smereh  $v_X$ ,  $v_Y$  in  $v_H$ )

Po pregledu rezultatov (slika 15) je lepo razvidno, da so boljši, kot v vseh učenjih do sedaj. Iz preglednice 5 vidimo, da se je najboljše naučila in nato napovedala hitrosti v smereh osi za točko 602 umetna nevronska mreža z geometrijo 3-15-15-3. Predvidevamo, da je geometrija 3 vhodni in 3 izhodni dobra za napovedovanje premikov, zato poizkusimo še z drugimi kombinacijami izhodnih podatkov. Poizkusimo tako, da za podatke v izhodnem sloju iz premikov in časovnih intervalov med meritvami izračunamo 3 različne hitrosti premikanja. To so hitrost premika po osi  $H$  ( $v_H$ ), hitrost premika po ravnini  $XY$  ( $v_{XY}$ ) in hitrost premika po prostoru  $XYH$  ( $v_{XYH}$ ). Primer vhodne datoteke, ki smo jo uporabili za učenje umetne nevronske mreže, prikazujemo na sliki 16, primer izhodne datoteke pa na sliki 17.



Slika 17: Prikaz testne datoteke z 19-im in 20-im vhodno-izhodnim parom za testiranje nevronske mreže v profilu 6 za točko 604. Za vhodne podatke imamo padavine za 90, 10 in 5 dni nazaj. Za izhodne pa hitrosti po osi -  $v_H$ , ravnini -  $v_{XY}$  in prostoru -  $v_{XYH}$ .

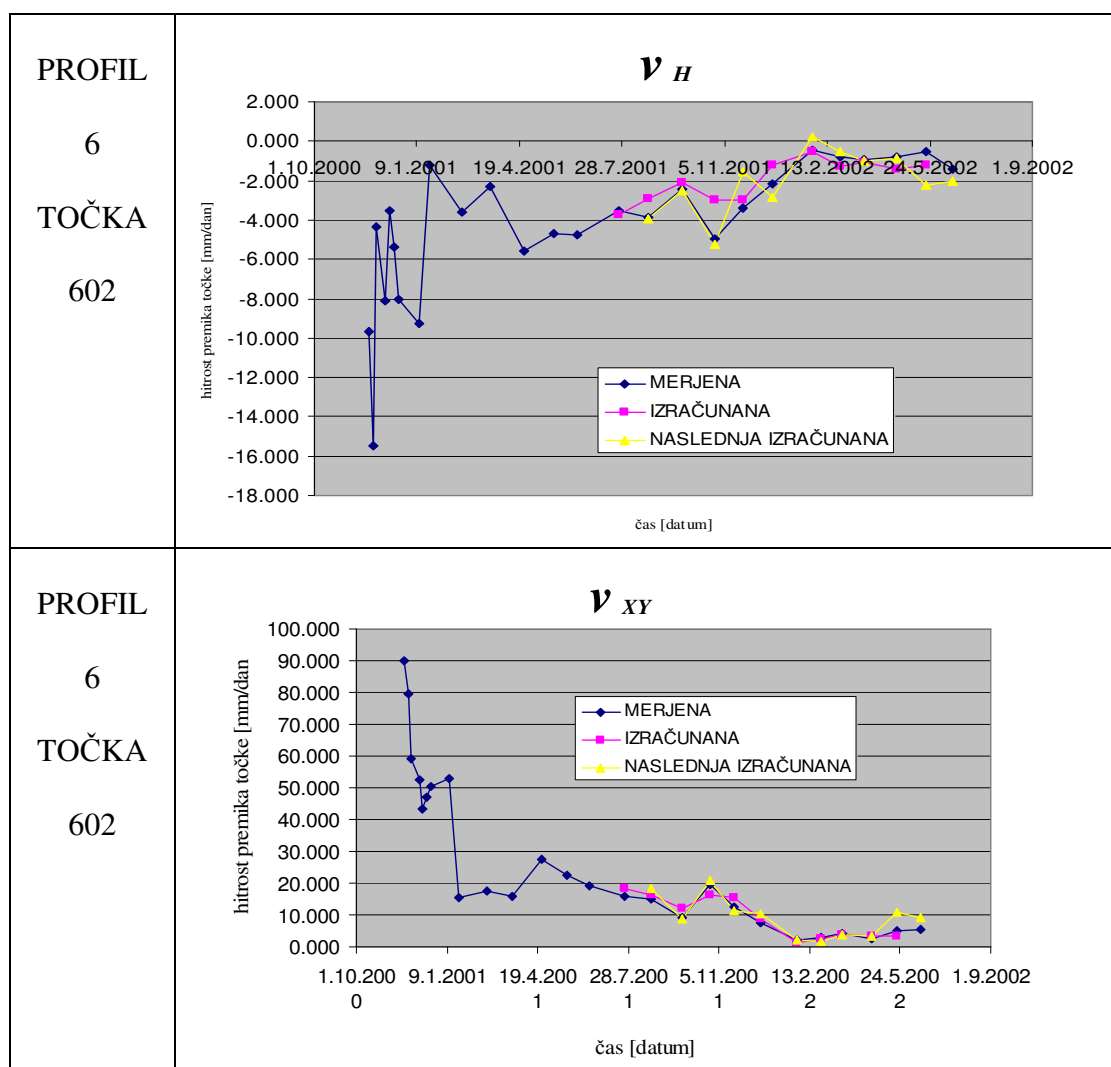
Preglednica 6: Rezultati testiranja naučene umeten nevronske mreže za primer točke 604 pri 3 vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih (hitrosti po osi  $v_H$ , ravnini -  $v_{XY}$  in prostoru -  $v_{XYH}$ ) podatkih. Imeli smo 18 učnih in 2 testna vhodno-izhodna para.

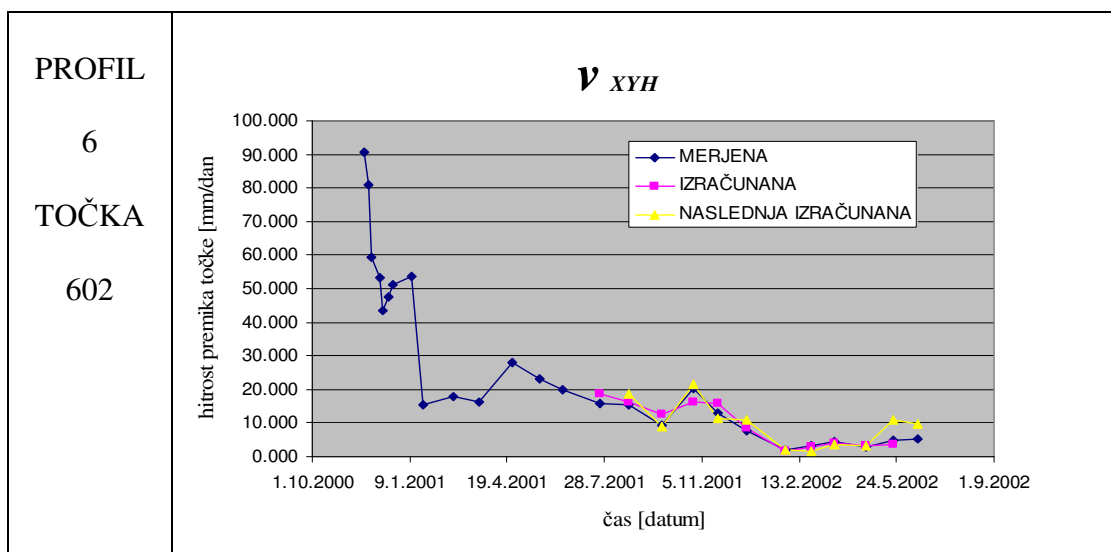
Razporeditev stolpcev je enaka kot pri razpredelnici 3.

1	2	3	4	5	6	7	8	9	10
5.inp	35001( 10)	1.0788	1.2586	1.1687	0.0081	0.0899	0.0899	1.0441	1.2933
		-0.0181	0.1532	0.0676	0.0073	0.0857	0.0857	-0.0512	0.1863
		-0.1141	-0.0135	-0.0638	0.0025	0.0503	0.0503	-0.1335	0.0059
10.inp	35001( 1)	0.8075	1.3206	1.0641	0.0658	0.2566	0.2566	0.7085	1.4197
		-0.0331	0.9659	0.4664	0.2495	0.4995	0.4995	-0.2259	1.1587
		-0.1558	0.7172	0.2807	0.1905	0.4365	0.4365	-0.3242	0.8856
15.inp	35001( 1)	-0.2935	0.5816	0.1441	0.1915	0.4376	0.4376	-0.4624	0.7505
		1.5071	2.5880	2.0475	0.2921	0.5405	0.5405	1.2985	2.7966
		1.4657	2.4975	1.9816	0.2662	0.5159	0.5159	1.2666	2.6967
20.inp	35001( 1)	0.3528	1.0749	0.7139	0.1304	0.3611	0.3611	0.2135	1.2143
		1.0917	1.7438	1.4178	0.1063	0.3261	0.3261	0.9659	1.8697
		0.9851	1.5137	1.2494	0.0698	0.2643	0.2643	0.8831	1.6157
30.inp	24899( 0)	0.0144	1.0180	0.5162	0.2518	0.5018	0.5018	-0.1792	1.2117
		1.6210	2.7034	2.1622	0.2929	0.5412	0.5412	1.4121	2.9123
		1.5309	2.4749	2.0029	0.2228	0.4720	0.4720	1.3488	2.6571
1010.inp	7920( 0)	1.7366	1.8496	1.7931	0.0032	0.0565	0.0565	1.7148	1.8714
		-0.9158	-0.1796	-0.5477	0.1355	0.3681	0.3681	-1.0578	-0.0375
		-1.1055	-0.5112	-0.8084	0.0883	0.2972	0.2972	-1.2202	-0.3965
1515.inp	6650( 0)	0.9591	1.3539	1.1565	0.0390	0.1974	0.1974	0.8829	1.4300
		-0.4760	2.3279	0.9259	1.9655	1.4020	1.4020	-1.0171	2.8690
		-0.6227	2.1702	0.7737	1.9500	1.3964	1.3964	-1.1616	2.7091
2020.inp	34040( 0)	-0.5789	2.2565	0.8388	2.0100	1.4177	1.4177	-1.1261	2.8037
		-1.1258	4.3458	1.6100	7.4844	2.7358	2.7358	-2.1816	5.4016
		-1.3311	4.2979	1.4834	7.9213	2.8145	2.8145	-2.4173	5.3841
2025.inp	27276( 0)	0.0119	2.2509	1.1314	1.2532	1.1195	1.1195	-0.4201	2.6829
		-0.7225	2.7000	0.9888	2.9284	1.7113	1.7113	-1.3829	3.3604
		-0.9370	2.6140	0.8385	3.1523	1.7755	1.7755	-1.6222	3.2992
2520.inp	15253( 0)	0.3103	1.1926	0.7515	0.1946	0.4412	0.4412	0.1401	1.3629
		1.3077	2.5531	1.9304	0.3878	0.6227	0.6227	1.0674	2.7935
		1.2945	2.2985	1.7965	0.2520	0.5020	0.5020	1.1007	2.4923
2525.inp	35001( 5)	-0.1176	1.0484	0.4654	0.3399	0.5830	0.5830	-0.3427	1.2734

