

ПРИМЕНА МЕТОДА ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ У ОБНОВЉИВИМ ИЗВОРИМА ЕНЕРГИЈЕ И ЕНЕРГЕТСКОЈ ЕФИКАСНОСТИ

APPLICATION OF ARTIFICIAL INTELLIGENCE METHODS IN RENEWABLE ENERGY SYSTEMS AND ENERGY EFFICIENCY

Радиша ЈОВАНОВИЋ*, Иван БОЖИЋ
Универзитет у Београду Машински факултет, Београд

Рад по позиву

<https://doi.org.10.240/ptk.018.31.1.63>

Развој система који користе обновљиве изворе енергије захтева примену софистицираних техника у циљу тачне процене расположивог енергетског потенцијала и њиховог ефикасног управљања и оптимизације. Основна карактеристика метода вештачке интелигенције је да оне користе рачунарске системе за извршавање задатака који захтевају интелигентно понашање, као што су учење, расуђивање, решавање проблема и доношење одлука у присуству неизвесности. То посебно може бити корисно у моделовању, анализи, оптимизацији и предикцији перформанси и управљању система са обновљивим енергијама и ефикаснијој употреби енергије у термоенергетским, термотехничким и процесним постројењима. Ови системи су изразито нелинеарни, сложени и динамички, где основни физички односи нису у потпуности разјашњени и где су доступни подаци често зашумљени и/или некомплетни. Вишепараметарски и вишекритеријумски аспект у пројектовању ових система није лако третирати применом аналитичких метода, физичких модела или нумеричких метода. Методе вештачке интелигенције могу да обезбеде обећавајућу и поуздану алтернативу, или допуну традиционалним детерминистичким и статистичким прилазима који се користе у енергетској ефикасности и обновљивим изворима енергије. Ове методе омогућавају изучавање система без икаквог познавања тачних релација које описују њихов рад, и једном када се обуче, дозвољавају извршавање сложених задатака као што су моделовање, предикција, идентификација, оптимизација и управљање. Вештачке неуронске мреже и метода потпорних вектора, као неке од најчешће коришћених методологија, и њихова примена у енергетској ефикасности и системима који користе обновљиве енергије, тема су овог рада.

Кључне речи: обновљиви извори енергије; енергетска ефикасност; методе вештачке интелигенције; неуронске мреже

The development of renewable energy systems requires the use of sophisticated techniques for an accurate estimation of the available energy potential and for effective control and optimization of systems operation. The common feature of artificial intelligence methods is that they employ computer systems to perform tasks which require intelligent behavior, such as learning, reasoning, problem solving and decision making under uncertainty. This can be particularly beneficial in modeling, analysis, optimization and prediction of the performance and control of renewable energy systems and more efficient energy use. These systems are highly nonlinear, complex and dynamic, where the underlying physical relationships are not fully understood and the available data are often noisy and/or incomplete. Multi-parameter and multi-criteria aspects of the design of these systems are not easily handled using analytical methods, physical models or numerical methods. Artificial intelligence techniques may provide a promising and reliable alternative, or a complement, to the traditional process-based or statistical approaches used in the energy efficiency and renewable energy systems. They enable to study these systems without any knowledge of the exact relations governing their operation, and once trained, allow performing as complex tasks as prediction, modeling, identification, optimization, forecasting and control. Artificial neural networks and support vector machine, as commonly used artificial intelligence methodologies, and their application in the energy efficiency and renewable energy systems are presented.

Key words: renewable energy sources; energy efficiency; artificial intelligence; neural networks

* Аутор за кореспонденцију: rjovanovic@mas.bg.ac.rs

1. Увод

Смањивање резерви фосилних горива, као и утицај експлоатације ових горива на животну средину, довели су до повећаног интересовања за развој алтернативних и одрживијих извора енергије. Обновљиви извори енергије, као што су енергија сунца, енергија ветра, енергија водених токова, енергија таласа и биомасе, бележе интензиван раст присуства на тржишту енергије. У процесу производње конвенционалне енергије, производња електричне енергије зависи од њене потражње од стране корисника, и стабилност енергетске мреже се ослања на равнотежу потражње и производње. Производња одговарајуће количине електричне енергије у правом тренутку је од пресудног значаја за несметано управљање електроенергетског система, и већу економску корист. За одржавање ове стабилности, многа истраживања се фокусирају на прогнозирање понуде и потражње да би се предвидела потребна количина електричне енергије, [1].

Резултујуће флукуације у производном капацитету једног електроенергетског система, где је доминатна употреба обновљивих извора, може имати за последицу појаву нестабилности у електроенергетској мрежи. Разлог томе је што енергију ових извора одређују фактори окружења као што су брзина ветра, интензитет сунчевог зрачења, облачност и други фактори, односно производња из обновљивих извора се карактерише изразитом променљивошћу, неравномерношћу и стохастичношћу. Друго важно ограничење је да су они подложни дневним и годишњим циклусима (на пример, сунчева енергије је доступна само током дана). Дакле, неопходно је генерисати енергију када су ресурси доступни и сачувати је за касније, и истовремено користити део генерисане енергије. Складиштење енергије из обновљивих извора, посебно енергије ветра и сунца, је још увек економски нерационално, па је неопходно пажљиво управљање производњом ове врсте енергије.

Упоредо са узлазним трендовима експлоатације обновљивих извора енергије, стратешки се промовише рационално и ефикасно коришћење финалне енергије и у складу с тим развијају одговарајуће технологије. Дефинисање и спровођење стратешких циљева енергетске ефикасности се заснива на средњорочним и дугорочним прогнозама енергетских биланса, анализи могућих развојних сценарија на страни производње и посебно на анализи и предвиђању потрошње различитих енергената. Свеобухватно разматрање трендова потрошње појединих енергената је мултидисциплинарног карактера и спроводи се помоћу предвиђања привредног развоја, демографске експанзије, употребе конвенционалних и алтернативних енергетских ресурса, повећања енергетске ефикасности у свим секторима потрошње енергије и стања и промена у тржишно оријентисаном окружењу. Бројни индикатори илуструју нерационалну потрошњу енергије: потрошња по глави становника, по јединици друштвеног производа, по учешћу трошкова енергије у укупном друштвеном производу, у целини и по секторима. Када је Република Србија у питању, наведени индикатори указују да се приоритетне активности у области ефикасног коришћења енергије морају спроводити првенствено у сектору зградарства. Стога се, на пример, у циљу дефинисања и оптимизације модела грејања врше потребне анализе и предикције потрошње потребних енергената које су у директној зависности од климатских карактеристика и бројних социјалних, енергетских и економских показатеља.

Претходно поменути изазови мотивисали су употребу метода вештачке интелигенције за подршку бољем управљању производње и потрошње енергије. Последњих година, методе вештачке интелигенције се користе као поуздана алтернатива класичним математичким моделима, и показале су се као веома успешне у решавању комплексних проблема у различитим инжењерским областима, укључујући индустријске процесе, дигиталну обраду сигнала, препознавање узорака, слика и говора, идентификација и моделовање система, медицинско инжењерство, управљање, моделовање и предикцију у области производње и потрошње енергије.

Различите технике се користе на различитима ступњевима интеграције обновљивих извора енергије у електроенергетску мрежу, зависно од захтева и карактеристика проблема. За мрежу са обновљивим изворима енергије који имају значајан допринос у снабдевању електричном енергијом, неопходно је предвидети и краткорочну и средњорочну потражњу. Са друге стране, неопходно је предвидети и излазну енергију самих обновљивих извора енергије, с обзиром да она зависи од многих фактора околине, као што су брзина и правац ветра, хидролошки услови, интензитет сунчевог зрачења у региону електране.

Још једна важна област примена техника вештачке интелигенције у контексту обновљивих извора енергије је и у одређивању оптималне локације, величине и конфигурације електрана које користе обновљиве изворе енергије. Ови параметри зависе од многих фактора, као што су близина становништва, локални климатски услови и промене, терен, доступност и трошкови логистике и других објеката, итд. Такође, не треба заборавити ни њихову значајну примену у свеукупном раду „паметне мреже”, као што су откривање грешака, управљање, и слично, [1].

2. Модели за предвиђање

Повећаном интеграцијом обновљивих извора енергије у електроенергетске мреже, од пресудне важности постаје потреба за што прецизнијим методама за предвиђање њихове производње. Истраживања на овом подручју су постала интензивна у последње време, и технике предвиђања се могу категоризовати у два типа: методе индиректног предвиђања и методе директног предвиђања, [2-21]. Код индиректних метода, на пример, интензитет сунчевог зрачења, протоци у рекама и брзина ветра се предвиђају на основу њихових мерених вредности и метеоролошких параметара у претходном периоду, а потом се, на основу тих вредности одређују производња, редом, фотонапонског система, мале хидроелектране и ветрогенератора. Директним методама се предвиђа производња из обновљивих извора енергије на основу њихових историјских мерених података и информација о метеоролошким параметрима. Зависно од временског хоризонта за који се врши предвиђање, у литератури се могу наћи различите поделе, а једна од њих је, на основу [2-21], да се предвиђања могу груписати у четири категорије. Врло краткорочна и краткорочна предвиђања се односе на временске интервале од 1 минута до неколико минута, евентуално до неколико сати унапред, и од 1 сата до неколико дана унапред, следствено. Средњорочна предвиђања подразумевају предвиђања од месец до годину дана унапред, а дугорочна од једне до неколико година унапред.

Према примењеној методологији предвиђања, модели за предвиђање који се примењују у области обновљивих извора енергије и енергетској ефикасности могу се класификовати у четири категорије, [2-21]:

- 1) физички модели, базирани на физичким законитостима, који су погодни за средњорочна и дугорочна предвиђања,
- 2) статистички модели, као што су ауторегресивни (AR), ауторегресивни модел покретних средина (ARMA), ауторегресивни интегрисани модел са покретним срединама (ARIMA),
- 3) методе вештачке интелигенције, као што су неуронске мреже, методе потпорних вектора, системи засновани на фази логици, и
- 4) хибридни модели, који представљају комбинацију претходно поменутих модела, као на пример неуро-фази модели.

