

ПРОГНОЗИРОВАНИЕ ВЫХОДНОЙ МОЩНОСТИ ФОТОЭЛЕКТРИЧЕСКОЙ СИСТЕМЫ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

Н.Б. Құттыбай*, Ш.Б. Айтбекова, Н.Ж. Қошқарбай, А.Б. Болатбек, Б.Н. Жоламанов

Казахский Национальный Университет имени аль-Фараби, Алматы, Казахстан,

e-mail: nurjigit.10.93@gmail.com

В данном исследовании был сосредоточен акцент на повышении эффективности прогнозирования мощности фотоэлектрических систем. Этот аспект играет важную роль в управлении и мониторинге таких систем, особенно в современном контексте увеличения доли возобновляемых источников энергии. Для достижения этой цели были применены два широко используемых метода машинного обучения: LSTM (Long Short-Term Memory) и XGBoost (Extreme Gradient Boosting), которые были тщательно настроены путем оптимизации их гиперпараметров. LSTM представляет собой разновидность рекуррентной нейронной сети, специально созданной для анализа последовательных данных, в то время как XGBoost использует ансамбль деревьев решений и метод градиентного бустинга. Осуществление настройки гиперпараметров для каждой из нейронных сетей было ключевым этапом в достижении поставленной цели. Была проведена оценка эффективности прогнозирования с использованием различных метрик, таких как средняя абсолютная ошибка (MAE), коэффициент детерминации (R^2) и квадратный корень из среднеквадратической ошибки (RMSE), на основе данных, собранных за один день. Полученные результаты подтвердили высокую точность обеих моделей, причем XGBoost продемонстрировал впечатляющие показатели R^2 в 0,99 для прогнозирования мощности и R^2 в 0,97 для прогнозирования излучения. Однако LSTM также показала хорошие результаты, что свидетельствует о ее перспективности в данной области и подтверждает ее эффективность. Полученные данные подчеркивают значимость выбранных методов в предсказании мощности фотоэлектрических систем. Разработанная система прогнозирования обеспечивает высокую стабильность и достоверность прогнозов, что является критически важным для эффективного управления и оптимизации работы таких систем в условиях переменных погодных и операционных сценариев.

Ключевые слова: прогнозирование, машинное обучение, солнечная энергетика, архитектура нейронной сети, коэффициент детерминации, среднеквадратическая ошибка.

FORECASTING THE OUTPUT POWER OF A PHOTOVOLTAIC SYSTEM BASED ON NEURAL NETWORKS

N. Kuttybay*, Sh. Aitbekova, N. Koshkarbay, A. Bolatbek, B. Zholamanov

Al-Farabi Kazakh National University, Almaty, Kazakhstan

e-mail: nurjigit.10.93@gmail.com

This study focused on improving the power forecasting performance of PV systems. This aspect plays an important role in the management and monitoring of such systems, especially in the modern context of increasing the share of renewable energy sources. To achieve this goal, two widely used machine learning methods were applied: LSTM (Long Short-Term Memory) and XGBoost (Extreme Gradient Boosting), which were carefully tuned by optimizing their hyperparameters. LSTM is a type of recurrent neural network specifically designed for analyzing sequential data, while XGBoost uses an ensemble of decision trees and a gradient boosting technique. Tuning the hyperparameters for each of the neural networks was a key step in achieving the goal. The forecasting performance was assessed using various metrics such as mean absolute error (MAE), coefficient of determination (R^2) and square root of root mean square error (RMSE) based on data collected in one day. The results confirmed the high accuracy of both models, with XGBoost achieving an impressive R^2 of 0.99 for power prediction and an R^2 of 0.97 for radiation prediction. However, LSTM also showed good results, which shows its promise in this field and confirms its effectiveness. The findings highlight the significance of the selected methods in predicting

the power of photovoltaic systems. The developed forecasting system provides high stability and reliability of forecasts, which is critical for effective management and optimization of the operation of such systems under variable weather and operational scenarios.

Keywords: forecasting, machine learning, solar energy, neural network architecture, coefficient of determination, root mean square error.

