

Универзитет у Београду, Грађевински факултет
Одсек за Хидротехнику и водно-еколошко инжењерство



МАСТЕР РАД

Ужа научна област: Механика нестишљивих флуида и
хидраулика

Тема: Прогноза промене нивоа на водомерним станицама
применом вештачких неуронских мрежа

Ментор

Доц. др. Милош Милашиновић

Студент

Душан Марјановић 518/20

Београд, 2021.

Резиме

У оквиру овог рада анализиране су способности неуронских мрежа ка прогнозирању нивоа на станицама у стварном систему, конкретно Хидроенергетски систем Ђердап 2. Анализирани су утицаји различитих архитектура неуронских мрежа, промене параметара неуронских мрежа, структуре, као и у последњем делу број улаза у неуронску мрежу. Као главни критеријум за поређење квалитета симулације коришћен је корен средњег квадратног одступања, због свог својства да дели јединицу са испитиваном вредношћу, у овом случају водостајем.

Анализе су рађене примарно према сложености архитектуре неуронских мрежа, у оквиру чега су се разматрали утицаји разних променљивих који се у њима налазе. Свака од наведених променљивих је одабрана на основу њеног уклапања са стварним измереним вредностима, помоћу претходно поменутог корена средњег квадратног одступања. Пошто је идеја рада да се предвиде сутрашње промене познавајући режим рада ХЕ, све симулације су рађене за период од 24 сата након престанка тренирања, под претпоставком да то адекватно симулира услове коришћења овакве мреже у пракси.

За сваку архитектуру неуронске мреже, дата је препорука о њеној употребљивости, као и променљивама које би биле погодне за одабрати да би се из ње добила највећа тачност.

Доступни подаци са станица Нера, Оршава, Панчево као и протицаји на ХЕ Ђердап 1, који су коришћени у тренирању мрежа, обухватају период од отприлике 2 и по године. У апсолутном смислу, доступних података има нешто мање од 22 000, што се сматра скупом задовољавајуће величине за квалитетно тренирање мреже.

У последњем делу рада разматрају се варијетети у грешкама које су се јавила кроз разна тренирања и симулације и дају се коментари и препоруке за даљу употребу и потенцијалне авеније истраживања.

Садржај

Резиме	2
Садржај	3
Списак слика	4
1. Увод	6
2. Методологија	8
2.1. Неуронске мреже	9
2.2. Генерални приказ методологије	14
2.3. Архитектуре неуронских мрежа	21
2.3.1. <i>Fitnet</i> неуронска мрежа	21
2.3.2. Неуронска мрежа са одлагањем улаза (<i>Time delay network</i>)	23
2.3.3. <i>NARX</i> мрежа	23
3. Резултати	25
3.1. Станица Оршава	25
3.1.1. Прогноза на станици Оршава коришћењем <i>Fitnet</i> мреже	25
3.1.2. Прогноза на станици Оршава коришћењем мреже са одлагањем улаза 29	
3.1.3. Прогноза на станици Оршава коришћењем <i>NARX</i> мреже	36
3.2. Станица Нера	46
3.2.1. Прогноза на станици Нера са једним улазом	46
3.2.2. Прогноза на станици Нера са два улаза	50
3.2.3. Прогноза на станици Нера са три улаза	54
3.2.4. Испитивање структуре мреже на станици Нера	58
4. Дискусија	60
5. Закључци	71
Литература	72

Списак слика

Слика 1 Модел хидросистема Дунав.....	8
Слика 2 Биолошки неурон (лево) и његов математички модел (десно)[10]	9
Слика 3 Диспозиција слојева и неурона у неуронској мрежи [11]	10
Слика 4 Приказ активационих функција[10]	11
Слика 5 Графички приказ опадајућег градијента[14].....	13
Слика 6 Општа скица модела за прогнозу нивоа.....	14
Слика 7 Прва диспозиција модела за предвиђање нивоа на станици Оршава.....	15
Слика 8 Друга диспозиција модела за предвиђање нивоа на станици Оршава	16
Слика 9 Прва диспозиција модела за предвиђање нивоа на станици Нера.....	17
Слика 10 Друга диспозиција модела за предвиђање нивоа на станици Нера	18
Слика 11 Трећа диспозиција модела за предвиђање нивоа на станици Нера	19
Слика 12 Четврта диспозиција модела за предвиђање нивоа на станици Нера.....	20
Слика 13 Tan-sigmoid функција[20]	21
Слика 14 Изглед констаната неуронске мреже	22
Слика 15 Демонстрација Overfit феномена[22].....	22
Слика 16 Ненормализовани резултати тренирања мреже.....	25
Слика 17 Ненормализовани резултати тренирања мреже кроз 9 симулација.....	26
Слика 18 Нормализовани резултати тренирања мреже	27
Слика 19 Поправљени нормализовани резултати тренирања мреже	27
Слика 20 Резултати неколико симулација тренирања fitnet мреже	28
Слика 21 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 2 скривена слоја са по 4 неурона.....	30
Слика 22 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 3 скривена слоја са по 4 неурона.....	31
Слика 23 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 2 скривена слоја са по 5 неурона.....	32
Слика 24 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 3 скривена слоја са по 5 неурона.....	33
Слика 25 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 2 скривена слоја са по 6 неурона.....	34
Слика 26 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 3 скривена слоја са по 6 неурона.....	35
Слика 27 Демонстрација помераја резултата	36

Слика 28 Резултати испитивања параметара за NARX мрежу, за 1 дан временског отклона улаза.....	38
Слика 29 Резултати испитивања параметара за NARX мрежу, за 2 дана временског отклона улаза.....	39
Слика 30 Резултати испитивања параметара за NARX мрежу, за 3 дана временског отклона улаза.....	40
Слика 31 Резултати RMSE током 10 симулација.....	42
Слика 32 Резултати испитивања дужине тренирања.....	43
Слика 33 Резултати испитивања структуре мреже.....	45
Слика 34 Резултати испитивања параметара мреже за станицу Нера са једним улазом за 1 дан временског отклона улаза	47
Слика 35 Резултати испитивања параметара мреже за станицу Нера са једним улазом за 2 дана временског отклона улаза.....	48
Слика 36 Резултати испитивања параметара мреже за станицу Нера са једним улазом за 3 дана временског отклона улаза.....	49
Слика 37 Резултати испитивања параметара мреже за станицу Нера са два улаза за 1 дан временског отклона улаза	51
Слика 38 Резултати испитивања параметара мреже за станицу Нера са два улаза за 2 дана временског отклона улаза	52
Слика 39 Резултати испитивања параметара мреже за станицу Нера са два улаза за 3 дана временског отклона улаза	53
Слика 40 Резултати испитивања параметара мреже за станицу Нера са три улаза за 1 дан временског отклона улаза	55
Слика 41 Резултати испитивања параметара мреже за станицу Нера са три улаза за 2 дана временског отклона улаза	56
Слика 42 Резултати испитивања параметара мреже за станицу Нера са три улаза за 3 дана временског отклона улаза	57
Слика 43 Резултати испитивања структуре мреже на станици Нера.....	59
Слика 44 Средње вредности грешака по испитивању.....	61
Слика 45 Вредности RMSE по параметру iDelays.....	62
Слика 46 Средње вредности грешака по броју улаза.....	64
Слика 47 Средња вредност грешке по броју улаза и вредности параметра inputDelays	65
Слика 48 Приказ вредности грешака у оквиру приложених симулација.....	66
Слика 49 Примена мреже на читав месец Нере	68
Слика 50 Примена мреже на читав месец Оршаве	69

1. Увод

Развој вештачке интелигенције, који доживљава велике напретке крајем XX и почетком XXI века нуди инжењерској пракси замену за математичке, односно физички засноване моделе који су дуго били најповерљивији начин за прогнозирање нивоа на рекама. Прогнозирање нивоа на реци је неопходна противмера за спречавање могућих катастрофалних последица поплава, поред тога значајно је и из аспекта одрживог развоја као и управљања водним потенцијалима, поготово у деоницама под значајним антропогеним утицајима (нпр. У близини ХЕ). Прогнозирање нивоа се најчешће врши помоћу модела заснованих на хидрауличко-хидролошким процесима, који захтевају сакупљање података са мерних места и редовно ажурирање постојећих база података. Тачна калибрација модела, путем параметара, је пресудна за адекватно симулирање промена нивоа на реци[1]. Са порастом броја параметара у моделу, расте и количина времена неопходна да се обезбеди одређени степен сигурности у тим моделским предвиђањима, као последица дуге калибрације[1]. Сложени физички модели засновани на хидрауличко-хидролошким процесима имају ограничење у погледу прогнозирања због велике количине времена потребне да се модели изврше, што је поготово непожељно код упозорења од поплава.

Сходно томе, развој вештачке интелигенције погодује оваквим прогнозама, јер нуди временски ефикасан начин прогнозирања који не зависи од мерења, чије је извођење јако сложено, у оквиру река. Једна од метода која се може користити су вештачке неуронске мреже (*ANN –Artificial Neural Networks*). *ANN* припадају класи модела заснованих на подацима, што представља алтернативу моделима заснованим на процесима, били они концептуални или физички.

У претходних неколико деценија, разни видови неуронских мрежа су коришћени зарад решавања великог дијапазона хидротехничких проблема, неки од примера укључују: Предвиђање поплава, прогнозирањем нивоа на основу хидрограма поплавних таласа (као узводног граничног услова) као улаза [1][2]; реконструкцију историјских поплава (конкретно на реци Рајна 1809), помоћу измерених водостаја из тог периода, уз одговарајућу реконструкцију геометрије и параметара хидрауличке храпавости [3]; предвиђања нивоа у урбаним дренажним системима такође помоћу улазних хидрограма [4]; прогнозе квалитета воде на сливу као последица сезонских промена [5]; као и предвиђања нивоа у резервоару током рада коришћењем улазног и излазног протока у резервоар као и климатолошких фактора попут падавина, испаравања, релативне влажности ваздуха и сл.[6]; између осталих.

Претходно поменута истраживања показују да су неуронске мреже валидан начин прогнозирања у оквиру хидротехничких система, имајући на уму да показују иста, ако не и мања одступања него што показују традиционални модели.

Из претходно поменутих разлога, од интереса је познавање нивоа воде на станицама унапред. Том интересу погодује чињеница да се на хидроелектранама (у даљем тексту ХЕ) познаје унапред режим испуштања воде (режим рада ХЕ) као последица потреба за електричном енергијом. Ако је могуће истренирати неуронску мрежу да са одговарајућом тачношћу (и наравно поновљивошћу, о чему ће бити речи у даљем тексту) прогнозира ниво на станицама узводно од ХЕ, као последица режима рада ХЕ, то би

представљало значајну помоћ при управљању водним ресурсима. Како се у хидроенергетском систему познаје потреба за енергијом у наредном дану, и сходно томе режим рада ХЕ, помоћу истрениране неуронске мреже, могуће је за сваки дан унапред прогнозировать промене нивоа воде на станицама.

Ово представља алтернативни приступ за прогнозирање промене у односу на софтвере коришћене у широј пракси (као што је нпр. *HEC-RAS*, који решавањем једначина одржања масе и количине кретања између осталих, уз одговарајуће параметре, рачуна промену нивоа воде[7]) који би представљали вид модела заснованих на хидрауличко-хидролошким процесима. Коришћење неуронских мрежа представља *data-driven* модел [8] који у себи нема никакво „познавање“¹ процеса који се догађају у оквиру разматраног система, већ користећи одређене моделе и архитектуре (неке од којих ће бити обрађене у оквиру овог рада) покушава да подеси своје параметре (који, наравно, зависе од архитектуре мреже) које користи за прогнозирање. Детаљан принцип рада неуронских мрежа биће објашњен у даљем тексту.

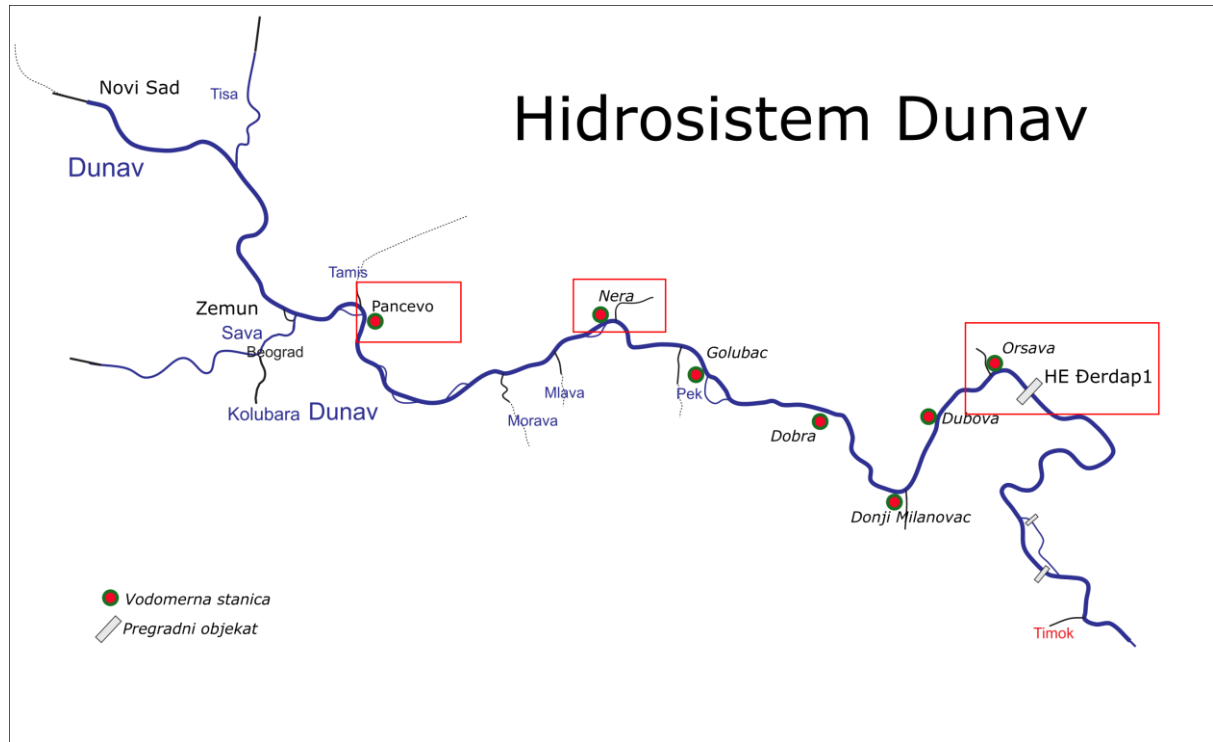
Овај рад ће се бавити прогнозом нивоа на водомерним станицама на 24-часовном нивоу. Под тиме се подразумева да ће циљ овог рада бити испитивање способности неуронске мреже да са одређеном тачношћу прогнозира промене нивоа воде на станицама у оквиру 24 часа, са познатим режимом рада ХЕ. Пошто ће та испитивања бити извршена на 24-часовном периоду за који се познаје ниво воде који се јавио, омогућено је поређење прогнозираног и измереног нивоа, на основу чега се може срачунати и грешка у прогнозирању. Детаљна диспозиција система дата је у даљем тексту

Значајан фактор у оваквим прогнозама је и брзина прогнозирања (односно брзина симулације), која у случају неуронских мрежа зависи од сложености архитектуре, као и од процесорске моћи рачунара на којем се врше симулације. Како међусобна интеракција процесорске моћи и брзине симулације није предмет разматрања у оквиру овог рада, биће испитано неколико различитих архитектура мрежа које ће бити испитиване по сложености, од најједноставније до најсложеније.

¹ Под овиме се подразумева да у оквиру модела нису испрограмиране математичке зависности између одређених параметара.

2. Методологија

Испитивање могућности предвиђања нивоа воде у хидроенергетском систему у зависности од режима испуштања воде кроз хидроелектрану, коришћењем вештачке интелигенције, испитивано је на хидросистему Дунав, који обухвата деоницу реке Дунав од Новог Сада до ХЕ Ђердап 2.



Слика 1 Модел хидросистема Дунав

За израду система вештачке интелигенције коришћен је програмски језик MATLAB[9], чији су већ постојећи пакети коришћени за креирање скелета система уз помоћ којег су предвиђања вршена. Вид вештачке интелигенције који је коришћен јесу неуронске мреже различитих врста о којима ће бити речи у даљем тексту.

Основни елементи испитиваног система су водомерне станице дуж Хидросистема Дунав, од којих су само неке коришћене у оквиру модела, као и протоци на ХЕ Ђердап 1 који су служили као основни улазни податак за предвиђање. Уоквирене станице на слици 1 представља станице на којима је вршено прогнозирање.

Елементи система су повезани пропагацијом поремећаја из ХЕ Ђердап 1, која је независна од узводних елемената система, али својим режимом рада изазива промене нивоа на узводним водомерним станицама. Границу доминантности овог поремећаја представља станица Нера, чији нивои зависе и од узводних услова, док код станица низводнијих од ње нивои зависе доминантно од режима рада ХЕ.

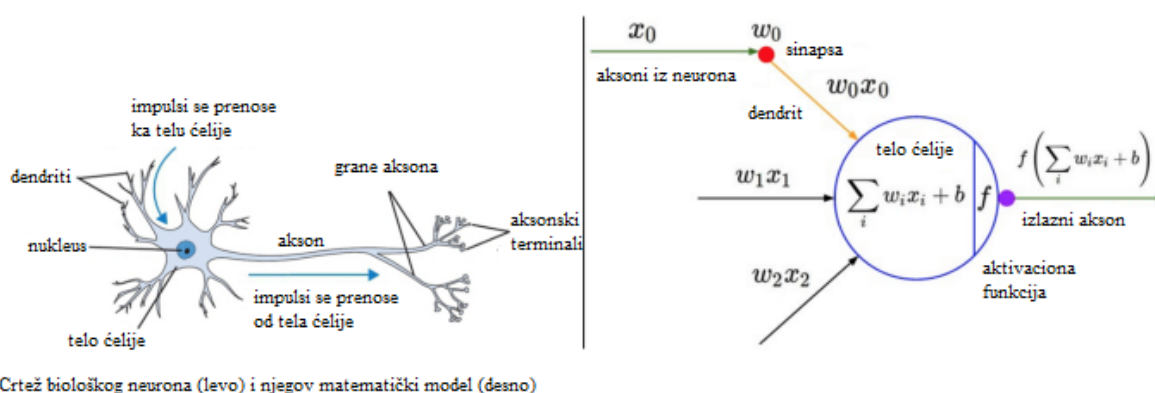
Подаци коришћени за потребе предвиђања обухватају оквирно двоипогодишњи период од 6. јуна 2017. године до 1. децембра 2019. године, начин коришћења тих података биће детаљно објашњен.

2.1. Неуронске мреже

Да би се разумела генерална методологија неопходно је разумевање функционисања неуронских мрежа, које се такође називају и вештачке неуронске мреже (Artificial Neural Networks - ANNs) или симулиране неуронске мреже (Simulated Neural Networks - SNNs).

Неуронске мреже су настале по угледу на неуроне људског мозга. Наиме, мрежа се састоји из великог броја међусобно повезаних неурона који заједно учествују у решавању конкретнoг проблема [10]. Аналогно људском мозгу, могуће их је обучити, али је за то неопходан велики број података. Контратежа неопходности великог броја података, способне су за решавање проблема из многих области. Мреже екстрахују обележја и уочавају компликоване правилности између одређених група података.


Основна јединица неуронске мреже је вештачки неурон моделиран према биолошком неурону са слике 2.



Слика 2 Биолошки неурон (лево) и његов математички модел (десно)[10]

Неуронске мреже се састоје из слојева неурона, који садрже слој неурона са улазом, један или више скривених слојева и излазни слој. Сваки неурон је повезан са сваким из наредног слоја, као што је приказано на слици 3, и њему се приписује одређена тежина. Излаз из сваког неурона је нелинеаран, о чему ће бити речи у даљем тексту.

Мреже са великим бројем скривених слојева представљају дубоке неуронске мреже (deep neural network), где се појам „дубоко“ у називу односи само на дубину, односно број скривених слојева који се налазе у оквиру мреже [11].



Слика 3 Диспозиција слојева и неурона у неуронској мрежи [11]

Сваки неурон у неуронској мрежи се може сматрати као засебан модел линеарне регресије, који се састоји од улазних података, тежине, слободног члана (*bias*) и излаза[11]. Груба верзија такве формуле би изгледала:

$$\sum_{i=1}^m w_i x_i + b = w_1 x_1 + w_2 x_2 + w_3 x_3 + \dots + bias \quad (2.1)$$

где су:

- x – улазни подаци
- w – тежински коефицијенти
- b – *bias*, односно слободни члан

вредност b се може сматрати аналогном некој константи у линеарној функцији, која функцију ефективно транслира.

Излаз из неуронске мреже се посматра као:

$$y = \varphi\left(\sum_{i=1}^m x_i w_i + b\right) \quad 2.2$$


Када се формира улазни слој, насумично се припишу тежине, односно тежински коефицијенти. Иницијално то не даје добар резултат класификације, али кроз тренинг одређене променљиве добијају на тежини. Ово помаже у одређивању значаја сваке променљиве, где „теже“ променљиве, односно оне са већом вредности тежинске

променљиве w много више утичу на излаз него „лакше“[11]. Сви улази се затим множе са њиховим тежинским вредностима и сумирају. Затим, излаз пролази кроз такозвану активациону функцију, која представља нелинеарност која се додаје излазу неурона, како би мрежа могла да учи нелинеарне репрезентације, чији резултат излаза сада постаје улазни податак за следећи слој неурона. Тај процес преношења података дефинише неуронске мреже као *feedforward* мреже[11].

Као што је раније поменуто, излази из неурона су нелинеарни, иако сваки неурон може да се представи помоћу линеарне регресије, нелинеарност излазу из неурона дају активационе функције $\varphi(x)$. Значај тога се огледа у томе да је велика већина реалних података нелинеарна, апропо чему неуроне треба „научити“ у условима нелинеарности.

Свака активациона функција узима један број и на њему врши одређену математичку операцију, тај број је линеарни излаз из неурона након сређивања тежинских коефицијената и слободног члана. У широј пракси примене неуронских мрежа користи се неколико активационих функција[10]:

- Сигмоидна функција $\sigma(z) = \frac{1}{1+e^{-z}}$
- Тангенс хиперболички $\sigma(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$
- ReLU $ReLU(z) = \begin{cases} z, & z > 0 \\ 0, & \text{у супротном} \end{cases}$
- LeakyReLU $LeakyReLU(z) = \begin{cases} z, & z > 0 \\ az, & \text{у супротном} \end{cases}$



Слика 4 Приказ активационих функција[10]

У приказаним функцијама, променљива z представља излаз из претходног неурона (важи и за излаз из неурона улазног слоја у коме се налазе улазни подаци) на које се пре уласка у наредни неурон примењује активациона функција. Замислимо да у неурон улазе три различита улаза x_1 , x_2 и x_3 са одговарајућим тежинским коефицијентима w_1, w_2 и w_3 и

слободним чланом b , ти производи се сумирају, затим сабирају са слободним чланом, на крају та вредност пролази кроз активациону функцију која служи да јој дода нелинеарност[12]. Математички, овај процес је приказан у једначини 2.2 где је φ активациона функција, а све унутар заграде представља променљиву z у претходно поменутих једначинама.

Најчешће коришћена активациона функција је исправљена линеарна јединица (*Rectified Linear Unit - ReLU*), као и њене модификација, накошена исправљена линеарна јединица (*Leaky ReLU*) и параметарска накошена исправљена линеарна јединица (*Parametric ReLU - PReLU*)[12]. Основна *ReLU* функција негативне вредности које улазе у њу записује као нулу, док позитивне вредности преписује без промене. Главна мана те функције јесте што за негативне вредности неки неурони никада неће бити ажурирани, што је довело до увођења модификације која при негативним вредностима нема вредност нулу, већ у случају обичне *LeakyReLU* функције негативне вредности множи са 0.01, или у случају *PReLU* функције поседује подесиви параметар a .

Окружење у којем су развијане мреже за потребе овог рада користи *ReLU* активационе функције, што је разлог њиховог детаљнијег објашњења. Иако се користи и *sigmoid* активациона функција, она не захтева детаљно објашњење.

У процесу тренирања неуронске мреже, неопходно је постојање критеријума који ће проценити тачност тих резултата. Неуронске мреже за ту проверу користе функцију губитака, која се дефинише као половина средње квадратне грешке, тј. *Mean squared error (MSE)*[13]. Функција губитака се рачуна као:

$$MSE = \frac{1}{2m} \sum_{i=1}^m (\hat{y} - y)^2 \quad (1.3)$$

где је:

- i – Редни број узорка
- \hat{y} – Вредност коју мрежа предвиђа да ће се јавити
- y – Стварна вредност
- m – Број узорака

Главни циљ тренирања мреже јесте смањивање ове грешке да би се осигурала тачност. Како модел подешава вредности тежина и пристрасности коришћењем *MSE* функције да дође до локалног минимума. Процес помоћу којег алгоритам подешава тежинске вредности је опадајући градијент[14][15]. Функција опадајућег градијента долази у неколико облика[14]:

- Опадајући градијент – *Gradient descent*
- Стохастички опадајући градијент – *Stochastic gradient descent*
- Опадајући градијент са мањим подскуповима података – *Mini-batch gradient descent*

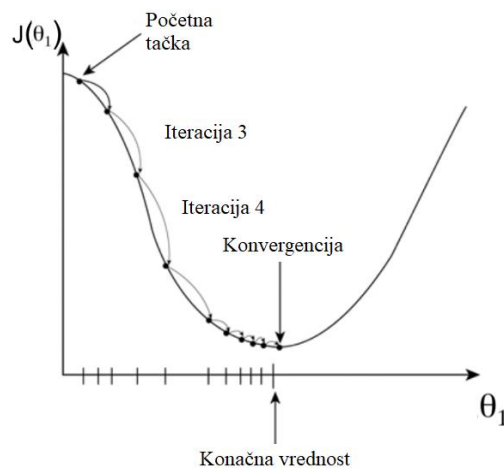
Градијент представља вектор чији смер представља смер највећег повећања вредности функције. Како је циљ неуронских мрежа да се ажурирањем тежина минимизује функција губитака (где је излази мреже функција тежине мреже), при обучавању рачунамо негативни градијент функције губитка по тежинама мреже, минимизујући функцију губитка. Опадајући градијент представља процес мењања

тежина мреже у корацима који су пропорционални негативном градијенту функције губитка док не дође до конвергенције, тај процес је приказан на слици 5.