Статистичке методе и методе вештачке интелигенције за предикцију користе историјске податке метеоролошких параметара (брзина и смер ветра, температура, глобално зрачење, облачност, влажност, проток воде, итд.), као и мерене податке производње или потрошње у претходном периоду.

Примена метода вештачке интелигенције се значајно повећава у задацима предикције у области енергетске ефикасности и обновљивим изворима енергије, и немогуће је дати свеобухватни приказ радова насталих у овим истраживањима. У наставку се даје преглед истраживања и радова у контексту примена техника вештачке интелигенције у области предвиђања енергије ветра, соларне енергије, предвиђања протока и електроенергетске производње у хидроелектранама, и потрошње енергије у зградарству, које је идентификовано као једна од кључних области у програму енергетске ефикасности. Са друге стране, постоји и велика разноврсност у погледу самих метода, те ће се у овом раду преглед и примена ограничити на вештачке неуронске мреже (artificial neural networks, ANN), тачније две врсте ових мрежа: ANN без повратних веза (feedforward neural networks, FFNN) и ANN са радијално базисним функцијама (radial basis functional neural network, RBFN), као и на методе потпорних вектора (support vector machine, SVM) и потпорних вектора за регресију (support vector regression, SVR).

2.1. Предвиђање енергије ветра

Енергија ветра, економски конкурентна и еколошки прихватљива, постала је најбржи растући обновљив извор енергије у свету за производњу електричне енергије, [2]. Међутим, због стохастичке природе ветра, временски и просторно, прецизне информације о динамици ветра на локацији ветроелектране су пресудне за рад и управљање система за претварање енергије ветра у електричну енергију. На пример, дугорочно предвиђање енергије ветра је од виталног значаја за процену потенцијала ветра и избор локације ветроелектране, док је краткорочно предвиђање брзине ветра важно за побољшање ефикасности система за производњу електричне енергије, као и интеграцију енергије ветра у електроенергетски систем. Приступ предвиђању се може одредити на темељу расположивих информација и временског хоризонта предвиђања. Краткорочна предвиђања углавном помажу у дневном и унутар дневном раду, управљању и одржавању система. За период од неколико секунди до неколико минута, циљ предикције је управљање система за конверзију енергије ветра. Предикција брзине ветра

у часовном интервалу односи се на проблем распореда рада појединих погона у енергетском систему, док се предвиђања у оквиру неколико дана односе на одржавање и планирање ресурса.

Брзина ветра има највећи утицај на генерисану електричну енергију ветрогенератора, и њено предвиђање је основа индиректних метода предвиђања, у којима се потом укупна производња израчунава коришћењем криве снаге турбине. Такође, генерисана електрична енергија зависи и од густине ваздуха, која пак зависи од његове релативне влажности и температуре. Ови параметри, као и број часова производње (који се дефинише као временски период током кога ветрогенератор генерише електричну енергију), коришћени су у [3], као улази у неуронску мрежу са два скривена слоја, за предвиђање производње електричне енергије једног ветропарка. Предвиђање брзине ветра 1 час унапред, применом три различите врсте неуронских мрежа (ADALINE, FFNN и RBFN) разматрано је у [2]. Метода потпорних вектора за регресију, способна да моделује нелинеарне релације на ефикасан и стабилан начин, демонстрира добре перформансе у проблемима регресије и предикције временских серија. У [4] је представљен систематски начин подешавања параметара SVR модела (величина обучавајућег скупа, ред методе, параметри кернела) за предикцију брзине ветра са линеарним, Гаусовим и полиномијалним кернелом, где су добијени упоредиви резултати по питању тачности. Примена SVR методе за предикцију брзине ветра и поређење добијених резултата са FFNN неуронском мрежом приказано је у [5]. Слично, у [6] је анализирана предикција и брзине ветра и произведене електричне енергије ветрогенератора са временским хоризонтом предвиђања од 10 минута до сат времена. У [7] је модел ANN коришћен за предвиђање произведене електричне енергије ветропарка, где су улазне величине модела брзина ветра, релативна влажност и часови производње. Већина истраживања се фокусира на предикцији брзине ветра, на супрот предикцији правца ветра. У [8] коришћене су ANN и SVM за предикцију правца ветра неколико минута унапред. Проблем дугорочне прогнозе брзине ветра и произведене електричне енергије, која се заснива на метеоролошким информацијама, за највише 72 дана унапред, третиран је у раду [9]. Као улазне величине, предложени модели користе нумеричке предикције брзине и правца ветра. Преглед истраживања предикције брзине ветра и производње електричне енергије ветрогенератора се може наћи у [10].

2.2. Предвиђање соларне енергије

Пошто произведена електрична енергија фотонапонским системом највише зависи од променљивости сунчевог зрачења и фактора околине, неочекиване варијације снаге фотонапонског система могу повећати оперативне трошкове електроенергетског система повећавајући захтеве за примарним резервама, као и да унесу потенцијалне ризике у поузданост снабдевања електричном енергијом. Поред оператора дистрибутивног система, предвиђање снаге фотонапонског система у реалном времену захтевају и разни крајњи корисници, као што су трговци енергијом, енергетски пружаоци услуга и независни произвођачи енергије, а да би обезбедили улазне параметре за различите функције, као што су економско планирање, трговање енергијом, и процена безбедности, [11]. Проблем предвиђања производње електричне енергије фотонапонских система се у многим случајевима решава у две фазе. У првој фази, врши се предвиђање сунчевог зрачења које се заснива на различитим методама, где се историјски (мерени) подаци и неки метеоролошки подаци за дато место користе у конструкцији одговарајућег модела. У другој фази, предвиђене вредности зрачења и температуре се користе као улазни параметри за комерцијалне симулационе софтвере. Поред тога, у другим радовима, емпиријски или једноставни нумерички модели се користе за израчунавање произведене електричне енергије коришћењем података о времену.

Примена ANN методе за предвиђање глобалног сунчевог зрачења на хоризонталној површини приказана је у [12], док је предвиђање средњег месечног сунчевог зрачења применом SVM методе тема рада [13]. Под претпоставком да је могуће побољшати краткорочну предикцију глобалног сунчевог зрачења применом ANN модела користећи просторну компоненту (локације суседних станица) и других улазних величина, у [14] се истражује предвиђање глобалног зрачења у временским хоризонтима од 1 до 6 часова моделујући ANN који укључује различите метеоролошке податке са суседних станица (температуру, релативну влажност, итд.).

Сунчево зрачење, услед утицаја метеоролошких услова, није детерминистичка величина. Постојство облака је један од најважнијих фактора слабљења сунчевог зрачења, а сам процес слабљења зрачења је нелинеаран, комплексан и динамички услед утицаја физичких феномена, и услед његове променљивости у времену и простору. Имајући то у виду, у [15] је предложена процедура којом се предвиђају не само часовне вредности глобалног зрачења, већ и вредности индекса ведрине за следећи дан. Моделовање и предикција су извршени у две различите фазе и применом различитих техника. Алгоритам за кластеризацију се најпре користи да се идентификује колико различитих типова дана

постоје (у правој фази), а у другој фази се различити класификациони алгоритми комбинују са регресионим алгоритмима, са четири различите методе комбиновања: ANN, SVM, SVR и стабло одлучивања. Класификациони алгоритми се користе за процену кластера коме одређени дан припада. Регресиони алгоритми се користе за процену дневног индекса ведрине, а потом се ова два естимована параметра користе за предикцију часовног соларног зрачења. Последњих година методе вештачке интелигенције користе, осим података о зрачењу на површини Земље, и сателитски добијене податке, као на пример у [16]. Фокус у [17] је на унутар дневном предвиђању сунчевог зрачења са хоризонтом предвиђања од 1 до 6 часова. Користи се ANN модел за предвиђање глобалног хоризонталног зрачења користећи мерене податке на земљи, а побољшање тачности предикције је постигнуто увођењем и сателитских података као улазних величина модела.

Реалистичне инсталације фотонапонских система обично укључују већу сложеност, како геометријску тако и сложеност по питању израчунавања соларног зрачења, а алтернативна стратегија може бити директно предвиђање производње електричне енергије базирано на неким а priori информацијама, или лако доступним подацима. У [11] је приказан прилаз у предвиђању генерисане електричне енергије комбиновањем неуронске мреже са RBFN мрежама и класификације типа времена, тј. типа дана. Као улазне величине коришћене су претходне вредности излаза (снаге) и метеоролошке прогнозе интензитета сунчевог зрачења, релативне влажности и температуре ваздуха за место где се фотонапонски систем налази. За класификацију локалног типа времена 24 часова унапред, за коју се подаци добијају из локалног метеоролошког сервиса, коришћене су самоорганизоване мапе, које су знатно побољшале тачност предвиђања. Поређење ANN, SVR, методе k -најближих суседа и мултиваријабилне линеарне регресије за предвиђање дневног сунчевог зрачења, са и без укључивања метеоролошких параметара као улазних величина, као и процедуре за избор улазних параметара, дато је у [18]. Циљ истраживања у [19] био је да се одреди временски хоризонт предвиђања који је најрепрезентативнији за предвиђање генерисане електричне енергије једне мале фотонапонске електране.

Рад [20] третира примену SVR методе за предикцију снаге фотонапонског система коришћењем претходно мерених вредности снаге, нумеричке предикције метеоролошких параметара и предикције сунчевог зрачења примененог вектора кретања облака, а за временски хоризонт од 15 минута до 5 часова унапред. При томе, разматран је појединачни фотонапонски систем, као и регионални, који је посебно значајан за операторе преносног система у циљу управљања мрежом на ефикасан начин. Анализирани хоризонти предвиђања су најинтересантнији за унутар дневно тржиште енергије.

