

EDN: VHRXXQ

УДК 004.896

An Indirect Forecasting System of the Power from a Solar Panel Array Based on Modified Fuzzy Neural Network

Ekaterina A. Engel* and Nikita E. Engel

Khakas State University

Abakan, Khakassia Republic, Russian Federation

Received 04.07.2023, received in revised form 28.07.2023, accepted 08.08.2023

Abstract. Forecasting systems of the power from a solar panel array based on neuronets increase the efficiency of a solar plant. Therefore, these systems are relevant in accordance with item 20A of the strategy of scientific and technological development of the Russian Federation. The power from a solar panel array has complex non-linear dynamic with uncertainties due to changes in cloudiness. Thus, it is impossible to approximate this complex dynamic with classical methods with a given accuracy, while neuronets provide the required accuracy. For identification of a forecasting system of the power from a solar panel array, intelligent methods in comparison with traditional methods provide the required accuracy by contributing to the safe and effective management of electric grids that integrating solar power plants. Under uncertainties by means of recurrent neurons and the attention mechanism the effective generation and transmission of a hidden information representation as a signal of the output layer of hidden recurrent neurons of deep neural networks, on the basis of the outputs of which a modified fuzzy neural network generated the forecasted value of power from a solar panel array by the fuzzy-possible convolution algorithm. The modified fuzzy neural network effectively distinguishes from the data significant functional aspects of forecasting of the power from a solar panel array, including aspects of identifying the cloudiness of the hour. The experimental modelling results of the indirect day ahead forecasting system of the power from a solar panel array based on the modified fuzzy neural network demonstrate its robustness and a decrease in the mean square error of its forecast by an average of three and six times in comparison with recurrent neural networks and a standard model of moving average autoregression under uncertainties.

Keywords: power from a solar panel array forecasting, recurrent neural networks, attention mechanism, modified fuzzy neural network.

Acknowledgements. The research was carried out within the framework of the event “Development of intelligent systems for forecasting and maximizing electricity generation of a solar power plant based on an original modified fuzzy neural network, their implementation as computer programs and the

© Siberian Federal University. All rights reserved

This work is licensed under a Creative Commons Attribution-Non Commercial 4.0 International License (CC BY-NC 4.0).

* Corresponding author E-mail address: ekaterina.en@gmail.com

introduction of renewable energy sources at power plants” of the world-class REC “Yenisei Siberia” activity program.

Financing. The research was carried out at the expense of a grant from the Ministry of Education and Science of the Republic of Khakassia (Agreement No. 91 dated 13.12.22), a research project “Development of an intelligent system for indirect forecasting of electricity generation of a solar power plant based on a modified fuzzy neural network”.

Citation: Engel, E.A., Engel, N.E. An indirect forecasting system of the power from a solar panel array based on modified fuzzy neural network. J. Sib. Fed. Univ. Eng. & Technol., 2023, 16(6), 744–758. EDN: VHRXXQ



Система непрямого прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на основе модифицированной нечеткой нейросети

Е. А. Энгель, Н. Е. Энгель
*ФГБОУ ВО «Хакасский государственный университет
им. Н. Ф. Катанова»,
Российская Федерация, Республика Хакасия, Абакан*

Аннотация. Интеллектуальные системы прогнозирования вырабатываемой электроэнергии массивом солнечных панелей повышают эффективность солнечной электростанции и, таким образом, актуальны в соответствии с пунктом 20А Стратегии научно-технологического развития РФ. Вырабатываемая массивом солнечных панелей электроэнергия имеет сложную нелинейную динамику с неопределенностями, обусловленными изменением облачности. В связи с этим идентифицировать систему прогнозирования вырабатываемой электроэнергии массивом солнечных панелей классическими методами с заданной точностью нельзя, в то время как нейросети обеспечивают требуемую точность. Системы прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на основе нейросетей в сравнении с традиционными методами обеспечивают требуемую точность прогноза, способствуя безопасному и эффективному управлению электрическими сетями, интегрирующими солнечные электростанции. В условиях неопределенности на основе модифицированной нечеткой нейросети, обеспечивающей средствами рекуррентных нейронов и механизма внимания эффективное формирование и передачу скрытого представления информации как сигнала выходного слоя скрытых рекуррентных нейронов глубоких нейросетей, на основе выходов которых алгоритмом нечетко-возможностной свертки генерируется прогнозируемое значение вырабатываемой электроэнергии массивом солнечных панелей. Модифицированная нечеткая нейросеть эффективно выделяет на основе архивных данных существенные функциональные аспекты прогнозирования вырабатываемой электроэнергии массивом солнечных панелей, включая аспекты идентификации облачности часа. Полученные результаты экспериментального моделирования системы прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей на основе модифицированной нечеткой нейросети демонстрируют ее робастность и снижение среднеквадратичной ошибки прогноза в среднем в три и шесть раз в сравнении с рекуррентными нейросетями и стандартной моделью авторегрессии скользящего среднего в условиях неопределенности.

Ключевые слова: прогнозирование вырабатываемой электроэнергии массивом солнечных панелей, рекуррентные нейросети, механизм внимания, модифицированная нечеткая нейросеть.

Благодарности. Исследование выполнено в рамках мероприятия «Разработка интеллектуальных систем прогнозирования и максимизации выработки электроэнергии солнечной электростанции на основе оригинальной модифицированной нечеткой нейросети, их реализация как программ для ЭВМ и внедрение на электростанции возобновляемых источников энергии» программы деятельности НОЦ мирового уровня «Енисейская Сибирь».

Финансирование. Исследование выполнено за счет средств гранта Министерства образования и науки Республики Хакасия (Соглашение № 91 от 13.12.22), научно-исследовательский проект «Разработка интеллектуальной системы непрямого прогнозирования выработки электроэнергии солнечной электростанции на основе модифицированной нечеткой нейросети».

