

УДК 621.311.29:535.8:51-74

DOI: 10.24160/1993-6982-2022-2-56-62

Нейросетевое моделирование производительности солнечного теплофотоэлектрического модуля

Н.С. Филиппченкова

Конструкция теплофотоэлектрических модулей (ТФМ) характеризуется неравномерным распределением температуры теплоносителя в канале, и солнечные элементы (СЭ), соседствующие в тепловом контакте с каналом ТФМ, находятся в различных температурных условиях. Неравномерное распределение температуры СЭ дает сложные и нелинейные нежелательные эффекты, такие как снижение генерируемой мощности, повреждение СЭ вследствие возникновения горячих пятен. Цель работы — разработка математической модели для моделирования тепловой и электрической производительностей ТФМ на основе искусственной нейронной сети прямого распространения (ИНС ПР).

Разработана двухслойная ИНС ПР с сигмоидными скрытыми и линейными выходными нейронами. Входной слой составляют температура окружающей среды, расход теплоносителя и переменные окружающей среды (суммарная инсоляция). Выходной слой представляют тепловой и электрический КПД ТФМ. Обучение и адаптация разработанной ИНС ПР проходили на основе моделирования и экспериментальной базы данных о входных и выходных параметрах ТФМ. Разработанная ИНС ПР обучена с помощью алгоритма Левенберга–Марквардта. Достигнутое при обучении значение средней абсолютной ошибки находится в пределах от $-0,319$ до $0,448$ — для электрического и от $-0,129$ до $0,198$ — для теплового КПД. Значение среднеквадратической ошибки составляет $0,0678$ — для электрического и $0,0247$ — для теплового КПД. Время обучения — от 15 с.

Создана эффективная модель, реализующая новый подход к моделированию производительности ТФМ на основе алгоритмов искусственных нейронных сетей со значительным приближением значений тепловой и электрической эффективностей.

Ключевые слова: солнечный модуль и коллектор, фотоэлектрический и теплофотоэлектрический модули, тепловой и электрический КПД, искусственная нейронная сеть прямого распространения, алгоритм обучения.

Для цитирования: Филиппченкова Н.С. Нейросетевое моделирование производительности солнечного теплофотоэлектрического модуля // Вестник МЭИ. 2022. № 2. С. 56—62. DOI: 10.24160/1993-6982-2022-2-56-62.

Neural Network Modeling of the Solar Photovoltaic Thermal Module Performance

N.S. Filippchenkova

The design of photovoltaic thermal modules (PVT modules) features a nonuniform distribution of coolant temperature in the channel, and the solar cells (SC) that are in thermal contact with the PVT module channel are under different temperature conditions. The nonuniform distribution of the SC temperature causes undesirable effects that are complex and nonlinear, such as a drop of generated power and SC damage resulting from the occurrence of hot spots. The aim of the work is to develop a mathematical model for modeling the PVT module thermal and electrical performance based on a feedforward artificial neural network (FNN). A two-layer FNN with sigmoid hidden neurons and linear output neurons has been developed. The input layer is made up of the ambient temperature, coolant flowrate and environmental variables (the total insolation). The output layer represents the PVT module thermal and electrical efficiencies. The developed FNN was trained and adapted on the basis of modeling and an experimental database on the PVT module input and output parameters. The developed FNN was trained using the Levenberg–Marquardt algorithm. The mean absolute error achieved during the training is in the range from -0.319 to 0.448 for electrical efficiency and from -0.129 to 0.198 for thermal efficiency. The r.m.s error is 0.0678 for electrical efficiency and 0.0247 for thermal efficiency; the training time is 15 s or longer. An effective model has been developed that implements a new approach to modeling the performance of PVT modules based on artificial neural network algorithms with fairly close values of thermal and electrical efficiencies.

Key words: solar module, solar collector, photovoltaic module, photovoltaic thermal module, thermal efficiency, electric efficiency, feedforward artificial neural network, training algorithm.

For citation: Filippchenkova N.S. Neural Network Modeling of the Solar Photovoltaic Thermal Module Performance. Bulletin of MPEI. 2022;2:56—62. (in Russian). DOI: 10.24160/1993-6982-2022-2-56-62.

Введение

В настоящее время при моделировании энергоустановок на базе возобновляемых источников энергии активно используются модели искусственных нейронных сетей (ИНС). Они служат для оценки или аппроксимации функций во многих практических приложениях, таких как распознавание образов, оценка времени ряда и моделирование нелинейных процессов. Среди существующих моделей ИНС наиболее широко рас-

пространена искусственная нейронная сеть прямого распространения (ИНС ПР), применяемая для решения многопараметрических задач с помощью нелинейных уравнений с помощью процесса, называемого обучением. Процесс обучения осуществляется посредством специальных алгоритмов, среди которых наиболее известен алгоритм обратного распространения ошибки. Результаты исследования различных конструкций, а также необходимость в создании методики расчета и

определения оптимальных режимов преобразования солнечной энергии одновременно в тепловую и электрическую в теплофотоэлектрических модулях (ТФМ) представлены в [1 — 6].