		1.1452	1.8505	1.4978	0.1243	0.3526	0.3526	1.0091	1.9865
		0.9413	1.6777	1.3095	0.1355	0.3682	0.3682	0.7993	1.8198
3030.inp	35001( 2)	-1.1997	-0.4806	-0.8401	0.1293	0.3595	0.3595	-1.3384	-0.3418
		2.7883	3.4680	3.1282	0.1155	0.3399	0.3399	2.6571	3.5992
		2.8569	3.3933	3.1251	0.0719	0.2682	0.2682	2.7534	3.4968

Na podlagi rezultatov iz preglednice 5 lahko zaključimo, da se je najbolje naučila tista umetna nevronska mreža, ki je imela geometrijo 3-10-10-3, ko je bilo v datoteki z učnimi podatki 18 vhodno-izhodni parov.





Slika 18: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mreže za točko 602 pri treh vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in treh izhodnih (hitrosti po osi  $v_H$ , ravnini  $v_{XY}$  in prostoru  $v_{XYH}$ ) podatkih.

Iz slike 18 vidimo kar veliko uspešnost učenja in nato napovedovanja premikanja plazu z nevronskimi umetnimi mrežami.

Grafični prikazi in numerični izračuni za točke 603 in 604 so prikazane v prilogah.

### 6.5.3 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 3 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. Odločili smo se uporabiti geometrijo mreže z tremi podatki v vhodnem sloju in sicer padavine za 90, 10 in 5 dni nazaj od dneva meritev. V izhodnem sloju pa iz podatkov o meritvah premikov izračunati 4 različne podatke. Ti so bili hitrost premika po osi  $X$  ( $v_X$ ), hitrost premika po osi  $Y$  ( $v_Y$ ), hitrost premika po osi  $H$  ( $v_H$ ) in hitrost premika po prostoru ( $v_{XYH}$ ).

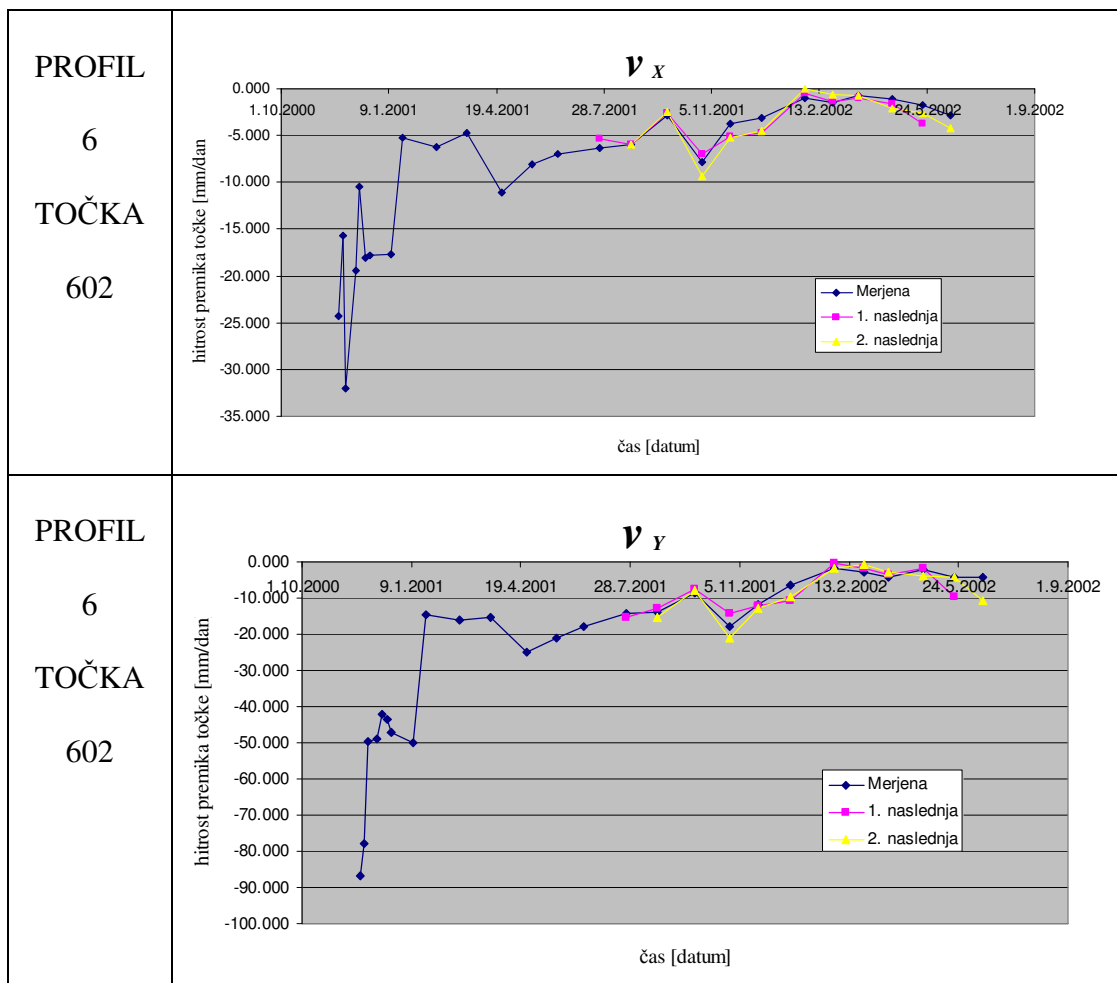


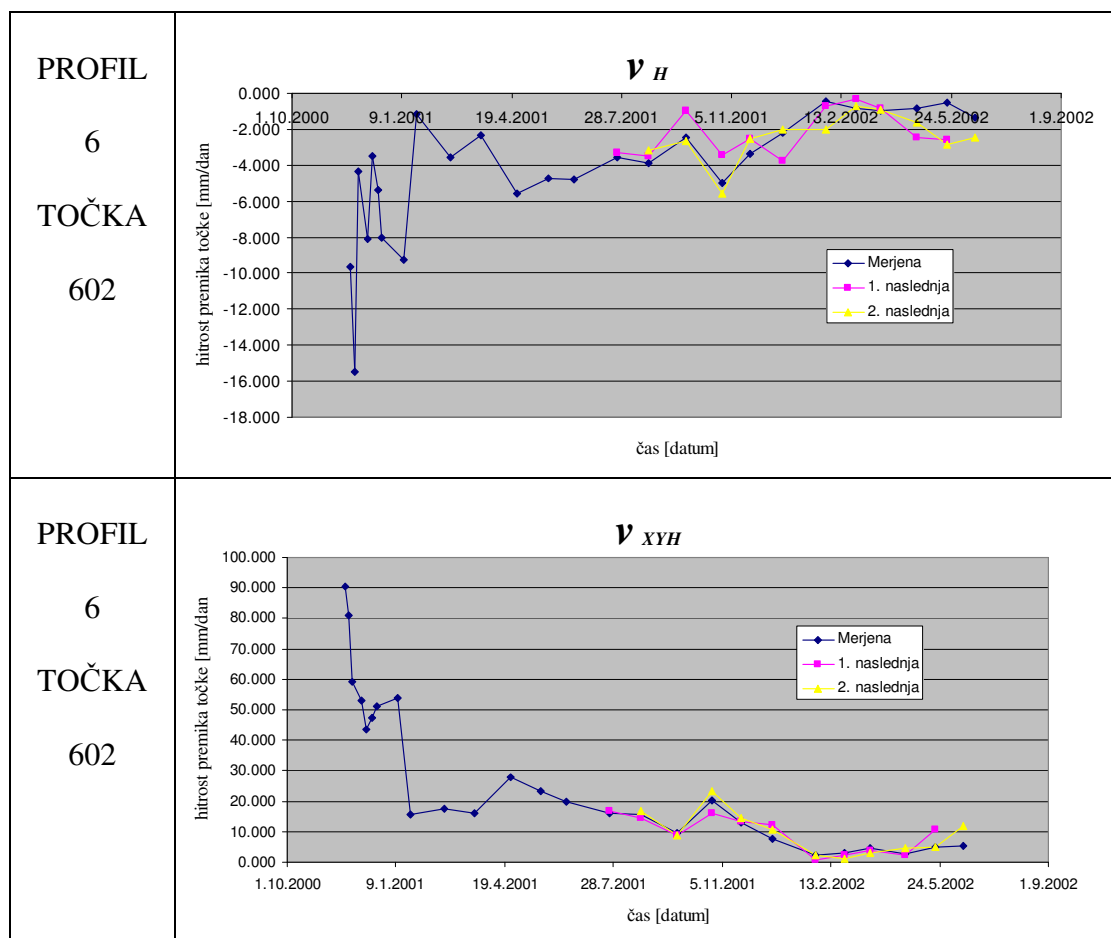
Preglednica 7: Rezultati testiranja naučene umetne nevronske mreže za primer točke 602 pri treh vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in štirih izhodnih podatkih (hitrosti po oseh  $v_x$ ,  $v_y$ ,  $v_H$  in hitrost premika po prostoru  $v_{xyH}$ . Imeli smo 22 učnih in 2 testna vhodno-izhodna para. Razporeditev stolpcev je enaka kot pri razpredelnici 3.