Претходно наведена истраживања су углавном имала акценат на тзв. тачкасту прогнозу, то јест, једну прогнозирану вредност за одређени временски тренутак. Интервална прогноза, која је погоднија за високо променљиву природу соларног зрачења, тема је рада [21]. Разматран је посебан тип интервалног предвиђања, који се назива 2Д интервално предвиђање, где је циљ предвидети опсег очекиваних вредности за излазну снагу фотонапонског система, за будући интервал времена. У моделу су коришћене претходне вредности мереног излаза и метеоролошки подаци као улазне величине, и SVR регресија као предикциони алгоритам.

2.3. Предвиђање протока и производње у хидроелектранама

У области обновљивих извора енергије хидроенергија се сврстава у економски и еколошки најприхватљиве изворе. Због својих карактеристика и економске одрживости, многе државе зависе од извлачења енергије из расположивих извора воде. Трансформација енергије воде се врши у енергетски врло ефикасним хидроенергетским постројењима. Основни показатељ од кога зависи електроенергетска производња у хидроелектранама је проток. Поуздан податак о протоку, као стохастичкој величини изразито променљивог и неравномерног карактера у времену, је од непроцењивог значаја за управљање водопривредних и оптималну експлоатацију електроенергетских система, [22]. Стога се вишедеценијски истраживачки напори улажу у покушаје да се ваљано и поуздано прогнозирају процоти на речним сливовима и водотоцима.

У том циљу се развијају и примењују бројне савремене статистичке, геостатистичке, регресионе и фази методе како би се поузданост добијених података подигла на виши ниво. С друге стране, разноврсност и бројност постојећих симулационих модела и софтверских алата који се користе у хидролошкој пракси указују да не постоје једнозначни концепти и јединствени приступи. Последњих година, методе вештачке интелигенције су нашле своју интензивну практичну примену у решавању инжењерских проблема у хидрологији.

У [23] је применом вишеслојних неуронских мрежа без повратних веза вршена предикција годишњих протока. Упоредна анализа добијених протока који су предвиђани помоћу двадесет различитих

тих неуронских мрежа приказани су у [24]. Увођењем хибридних модела [25] и комбинујући анализе помоћу SWAT (Soil and Water Assessment Tool) и вештачких неуронских мрежа, [26], показује се тежња ка унапређењу поузданости предвиђања дневних и недељних протока. У [27] је представљена примена комбинације рекурентне неуронске мреже и SVM методе за предикцију падавина. Осим тога, хаотични алгоритам оптимизације ројем честица је искоришћен за избор параметара SVM модела.

Савремене методе засноване на методама вештачке интелигенције пружају могућност поуздане предикције производње у хидроелектранама, али се поред познавања протока мора располагати и подацима о другим енергетским параметрима (пад, експлоатационе карактеристике хидроагрегата, оперативна корисна запремина акумулације, резервисана запремина акумулације за пријем и ретензирање таласа великих вода, итд.). Пример коришћења ових метода за предикцију производње у једној малој хидроелектрани приказан је у раду [28]. Затим, у раду [29] је, такође за малу хидроелектрану, приказан хибридни модел потпорних вектора и генетског алгоритма за предикцију краткорочне производње енергије.

2.4 Предвиђање потрошње енергије у зградарству

Чињеница да је у Европи сектор зградарства одговоран за 40% укупне потрошње енергије, као и за 36% емисије CO₂, [30], даје енергетској ефикасности, а самим тим и анализи потрошње енергије, посебан значај. Предвиђање потрошње енергије у зградама има веома важну улогу у управљању енергије зграде, јер може да укаже на употребу енергије изнад дозвољених граница, и/или да дијагностикује могуће узроке, уколико има довољно прикупљених мерених, историјских података, [31]. Научници и инжењери се у последње време, осим примени класичних метода за израчунавање потрошње енергије, све више окрећу ка анализи стварне употребе енергије у зградама. Један од разлога је тај што због сложености и великог броја утицајних параметара (климатски параметри, омотач зграде, опрема у згради, одржавање и управљање енергије, понашање корисника, унутрашњи услови), математички модели не могу добро да предвиде потрошњу енергије, тако да постоји потреба за реалном сликом о коришћењу енергије, која се добија коришћењем измерених и анализираних података.

Алтернатива многобројним софтверима за моделовање енергетског понашања зграде, који захтевају познавање великог броја параметара, су методе засноване на мереним вредностима, а међу њима и методе вештачке интелигенције. Преглед примене и класификација метода за предикцију потрошње енергије дат је у [32] и [33]. ANN модел је примењен у [34] за анализу укупне годишње потрошње енергије. Улазне величине за развијене методе су средња годишња спољашња температура, инсталисана снага, годишња потрошња енергије по становнику и бруто доходак по домаћинству. Резултати су упоређени и са резултатима добијеним линеарном регресијом и методом потпорних вектора, и показали су најбоље поклапање са стварним мереним вредностима. У радовима [35] и [36] аутори су поредили моделе добијене различитим неуронским мрежама и методом потпорних вектора за предвиђање топлотног оптерећења зграде. У раду [37] представљен је SVM модел за предвиђање месечне потрошње енергије зграде, при чему су улазне величине средња месечна спољашња температура, релативна влажност и глобално сунчево зрачење. Детаљнији преглед примене SVM и ANN метода за предвиђање потрошње електричне енергије може се наћи у [38]. У [39] је дискутовано како се неуронске мреже, примењене за предикцију потрошње енергије у зградама, могу побољшати неким статистичким процедурама. Анализирана је идентификација свих потенцијалних, релевантних улаза и избор скривених слојева за прелиминаран скуп улаза. Примена различитих топологија неуронских мрежа је анализирана у [40]. Најпре, упоређени су резултати предикције добијени различитим мрежама - FFNN, RBFN и адаптивним неуро-фази системом (adaptive neuro-fuzzy inference systems, ANFIS). Након тога, предложена је квалитативно нова метода, њихово комбиновање у облику ансамбла. При томе, све те анализе су вршене за различит број улазних величина. У радовима [31] и [41-47] креирани су модели различитих топологија мрежа (FFNN, RBFN, ANFIS, SVM), са различитим бројем улазних величина, за предикцију потрошње енергије једног универзитетског кампуса. Побољшања тачности предикције су постигнута креирањем ансамбла развијених модела, једноставним комбиновањем, као и новим методама, коришћењем вишестепеног ансамбла. Преглед различитих модела неуронских мрежа које се користе у предикцији енергије у зградама може се наћи у [48].

3. Методе вештачке интелигенције за предикцију

3.1. Вишеслојне неуронске мреже без повратних веза

Вештачке неуронске мреже представљају рачунарску структуру инспирисану биолошким нервним системом, и састоје се из великог броја веома једноставних и међусобно повезаних процесора који се називају неурони. Архитектура или топологија мреже одређује начин на који су неурони ме-

ђусобно повезани, а са друге стране, она је и у директној вези са алгоритмом који се користи у обучавању мреже. Код вишеслојних мрежа без повратних спрега неурони су организовани у слојеве, и не постоје никакве повратне или латералне везе између неурона. Ова мрежа се састоји од улазног слоја, излазног слоја и једног или више скривених слојева. Излаз из одређеног неурона је функција улазних величина, тежинских коефицијената (синаптичких тежина), прага осетљивости неурона и активационе функције. У једној типичној, потпуно повезаној мрежи, сваки појединачни неурон је повезан са неуронима из претходног слоја, и његов излаз је одређен са:

$$y_i = f \left(\sum_{j=1}^n w_{ij} x_j + b_i \right) \quad (1)$$

где су x_1, x_2, \dots, x_n улазни сигнали, $w_{i1}, w_{i2}, \dots, w_{in}$ су синаптичке тежине i -тог неурона, b_i је праг осетљивости (bias) i -тог неурона, f је активациона функција и y_i је излазни сигнал неурона. Сваки неурон прима улазне сигнале од других неурона или из спољашњег окружења, локално их обрађује користећи активациону функцију и генерише трансформисани излазни сигнал који се води на друге неуроне или пак у спољашњу средину.

Особина мреже која је од примарног значаја је њена способност да учи из свог окружења и побољшава своје перформансе кроз процес учења. Мрежа учи о свом окружењу кроз интерактивни процес подешавања својих синаптичких тежина и прагова осетљивости. Углавном, алгоритми за обучавање FFNN мрежа се заснивају на принципу итеративне корекције грешке, а алгоритам обучавања са повратним простирањем грешке (backpropagation algorithm, BP) и алгоритми изведени из њега представљају најчешће коришћене. BP алгоритам користи градијентну методу за минимизацију функције грешке, која представља квадрат разлике између жељених и стварних излаза мреже. Функција грешке коју BP алгоритам минимизира може се изразити као:

$$E = \frac{1}{2} \sum_j \sum_k (y_{jk} - \hat{y}_{jk})^2 \quad (2)$$

где су: j -индекс узорка, k -индекс елемента у вектору излаза мреже, y_k је k -ти елемент жељеног вектора излаза излаза за j -ти узорак и \hat{y}_k је k -ти елемент вектора излаза који се добија када се узорак j доведе на улаз мреже.

У процесу обучавања, функција грешке се минимизира модификовањем синаптичких тежина и прагова осетљивости неурона, и тај процес се понавља све док грешка не буде мања од неке предефинисане вредности, или док се не достигне максималан број итерација. Најпре се синаптичке тежине неурона иницијализују на случајне вредности, а потом се обучавајући скуп улазних података доводи на улазни слој мреже, који се простира кроз мрежу све до излазног слоја, и као резултат овог, тзв. унапредног тока сигнала, на излазном слоју мреже се генерише излазни скуп података. Уколико је овај скуп података различит од жељеног скупа података за дати улазни скуп, израчунава се грешка излаза, и овај сигнал грешке се простира уназад од излазног слоја до улазног слоја и користи се за подешавање њихових тежина. Након обучавања, мрежа се може користити и за предвиђање излаза за вредности вектора улаза које нису коришћене у процесу обучавања.