В [7] описан подход на основе ИНС для оценки максимально возможной выходной мощности ФЭМ в условиях неоднородной тени в заданном географическом местоположении. В качестве входных данных приняты инсоляция, температура окружающей среды и углы положения солнца. Данные для обучения ИНС сгенерированы путем проведения серии экспериментов на затемненной солнечной панели в разное время суток в течение нескольких дней. Показано, что разработанная ИНС позволяет достаточно точно (погрешность — 3,4%) оценить максимально возможную выходную мощность ФЭМ.

В [8] продемонстрировано успешное применение ИНС для управления движением умного солнечного трекера, а в [9] — интеллектуальная система диагностики неисправностей ФЭМ на основе ИНС с хаотическим расширением, устраняющая дефект недоступной диагностики неисправностей при любой инсоляции и температуре.

В [10] дана модель воздушного солнечного коллектора (СК) на основе ИНС. В качестве входных переменных модели взяты температура воздуха на входе в СК, суммарная инсоляция и температура пластины поглотителя. Температура воздуха на выходе из СК и значения теплового КПД — выходные параметры. Прогнозируемые значения по модели ИНС очень близки к экспериментальным, прогноз теплового КПД обладает 98%-ой точностью.

Результаты исследования различных конструкций, а также необходимость в разработке методики расчета и определения оптимальных режимов преобразования солнечной энергии одновременно в тепловую и электрическую в ТФМ приведены в [11, 12]. Выходная электрическая мощность ФЭМ, ТФМ зависит от многих параметров, в том числе, температуры солнечных элементов (СЭ). В случае ТФМ, характеризующихся неравномерным распределением температуры теплоносителя по каналу, СЭ могут располагаться в различных температурных условиях. В этих случаях неравномерное распределение температуры СЭ вызывает следующие сложные и нелинейные нежелательные эффекты: действительная мощность, генерируемая СЭ, падает намного ниже расчетного уровня, локальные горячие пятна становятся причиной повреждения СЭ.

Известные методики определения производительности ТФМ [1 — 6, 11 — 12] не учитывают влияния неравномерного распределения температуры СЭ. При расчете электрической эффективности ТФМ берется средняя по каналу температура теплоносителя.

Предложен подход на основе ИНС к моделированию взаимосвязи между электрической и тепловой эф-

фективностями ТФМ и факторами окружающей среды, такими как уровни суммарной инсоляции, температуры окружающего воздуха и теплоносителя (рабочего параметра ТФМ).

Цель настоящей работы — создание математической модели эффективности ТФМ на основе искусственной нейронной сети прямого распространения (ИНС ПР). Для ее достижения решены следующие задачи:

- разработана архитектура ИНС ПР для моделирования тепловой и электрической эффективностей ТФМ;
- выполнено обучение сети с использованием экспериментальной базы данных о эффективности ТФМ при различных условиях окружающей среды и рабочих параметрах;
- оценена эффективность различных алгоритмов обучения разработанной ИНС ПР.

Методы и материалы

В [13] представлена конструкция солнечного ТФМ, содержащего СЭ, размещенные между стеклом и корпусом с прямоугольным каналом теплоносителя. В ТФМ в качестве герметизирующего материала использован полисилоксановый двухкомпонентный кремнийорганический оптически прозрачный гель. Для оценки эффективности ТФМ (теплового и электрического КПД) разработана математическая модель ТФМ на основе ИНС ПР, представляющей собой совокупность нейронов, состоящих из нескольких слоев и связанных друг с другом таким образом, что выходы нейронов одного слоя передают сигналы на входы нейронов следующего слоя [14]. Функционирование i -го нейрона первого слоя определим следующим выражением [14, 15]:

$$y^{(l,i)} = \sigma^{(l,i)} \left(\sum_{j=0}^{N_{l-1}} w_j^{(l,i)} y^{(l-1,j)} \right),$$

где: $\sigma^{(l,i)}$ — функция активации ИНС ПР; $y^{(l-1,j)}$ — выход j -го нейрона $(l-1)$ -го слоя; $w_j^{(l,i)}$ — j -й вес i -го нейрона l -го слоя; $y^{(l-1,0)} = 1$ — фиктивный единичный выход нейрона; $y^{(0,j)} = x_j$ — j -й вход ИНС ПР, $j = 1 \dots n$.

