



НЕВРОННА МРЕЖА ЗА ПРОГНОЗИРАНЕ НА КОЛИЧЕСТВОТО ГЕНЕРИРАНА ОТ СЛЪНЧЕВА РАДИАЦИЯ ЕНЕРГИЯ¹

Пенка В. Георгиева

Информатика и технически науки
Бургаски свободен университет
penka.georgieva@bfu.bg

NEURAL NETWORK FOR PREDICTING THE ENERGY GENERATED BY SOLAR RADIATION

Penka V. Georgieva

Informatics and technical sciences
Burgas Free University

Abstract: В тази статия е предложен подход за краткосрочно прогнозиране на производството на електроенергия от микросистема PV система, използващи средствата на изкуствения интелект. При създаването на модела е използвана изкуствена невронна мрежа. Моделът за прогнозиране има три входни променливи: слънчева радиация, скорост на вятъра и температура на въздуха и една изходната променлива - количеството електрическа енергия, произведена от инсталираните фотоволтаични панели в микросистема. Това изследване е част от проект за оптимизиране на енергийното потребление на сграда с използване на независими алтернативни възобновяеми енергийни източници. Моделът е реализиран и е тестван с реални данни, събрани за 5 минути от специално проектирана метеорологична станция, инсталирана в сградата на Бургаския свободен университет.

Ключови думи: – изкуствена невронна мрежа, микро PV система, интелигентно управление на сгради.

Abstract: This article proposes an approach for short-term forecasting of electricity production from a micro grid connected PV system using the means of artificial intelligence. An artificial neural network is used to create the model. The forecasting model has three input variables: solar radiation, wind speed and air temperature, and one output variable - the amount of electricity produced by the installed photovoltaic panels in the microsystem. This study is a part of a project for optimization of the energy consumption of a building in case that independent alternative renewable energy sources are used. The model is implemented and tested on real data collected in 5 minutes from a specially designed meteorological station installed in the building of the Burgas Free University.

Keywords: artificial neural network, micro PV system, intelligent building management.

¹ Това изследване се финансира от Фонд за научни изследвания на България по договор № КР-06-COST-8 / 06.08.2019 г. за предоставяне на национално съфинансиране за участие на български екипи в одобрени действия по Европейската програма за сътрудничество в областта на изследователски и технологични разходи по проект „Прогнозиране на характеристики и оптимизация на фотоволтаична система с методи на изкуствения интелект“.

I. Въведение

Фотоволтаичните (PV) системи са проектирани така, че да преобразуват слънчевата радиация в електричество чрез фотоволтаични елементи. Капацитетът на фотоволтаичните системи варира от няколко киловата до стотици мегавата. Понастоящем търговските фотоволтаични системи са свързани към електрическата мрежа, докато автономните системи представляват малка част от пазарния дял. [1]

Една микро фотоволтаична система се състои от три модула: (1) източници на енергия, включително фотоволтаични панели и акумулаторни батерии; (2) контролер и променлив инвертор; (3) потребители – стандартни AC потребители и DC потребители.

Фотоволтаичните панели са конфигурирани в отделни блокове, в които те се разпределят паралелно и / или последователно. По същия начин батериите са конфигурирани паралелно и/или последователно, като акумулират излишната енергия, генерирана от фотоволтаиците от дневната светлина. Батериите, които се използват при такива системи трябва да могат да се разреждат напълно. Литиевите батерии са особено подходящи, но тяхната цена и експлоатационни характеристики възпрепятстват масовото им използване засега. Оловните акумулатори са по-евтини, но не могат да се разреждат напълно.

Инверторът преобразува постоянното напрежение в напрежение с индустриална честота и по този начин се осигурява захранване на всички стандартни консуматори. Малко системи са ограничени само за постояннотокови консуматори (без инвертор). Такива са например системите, предназначени за захранване на преносимо оборудване – светещи знаци, временни осветителни тела и други. Автономните фотоволтаични системи без инвертор са най-евтините. Използването на инвертор дава възможност на автономната фотоволтаична система да осигурява енергия с индикатори, идентични на тези на общото захранване.