1	2	3	4	5	6	7	8	9	10
5.inp	35001(19)	0.9302	2.9791	1.9546	1.0494	1.0244	1.0244	0.5349	3.3744
		-0.9110	0.0772	-0.4169	0.2442	0.4941	0.4941	-1.1017	0.2680
		-1.1725	-1.0289	-1.1007	0.0052	0.0718	0.0718	-1.2002	-1.0012
		-2.8833	-0.5558	-1.7196	1.3543	1.1637	1.1637	-3.3324	-0.1067
10.inp	35001(10)	1.6374	4.3039	2.9707	1.7775	1.3332	1.3332	1.1229	4.8184
		-2.1151	0.1069	-1.0041	1.2343	1.1110	1.1110	-2.5438	0.5357
		-0.9575	0.5392	-0.2092	0.5600	0.7483	0.7483	-1.2463	0.8280
		-3.5853	-1.6593	-2.6223	0.9274	0.9630	0.9630	-3.9570	-1.2876
15.inp	35001(8)	4.5173	4.5696	4.5435	0.0007	0.0262	0.0262	4.5072	4.5797
		-1.5440	2.3208	0.3884	3.7341	1.9324	1.9324	-2.2897	3.0666
		-0.7486	0.6647	-0.0420	0.4994	0.7066	0.7066	-1.0214	0.9374
		-5.0665	-3.8870	-4.4767	0.3478	0.5898	0.5898	-5.2941	-3.6593
20.inp	35001(5)	2.3169	5.0796	3.6982	1.9082	1.3814	1.3814	1.7838	5.6127
		-1.6263	2.5565	0.4651	4.3739	2.0914	2.0914	-2.4334	3.3636
		-0.3852	-0.1687	-0.2769	0.0117	0.1082	0.1082	-0.4269	-0.1269
		-5.6566	-1.6990	-3.6778	3.9155	1.9788	1.9788	-6.4202	-0.9354
30.inp	35001(4)	-1.6537	6.5435	2.4449	16.7984	4.0986	4.0986	-3.2355	8.1252
		-1.6357	2.2357	0.3000	3.7469	1.9357	1.9357	-2.3827	2.9827
		-0.4436	0.1751	-0.1342	0.0957	0.3094	0.3094	-0.5630	0.2945
		-6.8610	2.1690	-2.3460	20.3851	4.5150	4.5150	-8.6034	3.9115
1010.inp	9029(0)	-4.8156	2.6611	-1.0773	13.9751	3.7383	3.7383	-6.2583	4.1038
		-0.5715	0.0163	-0.2776	0.0864	0.2939	0.2939	-0.6849	0.1297
		-0.1935	0.6440	0.2252	0.1753	0.4187	0.4187	-0.3551	0.8056
		-2.5273	4.9388	1.2058	13.9358	3.7331	3.7331	-3.9680	6.3795
1515.inp	5804(0)	0.0986	1.1301	0.6144	0.2660	0.5158	0.5158	-0.1005	1.3292
		-1.2804	-0.2821	-0.7812	0.2491	0.4991	0.4991	-1.4730	-0.0895
		-0.1990	-0.1309	-0.1649	0.0012	0.0341	0.0341	-0.2122	-0.1177
		-0.6887	0.0478	-0.3205	0.1356	0.3682	0.3682	-0.8309	0.1899
2020.inp	24067(0)	2.7280	5.8702	4.2991	2.4684	1.5711	1.5711	2.1216	6.4766
		-1.6857	1.0369	-0.3244	1.8531	1.3613	1.3613	-2.2111	1.5623
		-0.4943	0.9643	0.2350	0.5319	0.7293	0.7293	-0.7757	1.2458
		-4.9220	-2.0142	-3.4681	2.1138	1.4539	1.4539	-5.4831	-1.4532
2025.inp	18771(0)	-1.6879	0.7180	-0.4850	1.4471	1.2029	1.2029	-2.1521	1.1822
		-0.9251	-0.2319	-0.5785	0.1201	0.3466	0.3466	-1.0589	-0.0982
		-0.8205	0.1345	-0.3430	0.2280	0.4775	0.4775	-1.0047	0.3187
		-0.5923	1.9444	0.6761	1.6087	1.2684	1.2684	-1.0818	2.4339
2520.inp	8326(0)	-3.1604	2.3932	-0.3836	7.7107	2.7768	2.7768	-4.2320	3.4649
		-0.6625	-0.5303	-0.5964	0.0044	0.0661	0.0661	-0.6880	-0.5048
		-0.6812	-0.2399	-0.4605	0.0487	0.2207	0.2207	-0.7664	-0.1547
		-2.2916	3.3373	0.5229	7.9213	2.8145	2.8145	-3.3778	4.4235

2525.inp	23980(0)	-2.2420	9.1152	3.4366	32.2464	5.6786	5.6786	-4.4335	11.3067
		-2.2451	0.4296	-0.9077	1.7886	1.3374	1.3374	-2.7613	0.9458
		-1.3493	1.3706	0.0107	1.8494	1.3599	1.3599	-1.8741	1.8954
		-9.1575	3.7499	-2.7038	41.6504	6.4537	6.4537	-11.6482	6.2406
3030.inp	6890(0)	-3.3426	-1.2206	-2.2816	1.1257	1.0610	1.0610	-3.7521	-0.8112
		-1.2503	-0.6563	-0.9533	0.0882	0.2970	0.2970	-1.3649	-0.5417
		-1.0626	0.0600	-0.5013	0.3150	0.5613	0.5613	-1.2792	0.2766
		1.4920	3.6688	2.5804	1.1846	1.0884	1.0884	1.0720	4.0888

V primeru, ko smo imeli 22 vhodno-izhodnih parov, se je najbolje naučila umetna nevronska mreža z geometrijo 3-20-25-4, kar je razvidno iz preglednice 7.





Slika 19: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in štirih izhodnih (hitrosti po oseh  $v_X$ ,  $v_Y$ ,  $v_H$  in prostoru -  $v_{XYH}$ ) podatkih.

Iz rezultatov je razvidno, da so podatki še boljši, kot pri treh izhodnih podatkih, kar je potrdilo našo tezo. Razvidno je tudi, da se je umetna nevronska mreža najslabše naučila pri napovedovanju hitrosti premikov pri premikih v smeri osi  $H$ .