Функционирование всей двуслойной ИНС ПР представим в виде [15]:

$$y = w_0^{(2)} + W_1^{(2)} \sigma \left(w_0^{(1)} + W_1^{(1)} x \right),$$

где: σ — векторная функция, соответствующая применению функций активации нейронов к каждому нейрону первого слоя; $w_0^{(l)}$ — веса нейронов, соответствующие фиктивным единичным входам; $W_1^{(l)}$ — матрица весов между нейронами $(l-1)$ -го и первого слоев.

Для моделирования эффективности ТФМ спроектирована двухслойная ИНС ПР с сигмоидными скрытыми и линейными выходными нейронами. Число скрытых нейронов определяли эмпирически с учетом увеличения времени обучения, весовые коэффициенты — методом обратного распространения, использующим алгоритм Левенберга–Марквардта.

На вход ИНС ПР подавали следующие переменные:

- температуру окружающей среды $t_{\text{окр}}$;
- расход теплоносителя L ;
- суммарную инсоляцию E .

Значения теплового η_t и электрического $\eta_{\text{эл}}$ КПД составили выход ИНС ПР. На рисунке 1 изображена разработанная ИНС ПР для моделирования эффективности ТФМ.

Обучение ИНС ПР можно разделить на два процесса:

- основной (60% данных) — первоначальное обучение и подбор весовых коэффициентов нейронов по результатам аналитического расчета;

- тестирования и проверки (40% данных) — адаптацию ИНС ПР на основании экспериментальных данных (служит для проверки результатов для получения представления о распределении данных (нужны для измерения обобщения сети и остановки обучения, когда обобщение перестает улучшаться, также гарантируют независимую оценку производительности сети во время и после обучения).

Для обучения разработанной ИНС ПР взят массив расчетных и экспериментальных данных, полученных для широкого диапазона температур окружающей среды и суммарной инсоляции: $t_{\text{ам}} = 5 \dots 30$ °C, $E = 100 \dots 900$ Вт/м².

Движение теплоносителя в канале ТФМ описывается системой уравнений Навье–Стокса для вязкой несжимаемой жидкости:

$$\begin{aligned} \rho \frac{\partial w_x}{\partial t} + \rho \left(w_x \frac{\partial w_x}{\partial x} + w_y \frac{\partial w_x}{\partial y} + w_z \frac{\partial w_x}{\partial z} \right) &= \\ = \rho g_x - \frac{\partial p}{\partial x} + \mu \left(\frac{\partial^2 w_x}{\partial x^2} + \frac{\partial^2 w_x}{\partial y^2} + \frac{\partial^2 w_x}{\partial z^2} \right); \\ \rho \frac{\partial w_y}{\partial t} + \rho \left(w_x \frac{\partial w_y}{\partial x} + w_y \frac{\partial w_y}{\partial y} + w_z \frac{\partial w_y}{\partial z} \right) &= \\ = \rho g_y - \frac{\partial p}{\partial y} + \mu \left(\frac{\partial^2 w_y}{\partial x^2} + \frac{\partial^2 w_y}{\partial y^2} + \frac{\partial^2 w_y}{\partial z^2} \right); \\ \rho \frac{\partial w_z}{\partial t} + \rho \left(w_x \frac{\partial w_z}{\partial x} + w_y \frac{\partial w_z}{\partial y} + w_z \frac{\partial w_z}{\partial z} \right) &= \\ = \rho g_z - \frac{\partial p}{\partial z} + \mu \left(\frac{\partial^2 w_z}{\partial x^2} + \frac{\partial^2 w_z}{\partial y^2} + \frac{\partial^2 w_z}{\partial z^2} \right), \end{aligned} \quad (1)$$

где $\rho g_x dx dy dz$ — сила тяжести в проекции на ось x , приложенная к выделенному элементарному объему жидкости с размерами ребер dx , dy , dz , Н; g — ускорение свободного падения, м/с²; $(-\partial p/\partial x) dx dy dz$ — сила давления, действующая на элемент в направлении, противоположном движению жидкости, Н;

$\mu \left(\frac{\partial^2 w_x}{\partial x^2} + \frac{\partial^2 w_x}{\partial y^2} + \frac{\partial^2 w_x}{\partial z^2} \right) dx dy dz$ — сила трения, Н; μ — коэффициент динамической вязкости, Па·с; w_x — проекция скорости жидкости на ось x , м/с.