ФОТОЭЛЕКТРЛІК ЖҮЙЕНІҢ ШЫҒЫС ҚУАТЫН НЕЙРОНДЫҚ ЖЕЛІЛЕР НЕГІЗІНДЕ БОЛЖАУ

Н.Б. Құттыбай*, Ш.Б. Айтбекова, Н.Ж. Қошқарбай, А.Б. Болатбек, Б.Н. Жоламанов

әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан

e-mail: nurjigit.10.93@gmail.com

Зерттеу жұмысында фотоэлектрлік жүйелердің қуатын болжау тиімділігін арттыруға баса назар аударылды. Бұл аспект мұндай жүйелерді басқаруда және бақылауда, әсіресе жаңартылатын энергия көздерінің үлесін арттырудың қазіргі жағдайында маңызды рөл атқарады. Осы мақсатқа жету үшін машиналық оқытудың екі әдісі қолданылды: LSTM (Long Short-Term Memory) және XGBoost (Extreme Gradient Boosting), сондай-ақ, олардың гиперпараметрлері мұқият конфигурациялану арқылы оңтайландырылған. LSTM - дәйекті деректерді талдау үшін арнайы жасалған қайталанатын нейрондық желінің бір түрі, ал XGBoost шешім ағаштары ансамблі мен градиентті күшейту әдісін пайдаланады. Нейрондық желілердің әрқайсысы үшін гиперпараметрлерді дұрыс таңдау арқылы зерттеу жұмысының мақсаты орындалды. Бір күндік тәжірибелік мағлұматтар нәтижесінде орташа абсолютті қате (MAE), детерминация коэффициенті (R^2) және орташа квадраттық қатенің квадрат түбірі (RMSE) сияқты әртүрлі көрсеткіштерді қолдана отырып, болжау тиімділігіне бағалау жүргізілді. Нәтижелер екі модельдің де жоғары дәлдігін растады, XGBoost қуатты болжау үшін R^2 мәні 0,99-да және сәулеленуді болжау үшін R^2 0,97-де әсерлі көрсеткіштерді көрсетті. Дегенмен, LSTM-де жақсы нәтиже көрсетті, бұл оның осы саладағы перспективасын көрсетеді және оның тиімділігін растайды. Фотоэлектрлік жүйелердің қуатын болжауда таңдалған әдістердің маңыздылығын алынған нәтижелер айқын көрсетеді. Әзірленген болжау жүйесі болжамдардың жоғары тұрақтылығы мен сенімділігін қамтамасыз ете отырып, өзгермелі ауа-райы мен жүйенің әртүрлі сценарийлері жағдайында фотоэлектрлік жүйелердің жұмысын тиімді басқару және оңтайландыру үшін өте маңызды.

Түйін сөздер: болжау, машиналық оқыту, күн энергетикасы, нейрондық желі архитектурасы, детерминация коэффициенті, күн панелінің шығыс қуаты, орташа квадраттық қателік.

Введение. В условиях прогнозируемого увеличения потребления электроэнергии, ограниченности ископаемых топлив и ухудшения климатических условий, вызванных выбросами парниковых газов, производство возобновляемой энергии становится неотъемлемым компонентом решения современных проблем в области энергетики. Особое внимание уделяется развитию производства солнечной фотоэлектрической (PV) энергии, представляющей собой важный шаг в переходе к устойчивой и эффективной энергетической системе [1].

Для обеспечения высокой эффективности интеграции солнечной энергии в традиционные энергосистемы необходимо решить комплекс проблем, связанных с переменностью метеорологических параметров в фотоэлектрической генерации, преимущественно обусловленной воздействием динамики облаков. Эта временная неустойчивость в процес-

се фотоэлектрической генерации оказывает существенное воздействие на баланс спроса и предложения, критически важный для обеспечения стабильности энергосистемы [2], сопровождается воздействием на функционирование рынков электроэнергии и увеличением дополнительных производственных затрат [3]. В свете этой проблематики операторы систем передачи и распределения электроэнергии выражают требование о снижении уровня неопределенности в области возобновляемых источников энергии перед последующим увеличением их доли, нацеленным на обеспечение стойкости и устойчивости энергосистемы [4].

В последние годы исследователи предложили разнообразные стратегии для снижения уровня неопределенности в области возобновляемых источников энергии. К примеру, комбинирование крупных возобновляемых генераторов с системами хранения

энергии [5], формирование ансамблей из небольших возобновляемых генераторов [6] и повышение точности прогнозирования с применением более сложных методов [7]. В контексте крупных возобновляемых генераторов предлагается внедрение масштабных систем хранения, таких как батареи, для обеспечения стабильности традиционных энергосистем в случае непредвиденных сбоев в производстве электроэнергии. Концепция виртуальной электростанции, объединяющая различные технологии возобновляемых источников энергии, основана на предположении, что при метеорологических изменениях те генераторы, которые временно не могут поставлять энергию, могут быть компенсированы работой других, повышая вероятность удовлетворения потребности в энергии [5,6].

Необходимо подчеркнуть, что хотя системы хранения энергии и виртуальные электростанции способны сглаживать уровень неопределенности в возобновляемых источниках энергии, их реакция не мгновенна. В связи с этим многие исследования поддерживают идею разработки прогнозируемых моделей, использующих различные методы, такие как анализ изображений неба или применение искусственного интеллекта, для дополнительного снижения уровня неопределенности в возобновляемых источниках энергии [8].