Јединствена предност примене неуронских мрежа је што није потребно дефинисати јасну везу између улазних и излазних величина пре коришћена модела за процес предвиђања, пошто се веза између величина одређују током учења. За вишеслојну мрежу без повратних веза и са једним скривеним слојем, излаз из мреже, у скаларном случају се може изразити као:

$$\hat{y} = f_2 \left\{ \sum_{i=1}^h w_i f_1 \left[\sum_{j=1}^p w_{ij} x_j + b_{i0} \right] + b_0 \right\} \quad (3)$$

где излаз мреже \hat{y} представља предикцију величине y , w_i и w_{ij} су тежински коефицијенти, а b_{i0} и b_0 су прагови осетљивости. Скалар h означава број неурона у скривеном слоју, p представља број улазних величина, док су f_1 и f_2 активационе функције у скривеном и излазном слоју, следствено.

1.1 3.2. Неуронске мреже са радијално базисним функцијама

Неуронска мрежа радијалних базисних функција, као врста вишеслојне неуронске мреже без повратних спрега, се састоји од једног улазног, једног скривеног и једног излазног слоја. Улазни чворови мреже су директно повезани са скривеним слојем, који врши нелинеарну трансформацију улаз-

ног простора у вишедимензионални простор скривеног слоја. Нелинеарна функција скривених неурона је симетрична у улазном простору, и излаз сваког скривеног неурона зависи само од радијалног растојања између улазног вектора и центра скривеног неурона. За RBFN мрежу са n -димензионалним вектором улаза $\mathbf{x} \in \mathbb{R}^n$ излаз j -тог неурона је одређен са:

$$h_j(\mathbf{x}) = \phi_j(\|\mathbf{x} - \mathbf{c}_j\|), \quad j = 1, 2, \dots, m \quad (4)$$

где је \mathbf{c}_j центар (вектор) j -тог скривеног неурона, m је број неурона у скривеном слоју, а ϕ је радијална базисна функција. Према томе, RBFN мрежа користи радијалну симетричну функцију као активациону функцију у скривеном слоју, и у овом раду се користи Гаусова функција, као најчешће коришћена. Трећи, излазни слој врши линеарну трансформацију из простора скривеног слоја у излазни простор, па је, према томе, одређен линеарном активационом функцијом. Коначно, k -ти излаз мреже се добија тежинским сумирањем излаза свих скривених неурона који су повезани са датим излазним неуроном:

$$y_k(\mathbf{x}) = \sum_{j=1}^m w_{kj} h_j(\mathbf{x}) + w_{k0} \quad (5)$$

где је w_{kj} тежински коефицијент између j -тог скривеног неурона и k -тог излазног, w_{k0} је праг осетљивости, а m је број неурона у скривеном слоју. Обучавање мреже подразумева подешавање параметара Гаусове функције, и тежинских коефицијената између скривеног и излазног слоја. На пример, центри се могу бирати неким алгоритмом кластеризације, док се тежински коефицијенти излазног слоја могу подешавати градијентном методом или методом најмањих квадрата.

3.3. Метода потпорних вектора за регресију

Метода потпорних вектора, као класа модела са надгледаним учењем, оригинално је развијена за решавање проблема класификације, али се успешно користи и у проблемима регресије и предикцији временских серија, [49, 50]. SVR може успешно да ради са високо димензионалним подацима и има одличну способност регуларизације за сложене моделе са релативно малим обучавајућим скупом узорака. За разлику од неуронских мрежа, код којих се током обучавања добија локално оптимално решење, SVR метода доводи до једнозначног глобалног решења, са мањим бројем параметара које треба подесити.

Нека је $\{\mathbf{x}_i, y_i\}$, $i=1, \dots, N$ скуп узорака за обучавање, са улазним подацима $\mathbf{x} \in \mathbb{R}^n$ и излазним подацима $y \in \mathbb{R}$. Нелинеарни задатак регресије SVR методом се решава пресликавањем Φ простора улаза (димензије n) у вишедимензионални простор (на пример m , при чему је $m \geq n$), где проблем постаје линеаран, и где потом треба решити проблем линеарне регресије:

$$y = f(\mathbf{x}) = \mathbf{w}^T \Phi(\mathbf{x}) + b, \quad \mathbf{w} \in \mathbb{R}^m, \quad b \in \mathbb{R} \quad (6)$$

Према томе, линеарна регресија у новом (вишедимензионалном) простору одговара нелинеарној регресији у оригиналном (мање димензионалном) простору, и кључни задатак у решавању овог проблема је наћи оптималне параметре \mathbf{w} и b . У тзв. ε -SVR методи, која се користи у овом раду, циљ је наћи функцију $f(\mathbf{x})$ која најбоље апроксимира стварну вредност излаза за све узорке, са највећим могућим одступањем ε . Дакле, ε дефинише околину регресионе линије која одговара прецизности са којом ће се улазно-излазно пресликавање апроксимирати – све грешке које се налазе унутар ε околине се игноришу. Параметри \mathbf{w} и b могу се наћи решавањем проблема оптимизације:

$$\text{минимизирати} \quad \frac{\lambda}{2} \|\mathbf{w}\|^2 + C \frac{1}{N} \sum_{i=1}^N L(y_i, f(\mathbf{x}_i, \mathbf{w})) \quad (7)$$

где $L(y_i, f(\mathbf{x}_i, \mathbf{w}))$ представља функцију губитка са ε зоном неосетљивости дефинисану са:

$$L(y_i, f(\mathbf{x}_i, \mathbf{w})) = \max\{0, |y_i - f(\mathbf{x}_i, \mathbf{w})| - \varepsilon\} \quad (8)$$

Први члан у једначини (7) одређује комплексност модела и користи се у превенцији од преобучавања избором одговарајуће константе регуларизације λ . Други члан у једначини (7) садржи функцију губитка и одређује тачност апроксимације, која пак зависи од толеранције грешке ε . Константа C представља и одређује компромис између грешке обучавања и комплексности модела. Оптимизациони метод дефинисан са (7) се може трансформисати у дуални проблем квадратног програмирања увођењем Лангранжеових множитеља и применом тзв. кернел методе, чиме он постаје:

$$\begin{aligned} & \text{максимизирати} \quad \left\{ -\frac{1}{2} \sum_{i,j=1}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)k(\mathbf{x}_i, \mathbf{x}_j) - \varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \right. \\ & \text{уз услов} \quad \left. \left\{ \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0, \alpha_i, \alpha_i^* \in [0, C] \right. \right. \end{aligned} \quad (9)$$

Применом кернел методе, функционални облик пресликавања не мора бити познат већ се имплицитно дефинише избором кернел функције $k(\mathbf{x}_i, \mathbf{x}_j) = \Phi^T(\mathbf{x}_i)\Phi(\mathbf{x}_j)$. Решење оптимизационог проблема (9) је облика:

$$f(\mathbf{x}, \alpha, \alpha^*) = \sum_{i=1}^N (\alpha_i - \alpha_i^*)k(\mathbf{x}_i, \mathbf{x}) + b \quad (10)$$

при чему ће само одређени број коефицијената α_i, α_i^* бити различит од нуле, и вектори података њима придружени се називају потпорни вектори. Неки од типичних избора за кернел у SVR методи су линеарни, полиномијални и Гаусов кернел, или радијално базисни кернел, који се користи у овом раду:

$$k(\mathbf{x}_i, \mathbf{x}) = \exp\left(-\gamma \|\mathbf{x} - \mathbf{x}_i\|^2\right) \quad (11)$$

4. Примери примена метода вештачке интелигенције у обновљивим изворима енергије и енергетској ефикасности

Примена изложених метода вештачке интелигенције илустрована је кроз примере предвиђања производње енергије једног ветропарка (RBFN метода), производње енергије једног фотонапонског система (SVR метода), предвиђање протока реке Дунав (FFNN метода) и предвиђање потрошње енергије за грејање једног универзитетског кампуса (више модела). За све моделе је заједничко да су од доступног скупа улазно-излазних података формирана два скупа: скуп обучавајућих података, и скуп података за тестирање модела (тест скуп података). Модели су обучавани на обучавајућем скупу података, а њихова тачност и квалитет су анализирани на, за њих непознатом, тест скупу узорака.

У истраживањима, литератури и пракси, различите мере тачности су предложене и прихваћене у оцени тачности предвиђања, а у овом раду се користе следећи критеријуми: средња процентуална апсолутна грешка (MAPE - the mean absolute percentage error) и квадратни корен квадрата грешака (RMSE - the root mean square error), дефинисани, следствено, са:

$$\text{MAPE} = \frac{1}{N} \sqrt{\sum_{k=1}^N \frac{|y_k - \hat{y}_k|}{y_k}} \cdot 100, \quad \text{RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2} \quad (12)$$

где су y_k и \hat{y}_k стварна и предвиђена вредност модела за k -ти узорак, следствено, а N је број узорака. Такође, све улазне и излазна величина обучавајућих и тест скупова података су нормализоване на интервал (0,1) применом линеарне функције скалирања:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad i = 1, \dots, N \quad (13)$$

где су x_{\max} и x_{\min} очекиване максималне вредности посматране променљиве, а да би се избегао доминантан утицај неке од њих услед различитости опсега њихових вредности.