Ажурирање тежина опадајућим градијентом постиже се следећом формулом[15]:

$$w_1 = w_0 - lr \frac{\partial(w_0, w_1)}{\partial w_j}, j = 0, 1 \quad (1.4)$$

где lr представља стопу учења (*learning rate*), која контролише величину корака по ком се тежине ажурирају пропорционално негативном градијенту. Парцијални извод $\frac{\partial(w_0, w_1)}{\partial w_j}$ представља градијент пада између вредности тежине у наредном временском кораку $j=1$ и претходном временском кораку $j=0$. Што је већа стопа учења, то је већи корак у ком се тежине при свакој итерацији мењају[14][15].



Функција губитка - "Половина средње квадратне грешке"

$$J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$$

Циљ

$$\min_{\theta_0, \theta_1} J(\theta_0, \theta_1)$$

Изводи

$$\frac{\partial}{\partial \theta_0} J(\theta_0, \theta_1) = \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})$$

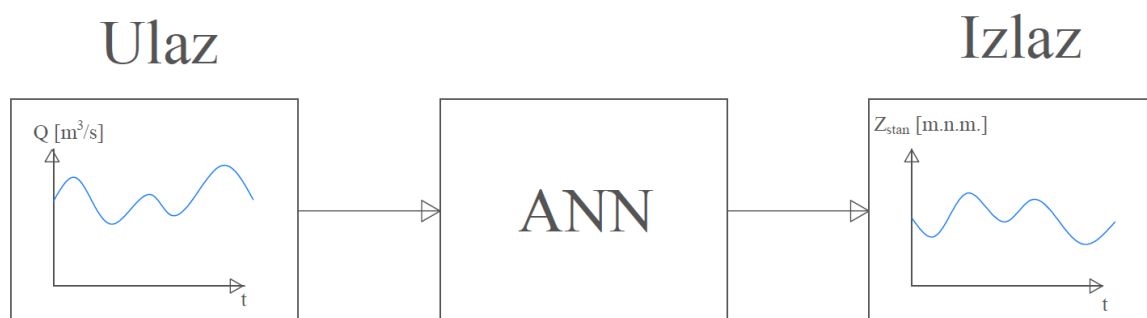
$$\frac{\partial}{\partial \theta_1} J(\theta_0, \theta_1) = \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x^{(i)}$$

Слика 5 Графички приказ опадајућег градијента[14]

2.2. Генерални приказ методологије

Режим рада ХЕ Ђердап 1 дат је у виду хидрограма који је унапред дефинисан од стране ЕПС зависно од потреба за електричном енергијом у домену који се снабдева од стране наведене ХЕ. Познавање испуштања воде кроз ХЕ унапред представља основу за овакво испитивање, односно идеје да се помоћу вештачке интелигенције предвиди ниво за наредне дане познавајући режим рада ХЕ.

Самим тим, режим рада ХЕ представља основни улаз у неуронске мреже, и подаци о режиму рада су садржани у улазном слоју, док, као што је раније поменуто, нивои на водомерним станицама представљају излаз система.



Слика 6 Општа скица модела за прогнозу нивоа

Вештачка неуронска мрежа (ANN) представља вид система сиве кутије (*Grey box system*). Системи сивих кутија комбинују делимичну теоријску структуру са улазним подацима, чиме се комплетира модел. Теоријска структура би представљала дефинисану зависност између улазних и излазних података, док је у случају делимичне теоријске структуре зависност повезана одређеним параметрима (у овом случају тежинским коефицијентима) који се морају подешавати поново за сваки случај, чак и случају веома сличних проблема. Општи случај модела сиве кутије је нелинеарни модел са делимичном теоријском структуром, који одређене непознате делове „извлачи“ из улазних података, ово се уклапа са претходно поменутом структуром неуронских мрежа у томе што се непознати делови, односно тежински коефицијенти, добијају из улазних података, комплетирајући модел који предвиђа излаз.

Улаз у систем неуронске мреже не мора бити јединствен, за тачнија предвиђања излаза зависе од неколико различитих спољашњих утицаја, неопходно је тренирати мрежу да сагледа све утицаје, што може довести до веће потребе за улазним подацима ради предвиђања или немогућности предвиђања, са одређеном тачношћу, као последица недостатака улазних параметара. Наравно, у реалним системима, једнозначна зависност је немогућа, али, као што је раније поменуто, доминантност одређеног параметра омогућава примену неуронских мрежа са довољном тачношћу.

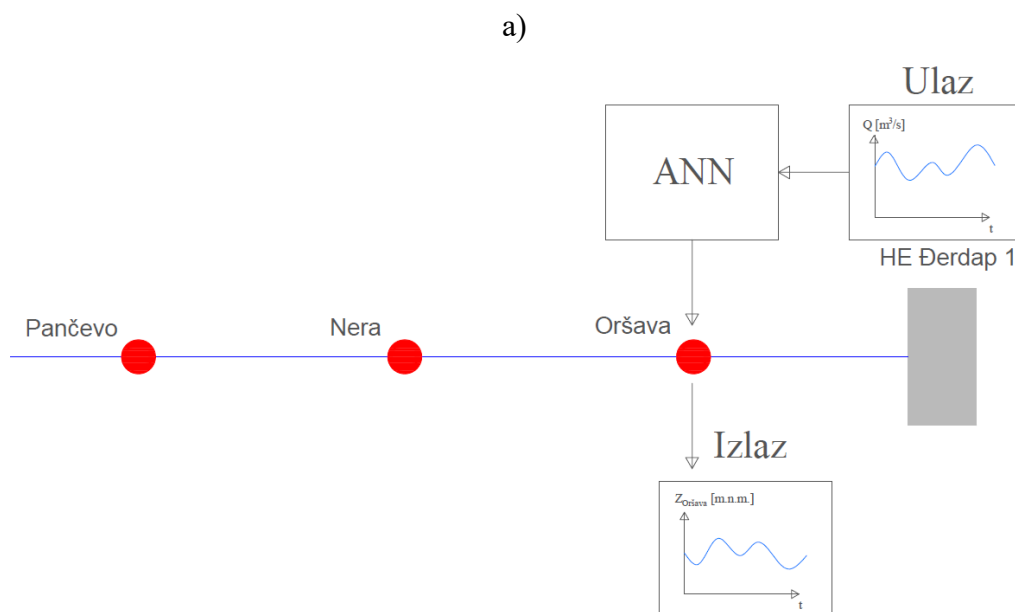
У случају ХС Дунав, доминантни утицај представља ХЕ Ђердап, али само за станицу Нера, за узводније станице неопходно је користити по неколико улаза за предвиђања, од којих макар један мора бити узводни због утицаја узводних притока на промене нивоа на тим станицама.

Подаци са станица који су коришћени за предвиђања на сливу ХС Дунав су:

- Протицаји кроз ХЕ Ђердап 1 - Q_{HE} [m^3/s]
- Нивои на станици Оршава - $Z_{Oršava}$ [$m.n.m.$]
- Нивои на станици Нера - Z_{Nera} [$m.n.m.$]
- Нивои на станици Панчево - $Z_{Pančevo}$ [$m.n.m.$]

Коришћењем неуронских мрежа обављена су испитивања предвиђања на станицама Оршава и Нера.

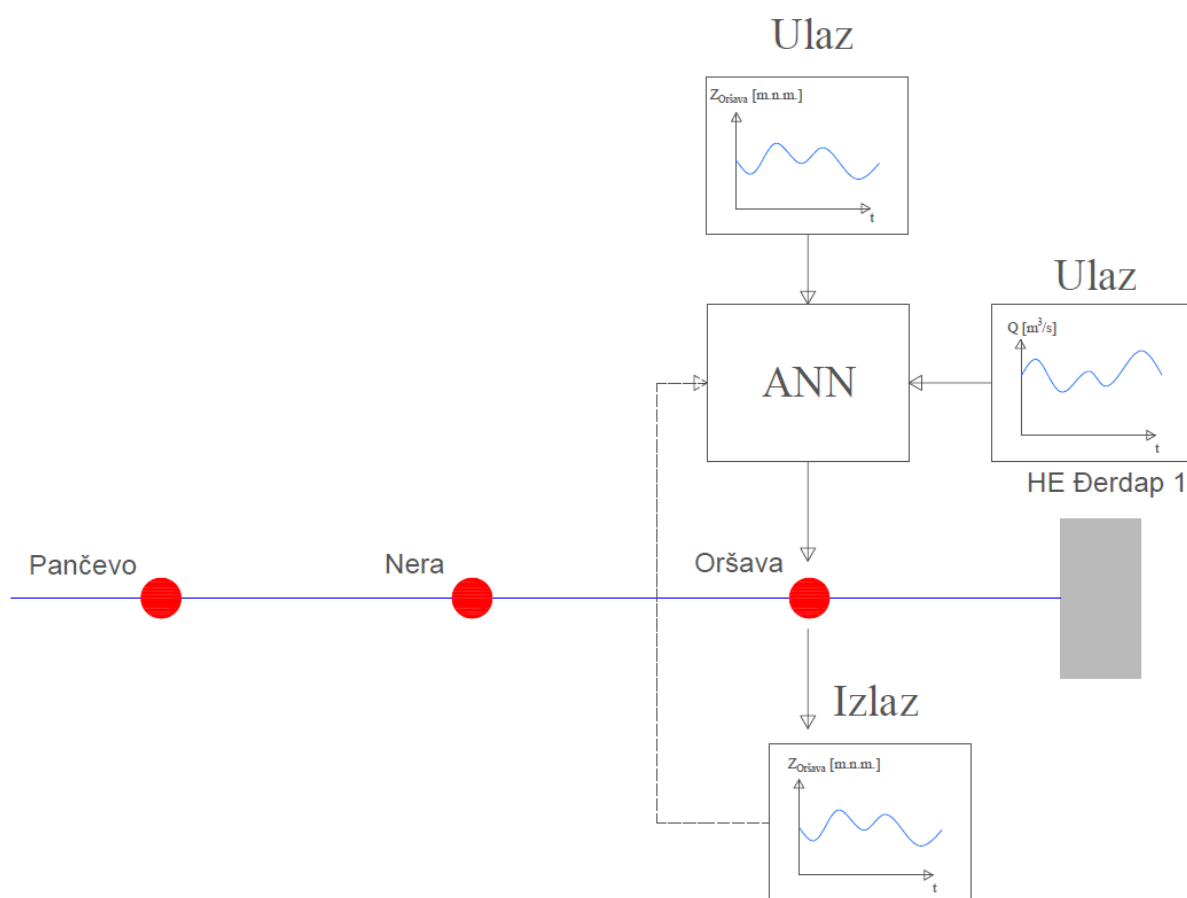
У случају предвиђања нивоа на станици Оршава, диспозиција испитиваног система има 2 варијанте:



Слика 7 Прва диспозиција модела за предвиђање нивоа на станици Оршава

У овом случају, једини улаз за тренирање неуронске мреже јесте протицај кроз ХЕ Ђердап 1, а излаз је ниво на станици.

б)



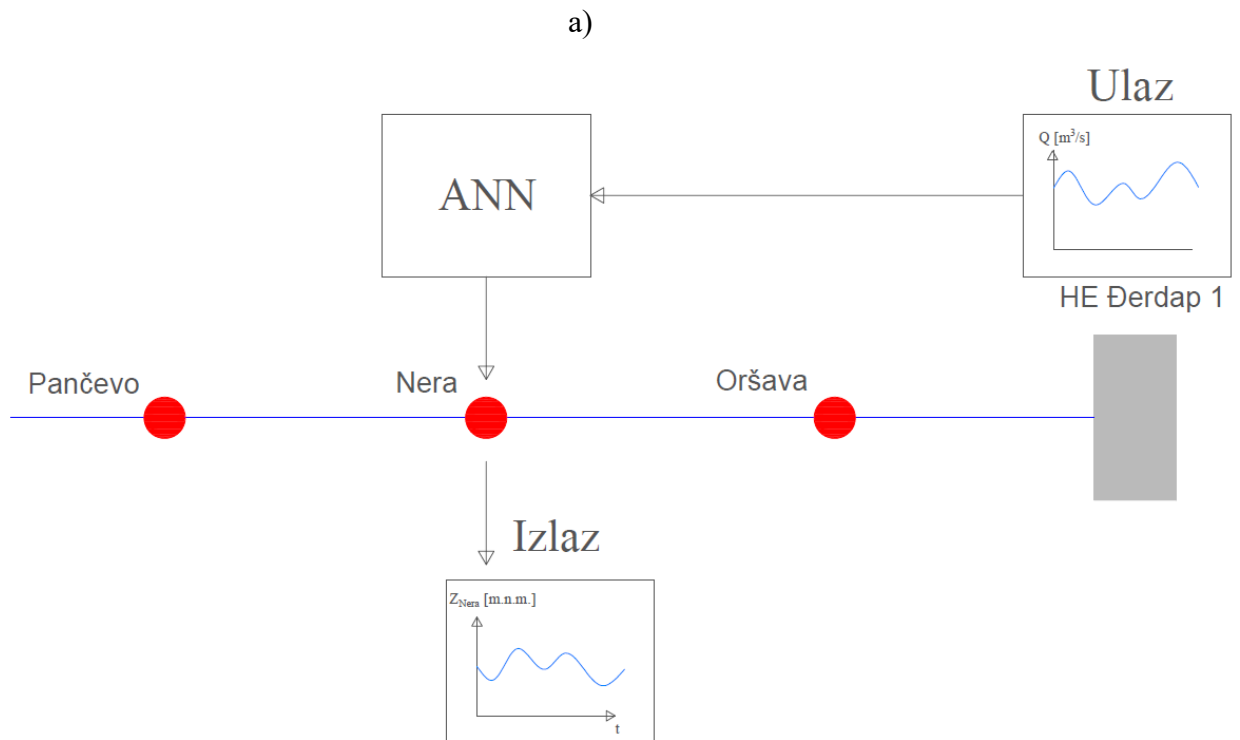
Слика 8 Друга диспозиција модела за предвиђање нивоа на станици Оршава

У овом случају, уводи се динамичка компонента у тренинг, за те потребе користиће се *NARX* мрежа (*Nonlinear AutoRegressive network with eXogenous inputs*) и мрежа са одлагањем улаза, о којима ће бити речи у даљем тексту.

Под појмом динамичка компонента подразумева се управо способност мреже да излаз из неуронске мреже у наредним временским корацима постане улаз, чиме се формира повратна спрега (дефинисано параметрима о којима ће бити речи у даљем тексту), као и тзв. *Multi-step prediction* опције (ексклузивне за *NARX* мрежу), зарад квалитетнијег моделирања динамичких серија. Испрекидана линија на овом цртежу, као и на свим даљим цртежима представља функцију *NARX* мреже да обавља *Multi-step prediction*, што ефективно значи да ће се излази приликом тренинга поредити са доступним подацима затим ће се мрежа „дотренирати“ на основу резултата тог поређења ради још квалитетнијег тренинга. Опсег вредности који се обухвата *Multi-step* предвиђањима дефинисан је параметром *feedbackDelays* о којем ће бити речи у даљем тексту.

Због своје удаљености од станице Нера, отприлике 132 km, као и блискости ХЕ, на станици Оршава није испитивана варијанта у којој су улазни подаци нивои на станици Нера, и проток кроз ХЕ.

У случају предвиђања нивоа на станици Нера, коришћено је неколико варијанти диспозиција система, приказаних према нивоу сложености:

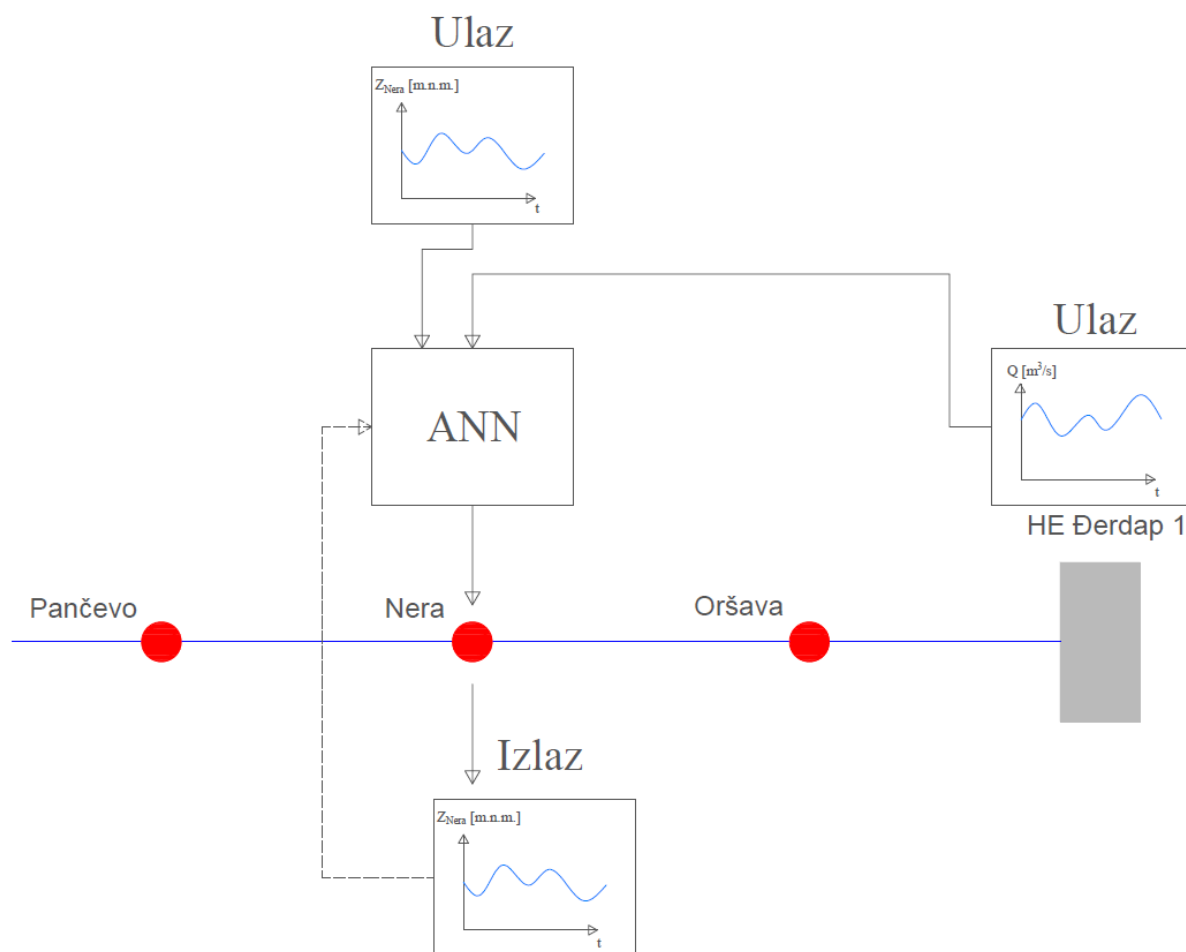


Слика 9 Прва диспозиција модела за предвиђање нивоа на станици Нера

За прву и најједноставнију варијанту, предвиђање на станици Нера зависи само од протицаја кроз ХЕ.

Ова диспозиција као најједноставнија, ни не треба да даје савршено тачна предвиђања већ се користи као вид еталона да би се видела побољшања са повећањем комплексности, што је тачно и за касније диспозиције, које ће бити поређене са још сложенијим диспозицијама.

б)

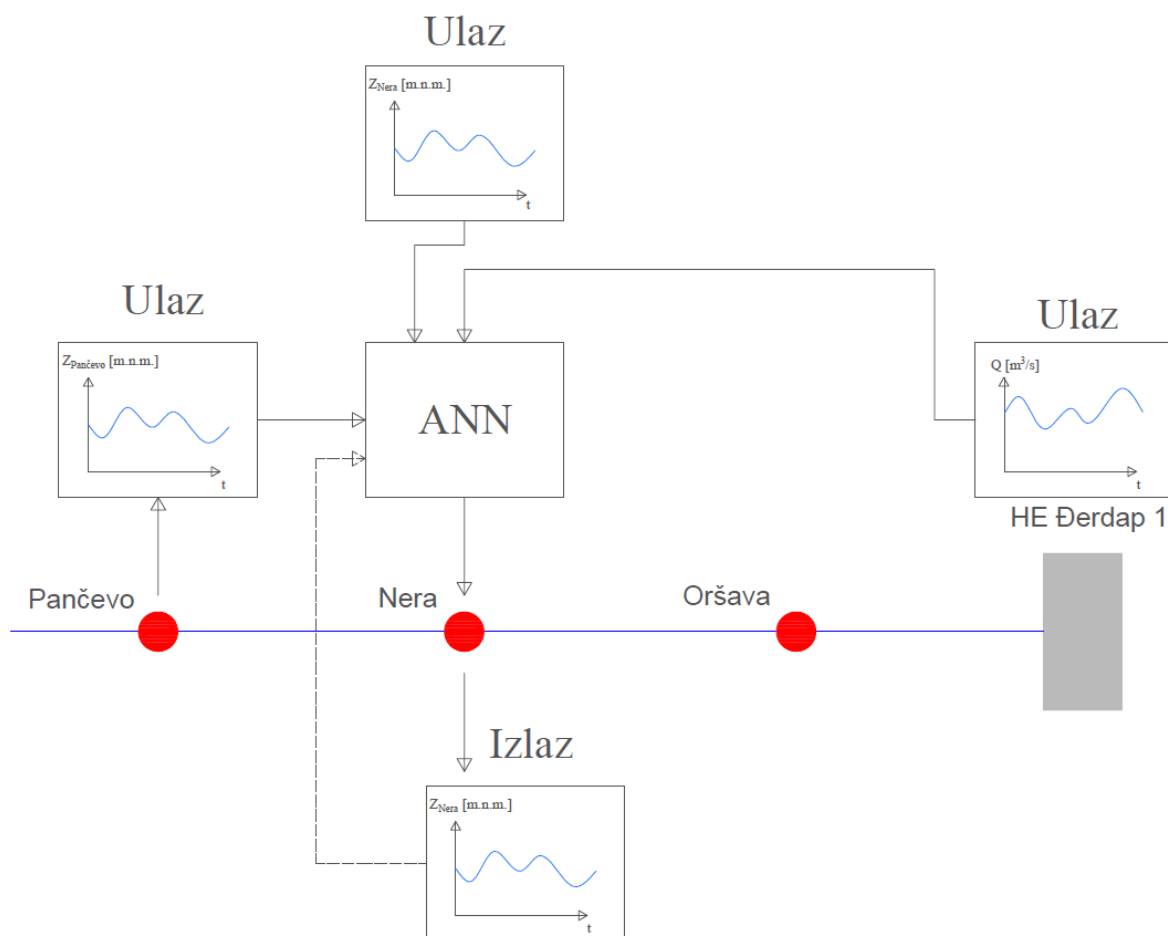


Слика 10 Друга диспозиција модела за предвиђање нивоа на станици Нера

У другом нивоу сложености, уводи се динамичка компонента, односно мрежа користи неколико улаза, као и претходне вредности нивоа које су се јавиле на испитиваној станици. За потребе ове мреже, као и све наредне које ће се користити за прогнозе на станици Нера, користи се искључиво *NARX* мрежа.

Ова диспозиција преодминантно показује утицај увођења динамичности у ова предвиђања, што би концептуално требало да помогне у „стабилизацији“ предвиђених вредности, односно да мрежа не претера ни у једну ни у другу страну када је примењена на нове податке.