Разработанные методы прогнозирования, связанные с метеорологическими параметрами, подразделяются по двум критериям. Первый критерий исследует предполагаемый горизонт прогнозирования, то есть временной интервал между текущим моментом и будущим эффектом прогноза [9]. Второй критерий анализирует предлагаемую технику прогнозирования системы. Согласно критерию горизонта прогнозирования, методы классифицируются следующим образом: внутрисуточное прогнозирование; внутрисуточное прогнозирование; прогнозирование на сутки вперед [10]. Внутрисуточное прогнозирование, также известное как "прогноз текущей погоды" [11], предсказывает состояние атмосферы от нескольких секунд до часа вперед [12]. Такие прогнозы используются для обеспечения стабильности основных энергетических сетей через диспетчеризацию вспомогательных услуг [13]. Прогнозы в течение дня обычно охватывают период от одного до шести часов вперед [14], и их результаты используются для обеспечения стабильности традиционных энергосистем в областях с высоким уровнем интеграции возобновляемых источников энергии [15]. В свою очередь, прогнозы на сутки вперед предсказывают

состояние атмосферы от шести до семидесяти двух часов вперед, чаще всего с почасовым разрешением [16]. Их результаты применяются для принятия решений, таких как определение обязательств подразделения или планирование резервирования мощности. Согласно второму критерию, разработанные методы прогнозирования классифицируются как физические, статистические модели или модели машинного обучения, в зависимости от используемого метода при создании прогнозного метода. Главной проблемой традиционных методов прогнозирования является то, что они прогнозируют только значения одной точки прогнозирования, что не представляет полной информации [17].

В существующих исследованиях активно используются прогностические модели, основанные на нейронных сетях, включая такие алгоритмы, как LSTM, CNN и XGBoost. Результаты исследований, представленные в работе [18] включают оценку моделей LSTM и CNN с использованием метрик MAE, RMSE и R^2 , продемонстрировавших значительные показатели точности с соответствующими значениями 0,37, 0,986 и 0,965. Другое исследование, представленное в статье [19] включает в себя сравнительный анализ алгоритмов LSTM и XGboost. Результаты подтверждают высокую эффективность алгоритмов LSTM и XGboost, выраженную показателями RMSE, MAE и R^2 в пределах 1,7-1,8, 0,88-1,01. Дополнительно, в работе [20] проведен анализ различных моделей машинного обучения, применяемых для прогнозирования энергии солнечных фотоэлектрических систем внутрисуточного диапазона. Этот анализ включает использование метрик RMSE, учитывая различные погодные условия и сезоны. В работе [21] проведено исследование, в рамках которого использовались модели LSTM, CNN, а также их гибридные варианты для выполнения краткосрочного прогнозирования мощности солнечных фотоэлектрических систем с использованием метода вариационной модовой декомпозиции. Эти работы в совокупности обеспечивают обширный обзор методов и результатов в области прогнозирования энергии с использованием нейронных сетей, а также выделяют перспективные направления исследований в данной области.

Все эти исследования занимают актуальную позицию в контексте современных вызовов, связанных с увеличением потребления электроэнергии, ограниченностью традиционных источников энергии и изменением климата. Развитие эффективных методов прогнозирования солнечной энергии представ-

ляет собой важный шаг в сторону создания устойчивой и эффективной энергетической системы.

Цель данного исследования заключается в разработке эффективного метода прогнозирования солнечной энергии с использованием алгоритмов нейронной сети. Для достижения поставленной цели исследования, направленного на разработку эффективного метода прогнозирования солнечной энергии с применением алгоритмов нейронной сети, были определены следующие задачи:

1. Проведение анализа и обработка экспериментальных данных о солнечном облучении и мощности солнечных панелей;
2. Получение прогнозируемых данных о производстве энергии фотоэлектрической системы путем обучения нейронных сетей на основе значений суточной солнечной радиации;
3. Оценка точности прогнозов прогностической способности нейронных сетей посредством вычисления показателей RMSE, MAE и R^2 .

В результате проведенного исследования были получены и оценены прогнозируемые данные по производству энергии фотоэлектрической системы. Применение нейронной сети в данном контексте открывает новые перспективы для улучшения точности прогнозов, что имеет ключевое значение для обеспечения стабильности энергосистемы.

Материалы и методы. Ключевым элементом предлагаемой системы является прогнозирование выходных данных мощности, генерируемой солнечными панелями. Сравнение двух методов машинного (RNN, Decisiontree) обучения для прогнозирования в различных погодных условиях показывает, что применение машинного обучения является более оптимальным и универсальным в данном контексте. Прогнозирование суточной солнечной радиации в ясные дни представляет собой более простую задачу, но при резких изменениях погоды требуется использование временных рядов и сложных методов стохастического прогнозирования. Рекуррент-

ные нейронные сети (Recurrentneuralnetwork RNN) эффективны для прогнозирования данных временных рядов, но могут столкнуться с трудностью сохранения информации в течение длительного времени. Для решения этой проблемы применяются сети с длительной кратковременной памятью, использующие специальные скрытые блоки для эффективного запоминания входных данных в течение продолжительного периода. LSTM это особая разновидность архитектуры RNN.