Потребителите на енергия са основно два вида – потребители, които получават енергия директно от батериите и потребители, получаващи преобразувана енергия. Всеки товар има някои специфични характеристики, които трябва да се вземат под внимание (номинална мощност, пикова мощност и др.). Тези параметри не са критични например за LED светлините, но за лаптопите работните граници са тесни и строго определени. За някои от потребителите на променлив ток, промяната на напрежението понякога може да се тълкува от защитния блок като токов удар или пренапрежение в мрежата. [2]

За правилната работа на фотоволтаичните панели, както и за правилната им координация с потребителите, системите са снабдени с контролер за управлението на заряда на батериите, на работата на фотоволтаичните панели и откриване на аварийни ситуации. Контролерът е най-важният елемент на системата и правилният избор и подходящ софтуер са ключови за безпроблемната работа на системата. [3]

Оперативните характеристики на електроенергията, произведена от фотоволтаичната система, са извън обхвата на настоящото изследване.

В [1] се предлагат две размити системи за подпомагане на управлението на микро фотоволтаични системи. В първия модел входните променливи са три: произведена енергия от PV панелите, налична енергия в батерията и енергия, необходима на консуматорите. Резултатът, получен след прилагане на размитите правила, е решение за избор на източник на енергия, който да се използва. Вторият модел има един допълнителен източник на енергия (дизелов генератор/горивна клетка) и по този начин входните променливи са четири. Предварително се измерва мощността, произведена от



фотоволтаичните панели, произведената енергия на допълнителния източник на енергия, енергията в батерията и консумираната енергия и се изчислява процентът на потреблението, обхванат от всеки от енергийните източници. Тези проценти стават входни стойности на размитите системи.

Количеството енергия, произведена от фотоволтаичните панели, е важен параметър във всяка от тези системи за управление и успешното ѝ прогнозиране значително повишава ефективността им.

Прогнозирането е ключов елемент от процеса на вземане на решения. Способността за анализ на неконтролируемите аспекти на различни видове събития е важен фактор в този процес. Развитието на компютърните технологии води до появата на нови методи за прогнозиране и такива са например размитите системи. Има много изследвания в областта на прогнозиране на енергията, получена от слънчевата радиация. [4]

В допълнение към традиционните методи за прогнозиране, съвременните инструменти на изкуствения интелект (AI) могат успешно да се използват в тази насока. AI е клон на компютърните науки и терминът е използван за първи път от Джон Маккарти през 1956 г. като „наука за създаване на интелигентни машини“. В исторически план AI се развива от опитите за формализиране на човешкото познание с инструментите на математическата логика и първоначално е приложено за доказателство на теореми и моделиране на игри. Основата на AI са философия, математика, алгоритми, логика, психология, информатика, лингвистика. Постепенно традиционният AI, фокусиран главно върху имитирането на човешкото поведение в езикова форма или символични правила, се обогати с нови идеи и така се развила модерната концепция за ИИ.

Понастоящем AI е комбинация от традиционните средства на AI, обогатени с различни методологии за числено изчисление, а предметът на AI са главно онези проблеми, за които не съществуват директни математически или логически алгоритми или могат да бъдат разрешени само интуитивно. AI, наред с традиционните си основни науки, включва някои нови: невронауката, когнитивната наука, онтологии, изследвания на операциите, икономиката, теория на вероятностите, апроксимации и оптимизации.

За разлика от традиционните изчисления, основна концепция в съвременния AI е разбирането, че точността и сигурността имат висока цена и толерантност към неточност и несигурност в изчисленията, разсъжденията и вземането на решения трябва да бъдат допуснати (когато и където е възможно). Изчислителните парадигми на AI са размитата логика, изкуствените невронни мрежи, приблизителни изводи и методи за недиференциална оптимизация като генетичните алгоритми и симулираното закаляване. [5]

Подробен преглед на приложенията на техниките на изкуствения интелект като „алтернативни подходи към конвенционалните техники или като компоненти на интегрирани системи“ може да бъде намерен в [6]. Изкуствените невронни мрежи са използвани за прогнозиране на метеорологични данни: слънчева радиация, скорост на вятъра, температура на въздуха, слънчева радиация; прогноза за времето; оразмеряване на фотоволтаични (PV) системи; моделиране и симулация на PV системи. Размитото моделиране е приложено за прогнозиране на слънчевата радиация и продължителността на слънчевото греене; управление на PV системи. Генетичните алгоритми се прилагат успешно за оразмеряване на различни видове PV и системи.