В)

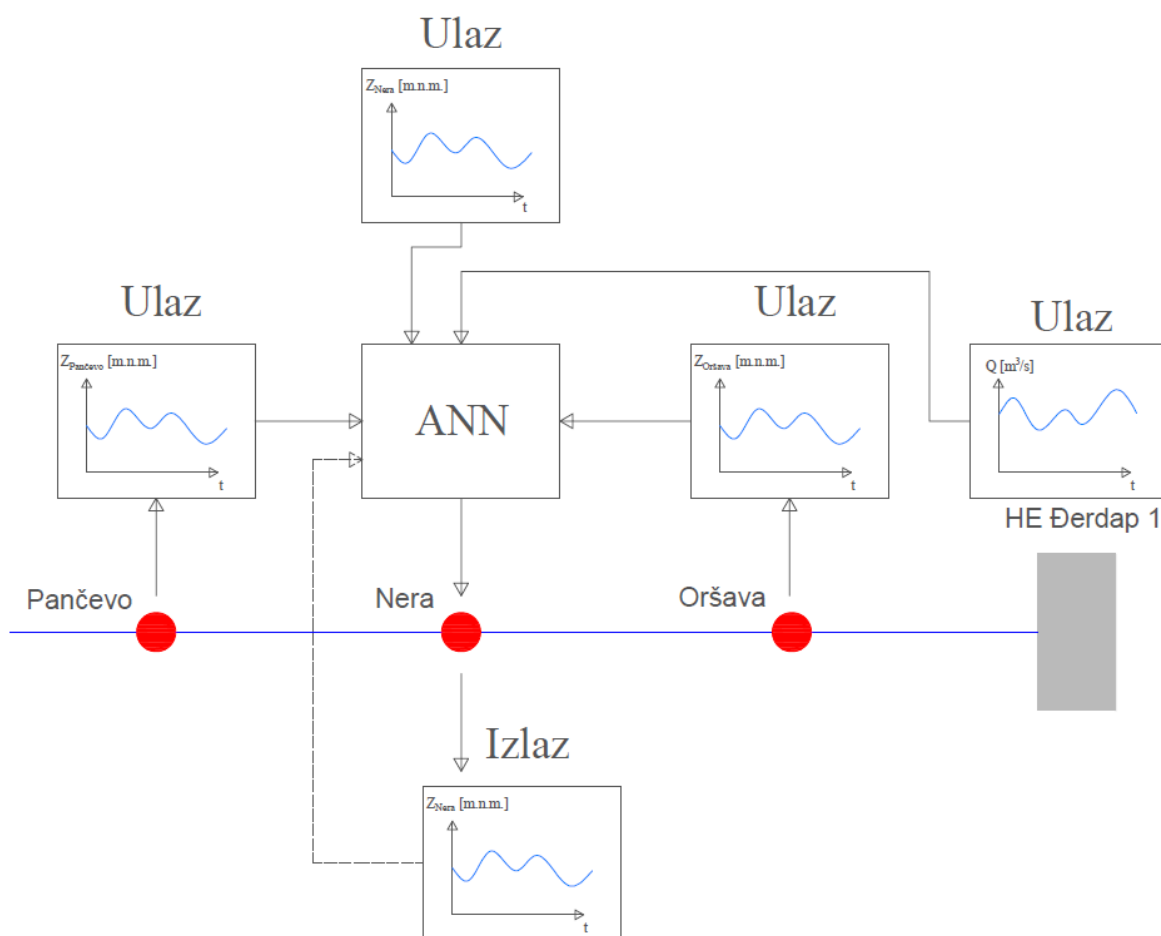


Слика 11 Трећа диспозиција модела за предвиђање нивоа на станици Нера

У трећем нивоу сложености, уводе се и нивои са узводне станице Панчево у мрежу.

Иако су протицаји кроз ХЕ главни катализатор промена нивоа и на станици Нера, ова диспозиција испитује да ли последице узводних поремећаја који се преносе кроз станицу Панчево доводе до тачнијих прогноза на моделу.

r)



Слика 12 Четврта диспозиција модела за предвиђање нивоа на станици Нера

У последњем нивоу сложености, уводе се и нивои са низводне станице Оршава у мрежу.

Као последица своје удаљености од ХЕ, увођење нивоа на станици Оршава концептуално служи да премости поремећаје од ХЕ кроз ниво на Оршави, ова мрежа би требала да обухвата (у опсегу могућности) већину утицаја на нивое на станици Нера, при чему би требала да показује најбоље резултате.

2.3. Архитектуре неуронских мрежа

За прогнозе на обе станице, иако је највише коришћена *NARX* мрежа, највише због њене динамичке компоненте, коришћене су и друге архитектуре мрежа.

За креирање кода неуронских мрежа коришћене су опције које већ постоје у *MATLAB* прогамском пакету, тај код је даље ажуриран по потреби за детаљнија испитивања, у овом делу ће бити обрађене основне форме и архитектуре сваке од коришћених неуронских мрежа, док је у даљем тексту прецизирано када је неки од параметара (доступних за промену приликом тренирања од стране корисника) мењан за потребе прогнозирања.

Коришћене неуронске мреже су поређане по нивоима сложености.

2.3.1. *Fitnet* неуронска мрежа


Најједноставнија од испитиваних неуронских мрежа, суштина овог типа мреже је принцип регресије између података који представљају улаз, и података чија вредност се тражи. Мрежа покушава да помоћу тежинских коефицијената приписаним улазним подацима, нађе регресиону криву или праву на коју ће једнозначно мапирати податке, са које се нови подаци једноставно читају када треба да се примени мрежа.

Од подесивих параметара које ове мрежа нуди постоји функција која се користи за тренирање и која је аутоматски подешена на *Levenberg-Marquardt (LM)* функцију. Ова функција користи више меморије, али нуди и најбрже тренирање, што је чини погодном за овакав проблем, због великог броја улазних података[17][18]. Пошто ће се *LM* функција такође користити и за остале типове мрежа, напомиње се да је критеријум за престанак тренирања у свакој итерацији да промена тежинских коефицијената (путем претходно описаног процеса опадајућег градијента) буде мања од 0.001 (у *MATLAB*-у параметар означен са μ). Такође се у оквиру ове мреже може подесити и структура скривених слојева, односно број скривених слојева и неурона у њима, као и подела података, која је усвојена да буде по блоковима. Постоје 3 блока за поделу:[19]

- Блок за тренирање – Усвојен на 70% доступних података
- Блок за валидацију – Усвојен на 15% доступних података
- Блок за тестирање – Усвојен на 15% доступних података

Пошто ова мрежа не садржи у себи динамику проблема, подела у блокове је насумична, затим се из тих блокова подаци „*fit*-ују“ на регресиону криву.[19]

Активациона функција коју ова мрежа користи је *tan-sigmoid* функција (односно *tanh*), приказана на слици 13.



Слика 13 *Tan-sigmoid* функција[20]

Овај тип мрежа такође омогућава да се сагледају тежински коефицијенти и вредности *bias*-а садржане у сваком слоју неурона, односно константе неуронске мреже. Те константе на примеру мреже са 2 скривена слоја и 4 неурона по слоју изгледају:

```

% Layer 1
b1 = [4.284222844314758305;2.3125696227168086594;-0.96827712991002190535;-5.6843861713579082462];
IW1_1 = [-6.1580260382311644562;-3.49915711499384674;-4.7895788001441941262;-5.4601261482693121962];

% Layer 2
b2 = [1.9055718036117665903;-0.83912327973784606172;0.63757429116908737043;-2.5300006846878688727];
LW2_1 = [-1.3577554736737824648 0.95167584683839467896 1.1066635313152051179 1.1499378821082002489;0.68006323262883794367

```

Слика 14 Изглед констаната неуронске мреже

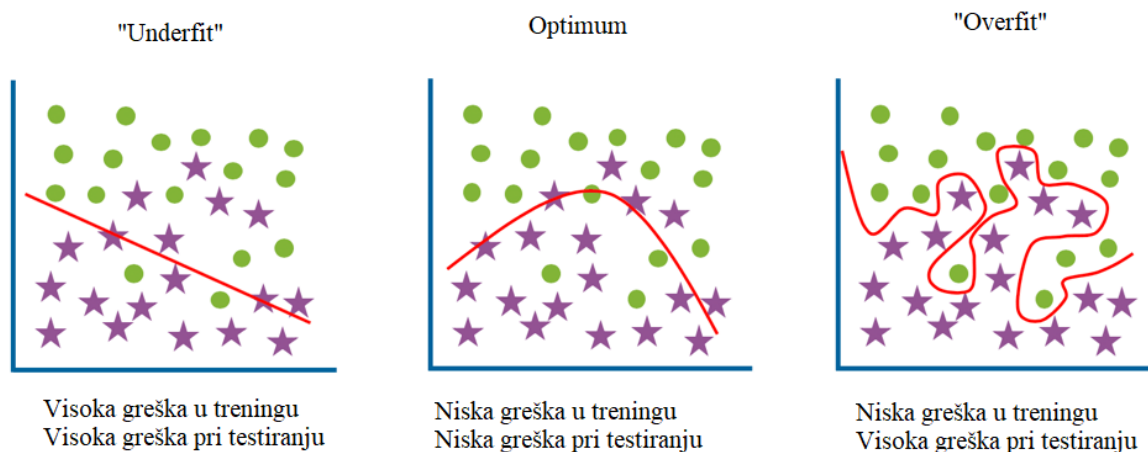
где су:

- b_1 и b_2 – вредности *bias*-а за сваки неурон
- $IW1$ и $LW2_1$ – вредности тежинских коефицијената у сваком неурону

Примећује се да у другом скривеном слоју постоји неколико тежинских коефицијената у сваком неурону који се сумирају према процесу описаном у поглављу 2.1. Саме вредности тих коефицијената нису значајне, јер је мрежа која је тестирана насумично одабрана.

Значајно је напоменути да при коришћењу ове функције не треба задавати превише неурона по слоју, јер се може јавити проблем претераног уклапања, односно *overfit*-овања.[22]

Overfit-овање је појава када се модел који је коришћен за уклапање података савршено уклапа са тренинг подацима, чинећи модел ефективно бескорисним ван (некада јако уског) дијапазона тренинг података. Овај феномен је поготово опасан за системе као што је ХС Дунав, где се јавља широк распон могућих појава, а доступни подаци могу обухватити период са јако малим унутрашњим варијететима.



Слика 15 Демонстрација *Overfit* феномена[22]

Пошто све мреже деле опцију функције за тренинг, структуре скривених слојева и поделе података, у наставку овог поглавља ове функције неће бити описиване већ ће се у поглављу 3. прецизирати промене ових, као и других параметара.

Као последица динамичности испитиваног система, од ове архитектуре мреже се не очекује никакав значајан квалитет резултата, имајући на уму да она нема опцију разматрања узастопности података, већ тражи једноставно пресликавање.

2.3.2. Неуронска мрежа са одлагањем улаза (*Time delay network*)

Овај тип мреже је коришћен као основни вид моделирања временских серија. Та способност је омогућена постојањем параметра *inputDelays*, који представља број временских корака улаза уназад који мрежа разматра приликом тренирања ради задржавања контекста унешених података и бољег тренирања за динамичке серије, укратко, мрежа побољшава свој тренинг разматрањем дефинисаног броја улаза уназад и задржавајући њихов редослед даје квалитетније резултате.[23]

Иако дели исте параметре са претходном мрежом, увођење параметра *inputDelays*, без опције за уношење времена, повлачи за собом одређене особености:

- Овај тип мреже третира податке као дугачку временску серију са међусобно униформним временским одстојањима без обзира на стварно временско одстојање између њих (нпр. У мрежу се могу унети подаци са различитим временским корацима, за које ће се мрежа истренирати као да је временски корак Δt исти).
- Омогућава подешавање „контекстуалног прозора“, односно омогућава да корисник подеси колико временских корака уназад ће мрежа узимати као референтних за тренирање (Ова могућност подешавања је поготово значајна код периодичних појава, као што је потрошња електричне енергије, која се угрубо креће у 24-часовном циклусу).
- Дељење података, поменуто у ранијем тексту, сада задржава редослед података, омогућавајући мрежи да након тренинга кораке валидације и тестирања одради секвенцијално што доприноси тачности резултата.

Имајући све ово на уму, од ове мреже се могу очекивати квалитетнији резултати од претходне.

2.3.3. NARX мрежа

Nonlinear AutoRegressive network with eXogenous inputs представља највиши ниво сложености мреже обрађиван у оквиру овог рада.

За разумевање принципа рада овог типа мреже неопходно је разумети њен назив. Наиме, ауторегресивни модели су врста модела временских серија, у којима излаз (односно излазна вредност) зависи од претходних вредности у временској серији и случајне грешке, док појам ексогених улаза подразумева спољашње улазе који не припадају разматраној временској серији.[24]

То значи да је ово модел који обухвата претходне вредности разматране временске серије (ауторегресијом), као и спољашње (ексогене) улазе који утичу на разматрану временску серију. Са овиме на уму алгебарски може се записати NARX модел као [25]:

$$y_t = F(y_{t-1}, y_{t-2}, y_{t-3}, \dots, x_t, x_{t-1}, x_{t-2}, x_{t-3}, \dots) + \varepsilon_t \quad (2.1)$$

где су у чланови разматране циљне временске серије, x чланови разматране улазне временске серије (у овој структури може бити и више улазних временских серија), док

слободни члан ε представља грешку[25]. У индексима се налазе временски тренуци где је t временски тренутак који се анализира.

Ова мрежа дели са претходним мрежама основне параметре, као и са претхоном мрежом параметар *inputDelays*, али уводи нови параметар *feedbackDelays*.

Параметар *feedbackDelays* је такође подесив од стране корисника и представља колико временских корака уназад разматране серије ће се користити приликом тренинга. [24] Такође ни ова мрежа нема у себи опцију разматрања датумских вредности за *Delays* (*input* и *feedback*) параметре већ сматра да је временски корак Δt исти.

Са овим на уму, овај тип мреже је способан за предвиђање и моделирање многих динамичких процеса. Као и претходна архитектура, поготово је погодан за процесе у којима је позната периодичност, уз то да је сада могуће разматрати и процесе у којима ће претходне вредности утицати на наредне. Проблем у одређивању тог временског одклона је што је јако тешко проценити, а још теже тачно одредити, након колико времена ће претходне вредности постати релевантне под дејством спољашњих утицаја. Тај проблем није концептуално детаљније анализиран у оквиру овог рада, већ су емпиријски анализирани временски одклони који дају најбоље резултате, о чему ће бити речи у даљем тексту.

У оквиру овог рада, испитиваће се и користити само униформне структуре неуронских мрежа, што подразумева исти број неурона по скривеном слоју, иако програмски пакет *MATLAB* у коме се обављају симулације подржава могућност потпуно произвољног задавања броја слојева и броја неурона по слоју.

3. Резултати

У оквиру овог поглавља биће приказани резултати испитивања прогнозе. Резултати су распоређени по станици која се анализира, у оквиру чега су распоређени према сложености мреже која је коришћена за прогнозу. Имајући на уму опсег доступних података за тренирање, у даљем тексту, ако није наведено друкчије, мрежа је тренирана на подацима од 3. Јуна 2017. до 29. Новембра 2019. године, ово представља тренинг групу:

3.1. Станица Оршава

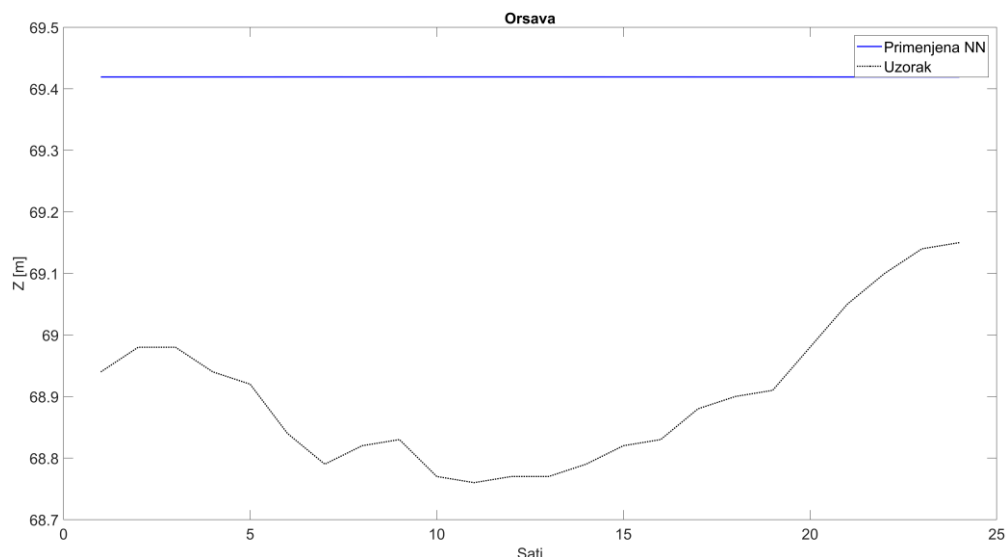
Поштујући распоред приказан у методологији кренуће се од станице Оршава.

3.1.1. Прогноза на станици Оршава коришћењем *Fitnet* мреже

Најједноставнији од анализираних приступа заснива се на *Fitnet* мрежи објашњеној у потпоглављу 2.3.1. и прати прву диспозицију за Оршаву приказану у потпоглављу 2.2. (Слика 7). Структура неуронске мреже која је коришћена је од два слоја по 4 неурона.

Као што је претходно поменуто ова мрежа користи *tan-sigmoid* активациону функцију, која, као што је приказано на слици 13 на оба екстрема асимптотски тежи вредностима 1, односно -1. Ово практично значи да ће она „спљоштити“ улазе у њу у опсег $[-1,1]$, што доводи до тога да ће се вредности које су довољно удаљене од нуле све бити спљоштене у вредност која је приближно 1, односно -1. То представља проблем при тренирању неуронске мреже јер ће као последица тога што су све вредности приближно 1, у мрежи се појавити једна вредност (која зависи од улазних тежинских коефицијената, који су, као што је раније поменуто, насумични у првој итерацији) која ће се јавити као излаз за сваки улаз који се у њу унесе.

Резултати без решавања овог проблема су приказани на симулацији мреже током 30. Новембра 2019. године:



Слика 16 Ненормализовани резултати тренирања мреже

Да би се овај проблем избегао, неопходно је нормализовати улазе и излазе који се прогнозирају. То је урађено према следећој формули [26]:

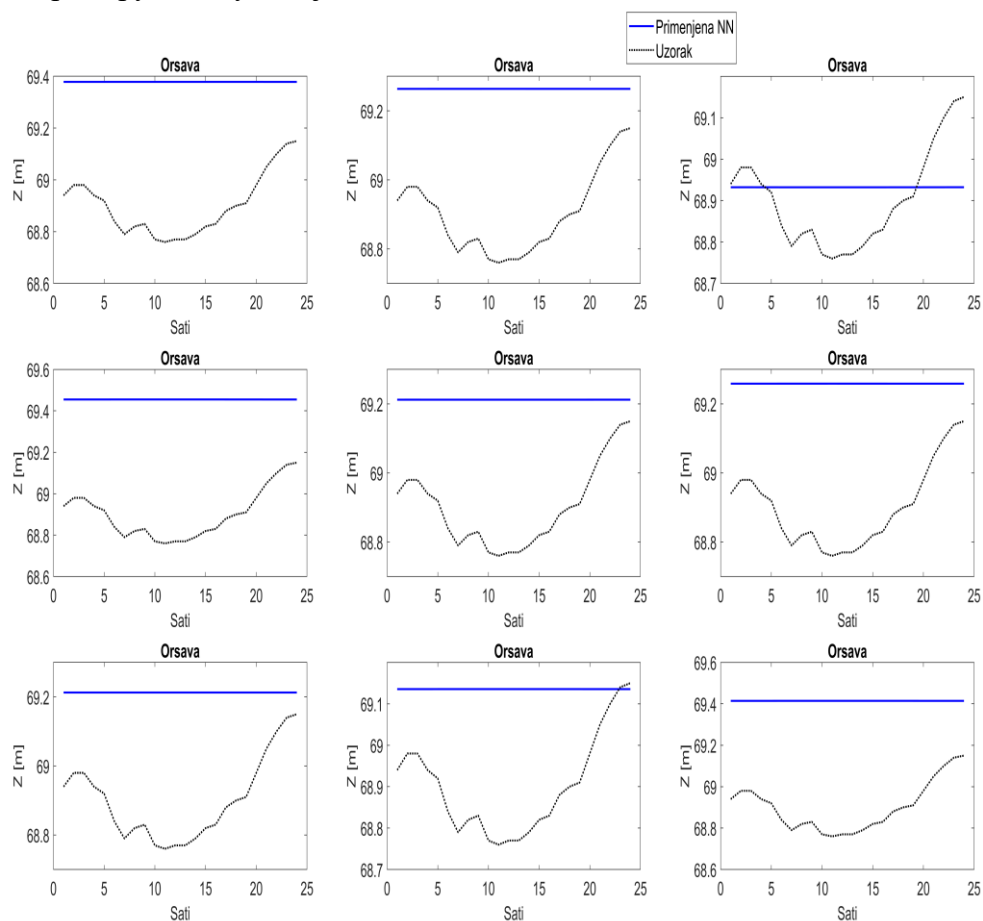
$$X' = \frac{X - \mu(X)}{\sigma(X)} \quad (3.1)$$

где су:

- X' - Нормализоване вредности тренинг групе
- X – Оригиналне вредности тренинг групе
- $\mu(X)$ – Средња вредност оригиналних вредности тренинг групе
- $\sigma(X)$ – Стандардна девијација оригиналних вредности тренинг групе


Треба напоменути да у прорачун средње вредности и стандардне девијације није улазио низ од једног дана који је коришћен за накнадно тестирање мреже.

Понављањем резултата симулације, константна вредност ће се мењати, као што је приказано на примеру 9 симулација на слици :




Слика 17 Ненормализовани резултати тренирања мреже кроз 9 симулација

Када се улази нормализују, резултати су очигледно бољи:



Слика 18 Нормализовани резултати тренирања мреже

Али, није довољно само приказати нормализоване резултате, већ након тренирања и вратити резултате у оригинални облик²:

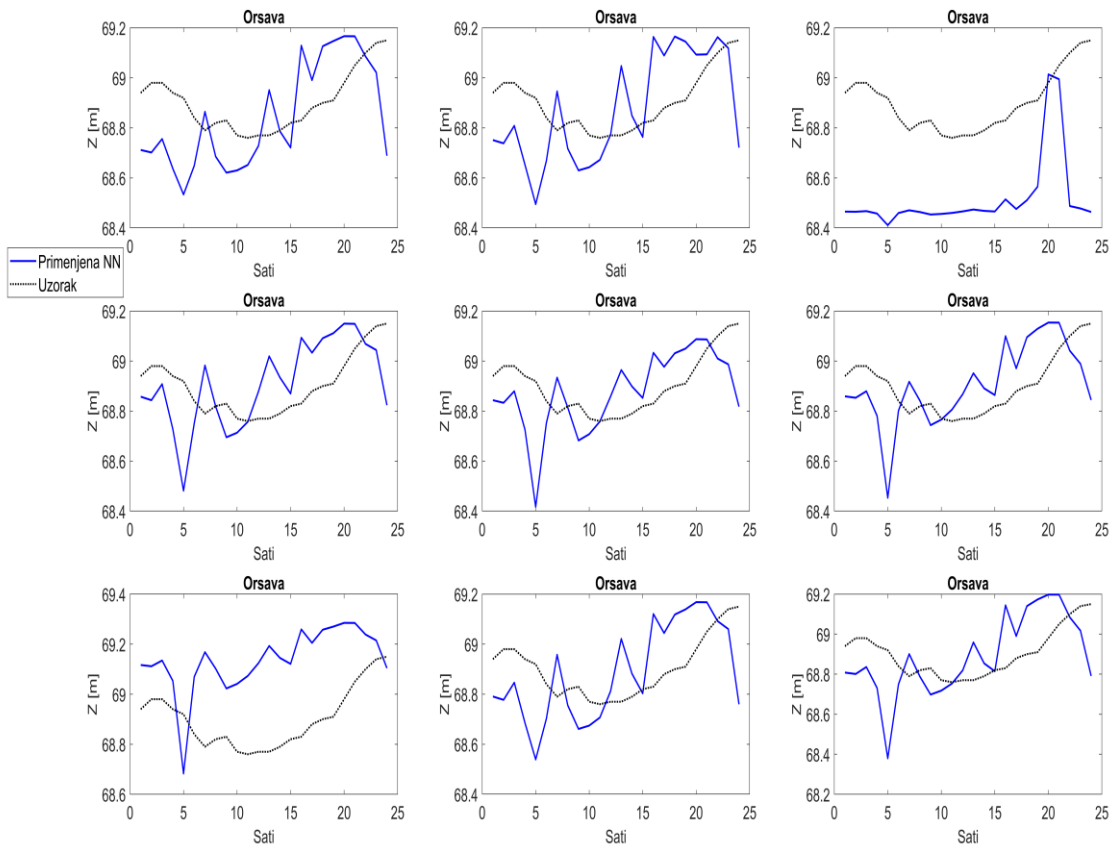


Слика 19 Поправљени нормализовани резултати тренирања мреже

За враћање у оригинални облик коришћена је једначина која је инверзна једначини (3.1).

Приказани су резултати за мањи узорак од 9 симулација, ради испитивања да ли симулација наведена на сликама 18 и 19 јесте или није пример изразито лошег тренинга:

² Јер се као последица нормализације улаза добијају варијације резултата око средње вредности за коју је улаз нормализован



Слика 20 Резултати неколико симулација тренирања *fitnet* мреже

Визуелним прегледом резултата очигледно је да резултати симулација тренд промене прате јако слабо или никако, чинећи ову мрежу неподобном за прогнозирање нивоа у пракси.

3.1.2. Прогноза на станици Оршава коришћењем мреже са одлагањем улаза

У оквиру ове мреже се јавља параметар *inputDelays*, ради што квалитетнијег тренирања, корисно је испитати утицај тог параметра, и које вредности тог параметра, за испитивани случај, дају најбоље резултате. Други параметар који треба испитати је број скривених неурона и број њихових слојева.

Ови параметри су испитивани паралелно, методологија испитивања је следећа: Усвојене су структуре мрежа се које се састоје од 2 и 3 слоја скривених неурона са по 4, 5 и 6 неурона по слоју, укупно 6 слојева, усвојено је 9 могућих вредности параметра *inputDelays* који одговарају до 9 сати уназад (односно за вредност 1, мрежа разматра један претходни сат улаза уназад за тренинг, док за вредност 9, мрежа разматра девет претходних сати за тренирање).