Цитирование: Энгель Е. А. Система непрямого прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на основе модифицированной нечеткой нейросети / Е. А. Энгель, Н. Е. Энгель // Журн. Сиб. федер. ун-та. Техника и технологии, 2023, 16(6). С. 744–758. EDN: VHRXXQ

Тематика и результаты данного научного исследования актуальны, поскольку соответствуют пункту 20А стратегии научно-технологического развития РФ [1]. Отрасли и области применения результатов исследования соответствуют стратегии социально-экономического развития Республики Хакасия, поскольку Республика Хакасия обладает высоким природным потенциалом для развития солнечной энергетики (величина годовой солнечной инсоляции соответствует, например, уровню инсоляции в южных районах Краснодарского края). Результаты исследования развивают интеллектуальные технологии возобновляемой электроэнергетики, способствуют снижению выбросов парниковых газов, улучшению экологической обстановки и экологического благополучия населения Сибири и Российской Федерации в целом.

Прогнозирование мощности солнечных электростанций критически важно для обеспечения эффективной работы и безопасного управления электрическими сетями с интегрированными солнечными электростанциями. Рынок «сутки вперед» предусматривает наложение штрафных санкций на владельцев солнечных электростанций за отклонение от предоставляемого графика почасовой выработки солнечной электростанции. В обзорных [2–3] и научных [4–20] публикациях рассматриваются нейросетевые модели прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей и оцениваются различные алгоритмы и подходы для повышения точности и снижения неопределенности в моделях прогнозирования.

Согласно обзорной статье [3] нормированная инсоляция (полученная путем деления реальной инсоляции на инсоляцию безоблачного неба) обеспечивает лучшую точность нейросетевой модели. В соответствии с работой [4] вырабатываемая электроэнергия массива солнечных панелей зависит от инсоляции и температуры линейно и нелинейно соответственно.

В [5] сверточная нейросеть с механизмами внимания (multi-headed CNN) обеспечивает эффективный прогноз на сутки вперед выработки электроэнергии массивом солнечных панелей (табл. 1). В [6] аналогичная задача решается ансамблем перцептронов, настроенных на основе следующих входных сигналов: фактическая инсоляция, скорость ветра, влажность, температура, давление, облачность, время года и суток. Экспериментальные результаты отражают лучшую эффективность ансамбля перцептронов в сравнении с одиночным перцептроном аналогичной конфигурации (табл. 1).

В публикации [7] исследователи интегрировали физическую модель массива солнечных панелей в следующие нейросети: сверточная нейросеть, нейросеть с долгой краткосрочной памятью (LSTM) и гибридная архитектура CNN-LSTM. Экспериментальные результаты выявили лучшую точность нейросетей, интегрирующих общую физическую модель массива солнечных панелей, вне зависимости от типа нейросети (табл. 1).

В статье [8] разработана система прогнозирования мощности массива солнечных панелей на основе рекуррентной нейросети, обученной с использованием данных выработки солнечной электростанции, инсоляции, температуры модуля и окружающей среды, скорости ветра, влажности. Результаты экспериментов показали, что обученная рекуррентная нейросеть (PHC) достигла точности нормализованного среднего значения в среднем 97 % [9].

Непрямая система прогнозирования генерируемой мощности солнечной панели, включающая подсистему прогноза инсоляции и подсистему солнечной панели, разработана в [10]. Подсистема прогноза инсоляции основана на нескольких перцептронах, обеспечивающих абсолютную ошибку (в процентах) 3,4 % в солнечный день и 23 % в пасмурный день. Точность прогноза не прямой системы прогнозирования выходной мощности солнечной панели оказалась намного выше, чем при прямой системе прогнозирования выходной мощности солнечной панели [10].

В публикации [11] предложен алгоритм прогнозирования генерируемой мощности массива солнечных панелей на основе рекуррентных нейронных сетей с входными сигналами, инте-

Таблица 1. Результаты нейросетевых моделей прогнозирования на сутки вперед выработки электроэнергии массивом солнечных панелей

Table 1. The results of neural network models for hourly forecasting of the electric power generated from the solar panels array

Алгоритм прогнозирования	Объем данных	RMSE (кВт*ч)	RMSE %
PHC-LSTM [13]	4 года	26.85	-
Transfer learning constrained LSTM (TL + C-LSTM) [14]	1 год	8.89	-
DPNN [15]	2 недели	52.8	-
CNN-LSTM [16]	-	45.11	-
LSTM-PHC [17]	1 год	82.15	-
LSTM [18]	-	139.3	-
Ансамбль перцептронов [6]	-	5	6.25 %
Перцептрон [19]	1 год	160.3	-
TDNN [19]	1 год	122	-
CNN с механизмом внимания [5]	6 лет	81	-
D-PNN [20]	-	60	-
CNN [7]	15 месяцев	-	8.69 %
LSTM [7]	15 месяцев	-	7.56 %
Гибридная нейросеть [7]	15 месяцев	-	8.06 %
Перцептрон [9]	100 дней	3.66	-
LSTM [12]	3 месяца	7.1	-

гированными из нескольких источников. Результаты экспериментов показали существенное снижение средней абсолютной ошибки в процентах рекуррентными нейросетями в сравнении с персептронами.

Исследование [12] демонстрирует эффективность системы прогнозирования выработки массивом солнечных панелей на основе LSTM с механизмом внимания.