В последното десетилетие AI техники са широко използвани за управление на различни самостоятелни PV инсталации, извън мрежовите PV системи и различни

хибридни системи за производство на електричество чрез използване на фотоволтаици. [7-11]

Това проучване е фокусирано върху прогнозирането на количеството електроенергия, произведено от фотоволтаични панели, инсталирани върху една сграда и свързани с мрежата. Целта е да се използва тази прогноза за ефективно управление на енергийните потоци на сградата. Моделът за прогнозиране е невронна мрежа, обучена по реални данни, събрани от микроенергийната система, инсталирана в сградата на Бургаския свободен университет.

II. Описание на микро PV системата

Предложеният в тази разработка прогнозиращ модел има за цел да подпомогне по-ефективното управление на микро PV система. Изследването е част от проект за оптимизиране на енергийното потребление на сграда с използване на независими алтернативни възобновяеми енергийни източници. Входните данни за слънчевата радиация, скоростта на вятъра и температурата на въздуха се получават от BFU METEO – метеорологична станция, специално проектирана и инсталирана в сградата на Бургаския свободен университет за нуждите на този проект. BFU METEO се състои от сензори за наблюдение на входните променливи – Fronius Sensor Box и FroniusDatalogger Web. Данните се събират в интервал от 5 минути и се съхраняват в база от данни в сървър.



Фиг. 1. Компоненти на микро PV

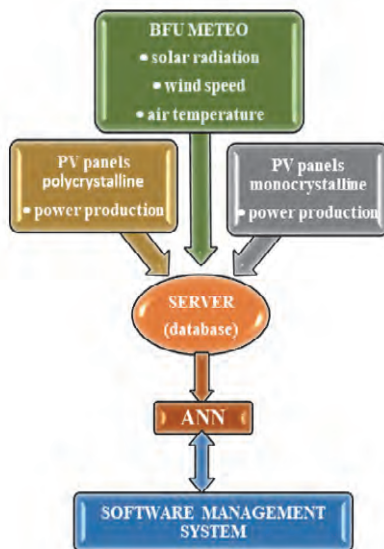
10 A; 100-350 VDC MPP; изход 230 VAC, 50 Hz, клас I, 3300 W/3600 W, 15,5 Amax. Някои от компонентите на микро PV системата са показани на фиг.1.

Микро PV системата се състои от:

- 20 поликристални PV панела с максимална мощност прибрл. 235Wp, инвертор SolarMax 13MT2 със следните технически спецификации: входни стойности: MPP напрежение обхват 250... 750 V, минимално напрежение с номинална мощност 370 V, максимално постоянноково напрежение 900 V, максимален постоянен ток 2 x 18 A, брой MPP – проследяващи 2, макс. производителност на PV генератор на MPP тракер: 9 000 W; изходни стойности: номинална изходна мощност при $\cos(\phi) = 1$ е 13 000 W, максимална изходна мощност 13 000 VA, номинално мрежово напрежение 3 x 400 V, максимален променлив ток 3 x 20, номинална честота на мрежата/обхват 50 Hz/45 Hz... 55 Hz; мрежова връзка трифазна (3 / N / PE);

- 10 монокристални PV панела с максимална мощност прибрл. 150Wp всеки; инвертор IBC Serve Master 3300 MV със следните технически спецификации: PV вход 450 VDC, макс. 2 x

Данните се събират от сензорите на BFU METEO на всеки 5 минути и след това автоматично се съхраняват в базата от данни. Данните за количеството произведена електроенергия от двата вида инсталирани фотоволтаични панели (поликристални и монокристални) също се събират и съхраняват в базата от данни на интервали от 5 минути. (Фиг. 2) [12]



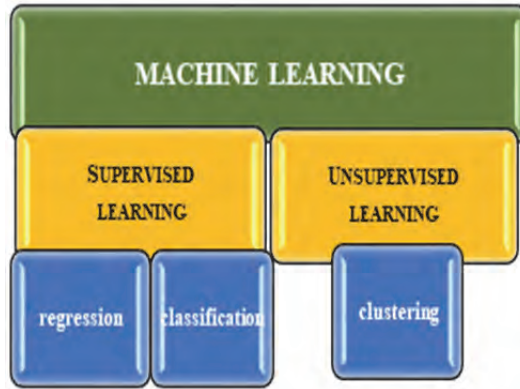
Фиг. 2. Потоци от данни при управление на микро PV системата