Дифференциальные уравнения (1) решают методом конечных объемов на трехмерной сетке, исходной геометрии, разбитой на конечные объемы — геометрические примитивы (шестигранники, призмы, тетраэдры). Общее количество элементов расчетной сетки — 52866 конечных объемов. Уравнения теплового баланса вычисляются итерационным методом при помо-

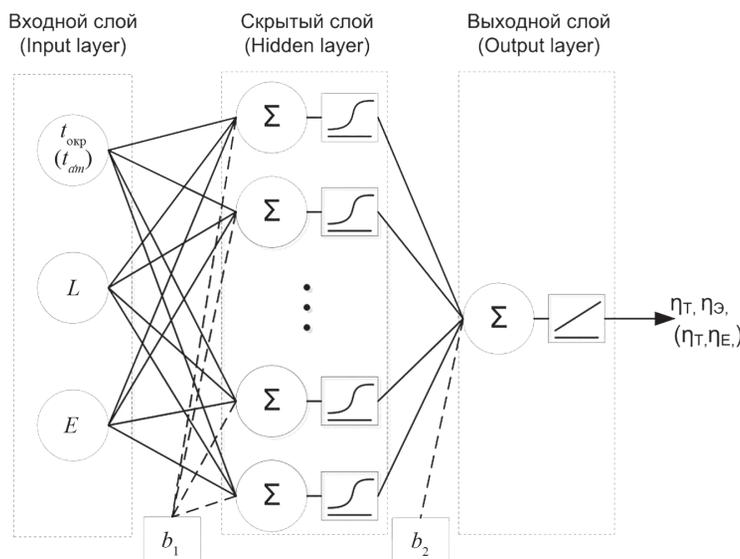


Рис. 1. Архитектура ИНС ПР для моделирования теплового и электрического КПД ТФМ

щи программы Matlab. Компьютерная модель позволяет установить температуры теплоносителя и СЭ. Для упрощения расчетной части взяты следующие допущения: тепловой поток через покрытия равномерен; свойства материалов (теплопроводность, геометрические параметры и т. д.) не зависят от температуры; площадь СЭ покрывает всю площадь абсорбера.

Тепловой КПД ТФМ зависит от суммарной инсоляции, температуры на входе/выходе в ТФМ, теплофизических свойств теплоносителя, изоляции, абсорбера, геометрических параметров ТФМ, а также расхода теплоносителя:

$$\eta_{\text{т}} = \frac{c_p \rho L (t_{\text{out}} - t_{\text{in}})}{EA_{\text{аб}}},$$

где L — расход воды, м³/с; E — суммарная инсоляция, Вт/м²; $A_{\text{аб}}$ — площадь абсорбирующей поверхности, м².

Электрический КПД ТФМ также зависит от суммарной инсоляции, температуры окружающей среды, рабочей температуры СЭ, КПД СЭ, измеренного при стандартных условиях измерений характеристик СЭ, площади поверхности СЭ, коэффициента пропускания остекленной поверхности:

$$\eta_{\text{эл}} = \frac{P_{\text{эл}}}{EA_{\text{СЭ}}},$$

где $P_{\text{эл}}$ — электрическая мощность в точке максимальной мощности, Вт; E — суммарная инсоляция, Вт/м²; $A_{\text{СЭ}}$ — площадь СЭ, м².

Электрическая мощность ТФМ равна

$$P_{\text{эл}} = \eta_{\text{эл0}} A_{\text{СЭ}} E \tau (1 - \beta_t (t_{\text{sc}} - t_0)),$$

где $\eta_{\text{эл0}}$ — КПД СЭ при стандартных условиях окружающей среды ($t_{\text{ам}} = 25$ °С), о.е.; τ — коэффициент пропускания остекленной поверхности, о.е.; β_t — коэффициент изменения КПД СЭ от температуры (0,005 °С⁻¹); t_0 — температура, соответствующая стандартным условиям измерений характеристик СЭ (25 °С).

Результаты

Разработанная ИНС ПР реализована в программе Matlab. Обучение ИНС ПР проведено с помощью алгоритма Левенберга–Марквардта, выбор которого обусловлен проведенной сравнительной оценкой раз-

личных алгоритмов обучения по показателям времени обучения T , среднеквадратической ошибки MSE . Результаты оценки приведены в таблице для различных значений числа нейронов N в скрытом слое ИНС ПР.

Из таблицы следует, что наиболее эффективен алгоритм обучения Левенберга–Марквардта: при различных значениях числа нейронов в скрытом слое ИНС ПР значение среднеквадратической ошибки MSE находится в пределах от 0,0678 до 0,071, время обучения T составляет от 15 до 25 с. Наименьшее значение среднеквадратической ошибки MSE получено при обучении ИНС ПР методом Байесовской регуляции ($MSE = 0,008$), однако указанный метод отличается значительным временем обучения, возрастающим в среднем в 4,5...3,6 раза при увеличении количества нейронов в скрытом слое ИНС ПР от 10 до 30 по сравнению с алгоритмом Левенберга–Марквардта. Метод сопряженных градиентов отличается самой высокой скоростью обучения, но самым низким из представленных алгоритмов обучения значением MSE .

