

СОЛНЕЧНАЯ ЭНЕРГЕТИКА

SOLAR ENERGY

КОНЦЕНТРАТОРЫ СОЛНЕЧНОГО ИЗЛУЧЕНИЯ

SOLAR RADIATION CONCENTRATORS

Статья поступила в редакцию 15.10.20 Ред. Рег. №11-08

The article has entered in publishing office 15.10.20 Ed. Reg. No. 11-08

УДК 621.311.29:535.8:51-74

**МОДЕЛИРОВАНИЕ ПРОИЗВОДИТЕЛЬНОСТИ СОЛНЕЧНЫХ
КОНЦЕНТРАТОРНЫХ МОДУЛЕЙ НА ОСНОВЕ АЛГОРИТМОВ
ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ**

Н.С. Филиппченкова

Акционерное общество Объединенная энергетическая компания,
Раушская набережная, д.8, Москва, Россия, 115035
тел.:+7(495) 657-91-01, e-mail: natalja.filippchenkowa@yandex.ru

doi: 10.15518/isjaee.2020.11.004

Заключение совета рецензентов: 25.10.20

Заключение совета экспертов: 25.10.20

Принято к публикации:30.10.20

Поскольку производительность солнечных энергетических установок носит довольно изменчивый характер, зависимость выработки от погодных условий существенно повышает необходимость точного прогнозирования. В настоящее время особую актуальность приобретает формирование нового подхода к разработке моделей производительности солнечных энергетических установок на основе алгоритмов искусственных нейронных сетей. Достоинства искусственных нейронных сетей при прогнозировании, такие как возможность обучения и учета множества параметров, не состоящих в функциональной связи, позволяют успешно использовать их при разработке моделей производительности солнечных энергетических установок. Проведен анализ существующих разработок и определены перспективные направления применения алгоритмов искусственного интеллекта в солнечной энергетике. Для моделирования производительности солнечного концентраторного модуля разработана двухслойная искусственная нейронная сеть с сигмоидными скрытыми нейронами и линейными выходными нейронами. Разработанная модель производительности солнечного концентраторного модуля на основе искусственной нейронной сети позволяет со значительным приближением определить тепловую эффективность солнечного модуля в зависимости от различных внешних условий и рабочих параметров.

Ключевые слова: искусственный интеллект, искусственная нейронная сеть, генетический алгоритм, нечеткая логика, солнечная энергетическая установка.

**MODELING THE PERFORMANCE OF SOLAR CONCENTRATOR MODULES BASED
ON ARTIFICIAL NEURAL NETWORK ALGORITHMS**

N.S. Filippchenkova

Joint stock company United Energy Company, Raushskaya embankment, 8, Moscow, Russia, 115035
tel.:+7(495) 657-91-01, e-mail: natalja.filippchenkowa@yandex.ru

doi: 10.15518/isjaee.2020.11.004

Referred: 25.10.20

Received in revised form: 25.10.20

Accepted:30.10.20

Since the performance of solar power plants is quite variable, the dependence of production on weather conditions significantly increases the need for accurate forecasting. At present, the formation of a new approach to the develop-



ment of predictive models of the performance of solar power plants based on artificial neural network algorithms is acquiring special relevance. The advantages of artificial neural networks in forecasting, such as the ability to learn and take into account a set of parameters that are not in a functional connection, make it possible to successfully use them in the development of models of the performance of solar power plants. The analysis of existing developments is carried out and promising areas of application of artificial intelligence algorithms in solar energy are determined. To simulate the performance of a solar concentrator module, a two-layer artificial neural network with sigmoid hidden neurons and linear output neurons has been developed. The developed performance model of a solar concentrator module based on an artificial neural network makes it possible, with a significant approximation, to determine the thermal efficiency of a solar module depending on various external conditions and operating parameters.

Keywords: artificial intelligence, artificial neural network, genetic algorithm, fuzzy logic, solar power plant.