I. Модел за прогнозиране

A. Машинно обучение

Машинното обучение (ML) е област на компютърните науки за създаване на алгоритми, способни да „учат“ как да изпълняват определена задача, без да са изрично програмирани за това. ML включва адаптивни алгоритми, способни да се „учат“ от примери и да намират модели и шаблони в данните. Те се използват за подпомагане на процеса на вземане на решения, както и за прогнози в различни области: медицинска диагностика, компютърно зрение, разпознаване на лица, търговия с акции, оценка на кредитен рейтинг, прогнозиране на енергийната ефективност, изчислителна биология, обработка на естествени езици и др. ML се предпочита когато: 1) съществуват трудности във формалното описание на знанията; 2) бъдещите състояния са непредсказуеми и 3) изучаваните обекти динамично се променят и е трудно или невъзможно да се предвидят всички изменения във времето.

Две са основните техники, използвани в ML: обучението с надзор и такова без надзор. Обучението с надзор се провежда по известни входни и изходни данни, така че да се прогнозира бъдещи резултати от нови данни, докато при обучението без надзор се търсят (и биват намерени) скрити модели във входните данни. (Фиг. 3)



Фиг. 3. Основни техники на машинното обучение

Машинното обучение с надзор има за цел изграждането на модели в условията на някакъв източник на несигурност. Един контролиран алгоритъм за обучение използва известен набор от входни данни и известни изходни данни и „учи“ модела на генериране на осъществими резултати от нови данни. Контролираното обучение използва регресионни техники и класификация за разработване на прогнозни модели. Регресионните техники се използват за прогнозиране на непрекъснати величини (например промени в температурата или в потреблението на електроенергия). Техниките за класификация се използват основно при прогнозиране на бъдещи стойности на дискретни величини чрез класифициране на входните данни в категории (например дали в снимка има животно или растение или човек).

Машинното обучение без надзор се използва за откриване на скрити модели или вътрешни структури в данните, както и за получаване на изводи. Клъстеризирането е най-често срещаната техника за обучение без надзор. Използва се за анализ на данни с цел намиране на скрити модели или групи в данните. Приложенията на клъстеризирането включват анализиране на ДНК и гени, проучване на пазара, разпознаване на обекти и др.

Изборът на алгоритъм за машинно обучение е процес на опити и грешки и се подчинява на намиране на баланс между характеристиките на алгоритмите: скорост; използване на паметта; прогнозна прецизност; възможност за интерпретиране.

В. Регресионни алгоритми

Логистичната регресия е инструмент за прогнозен анализ и се използва за обяснение на зависимостите между една зависима двоична променлива и една или повече независими променливи. Логистичната регресия често се използва начало на бинарна класификация.

Линейна регресия е техника за статистическо моделиране, използвана за описание на променлива като линейна функция на една или повече променливи. Тъй като моделите на линейна регресия са лесни за интерпретиране и лесни за обучение, те често са първият модел, който се прилага към нов набор от данни и по могат да бъдат използвани като първи етап на изграждане на по-сложни регресионни модели.

Нелинейната регресия е техника на статистическо моделиране, която се използва за описание на нелинейни връзки в експериментални данни. Нелинейните регресион-



ни модели са параметрични и обикновено се използват, когато данните имат нелинейни зависимости.