На крају уводи се контрола која се састоји од 10 индивидуалних симулација које ће бити обављене за сваку структуру мреже (као последица насумичног задавања почетних тежинских коефицијената) из којих ће бити одабрана најбоља. Одабир најбоље симулације се врши на основу корена средњег квадратног одступања, у даљем тексту *RMSE* (*Root Mean Squared Error*), који се рачуна за 24 сата након тренинга што представља тест мреже коришћен и у претходној симулацији. *RMSE* је дефинисан као [27]:

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (x - \hat{x})^2}{N}} \quad (3.2)$$

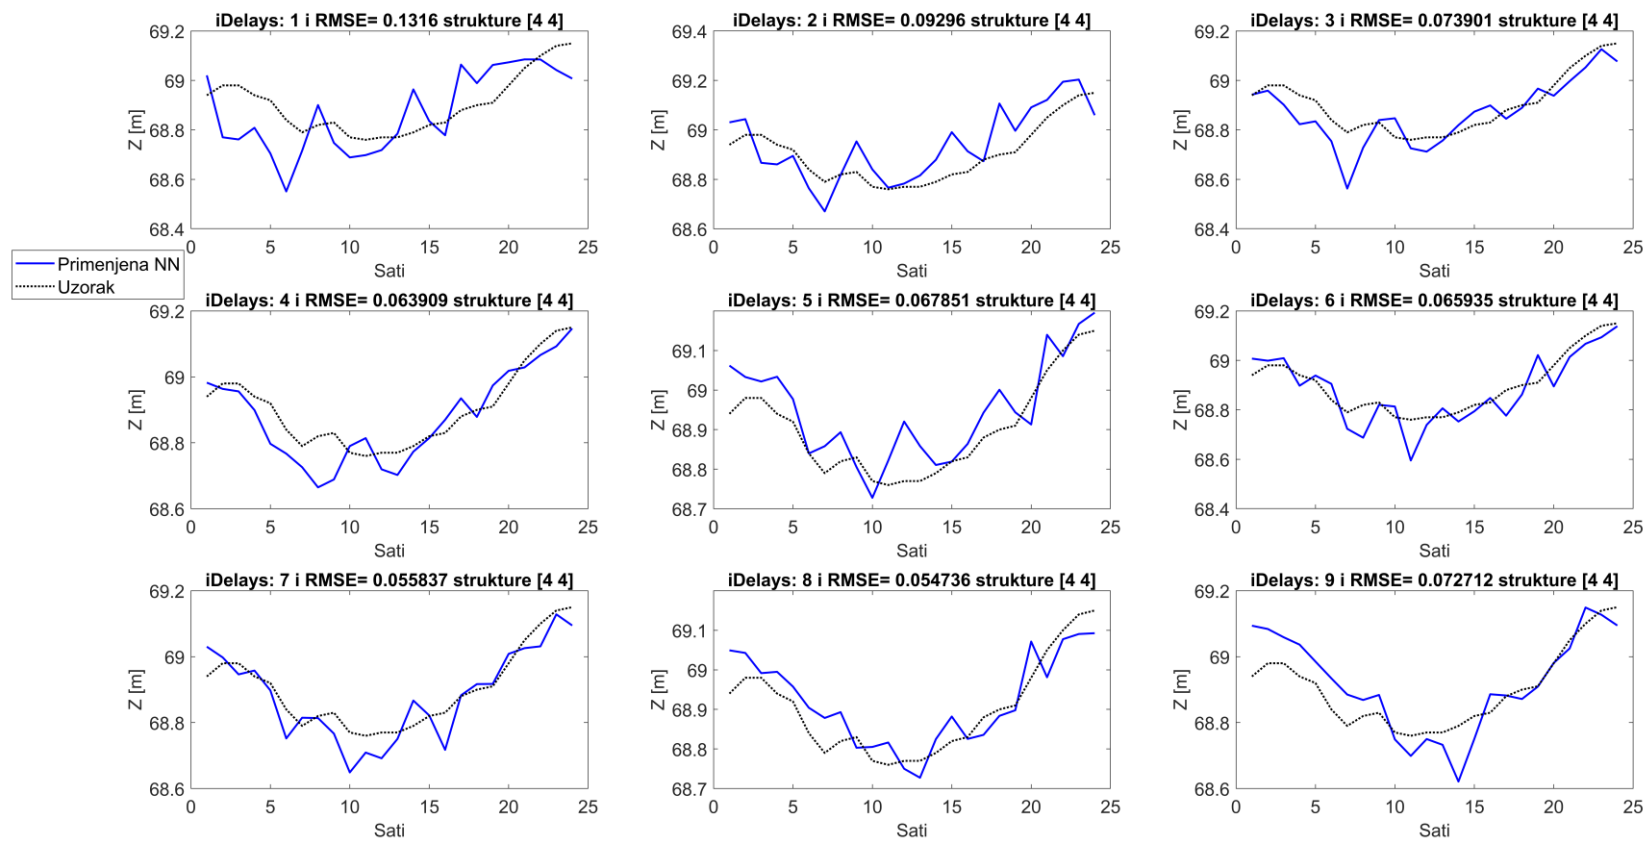
RMSE се користи као критеријум јер испитује одступање у истој јединици у којој је улаз, као и потреба за независном методом која би испитала примену истрениране мреже. Мана ове методе је што не узима у обзир да ли серије које се пореде имају исти облик, што захтева додатну контролу визуелном инспекцијом резултата заједно са разматрањем параметра *RMSE*³. Критеријум *MSE* није могао бити коришћен јер, иако је аутоматски срачунат, он је срачунат само за тренинг групу.

Као и са претходном архитектуром мреже, поново се јавља потреба за нормализацијом улаза због активационе функције (такође *tan-sigmoid*) која се користи и у овој архитектури. Нормализација је одрађена по истим принципима као и за претходну архитектуру мреже.

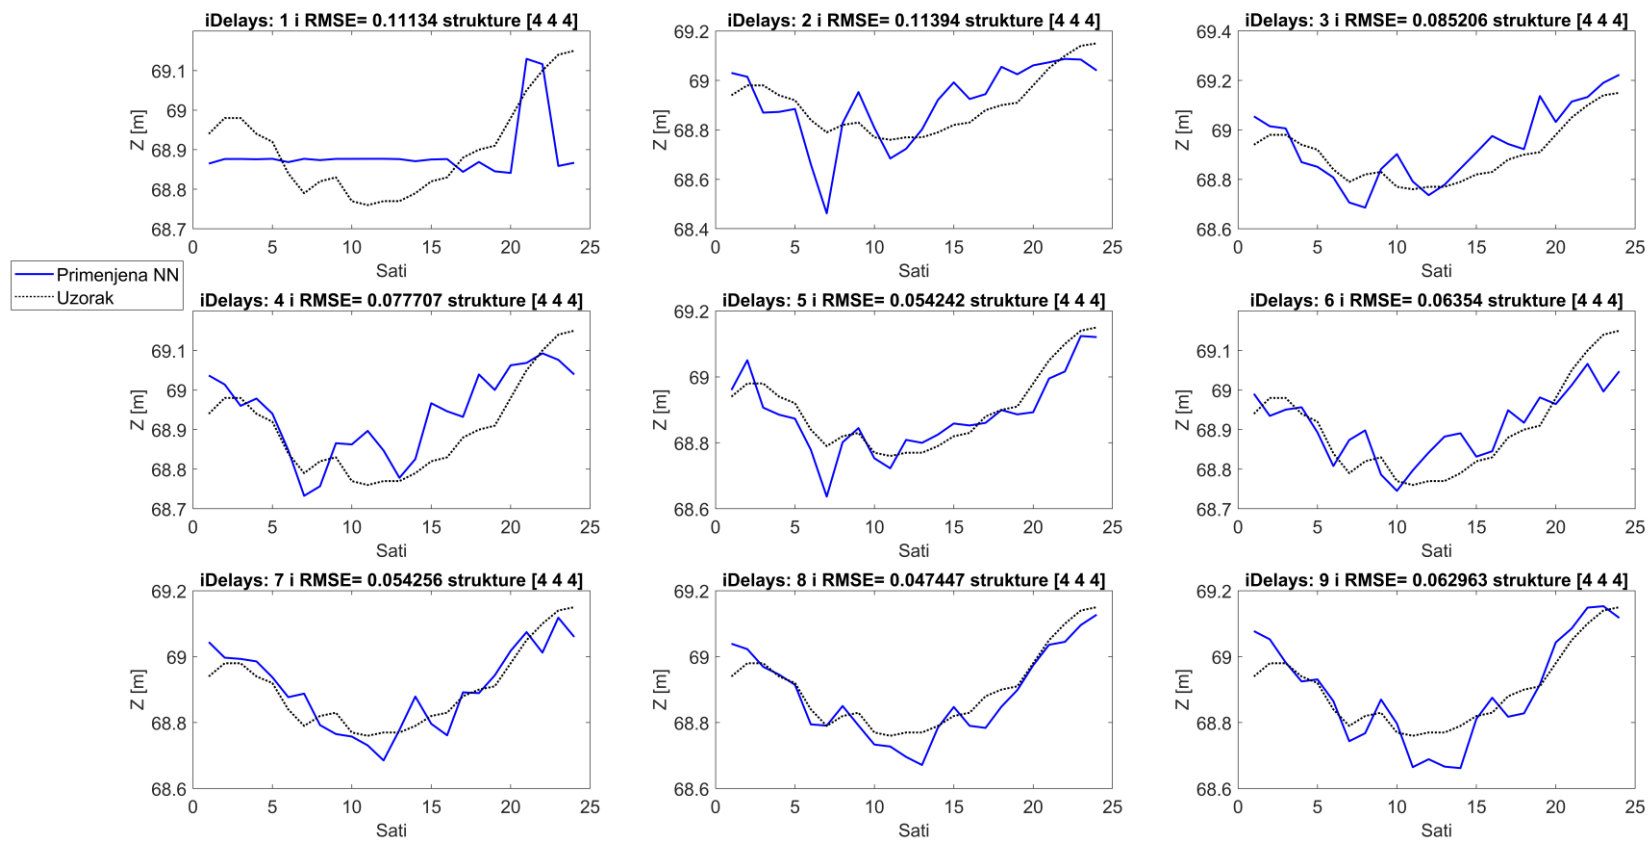
На наредним сликама ознака *iDelays* означава вредност параметра *inputDelays* за дато испитивање, а вредност *RMSE* одговара најбољој мрежи од 10 симулација, која је и приказана.

Резултати овог испитивања приказани су на наредним странама.

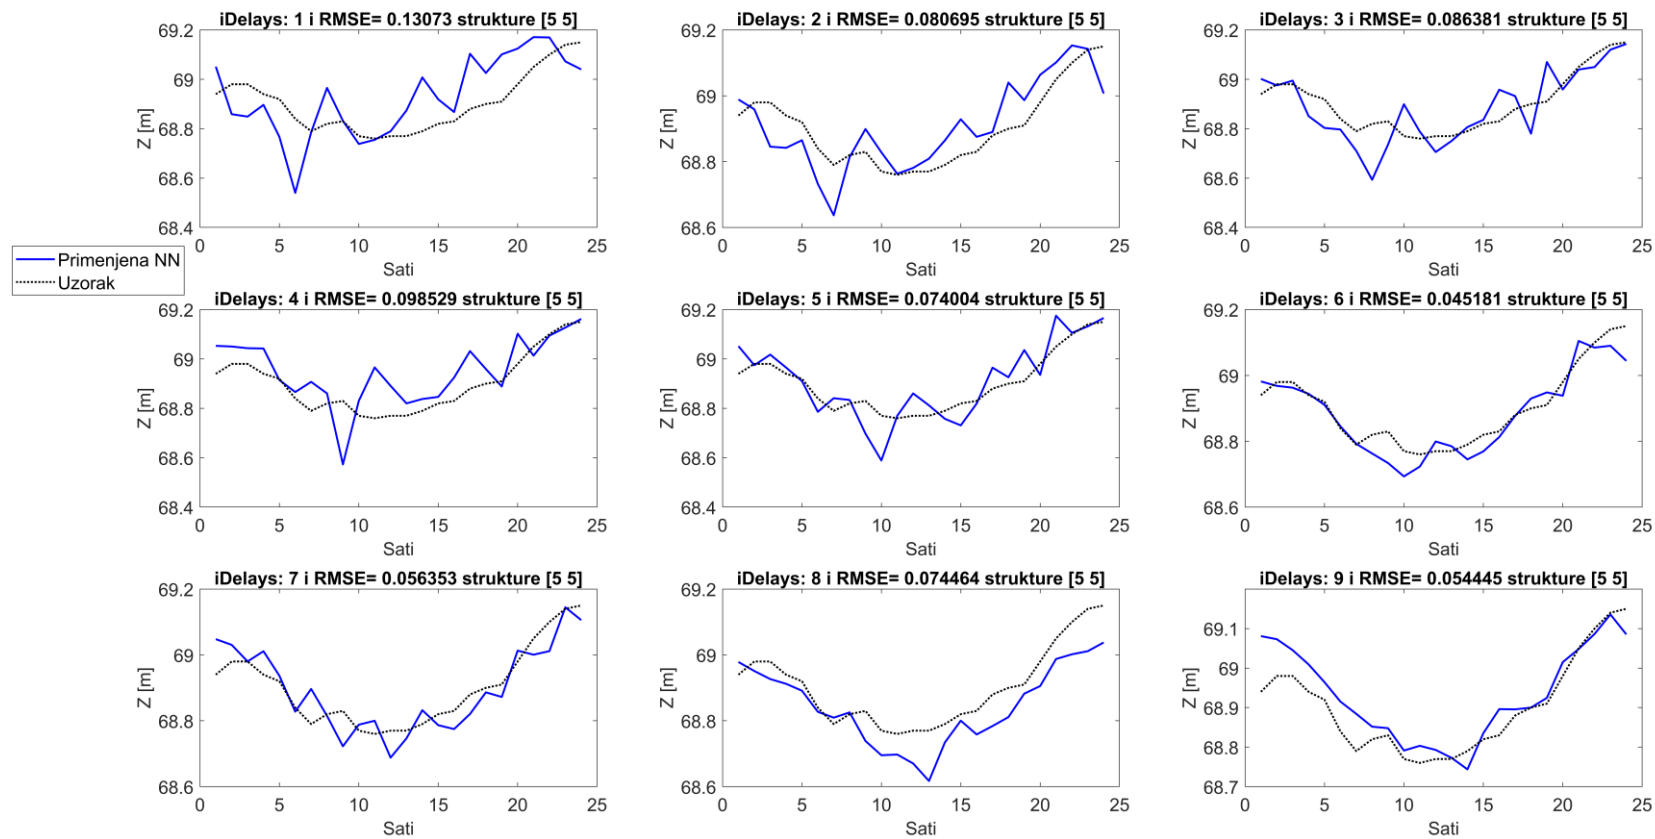
³ Хипотетички је могућа ситуација две симулације са истом вредношћу грешке где се једна слаже са трендом промене нивоа (нпр. Осцилира око нивоа) док је друга права или изломљена линија.



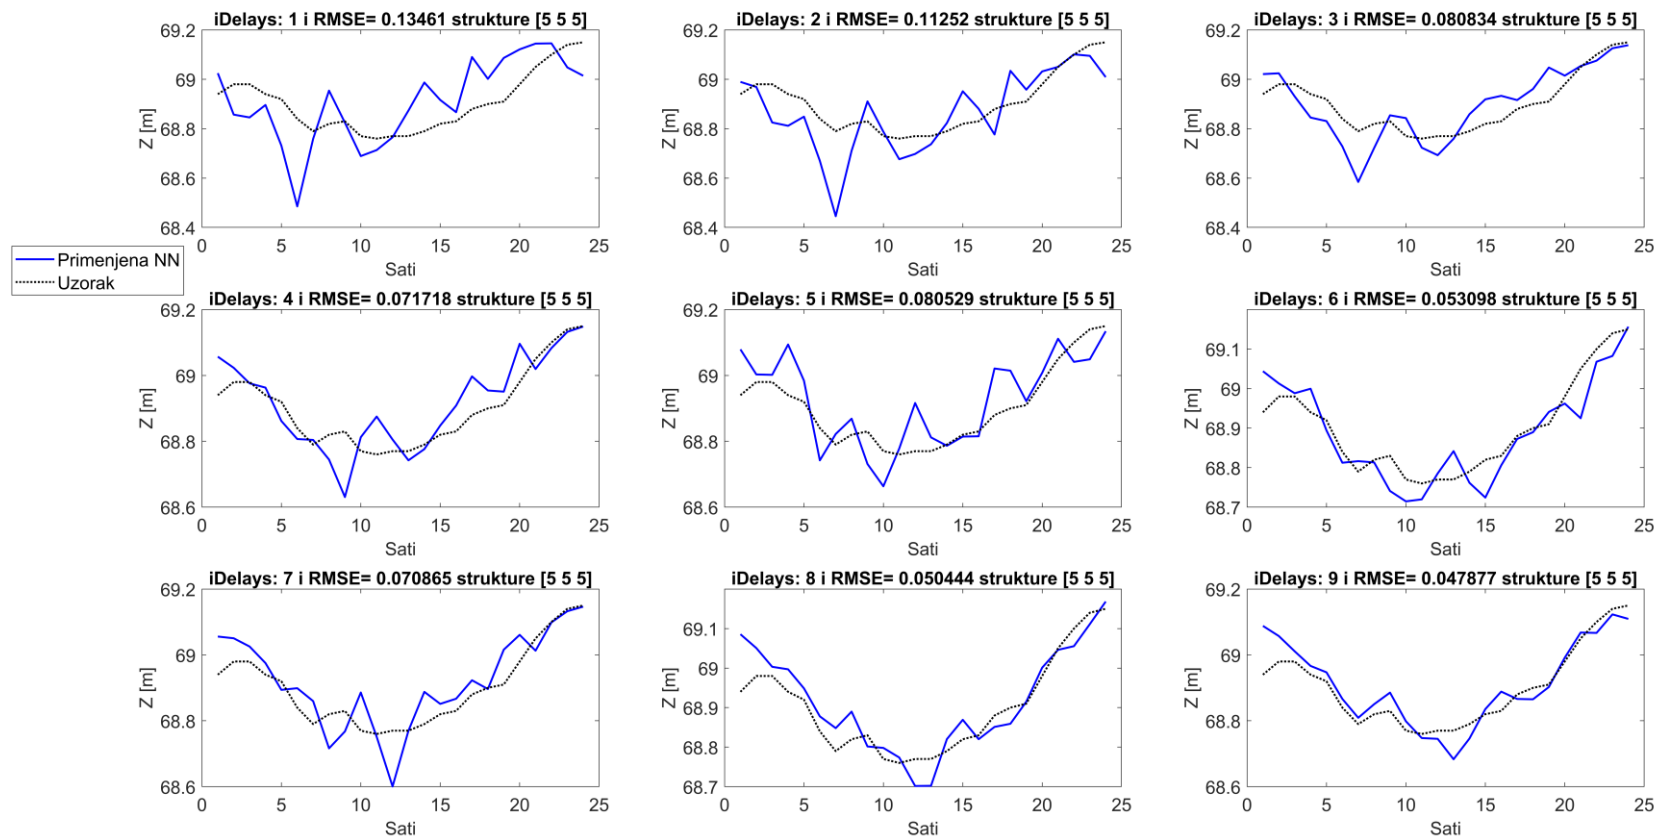
Слика 21 Резултати испитивања параметра за мрежу са одлагањем улаза, за структуру мреже са 2 скривена слоја са по 4 неурона



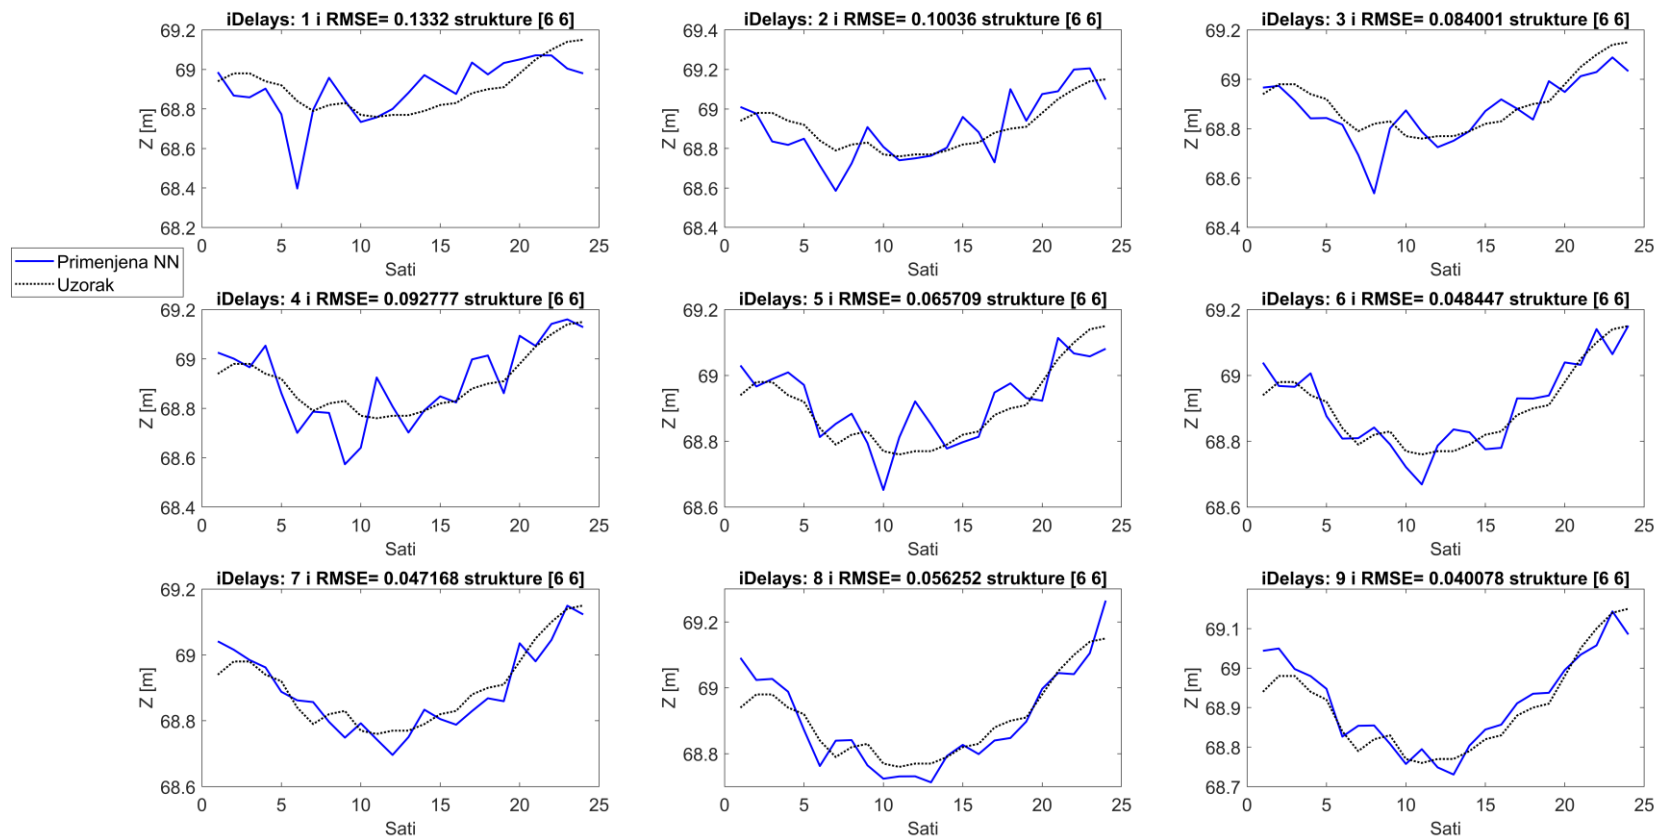
Слика 22 Резултати испитивања параметра за мрежу са одлагањем улаза, за структуру мреже са 3 скривена слоја са по 4 неурона



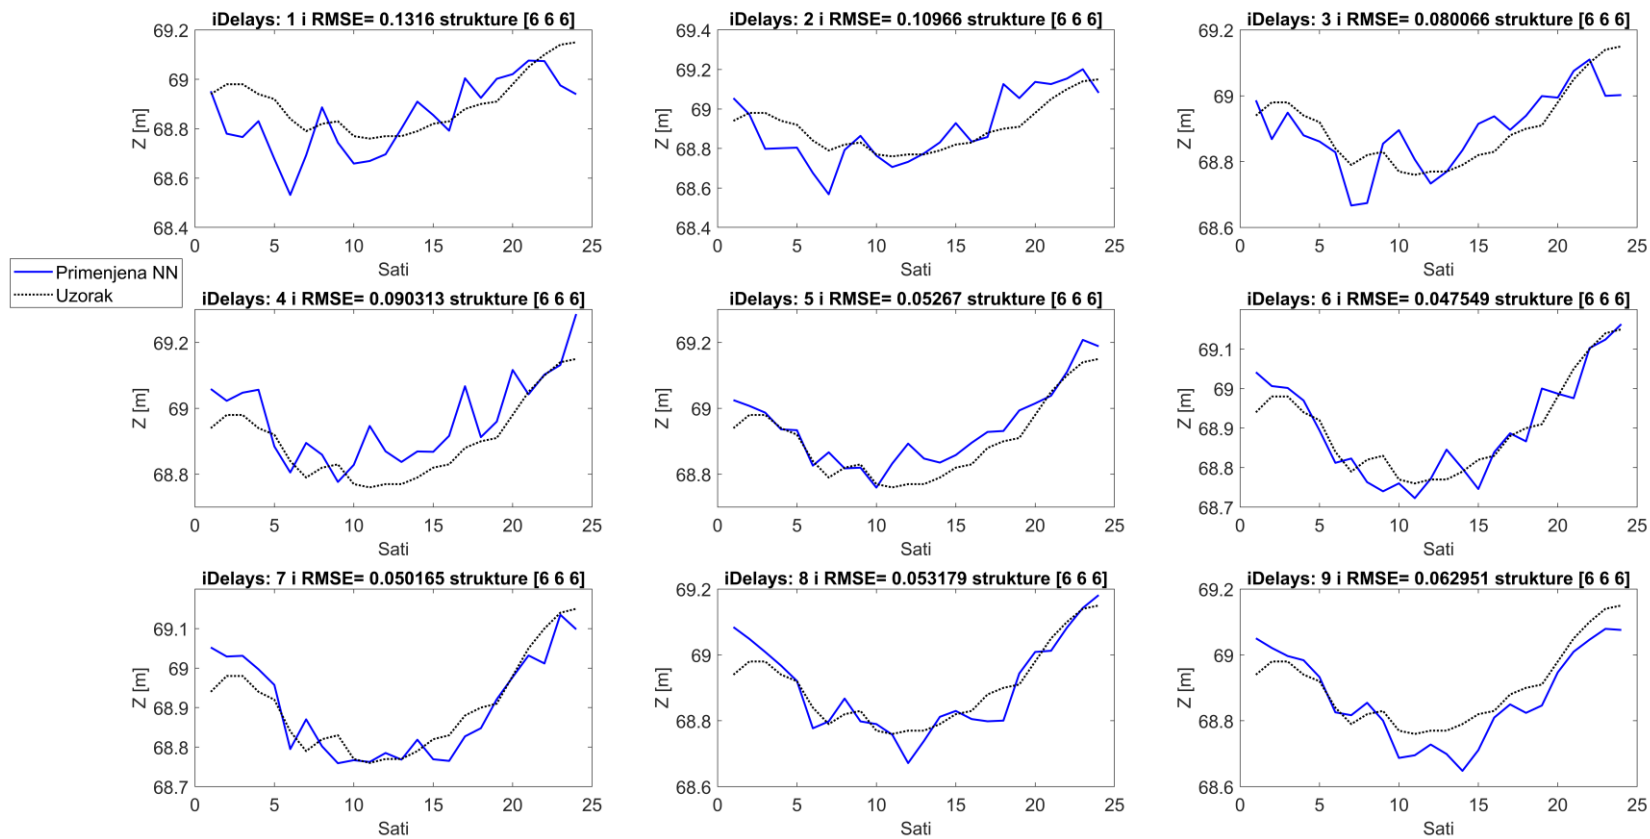
Слика 23 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 2 скривена слоја са по 5 неурона



Слика 24 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 3 скривена слоја са по 5 неурона



Слика 25 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 2 скривена слоја са по 6 неурона



Слика 26 Резултати испитивања параметара за мрежу са одлагањем улаза, за структуру мреже са 3 скривена слоја са по 6 неурона

Визуелним прегледом резултата (иако мрежа показује далеко боље резултате од претходне), као и ниске вредности грешке $RMSE$, интензивне осцилације око измерених вредности чине ову мрежу јако тешко употребљивом у инжењерској пракси. Додуше, могуће је користити ову мрежу за грубу процену, поготово након накнадног третирања резултата (нпр. коришћењем путујуће средње вредности (*filter moving average*) [28]) али не за детаљну анализу. Али суштина овог рада је да испита способност прогнозирања помоћу истрениране мреже са одређеном тачношћу, тако да накнадна третирања ове архитектуре неће бити рађена у оквиру овог рада.