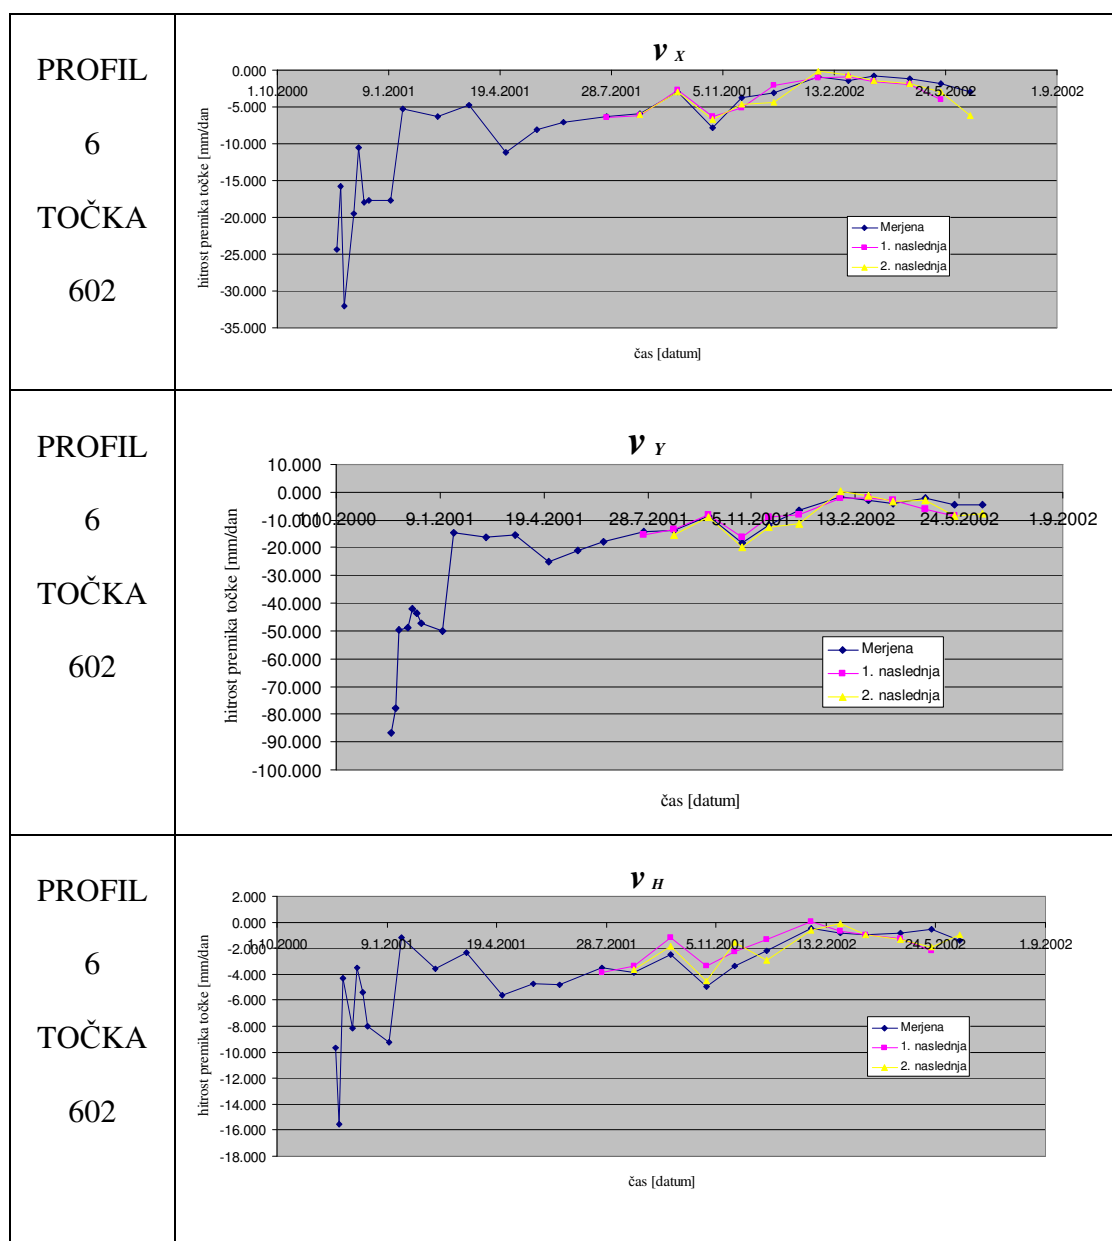
#### 6.5.4 Učenje umetne nevronske mreže s tremi nevroni v vhodnem in petimi v izhodnem sloju

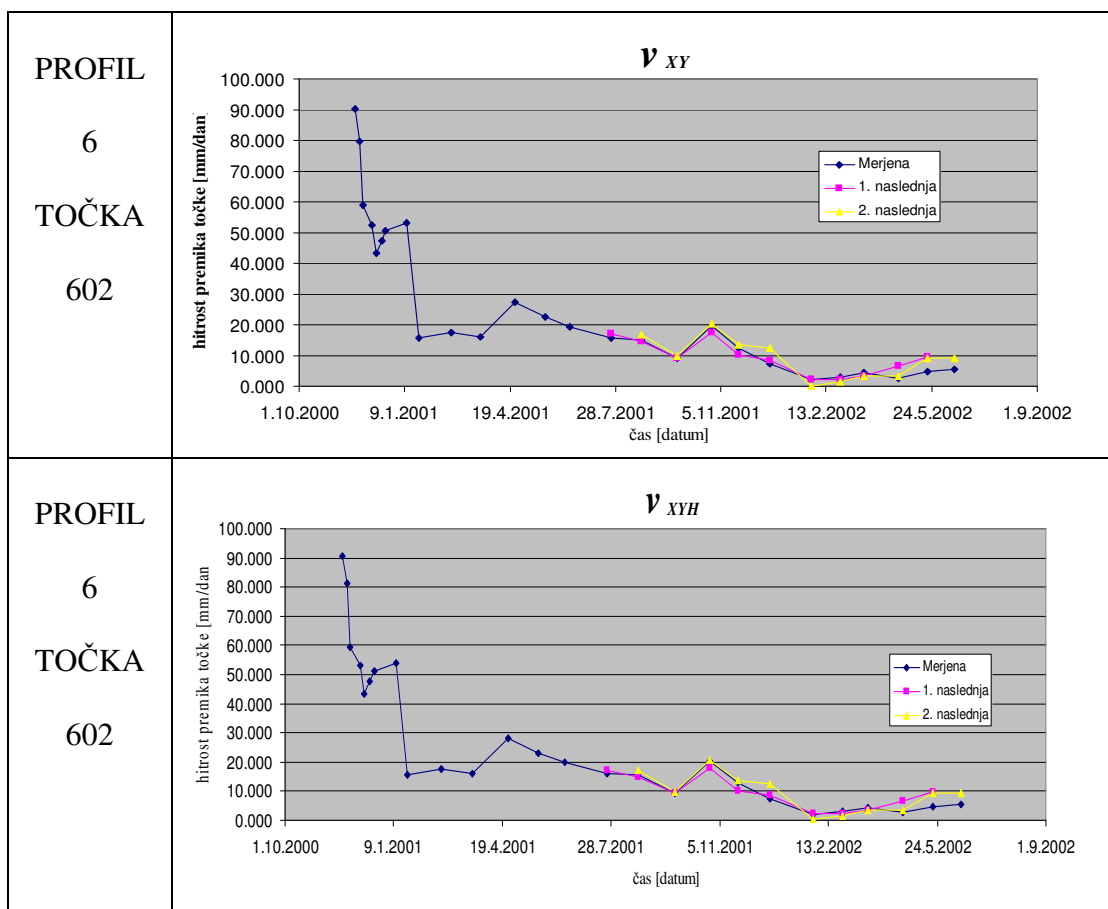
Zaradi vse boljših rezultatov učenja umetne nevronske mreže z večanjem podatkov na izhodnem sloju smo se odločili, da geometrijo umetne nevronske mreže povečamo še za en podatek. V izhodnem sloju smo podali še podatek za hitrosti premika v ravnini -  $v_{XY}$ .

Preglednica 8: Rezultati testiranja naučene umetne nevronske mreže za primer točke 602 pri treh vhodnih podatkih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih (hitrosti po oseh  $v_x$ ,  $v_y$ ,  $v_H$ , hitrost premika po ravnini  $v_{xy}$  in hitrost premika po prostoru  $v_{xyH}$ . Imeli smo 24 učnih in 2 testna vhodno-izhodna para. Najugodnejša geometrija umetne nevronske mreže je 3-25-25-5. Razporeditev stolpcev je enaka kot pri preglednici 3.

1	2	3	4	5	6	7	8	9	10
5.inp	35001(18)	-13.9415	-9.6378	-11.7896	4.6306	2.1519	2.1519	-14.7720	-8.8073
		-3.7064	-2.7077	-3.2070	0.2493	0.4993	0.4993	-3.8991	-2.5150
		-3.0788	-0.3495	-1.7142	1.8624	1.3647	1.3647	-3.6055	0.1772
		10.0377	13.8757	11.9567	3.6825	1.9190	1.9190	9.2971	14.6163
		10.4883	13.8659	12.1771	2.8520	1.6888	1.6888	9.8366	14.5177
10.inp	35001(12)	-8.7207	-2.3404	-5.5305	10.1770	3.1901	3.1901	-9.9518	-1.1092
		-2.9876	-0.6005	-1.7941	1.4246	1.1936	1.1936	-3.4482	-0.1399
		-2.5910	0.8133	-0.8889	2.8973	1.7022	1.7022	-3.2479	1.4702
		2.3566	9.2820	5.8193	11.9902	3.4627	3.4627	1.0203	10.6183
		2.2154	9.6119	5.9136	13.6769	3.6982	3.6982	0.7881	11.0391
15.inp	35001(17)	-6.8539	-6.0881	-6.4710	0.1466	0.3829	0.3829	-7.0017	-5.9403
		-4.8959	-3.5279	-4.2119	0.4679	0.6840	0.6840	-5.1599	-3.2639
		-2.0018	-0.4547	-1.2282	0.5984	0.7736	0.7736	-2.3003	-0.1561
		7.3228	7.4605	7.3916	0.0047	0.0689	0.0689	7.2962	7.4871
		7.4794	7.5838	7.5316	0.0027	0.0522	0.0522	7.4593	7.6040
20.inp	35001(18)	-11.1907	-7.5091	-9.3499	3.3885	1.8408	1.8408	-11.9011	-6.7987
		-5.2614	-3.2036	-4.2325	1.0586	1.0289	1.0289	-5.6585	-2.8065
		-2.1760	-1.3649	-1.7704	0.1645	0.4055	0.4055	-2.3325	-1.2084
		8.8968	11.6608	10.2788	1.9100	1.3820	1.3820	8.3634	12.1942
		9.1849	11.8247	10.5048	1.7423	1.3199	1.3199	8.6755	12.3342
30.inp	35001(3)	-2.7718	5.0017	1.1149	15.1068	3.8867	3.8867	-4.2718	6.5017
		-2.2398	-0.3707	-1.3053	0.8735	0.9346	0.9346	-2.6005	-0.0100
		-1.2666	1.6907	0.2120	2.1864	1.4787	1.4787	-1.8373	2.2613
		-5.0288	3.3152	-0.8568	17.4055	4.1720	4.1720	-6.6389	4.9252
		-5.2640	3.4282	-0.9179	18.8885	4.3461	4.3461	-6.9413	5.1055
1010.inp	6683(0)	-15.2043	-7.5612	-11.3827	14.6041	3.8215	3.8215	-16.6791	-6.0864
		-3.7184	-1.5878	-2.6531	1.1349	1.0653	1.0653	-4.1296	-1.1767
		-2.9441	-2.1364	-2.5402	0.1631	0.4038	0.4038	-3.0999	-1.9806
		8.3029	14.6908	11.4969	10.2012	3.1939	3.1939	7.0703	15.9234
		8.6682	14.9560	11.8121	9.8840	3.1439	3.1439	7.4549	16.1693
1515.inp	4728(0)	-10.6669	-4.0632	-7.3650	10.9019	3.3018	3.3018	-11.9411	-2.7890
		-2.5594	-0.6610	-1.6102	0.9010	0.9492	0.9492	-2.9258	-0.2947
		-2.3601	-1.2674	-1.8137	0.2985	0.5463	0.5463	-2.5709	-1.0566
		4.6139	10.2155	7.4147	7.8445	2.8008	2.8008	3.5330	11.2964
		4.9187	10.3844	7.6515	7.4683	2.7328	2.7328	3.8640	11.4390
2020.inp	35001(21)	-5.2142	-5.1353	-5.1748	0.0016	0.0394	0.0394	-5.2294	-5.1201
		-1.6613	-0.4945	-1.0779	0.3404	0.5834	0.5834	-1.8865	-0.2694
		-1.9559	-1.1328	-1.5443	0.1694	0.4115	0.4115	-2.1147	-0.9740
		4.9176	5.3829	5.1503	0.0541	0.2327	0.2327	4.8278	5.4727
		5.0411	5.6539	5.3475	0.0939	0.3064	0.3064	4.9229	5.7722
2025.inp	9772(0)	-6.3464	-2.8778	-4.6121	3.0078	1.7343	1.7343	-7.0157	-2.2085
		-3.0641	0.3365	-1.3638	2.8910	1.7003	1.7003	-3.7203	0.9927
		-2.5773	-1.4431	-2.0102	0.3216	0.5671	0.5671	-2.7962	-1.2242
		2.3064	6.7977	4.5520	5.0430	2.2457	2.2457	1.4397	7.6644
		2.4008	7.0912	4.7460	5.5001	2.3452	2.3452	1.4957	7.9963
2520.inp	5430(0)	-9.5581	-4.4031	-6.9806	6.6434	2.5775	2.5775	-10.5528	-3.4084