Филиппченкова
Наталья Сергеевна
Filippchenkova Natalia
Sergeevna

Сведения об авторе: к.т.н., ведущий инженер, АО «ОЭК».

Образование: ФГБНУ ФНАЦ ВИМ.

Область научных интересов: солнечная энергетика, возобновляемые источники энергии, концентраторы солнечной энергии

Публикации: 36.

Information about the author: Ph.D., Leading Engineer, JSC UE

Education: Federal State Budget Scientific Institution Federal Scientific Agroengineering Center VIM (FSAC VIM)

Research interests: solar energy, renewable energy, solar energy concentrators

Publications: 36.

Введение

В настоящее время в области солнечной энергетики при решении задач моделирования и оптимизации все более возрастает интерес к использованию алгоритмов искусственного интеллекта (ИИ), в частности, алгоритмов искусственных нейронных сетей (ИНС) [1]. В работе [2] Калогироу С.А. и др. использовали ИНС для моделирования переходной реакции нагрева солнечной парогенераторной установки. В [3] Альмонацид Ф. и др. использовали ИНС для прогнозирования вольт-амперных характеристик (ВАХ) Si-кристаллических модулей. В работе [4] Зёцен А. и др. разработали новую формулу на основе методов ИНС для определения эффективности плоских солнечных коллекторов (СК). Эсен Х. и др. в работе [5] предложили модели системы солнеч-

ного воздухонагревателя на базе ИНС и вейвлет-нейронной сети. В работе [6] Ларбес С. и др. исследовали использование интеллектуальных методов управления для отслеживания точки максимальной мощности фотоэлектрических систем (ФЭС). Предложена разработка и моделирование контроллера слежения за точкой максимальной мощности (ТММ) на основе нечеткой логики (НЛ). Загруба М. и др. в [7] предложили выполнить численный метод на основе генетических алгоритмов (ГА) для определения электрических параметров ФЭМ и солнечных элементов (СЭ). В работе [8] Калогироу С.А. использовал методы ИИ, такие как ИНС и ГА для оптимизации СЭУ с целью максимизации ее экономических выгод. Алгоритмы ИИ успешно применяются в широком спектре приложений солнечной энергетики [9-16].

Список обозначений

Список обозначений	
Буквы греческого алфавита	
β	Угол наклона поверхности входа концентратора
η	КПД
Буквы латинского алфавита	
E	Инсоляция
T	Температура
F	Расход теплоносителя
N	Количество нейронов в скрытом слое
R	Коэффициент корреляции
Y	Прогнозируемая переменная
z	Угол наклона зеркальных ламелей
v	Скорость ветра
m	Количество предсказаний
t	Время обучения
Буквы русского алфавита	

Индексы нижние

$вх$	температура теплоносителя на входе модуля
$вых$	температура теплоносителя на выходе модуля
$сум$	суммарная инсоляция
$пр$	прямая инсоляция
$окр$	температура окружающего воздуха
T	тепловой КПД модуля
Единицы измерения	
$кВт \cdot ч / м^2$	Киловатт в час на метр квадратный
град.	Градус
$^{\circ}К$	Градус Кельвина
$м^3 / с$	Кубический метр в секунду
$м / с$	Метр в секунду
Аббревиатуры	
ИИ	Искусственный интеллект
ИНС	Искусственная нейронная сеть

ИСН ПР	Искусственная нейронная сеть прямого распространения
СЭУ	Солнечная энергетическая установка
ВАХ	Вольт-амперная характеристика
ФЭМ	Фотоэлектрический модуль
СК	Солнечный коллектор
ФЭС	Фотоэлектрические системы
ТММ	Точка максимальной мощности
СЭ	Солнечный элемент

НЛ	Нечеткая логика
ГА	Генетический алгоритм
ANFIS	Adaptive neuro-fuzzy inference system
НСКМ с ЖГ	Неследящий солнечный концентраторный модуль с жалюзийным гелиостатом
КПД	Коэффициент полезного действия
MSE	Mean squared error
ANN	Artificial neural network

1. Цель работы

Разработка математической модели для прогнозирования производительности не следящего солнечного концентраторного модуля с жалюзийным гелиостатом (НСКМ с ЖГ) на основе искусственной нейронной сети.