Анализ интеллектуальных систем прогнозирования вырабатываемой электроэнергии массивом солнечных панелей показал, что точность прогноза системы непрямого прогнозирования выходной мощности солнечной панели намного выше, чем прямой системы прогнозирования выходной мощности солнечной панели [2–4]. Таким образом, целесообразна и актуальна разработка интеллектуальной системы непрямого прогнозирования вырабатываемой электроэнергии массивом солнечных панелей, включающей интеллектуальные подсистемы прогнозирования инсоляции и температуры, на основе модифицированной нечеткой нейросети (МНН) в условиях неопределенности. В данном исследовании разработана система непрямого почасового прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей в условиях неопределенности с использованием МНН. В сравнении с существующими нечеткими нейросетями, например адаптивной сетью на основе системы нечеткого вывода (ANFIS) [3], МНН отличается следующими особенностями: многомерные функции принадлежности аппроксимируются на основе архивных данных рекуррентной нейросетью с механизмом внимания; выход модифицированной нейросети (прогнозируемое значение вырабатываемой электроэнергии массивом солнечных панелей) генерируется алгоритмом нечетко-возможностной свертки [21] на основе выходов глубоких нейросетей с механизмом внимания.

В данном исследовании нейросетевые слои МНН составляют рекуррентные нейросети с механизмом внимания, обеспечивающие, в сравнении со стандартными нейросетями, возможность интеграции информации временных рядов, генерирующие робастные выходные сигналы при возмущениях и недостатке архивных данных [3, 5].

В настоящем научном исследовании разработана система непрямого почасового прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей на основе МНН в условиях неопределенности. Жизненный цикл указанной системы обеспечивают модифицированные автоматизированные методы МНН:

- модифицированный метод создания МНН, снижающий размерность пространства поиска и вычислительные затраты и упрощающий глобальную оптимизацию;
- модифицированный метод функционирования МНН, автоматически идентифицирующий состояние облачности часа и генерирующий алгоритмом нечетко-возможностной свертки прогнозируемое значение вырабатываемой электроэнергии массивом солнечных панелей на основе выходов глубоких нейросетей с механизмом внимания.

МНН эффективно выделяет на основе данных существенные функциональные аспекты прогнозирования вырабатываемой электроэнергии массивом солнечных панелей, включая аспекты идентификации облачности часа, обеспечивая средствами рекуррентных нейронов и механизма внимания эффективное формирование и передачу скрытого представления информации как сигнала выходного слоя скрытых рекуррентных нейронов глубоких нейросетей, на основе выходов которых алгоритмом нечетко-возможностной свертки генерируется прогно-

зируемое значение вырабатываемой электроэнергии массивом солнечных панелей. Результаты экспериментального моделирования интеллектуальной системы непрямого прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей на основе МНН демонстрируют ее робастность и снижение среднеквадратичной ошибки ее прогноза в среднем в три и шесть раз в сравнении с рекуррентными нейросетями и стандартной авторегрессией скользящего среднего (ARMA) при воздействии разных внешних и внутренних факторов неопределенности.

1. Система непрямого прогнозирования электроэнергии, вырабатываемой массивом солнечных панелей на основе модифицированной нечеткой нейросети

Система непрямого почасового прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед реализована на основе модифицированной нечеткой нейросети, настроенной модифицированным методом создания на основе собранного на территории Абакана трехлетнего архива данных фактической вырабатываемой электроэнергии массивом солнечных панелей I_h^t и вектора

$$X_h^t = (C_h^{t-2-m}, I_r^{t-2-m}, I_h^{t-m}, T_h^{t-m}, P_h^{t-m}, W_h^{t-m}, d_h^{t-m}), \quad (1)$$

где C_h^{t-2-m} – индекс ясного неба; I_r^{t-2-m} – нормированная инсоляция; I_h^{t-m} – облачность (%); P_h^{t-m} – атмосферное давление; W_h^{t-m} , d_h^{t-m} – скорость и направление ветра соответственно; T_h^{t-m} – температура воздуха; m – размер окна прогнозирования, $m = \overline{0..14, 361..369}$, $h \in \{1, \dots, 19\}$, $t \in \{370, \dots, 1095\}$.

Размерность частицы X была закодирована как $d = (h_1^0, h_2^0, h_1^1, h_2^1, h_1^2, h_2^2) \in \{d_{min} = (1, 1, 1, 1, 1, 1), d_{max} = (7, 7, 7, 3, 3, 3)\}$, где h_j^s – количество нейронов в скрытом слое нейросети, составляющей МНН. Количество всех $d = 9261$.

Фитнес-функция вычисляется как среднеквадратичная ошибка (RMSE) следующим образом:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (I_i^f - I_i^m)^2}, \quad (2)$$

где N – число оцениваемых примеров; I_i^f – прогнозируемое значение вырабатываемой электроэнергии массивом солнечных панелей; I_i^m – фактическое значение вырабатываемой электроэнергии массивом солнечных панелей.

Модифицированный метод создания МНН (в данном исследовании критерии останова: $\{T = 1000\}$; $S = 100$; T – максимальное число итераций; S – количество частиц роя) состоит из семи шагов:

Шаг 1. For $\forall a \in 1, S$, do иницируем равномерно распределенные векторы $xd_a(1), vd_a(1)$.

Генерируем $\widetilde{xd}_a(0)$ по правилу Видроу [22], используя данные (1).

For $\forall d \in [D_{min}, D_{max}]$ do генерируем векторы $xx_a^d(1), xv_a^d(1)$ методом Нгуена-Видроу [22], используя данные (1), где X^t – входной вектор МНН; I^t – целевой выходной вектор для МНН.

Инициализируем $xu_a^d(0) = xx_a^d(1), \overline{xy}_a^d(0) = xv_a^d(1)$.

End For.

End For.