		-1.4382	0.8026	-0.3178	1.2553	1.1204	1.1204	-1.8706	1.2350
		-2.1233	-1.6471	-1.8852	0.0567	0.2381	0.2381	-2.2151	-1.5553
		4.5038	8.6017	6.5527	4.1981	2.0489	2.0489	3.7131	9.3924
		4.7306	8.8219	6.7762	4.1846	2.0456	2.0456	3.9411	9.6113
2525.inp	22056(0)	-4.0822	-3.2867	-3.6845	0.1582	0.3978	0.3978	-4.2358	-3.1332
		-3.2849	-2.2240	-2.7545	0.2814	0.5305	0.5305	-3.4896	-2.0193
		-1.6291	0.3833	-0.6229	1.0124	1.0062	1.0062	-2.0174	0.7716
		3.9228	4.6077	4.2653	0.1173	0.3425	0.3425	3.7906	4.7399
		3.8073	4.8627	4.3350	0.2785	0.5277	0.5277	3.6037	5.0664
3030.inp	14951(0)	-11.1496	-5.6292	-8.3894	7.6187	2.7602	2.7602	-12.2149	-4.5640
		-11.4413	-3.3228	-7.3820	16.4773	4.0592	4.0592	-13.0078	-1.7562
		-2.8880	-0.8582	-1.8731	1.0301	1.0149	1.0149	-3.2797	-0.4665
		6.3998	13.6085	10.0041	12.9911	3.6043	3.6043	5.0088	14.9995
		6.6427	13.7423	10.1925	12.6011	3.5498	3.5498	5.2727	15.1123






Slika 20: Grafični prikaz napovedovanja hitrosti premikanja z naučeno umetno nevronske mrežo za točko 602 pri treh vhodnih (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih (hitrosti po oseh  $v_X$ ,  $v_Y$ ,  $v_H$ , ravnini -  $v_{XY}$  in prostoru -  $v_{XYH}$ ) podatkih.

Ker so rezultati učenja umetnih nevronskih mrež in napovedovanja premikov odlični, smo dobljene rezultate še nadalje obdelali. Iz napovedanih hitrosti, ki smo jih izračunali z naučeno umetno nevronske mrežo, smo nazaj izračunali premike in jih primerjali s premiki merjenimi na Macesnikovem plazu. Razlike med izmerjenimi in izračunani premik z umetnimi nevronskimi mrežami so prikazani v spodnjih grafih.

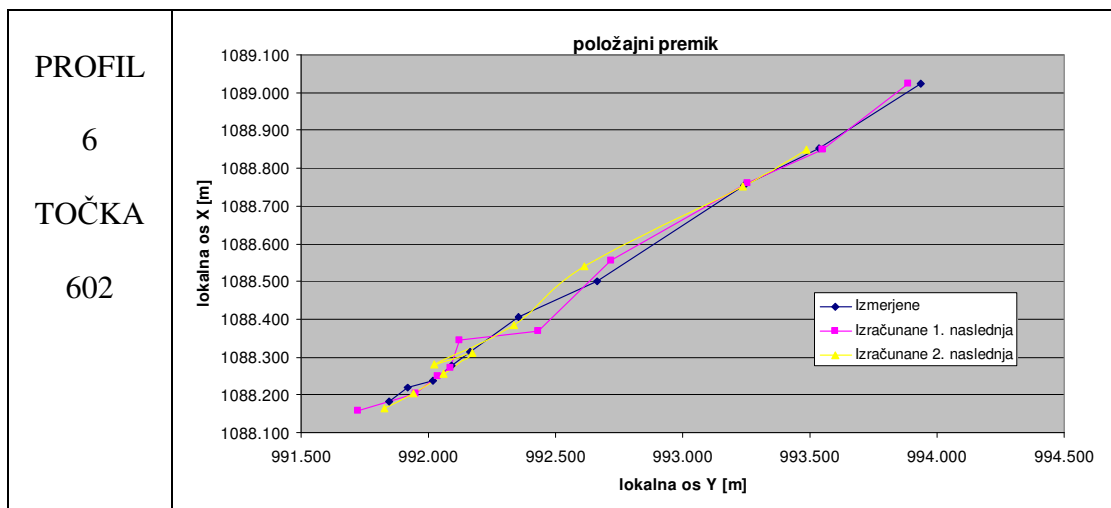


Slika 21: Grafični prikaz relativne razlike med izračunanimi (napovedovanje 1. naslednje meritve) in izmerjenimi premiki na Macesnikovem plazu. Gre za profil 6, točko 602.

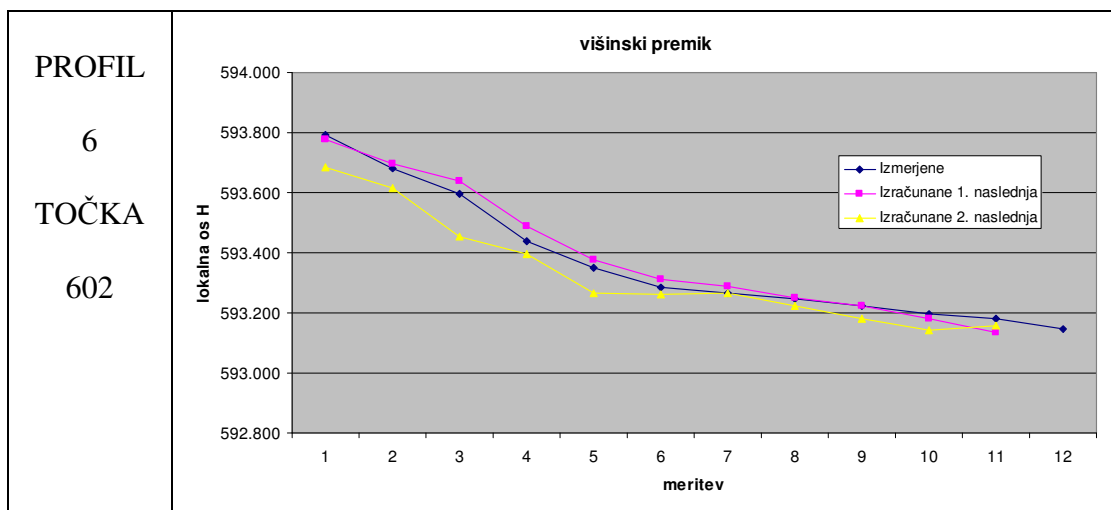


Slika 22 : Grafični prikaz relativne razlike med izračunanimi (napovedovanje 2. naslednje meritve) in izmerjenimi premiki na Macesnikovem plazu. Gre za profil 6, točko 602.

V nadaljevanju smo iz napovedanih hitrosti, ki smo jih izračunali z naučeno umetno nevronske mrežo, nazaj izračunali lokalne koordinate in jih primerjali z lokalnimi koordinatami merjenimi na Macesnikovem plazu. Razlike med izmerjenimi in izračunani lokalnimi koordinatami z umetnimi nevronskimi mrežami so prikazani na slikah 23 in 24.



Slika 23 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 602.



Slika 24: 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. Premike smo napovedovali za 1. in 2. naslednjo napoved po učnih vhodno-izhodnih parih. Primerjava je narejena za profil 6 in točko 602.