Изкуствените невронни мрежи (ANN) са вдъхновени от човешкия мозък и се състоят от свързани мрежи от неврони. ANN се обучават да моделират зависимостите между входните и изходните данни чрез итеративно изменение на теглата на връзките. ANN се използват най-добре за моделиране на нелинейни зависимости, в случаите на неочаквани промени във входните данни и/или когато интерпретируемостта на модела не е основно изискване. Хората са много добри в разпознаването на обекти и лица, разпознаването на различни характеристики на околната среда, решаването на различни ситуационни проблеми, действия и реакции на мозъка. От раждането на човек мозъкът му има способността да разработва свои собствени правила въз основа на предишен опит. Тези правила са направени чрез укрепване на старите и създаване на нови връзки между невроните. Човешкият мозък има милиарди неврони, които са свързани помежду си и комуникират чрез електрохимични сигнали. Обучението на ANN много прилича на това на човешкия мозък и е предназначено да решава сложни проблеми в машинното обучение. Обучението на ANN не се извършва за всеки неврон поотделно, а се реализира в система. Един от видовете невронни мрежи е невронната мрежа с обратно разпространение на грешката. Обратното разпространение на грешката се осъществява след всяка итерация. Функцията за активиране за всеки неврон се определя от стойността на изхода от предишния слой неврони и теглата на връзките между тях. Първо се изчислява грешка в изхода, която е равна на несъответствието между очаквания и реалния резултат (разпространение напред). След като грешката е известна, нейното минимизиране се постига чрез обратно разпространение. Това означава, че алгоритъмът се разпространява назад, от изходния слой към входния слой и теглата на връзките се модифицират, за да се сведе до минимум общата грешка [13].


C. Модел на изкуствена невронна мрежа за прогнозиране

За прогнозиране на количеството произведена електроенергия от монтираните върху сградата на БСУ PV панели се използва *Deep Learning Toolbox*TM (преди *Neural Network Toolbox*TM), вградено в *MatLab* софтуерно средство. вградения в предоставя рамка за проектиране и внедряване на невронни мрежи с алгоритми, проучени модели и приложения. Създадените модели могат да бъдат реализирани в *TensorFlow*TM и *PyTorch* чрез ONNX формата и импортирани от *TensorFlow-Keras* и *Caffe*. Приложението поддържа обучение с библиотека от предварително обучени модели. Обучението може да се ускори с *Parallel Computing Toolbox*TM или да се премасштабира на кълътери и облак, включително *NVIDIA@GPU Cloud* и *Amazon EC2@GPU*. [14]

За това изследване е избрана вградена в *MatLab* функция за генериране на невронна мрежа с определен размер на скрития слой и предварително зададена тренировъчна функция:

fitnet(hiddenSizes,trainFcn).

Общата схема на невронната мрежа е показана на фигура 4.




Фиг. 4. Обща схема на прогнозния модел

За настройване на архитектурата на невронната мрежа се следва следната процедура:

- 1) почистване на данните;
- 2) стартиране на невронната мрежа;
- 3) получаване на резултати;
- 4) сравняване и настройване на невронната мрежа (брой слоеве и/или брой неврони);
- 5) връщане към 2).

Първият въпрос, на който трябва да се отговори, е върху какви данни ще се обучава невронната мрежа. Както се вижда от фигура 5, петминутните наблюдения показват значителни колебания и разлики през деня и нощта. Въпреки че има много нулеви стойности, те не могат да бъдат пропуснати, тъй като без тях невронната мрежа губи точност. След изпитвания в различен брой дни, най-добрите резултати при трениране на нервната мрежа се получават, когато се използват няколко еднодневни последователности от петминутни наблюдения, започващи в 00:00 ч (288 наблюдения на ден).



Фиг. 5. Визуализация на петминутните наблюдения за 6 последователни дни: слънчева радиация (ляво); скорост на вятъра (дясно), температура на въздуха (ляво), количество генерирана електроенергия (дясно)