Шаг 2. For $\forall i \in \{1, \text{IterNo}\}$ Do:

For $\forall a \in \{1, S\}$ Do:

If $\left(f\left(\text{xx}_a^{\text{xd}_a(i)} \right) \right) < f\left(\text{xy}_a^{\text{xd}_a(i)}(i-1) \right)$ then do $\text{xy}_a^{\text{xd}_a(i)}(i) = \text{xx}_a^{\text{xd}_a(i)}(i)$,

If then $f\left(\text{xx}_a^{\text{xd}_a(i)}(i) \right) > f\left(\text{xy}_a^{\text{xd}_a(i-1)}(i-1) \right)$ then $\text{xd}_a(i) = \text{xd}_a(i-1)$ Else $\text{xd}_a(i) = \text{xd}_a(i)$ end

If

Else $\text{xy}_a^{\text{xd}_a(i)}(i) = \text{xy}_a^{\text{xd}_a(i)}(i-1)$ end If.

If $\left(f\left(\text{xx}_a^{\text{xd}_a(i)} \right) \right) < \min \left(f\left(\text{xy}_a^{\text{xd}_a(i)}(i-1) \right), \min_{1 \leq p < a} \left(f\left(\text{xx}_p^{\text{xd}_a(i)} \right) \right) \right)$ then do

$\text{gbest}(\text{xd}_a(i)) = a$, на i -той итерации частица с индексом $\text{gbest}(\text{xd}_a(i)) = a$ является глобально

лучшим решением, If $\left(f\left(\text{xx}_a^{\text{xd}_a(i)} \right) \right) < f\left(\text{xy}^{\text{dbest}}(i-1) \right)$ then $\text{dbest} = \text{xd}_a(i)$ end If.

For $\forall j \in [1, d]$, где $d \in [D_{\min}, D_{\max}] - \{\text{xd}_a(i)\}$

For $\forall a \in \{1, S\}$ Do $\text{xy}_{a,j}^d(i) = \text{xy}_{a,j}^d(i-1)$, $\text{xy}_j^d(i) = \text{xy}_j^d(i-1)$ End For. End For.

End For.

$\mu = \text{vd}_a(i)$.

Шаг 3. Вычисляем $E = f\left(\text{xx}_{\text{gbest}(\text{xd}_a(i))}^{\text{xd}_a(i)} \right)$ согласно выражению (4).

Шаг 4. While ($I < \text{IterNo}$) OR ($E > \varepsilon_c$).

Вычисляем приращения весов ΔW_1 , решая уравнение $\Delta W_1 = [J_1^T]_1 + \mu * X]^{-1} J_1^T E$, где J_1 – матрица Якоби.

Шаг 5. Обновляя веса $W_1 = W_1 + \Delta W_1$, уточняем положение частицы $\text{xx}_{\text{gbest}(\text{xd}_a(i))}^{\text{xd}_a(i)}$. Вы-

числяем соответствующую фитнес-функцию $E' = f(\text{xx}'^{\wedge}\{\text{xd}_a(i)\}_{\text{gbest}(\text{xd}_a(i))})$ согласно выражению (4).

Шаг 6. If $E' < E$ then $W_1 = W_1 + \Delta W_1$; $\mu = \mu\beta$; $E' = E$; Go to шаг 3 else $\mu = \mu/\beta$, go to шаг 5 end If.

Шаг 7. For $\forall a \in 1, S$ Do:

For $\forall j \in \{1, \text{xd}_a(i)\}$ Do: Вычисляем

$$\begin{aligned} \text{vx}_{a,j}^{\text{xd}_a(i)}(i+1) = & w(i)\text{vx}_{a,j}^{\text{xd}_a(i)}(i) + c_1 r_{1,j}(i) \left(\text{xy}_{a,j}^{\text{xd}_a(i)}(i) - \text{xx}_{a,j}^{\text{xd}_a(i)}(i) \right) + \\ & + c_2 r_{2,j}(i) \left(\text{xy}_j^{\text{xd}_a(i)}(i) - \text{xx}_{a,j}^{\text{xd}_a(i)}(i) \right), \end{aligned}$$

где $r_{1,j}(i) = U(0,1)$, $r_{2,j}(i) = U(0,1)$, $c_1 = 1.49$, $c_2 = 2$.

If $\text{vx}_{a,j}^{\text{xd}_a(i)}(i+1) \in [V_{\min}, V_{\max}]$ then $\text{xx}_{a,j}^{\text{xd}_a(i)}(i+1) = \text{xx}_{a,j}^{\text{xd}_a(i)}(i) + \text{vx}_{a,j}^{\text{xd}_a(i)}(i+1)$ else

$\text{xx}_{a,j}^{\text{xd}_a(i)}(i+1) = \text{xx}_{a,j}^{\text{xd}_a(i)}(i) + U(V_{\min}, V_{\max})$ end If.

If $xx_{a,j}^{xd_a(i)}(i+1) \in [X_{min}, X_{max}]$ then $xx_{a,j}^{xd_a(i)}(i+1) = xx_{a,j}^{xd_a(i)}(i+1)$ else

$xx_{a,j}^{xd_a(i)}(i+1) = U(X_{min}, X_{max})$ end If.

End For.

$$vd_a(i+1) = vd_a(i) + c_1 r_1(i) (\widetilde{xd}_a(i) - xd_a(i)) + c_2 r_2(i) (dbest - xd_a(i)).$$

If $vd_a(i+1) < v_{min}$ then $z = v_{min}$ end If. If $vd_a(i+1) > v_{max}$ then $z = v_{max}$ end If.

If $v_{min} \leq vd_a(i+1) \leq v_{max}$ then $xd_a(i+1) = xd_a(i) + vd_a(i+1)$ else $xd_a(i+1) = xd_a(i) + z$ end If. $[v_{min}, v_{max}]$ – диапазон скорости для размерности.

If $(xd_a(i+1) < D_{min})$ or $(xd_a(i+1) > D_{max})$ or $(P_{xd_a(i)}(i) \geq \max(15, xd_a(i+1)))$ then $xd_a(i+1) = xd_a(i)$ Else $xd_a(i+1) = xd_a(i+1)$ end If. End For. End For.