Для оценки эффективности разработанной ИНС ПР выполнено сравнение показателей о фактических значениях электрического и теплового КПД ТФМ, полученных с помощью системы автоматической регистрации основных параметров ТФМ [16] и данных разработанной модели. На рисунках 2, 3 представлены зависимости электрического (теплового) КПД от расхода теплоносителя при различных значениях инсоляции и температуры окружающей среды.

Из рисунков 2, 3 видно, что фактические данные об электрическом и тепловом КПД ТФМ сопоставимы с результатами разработанной ИНС ПР. Относительная погрешность в обоих случаях составляет не более ±5% на этапе адаптации.

Обсуждение

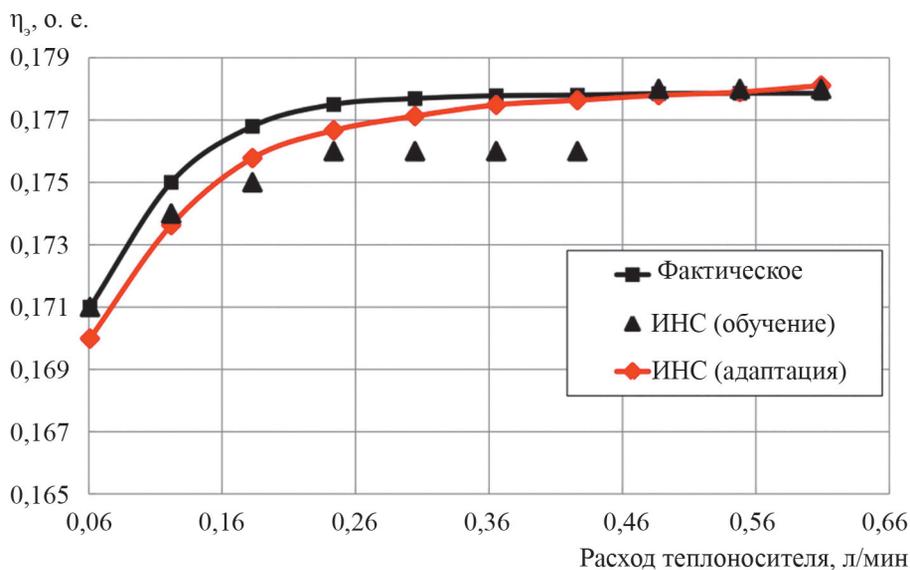
Производительность алгоритма обучения оценивали по следующим параметрам:

- время обучения T ;
- среднеквадратическая ошибка (Mean Squared Error) MSE ;
- средняя абсолютная ошибка (Mean Absolute Error) MAE .

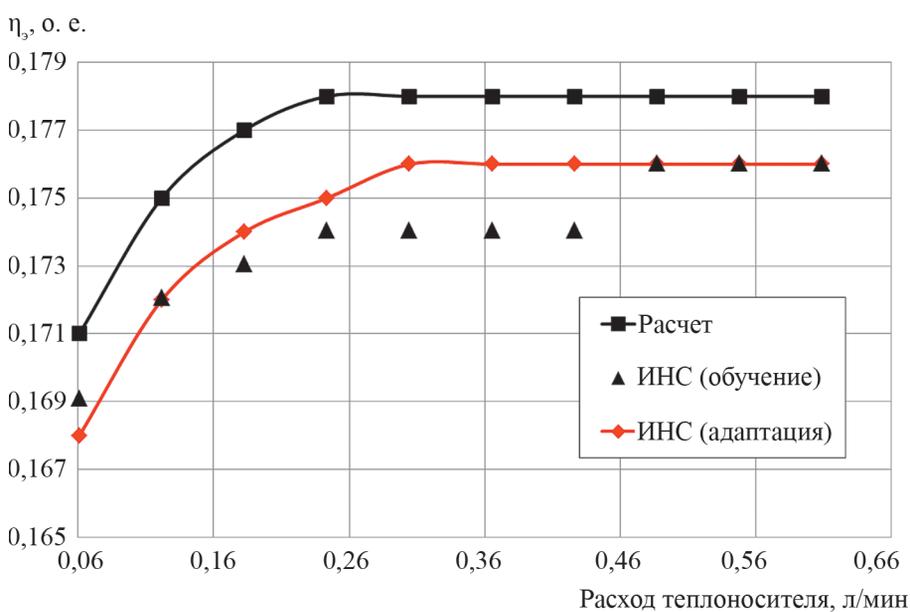
Для созданной ИНС ПР значение средней абсолютной ошибки MAE располагается в пределах от –0,319 до 0,448 — для электрического КПД и от –0,129 до