4.1. Пример предикције енергије ветра


За пример предикције енергије ветра у раду се користе доступни подаци за укупну снагу свих ветропаркова у Белгији, [51]. База података садржи мерене податке о укупној производњи, за временски период од три месеца - од 1.02.2017. до 30.04.2017. године, са интервалом мерења од 15 минута. Дакле, задатак предикције је краткорочна предикција снаге, и то само на основу претходних мерених вредности снаге, чиме се он своди на предикцију временске серије. Генерално, временска серија представља скуп временски уређених опсервација неке променљиве у току више узастопних и једнаких интервала. Смисао анализе временске серије јесте управо откривање законитости у развоју појаве (процеса, величине) која се моделује, а како би се те законитости могле пројектовати на будући период и извршила предикција појаве за неки краћи или дужи временски период. Основни модел за предикцију временске серије је облика:

$$\hat{y}(t+T) = f(y(t), y(t-T), \dots, y(t-mT)) \quad (14)$$

где је T временски интервал, $\hat{y}(t+T)$ предвиђена вредност променљиве y , а $y(t)$, $y(t-T)$, ..., $y(t-mT)$ су њене тренутна и претходне вредности, следствено. Према томе, број предиктора, тј. улазних величина модела (14) је $m+1$, и њихов избор је значајан за добијање што тачнијег модела.

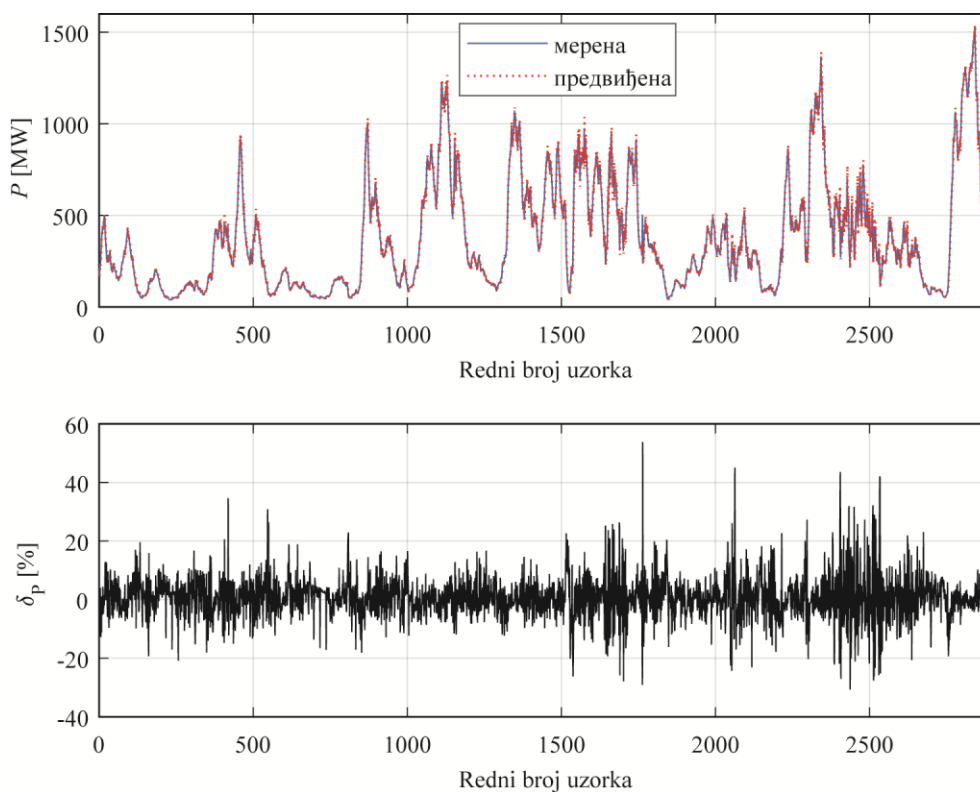
У овом раду анализирана је парцијална аутокорелациона функција излазне величине, (која показује корелацију излазне величине са њеним вредностима у претходним тренуцима), након чега су изабране две улазне величине, тј. вредности мереног излаза у претходна два временска тренутка. Из доступне базе података првих 5658 узорака је изабрано за обучавање, а остатак од 2880 за тестирање модела.

RBFN мрежа је обучавана тако што се мрежа итеративно креирала додавањем по једног неурона у сваком тренутку интерације. Број неурона у скривеном слоју је аутоматски повећаван док се није постигла задата вредност грешке или док се није достигао максимални број неурона у скривеном слоју, те су у том смислу одређене оптималне вредности параметара RBFN мреже, тј. параметар Гаусових радијалних базисних функција (њихова ширина).



Слика 1 Резултати предикције снаге ветропарка за обучавајући скуп података

Поређење предвиђених и стварних (мерених) вредности снаге ветропарка дато је на сликама 1 и 2, за обучавајући и тест скуп података, следствено. Као показатељ квалитета, односно тачности предвиђања, приказане су и вредности релативног одступања δ_P између предвиђених и мерених вредности. Екстремна вредност релативног одступања модела на обучавајућем скупу је приближно -71%, а приликом тестирања око 54%. Међутим, број тачака са већим релативним одступањима је мали у односу на број узорака у оба скупа података. Тако, на пример, укупно за 69 узорака на тест скупу је вредност релативног одступања већа од $\pm 20\%$, што чини 2,4% од укупног броја узорака. Ако се $\pm 10\%$ релативног одступања прогласи прихватљивим, тада на тест скупу укупно 2810 узорака задовољава тај критеријум, тј. 87,25% узорака. Вредности средње апсолутне процентуалне грешке су 4,15% за обучавајући и 5,29% за тест скуп података, а вредности корена средње квадратне грешке су 34,01 MW за обучавајући скуп, односно 28,76 MW за тест скуп узорака.

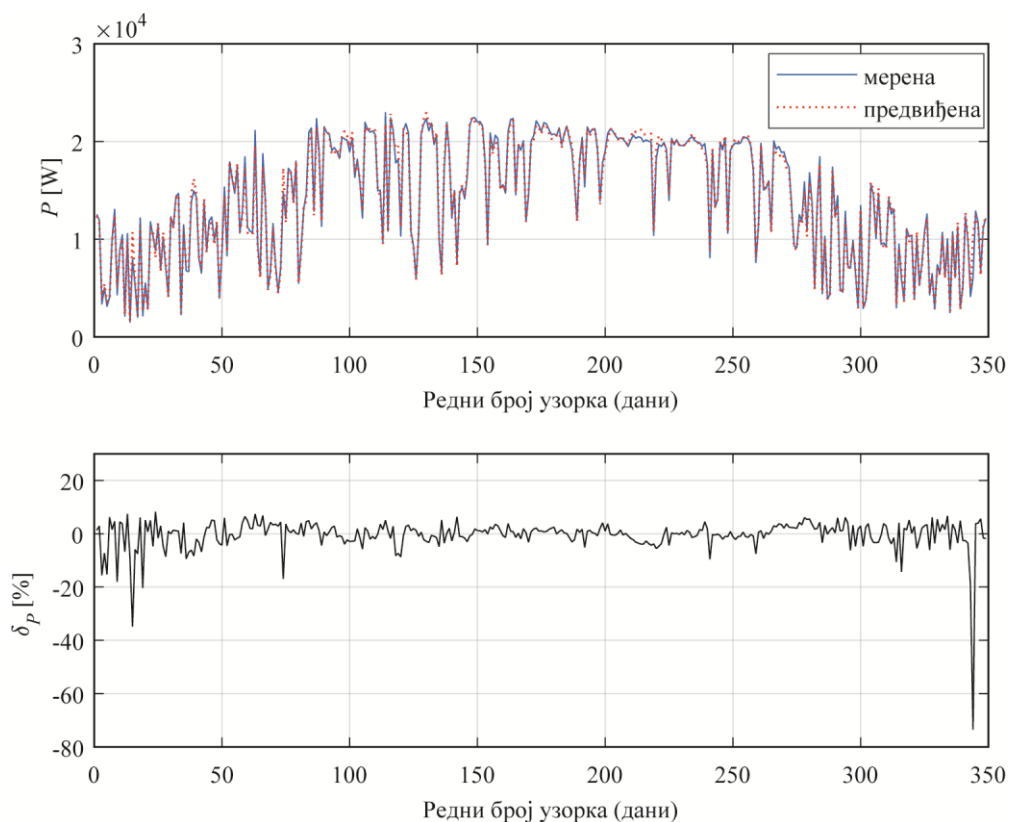


Слика2 Резултати предикције снаге ветропарка за тест скуп података


4.2. Пример предикције производње фотонапонског система

SVR метода је искоришћена за предикцију производње једног фотонапонског система инсталираном у граду Bend, Oregon, USA, при чему је коришћена база података из Solar Monitoring Laboratory, University of Oregon, USA, [52], за период од 1.01.2016.-31.12.2017. године. Мерења се на поменутом систему врше са интервалом мерења од 5 минута, на основу којих се формира база података са дневним вредностима. Након што су из скупа података уклоњени подаци са грешкама и недостајућим вредностима, од података за 2016. годину (укупно 349 узорака) формиран је обучавајући скуп података, док је 336 узорака за 2017. годину предвиђено за тестирање модела, тј. предикцију. У скупу података се, осим произведене снаге фотонапонског система, налазе и вредности за глобално сунчево зрачење и зрачење под углом од 30° , $[W/m^2]$, средња вредност брзина ветра $[m/s]$, као и средња, минимална и максимална дневна температура $[^\circ C]$. Иако је код метода заснованих на мерним вредностима идентификација најутицајнијих променљивих (тј. избор улазних величина модела) кључни задатак, у овом примеру неће бити фокус на томе, већ да се покаже могућност синтезе једног оваквог модела, а на основу већ доступних метеоролошких параметара. За SVR модел усвојена је Гаусова кернел функција, дефинисана једначином (11). Параметри које треба оптимизовати у моделу су константа C из једначине (7), вредност ϵ из функције губитка и параметар саме Гаусове функције, тј. њена ширина γ . Оптимизација је вршена применом технике тзв. мрежног претраживања, где се параметарска област претражује комбинацијама параметара.