Модифицированный метод создания МНН автоматически генерирует размерность (оптимальное закодированное измерение – *dbest*, т.е. оптимальную архитектуру МНН: количество скрытых нейронов) и значение – *gbest* (оптимальные значения весовых коэффициентов МНН) позиционного оптимума, используя разработанную кодировку размерности пространства частиц.

Эффективность моделей почасового прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед на основе МНН, стандартной модели ARMA и рекуррентной нейросети оценена на основе среднеквадратичной ошибки (4), средней абсолютной ошибки (MABE) и ошибки смещения (BIAS).

Средняя абсолютная ошибка вычисляется следующим образом:

$$MABE = \frac{1}{N} \sum_{i=1}^N |I_i^f - I_i^m|. \tag{3}$$

Ошибка смещения вычисляется как

$$BIAS = \frac{1}{N} \sum_{i=1}^N (I_i^f - I_i^m). \tag{4}$$

Формирование системы непрямого почасового прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед на основе МНН включает три шага, кратко описываемых следующим образом:

Шаг 1. Формируется подсистема прогнозирования инсоляции на основе рекуррентной нейросети с механизмом внимания, имеющей входной X_h^t (1) и целевой сигнал $I r_h^t$ соответственно. В архитектуру Y^0 после ее скрытого слоя рекуррентных нейронов добавляется слой механизма внимания, составляющий первый и второй слои МНН.

Неинтерпретированный выходной сигнал рекуррентной нейросети с механизмом внимания – $n = NN(h_1^0, h_2^0, X_h^t)$, где h_1^0 и h_2^0 – количество нейронов в слое скрытом рекуррентном и механизма внимания, соответственно, определяет нечеткие множества A_j (A_1 – солнечный час, A_2 – облачный час) с соответствующими функциями принадлежности μ_j ($j = \overline{1..2}$) следующим образом:

$$\text{If } n > 0 \text{ then } \mu_1(X_h^t) = n, \mu_2(X_h^t) = 1 - \mu_1(X_h^t) \text{ else } \mu_2(X_h^t) = abs(n), \mu_1(X_h^t) = 1 - \mu_2(X_h^t).$$

Шаг 2. Метод создания МНН формирует оптимальную МНН, включая третий нейросетевой слой МНН как j -тую субкультуру рекуррентных нейросетей Y_i^j , генерирующих выходной сигнал $y_i^j = Y(h_i^j, I_h^{t-2-m})$, $i \in \{1, 2\}$.

Слой механизма внимания состоит из h_2^0 нейронов однослойной нейросетью, матрица весов внимания которой – вектор L – вычисляется следующим образом: вектор скрытых состояний $H_e^0 (e = \overline{1..h_1^0})$, пополненный последним элементом $Y(h_i^j, I_h^{t-3-m})$ (где $Y(h_i^j, I_h^{t-3-m})$ – предыдущее значение выходного нейрона рекуррентной нейросети третьего нейросетевого слоя МНН) умножается на матрицу синаптических коэффициентов однослойной нейросети, реализующей функцию внимания. К полученному вектору L применяется активационная функция Softmax, получается V – вектор весов внимания. Вектор-контекст c вычисляется как произведение векторов H и V . Далее рекуррентные нейросети Y_i^j функционируют как обычно, с учетом значений $Y(h_i^j, I_h^{t-3-m})$, $NN(h_1^0, h_2^0, X_h^t)$ и вектора-контекста c .

Шаг 3. Составляются нейро-нечеткие продукционные правила, обеспечивающие нейро-нечеткую базу знаний МНН

$$P_j: \text{ЕСЛИ } X_h^t \text{ есть } A_j, \text{ ТО } u \text{ есть } Fes(y_i^j). \quad (5)$$

В данном исследовании модифицированный метод создания МНН автоматически сгенерировал – *gbest* – оптимальную архитектуру МНН, включающую:

рекуррентную нейросеть с механизмом внимания Y^0 с двумя рекуррентными нейронами в скрытом слое ($h_1^0 = 2$, временная задержка равна 2) и с тремя нейронами в слое механизма внимания ($h_2^0 = 3$);

2 рекуррентные нейросети Y_i^1 первой субкультуры, соответствующей облачному часу, с четырьмя и пятью рекуррентными нейронами в скрытом слое соответственно ($h_1^1 = 4$, $h_2^1 = 5$, временная задержка равна 2);

2 рекуррентные нейросети Y_i^2 первой субкультуры, соответствующей солнечному часу, с двумя и тремя рекуррентными нейронами в скрытом слое соответственно ($h_1^2 = 2$, $h_2^2 = 3$, временная задержка равна 1).

Функционирование системы непрямого почасового прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед на основе МНН включает два шага, кратко описываемых следующим образом:

Шаг 1. Агрегация условной части правил (5) активирует k -е рабочее правило, формирующее устойчивое k -е состояние облачности часа.

Шаг 2. МНН формирует сигнал выход МНН – u , соответствующий k -му состоянию облачности часа, выход МНН вычисляется как нечетко-возможностная свертка на основе выходных сигналов рекуррентных нейросетей Y_i^j .

Реализация системы непрямого прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед на основе МНН кратко описывается схемой на рис. 1, который отражает этапы синтеза и функционирования МНН.