Сравнительная оценка производительности алгоритмов обучения ИНС ПР

Алгоритм обучения ИНС ПР	Число нейронов					
	10		20		30	
	T , с	MSE	T , с	MSE	T , с	MSE
Левенберга–Марквардта	15	0,0678	18	0,0560	25	0,0710
Байесовская регуляция	68	0,0080	84	0,0680	91	0,0200
Метод сопряженных градиентов	2	0,0766	2	0,1952	4	0,1114



а



б

Рис. 2. Зависимости электрического КПД ТФМ от расхода теплоносителя:

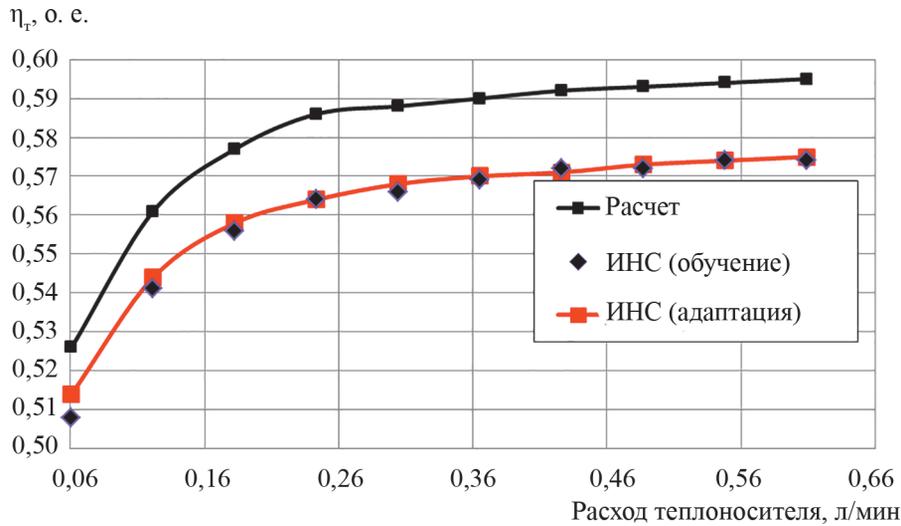
а — $E = 800 \text{ Вт/м}^2$, $t_{ам} = 10 \text{ °C}$; б — $E = 600 \text{ Вт/м}^2$, $t_{ам} = 25 \text{ °C}$

0,198 — для теплового. Среднеквадратическая ошибка MSE : 0,0678 — для электрического КПД и 0,0247 — для теплового. Время обучения T — 15 с.

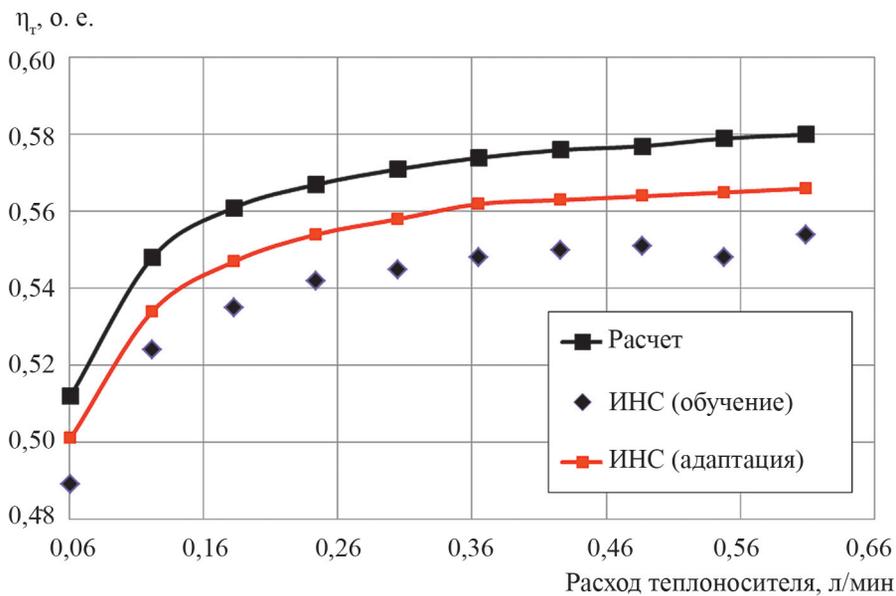
Заключение

Представленная математическая модель на основе ИНС ПР использована для моделирования эффективности ТФМ со значительным приближением теплового и электрического КПД. Дальнейшее ее применение