Научная новизна работы заключается в том, что разработанная математическая модель на основе ИНС позволяет выполнять расчеты при неизвестных закономерностях входных и выходных параметров и прогнозировать производительность НСКМ с ЖГ со значительным приближением теплового КПД.

Научная значимость работы состоит в формировании научно-обоснованного подхода к прогнозированию производительности НСКМ с ЖГ для оценки оптимальных условий эксплуатации НСКМ с ЖГ для достижения целевых значений теплового КПД.

2. Методы и материалы

ИНС – математические модели, построенные по принципу организации и функционирования биологических нейронных сетей – сетей нервных клеток живого организма. ИСН содержат узлы или нейроны и делятся на слои, входные слои, выходные и скрытые.

В работах [17-20] представлены разработанная конструкция не следящего солнечного концентратор-

ного модуля с жалюзийным гелиостатом (НСКМ с ЖГ) и результаты экспериментального исследования данного модуля в натуральных условиях. Для моделирования производительности разработанного модуля была разработана двухслойная ИНС с сигмоидными скрытыми нейронами и линейными выходными нейронами. Первый этап моделирования состоит в создании базы данных с наиболее важными параметрами НСКМ с ЖГ, такими как тепловой КПД модуля. На вход ИНС подаются следующие переменные:

- 1) рабочие переменные:
 - угол наклона поверхности входа концентратора (β), град.,
 - угол наклона зеркальных ламелей (z), град.,
 - температура теплоносителя на входе (T_{ex}), °K,
 - расход теплоносителя (F), м³/с;
- 2) переменные окружающей среды:
 - прямая инсоляция (E_{np}), кВт*ч/м².

Вышеуказанные входные переменные и значения теплового КПД составляют базу данных разработанной ИНС. На рис.1 представлена архитектура разработанной ИНС для моделирования теплового КПД НСКМ с ЖГ.

На втором этапе ИНС обучалась для минимизации ошибки аппроксимации.

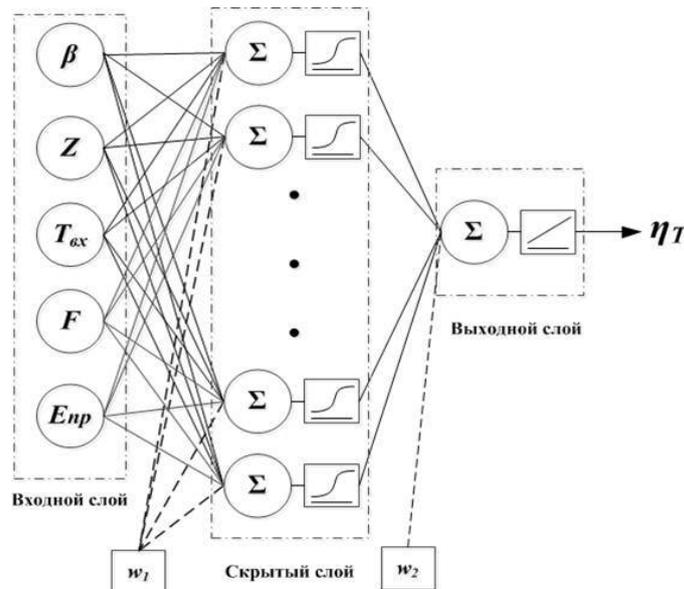


Рис. 1. Архитектура разработанной ИНС для прогнозирования теплового КПД НСКМ с ЖГ
 Fig. 1. The architecture of the developed ANN for predicting the thermal efficiency of the NSCM with LH

3. Результаты и обсуждение

Разработанная ИНС была обучена с помощью алгоритма Левенберга-Марквардта [14]. Алгоритм Левенберга-Марквардта – наиболее распространенный алгоритм оптимизации ИСН, превосходящий по производительности метод наискорейшего спуска и другие методы сопряженных градиентов в различных задачах. Алгоритм Левенберга-Марквардта – это комбинация простейшего градиентного метода и метода Гаусса-Ньютона, также данный алгоритм можно также рассматривать как метод доверитель-

ных интервалов. Основным преимуществом данного метода является высокая сходимость.