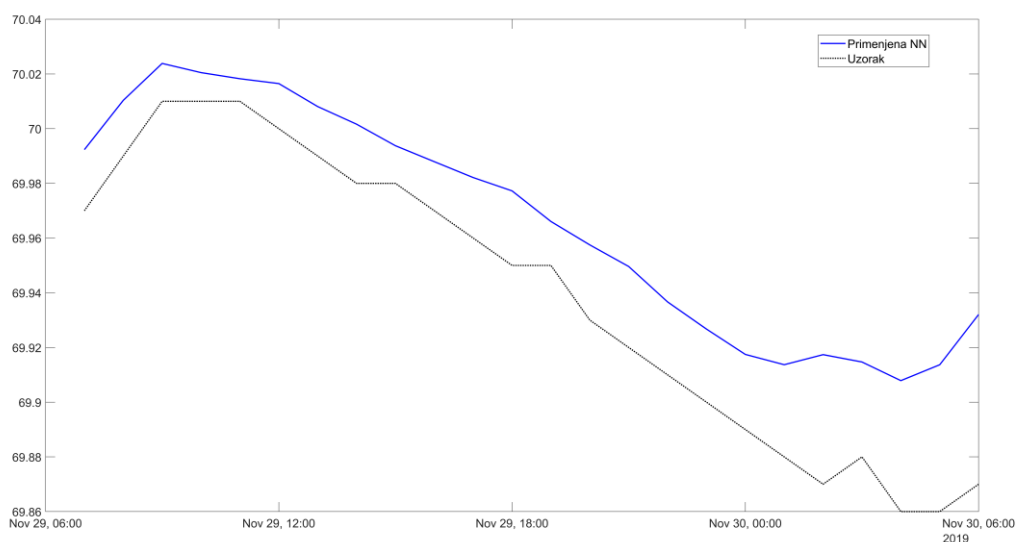
Ова мрежа по својој дефиницији омогућава само један улаз у мрежу, као последица тога, она се неће разматрати на станици Нера због више утицаја који се јављају на тој станици.

3.1.3. Прогноза на станици Оршава коришћењем $NARX$ мреже

Као што је поменуто раније, у овој мрежи се уводи параметар *feedbackDelays*, тако да је неопходно испитати и тај параметар. Ова испитивања одговарају другој диспозицији модела за прогнозу на Оршави (слика 8).

Принцип испитивања је сличан принципу из претходног случаја, само што се уместо структуре мреже, која ће бити фиксна, варирају параметри *inputDelays* и *feedbackDelays*. Структура мреже са којом ће се радити испитивања параметра су 2 скривена слоја са по 4 неурона. Као и у прошлом случају, за сваку вредност параметара обавиће се по 10 симулација, затим ће бити одабрана најбоља симулација од тих која ће бити приказана, по истом критеријуму као и у претходном случају, односно $RMSE$.

Треба напоменути да се код ове мреже, при примени истрениране мреже на новим подацима, јавља померај резултата. Наиме, симулација прати тренд узоркованих података, али је „склизнута“ у односу на узорковане податке. Та ситуација је приказана на наредној слици:



Слика 27 Демонстрација помераја резултата

Тај проблем се заобилази у фази постпроцесирања мреже, где се на основу резултата неуронске мреже срачунају прираштаји нивоа, који се додају на последњи измерени

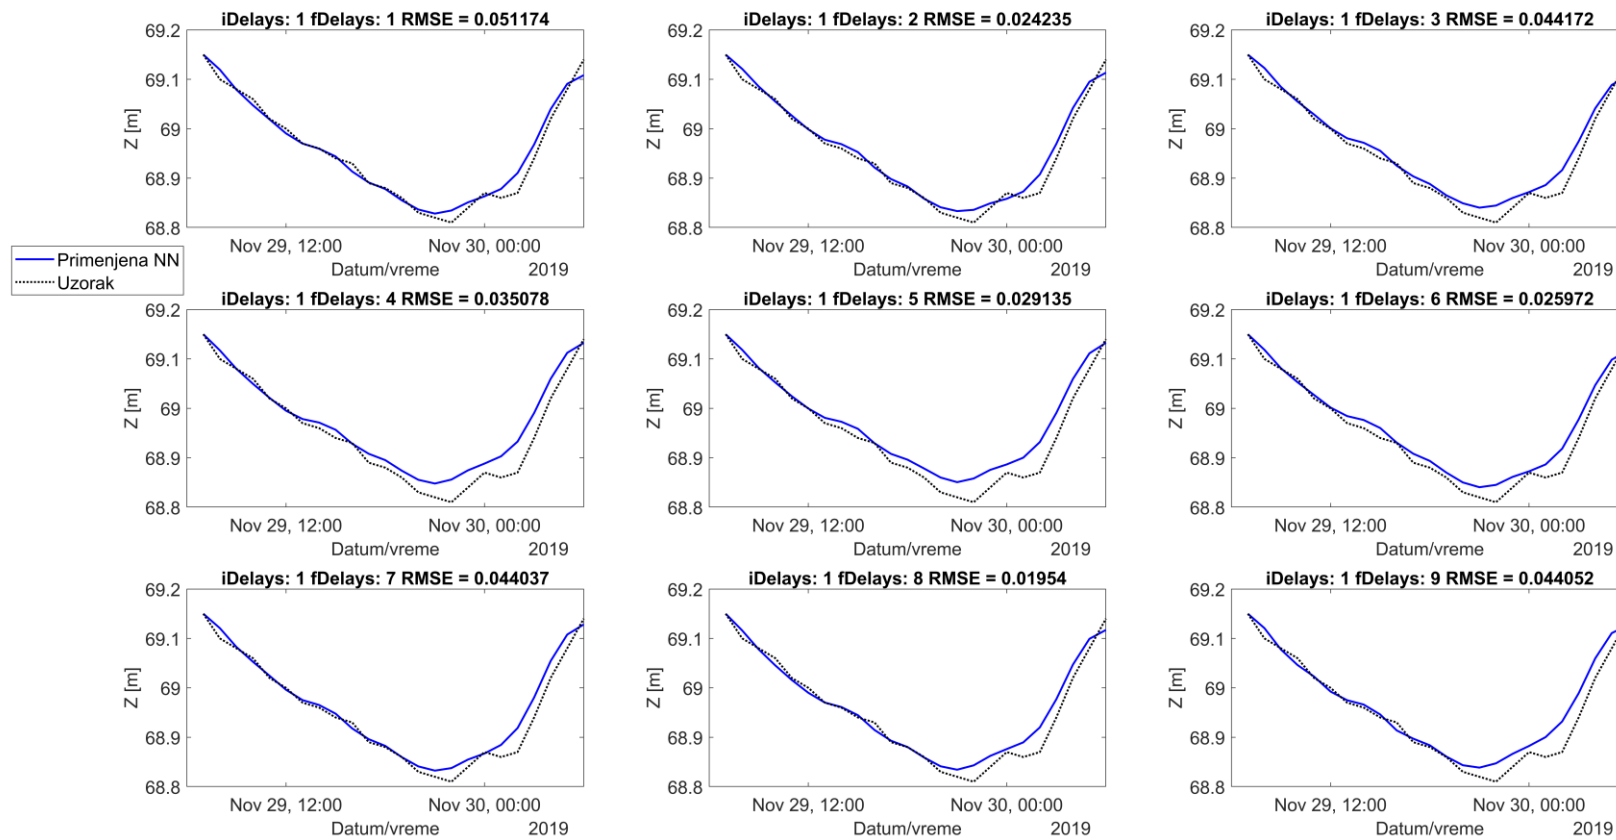
податак. У наредним коришћењима *NARX* мреже, подразумева се да је ова корекција извршена.

3.1.3.1. Испитивање параметара

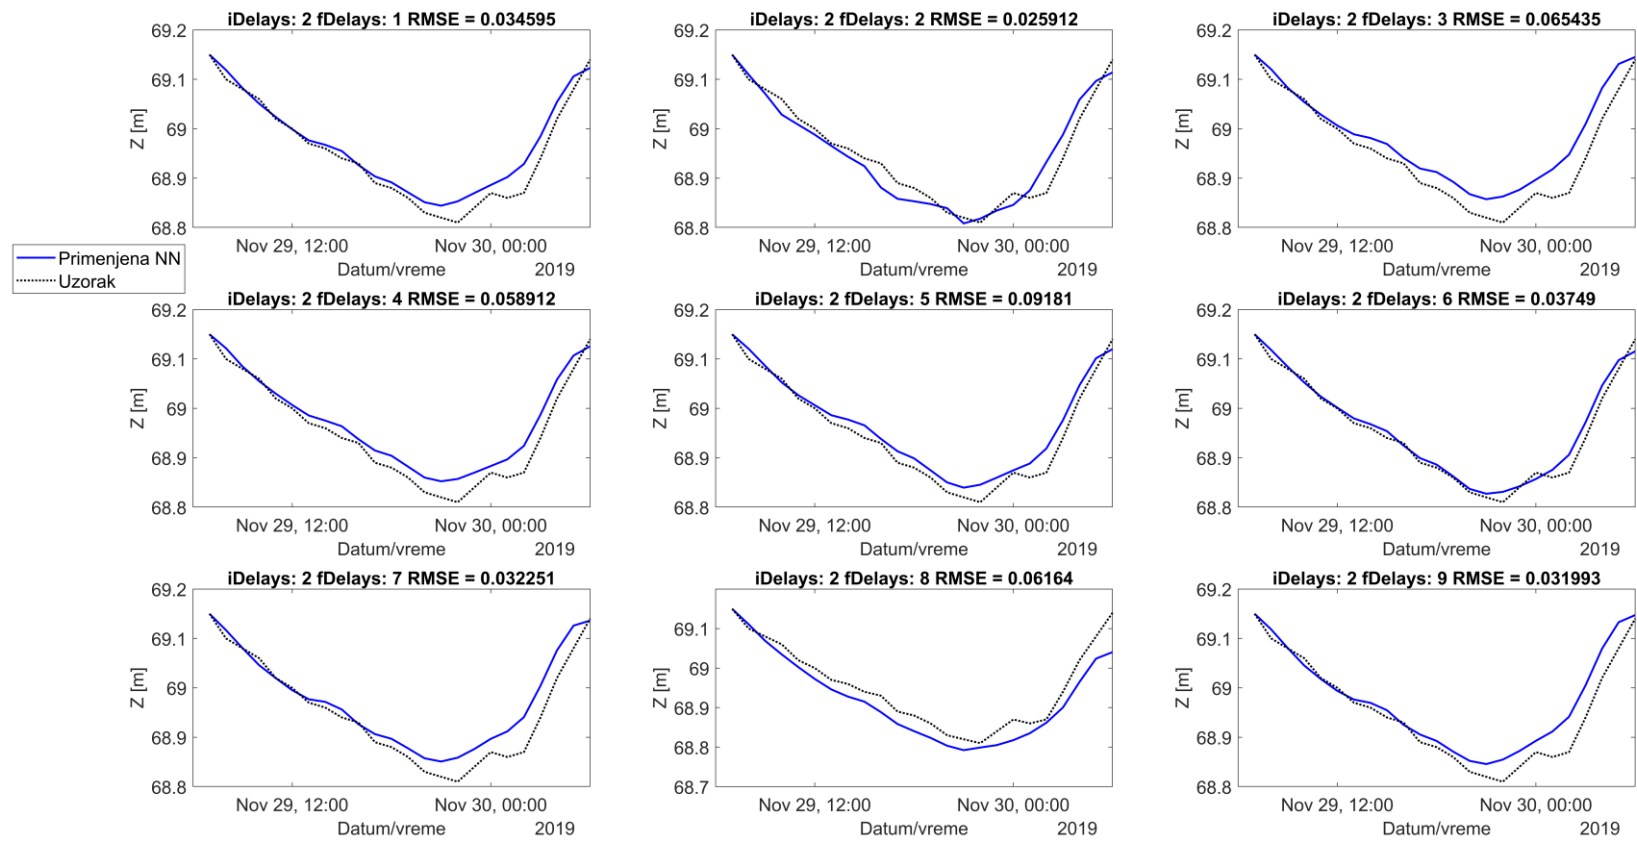
Обухватиће се 3 вредности за испитивање *inputDelays* које су 24, 48 и 72 што представља број сати (1, 2 и 3 дана респективно) уназад из скупа улазних података (протоци кроз ХЕ) која ће мрежа разматрати, док ће се за *feedbackDelays* разматрати вредности од 1 до 9, овај параметар је објашњен у ранијем тексту. Ово ће потенцијално представљати почетну фазу испитивања, јер у случају да се резултати буду побољшавали са повећањем вредности параметра повећаће се разматрани опсег параметара.

Параметри и структура мреже који се покажу као најбољи у оквиру овог испитивања могу се усвојити и за прогнозирање на станици Нера.

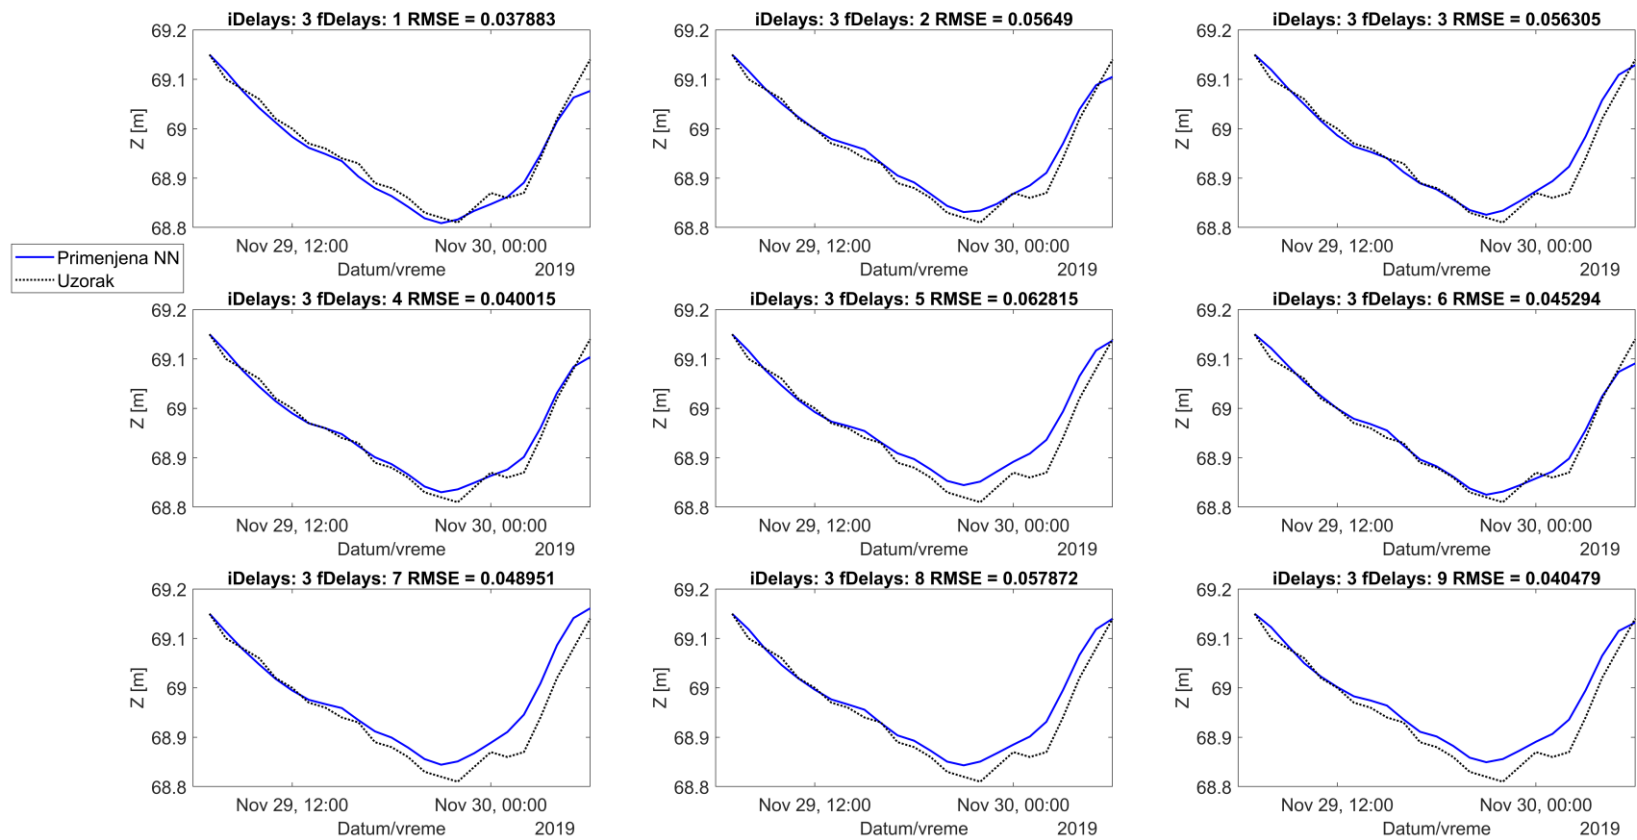
У оквиру назива сваког графикана ознака *iDelays* означава вредност *inputDelays* у данима, ознака *fDelays* означава вредност *feedbackDelays* у сатима; у наслов је такође уписана и вредност *RMSE* ради прегледности резултата.



Слика 28 Резултати испитивања параметара за NARX мрежу, за 1 дан временског отклона улаза



Слика 29 Резултати испитивања параметра за NARX мрежу, за 2 дана временског отклона улаза



Слика 30 Резултати испитивања параметра за NARX мрежу, за 3 дана временског отклона улаза

Очигледно је да су резултати далеко побољшани коришћењем ове архитектуре мреже. Са овом архитектуром симулирана мрежа прати скоро савршено снимљени тренд промене нивоа на станици, уз варијације у другој половини симулираног дана.

Са повећавањем параметра *inputDelays* не јавља се повећање тачности симулације, штавише, највећа тачност се јавља са најмањом испитиваном вредношћу, сходно чему нема потребе за даљим испитивањем овог параметра.

Са повећањем параметра *feedbackDelays* такође се не види никакво значајно побољшање, сходно чему нема потребе за даљим испитивањем овог параметра.

Може се донети закључак да се ова архитектура мреже показује као најбоља у решавању оваквих проблема што је евидентно из приложених резултата. Сада се поставља питање које вредности параметара треба усвојити ради највеће тачности за ово, и даља испитивања. За вредност *inputDelays* одговор се сам намеће, па ће се усвојити вредност параметра 1, односно 24 сата. За вредност параметра *feedbackDelays* на питање је нешто теже одговорити. Наиме, за било коју вредност тог параметра, грешка не прелази 10 см (као што је раније поменуто, *RMSE* је у јединици испитиваног низа, тј метрима, па се може третирати као грешка при симулацији⁴), уз то да се већина грешака (тачније 22 од укупно 27) креће у распону од 2 до 6 см. У оквиру овог рада додуше, неће се даље анализирати овај параметар већ ће се за потребе даљих симулација усвојити директно вредност параметра *feedbackDelays* која је дала најнижу вредност грешке, која важи *feedbackDelays* = 8, што представља и вредност која ће бити усвојена.

Резимирајући ова испитивања, наводи се да ће да у даљим испитивањима бити усвојена вредност параметра *inputDelays* = 24 и вредност параметра *feedbackDelays* = 8.

Наравно, оваква тачност у резултатима се не очекује при сваком покретању неког броја симулација, због променљивости у почетним тежинским коефицијентима, али ова испитивања су добар показатељ константности тренинга и препорука за усвајање у даљим анализама и испитивањима. Са повећањем броја симулација и усвајањем најбољих неминовно ће се доћи до бољих резултата. За потребе почетне анализе, свакако, не би представљало значајну грешку усвајање било ког од параметара који су испитивани овде.

3.1.3.2. Испитивање дужине тренирања

Корисно је размотрити и утицај дужине тренирања за овакву мрежу, иако се ту одговор сам намеће: да ће се са већим скупом података побољшати прогноза, ово испитивање свакако представља корисне информације за потребе даљег истраживања.

За ово испитивање коришћени су параметри усвојени у претходном тексту. Поново коришћењем најбољих од 10 симулација.

За испитивање дужине тренирања, 2 и по године доступне за тренинг издељене су у блокове од приближно 6 месеци инкремента од почетног тренутка серије доступне за тренинг, који је 3. Јун 2017. године. Ефективно то значи да су коначне испитиване дужине тренирања:

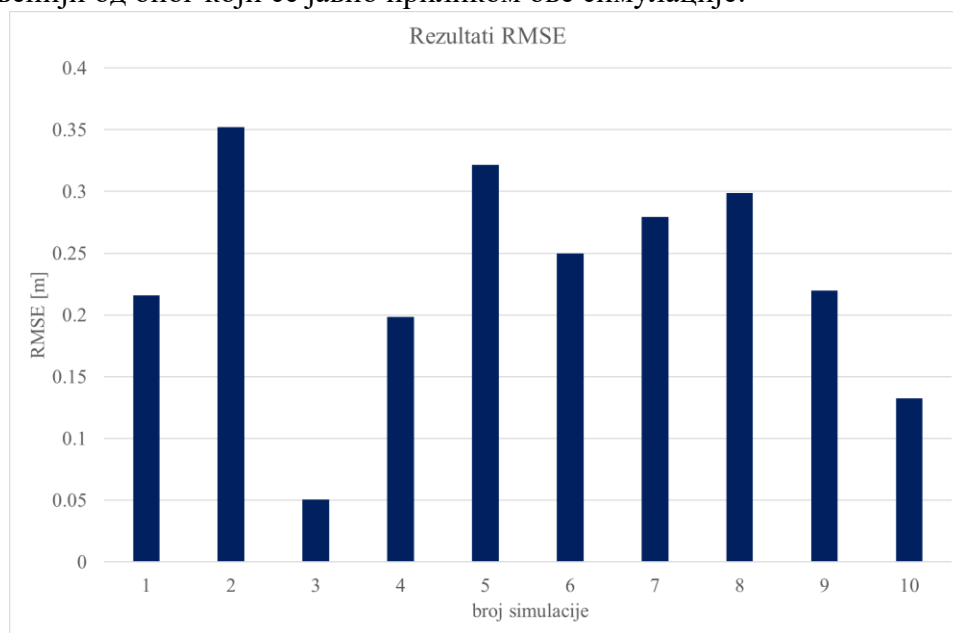
- 1. Јануар 2018.