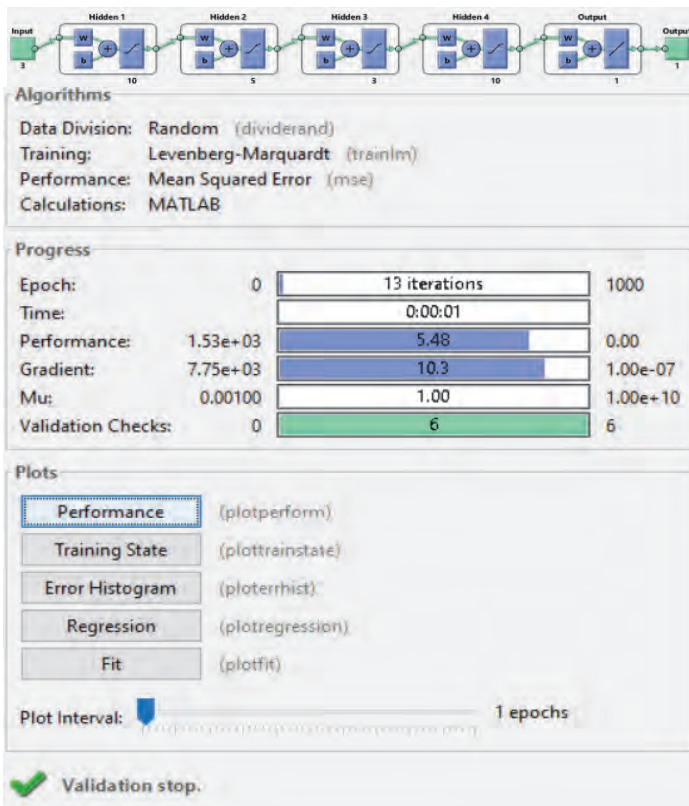


След прилагането на описания модел на невронната мрежа са проведени експериментални тестове в MatLab. Тестовите имат за цел да изучат резултатите, получени след обучението на невронната мрежа при променяне на стойностите на параметрите на нейната архитектура – броя на скритите слоеве и броя на невроните във всеки слой.

След проведените многобройни тестове с различни архитектури на невронни мрежи, най-добри резултати се получават от невронна мрежа със следните параметри:

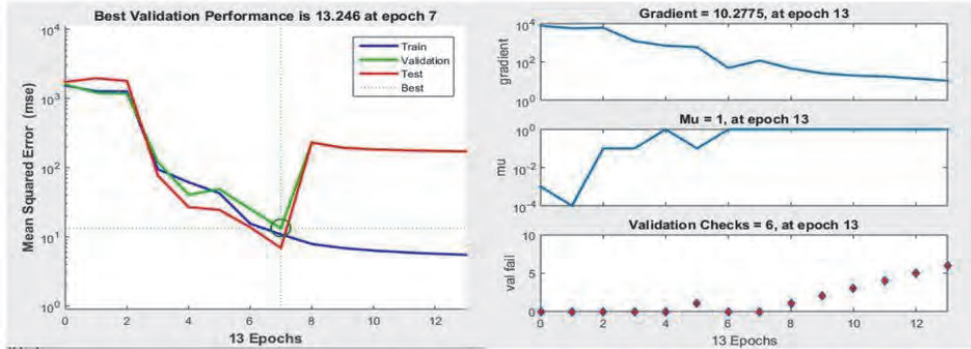
fitnet([10,5,3,10],trainlm),

която е невронна мрежа с четири скрити слоя със съответно 10, 5, 3 и 10 неврона и алгоритъм за обратно разпространение на Levenberg-Marquardt (фиг. 6). Подробности за този алгоритъм могат да бъдат намерени в [15].



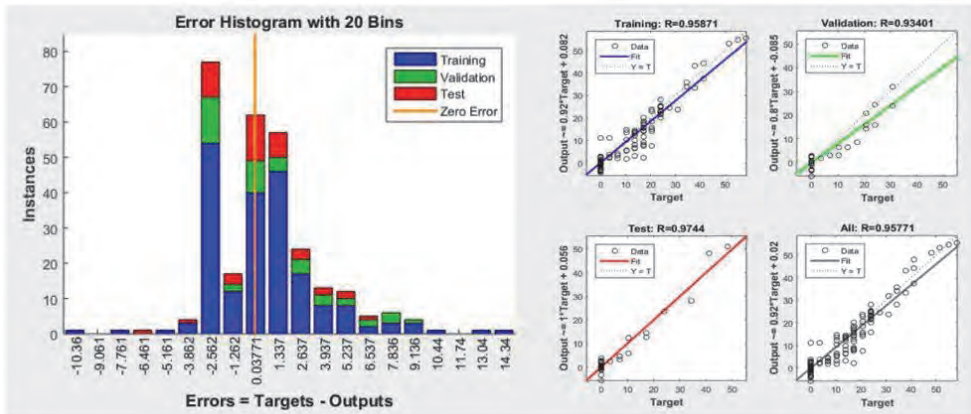
Фиг. 6. Архитектура и резултати от обучението на ANN

Най-добрият валидиращ резултат се постига след 13 епохи и е 13,246, като съответният градиент е 10,2775. (Фиг. 7)



Фиг. 7. Най-добър валидиращ резултат (13 епохи)

Хистограмата на грешката и отклоненията след обучението, валидирането и тестването са на фигура 8.