Количество нейронов в скрытом слое принято равным $N=10$. Оценка производительности алгоритма обучения осуществлялась по следующим параметрам: время обучения (t), среднеквадратическая ошибка (Mean squared error – MSE), коэффициент корреляции между результатами и целями (R) [14].

На рис. 2 представлен график обучения ИНС, показывающий изменение ошибки обучения сети. График на рис. 2 показывает, что за 50 итераций достигнуто среднеквадратическое значение ошибки равной $MSE=0.0183$.

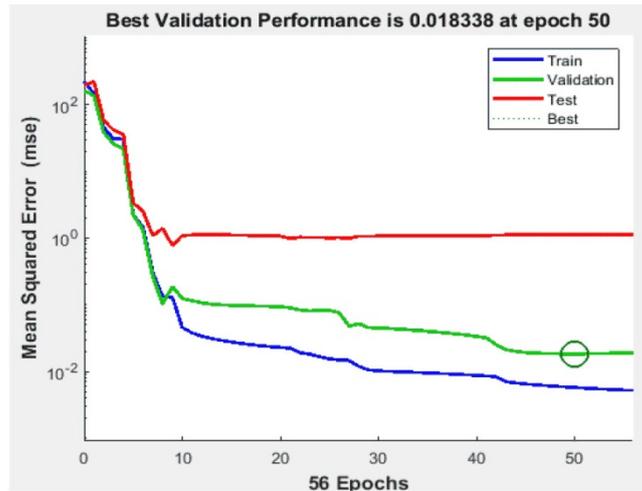


Рис. 2. График обучения ИНС
Fig. 2. ANN training graph

На рис. 3 представлен график линейной регрессии результатов обучения, показывающий линейную регрессию результатов обучения сети на трех анализированных подмножествах и на всех множествах. Как

видно из рис. 3 ИНС аппроксимирует функцию со значением коэффициента корреляции, равным $R=1$. Время обучения сети T составило 2 секунды.

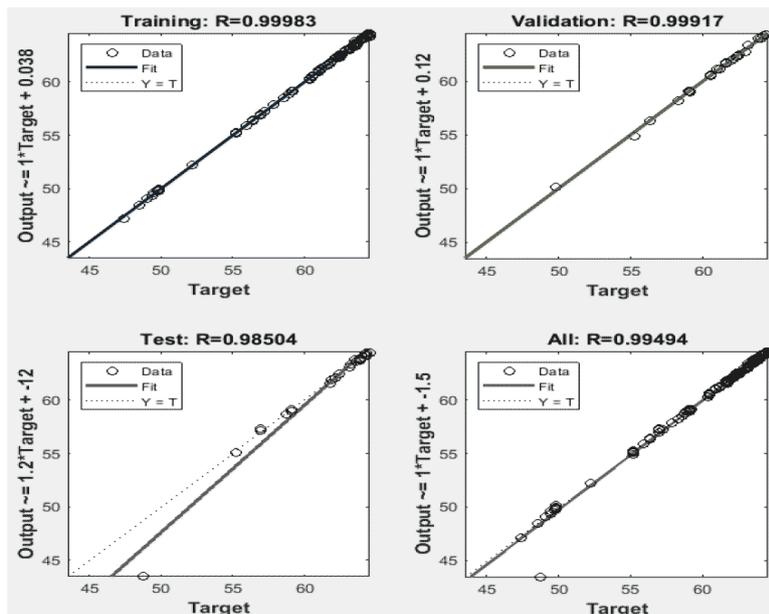


Рис. 3. Графики линейной регрессии результатов обучения ИНС
Fig. 3. Linear regression graphs of ANN training results



На рис. 4 приведены графики состояния обучения ИНС.