На рисунке 1 представлена архитектура ячейки долгой краткосрочной памяти (LongShort-TermMemory LSTM). Здесь каждая стрелка представляет собой вектор. $C_{(t-1)}$ обозначает вход из ячейки памяти в момент времени t , x_t - вход в момент времени t , а h_t - выход в момент времени t , который передается как на выходной слой, так и на скрытый слой в следующий момент. Ячейка включает в себя 5 точечных операций, из которых 3 помечены как "x", одна - как "+", а последняя - как "tanh". Фильтры (фильтр забывания, фильтр памяти и выходной фильтр), обозначенные как "x", представляют точки, в которых они могут быть открытыми, закрытыми или открытыми в течение некоторого времени. Например, фильтр забывания в верхнем левом углу, фильтр памяти в центре и выходной фильтр в правой части диаграммы управляются операциями слоев σ (фиолетовые сигмовидные прямоугольники). В зависимости от решения функции активации сигмовидной функции фильтр забывания (в диапазоне от 0 до 1) фильтр может быть полностью открытым, закрытым или открытым частично. Если он открыт, память свободно перемещается из $C_{(t-1)}$ в C_t . Если он закрыт, память отключена, и возможно, будет добавлена новая память при другой точечной операции. Символ "+" представляет собой T-образное соединение, через которое проходит память. Дополнительная память может быть добавлена при этом соединении, если фильтр памяти открыт. "tanh" отвечает за преобразование значения в диапазоне от -1 до 1 по математическим причинам.




Рис.1 - Архитектура ячейки долгой краткосрочной памяти(LSTM)

Основные математические выражения, применяемые в структуре LSTM, могут быть представлены следующим образом:

$$f_t = \sigma(w_f * [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(w_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

$$g_t = \tanh(w_g * [h_{t-1}, x_t] + b_g) \quad (3)$$

$$c_t = f_t * c_{t-1} + i_t * g_t \quad (4)$$

$$o_t = \sigma(w_o * [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

В данном контексте, обозначения i_t , f_t , g_t и o_t представляют соответственно входное значение элемента управления, выходное значение элемента забывания, выходные данные обновления и значение открытого элемента управления. Параметры w и b обозначают весовые матрицы и векторы смещения соответственно.

Каждый слой в нейронной сети оборудован ограниченным числом узлов, связанных синаптическими весами, которые подвергаются коррекции в процессе обучения модели для уменьшения ошибок. Каждый слой функционально иницирован соответствующей функцией. На каждом узле вычисляется взвешенная сумма, после чего результат передается через функцию активации для получения выходных данных. Прямое распространение прогнозируемых выходных данных осуществляется для вычисления функции затрат. На последующем этапе оптимизаторы применяются для уменьшения ошибки путем коррекции весов узлов.

Воздействие на точность модели долгой краткосрочной памяти (LSTM) зависит не только от объема обучающих данных, но также от архитектуры сети, гиперпараметров и используемых оптимизаторов.

Другой метод прогнозирования может быть реализован с использованием регрессии на основе деревьев решений. Этот метод обычно оказывается менее эффективным по сравнению с рекуррентными нейронными сетями (RNN), однако применение метода градиентного бустинга позволяет улучшить качество прогнозов путем создания

ансамбля более слабых моделей. В качестве одного из таких методов можно выделить XGBoost (eXtremeGradientBoosting). XGBoost представляет собой алгоритм классификации и регрессии, основанный на градиентном бустинге деревьев решений. Этот метод иницирует определенное количество слабых учащихся, в основном представленных деревьями классификации и регрессии, для обучения уязвимых учащихся. После завершения обучения, XGBoost выполняет взвешенное суммирование результатов, создавая окончательную модель регрессии.

Процесс построения модели включает последовательное добавление новых учащихся, ориентированных на остаточные ошибки, полученные на предыдущих этапах слабого обучения. Каждый новый учащийся строится на основе градиента с целью минимизации общей ошибки модели. Этот градиентный подход обеспечивает постепенное улучшение качества модели регрессии и повышение ее прогностической способности в контексте прогнозирования солнечной энергии.

XGBoost выделяется среди других алгоритмов благодаря множеству улучшений. Он применяет разложение Тейлора второго порядка для оптимизации функции потерь, что способствует более эффективному обучению. Кроме того, XGBoost поддерживает выборочное использование столбцов данных, что помогает предотвратить переобучение и снизить объем вычислений.

Особенностью XGBoost является также его стратегия по управлению скоростью обучения после каждой итерации. Алгоритм распределяет скорость обучения среди листовых узлов, уменьшает вес каждого дерева и создает пространство для последующего улучшения. Эти меры способствуют более устойчивому и эффективному процессу обучения, делая XGBoost мощным инструментом для задач прогнозирования и классификации.