Iz zgornjih grafičnih prikazov je razvidno, da bi se merjenim vrednostim z naučeno nevronske mrežo najbolj približali, če bi vzeli sredino med 1. in 2. naslednjo napoved po učnih vhodno-izhodnih parih. Najbrž gre samo za slučajnost, saj iz zgoraj prikazanih grafikonov je razvidno, da so napovedovanja za prvo naslednjo meritev natančnejša, kot za drugo naslednjo meritev po učnih vhodno-izhodnih parih. Mislimo, da je dobljena natančnost že sprejemljiva za uporabnike v praksi.

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

V nadaljevanju poizkušanja različnih geometrij in kombinacij vhodno-izhodnih parov, da bi kar najbolj naučili umetno nevronske mrežo, smo se lotili učenja z Gauß – Krügerjevimi koordinatami. Mišljenja smo bili, da 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.

Najprej je bilo potrebno vse lokalne točke na profilih transformirati v Gauß – Krügerjev koordinatni sistem. Uporabili smo transformacijo, saj smo imeli Gauß – Krügerjeve koordinate zunanjih točk posameznih profilov, katere so bile tudi izhodišče meritev na profilih.

Umetno nevronske mrežo smo učili na 4 podatkih v vhodnem sloju in sicer prvi podatek je bil časovni interval v dnevih od ničelne meritve, ostali trije pa so bili podatki o padavinah, in sicer za 90, 10 in 5 dni nazaj od dneva meritve.

Za podatke v izhodnem sloju smo uporabili Gauß – Krügerjeve koordinate  $Y$ ,  $X$ ,  $H$ , 2D premik v ravnini  $YX$  in 3D premik v prostoru  $XYH$ .

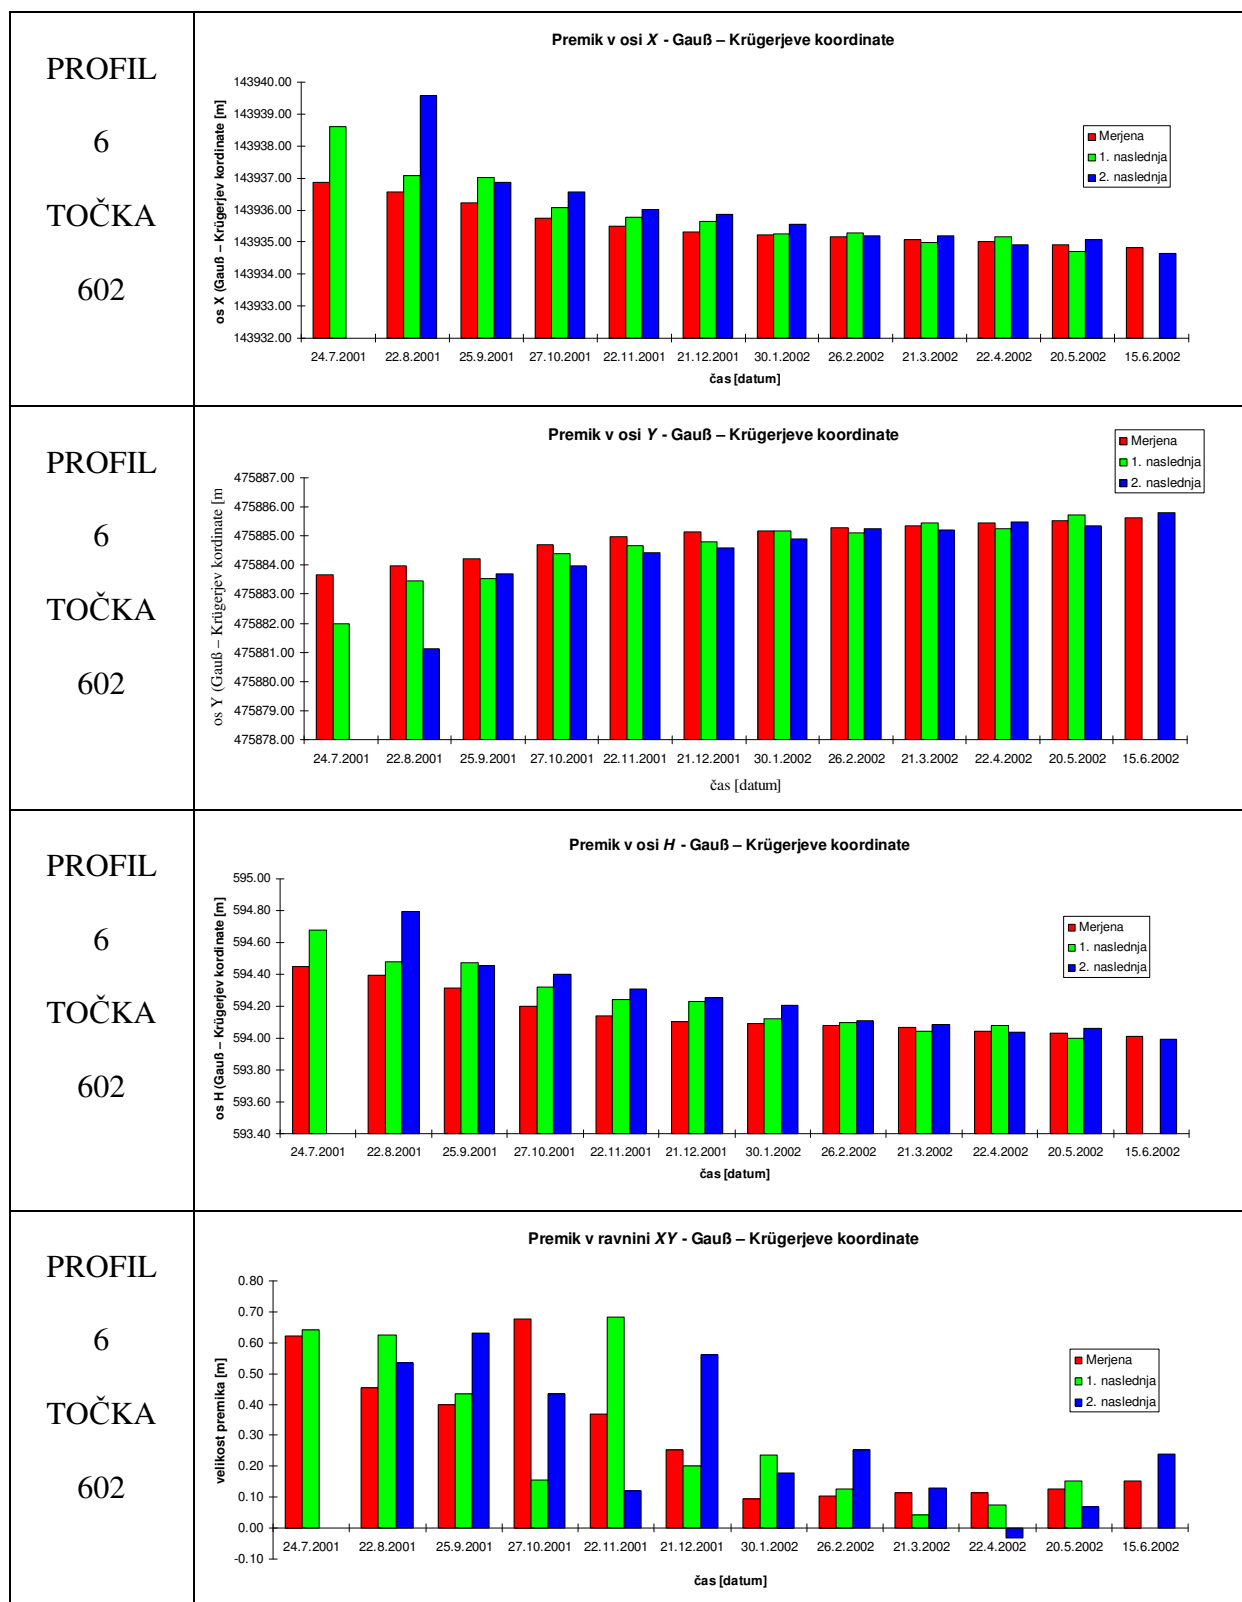
$\beta$	905.1	195.7	68.0	475879.31	143941.38	594.98	0.25	0.25
7	927.4	128.1	26.6	475879.49	143941.14	594.95	0.30	0.30
10	912.2	77.5	9.4	475879.63	143941.03	594.94	0.18	0.18
19	862.4	0.0	0.0	475879.96	143940.74	594.91	0.44	0.45
23	868.6	6.2	6.2	475880.06	143940.62	594.90	0.16	0.16
28	878.2	42.7	36.5	475880.23	143940.46	594.89	0.23	0.23
32	859.5	37.1	0.6	475880.36	143940.33	594.88	0.18	0.18
52	720.4	67.0	63.5	475881.07	143939.60	594.80	1.02	1.02
63	706.5	1.4	1.4	475881.18	143939.46	594.80	0.18	0.18
94	273.1	0.0	0.0	475881.55	143939.11	594.74	0.52	0.52
122	346.3	59.1	8.3	475881.84	143938.79	594.72	0.43	0.43
155	394.0	53.0	44.2	475882.50	143938.14	594.63	0.93	0.93
183	409.8	14.4	14.4	475882.92	143937.68	594.57	0.62	0.62
207	422.5	76.6	53.6	475883.24	143937.33	594.52	0.48	0.48
246	345.2	50.1	31.9	475883.67	143936.87	594.45	0.62	0.63
275	293.9	0.9	0.9	475883.98	143936.55	594.40	0.45	0.46
309	368.4	91.4	44.3	475884.21	143936.22	594.31	0.40	0.41
341	382.9	12.2	1.5	475884.70	143935.75	594.20	0.68	0.69
367	401.9	4.6	0.0	475884.96	143935.49	594.14	0.37	0.38


Slika 25: Prikaz učne datoteke z 19-imi učnimi pari (prvih 19 meritev) za učenje umetne nevronske mreže v profilu 6 v točki 603. Za vhodne podatke imamo časovne intervale v dnevih od (prve) ničelne meritve in padavine za 90, 10 in 5 dni nazaj. Za izhodne pa Gauß – Krügerjeve koordinate  $Y$ ,  $X$ ,  $H$ , 2D premik v ravnini  $XY$  in 3D premik v prostoru  $XYH$ .