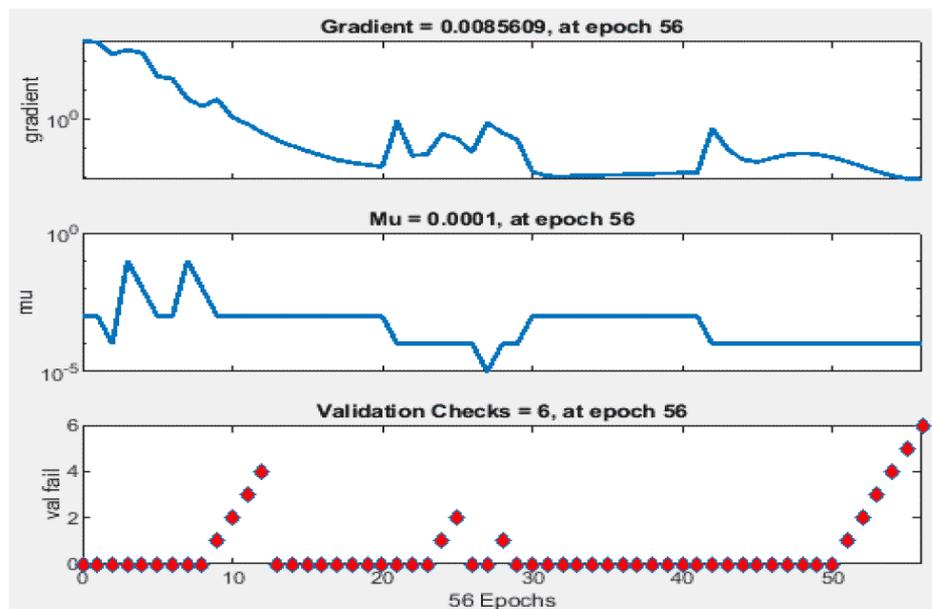


Рис. 4. Графики состояния обучения ИНС
Fig. 4. ANN training status graphs

4. Анализ полученных результатов

В работе [4] представлены результаты моделирования эффективности плоских солнечных коллекторов с помощью ИНС: значения среднеквадратической ошибки составили 2.5584 и 0.02 соответственно. Для обучения разработанной ИНС использовался алгоритм Левенберга-Марквардта. В результате моделирования установлено, что при значениях числа нейронов в скрытом слое ИНС от 10 до 30 время обучения составляет от 1 до 5 секунд, достигается коэффициент корреляции равный $R=1$, при этом значение среднеквадратической ошибки (MSE) находится в пределах от 0.0183 до 0.0436, что соответствует точности, представленной в работах [3-5, 8].

Заключение

Программно-аппаратные комплексы на базе алгоритмов ИНС позволят эффективно определять причину и типы повреждений и аварийных ситуаций, с требуемой точностью прогнозировать производительность объектов солнечной энергетике в зависимости от внешних условий, а также адаптироваться к конкретному типу оборудования СЭУ.

Благодарности

Работа выполнена при финансовой поддержке Федерального государственного бюджетного учреждения «Фонд содействия развитию малых форм предприятий в научно-технической сфере» (Фонд содействия инновациям) в соответствии с договором №15711ГУ/2020 (от 11 июля 2020 г.).