Упоредни приказ предвиђених и измерених вредности снаге за обучавајући и тест скуп података у случају фотонапонског система приказан је на сликама 3 и 4. Средња апсолутна процентуална грешка за обучавајући скуп података је 3,28%, а 3,78% за тест скуп података. Што се тиче вредности корена средње квадратне грешке, оне су 538,35 W и 723,35 W, за обучавање и тестирање, следствено. Екстремна вредност релативног одступања δ_p за обучавајући скуп узорака је око -73%, и осим још једне вредности (око -35%), све остале вредности су испод $\pm 20\%$. На тест скупу узорака, екстремно релативно одступање је 53%. Може се уочити да је на тест узорцима, осим за 20-так узорака, вредност релативног одступања у границама $\pm 10\%$.



Слика 3 Резултати предикције снаге фотонапонског система за обучавајући скуп података



Слика 4 Резултати предикције снаге фотонапонског система за тест скуп података


4.3. Пример предикције протока

Чињеница да је производња електричне енергије у проточним хидроелектранама директна последица дотицаја воде указује на значај предикције протока, и у овом раду је креиран модел на бази ANN за дневну предикцију протока воде. Подаци о дневним протоцима на реци Дунав, [53], за временски период од 2005 –2014. године, чине базу мерених података, при чему су мерени подаци за


првих осам година (период од 2005. године до 2012. године) изабрани за обучавајући скуп података, а преостале две године за тест скуп података. С обзиром да се располаже само са мереним, историјским подацима о протоку, задатак предикције протока се своди на проблем предикције временске серије.

Архитектура мреже је генерално дефинисана бројем скривених слојева и бројем неурона у сваком од тих слојева, и она одређује број параметара модела које је неопходно естимовати. Број неурона у улазном слоју једнозначно је одређен бројем улазних величина, док се у излазном слоју налази један неурон. Анализом парцијалне аутокорелационе функције усвојене су две улазне величине, тако да је задатак модела да предвиди вредност протока $Q(k)$ у неком дану k , а на основу мерених вредности протока протекла два дана, $Q(k-1)$ и $Q(k-2)$. Код FFNN мреже број скривених слојева је један од параметара мреже који треба одредити, а у циљу добијања најбољег решења. Међутим, у овом раду је усвојено да мрежа има један скривени слој, јер је показано да оваква структура може да апроксимира било коју непрекидну функцију са жељеном тачношћу, [54]. Коначно, број неурона у скривеном слоју мреже је одређен итеративним путем тако што је обучавање започето са минималним бројем неурона, након чега је њихов број повећаван све док се није добила задовољавајућа тачност. Као алгоритам обучавања мреже изабран је Levenberg–Marquardt алгоритам, као једна од варијанти ВР алгоритма, и с обзиром да он захтева да активационе функције неурона буду диференцијабилне функције, у скривеном и излазном слоју коришћени су хиперболички тангенс и линеарна функција, следствено.

Резултати предикције ANN мреже за предвиђање протока реке Дунав приказани су на сликама 5 и 6, за обучавајући и тест скуп података, следствено. Осим упоредног приказа мерених и предвиђених вредности протока, приказана су и релативна одступања δ_Q између предвиђених и мерених резултата. На обучавајућем скупу података релативна грешка се налази у интервалу од $\pm 25\%$, док је на скупу за тестирање нешто нижа, $\pm 21\%$. Међутим, треба уочити да је у далеко највећем броју тачака вредност релативног одступања мања од 10% . Тачније, за укупно 690 од 730 узорака за тестирање, тј. за $94,5\%$ узорака, релативно одступање је у границама $\pm 10\%$, а $64,5\%$ узорака је у границама $\pm 5\%$. Средње апсолутне процентуалне грешке обучавања и тестирања су $4,62\%$ и $4,23\%$, следствено, а вредности корена средње квадратне грешке су $324,23 \text{ m}^3/\text{s}$, односно, $331,95 \text{ m}^3/\text{s}$.



Слика 5 Резултати предикције протока за обучавајући скуп података



Слика 6 Резултати предикције протока за тест скуп података

Претходно наведена методологија се итекако поуздано може примењивати за предикцију протока на мањим водотоцима и на малим хидроелектранама. За разлику од великих водотока где је грешка мерења протока релативно велика, [22], мањи водотоци посебно у планинским крајевима могу имати одлике које су изразито неравномерног (у различитим периодима године) и могућег екстремног (бујичасте воде и/или периодична исушивања корита) карактера.

Показатељи тачности предикције - средња апсолутна процентуална грешка и корен квадратне грешке, за све претходно креиране моделе, приказани су у Табели 1. Анализом добијених резултата може се извести закључак да је у свим примерима добијено добро поклапање предвиђених и стварних, мерених података. Креирани модели су потврдили добру способност регуларизације коришћених метода.

Табела 1: Показатељи квалитета предикције

	MAPE [%]		RMSE [MW],[W], [m³/s]	
	обучавање	тестирање	обучавање	тестирање
RBFN (ветропарк)	4,15	5,29	34,01	28,76
SVR (фотонапонски систем)	3,28	3,78	538,35	723,35
FFNN (проток)	4,62	4,23	324,23	331,95

4.4. Пример предикције потрошње топлоте

Примена метода вештачке интелигенције у области потрошње енергије, која је једна од кључних области у задацима енергетске ефикасности, биће показана на примеру предикције потрошње топлоте једног универзитетског кампуса. За разлику од претходна три примера, овај пример се заснива на претходно објављеним резултатима аутора овог рада, који се овде дају у прегледу. С обзиром да је развијено неколико модела, и да су временом нови модели настајали из жеље за побољшањем тачности, преглед даје могућност увида у још неке од метода, а које нису разматране у овом раду, као и неке оригиналне алгоритме. Преглед који следи заснива се на радовима [31] и [41-47].

Универзитетски кампуси су специфичне групе различитих типова зграда, са значајном потрошњом енергије, који због разноликости у намени зграда представљају град у малом, па су одличан пример за анализу и разумевање потрошње енергије. Кампус Норвешког Универзитета Науке и Технологије (Norwegian University of Science and Technology - NTNU) Глосхауген (Gløshaugen) се састоји из 35 зграда, укупне површине око 300.000 m². Из система за праћење и управљање доступни

су подаци о дневној потрошњи енергије за грејање кампуса, а сви метеоролошки подаци су прикупљени у локалној метеоролошкој станици.


У раду [41] за FFNN модел као улазне величине мреже су коришћене средња дневна температура, дан у недељи, месец у години, брзина ветра, сунчево зрачење и релативна влажност спољашњег ваздуха. Улазне величине дан у недељи и месец у години су кодирани користећи бројеве од 1 до 7, и од 1 до 12, следствено. Број неурона у мрежи је вариран током обучавања, и најбоља добијена мрежа је за MAPE показатељ тачности имала вредности 10,62% за обучавање и 10,36% за тестирање. У радовима [42] и [43] су разматране поједностављене FFNN мреже по питању броја улазних величина и показано је и да оне могу са незнатно мањом тачношћу успешно да предвиђају потрошњу енергије. Најпре, у [42] су се као улазне величине користиле само средња дневна температура, дан у недељи и месец у години, а у [43] средња дневна температура, месец у години и параметар који дефинише тип дана (1 за радни дан, 2 за дане викенде и празнике).

Значајно побољшање тачности предвиђања потрошње приказано је у раду [31], у коме је креирано 12 различитих модела, користећи три врсте топологије мрежа - FFNN, RBFN и ANFIS, уз предлагање новог алгоритма. Први корак био је анализа средње дневне спољашње температуре као најутицајнијег параметра на потрошњу енергије за грејање, након чега је база података подељена на три периода: хладан период, умерен период и топао период (ван грејне сезоне). Резултати анализе сугерисали су да би се бољи резултати предвиђања могли добити коришћењем одвојених модела мреже за сваки период, уместо да се користи једна мрежа за целу годину, те је у наставку анализирана потрошња само у хладном периоду (са највећом потрошњом енергије за грејање). Скуп података за обучавање се састојао од података за три године, 2009-2011, а тест скуп података за 2012. Резултати претходне анализе и формирана база су основе и за радове [44-47].

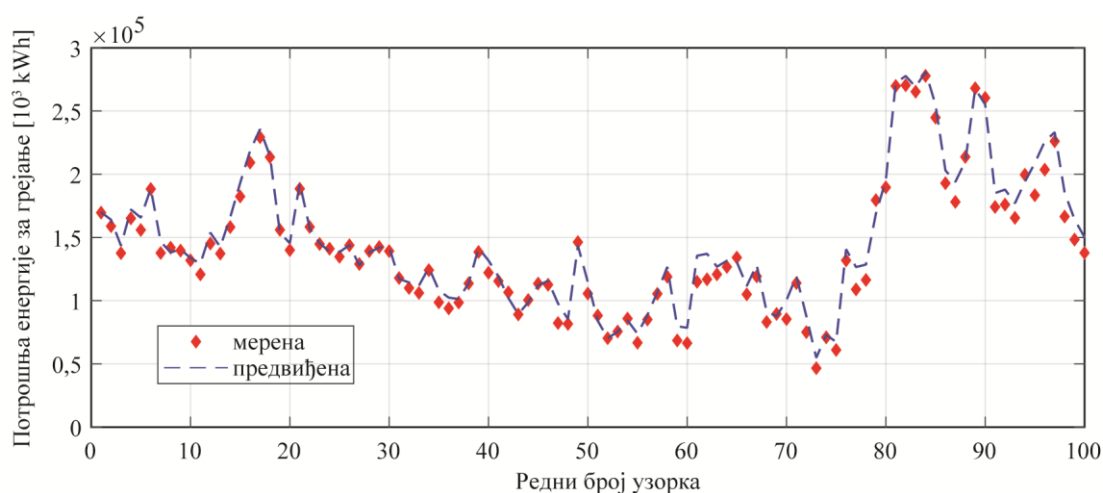
Улазне променљиве за моделе неуронских мрежа, које су овде анализирани су: средња дневна спољашња температура, средња дневна брзина ветра, укупно сунчево зрачење у току дана, најнижа средња дневна температура, највиша дневна температура, релативна влажност спољашњег ваздуха, дан у недељи, месец у години и потрошња топлоте претходног дана. Потрошња топлоте претходног дана је изабрана на основу резултата парцијалне аутокорељационе функције која указује да је највећа вредност аутокорељације добијена за претходни дан. За сваку од топологија мреже је развијено по 3 модела, са свим и редукованим бројем улазних величина. Мањи број улазних величина је значајан за разматрање због чињенице да у реалним условима није увек могуће мерити и прикупити вредности за све величине које су биле доступне у овом случају, као и за случај предвиђања за дужи период када долази до акумулирања грешака (због коришћења предвиђених вредности уместо мерених). Избор најутицајнијих улазних величина вршен је систематски, методом селекције унапред (forward selection), и на тај начин су изабрана још 2 модела - један са 7 улазних променљивих, а други са само 3 улазне променљиве (потрошња топлоте за претходни дан, средња дневна температура и дан у недељи).