планируется при реализации контроллера управления системой тепло- и электроснабжения на базе ТФМ. Преимущество ИНС ПР заключается в возможности выполнения расчетов при неизвестных закономерностях входных и выходных параметров. Алгоритмы ИНС позволяют разработать новый подход для оценки оптимальных условий эксплуатации ТФМ с возможностью достижения целевых значений тепловой и электрической эффективностей.



a



б

Рис. 3. Зависимости теплового КПД ТФМ от расхода теплоносителя:

a — $E = 800 \text{ Вт/м}^2$, $t_{\text{ам}} = 10 \text{ }^\circ\text{C}$; б — $E = 600 \text{ Вт/м}^2$, $t_{\text{ам}} = 25 \text{ }^\circ\text{C}$

Литература

References

1. Турсунов М.Н., Дыскин В.Г., Турдиев Б.М., Юлдашев И.А. Влияние конвективного теплообмена на температуру солнечной фотоэлектрической батареи // Гелиотехника. 2014. № 4. С. 13—16.
2. Майоров В.А. Исследования тепловых характеристик теплофотоэлектрического солнечного модуля с концентратором и приемником треугольного профиля // Гелиотехника. 2018. № 6. С. 45—55.
3. Guo J., Zheng L. Numerically Study on a New Hybrid Photovoltaic Thermal (PVT) Collectors with Natural Circulation // Appl. Solar Energy. 2017. V. 53. Pp. 316—321.
4. Kazanci O.B., Skrupskelis M., Sevela P., Pavlov G.K. Olesen B.W. Sustainable Heating, Cooling and

1. Tursunov M.N., Dyskin V.G., Turdiev B.M., Yuldashev I.A. Vliyanie Konvektivnogo Teploobmena na Temperaturu Solnechnoy Fotoelektricheskoy Batarei. Geliotekhnika. 2014;4:13—16. (in Russian).
2. Mayorov V.A. Issledovaniya Teplovykh Kharakteristik Teplofotoelektricheskogo Solnechnogo Modulya s Kontsen-tratorom i Priemnikom Treugol'nogo Profilya. Geliotekhnika. 2018;6:45—55. (in Russian).
3. Guo J., Zheng L. Numerically Study on a New Hybrid Photovoltaic Thermal (PVT) Collectors with Natural Circulation. Appl. Solar Energy. 2017;53:316—321.
4. Kazanci O.B., Skrupskelis M., Sevela P., Pavlov G.K. Olesen B.W. Sustainable Heating, Cooling and

Ventilation of a Plus-energy House Via Photovoltaic/Thermal Panels // *Energy Buildings*. 2014. V. 83. Pp. 122—129.

5. **Haloui H., Touafek K., Zaabat M., Cheikh El Hocine H.B., Khelifa A.** Modelling of a Hybrid Photovoltaic Thermal Collector Based on CdTe // *Appl. Solar Energy*. 2016. V. 52(1). Pp. 27—31.

6. **Makki A.** Advancements in Hybrid Photovoltaic Systems for Enhanced Solar Cells Performance // *Renew. Sust. Energy Rev.* 2015. V. 41. Pp. 658—684.

7. **Durrani S.P., Balluff S., Wurzer L., Krauter S.** Photovoltaic Yield Prediction Using an Irradiance Forecast Model Based on Multiple Neural Networks // *J. Modern Power Systems and Clean Energy*. 2018. V. 6(2). Pp. 255—267.

8. **Adhitya R.Y., Sarena S.T., Atmoko R.A., Hartono D.** Smart PV Solar Tracking System Menggunakan Metode BP-NN (Back Propagation Neural Network) // *Seminar MASTER PPNS*. 2016. V. 1. Pp. 1—5.

9. **Yu K.N., Yau H.T., Li J.Y.** Chaotic Extension Neural Network-based Fault Diagnosis Method for Solar Photovoltaic Systems // *Math. Problems in Eng.* 2014. V. 2014. Pp. 1—9.

10. **Abuşka M., Akgül M.B., Altıntaş V.** Artificial Neural Network Modeling of the Thermal Performance of a Novel Solar Air Absorber Plate // *Proc. III Rostocker Symp. Thermophys. Properties Techn. Thermodynamics*. 2014. Pp. 572—581.

11. **Панченко В.А.** Солнечные кровельные панели для электро- и теплогенерации // *Гелиотехника*. 2018. № 4. С. 54—59.

12. **Тихонов П.В.** Обоснование параметров фотоэлектрического теплового модуля: дис. ... канд. техн. наук. М.: ФБГНУ ВИАЭСХ, 2014.

13. **Пат. № 2546332 РФ.** Гибридный фотоэлектрический модуль / Д.С. Стребков, А.Е. Иродионов, И.С. Персиц, Н.С. Филиппченкова // *Бюл. изобрет.* 2015. № 10.