Предположим, что набор данных обучающей выборки D , а также выборка x_i и метка класса y_i в нем выражаются как:

$$D = \{(x_1, y_1), (x_2, y_2) \dots (x_n, y_n)\} \quad (7)$$

$$y_i = \sum_{k=1}^k f_k(x_i), f_k \in F \quad (8)$$

Здесь, $f_k(x_i)$ дискриминантная функция k -го дерева по отношению k_i -м данным, а F - надежная мо-

дель интеграции k моделей дерева решений.

На рисунке 2 демонстрируется, что XGBoost представляет собой усовершенствованную древовидную модель. Изначальное дерево делает предсказание, затем оценивает разницу между этим предсказанием и реальным значением, и, наконец, добавляет новое дерево для изучения этой разницы. Таким образом, модель последовательно корректирует свои предсказания, учитывая дополнительные деревья, что способствует улучшению ее точности и способности адаптироваться к сложным зависимостям

в данных.

В данном исследовании для обучения нейронных сетей используются данные о мощности солнечной панели в качестве входных параметров. Эти параметры представляют собой ключевые переменные, используемые в процессе обучения модели. Анализ взаимодействия между мощностью панели и солнечной радиацией позволяет разработать эффективные стратегии прогнозирования и управления энергетическими системами.

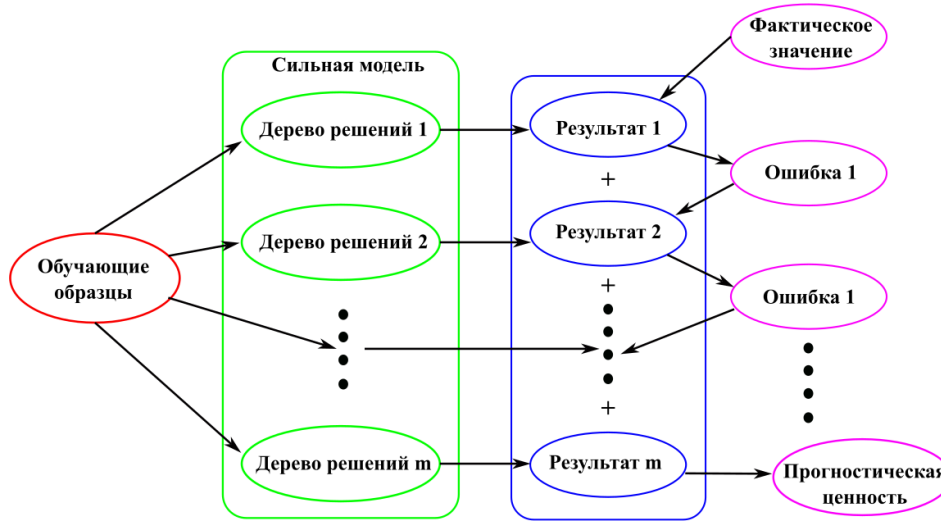


Рис. 2 - Архитектура XGBoost

Модель точечного прогнозирования XGBoost использует соответствующие факторы, влияющие на солнечное излучение, в качестве входных данных. Эти данные применяются для генерации детерминированного прогноза солнечной энергии на будущее. Параллельно с этим, ядерная оценка плотности преобразует результаты XGBoost в плотности вероятности и формирует интервалы прогнозирования с различными уровнями уверенности. Таким образом, модель комбинирует точечные прогнозы с распределением вероятностей, что позволяет предсказывать не только средние значения, но и оценивать степень неопределенности в прогнозах солнечной энергии.

При оценке детерминированного прогноза основное внимание уделяется средней абсолютной ошибке и среднеквадратической ошибке. Для оценки результатов детерминированного прогноза используются следующие метрики:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

Здесь, y_i - истинное значение, а \hat{y}_i это прогнозируемое значение. n - количество выборок.

RMSE (Root Mean Squared Error) отражает среднеквадратичное отклонение между прогнозируемыми и фактическими значениями, служа ключевым показателем точности модели. Этот параметр, выраженный в единицах целевой переменной, количественно измеряет степень отклонения прогнозов от реальных данных, подчеркивая важность минимизации этого отклонения для достижения высокой точности.

MAE(MeanAbsoluteError) представляет абсолютное среднее отклонение между прогнозами и фактическими значениями. Игнорируя направление ошибки, эта метрика предоставляет простую интерпретацию средней величины ошибок модели, что полезно для выявления особенностей ошибок без учета их знака.

Коэффициент детерминации R^2 является индикатором объясняющей силы модели, измеряя долю объясненной дисперсии зависимой переменной.

Близость значения R^2 к 1 свидетельствует о высокой предсказуемости модели, указывая на успешное объяснение изменчивости целевой переменной.

Эти показатели, играя фундаментальную роль в оценке моделей прогнозирования, обеспечивают научное обоснование их эффективности и применимости в реальных условиях. Модели были полностью разработаны на языке программирования Python с использованием библиотеки TensorFlow.