В ходе данного исследования модифицированы, верифицированы и экспериментально апробированы моделированием на основе модифицированного авторского ПО [23] автоматизированные методы обеспечения жизненного цикла системы непрямого прогнозирования вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед на основе МНН:

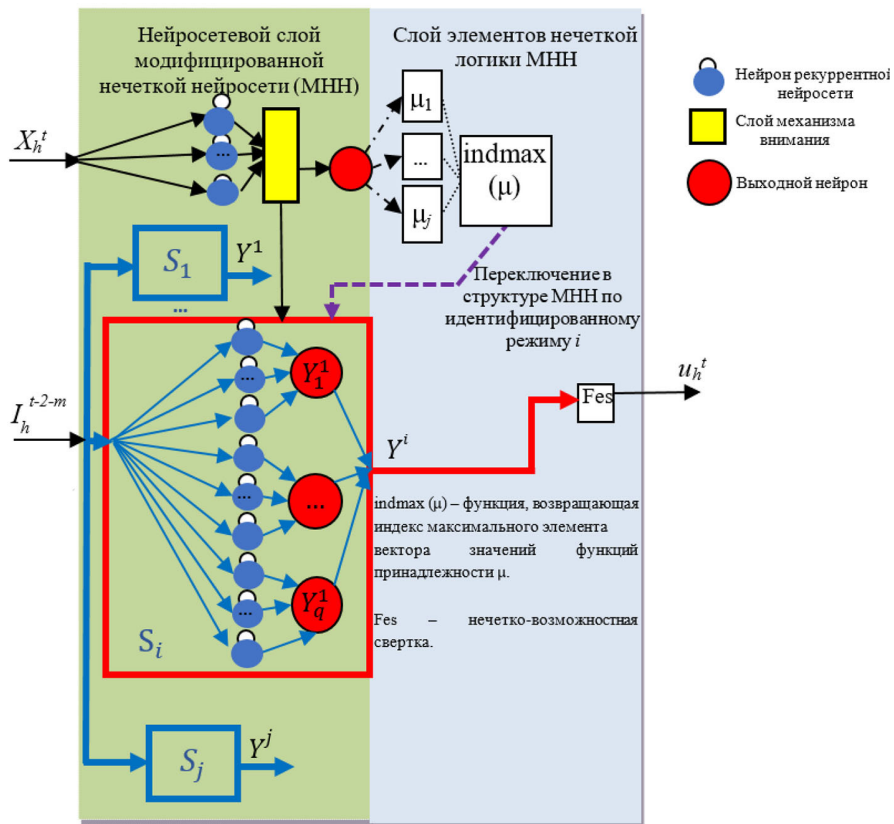


Рис. 1. Схема системы непрямого прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей на основе МНН

Fig. 1. The scheme of the indirect day ahead forecasting system of the power from a solar panel array based on the modified fuzzy neural network

- модифицированный (разработана новая кодировка архитектуры МНН, снижающая размерность пространства поиска и вычислительные затраты, упрощающая оптимизацию) метод создания МНН, инициализирующий положения частиц роя (синаптические карты нейросетевых слоев МНН) методом Нгуена-Видроу, включающий в себя этапы глобальной (реализуемые модифицированным многомерным методом роя частиц) и локальной оптимизации (реализуемой алгоритмом Левенберга-Марквардта); экспериментальное сравнение названного метода с традиционными методами настройки интеллектуальных систем (градиентным (алгоритмом Левенберга-Марквардта) и роевыми методами) выявило следующие его преимущества: автоматический режим генерации оптимальной архитектуры МНН (градиентные методы не обеспечивают глобальный экстремум фитнес-функции) с меньшими, в сравнении с роевыми методами настройки интеллектуальных моделей, вычислительными затратами;
- модифицированный метод функционирования МНН, автоматически идентифицирующий состояние облачности часа и генерирующий выход МНН (прогнозируемое значение вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед) на основе выходов глубоких нейросетей с механизмом внимания Y_i^j алгоритмом нечетко-возможностной свертки.

2. Анализ эффективности системы непрямого прогнозирования электроэнергии, вырабатываемой массивом солнечных панелей на основе МНН

МНН и рекуррентная нейросеть настроены на основе архивных данных (1) территории города Абакана. Используя модифицированное авторское ПО [23], сформирована МНН и обучена рекуррентная нейросеть (количество скрытых нейронов и задержек равно 5 и 2 соответственно) на основе данных (1). Сравнительный анализ эффективности МНН, ARMA и рекуррентной нейросети при почасовом прогнозировании вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед для последних двух месяцев трехлетнего архива (неиспользуемых для синтеза МНН и рекуррентной нейросети), отраженный на рис. 2 и в табл. 2, выявил преимущество МНН, реализующей систему непрямого прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей. Табл. 2 отражает, что генерируемые МНН и РНС прогнозируемые значения близки к фактической вырабатываемой электроэнергии массивом солнечных панелей в сравнении с классической моделью ARMA. Рис. 2 отражает графики фактической и прогнозируемой РНС и МНН почасовой вырабатываемой электроэнергии массивом солнечных панелей.

Рис. 2 отражает, что МНН, в сравнении с рекуррентной нейросетью, обеспечивает более точный почасовой прогноз вырабатываемой электроэнергии массивом солнечных панелей на сутки вперед на территории Абакана.

Табл. 2 отражает, что для построенных интеллектуальных моделей прогноза вырабатываемой электроэнергии массивом солнечных панелей ошибки (BIAS, RMSE, MABE) в солнечные часы меньше в сравнении с облачными часами. Также рис. 2 отражает, что, в сравнении с солнечными, в облачные часы точность прогноза вырабатываемой электроэнергии массивом солнечных панелей МНН и рекуррентной нейросети снижается. Тем не менее МНН эффек-