14. **Хайкин С.** Преимущества и ограничения обучения методом обратного распространения. М.: Вильямс, 2006.

15. **Пархоменко С.С., Леденева Т.М.** Обучение нейронных сетей методом Левенберга–Марквардта в условиях большого количества данных // *Вестник Воронежского гос. ун-та. Серия «Системный анализ и информационные технологии»*. 2014. № 2. С. 98—106.

16. **Филиппченкова Н.С., Харченко А.В.** Разработка автоматической системы регистрации основных параметров солнечной концентраторной установки // *Фундаментальные и прикладные вопросы физики: Труды Междунар. конф. Ташкент: Изд-во АН Республики Узбекистан НПО «Физика-Солнце»*, 2017. С. 192—195.

Ventilation of a Plus-energy House Via Photovoltaic/Thermal Panels. *Energy Buildings*. 2014;83:122—129.

5. **Haloui H., Touafek K., Zaabat M., Cheikh El Hocine H.B., Khelifa A.** Modelling of a Hybrid Photovoltaic Thermal Collector Based on CdTe. *Appl. Solar Energy*. 2016;52(1):27—31.

6. **Makki A.** Advancements in Hybrid Photovoltaic Systems for Enhanced Solar Cells Performance. *Renew. Sust. Energy Rev.* 2015;41:658—684.

7. **Durrani S.P., Balluff S., Wurzer L., Krauter S.** Photovoltaic Yield Prediction Using an Irradiance Forecast Model Based on Multiple Neural Networks. *J. Modern Power Systems and Clean Energy*. 2018;6(2):255—267.

8. **Adhitya R.Y., Sarena S.T., Atmoko R.A., Hartono D.** Smart PV Solar Tracking System Menggunakan Metode BP-NN (Back Propagation Neural Network). *Seminar MASTER PPNS*. 2016;1:1—5.

9. **Yu K.N., Yau H.T., Li J.Y.** Chaotic Extension Neural Network-based Fault Diagnosis Method for Solar Photovoltaic Systems. *Math. Problems in Eng.* 2014;2014:1—9.

10. **Abuşka M., Akgül M.B., Altıntaş V.** Artificial Neural Network Modeling of the Thermal Performance of a Novel Solar Air Absorber Plate. *Proc. III Rostocker Symp. Thermophys. Properties Techn. Thermodynamics*. 2014:572—581.

11. **Panchenko V.A.** Solnechnye Krovельnye Paneli dlya Elektro- i Teplogeneratsii. *Geliotekhnika*. 2018;4:54—59. (in Russian).

12. **Tikhonov P.V.** Obosnovanie Parametrov Fotoelektricheskogo Teplovogo Modulya: Dis. ... Kand. Tekhn. Nauk. M.: FBG NU VIESKH, 2014. (in Russian).

13. **Pat № 2546332 RF.** Gibriddnyy Fotoelektricheskiy Modul'. D.S. Strebkov, A.E. Irodionov, I.S. Persits, N.S. Filippchenkova. *Byul. izobret.* 2015;10. (in Russian).

14. **Khaykin S.** Preimushchestva i Ogranicheniya Obucheniya Metodom Obratnogo Rasprostraneniya. M.: Vil'yams, 2006. (in Russian).

15. **Parkhomenko S.S., Ledeneva T.M.** Obuchenie Neyronnykh Setey Metodom Levenberga–Markvardta v Usloviyakh Bol'shogo Kolichestva Danykh. *Vestnik Voronezhskogo Gos. Un-Ta. Seriya «Sistemnyy Analiz i Informatsionnye Tekhnologii»*. 2014;2:98—106. (in Russian).

16. **Filippchenkova N.S., Kharchenko A.V.** Razrabotka Avtomaticheskoy Sistemy Registratsii Osnovnykh Parametrov Solnechnoy Kontsentratornoy Ustanovki. *Fundamental'nye i Prikladnye Voprosy Fiziki: Trudy Mezhdunar. Konf. Tashkent: Izd-vo AN Respubliki Uzbekistan NPO «Fizika-Solntse»*, 2017:192—195. (in Russian).

Сведения об авторе:

Филиппченкова Наталья Сергеевна — кандидат технических наук, ведущий инженер по проектированию, АО «Объединенная энергетическая компания», e-mail: natalja.filippchenkova@yandex.ru

Information about author:

Filippchenkova Nataliya S. — Ph.D. (Techn.), Leading Design Engineer, JSC «United Energy Company», e-mail: natalja.filippchenkova@yandex.ru

Статья поступила в редакцию: 09.08.2021

The article received to the editor: 09.08.2021