Рис. 3 - Экспериментальная установка фотоэлектрической системы

На рисунке 3 представлена экспериментальная установка, состоящая из солнечной панели и датчика радиации. Полученные данные были автоматически обработаны и переданы через беспроводную сеть к персональному компьютеру для последующего хранения и анализа.

Результаты и обсуждения. Эксперименты были реализованы на территории Казахского национального университета имени Аль-Фараби в городе Алматы с использованием стационарной фотоэлектрической установки. Основной целью исследования было измерение выходных параметров фотоэлектрической системы в различных метеорологических условиях. Фотоэлектрическая панель была установлена на металлическом каркасе под оптимальным углом в 45 градусов к горизонту. Изме-

нение проводилось в интервале каждые 10 минут с 09:00 до 18:00 в день с переменной облачностью.

Приложения, направленные на прогнозирование выходной мощности фотоэлектрических систем, особенно в контексте краткосрочного предсказания (например, за 24 часа вперед), могут быть разделены на две основные категории. Первая - это метод прогнозирования, опирающаяся на интенсивность солнечной радиации. Другой метод заключается в прямом предсказании выходной мощности фотоэлектрической системы.

На рисунке 4 изображено суточное динамическое изменение солнечной радиации. Значения солнечного излучения были измерены с использованием пиранометра RK200-03. Интенсивность солнечной радиации подвержена воздействию различ-

ных факторов, включая степень облачности, освещенность, метеорологические параметры и зенитный угол солнца.




Рис.4 - Изменение солнечной радиации в течение времени

На рисунке 5 представлена динамика изменения выходных электрических величин солнечной панели в течение временного интервала с 9:00 до 18:00. График наглядно иллюстрирует динамику мощности солнечной панели, подчеркивая максимальное значение в утренний период и минимальное значение

в вечерний период. В часы утра отмечается пиковая активность, достигая максимальной мощности в 9:30. В то время как в вечерний период, после 17:40, отмечается минимальное значение мощности панели.




Рис. 5 - Динамика изменений напряжения (а), тока (б) и мощности (в) солнечной панели во времени

В рамках данного исследования основным методом прогнозирования солнечной энергии является применение нейронной сети, где входным параметром выступает значение излучения. Процесс обучения идентифицируется передачей данных об излу-

чении для обучения нейронной сети с целью формирования выходного значения в виде мощности. Основной целью исследования является сравнение эффективности двух алгоритмов - LSTM и XGBoost - в контексте прогнозирования солнечной энергии. Это

сравнение основано на оценке показателей RMSE (RootMeanSquareError), MAE (MeanAbsoluteError) и R^2 (коэффициент детерминации), которые служат критериями для определения качества моделей с учетом их прогностической способности.

Значения RMSE и MAE преследуют цель минимизации, что обеспечивает более точное предсказание целевых переменных. В случае R^2 , близкое к единице значение указывает на успешную интерпретацию моделью вариаций в предоставленных данных. Применение данных метрик в нейронных сетях предоставляет возможность выбирать модели с высокой предсказуемостью, а также осуществлять сравнение различных моделей между собой.

Анализируя результаты оценок MAE, R^2 и RMSE для прогнозирования мощности солнечной панели с применением LSTM и XGBoost (приведенных в

таблице 1), можно выделить, что даже при рассмотрении данных за один день модели демонстрируют относительно высокие показатели RMSE и MAE. XGBoost достигает впечатляющих значений R^2 для мощности панели, приближенных к 0,99, в то время как LSTM показывает коэффициент R^2 на уровне 0,6 для мощности соответственно.

В таблице 2 представлены показатели MAE, R^2 и RMSE, относящиеся к прогнозированию излучения при использовании моделей LSTM и XGBoost. Значения RMSE и MAE демонстрируют выдающиеся результаты во второй модели. В частности, в XGBoost коэффициент R^2 составил 0,97, что свидетельствует о высоком качестве прогнозирования. Следует отметить, что это отличный результат. В то время как в LSTM значение R^2 оказалось на уровне 0,67, что указывает на некоторую уязвимость данного метода.

Таблица 1 - Оценка прогнозирования мощности: MAE, R^2 и RMSE для LSTM и XGBoost

Название	RMSE	MAE	R^2
LSTM	0,13	0,1	0,6
XGBoost	0,005	0,001	0,99

Таблица 2 - Оценка прогнозирования мощности: MAE, R^2 и RMSE для LSTM и XGBoost

Название	RMSE	MAE	R^2
LSTM	0,15	0,12	0,67
XGBoost	0,04	0,27	0,97

Результаты сравнительного анализа показателей MAE, R^2 и RMSE для прогнозирования излучения с использованием LSTM и XGBoost указывают на значительное преимущество XGBoost. XGBoost проявляет выдающуюся эффективность в интерпретации и предсказании изменений в мощности и излучении солнечной панели. Таким образом, представленный метод XGBoost выделяется своей значительной долей достоверности в предсказаниях, что делает ее предпочтительным вариантом для использования в контексте анализа энергетических систем, ориентированных на солнечные источники.