Список литературы

1. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. – 2-е изд., пер. с англ. – М.: Вильямс, 2006. – 1104 с.
2. Kalogirou, S.A. / Artificial neural networks for modelling the starting-up of a solar steam-generator / S.A. Kalogirou, C.C. Neocleous, C.N. Schizas // Applied Energy. – 1998. – V. 60. – P. 89–100.
3. Almonacid, F. / Characterisation of Si-crystal line PV modules by artificial neural Networks / F. Almonacid, C. Rus, L. Hontoria, M. Fuentes, G. Nofuentes // Renewable Energy. – 2009. – V. 34. – P. 941–949.
4. Sözen, A. / Determination of efficiency of flat-plate solar collectors using neural network approach / A. Sözen, T. Menlik, S. Unvar // Expert Systems with Applications. – 2008. – V. 35. – P. 1533–1539.
5. Esen, H. / Artificial neural network and wavelet neural network approaches for modelling of a solar air heater / H. Esen, F. Ozgen, M. Esen, A. Sengur // Expert Systems with Applications. – 2009. – V. 36. – P. 11240–11248.
6. Larbes, C. / Genetic algorithms optimized fuzzy logic control for the maximum power point tracking in photovoltaic system / C. Larbes, S.M. Ait Cheikh, T. Obeidi, A. Zerguerras // Renewable Energy. – 2009. – V. 34. – P. 2093–2100.
7. Zagrouba, M. / Identification of PV solar cells and modules parameters using the genetic algorithms: Application to maximum power extraction / M. Zagrouba, A. Sellami, M. Bouaicha,



M. Ksouri // *Solar Energy*. – 2010. – V. 84. – № 5 – P. 860–866.

8. Kalogirou, S.A. / Optimization of solar systems using artificial neural-networks and genetic algorithms / S.A. Kalogirou // *Applied Energy*. – 2004. – V. 77. – P. 383–405.

9. Sanchez, E.N. / Electric load demand prediction using neural networks trained by Kalman Filtering / E.N. Sanchez, A.Y. Alanis, J. Rico // *IEEE International Joint Conference on Neural Networks*, Budapest, Hungary. –2004. – V.4. – P. 2771–2775. DOI: 10.1109/IJCNN.2004.1381093.

10. Lippmann, R.P. / An introduction to computing with neural nets / R.P. Lippmann // *IEEE ASSP Magazine*. – 1987. – V.4(2). – P. 4–22.

11. Rumelhart, D. / Learning internal representations by error propagation / D.Rumelhart, E. Geoffrey, R.J. Williams // *Parallel distributed processing: explorations in the microstructure of cognition*. –1986. – V.1. – P. 282-317.

12. Сараев, П.В. Идентификация нейросетевых моделей / П.В. Сараев. –Л.: Изд-во ЛГТУ, 2011. – 94 с.

13. Хайкин, С. Преимущества и ограничения обучения методом обратного распространения / С. Хайкин. – 2-е изд., пер. с англ. – М.: Вильямс, 2006. – 314 с.

14. Пархоменко, С.С. / Обучение нейронных сетей методом Левенберга-Марквардта в условиях большого количества данных / С.С. Пархоменко, Т.М. Леденева // *Вестник Воронежского государственного университета*. – 2014. – № 2. – С. 98-106.

15. Yousif, J.H. / A comparison study based on artificial neural network for assessing PV/T solar energy production / J.H. Yousif, H.A. Kazem, N.N. Alattar, I.I. Elhasa // *Case Studies in Thermal Engineering*. – 2019. – V. 13. – P. 1-13. DOI: 10.1016 / j.csite.2019.100407.

16. O'Leary, D. / Feature Selection and ANN Solar Power Prediction / D. O'Leary, J. Kubby // *Hindawi*. – 2017. – V.2017. – P. 1-7. DOI: 10.1155/2017/2437387.

17. Стребков, Д.С. / Неследящие солнечные концентраторы с жалюзийными гелиостатами: межламельные эффекты / Д.С. Стребков, А.Е. Иродионов, Н.С. Филиппченкова // *Гелиотехника*. – 2015. – № 4. – С. 72-78.