⁴ Практично се може размишљати о вредности параметра *RMSE* као о другом низу који је идентичан узоркованом, само померен по ординати за вредност параметра *RMSE*

- 1. Јул 2018
- 1. Јануар 2019.
- 1. Јул 2019.
- 29. Новембар 2019. (што уједно представља и крај низа доступног за тренирање)

Резултати испитивања приказани су на следећој страни.

Испитивањем дужине тренирања потврђује се почетна претпоставка, која је да ће се са повећањем дужине тренинга, побољшати квалитет резултата, изненађујућ резултат, у томе да је тренирање до Јула 2018 показало боље резултате од тренирања до 1 Јануара 2019 и 1 Јула 2019. То се објашњава тиме да су резултати у 10 симулација у просеку доста удаљенији од оног који се јавио приликом ове симулације:








Слика 31 Резултати RMSE током 10 симулација

Из ових резултата се види да је случај јављања оволико ниског *RMSE* инцидентан, док се из претходних резултата тестирања параметара види да се толико ниске грешке јављају устаљено, док овде представљају инцидентан случај.

Ово представља добру прилику за дискусију о инцидентно добрим резултатима: Код таквих резултата неопходно је проверити остатак резултата симулације да се види да ли инцидентни резултат испада из опсега грешке у којима се крећу остали резултати. Разлог за израз „инцидентни“ резултат потиче из тога што су такви резултати спој многих случајности инхерентних процесу тренирања неуронских мрежа, почевши од тежинских коефицијената, преко података који су коришћени за тренинг и одабира података на који се примењује истренирана мрежа, па све до појаве случајног *overfit*-овања поменутог у ранијем тексту.

Рационално је претпоставити да применом ове мреже на наредних 24 сата се неће добити ни близу толико добри резултати колико су добијени на изабраном тренутку, баш као последица *overfit*-ованих резултата. Иако овакви резултати представљају интересантну тему за даље истраживање, у погледу домена њихове употребе, потенцијално дотрениравање ради побољшања домена употребе итд, они неће даље бити разматрани у оквиру овог рада.



— Primenjena NN
..... Uzorak

Слика 32 Резултати испитивања дужине тренирања

3.1.3.3. Испитивање структуре мреже

За крај, неопходно је испитати која структуре неуронске мреже даје најбоље резултате. Усвојени параметри су:

- *inputDelays*: 24 часа
- *feedbackDelay*: 8 часова
- Дужина тренирања: до 29 Новембра 2019
- Критеријум за усвајање је *RMSE*


За потребе испитивања структуре која ће бити усвојена, коришћене су исте потенцијалне структуре као и у случају мреже са одлагањем улаза, уз додатак да је пронађена најбоља од 20 симулација.

Резултати испитивања су дати на наредној страни.

Из резултата је очигледно да су најбоље резултате показале мреже са 3 скривена слоја са по 4 и 5 неурона по слоју, као и мрежа од 2 скривена слоја са по 6 неурона по слоју. Строго поштујући критеријум усвајања, усвојиће се структура са 3 скривена слоја са 5 неурона по слоју.

Са свим испитаним параметрима, строго поштујући критеријуме усвајања, за даље прогнозе на станици Оршава препоручује се усвајање следећих карактеристика мреже:

- *inputDelays*: 24 часа
- *feedbackDelay*: 8 часова
- Структура мреже са 3 скривена слоја са 5 неурона по слоју; поштујући *MATLAB* номенклатуру, то је представљено као: [5 5 5]



Слика 33 Резултати испитивања структуре мреже

3.2. Станица Нера

Као што је поменуто, станица Нера је довољно удаљена од ХЕ да се не може претпоставити да је она главни катализатор поремећаја нивоа на тој станици; ова чињеница у комбинацији са резултатима испитивања на станици Оршава, која су показала да једноставније архитектуре неуронских мрежа нису способне да предвиде промену нивоа чак ни када је ХЕ главни катализатор промене нивоа, доводи до тога да се прва диспозиција описана у оквиру методологије на слици (односно диспозиција где се тражи веза између промена на ХЕ и поремећаја нивоа на станици Нера) неће ни разматрати.

За потребе читавог испитивања на станици Нера користиће се *NARX* мрежа, због претходно показаних осцилација око узоркованих нивоа. Испитивање ће бити обављено као и у претходном случају, испитивањем параметара и структура мреже, уз то да ће бити анализирана најбоља од 20 симулација за сваки пар параметара, односно за сваку структуру када буду одређени вредности параметара са најмањом грешком. Прво ће се испитати улази и параметри, затим ће се испитати структура, тако да ће за потребе испитивања улаза и параметра бити усвојен елементарни облик дубоког учења који је структура са 3 скривена слоја од по 5 неурона.

Једино што неће бити разматрано у оквиру ових испитивања је дужина тренирања, одлука која је поткрепљена испитивањима дужине тренирања обављеним на станици Оршава.

Када се у даљем тексту буду описивали улази, бројаће се само спољашњи (ексогени) улази у мрежу.

3.2.1. Прогноза на станици Нера са једним улазом

Ова прогноза одговара диспозицији 2 где је улаз у мрежу за станицу Нера протицај на ХЕ.

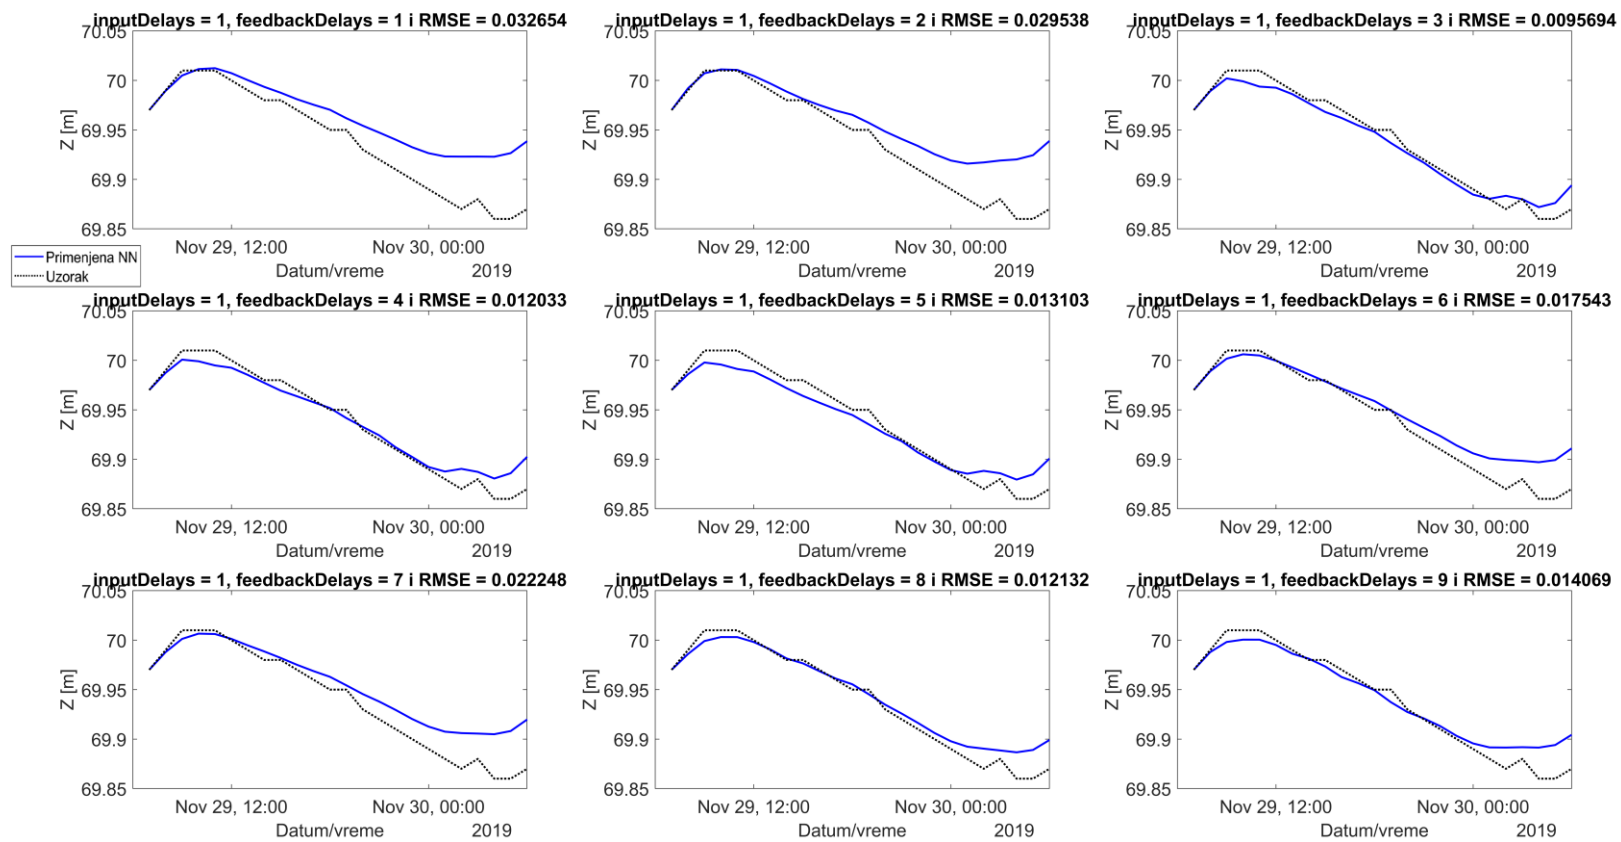
Прво ће се обавити испитивање *Delays* параметара објашњених у претходном тексту.

Резултати су дати на наредној страни.

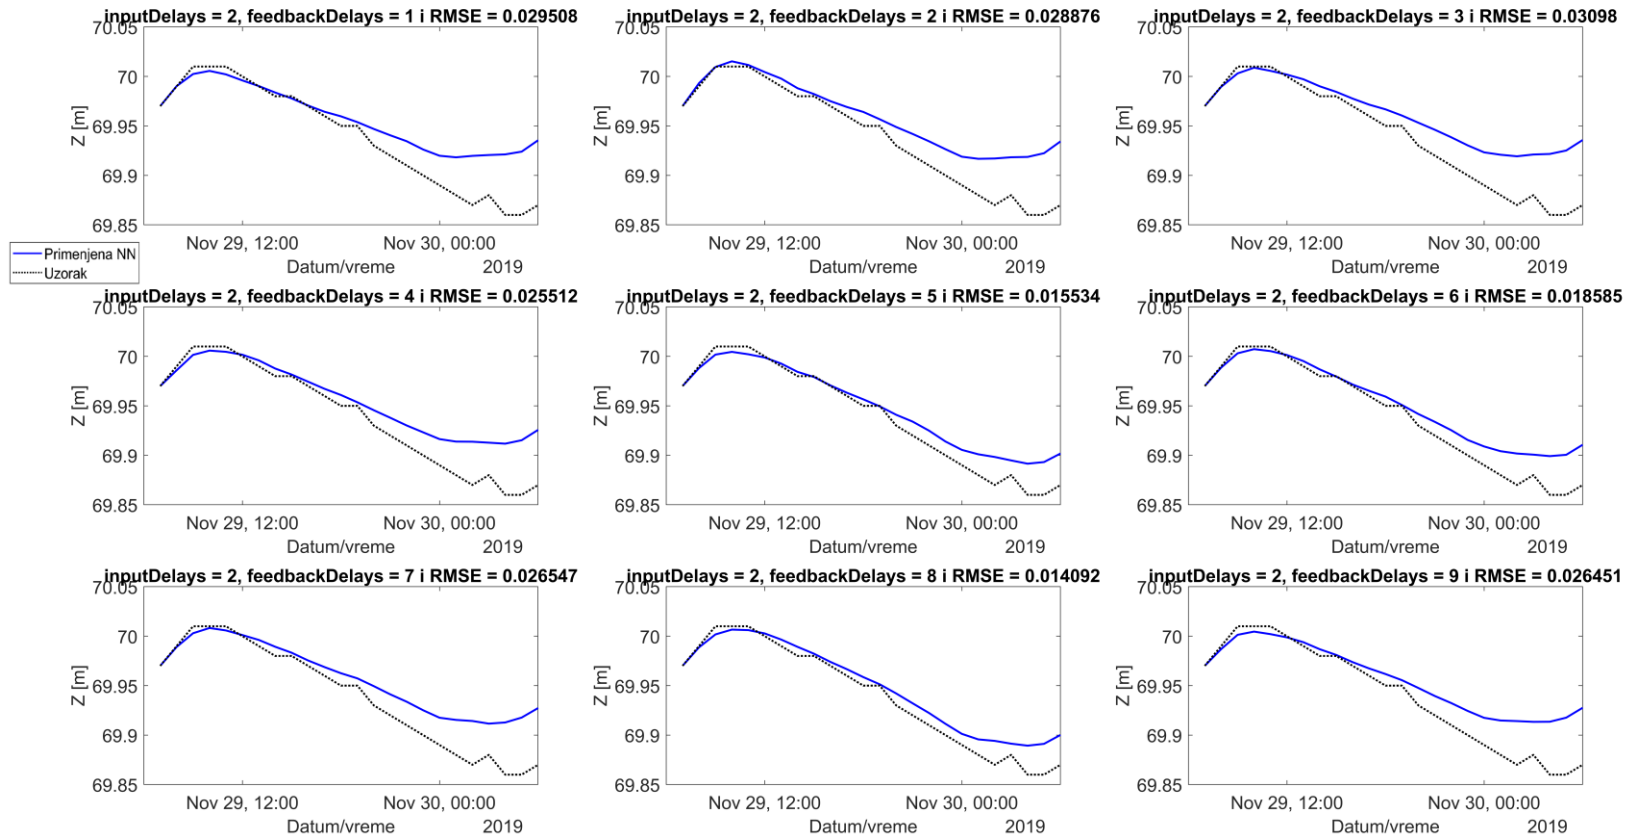
Као што је и очекивано, овај вид прогнозе не даје добре резултате у погледу прогнозирања као последица тога што протицаји на ХЕ нису главни узрок промена на станици Нера.

Грешке применом овог вида прогнозе најмање су за *inputDelay* = 1 дан, где је за свих 9 вредности параметра *feedbackDelays* средња вредност: 0.014 m.

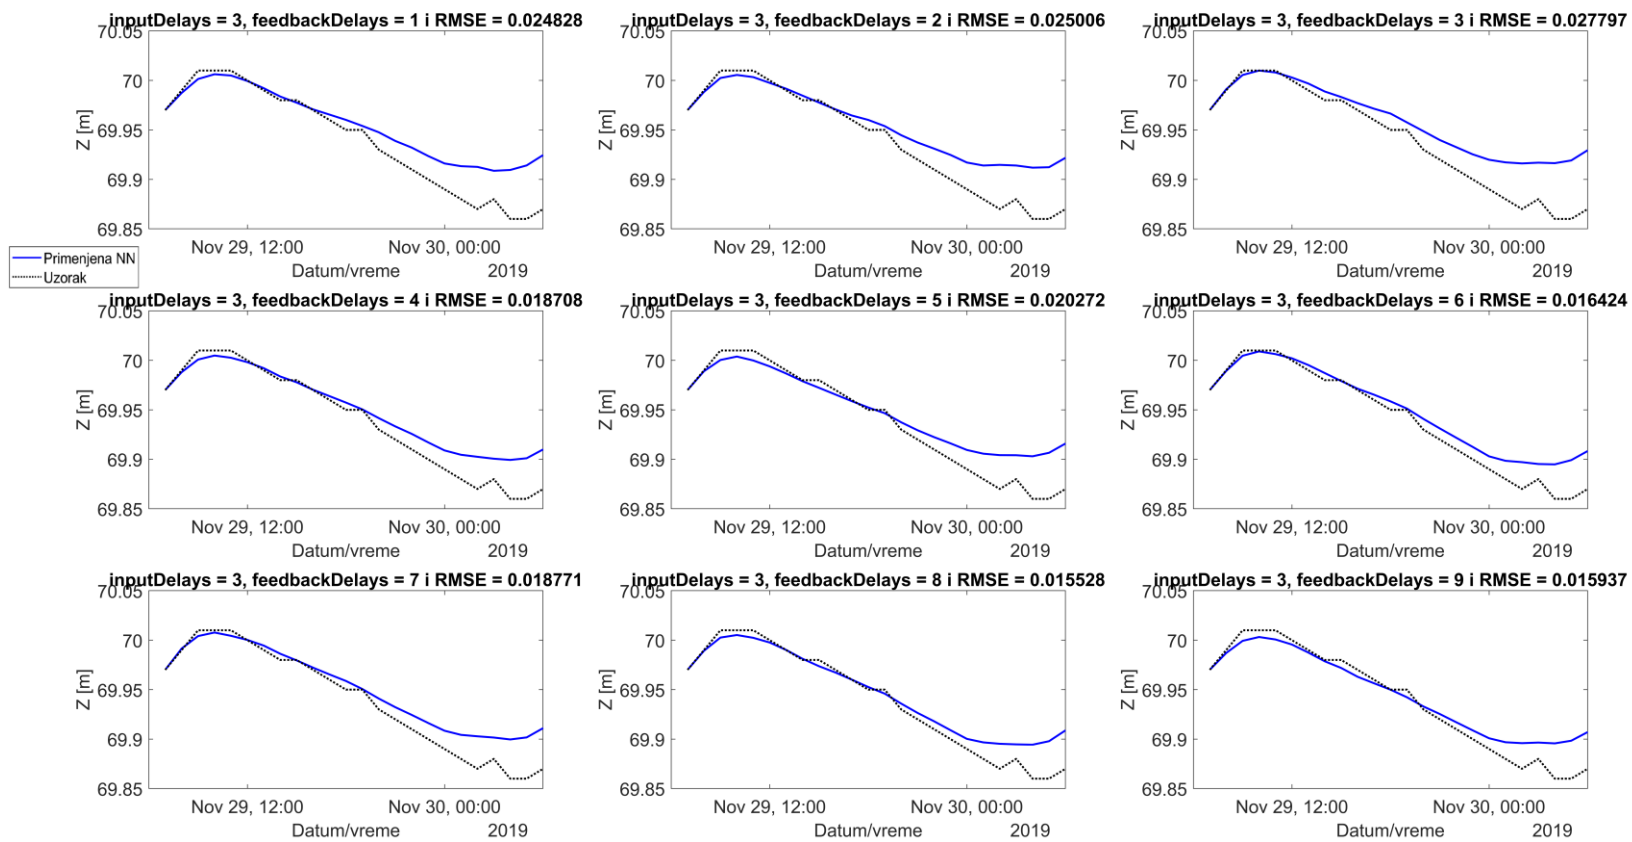
Средња вредност грешке за све вредности оба параметара за овај случај износи 0.0185 m, глобални минимум је 0.006 m, док је највећа грешка која се јавила износила 0.032 m.



Слика 34 Резултати испитивања параметара мреже за станицу Нера са једним улазом за 1 дан временског отклона улаза



Слика 35 Резултати испитивања параметара мреже за станицу Нера са једним улазом за 2 дана временског отклона улаза



Слика 36 Резултати испитивања параметара мреже за станицу Нера са једним улазом за 3 дана временског отклона улаза

3.2.2. Прогноза на станици Нера са два улаза

Ова прогноза одговара диспозицији 3 где су улази у мрежу за станицу Нера протицај са ХЕ и нивои на станици Панчево.

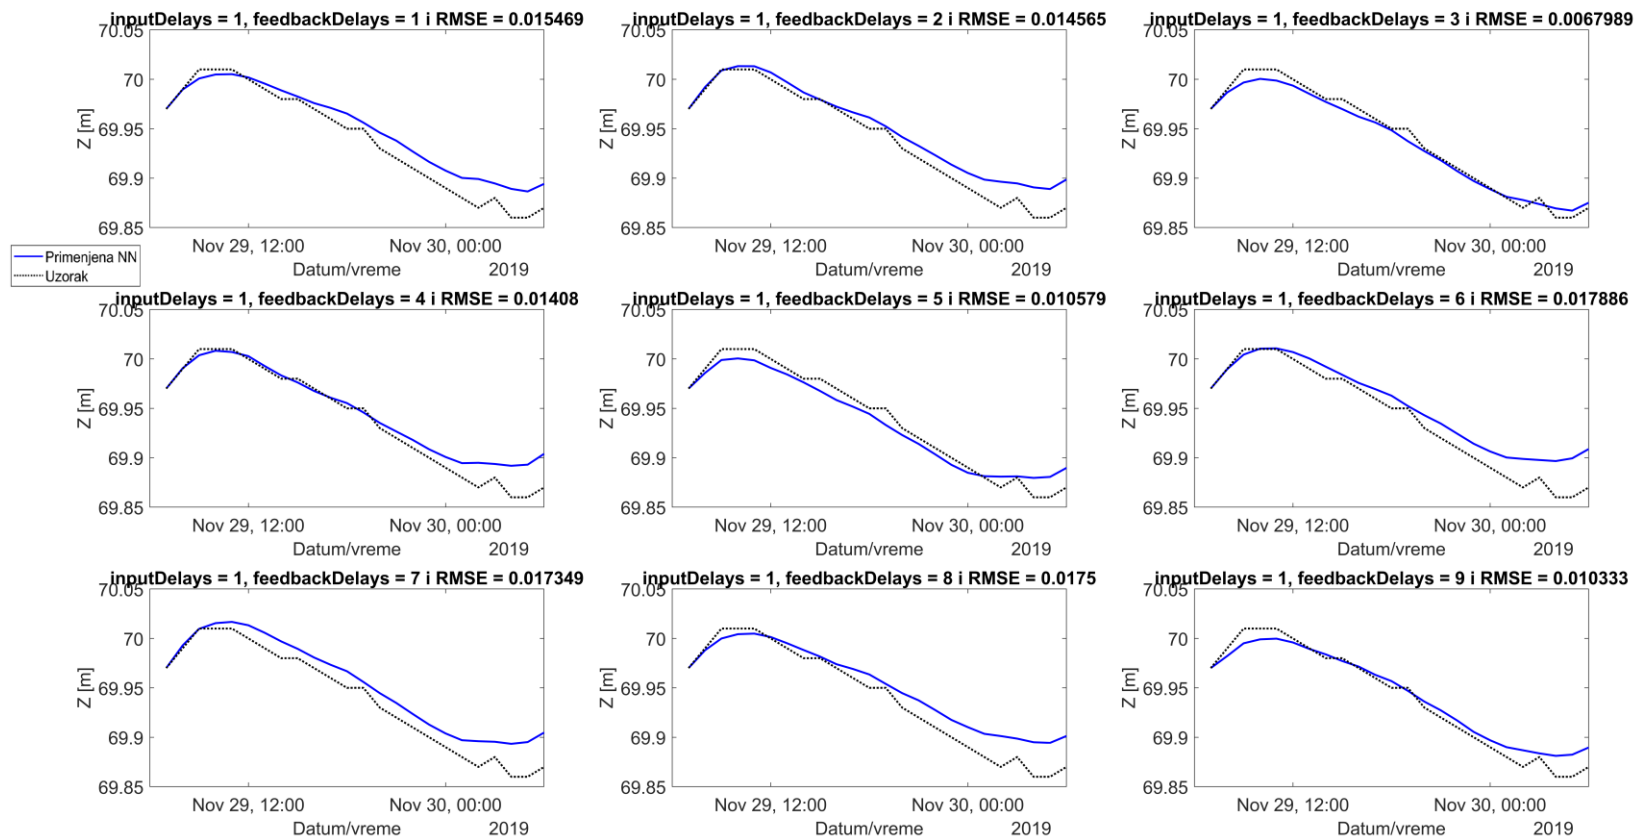
Резултати су дати на наредној страни.

Очигледно је да ова диспозиција показује боље резултате од диспозиције са једним улазом, што је и било очекивано, због утицаја станице Панчево на станицу Нера. Иако су промене вредности параметара показале међусобне разлике у резултатима, највећи део побољшања резултата може се приписати повећању броја улаза.