Preglednica 9: Rezultati testiranja naučene umetne nevronske mreže za primer točke 603 pri štirih vhodnih podatkih (časovni interval v dnevih od (prve) ničelne meritve in padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih (Gauß – Krügerjeve koordinate  $Y$ ,  $X$ ,  $H$ , 2D premik v ravnini  $XY$  in 3D premik v prostoru  $XYH$ ) in pri 19 učnih vhodno-izhodnih parih in 2 testnih. Razporeditev stolpcev je enaka kot pri preglednici 3.

1	2	3	4	5	6	7	8	9	10
5.inp	35001(12)	-1.5660	-0.7248	-1.1454	0.1769	0.4206	0.4206	-1.7283	-0.5625
		0.7263	1.6525	1.1894	0.2145	0.4631	0.4631	0.5476	1.8313
		0.1651	0.3037	0.2344	0.0048	0.0693	0.0693	0.1384	0.3305
		0.2216	0.3925	0.3070	0.0073	0.0854	0.0854	0.1886	0.4254
		0.2205	0.3875	0.3040	0.0070	0.0835	0.0835	0.1882	0.4197
10.inp	13188(0)	-1.4845	-0.8296	-1.1571	0.1072	0.3275	0.3275	-1.6109	-0.7032
		0.8385	1.5790	1.2087	0.1371	0.3702	0.3702	0.6956	1.7218
		0.1927	0.3238	0.2583	0.0043	0.0656	0.0656	0.1674	0.3491
		0.2870	0.3014	0.2942	0.0001	0.0072	0.0072	0.2842	0.3042

		0.2778	0.2979	0.2879	0.0001	0.0101	0.0101	0.2739	0.3018
15.inp	12304(0)	-0.9962	-0.9065	-0.9514	0.0020	0.0449	0.0449	-1.0135	-0.8892
		0.9177	1.0440	0.9809	0.0040	0.0631	0.0631	0.8934	1.0684
		0.2589	0.2788	0.2689	0.0001	0.0099	0.0099	0.2551	0.2826
		-0.0010	0.1550	0.0770	0.0061	0.0780	0.0780	-0.0312	0.1851
		-0.0017	0.1558	0.0771	0.0062	0.0787	0.0787	-0.0321	0.1862
20.inp	11551(0)	-0.3429	-0.1989	-0.2709	0.0052	0.0720	0.0720	-0.3707	-0.1711
		0.2116	0.3246	0.2681	0.0032	0.0565	0.0565	0.1897	0.3464
		0.0780	0.1083	0.0932	0.0002	0.0151	0.0151	0.0722	0.1142
		0.0181	0.1170	0.0676	0.0024	0.0495	0.0495	-0.0010	0.1361
		0.0196	0.1180	0.0688	0.0024	0.0492	0.0492	0.0006	0.1370
30.inp	13855(0)	-0.5814	-0.4878	-0.5346	0.0022	0.0468	0.0468	-0.5994	-0.4698
		0.4697	0.5838	0.5268	0.0033	0.0570	0.0570	0.4477	0.6058
		0.1490	0.1495	0.1493	0.0000	0.0003	0.0003	0.1489	0.1496
		-0.0943	-0.0020	-0.0482	0.0021	0.0461	0.0461	-0.1121	0.0158
		-0.0991	-0.0109	-0.0550	0.0019	0.0441	0.0441	-0.1161	0.0061
1010.inp	20403(0)	-3.0993	-0.7929	-1.9461	1.3299	1.1532	1.1532	-3.5443	-0.3478
		0.8186	3.3416	2.0801	1.5913	1.2615	1.2615	0.3318	3.8284
		0.2150	0.6100	0.4125	0.0390	0.1975	0.1975	0.1388	0.6863
		0.0276	0.1957	0.1116	0.0071	0.0841	0.0841	-0.0048	0.2281
		0.0243	0.1874	0.1059	0.0066	0.0815	0.0815	-0.0071	0.2188
1515.inp	8029(0)	-2.1329	-0.9293	-1.5311	0.3622	0.6018	0.6018	-2.3651	-0.6970
		0.9790	2.3304	1.6547	0.4565	0.6757	0.6757	0.7182	2.5911
		0.2179	0.4001	0.3090	0.0083	0.0911	0.0911	0.1828	0.4353
		0.4240	0.7476	0.5858	0.0262	0.1618	0.1618	0.3616	0.8101
		0.4261	0.7439	0.5850	0.0252	0.1589	0.1589	0.3648	0.8052
2020.inp	4353(0)	-5.8691	-3.2318	-4.5505	1.7389	1.3187	1.3187	-6.3780	-2.7229
		3.4451	6.2017	4.8234	1.8997	1.3783	1.3783	2.9132	6.7337
		0.6217	0.9321	0.7769	0.0241	0.1552	0.1552	0.5619	0.9919
		0.1411	0.5915	0.3663	0.0507	0.2252	0.2252	0.0542	0.6785
		0.1325	0.5725	0.3525	0.0484	0.2200	0.2200	0.0476	0.6574
2025.inp	6270(0)	-1.5702	-0.9689	-1.2695	0.0904	0.3007	0.3007	-1.6862	-0.8528
		1.0121	1.7096	1.3608	0.1216	0.3487	0.3487	0.8775	1.8442
		0.2153	0.3276	0.2715	0.0032	0.0561	0.0561	0.1937	0.3493
		-0.0544	0.0556	0.0006	0.0030	0.0550	0.0550	-0.0756	0.0768
		-0.0587	0.0489	-0.0049	0.0029	0.0538	0.0538	-0.0794	0.0697
2520.inp	7991(0)	-4.8984	-3.5263	-4.2124	0.4707	0.6861	0.6861	-5.1632	-3.2616
		3.7638	5.2632	4.5135	0.5620	0.7497	0.7497	3.4744	5.5525
		0.6647	0.8129	0.7388	0.0055	0.0741	0.0741	0.6361	0.8414
		0.0559	0.1916	0.1237	0.0046	0.0679	0.0679	0.0297	0.2178
		0.0498	0.1784	0.1141	0.0041	0.0643	0.0643	0.0250	0.2032
2525.inp	4265(0)	-0.3371	-0.2745	-0.3058	0.0010	0.0313	0.0313	-0.3492	-0.2624
		0.3120	0.3353	0.3237	0.0001	0.0116	0.0116	0.3076	0.3397
		0.1175	0.1281	0.1228	0.0000	0.0053	0.0053	0.1154	0.1301
		-0.0499	0.0899	0.0200	0.0049	0.0699	0.0699	-0.0769	0.1169
		-0.0577	0.0821	0.0122	0.0049	0.0699	0.0699	-0.0847	0.1091
3030.inp	3793(0)	-2.6560	-0.6401	-1.6481	1.0159	1.0079	1.0079	-3.0450	-0.2512
		0.6382	2.8228	1.7305	1.1932	1.0923	1.0923	0.2166	3.2444
		0.1619	0.5275	0.3447	0.0334	0.1828	0.1828	0.0914	0.5980
		0.0056	0.0920	0.0488	0.0019	0.0432	0.0432	-0.0110	0.1087
		0.0016	0.0830	0.0423	0.0017	0.0407	0.0407	-0.0141	0.0987





Slika 26: Grafični prikaz napovedovanja premikanja z naučeno umetno nevronske mreže za točko 602 pri štirih vhodnih podatkih (časovni interval v dnevih od (prve) ničelne meritve in padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih (Gauß – Krügerjeve koordinate  $Y, X, H$ , 2D premik v ravnini  $XY$  in 3D premik v prostoru  $XYZ$ )

Iz rezultatov učenja umetne nevronske mreže na štirih vhodnih (časovni interval v dnevih od (prve) ničelne meritve in padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petih izhodnih podatkih (Gauß – Krügerjeve koordinate  $Y, X, H$ , 2D premik v ravnini  $XY$  in 3D premik v prostoru  $XYH$ ) in iz slike 26 lahko rečemo, da

- je bilo učenje umetnih nevronske mreže uspešno,
- je napovedovanje uspešnejše za bližnje obdobje (1. naslednja) kot za bolj oddaljeno obdobje (2. naslednja), kar je pričakovano,
- je napovedovanje z naučeno umetno nevronske mreže na manjšem številu učnih vhodno-izhodnih parov težavnejše oziroma manj zanesljivo, kot če učimo umetno nevronske mreže na večjem številu učnih vhodno-izhodnih parov, kar je logično,
- ne znamo pojasniti nepričakovanega odmika napovedi 3D premika po 23 meritvah premikov,
- bi rezultate lahko uporabili v praksi.

Umetno nevronske mreže smo učili tudi na točkah iz profilov 1, 2, 3, 4, 5, 7, 8. Dobili smo podobne rezultate.

Na koncu smo umetno nevronske mreže učili na celotnem plazu skupaj (možno le, če so vse točke v vseh profilih transformirane v Gauß – Krügerjevo projekcijo) in dobili nekoliko slabši rezultat, kot v primerih, kjer smo mreže učili na vsakem profilu posebej, vendar še vedno zadovoljivo za grobo napovedovanje plazenja celotnega plazu.