В аналогичном исследовании оценочные показатели LSTM были следующими: $R^2 = 0,85$, RMSE = 2,44, MAE = 1,27; для ANN эти показатели составили $R^2 = 0,86$, RMSE = 2,4, MAE = 1,29, а для XGboost - $R^2 = 0,95$, RMSE = 1,30, MAE = 0,83. По сравнению с этими результатами, в нашем исследовании

были получены более высокие оценочные показатели, что указывает на эффективный подбор гиперпараметров моделей нейронных сетей.

Гиперпараметры - это параметры, которые позволяют настраивать процесс обучения нейронной сети. Они выбираются перед началом обучения и могут значительно влиять на качество и эффективность работы сети. Выбор оптимальных гиперпараметров зависит от типа нейронной сети, её архитектуры, задачи, на которую она настраивается, и особенностей данных, на которых происходит обучение. В таблице 3 приведены гиперпараметры нами исследуемых нейронных сетей. Здесь, batchsize - объем данных, обрабатываемых за один шаг; Epochs - однократное прохождение всех обучающих выборок; Activation function - математическая функция, которая определяет выходные данные нейрона на основе его входных данных; Optimizer - алгоритмы или методы,

используемые для изменения атрибутов нейронной сети, таких как веса и скорость обучения, чтобы уменьшить потери; Gamma - минимальное сокращение потерь, необходимое для создания дальнейше-

го разделения на конечном узле дерева; Subsample - соотношение подвыборки обучающих экземпляров; Max depth - максимальная глубина дерева.

Таблица 3 - Гиперпараметры нейронных сетей

LSTM		XGBOOST	
Batchsize	16	Gamma	0.5
Epochs	120	Subsample	0.4
Activationfunction	sigmoid	Maxdepth	6
Optimizer	Adamax		

Основываясь на вышеописанных выводах, мы намерены внедрить и использовать XGBoost для более точного и надежного прогнозирования в области сбора данных о мощности и излучении солнечной панели.

В заключении данной научной статьи подытожены основные результаты и выводы, полученные в ходе исследования прогнозирования мощности фотоэлектрических систем с использованием моделей LSTM и XGBoost.

Выводы. В результате данного исследования был разработан эффективный метод прогнозирования солнечной энергии с использованием алгоритмов нейронной сети. Цель исследования была успешно достигнута, так как были выполнены все поставленные задачи. Основными результатами исследования является сравнительный анализ двух алгоритмов - LSTM и XGBoost - в контексте прогнозирования солнечной энергии. Наиболее выдающимся результатом является высокий коэффициент детерминации (R^2) модели XGBoost, достигший значения 0,99. Этот результат свидетельствует о высокой способности модели предсказывать выходную мощность солнечных панелей. Модель LSTM также показала хорошие результаты с R^2 , равным 0,6.

Отличительными признаками полученного результата являются - высокая точность и надежность обеих моделей, что подтверждается анализом мет-

рик MAE, R^2 и RMSE, а также эффективный подбор гиперпараметров моделей нейронных сетей, что привело к получению более высоких оценочных показателей по сравнению с известными результатами.

Эти выводы утверждают, что предложенные модели, базирующиеся на машинном обучении, успешно справляются с задачей прогнозирования производства фотоэлектрических систем. Они обеспечивают стабильность и высокую точность в предсказании выходной мощности солнечных панелей даже при ограниченных данных.

В перспективе предлагается дальнейшее улучшение методов и расширение исследования на более продолжительный временной интервал. Это позволит получить дополнительные инсайты в поведение фотоэлектрических систем при различных погодных условиях и увеличит обобщающую способность моделей. Такие улучшения могут существенно расширить область применения разработанных методов в реальных условиях энергетических систем, ориентированных на солнечные источники.

Работа выполнена при поддержке исследовательского проекта AP23487428 Комитета науки Министерства науки и высшего образования Республики Казахстан и выполнена в Казахском Национальном Университете имени аль-Фараби, что с благодарностью признано авторами.

Литература

1. Lott M. C., Pye S., Dodds P. E. Quantifying the co-impacts of energy sector decarbonization on outdoor air pollution in the United Kingdom //Energy Policy. - 2017. - Vol. 101. - pp. 42-51. <https://doi.org/10.1016/j.enpol.2016.11.028>.
2. Marchesoni-Acland F., Alonso-Suárez R. Intra-day solar irradiation forecast using RLS filters and satellite images //Renewable Energy. - 2020. - Vol. 161. - pp. 1140-1154. <https://doi.org/10.1016/j.renene.2020.07.101>.