Даље побољшање тачности предвиђања је постигнуто применом ансамбла неуронских мрежа. Ансамбл је веома успешна техника, код које се излази посебно обучавањих мрежа комбинују како би се креирало јединствено предвиђање, које показује већу тачност у односу на чланице из којих се састоји. За комбиновање излаза појединачних мрежа примењене су три различите методе – аритметичко осредњавање, тежинско осредњавање и осредњавање методом медијане.

Следећа идеја је била обучити 50 различитих FFNN мрежа и применити k-means алгоритам кластеризације у циљу избора елемената ансамбла. Кластеризација се користи да се мреже поделе у групе, а онда се најбоље мреже по питању тачности из група користе за ансамбл. Ова идеја је реализована у радовима [44] и [45], где су предложени нови алгоритми, тако што су искоришћене FFNN и ANFIS мрежа за креирање двостепеног ансамбла, где су поменуте мреже биле део другог степена у коме се врши комбинација мрежа изабраних кластеризацијом. У [45] је коришћена RBFN мрежа у другом степеноу. У [46], k-means алгоритам кластеризације је коришћен за креирање подскупова скупа обучавања, на којима су обучаване индивидуалне RBFN мреже. Други корак је био комбиновање излаза појединачних мрежа одвојено обучених на различитим скуповима за обучавање, где су након кластеризације сви ти скупови допуњени до оригиналног броја узорака тзв. resampling техником. Коначно, у [47], коришћена је SVR метода, и дато поређење свих претходних резултата. Обучавајући скуп података за све развијене моделе дат је на слици 7, а поређења предвиђених и мерених вредности потрошње енергије за грејање применом једног од модела дат је на слици 8, [46].



Слика 7 Обучавајући скуп подата за предикцију потрошње енергије, [46]



Слика 8 Резултати предикције потрошње енергије на тест скупу података, [46]

Табела 2 даје преглед најбољих резултата свих претходно поменутих истраживања. Сви предложени алгоритми показују побољшање тачности предвиђања у односу на појединачне мреже.

Табела 2: Показатељи квалитета предикције за различите моделе, [31, 41-47]

	RMSE [kWh]		MAPE [%]	
	обучавање	тестирање	обучавање	тестирање
FFNN [31]	7152	8496	3,440	5,628
RBFN [31]	8474	8849	4,466	5,668
ANFIS [31]	7200	9115	3,873	5,577
Вишестепени RBFN ансамбл, [45]	6128	8548	3,087	5,493
Вишестепени ANFIS ансамбл, 44]	6029	8221	2,996	5,381
Ансамбл са осредњавањем, [46]	-	8640	-	5,269

2 5. Закључна разматрања

Приказани, и претходно анализирани резултати недвосмислено говоре у прилог све интензивнијој примени метода вештачке интелигенције у задацима предикције у области обновљивих извора енергије и енергетске ефикасности. У овом раду су дате краће теоријске основе и осврт на истраживања и примене неуронских мрежа без повратних спрега и методе потпорних вектора за регресију у области енергије ветра, соларне енергије и хидроенергије. Такође, приказана је и њихова примена на изабраним примерима из сваке од ове области, у свом једноставном облику, са минималним или релативно малим бројем доступних мерених података. За предикцију производње електричне енергије ветропарка и предикцију протока реке то су биле само мерене вредности тих величина, без икаквих других (метеоролошких, и слично), док су за предвиђање производње електричне енергије фотонапонског система коришћени само метеоролошки подаци (интензитет сунчевог зрачења, брзина ветра и температуре). Пример потрошње енергије за грејање једног универзитетског кампуса је приказан у прегледу, са анализом примењених метода. Валидација предложених модела, извршена на непознатим подацима, и добијена тачност предикције, потврдили су потенцијал метода вештачке интелигенције у задацима моделовања и предикције сложених и динамичких појава, што енергија обновљивих извора, производња и потрошња енергије и њено ефикасно коришћење, свакако јесу. Како потреба за чистом енергијом наставља да расте, производња енергије из обновљивих извора енергије ће бити један од најважнијих чинилаца у задовољењу тих потреба. Главне предности метода вештачке интелигенције – способност самоучења и могућност апроксимације нелинеарне зависности између улазних и излазних величина сложеног система, као и могућност њихове примене у предикцији без познавања јасне везе, законитости између улазних и излазних величина, препоручују их као поуздану алтернативу класичним методама у области обновљивих извора енергије и енергетске ефикасности.

6. Захвалност

Аутори се захваљују Министарству просвете, науке и технолошког развоја Републике Србије.

7. Списак скраћеница

ANFIS (adaptive neuro-fuzzy inference systems) – адаптивни неуро-фази систем
ANN (artificial neural network) – вештачка неуронска мрежа
AR (autoregressive) - ауторегресивни модел
ARMA (autoregressive moving average) – ауторегресивни модел покретних средина
ARIMA (autoregressive integrated moving average) - ауторегресивни интегрисани модел покретних средина
BP ((backpropagation algorithm) – алгоритам са повратним простирањем грешке
FFNN (feedforward neural networks) – вишеслојна неуронска мрежа без повратних веза
MAPE (mean absolute percentage error) – средња процентуална апсолутна грешка
RBFN (radial basis functional neural network) – неуронска мрежа са радијално базисним функцијама
RMSE (root mean square error) - квадратни корен квадрата грешака
SVM (support vector machine) – метода потпорних вектора
SVR (support vector regression) – метода потпорних вектора за регресију

8. Литература

- [1] **Perera K.S., Z. Aung, W. L. Woon**, Machine Learning Techniques for Supporting Renewable Energy Generation and Integration: A Survey. In: Woon W., Aung Z., Madnick S. (eds) Data Analytics for Renewable Energy Integration, DARE 2014, Lecture Notes in Computer Science, Volume 8817, Springer, Cham.
- [2] **Li, G., J. Shi**, On comparing three artificial neural networks for wind speed forecasting, *Applied Energy*, Volume 87, issue 7, (2010), pp. 2313-2320.
- [3] **Grassi, G., P. Vecchio**, Wind energy prediction using a two-hidden layer neural network, *Communications in Nonlinear Science and Numerical Simulation*, Volume 15, issue 9, (2010), pp. 2262–2266.
- [4] **Zhou, J., J. Shi, G. Li**, Fine tuning support vector machines for short-term wind speed forecasting, *Energy Conversion and Management*, Volume 52, issue 4, (2011), pp. 1990-1998.
- [5] **Mohandes, M. A., T. O. Halawani, S. Rehman, A. A. Hussain**, Support vector machines for wind speed prediction, *Renewable Energy*, Volume 29, issue 6, (2004), pp. 939-947.
- [6] **Kusiak, A., H. Zheng, Y. Song**, Short-Term Prediction of Wind Farm Power: A Data Mining Approach, *IEEE Transactions on Energy Conversion*, Volume 24, issue 1, (2009), pp. 125-136.