## 7 ZAKLJUČEK

Napovedovanje plazenja zemljin je težavno, saj je težko določiti vse parametre, ki vplivajo na plazenje, še težje je pa določiti pravilen odnos med njimi. Merjenje premikov na površini, v notranjosti zemljine, nivoja vode in sestavo zemljine, je zelo zahtevno, dolgotrajno in drago, pri samem napovedovanju plazenja pa ni nujno potrebno, saj nam ti parametri ne daje dovolj podatkov za dovolj natančno napovedovanje plazenja.

Ključno vlogo pri sprožanju in premikih plazov imajo padavine. Zato smo jih poleg meritev premikov na površju plazu uporabili pri učenju umetne nevronske mreže. 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 mrežo 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 mrežo 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 n. pr. 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 večslojno usmerjeno umetno nevronske mrežo. Zanimivo bi bilo poskusiti tudi z drugimi umetnimi nevronske mrežami in drugače urejenimi merskimi podatki, saj mislimo, da meritve v lokalnih profilih niso najboljši podatek za napovedovanje plazenja vsega plazu. Posebej bi bilo zanimivo napovedovanje plazu, če bi imeli več meritev s 3D laserskim skenerjem in bi za učne podatke uporabili gridno mrežo, ki bi se z vsako meritvijo spreminjala. Tako bi naenkrat zajeli celoten plaz, vse medsebojne odnose, ki se vzdolž plazu močno spreminjajo. Takšno napovedovanje z umetno nevronske mrežo bi se lahko vizualno lepo in praktično prikazalo.

Pred začetkom učenja smo določili uteži naključno z generatorjem slučajnih števil. Število uteži za primer geometrije z dvema skritima sloja je naslednje  $\mathbf{1} \times \mathbf{X} + \mathbf{X} \times \mathbf{Y} + \mathbf{Y} \times \mathbf{1}$ , če je v vhodnem in izhodnem sloju samo en nevron.

Umetne nevronske mreže smo učili po geometriji:

- z enim podatkom v vhodnem (časovnim intervalom od ničelne meritve) in enim v izhodnem sloju (premik točke po posamezni koordinatni osi)
- z dvema vhodnima nevronoma (časovni interval od ničelne meritve in količina mesečnih padavin ) in enim izhodnim nevronom (premik točke po posamezni koordinatni osi)
- s tremi vhodnimi nevroni (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in enim v izhodnem sloju (hitrost premika po prostoru -  $v_{XYH}$  )
- s tremi vhodnimi nevroni (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in tremi v izhodnimi nevroni (hitrosti premikov po oseh  $v_X$  ,  $v_Y$  in  $v_H$  ) in (hitrost premikov po osi -  $v_H$  , hitrost premika po ravnini  $XY$  -  $v_{XY}$  in hitrost premika po prostoru -  $v_{XYH}$  )
- s tremi nevroni v vhodnem sloju (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in štirimi v izhodnem sloju (hitrosti po oseh  $v_X$  ,  $v_Y$  ,  $v_H$  in prostoru -  $v_{XYH}$  ).
- s tremi nevroni v vhodnem sloju (padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petimi v izhodnem sloju (hitrosti po oseh  $v_X$  ,  $v_Y$  ,  $v_H$  , hitrost premika po ravnini  $XY$  -  $v_{XY}$  in hitrost premika po prostoru -  $v_{XYH}$  ).
- s štirimi nevroni v vhodnem sloju (časovnim intervalom od ničelne meritve , padavine za 90, 10 in 5 dni nazaj od dneva meritev) in petimi v izhodnem sloju (Gauß – Krügerjeve koordinate  $Y$ ,  $X$ ,  $H$ , 2D premik v ravnini  $YX$  in 3D premik v prostoru  $XYH$ ).

Za vse naše primere učenja umetnih nevronskih mrež na vhodno-izhodnih parih Macesnikovega plazu smo imeli dvanajstih različnih geometrij umetnih nevronskih mrež z različnim številom skritih slojev in različnim številom nevronov v posameznem skitem sloju:

- 5, 10, 15, 20 in 30 nevronov v enem skitem sloju in



- 10-10, 15-15, 20-20, 20-25, 25-20, 25-25, 30-30 nevronov v dveh skritih slojih.

V vseh primerih napovedovanja plazenja zemljin smo umetno nevronske mrežo 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 mrežo izračunano vrednostjo.

Med poskušanjem smo opazili, da se kvaliteta rezultatov izboljšuje. Najslabše rezultate smo dobili na začetku, ko smo imeli geometrijo umetne nevronske mreže z enim podatkom v vhodnem sloju (število dni od ničelne meritve) in enim v izhodnem (premik točke po posamezni koordinatni osi). Uspešnejše se je 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). Zmanjšalo se je tudi število iteracij potrebnih za konvergiranje mreže (na približno 5000).

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.

Boljše rezultate smo dobili tudi z geometrijami umetne nevronske mreže z dvema skritima slojema kot z enim skritim slojem in tudi večje kot je bilo število učnih vhodno-izhodnih parov. Zaradi tega smo mnenja, da se da rezultate še izboljšati:

- z dodajanjem vhodnih nevronov, pri tem mislimo še vedno samo na padavine v nekem obdobju iz preteklosti,
- s smiselnim povečanjem nevronov v izhodnem sloju in
- z izborom kakšne druge vrste umetne nevronske mreže (n. pr. Radialne bazične funkcije).

S testiranjem naučene umetne nevronske mreže smo videli, da je možno napovedovanje plazenja zemljin z umetnimi nevronske mrežami in da bi bile nadaljnje raziskave v tej smeri smiselne, saj smo že mi dobili zavidljive rezultate. Tako smo tudi dosegli cilj naše naloge in potrdili naša predvidevanja, da uporaba umetnih nevronske mreže predstavlja alternativo klasičnim prognoznim metodam, ki slonijo na geoloških, hidroloških in geomehanskih

meritvah plazov. 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 izračunanimi pričakovanimi premiki plazov, odločala o morebitnih evakuacijah ogroženih ljudi ali drugih ukrepov.

## 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.

Ambrožič, T., Kuhar, M., Stopar, B., Turk, G. 1999. Modeliranje lokalnega geoida z umetnimi nevronskimi mrežami. Geodetski vestnik 43, 2: 118-129.

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

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

Fifer Bizjak, K. 1999. Uporabnost nevronskih mrež v inženirski tehnologiji. Doktorska disertacija, Ljubljana, Univerza v Ljubljani, Naravoslovnotehniška fakulteta, Oddelek za geologijo: str. 112-117

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.

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.

Komac, M. 2005. Intenzivne padavine kot sprožilni dejavnik pri pojavljanju plazov v Sloveniji. *Geologija*, 48, št. 2: str. 263-279.

Komac, M. 2003. Napoved verjetnosti pojavljanja plazov z analizo satelitskih in drugih prostorskih podatkov. Ljubljana: Geološki zavod Slovenije: 232 str.

Kononenko, I. 1997. Strojno učenje. 1. izdaja. Ljubljana, Univerza v Ljubljani, Fakulteta za računalništvo in informatiko: 305 str.

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

Kuhar, M., Stopar, B., Turk, G., Ambrožič, T. 2001. The use of artificial neural network in geoid surface approximation. *AVN*, 1/2001: 22-27 str.

Likar, J., Žigman, F., Čadež, F., Merhar, B., Križnič, A., Vukadin, V., Žigman, U., Muhić, E., Hribar, T., Jelen, B. 2001. Preliminarno poročilo o raziskavah in študiji možnosti sanacije Macesnikovega plazu: št: 50/2001. Ljubljana: IRGO Consulting d.o.o.

Maček, M. 2003. Transformacije koordinatnih sistemov s pomočjo umetnih nevronskih mrež. Diplomaska naloga, Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Oddelek za geodezijo: 112 str.

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

Majes, B., Ribičič, M., Komac, M., et. al. 2005. Novelacija in nadgradnja informacijskega sistema o zemeljskih plazovih in vključitev v bazo GIS UJME, Priloga III: Merske metode za spremljanje premikov zemeljskih plazov. Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo.

[www.sos112.si/slo/tdocs/merske\\_metode.pdf](http://www.sos112.si/slo/tdocs/merske_metode.pdf) (25. 9. 2007)

Park, C. 1997. The Environment. London: Routledge: 173-179 str.

Peteley, D.N., Mantovani, F., Bulmer, M.H., Zannoni, A. 2005. The use of surface monitoring data for the interpretation of landslide movement patterns. *Geomorphology*, vol. 30, no. 8, 719-722 str.

Plankl, S. 2006. Izdelava projekta spremljanja premikov in deformacij pri gradnji avtocest. Diplomsko naloga, Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Oddelek za geodezijo: 92 str.

Potočnik, B. 2007. Osnove razpoznavanja vzorcev z nevronske mrežami. Maribor, Univerza v Mariboru, FERI: 213 str.

Ribičič, M. 2002. Inženirska geologija I: skripta. Ljubljana: Naravoslovnotehniška fakulteta.

Skaberne, D. 2001. Predlog slovenskega irazoslovja pobočnih premikanj – pobočnega transporta. *Geologija*, 44, št. 1, 89-100 str.

Stopar, B., Pavlovčič, P. 2001. GPS v geodetski praksi, Študijsko gradivo, Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo, Oddelek za geodezijo: str. 79-96.

Savšek-Safić, S., Ambrožič, T., Stopar, B., Turk, G. 2003, Ugotavljanje premikov točk v geodetski mreži. Geodetski vestnik, 47, 2: 7-17.

Vodopivec, F., Kogoj, D. 2005. Nov način precizne stabilizacije geodetskih točk za opazovanje premikov. Geodetski vestnik, 49, 1:9-17.