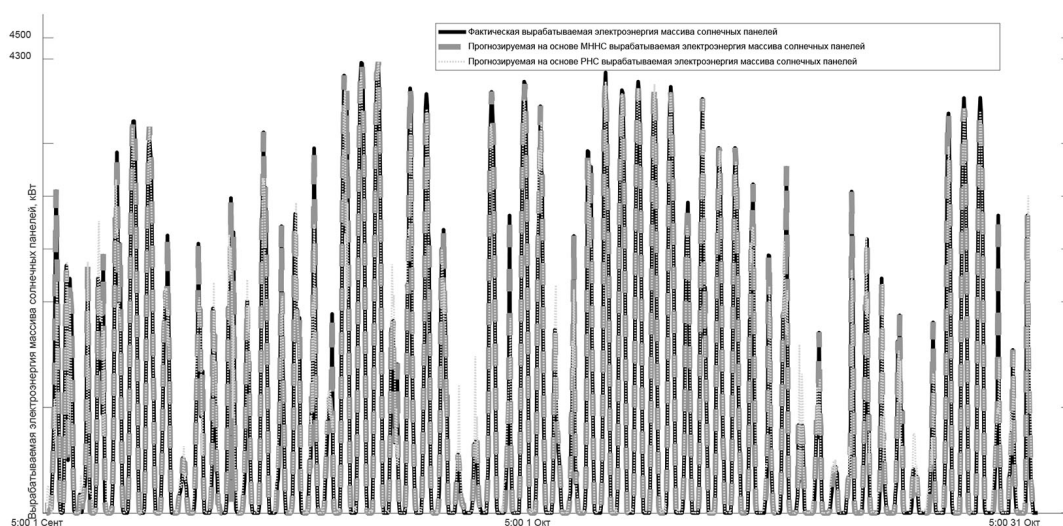


Рис. 2. Графики фактической и прогнозируемой на основе РНС и МНН электроэнергии, вырабатываемой массивом солнечных панелей

Fig. 2. Plots of actual and forecasted electric power generated from the solar panels array based on RNN and modified fuzzy neural network

Таблица 2. Результаты МНН и рекуррентной нейросети при почасовом прогнозировании на сутки вперед вырабатываемой электроэнергии массива солнечных панелей

Table 2. The results of modified fuzzy neural network and recurrent neural network for hourly forecasting of the electric power generated from the solar panels array

Модель	Рекуррентная нейросеть		МНН		ARMA	
	Солнечные часы	Облачные	Солнечные часы	Облачные	Солнечные часы	Облачные
MABE (W/m ²)	8,47	21,41	0,81	2,43	17,81	41,75
RMSE (W/m ²)	31,45	75,34	12,25	23,34	61,41	145,23
BIAS(W/m ²)	-2,08	4,16	0,15	0,31	3,24	7,13

тивно отражает сложную динамику колебаний фактической вырабатываемой электроэнергии массивом солнечных панелей в облачные часы.

Табл. 2 указывает, что эффективность МНН, генерирующей прогнозируемое на сутки вперед значение вырабатываемой электроэнергии массивом солнечных панелей как нечетко-возможностную свертку выходов глубоких нейросетей с механизмом внимания Y_i^j , выше, чем эффективность отдельной рекуррентной нейросети, особенно в облачные часы. Табл. 2 отражает абсолютную неэффективность рекуррентной нейросети в облачные часы. Рис. 2 и табл. 2 подтверждают экспериментально, что простая/сложная динамика вырабатываемой электроэнергии массивом солнечных панелей в солнечные часы обеспечивает простоту/сложность системной зависимости фактической вырабатываемой электроэнергии массивом солнечных панелей от переменных (1) и, следовательно, эффективность/неэффективность аппроксимации указанной функции рекуррентной нейросетью.

Таким образом, эффективность МНН (как нечеткой системы, формируемой рекуррентными нейросетями с механизмом внимания) при почасовом прогнозировании на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей выше, чем эффективность отдельной рекуррентной нейросети в облачные часы, особенно в условиях быстрых колебаний инсоляции. МНН эффективно транслирует функциональные аспекты прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей средствами рекуррентных нейронов и механизма внимания, обеспечивая эффективное формирование на основе данных (1) и трансляцию скрытого представления информации идентифицированных аспектов облачности часа, включая динамику флуктуаций вырабатываемой электроэнергии массивом солнечных панелей. Механизм внимания обеспечивает выделение существенных аспектов состояния облачности часа и передачу этой информации как сигнала выходного слоя скрытых рекуррентных нейронов j -той субкультуры нейросетей Y_i^j .

Анализ ошибок между фактическими и прогнозируемыми на сутки вперед значениями вырабатываемой электроэнергии массивом солнечных панелей приводит к заключению о целесообразности использования МНН для прогнозирования солнечной вырабатываемой электроэнергии массивом солнечных панелей.

Таким образом, результаты экспериментального моделирования системы непрямого прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей

на основе МНН демонстрируют ее робастность и снижение среднеквадратичной ошибки ее прогноза в среднем в три и шесть раз в сравнении с рекуррентными нейросетями и стандартной моделью ARMA при воздействии различных внутренних и внешних факторов неопределенности.

Заключение

В данном научном исследовании разработана система непрямого прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей на основе МНН, жизненный цикл которой обеспечивают модифицированные, верифицированные и экспериментально апробированные моделированием, используя модифицированное авторское ПО, следующие автоматизированные методы:

- модифицированный метод создания МНН, снижающий размерность пространства поиска и вычислительные затраты, упрощающий оптимизацию; экспериментальное сравнение названного метода с традиционными методами настройки интеллектуальных систем (градиентным (алгоритмом Левенберга-Марквардта) и роевыми методами) выявило следующие его преимущества: автоматический режим генерации оптимальной архитектуры МНН с меньшими, в сравнении с роевыми методами настройки интеллектуальных моделей, вычислительными затратами;

- модифицированный метод функционирования МНН, автоматически идентифицирующий состояние облачности часа и генерирующий прогнозируемое значение вырабатываемой электроэнергии массивом солнечных панелей на основе выходов глубоких нейросетей с механизмом внимания алгоритмом нечетко-возможностной свертки.