18. Стребков Д.С. / Экспериментальное исследование солнечных концентраторных модулей с жалюзийными гелиостатами / Д.С. Стребков, А.Е. Иродионов, Н.С. Филиппченкова // *Материалы Всероссийской научной конференции с международным участием и XI научной молодежной школы «Возобновляемые источники энергии»*. – 2018. – С. 188-195.

19. Strebkov, D.S. / Nontracking solar concentrators with louver heliostats: bar-to-bar effects / D.S. Strebkov, A.E. Irodionov, N.S. Filippchenkova // *Applied Solar Energy*. – 2015. – V. 51. – № 4. – P. 306-310.

20. Strebkov, D.S. / Nontracking Solar Concentrators with louvered heliostats: A Calculation Algorithm / D.S. Strebkov, A.E. Irodionov, N.S. Filippchenkova // *Applied Solar Energy*. –2017. –V. 53. – № 1. – P. 39–44.

References

1. Khaikin, S. *Neironnye seti: polnyi kurs* / S. Khaikin. – 2-e izd., per. s angl. – M.: Vil'yams, 2006. – 1104 s.

2. Kalogirou, S.A. / Artificial neural networks for modelling the starting-up of a solar steam-generator / S.A. Kalogirou, C.C. Neocleous, C.N. Schizas // *Applied Energy*. – 1998. – V. 60. – P. 89–100.

3. Almonacid, F. / Characterisation of Si-crystal line PV modules by artificial neural Networks / F. Almonacid, C. Rus, L. Hontoria, M. Fuentes, G. Nofuentes // *Renewable Energy*. – 2009. – V. 34. – P. 941–949.

4. Sözen, A. / Determination of efficiency of flat-plate solar collectors using neural network approach / A. Sözen, T. Menlik, S. Unvar // *Expert Systems with Applications*. – 2008. – V. 35. – P. 1533–1539.

5. Esen, H. / Artificial neural network and wavelet neural network approaches for modelling of a solar air heater / H. Esen, F. Ozgen, M. Esen, A. Sengur // *Expert Systems with Applications*. – 2009. – V. 36. – P. 11240–11248.

6. Larbes, C. / Genetic algorithms optimized fuzzy logic control for the maximum power point tracking in photovoltaic system / C. Larbes, S.M. Ait Cheikh, T. Obeidi, A. Zerguerras // *Renewable Energy*. – 2009. – V. 34. – P. 2093–2100.

7. Zagrouba, M. / Identification of PV solar cells and modules parameters using the genetic algorithms: Application to maximum power extraction / M. Zagrouba, A. Sellami, M. Bouaicha, M. Ksouri // *Solar Energy*. – 2010. – V. 84. – № 5 – P. 860–866.

8. Kalogirou, S.A. / Optimization of solar systems using artificial neural-networks and genetic algorithms / S.A. Kalogirou // *Applied Energy*. – 2004. – V. 77. – P. 383–405.

9. Sanchez, E.N. / Electric load demand prediction using neural networks trained by Kalman Filtering / E.N. Sanchez, A.Y. Alanis, J. Rico // *IEEE International Joint Conference on Neural Networks*, Budapest, Hungary. –2004. – V.4. – P. 2771–2775. DOI: 10.1109/IJCNN.2004.1381093.

10. Lippmann, R.P. / An introduction to computing with neural nets / R.P. Lippmann // *IEEE ASSP Magazine*. – 1987. – V.4(2). – P. 4–22.

11. Rumelhart, D. / Learning internal representations by error propagation / D.Rumelhart, E. Geoffrey, R.J. Williams // *Parallel distributed processing: explorations in the microstructure of cognition*. –1986. – V.1. – P. 282-317.