Фиг. 8. Хистограма на грешките и отклоненията

IV. Заключение

В тази статия се предлага модел за прогнозиране на производството на електрическа енергия, който да бъде използван за подпомагане на процеса на управление на микро фотоволтаични системи. Моделът използва машинно обучение и е реализиран чрез изкуствена невронна мрежа. Обучената невронна мрежа показва удовлетворителни резултати, които могат да бъдат използвани при управлението на енергийните потоци на микро PV системата.

Обучението и тестовите са проведени в MatLab. Това изследване е част от проект за оптимизиране на енергийното потребление на сграда с използване на независими алтернативни възобновяеми енергийни източници. Входните тестови данни за опти-



мизацията са количеството използвана енергия за осветление, отопление, електрозахранване на компютри и други нужди на една конкретна сграда (Бургаски свободен университет).

Полезно развитие на представения модел за прогнозиране е създаването на автономен софтуер за управление на фотоволтаични системи. Такава програма ще бъде широко използвана предвид темповете на развитие на тази технология по целия свят.

Друг приоритет при бъдещите изследвания е оптимизирането на фотоволтаичните системи по отношение на тяхната цена.

REFERENCES

- [1] P. V. Georgieva, R. Dolchinkov, „Fuzzy Models for Managing a Micro Grid PV System”, 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), pp. 1066-1071, 2019
- [2] E. Skoplaki, J. A. Palyvos, „Operating temperature of photovoltaic modules: A survey of pertinent correlations”. *Renewable Energy*, Vol. 34 № 1, pp. 23-29, 2009
- [3] R. Dolchinkov, P. Georgieva, „Effectiveness of solar tracking systems“, *Yearbook of Burgas Free University*, Vol. XXVII, 2012 (in Bulgarian)
- [4] A. Tuohy, and coauthors, „Solar forecasting: Methods, challenges, and performance”, *IEEE Power and Energy Magazine* vol. 13 (6), pp. 50–59, 2015
- [5] P. V. Georgieva, „Fuzzy rule-based systems for decision-making”, *Engineering Sciences, Bulgarian Academy of Sciences*, vol. 53 (1), pp. 5–16, 2016
- [6] A. Mellit and S. Kalogiroub, „Artificial intelligence techniques for photovoltaic applications: A review“, *Progress in Energy and Combustion Science* vol. 34, pp. 574–632, 2008
- [7] E. Kardakos, M. Alexiadis, S. Vagropoulos, C. Simoglou, P. Biskas and A. Bakirtzis, „Application of time series and artificial neural network models in short-term forecasting of PV power generation“, 48th International Universities' Power Engineering Conference (UPEC), pp. 1-6, 2013
- [8] R. Welch, S. Ruffing and G. Venayagamoorthy, „Comparison of feedforward and feedback neural network architectures for short-term wind speed prediction”, *Proceedings of international joint conference on neural networks*, 2009
- [9] Y. Huang, J. Lu, C. Liu, X. Xu, W. Wang, and X. Zhou, „Comparative study of power forecasting methods for PV stations,” *International Conference on Power System Technology (POWERCON)*, Hangzhou, China, pp. 1 – 6, 2010
- [10] T. Wang and Su-Yuan Tsai, „Solar Panel Supplier Selection for the Photovoltaic System Design by Using Fuzzy Multi-Criteria Decision Making Approaches”, *Energies* vol. 11(8), 2018
- [11] A. Lee, H.-Y. Kang, C.-Y. Lin and K.-C. Shen, „An integrated decision-making model for the location of a PV solar plant”, *Sustainability*, vol. 7(10), pp. 13522–13541, 2015
- [12] S. Letskovska, K. Seymenliyski, E. Zaerov and R. Simionov, „System for visualization of data from energy training complex”, *Computer Science and Communications*, vol. 8 (1), pp. 42-47, 2019 (in Bulgarian)
- [13] M. A. Nielsen, *Neural Network and Deep learning*, Determination Press, 2015.
- [14] <https://www.mathworks.com/products/deep-learning.html>
- [15] <https://se.mathworks.com/help/deeplearning/ref/trainlm.html;jsessionid=b8f21ff67e433e3e6fe7f697887f>