- [7] **Mabel, M. C., E. Fernandez**, Analysis of wind power generation and prediction using ANN: A case study, *Renewable Energy*, Volume 33, issue 5, (2008), pp. 986-992.
- [8] **Tagliaferri, F., I. M. Viola, R. G. J. Flay**, Wind direction forecasting with artificial neural networks and support vector machines, *Ocean Engineering*, Volume 97, (2015), pp. 65-73.
- [9] **Barbounis, T. G., J. B. Theocharis, M. C. Alexiadis, P. S. Dokopoulos**, Long-term wind speed and power forecasting using local recurrent neural network models, *IEEE Transactions on Energy Conversion*, Volume 21, no. 1, (2006), pp. 273-284.
- [10] **Lei, M., L. Shiyang, J. Chuanwen, L. Hongling, Y. Yan**, A review on the forecasting of wind speed and generated power, *Renewable and Sustainable Energy Reviews*, Volume 13, issue 4, (2009), pp. 915-920.
- [11] **Chen, C., S. Duan, T. Cai, B. Liu**, Online 24-h solar power forecasting based on weather type classification using artificial neural network, *Solar Energy*, Volume 85, issue 11, (2011), pp. 2856-2870.
- [12] **Paoli, C., C. Voyant, M. Muselli, M. N. Nivet**, Forecasting of preprocessed daily solar radiation time series using neural networks, *Solar Energy*, Volume 84, issue 12, (2010), pp. 2146-2160.
- [13] **Chen, J. L., H. B. Liu, W. Wu, D. T. Xie**, Estimation of monthly solar radiation from measured temperatures using support vector machines – A case study, *Renewable Energy*, Volume 36, issue 1, (2011), pp. 413-420.
- [14] **Gutierrez-Corea, F. V., M. A. Manso-Callejo, M. P. Moreno-Regidor, M. T. Manrique-Sancho**, Forecasting short-term solar irradiance based on artificial neural networks and data from neighboring meteorological stations, *Solar Energy*, Volume 134, (2016), pp. 119-131.
- [15] **Jiménez-Pérez, P. F., L. Mora-López**, Modeling and forecasting hourly global solar radiation using clustering and classification techniques, *Solar Energy*, Volume 135, (2016), pp. 682-691.
- [16] **Marquez, R., H. T. T. Pedro, C. F. M. Coimbra**, Hybrid solar forecasting method uses satellite imaging and ground telemetry as inputs to ANNs, *Solar Energy*, Volume 92, (2013), pp. 176-188.
- [17] **Aguiar, L. M., B. Pereira, M. David, F. Díaz, P. Lauret**, Use of satellite data to improve solar radiation forecasting with Bayesian Artificial Neural Networks, *Solar Energy*, Volume 122, 2015, pp. 1309-1324.
- [18] **Long, H., Z. Zhang, Y. Su**, Analysis of daily solar power prediction with data-driven approaches, *Applied Energy*, Volume 126, (2014), pp. 29-37.
- [19] **İzgi, E., A. Öztopal, B. Yerli, M. K. Kaymak, A. D. Şahin**, Short–mid-term solar power prediction by using artificial neural networks, *Solar Energy*, Volume 86, issue 2, (2012), pp. 725-733.
- [20] **Wolff, B., J. Kühnert, E. Lorenz, O. Kramer, D. Heinemann**, Comparing support vector regression for PV power forecasting to a physical modeling approach using measurement, numerical weather prediction, and cloud motion data, *Solar Energy*, Volume 135, (2016), pp. 197-208.
- [21] **Rana, M., I. Koprinska, V. G. Agelidis**, 2D-interval forecasts for solar power production, *Solar Energy*, Volume 122, (2015), pp. 191-203.
- [22] **Божић, И., Р. Јовановић**, Стандардни и савремени приступи у одређивању енергетских карактеристика великих и малих хидроелектрана, *31. Међународни конгрес о процесној индустрији PROCESING '18*, Савез машинских и електротехничких инжењера и техничара Србије (СМЕИТС), Бајина Башта, Србија, 2018.
- [23] **Lachtermacher G., J. D. Fuller**, Backpropagation in Hydrological Time Series Forecasting. In: Hipel, K. W., McLeod A. I., Panu U. S., Singh V. P. (eds), *Stochastic and Statistical Methods in Hydrology and Environmental Engineering*, Water Science and Technology Library, Volume 10/3, Springer, Dordrecht, (1994), pp. 229-242.
- [24] **Raman, H., N. Sunilkumar**, Multivariate modelling of water resources time series using artificial neural networks, *Hydrological Sciences Journal*, Volume 40, issue 2, (1995), pp. 145–163.
- [25] **Ochoa-Rivera, J. C., R. García-Bartual, J. Andreu**, Multivariate synthetic streamflow generation using a hybrid model based on artificial neural networks, *Hydrology and Earth System Sciences Discussions*, European Geosciences Union, Volume 6, issue 4, (2002), pp. 641-654.
- [26] **Noori, N., L. Kalin**, Coupling SWAT and ANN models for enhanced daily streamflow prediction, *Journal of Hydrology*, Volume 533, (2016), pp. 141-151.
- [27] **Hong, W. C.**, Rainfall forecasting by technological machine learning models, *Applied Mathematics and Computation*, Volume 200, issue 1, (2008), pp. 41-57.
- [28] **Hammid, A. T., M. H. B. Sulaiman, A. N. Abdalla**, Prediction of small hydropower plant power production in Himreen Lake dam (HLD) using artificial neural network, *Alexandria Engineering Journal*, Volume 57, issue 1, (2018), pp. 211-221.
- [29] **Li, G., Y. Sun, Y. He, X. Li, Q. Tu**, Short-Term Power Generation Energy Forecasting Model for Small Hydropower Stations Using GA-SVM, *Mathematical Problems in Engineering*, Volume 2014, Article ID 381387, 9 pages, 2014.
- [30] E. Council, Directive 2010/31/EU of the European Parliament and of the Council of 19 May 2010 on the energy performance of buildings, Off. J. Eur. Union 18(201) (2010), 13–35.
- [31] **Jovanović, R., A. Sretenović, B. Živković**, Ensemble of various neural networks for prediction of heating energy consumption, *Energy and Buildings*, (ISSN 0378-7788), Volume 94, (2015), pp.189-199.
- [32] **Zhao, H.-X., F. Magoulès**, A review on the prediction of building energy consumption, *Renewable and Sustainable Energy Reviews*, Volume 16, issue 6, (2012), pp. 3586-3592.
- [33] **Foucquier, A., S. Robert, F. Suard, L. Stéphan, A. Jay**, State of the art in building modelling and energy performances prediction: A review, *Renewable and Sustainable Energy Reviews*, Volume 23, (2013), pp. 272-288.

- [34] **Ekonomou, L.**, Greek long-term energy consumption prediction using artificial neural networks, *Energy*, Volume 35, Issue 2, (2010), pp. 512-517.
- [35] **Li, Q., Q. Meng, J. Cai, H. Yoshino, A. Mochida**, Predicting hourly cooling load in the building: a comparison of support vector machine and different artificial neural networks, *Energy Conversion and Management*, Volume 50, issue 1, (2009), pp. 90-96.
- [36] **Li, Q., Q. Meng, J. Cai, H. Yoshino, A. Mochida**, Applying support vector machine to predict hourly cooling load in the building, *Applied Energy*, Volume 86, issue 10, (2009), pp. 2249-2256.
- [37] **Dong, B., C. Cao, S. E. Lee**, Applying support vector machines to predict building energy consumption in tropical region, *Energy and Buildings*, Volume 37, issue 5, (2005), pp. 545-553.
- [38] **Ahmad, A. S., M. Y. Hassan, M. P. Abdullah, H. A. Rahman, F. Hussin, H. Abdullah, R. Saidur**, A review on applications of ANN and SVM for building electrical energy consumption forecasting, *Renewable and Sustainable Energy Reviews*, Volume 33, (2014), pp. 102-109.
- [39] **Karatasou, S., M. Santamouris, V. Geros**, Modeling and predicting building's energy use with artificial neural networks: Methods and results, *Energy and Buildings*, Volume 38, issue 8, (2006), pp. 949-958.
- [40] **Li, K., H. Su, J. Chu**, Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study, *Energy and Buildings*, Volume 43, issue 10, (2011), pp. 2893-2899.
- [41] **Jovanović, Ž. R., A. Sretenović, B. Živković**, Application Of Artificial Neural Networks For Prediction Of Heating Energy Consumption In University Buildings, Proceedings 18th *International Research/Expert Conference "Trends in the Development of Machinery and associated Technology" TMT 2014*, ISSN 1840-4944, pp. 229-232, Budapest, Hungary, 10-12th September 2014.
- [42] **Jovanović, Ž. R., A. Sretenović, B. Živković**, Prediction Of Heating Energy Consumption In University Buildings Based On Simplified Artificial Neural Networks, Proceedings 18th *International Research/Expert Conference "Trends in the Development of Machinery and associated Technology" TMT 2014*, ISSN 1840-4944, pp. 213-216, Budapest, Hungary, 10-12th September 2014.
- [43] **Jovanović, Ž. R., A. Sretenović, B. Živković**, Application of Artificial Neural Networks for the Prediction of Heating Energy Consumption for University Campus, 45th *International HVAC&R Congress*, printed CD pp 71, ISBN/ISSN 978-86-81505-75-5, SMEITS, Belgrade, 3-5th December 2014.
- [44] **Jovanović, Ž. R., A. Sretenović**, Various multistage ensembles for prediction of heating energy consumption, *Modeling Identification and Control*, Volume 36, No.2, (2015), pp.119-132.
- [45] **Jovanović, Ž. R., A. Sretenović, B. Živković**, Multistage ensemble of feedforward neural networks for prediction of heating energy consumption, *Thermal Science*, Volume 20, No.4, (2016), pp. 1321-1331.
- [46] **Jovanović Ž. R., A. Sretenović**, Ensemble of radial basis neural networks with k-means clustering for heating energy consumption prediction, *FME Transactions*, Volume 45, No.1, (2017), pp. 51-57.
- [47] **Sretenović, A., R. Ž. Jovanović, V. M. Novaković, N. M. Nord, B. D. Živković**, Support vector machine for the prediction of heating energy use, *Thermal Science*, (2018), online first, doi: <https://doi.org/10.2298/TSCI170526126S>
- [48] **Kumar, R., R. K. Aggarwal, J. D. Sharma**, Energy analysis of a building using artificial neural network: A review, *Energy and Buildings*, Volume 65, (2013), pp. 352-358.
- [49] **Müller, K. R., A. J. Smola, G. Rätsch, B. Schölkopf, J. Kohlmorgen, V. Vapnik**, Predicting time series with support vector machines, In: Gerstner W., Germond A., Hasler M., Nicoud JD. (eds) *Artificial Neural Networks — ICANN'97, ICANN 1997*, Lecture Notes in Computer Science, Volume 1327, Springer, Berlin, Heidelberg, pp. 999-1004.
- [50] **Smola, A. J., B. Schölkopf**, A tutorial on support vector regression, *Statistics and Computing*, Volume 14, issue 3, pp. 199—222.
- [51] Elia, Belgium's electricity transmission system operator, <http://www.elia.be/en/grid-data/power-generation/wind-power>
- [52] Solar Radiation Monitoring Laboratory, University of Oregon, USA, <http://solarat.uoregon.edu/index.html>
- [53] *Хидролошки годишњаци - површинске воде од 2004. до 2014*, Републички хидрометеоролошки завод Републике Србије, 2005-2014, http://www.hidmet.gov.rs/ciril/hidrologija/povrsinske_godisnjaci.php
- [54] **Hornik, K., M. Stinchcombe, H. White**, Multilayer feedforward neural networks are universal approximators, *Neural Networks*, Volume 2, (1989), pp. 359–366.