12. Saraev, P.V. *Identifikatsiya neurosetevykh modelei* / P.V. Saraev. –L.: Izd-vo LGTU, 2011. – 94 s.



13. Khaikin, S. Preimushchestva i ogranicheniya obucheniya metodom obratnogo rasprostraneniya / S. Khaikin. – 2-e izd., per. s angl. – M.: Vil'yams, 2006. – 314 s.
14. Parkhomenko, S.S. / Obuchenie neironnykh setei metodom Levenberga-Markvardta v usloviyakh bol'shogo kolichstva dannykh / S.S. Parkhomenko, T.M. Ledeneva // Vestnik Voronezhsko-go gosudarstvennogo universiteta. – 2014. – № 2. – S. 98-106.
15. Yousif, J.H. / A comparison study based on artificial neural network for assessing PV/T solar energy production / J.H. Yousif, H.A. Kazem, N.N. Alattar, I.I. Elhassa // Case Studies in Thermal Engineering. – 2019. – V. 13. – P. 1-13. DOI: 10.1016 / j.csite.2019.100407.
16. O'Leary, D./ Feature Selection and ANN Solar Power Prediction / D. O'Leary, J. Kubby // Hindawi. – 2017. – V. 2017. – P. 1-7. DOI: 10.1155/2017/2437387.
17. Strebkov, D.S. / Nesledyashchie solnechnye kontsentratory s zhalyuziynymi geliostatami: mezhlam-el'nye ehffekty / D.S. Strebkov, A.E. Irodionov, N.S. Filippchenkova // Geliotekhnika. – 2015. – № 4. – С. 72-78.
18. Strebkov D.S. / Ehksperimental'noe issledovanie solnechnykh kontsentratornykh modulei s zhalyuziynymi geliostatami / D.S. Strebkov, A.E. Irodionov, N.S. Filippchenkova // Materialy Vserossiiskoi nauchnoi konferentsii s mezhduna-rodnyim uchastiem i XI nauchnoi molodezhnoi shko-ly «Vozobnovlyaemye istochniki ehnergi». – 2018. – S. 188-195.
19. Strebkov, D.S. / Nontracking solar concentrators with louver heliostats: bar-to-bar effects / D.S. Strebkov, A.E. Irodionov, N.S. Filippchenkova // Applied Solar Energy. – 2015. – V. 51. – № 4. – P. 306-310.
20. Strebkov, D.S. / Nontracking Solar Concentrators with louvered heliostats: A Calculation Algorithm / D.S. Strebkov, A.E. Irodionov, N.S. Filippchenkova // Applied Solar Energy. – 2017. – V. 53. – № 1. – P. 39-44.



«Газпром» рассмотрел направления развития водородной энергетики

Правление «Газпрома» рассмотрело вопрос о производстве и применении водорода, осуществлении экспортных поставок водорода и метано-водородных смесей с использованием существующей газовой инфраструктуры.

Отмечено, что в последнее время водородная энергетика рассматривается во многих странах как одно из ключевых направлений при реализации национальных стратегий по низкоуглеродному развитию. Вместе с тем, водород является вторичным энергоресурсом – для его производства требуется дополнительная энергия, что отражается на его себестоимости. Большинство заявленных в этой области зарубежных проектов реализуются за счет государственных субсидий и льгот, а общего мирового рынка «энергетического» водорода сегодня не существует.

На предприятиях Группы «Газпром» в настоящее время по различным технологиям производится более 350 тыс. тонн водорода, который используется для получения различных видов продукции.

Для «Газпрома» представляется важным формировать собственные технологические компетенции в области водородной энергетики, используя уникальные свойства природного газа – экологичность и экономичность. В этой связи компания рассматривает несколько направлений использования водорода как энергоресурса.

Прежде всего, это разработка инновационных технологий для применения метано-водородного топлива в собственной производственной деятельности, а также разработка инновационных технологий для производства водорода из метана без выбросов CO₂ и способов его транспортировки, в том числе, для экспорта.

Масштабное внедрение подобных технологий создаст дополнительный спрос на природный газ как сырье для производства водорода.

Вопрос о производстве и применении водорода, осуществлении экспортных поставок водорода и метано-водородных смесей с использованием существующей газовой инфраструктуры будет внесен на рассмотрение Совета директоров.

globalenergyprize.org