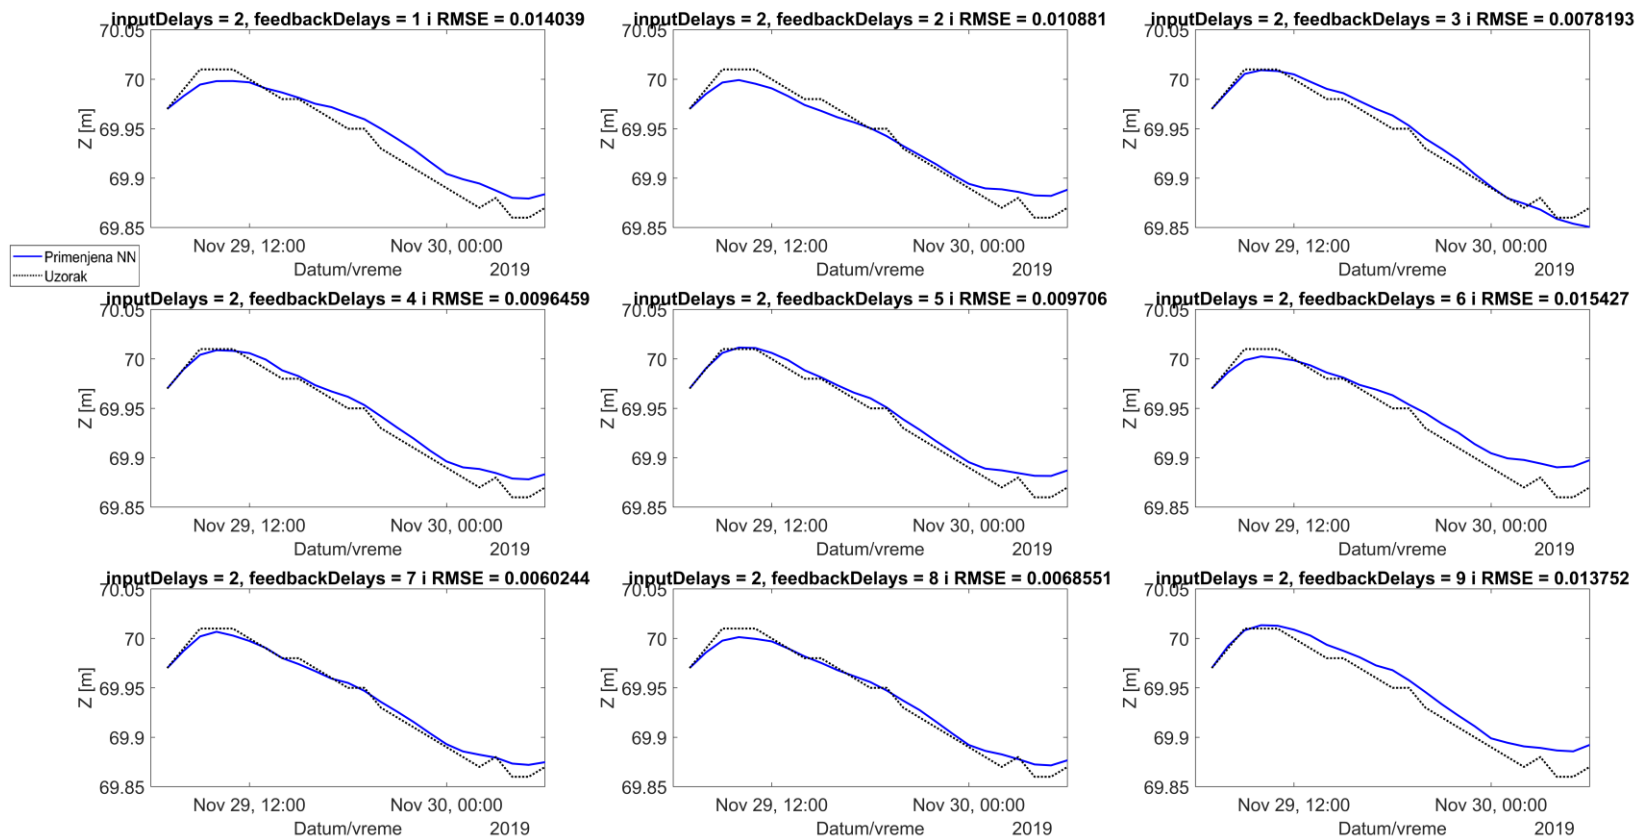
То се доказује разматрањем распона грешака, односно *RMSE* у оквиру сваке диспозиције.

Из ове анализе закључује се да се при вредности параметра *inputDelays* = 3 јавља најмања укупна грешка која износи 0.008 m, скоро дупло мање од најбоље варијанте из претходног случаја, док укупна грешка износи 0.01 m, поново скоро дупло мање од претходног случаја, и глобални минимум и максимум респективно износе 0.006 m и 0.017 m.

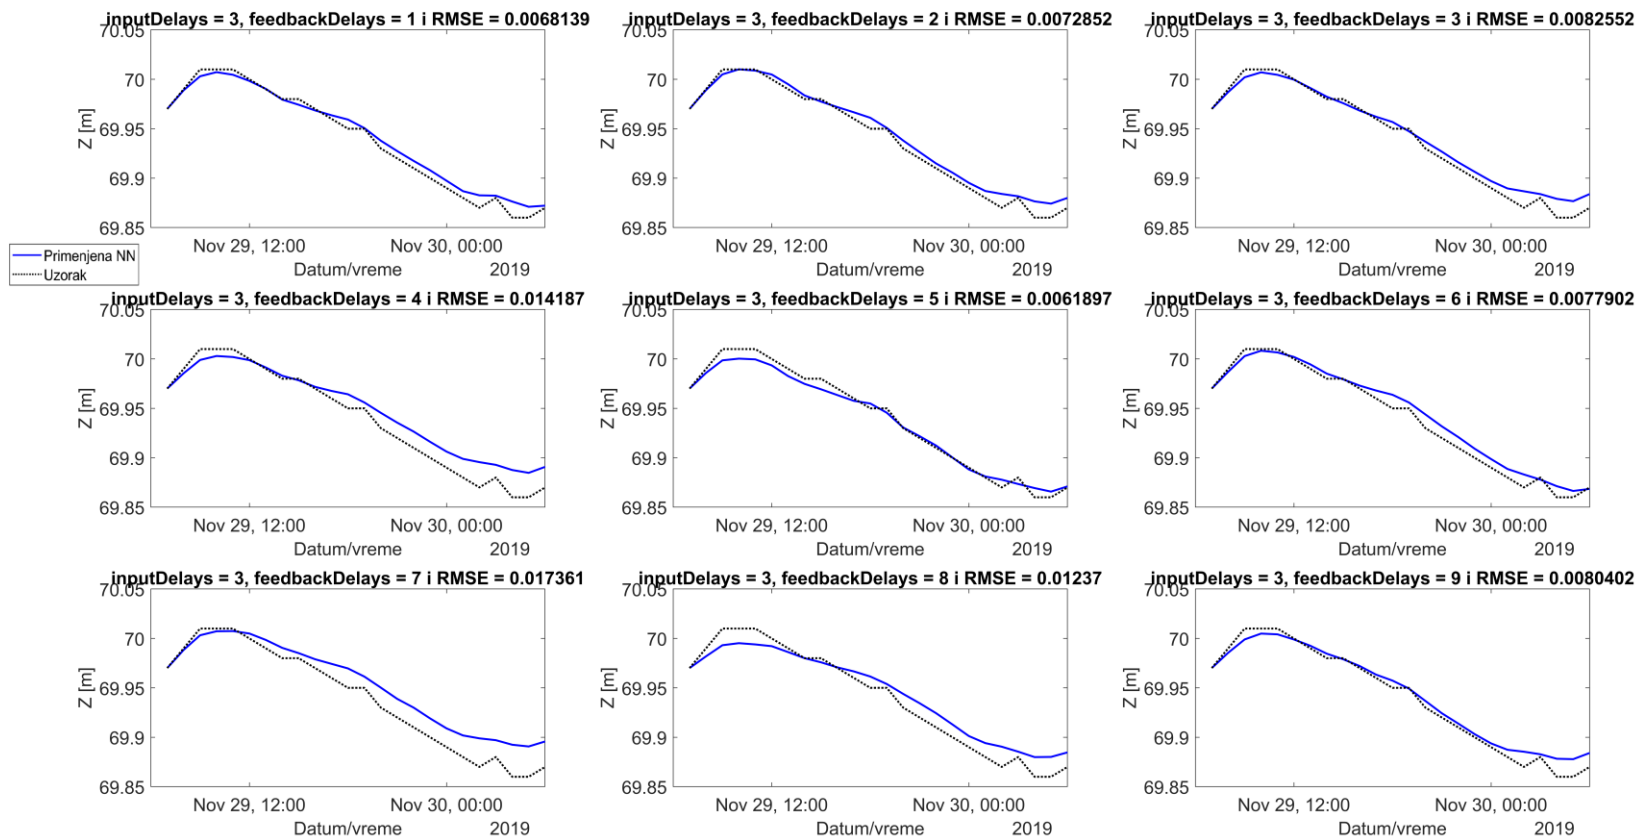
Закључује се да ово представља значајно побољшање у односу на претходни случај у сваком смислу.



Слика 37 Резултати испитивања параметара мреже за станицу Нера са два улаза за 1 дан временског отклона улаза



Слика 38 Резултати испитивања параметара мреже за станицу Нера са два улаза за 2 дана временског отклона улаза



Слика 39 Резултати испитивања параметара мреже за станицу Нера са два улаза за 3 дана временског отклона улаза

3.2.3. Прогноза на станици Нера са три улаза

Ова прогноза одговара диспозицији 4 где су улази у мрежу за станицу Нера протицај са ХЕ, нивои на станици Оршава и нивои на станици Панчево.

Резултати су дати на наредној страни.

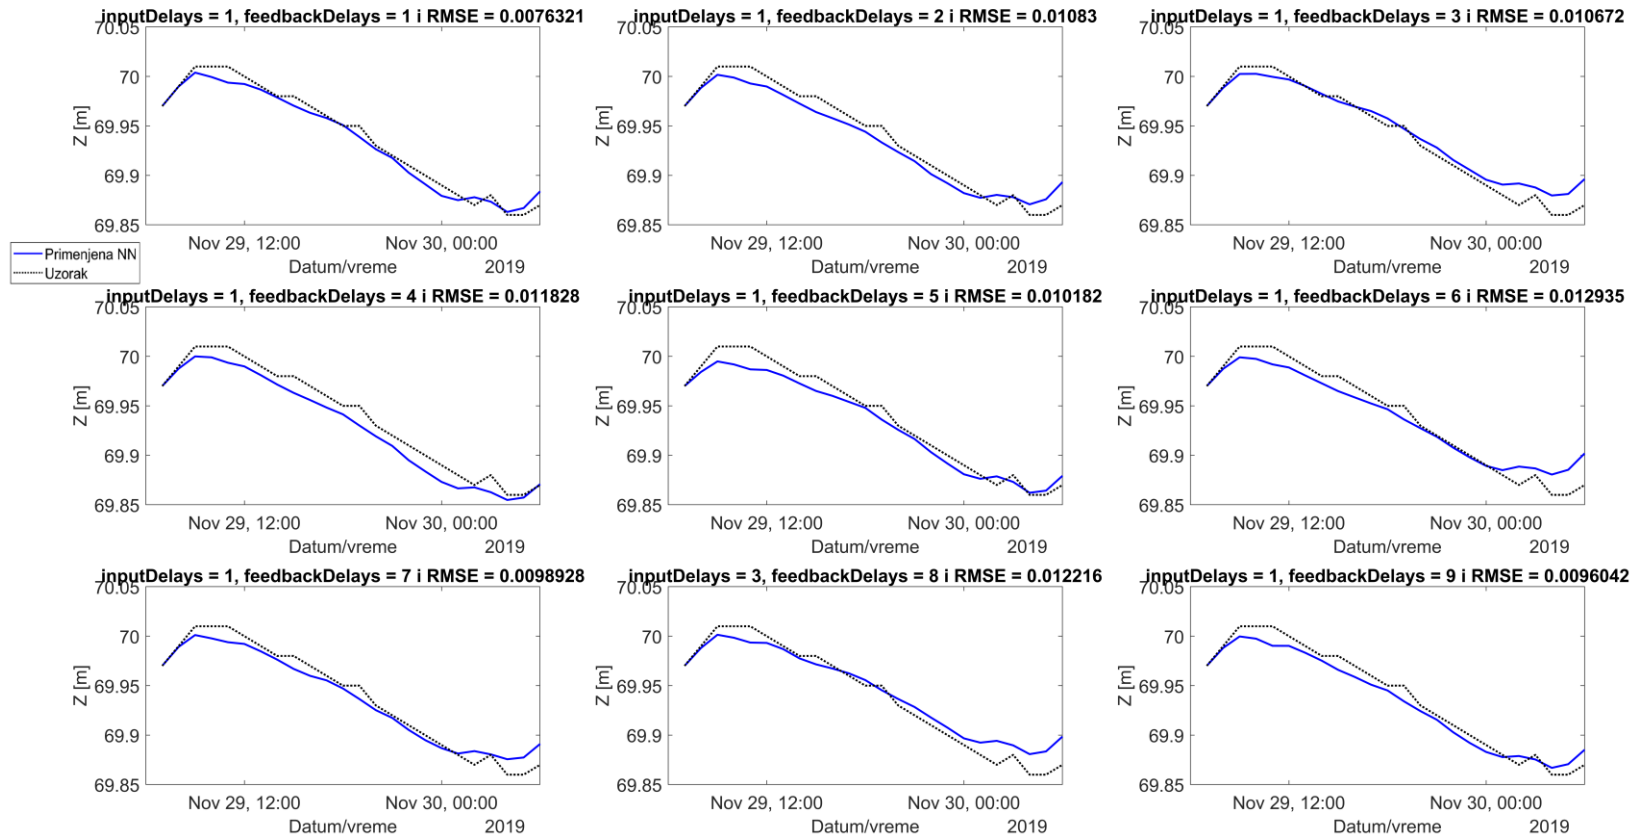
Поштујући стандарде постављене приликом претходне 2 анализе, закључује се следеће.

Ова диспозиција, иако показује боље резултате од прве диспозиције, показује благо лошије резултате од друге диспозиције, претпоставља се да је то последица тога што нивои на Оршави мрежи представљају вид „шума“. Просечна вредност свих грешака износи 0.011 m, глобални максимум и минимум износе, 0.007 m и 0.014 m респективно.

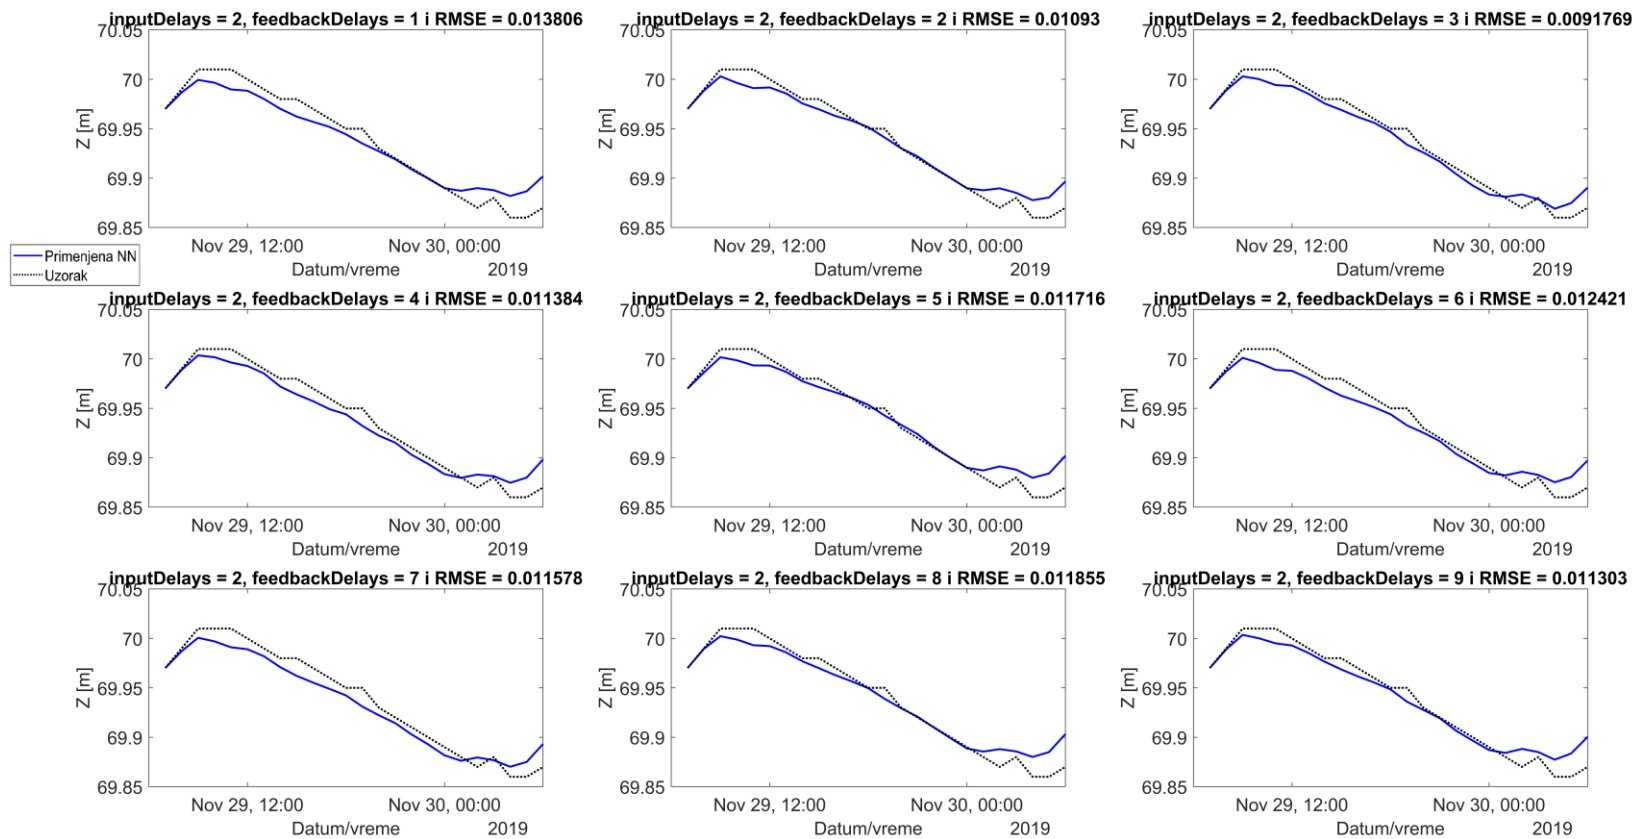
Примећује се да су просечне вредности одступања, када се рачунају по параметру *inputDelays* скоро исте, и прва износи 0.01 m, док друге две просечне вредности износе 0.011 m. То значи да ова мрежа, иако има већу грешку од диспозиције са 2 улаза, даје константније резултате, односно показује већу поновљивост. Једно од могућих објашњења за то је да, на неки начин, мрежа има све податке који јој требају да се истренира колико је то могуће, и не може прецизније од грешке која износи 1 cm, односно 0.01m предвидети ниво.

То би даље значило да изузетно ниске вредности грешке, које су се јавиле као глобални минимуми у претходним случајевима представљају неки вид благог *overfit*-овања (благог зато што грешка идаље постоји) што је, као што је раније дискутовано, инцидентни случај на који се не може ослонити у инжењерској пракси.

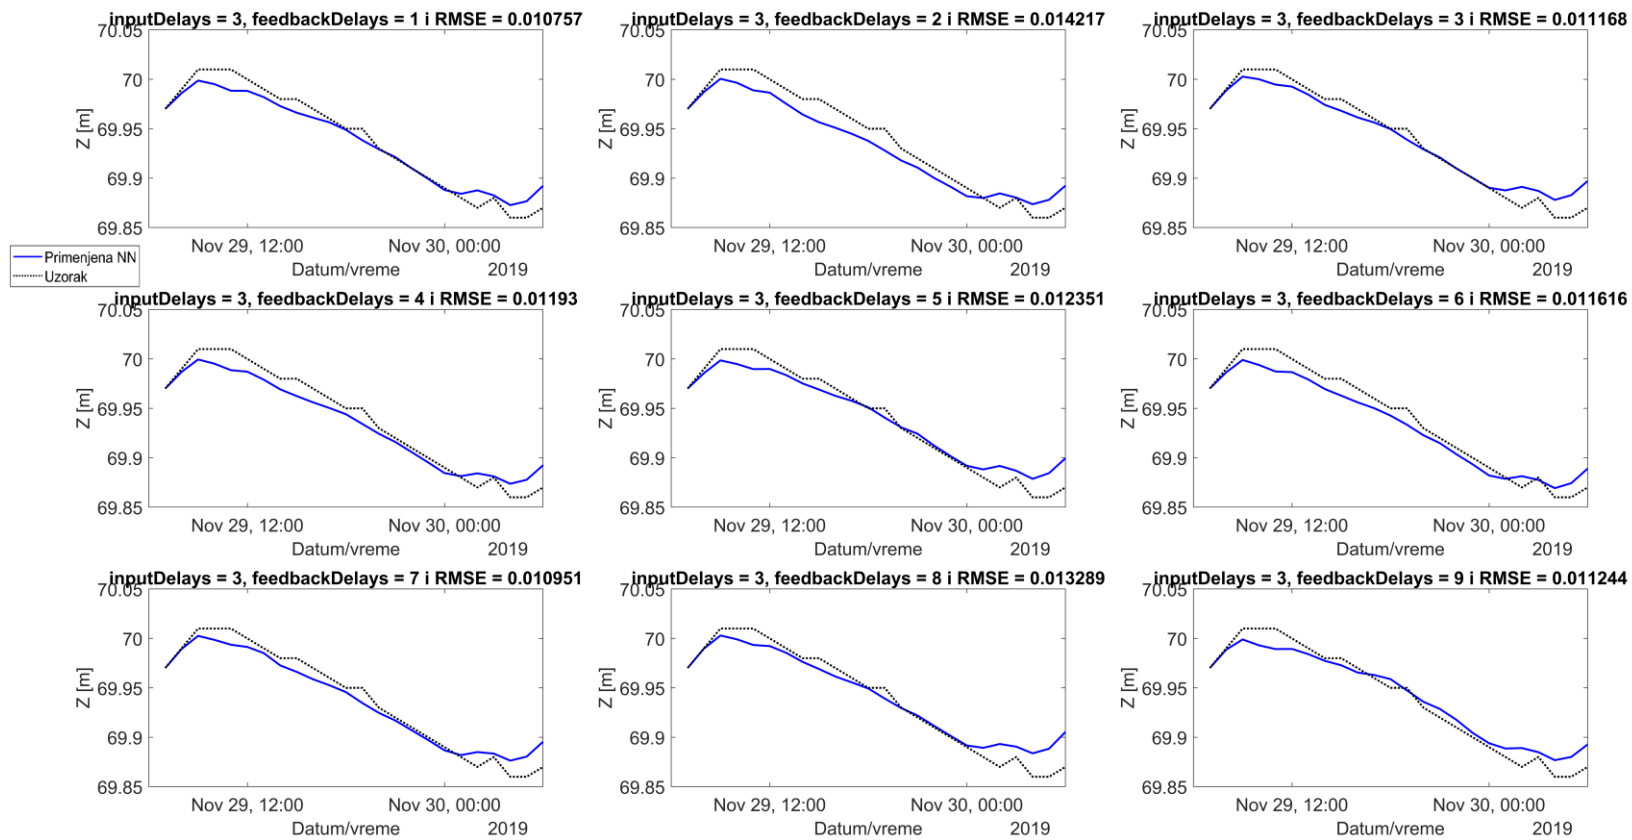
Због претходно поменуто повећане поновљивости овог типа прогнозирања, ова диспозиција мреже ће бити одабрана као референтна.



Слика 40 Резултати испитивања параметара мреже за станицу Нера са три улаза за 1 дан временског отклона улаза



Слика 41 Резултати испитивања параметара мреже за станицу Нера са три улаза за 2 дана временског отклона улаза



Слика 42 Резултати испитивања параметара мреже за станицу Нера са три улаза за 3 дана временског отклона улаза

3.2.4. Испитивање структуре мреже на станици Нера

Када су испитане све варијанте параметара, као и могућих улаза, односно диспозиција, неопходно је такође испитати и могуће структуре мреже. Испитаће се исте структуре мреже, и на основу *RMSE* параметара закључити која је показала најбоље резултате. Као и претходна испитивања на станици Нера, усвајана је најбоља од 20 симулација.