МНН эффективно выделяет и транслирует существенные функциональные аспекты прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей средствами рекуррентных нейронов и механизма внимания, обеспечивая эффективное формирование на основе данных и трансляцию скрытого представления информации идентифицированных аспектов облачности часа, включая динамику флуктуаций вырабатываемой электроэнергии массивом солнечных панелей. Механизм внимания обеспечивает выделение существенных аспектов состояния облачности часа и передачу этой информации как сигнала выходного слоя скрытых рекуррентных нейронов глубоких нейросетей, на основе выходов которых алгоритмом нечетко-возможностной свертки генерируется прогнозируемое на сутки вперед значение вырабатываемой электроэнергии массивом солнечных панелей.

Результаты экспериментального моделирования системы непрямого прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей на основе МНН демонстрируют ее робастность и снижение среднеквадратичной ошибки ее прогноза в среднем в три и шесть раз в сравнении с рекуррентными нейросетями и стандартной моделью ARMA при воздействии различных внутренних и внешних факторов неопределенности. Таким образом, МНН обеспечивает структурно-параметрический синтез и эффективность интеллектуальной системы непрямого прогнозирования на сутки вперед вырабатываемой электроэнергии массивом солнечных панелей, развивая основы интеллектуальных систем прогнозирования.

Список литературы / References

- [1] *Большие вызовы и приоритеты научно-технологического развития* [Электронный ресурс] – Режим доступа: [https://xn – mlagf.xn – plai/challenges-priorities/](https://xn--mlagf.xn--plai/challenges-priorities/) – Заглавие с экрана [Great challenges and priorities of scientific and technological development [Electronic resource] – Access: [https://xn – mlagf.xn – plai/challenges-priorities/](https://xn--mlagf.xn--plai/challenges-priorities/)
- [2] Wu Y.K. Completed Review of Various Solar Power Forecasting Techniques Considering Different Viewpoints. *Energies*, 2022, 15, 332.
- [3] Das U.K. Forecasting of photovoltaic power generation and model optimization: A review. *Renew. Sustain. Energy Rev*, 2018, 81, 912–928.
- [4] Liu L. Forecasting Power Output of Photovoltaic System Using A BP Network. *Energy Procedia*, 2017, 142, 80–786.
- [5] Vishnu S. Forecasting Solar PV Output Using Convolutional Neural Networks with a Sliding Window Algorithm. *Energies*, 2020, 13, 723.
- [6] Omar M. Day-ahead forecasting for photovoltaic power using artificial neural networks ensembles. In *Proceedings of the 2016 IEEE International Conference on Renewable Energy Research and Applications*, Piscatavai: Institute of Electrical and Electronics Engineers (IEEE), 2016, 1152–1157.
- [7] Pombo D.V. Increasing the Accuracy of Hourly Multi-Output Solar Power Forecast with Physics-Informed Machine Learning. *Sensors*, 2022, 22, 749.
- [8] Ahn H.K., Park N. Deep RNN-Based Photovoltaic Power Short-Term Forecast Using Power IoT Sensors. *Energies*, 2021, 14, 436.
- [9] Wang Y. Adaptive Solar Power Forecasting based on Machine Learning Methods. *Appl. Sci*, 2018, 8, 2224.
- [10] Durrani S.P. Photovoltaic yield prediction using an irradiance forecast model based on multiple neural networks. *J. Mod. Power Syst. Clean Energy*, 2018, 6, 255–267.
- [11] Wang Y. Short-term load forecasting with multi-source data using gated recurrent unit neural networks, *Energies*, 2018, 11, 1138.
- [12] Pan C. Very Short-Term Solar Generation Forecasting Based on LSTM with Temporal Attention Mechanism. *IEEE 5th International Conference on Computer and Communications (ICCC)*, 2019, 267–271.
- [13] Akhter M.N. An Hour-Ahead PV Power Forecasting Method Based on an RNN-LSTM Model for Three Different PV Plants. *Energies*, 2022, 15, 33.
- [14] Xing Luo, Dongxiao Zhang, Xu Zhu. Combining transfer learning and constrained long short-term memory for power generation forecasting of newly-constructed photovoltaic plants. *Renewable Energy*, 2022, 185, 1062–1077.
- [15] Zjavka L. PV power intra-day predictions using PDE models of polynomial networks based on operational calculus. *IET Renew. Power Gener*, 2020, 14, 1405–1412.
- [16] Zhen Z. Deep learning based surface irradiance mapping model for solar PV power forecasting using sky image. *IEEE Trans. Ind. Appl.*, 2020, 56, 3385–3396.
- [17] Abdel-Nasser M., Mahmoud K. Accurate photovoltaic power forecasting models using deep LSTM-RNN. *Neural Comput. Appl.*, 2019, 31, 2727–2740.
- [18] Zhang J. Deep photovoltaic nowcasting. *Sol. Energy*, 2018, 176, 267–276.

[19] Akhter M.N. Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques. *IET Renew. Power Gener.*, 2019, 13, 1009–1023.

[20] Zjavka L., Snášel V. PV Energy Prediction in 24 h Horizon Using Modular Models Based on Polynomial Conversion of the L-Transform PDE Derivatives in Node-by-Node-Evolved Binary-Tree Networks. *Eng. Proc.*, 2022, 18, 34.

[21] Engel E., Engel N. A Review on Machine Learning Applications for Solar Plants. *Sensors*, 2022, 22, 9060.

[22] Derrick Nguyen, Bernard Widrow Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. *Proceedings of the International Joint Conference on Neural Networks*, 1990, 3, 21–26.

[23] *Модуль модифицированной нечеткой нейронной сети*. М.: РОСПАТЕНТ, 2021. Свидетельство о регистрации программы для ЭВМ 2021681065 [*Module of modified fuzzy neural network*. М.: ROSPATENT, 2021. Certificate of software registration 2021681065].