Параметри за испитивање структуре су усвојени на основу претходних резултата, односно:

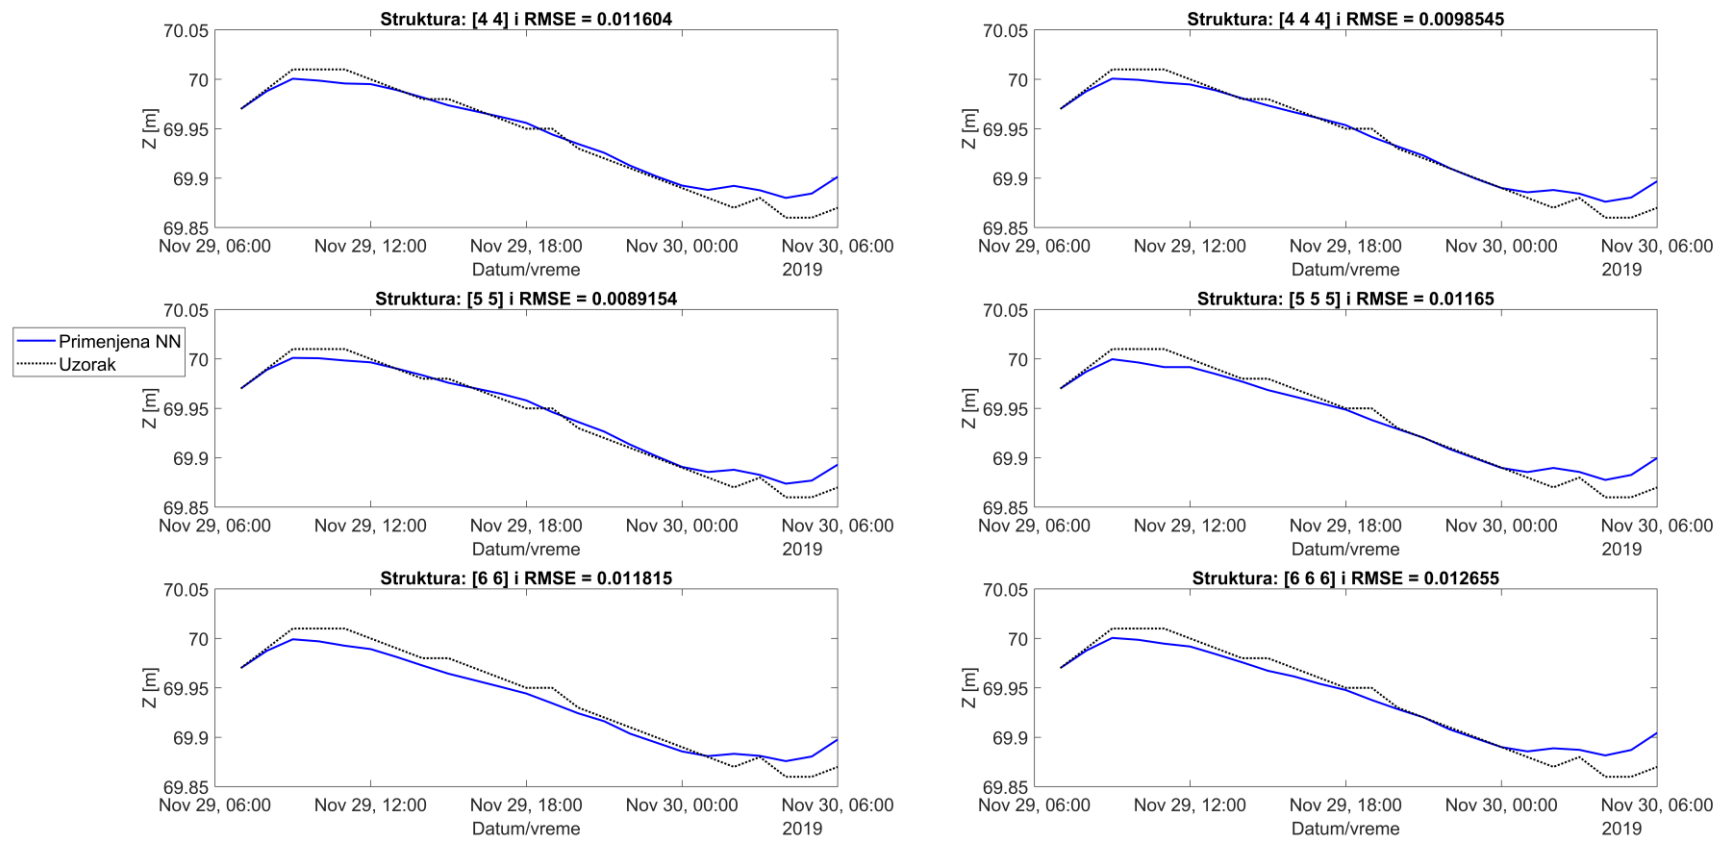
- Усвојена је диспозиција модела са 3 улаза
- Вредности параметара су *inputDelays* = 1 дан и *feedbackDelays* = 1 час.
- Мрежа је тренирана до 29 Новембра 2019. године

Резултати су приказани на наредној страни.

Резултати испитивања структуре мреже показују мало расипање вредности грешке, што значи да су претходни фактори који су одабрани на основу испитивања одговарајући. Иако не показују велику међусобну варијацију, структура од 2 скривена слоја са по 5 неурона показује глобални минимум грешке, на основу чега се она усваја као последњи непознати фактор у прогнозирању на станици Нера.

Са свиме обрађеним у оквиру овог поглавља на уму, за прогнозе на станици Нера се препочује усвајање:

- Диспозиција модела са 3 улаза (ХЕ, Оршава, Панчево)
- Вредности параметра *inputDelays* = 1 дан и *feedbackDelays* = 1 час
- Мрежа тренирана до 29 Новембра 2019. године
- Структура мреже од 2 скривена слоја са по 5 неурона



Слика 43 Резултати испитивања структуре мреже на станици Нера

4. Дискусија

Иако једноставнији видови мрежа нису показали задовољавајуће резултате, макар у оквиру овог проблема, *NARX* мрежа је дала резултате који су у потпуности употребљиви у инжењерској пракси.


Нијансе *NARX* мреже се налазе управо у структурама за које ће се корисник одредити, као и параметрима који ће бити одабрани, али је очигледно, поготово из резултата испитивања станице Нера, да је број улаза далеко значајнији од вредности параметара, иако се ни параметри не могу занемарити у потпуности. Проблеми који се често могу јавити код оваквих мрежа, као што су пристрасност података, видови *overfit/underfit* тренирања и сл не могу никада бити потпуно заобиђени, али приложени резултати показују да су овакве мреже способне да са великим степеном сигурности предвиде промене нивоа. Пожељно је сагледати у целисти све вредности грешака које су се јавиле током резултата у претходном поглављу не би ли се увидео утицај промене архитектура мреже, параметара, одабира, и сл.

Прво ће се размотрити резултати на станици Оршава. При одабиру параметара и структуре, од интереса је која вредност параметра, односно структуре показује најмању грешку. Иако је раније поменуто да је архитектура мреже са одлагањем улаза одбачена конто великих осцилација око узоркованих нивоа, она ће бити приказана овде да би се приказало побољшање које је остварено коришћењем *NARX* мреже.

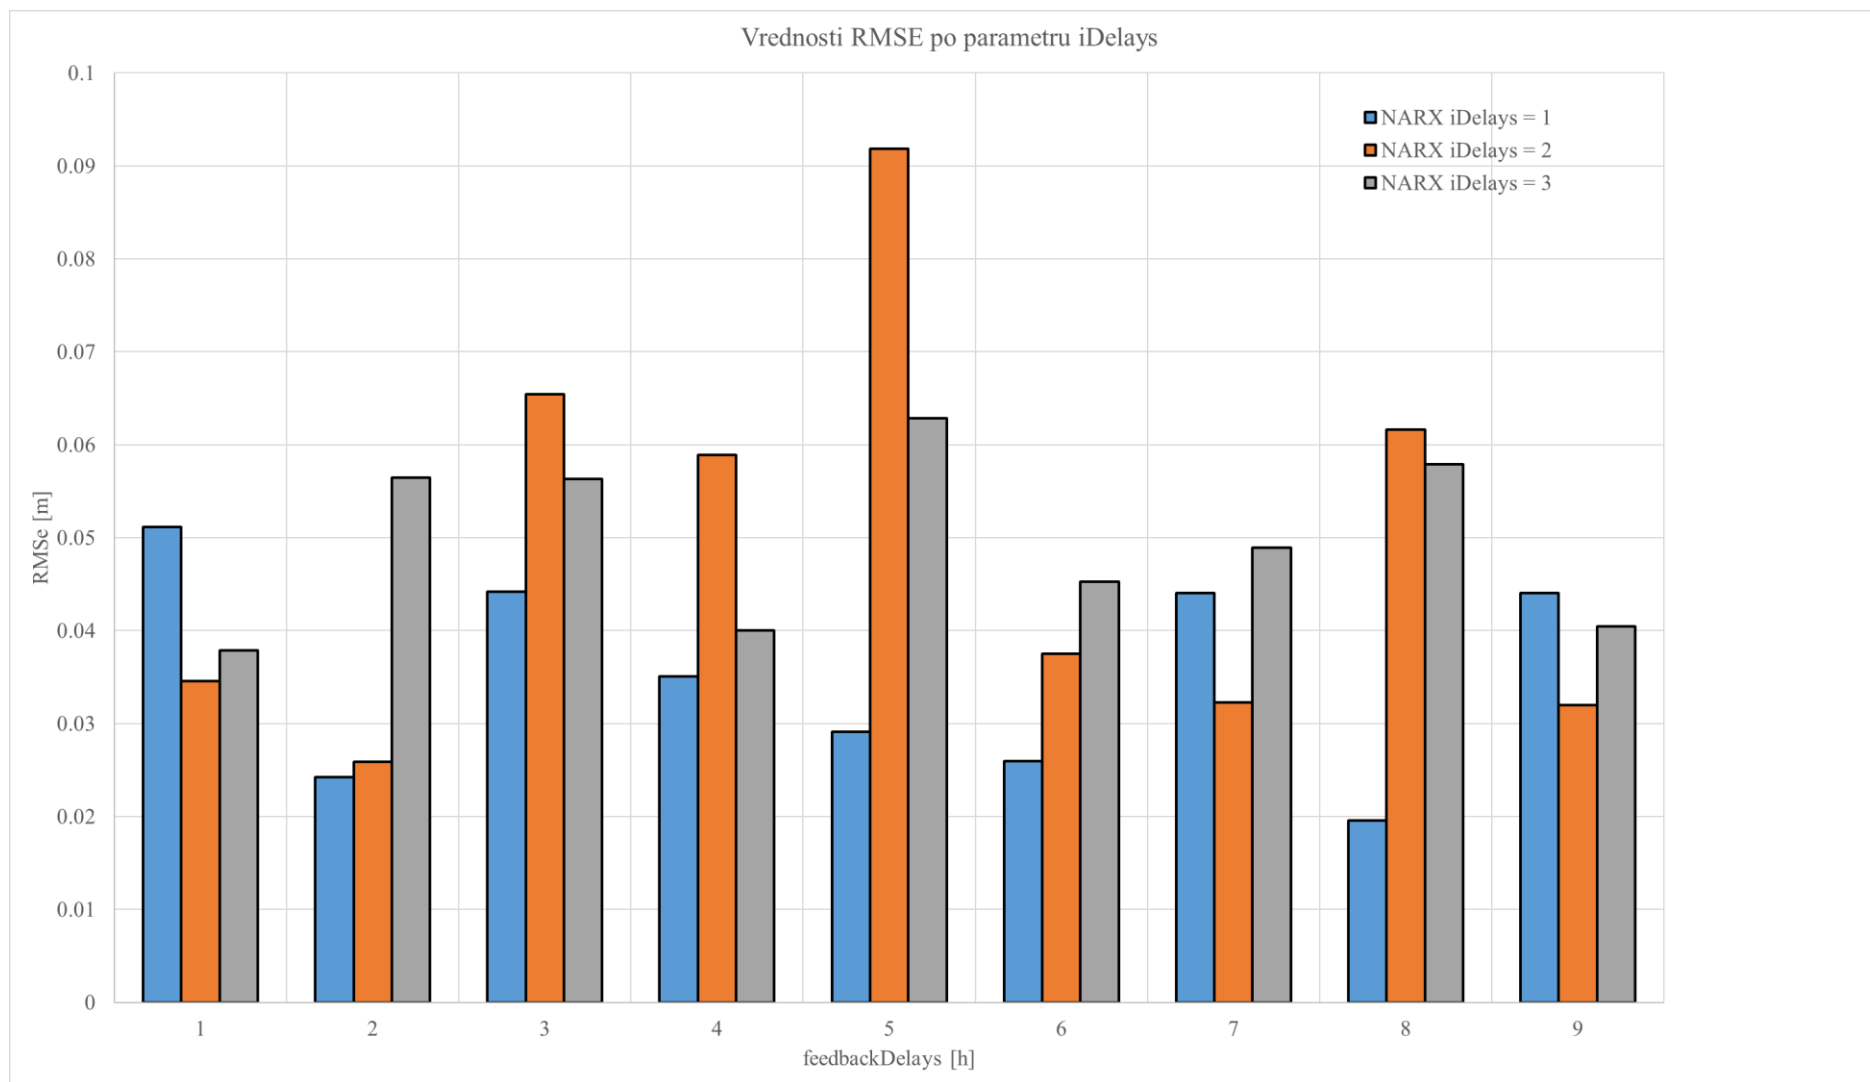
Пошто су у оквиру *NARX* мреже испитивана оба параметра одредиће се средње вредности грешке по параметру *inputDelays*. На слици 44 обележен као (*iDelays*), док је структура мреже, по којој се одређује средња вредност код мреже са одлагањем улаза, означена исто као и у претходном поглављу.

Иако су се у мрежи са одлагањем улаза испитивале структуре мреже са променљивим параметром, док се у оквиру *NARX* мреже испитивао један параметар (*inputDelays*) са другим променљивим (*feedbackDelays*), корисно је показати оба јер су структура и вредност параметра једине променљиве у мрежи са одлагањем улаза. Преко тога вршен је одабир најбоље из 10 симулација, ефективно контролишући за све могуће променљиве. Такво испитивање није могуће урадити са *NARX* мрежом, као последица постојања три променљиве (структура и два параметра), што оставља један степен побољшања за *NARX* мрежу са променом структуре. Чак и са могућим додатним побољшањем *NARX* мреже, она показује значајно боље резултате, толико да би се из одабира архитектуре мрежа са одлагањем улаза искључила и да не показује претходно поменуте значајне осцилације око узоркованог нивоа.

На слици 44, *NARX* мреже су сортиране по вредности параметра *inputDelays*, док су мреже са одлагањем улаза сортиране по структури, која је обележена као и у оквиру самог *MATLAB*-а (нпр. [4 4 4] представља мрежу са структуром од 3 скривена слоја са 4 неурона по слоју). Као што се види на слици 44 сваки случај *NARX* мреже има нижу средњу вредност грешке од било које мреже са одлагањем улаза, из тога следи да је одабир *NARX* мреже био исправан. Такође, од интереса је видети да ли се минимум јавио у оквиру параметра који показује најмању средњу грешку. На слици 45, види се да се минимум налази у оквиру прве групе података, којој одговара вредност параметра *iDelays* = 1 дан, што додатно утврђује одлуку о одабиру вредности параметара мреже.



Слика 44 Средње вредности грешака по испитивању



Слика 45 Вредности RMSE по параметру iDelays


Што се тиче станице Нера, у оквиру ње су испитиване разлике при промена броја улаза и коришћена је искључиво *NARX* мрежа, то чини међусобне резултате једноставнијим за поређење, поготово када се узме у обзир да је најбоља мрежа бира на узорку од 20 симулација, као и то да су све симулације рађене контролишући за структуру (односно у свакој симулацији је иста структура). Структура која је коришћена за испитивање улаза и параметара је, као што је раније поменуто, структура од 3 скривена слоја са по 5 неурона.

Иако су све вредности грешака и средњих вредности грешака поменуте у претходном поглављу, у оквиру овог поглавља биће мало детаљније прокоментарисане.


Прво што је од интереса је како утиче број улаза на грешке у систему. На слици 46 се види значајно побољшање са повећањем броја улаза, што је било и очекивано због мања једнозначне зависности између ХЕ и станице Нера. Али, ради доношења одлуке, неопходно је загледати дубље од прости средње вредности грешке по броју улаза. На слици 47 се види како се мењала средња грешка, овај пут по вредности параметра *inputDelays*, у легенди истог графикана названо *iDelays*, где се види поново да 2 улаза показују најмању грешку. Као што је поменуто раније, није одабрана диспозиција од 2 улаза. Главни разлог иза тога је што диспозиција од 3 улаза показује далеко већу поновљивост од диспозиције од 2, као што се види разлика између средњих вредности грешке је непуних 1 mm. То имплицира, за варијанту са 3 улаза, да су се вредности кретале у јако уском опсегу ма која вредност параметара да је изабрана.

На слици 48 приказане су вредности грешака најбољих од 20 симулација за сваку вредност параметра *inputDelays* и *feedbackDelays* поређане редом, где 1 представља вредности параметра *inputDelays* = 1 и *feedbackDelays* = 1, док 27 представља *inputDelays* = 3 и *feedbackDelays* = 9. Показује се да са 1 улазом, вредности грешке интензивно варирају, са 2 улаза осетно мање, док са 3 улаза се грешке све крећу у опсегу од 0.005-0.015 m.


То указује на висок степен тачности ове диспозиције модела, као и висок степен поновљивости, који чини ову мрежу најбољом која је обрађена у оквиру овог рада за предвиђање нивоа на станици Нера.



Слика 46 Средње вредности грешака по броју улаза



Слика 47 Средња вредност грешке по броју улаза и вредности параметра *inputDelays*



Слика 48 Приказ вредности grešaka u okviru priloženih simulacija

Један од разлога за одабир најбоље мреже за сваки пар параметара, приликом симулација, је управо био испитивање *overfit* феномена. Неминовно, *overfit*-оване мреже ће се показати као најбоље током одабраног броја симулација, и оне представљају глобалне минимуме грешке поменуте у претходном тексту. Напомиње се да за испитивања *NARX* мреже није дошло до строгог *overfit*-овања већ до благог *overfit*-овања, тако да се у даљем тексту подразумева да се мисли на благи *overfit*. Примећује се да је тај феномен далеко израженији за *NARX* мреже са мање улаза, што се закључује из апсолутне разлике глобалног минимума и максимума, као и разлике глобалних средњих вредности грешке и глобалног минимума. То наводи на интуитиван закључак да се појава *overfit* проблема контролише повећањем улаза, односно када се мрежа тренира за различите (понекад и независне, као што су ХЕ и станица Панчево) улазе.

Са увођењем трећег улаза, односно станице Оршава, који функционално има исту сврху „низводног граничног услова“ за који се мрежа тренира као и ХЕ, драстично се оборио феномен *overfit*-овања, сужавањем домена резултата што је изузетно значајно са практичне перспективе, јер поверљивост мреже, односно поновљивост резултата расте. Иако, концептуално, постоји граница тачности ових модела, као последица тога што ови модели нису засновани на физичким принципима који условљавају течење, та граница остаје непозната, тако да ови модели нуде у суштини бесконачну могућност побољшавања и усавршавања. Питање које се поставља за примену оваквих модела је, како разликовати тачност у симулацији у општем смислу, за све улазе, од тога да је симулација тачна за примењене податке (нпр. Наредних 24 сата)? И где би се та граница налазила ако је то могуће аналитички показати? Свакако, евидентно је да константност резултата *NARX* мреже на станици Нера са три улаза (независно од параметара) највише значи у пракси.


Сходно томе, за предвиђање на станици Нера, препоручује се коришћење модела са три наведена улаза (Панчево, Оршава, ХЕ), независно од параметара мреже.

Сад кад су одређене све променљиве које се подешавају за тренирање мреже, било би корисно дати приказ рада мреже у практичном смислу.


Претпоставља се да се мрежа неће дотрениравати сваки дан када пристигну мерења са станица, већ ће пролазити неки период између дотрениравања мреже. Са тиме на уму, следећа ситуација ће бити обрађена.:

Испитује се станица Нера, на мрежи која је тренирана до 1. Новембра 2019, мрежа је тренирана са 3 улаза, вредности параметара су $inputDelays = 1$ и $feedbackDelays = 1$, и структура мреже је са 2 скривена слоја од 5 неурона. Претпоставља се да месец дана скраћивања тренинга неће представљати значајну препреку тачности симулације. Одабрана је најбоља од 5 симулација. У сваком дану током Новембра, мрежа је пуштена у рад (што је разлог идентичних вредности симулације и узорка у поноћ сваког дана), резултати тих симулација повезани су у један континуални дијаграм, и за сваки дан је срачунат *RMSE* да би се видела одступања. Резултати тих симулација приказани су на слици 49.

Исто ће се приказати и за станицу Оршава, која је тренирана са једним улазом, чије су вредности параметара $inputDelays = 1$ и $feedbackDelays = 8$, док је структура мреже од 3 скривена слоја са по 5 неурона. Чији су резултати приказани на слици 50.



Слика 49 Примена мреже на читав месеџ Нере



Слика 50 Примена мреже на читав месец Оршаве

Резултати ових симулација, иако јесу задовољавајући, показују резултате, као и вредности грешака, који су лошији од претходно обављених тестирања. Неки од фактора који утичу на то су 4 пута мањи број симулација из којих се бирала најбоља, као и месец дана краћи тренинг.

Свакако, резултати ових симулација, поготово у данима са врло ниском грешком, су и више него употребљиви у практичном смислу.

5. Закључци

Значај прогнозирања нивоа као последица промене неког граничног услова се не може потценити. Поготово у XXI веку у којем је на светском нивоу интензиван интерес ка одрживом управљању водама. Поред тога, не сме се ни заборавити ни на значај таквих прогноза у циљу одбране од поплава. За сваку од тих ситуација неуронске мреже представљају моћан алат који омогућава заобилажење јако сложене математике која се јавља, поготово у водотоцима у природним режимима, и помоћу једноставних мерења дати довољно тачна предвиђања да се даље може поступати према тим предвиђањима.

Показано је да су неуронске мреже, додуше оне сложеније, и више него способне за прогнозирање нивоа са тачношћу од неколико см (најчешће и мање). Имајући на уму не само резултате овог рада, већ и резултате на сличним хидротехничким проблемима, неуронске мреже, као и вештачка интелигенција генерално, су се веома брзо уврстиле у каталог начина које инжењери хидротехнике имају за решавање јако сложених проблема.

Испитивања која би била интересантна у оквиру тематике прогнозирања нивоа, би била на тему потенцијалне горње границе тачности неуронске мреже. Да ли је могуће аналитички или експериментално (уз n -ти број симулација ако је неопходно) показати да мрежа не може бити тачније од неке вредности, и ако је то могуће показати, поставља се питање зашто је то тако.

У оквиру овог рада загребана је само површина многих испитивања која могу да се раде на оваквим системима помоћу неуронских мрежа. Будући правци истраживања би могли да обухватају прогнозе на станицама узводнијим од Панчева, уз одговарајуће обухватање утицаја на те станице додавањем улаза; такође би било интересно разматрање утицаја притока на нивое на станицама, односно да ли би се (и ако да, колико) побољшала тачност прогнозе увођењем мерења на притокама у улазне податке. Истраживања на ХС не морају нужно бити везана за прогнозирање нивоа, неуронске мреже се могу користити и за оптимизацију производње електричне енергије. Са свим тим на уму, демонстриране су изванредне способности неуронских мрежа за решавање оваквих проблема.

Литература

- [1] Sung, J.Y.; Lee, J.; Chung, I.-M.; Heo, J.-H. Hourly Water Level Forecasting at Tributary Affected by Main River Condition. *Water* 2017, 9, 644.
- [2] Campolo, Marina & Andreussi, Paolo & Soldati, Alfredo. (1999). River Flood Forecasting With a Neural Network Model. *Water Resources Research*. 35. 10.1029/1998WR900086.
- [3] Bomers, Anouk & van der Meulen, Bas & Schielen, R.M.J. & Hulscher, Suzanne. (2019). Historic Flood Reconstruction With the Use of an Artificial Neural Network. *Water Resources Research*. 55. 10.1029/2019WR025656.
- [4] Abou Rjeily, Yves & Abbas, Oras & Sadek, Marwan & Shahrour, Isam & hage Chehade, Fadi. (2017). Flood forecasting within urban drainage systems using NARX neural network. *Water Science & Technology*. 76. wst2017409. 10.2166/wst.2017.409.
- [5] Faruk, Durdu. (2010). A hybrid neural network and ARIMA model for water quality time series prediction. *Eng. Appl. of AI*. 23. 586-594. 10.1016/j.engappai.2009.09.015.
- [6] Zhang, Di & Peng, Qidong & Lin, Junqiang & Wang, Dongsheng & Liu, Xuefei & Zhuang, Jiangbo. (2019). Simulating Reservoir Operation Using a Recurrent Neural Network Algorithm. *Water*. 11. 865. 10.3390/w11040865.
- [7] US Army Corps of Engineers (*Feb.* 2016). HEC-RAS River Analysis System, Hydraulic Reference Manual, Version 5.0
- [8] Solomatine, D., See, L. M., & Abrahart, R. J. (n.d.). Data-Driven Modelling: Concepts, Approaches and Experiences. *Water Science and Technology Library*, 17–30. doi:10.1007/978-3-540-79881-1_2
- [9] MATLAB and Statistics Toolbox Release 2017b, The MathWorks, Inc., Natick, Massachusetts, United States.
- [10] <https://purnasaigudikandula.medium.com/a-begginer-intro>
- [11] <https://www.ibm.com/cloud/learn/neural-networks>
- [12] <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>
- [13] <https://stats.stackexchange.com/questions/313070/>
- [14] <https://www.kdnuggets.com/2020/05/5-concepts-gradient-descent-cost-function.html>
- [15] <https://towardsdatascience.com/gradient-descent-explained-9b953fc0d2c>
- [16] <https://www.mathworks.com/help/deeplearning/ref/fitnet.html>
- [17] <https://www.mathworks.com/help/deeplearning/ug/choose-a-multilayer-neural>
- [18] <https://www.mathworks.com/help/deeplearning/ref/trainlm.html>
- [19] <https://www.mathworks.com/help/deeplearning/gs/fit-data-with-a-neural-network.html>
- [20] Ramakrishnan D,T.N. Singh, N. Purwar, Suprakash Gupta, Artificial neural network and liquefaction susceptibility assessment: A case study using the 2001 Bhuj earthquake data, Gujarat, India, April 2012.
- [21] <https://www.mathworks.com/matlabcentral/answers/323651-what-is-the-default>

- [22] <https://www.ibm.com/cloud/learn/overfitting>
- [23] <https://www.mathworks.com/help/deeplearning/ref/timedelaynet.html>
- [24] <https://www.mathworks.com/help/deeplearning/ref/narxnet.html>
- [25] Leontaritis, I. J.; Billings, S. A. (1985). Input-output parametric models for non-linear systems Part II: stochastic non-linear systems. *International Journal of Control*, 41(2), 329–344.
- [26] <https://www.statisticshowto.com/standardized-values-examples/>
- [27] <https://www.statisticshowto.com/probability-and-statistics/regression-analysis/rmse>
- [28] <https://www.investopedia.com/terms/m/movingaverage.asp>