3. Notton G. et al. Intermittent and stochastic character of renewable energy sources: Consequences, cost of intermittence and benefit of forecasting //Renewable and sustainable energy reviews. - 2018. - Vol. 87. - pp. 96-105. <https://doi.org/10.1016/j.rser.2018.02.007>.
4. Rodríguez F. et al. Very short-term temperature forecaster using MLP and N-nearest stations for calculating key control parameters in solar photovoltaic generation //Sustainable Energy Technologies and Assessments. - 2021. - Vol. 45. - p. 101085. <https://doi.org/10.1016/j.seta.2021.101085>.
5. Alahyari A., Ehsan M., Mousavizadeh M. S. A hybrid storage-wind virtual power plant (VPP) participation in the electricity markets: A self-scheduling optimization considering price, renewable generation, and electric vehicles uncertainties //Journal of Energy Storage. - 2019. - Vol. 25. - p. 100812. <https://doi.org/10.1016/j.est.2019.100812>.
6. Adu-Kankam K. O., Camarinha-Matos L. M. Towards collaborative virtual power plants: Trends and convergence //Sustainable Energy, Grids and Networks. - 2018. - Vol. 16. - pp. 217-230. <https://doi.org/10.1016/j.segan.2018.08.003>.
7. Wen L. et al. Optimal load dispatch of community microgrid with deep learning based solar power and load forecasting //Energy. - 2019. - Vol. 171. - pp. 1053-1065. <https://doi.org/10.1016/j.energy.2019.01.075>.
8. Sobri S., Koohi-Kamali S., Rahim N. A. Solar photovoltaic generation forecasting methods: A review //Energy conversion and management. - 2018. - Vol. 156. - pp. 459-497. <https://doi.org/10.1016/j.enconman.2017.11.019>.
9. Antonopoulos I. et al. Artificial intelligence and machine learning approaches to energy demand-side response: A systematic review //Renewable and Sustainable Energy Reviews. - 2020. - Vol. 130. - p. 109899. <https://doi.org/10.1016/j.rser.2020.109899>.
10. Li Z. et al. A hierarchical approach using machine learning methods in solar photovoltaic energy production forecasting //Energies. - 2016. - Vol. 9. - №. 1. - pp. 55. <https://doi.org/10.3390/en9010055>.
11. Zhang J. et al. Deep photovoltaic nowcasting //Solar Energy. - 2018. - Vol. 176. - pp. 267-276. <https://doi.org/10.1016/j.solener.2018.10.024>.
12. Chu Y., Li M., Coimbra C. F. M. Sun-tracking imaging system for intra-hour DNI forecasts //Renewable Energy. - 2016. - Vol. 96. - pp. 792-799. <https://doi.org/10.1016/j.renene.2016.05.041>.
13. Jamal T. et al. An energy flow simulation tool for incorporating short-term PV forecasting in a diesel-PV-battery off-grid power supply system //Applied Energy. - 2019. - Vol. 254. - p. 113718. <https://doi.org/10.1016/j.apenergy.2019.113718>.
14. Kaur A. et al. Benefits of solar forecasting for energy imbalance markets //Renewable energy. - 2016. - Vol. 86. - pp. 819-830. <https://doi.org/10.1016/j.renene.2015.09.011>.
15. Aguiar L. M. et al. Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting //Renewable Energy. - 2016. - Vol. 97. - pp. 599-610. <https://doi.org/10.1016/j.renene.2016.06.018>.
16. Sperati S., Alessandrini S., DelleMonache L. An application of the ECMWF Ensemble Prediction System for short-term solar power forecasting //Solar Energy. - 2016. - Vol. 133. - pp. 437-450. <https://doi.org/10.1016/j.solener.2016.04.016>.
17. Gürtler M., Paulsen T. The effect of wind and solar power forecasts on day-ahead and intraday electricity prices in Germany //Energy Economics. - 2018. - Vol. 75. - pp. 150-162. <https://doi.org/10.1016/j.eneco.2018.07.006>.
18. Liu L. M. et al. Dual-dimension Time-GGAN data augmentation method for improving the performance of deep learning models for PV power forecasting //Energy Reports. - 2023. - Vol. 9. - pp. 6419-6433. <https://doi.org/10.1016/j.egyr.2023.05.226>.
19. Khan W., Walker S., Zeiler W. Improved solar photovoltaic energy generation forecast using deep learning-based ensemble stacking approach //Energy. - 2022. - Vol. 240. - p. 122812.

<https://doi.org/10.1016/j.energy.2021.122812>.

20. Etxegarai G. et al. An analysis of different deep learning neural networks for intra-hour solar irradiation forecasting to compute solar photovoltaic generators' Energy for Sustainable Development. - 2022. - Vol. 68. - pp. 1-17. <https://doi.org/10.1016/j.esd.2022.02.002>.

21. Trong T. N. et al. Short-term PV power forecast using hybrid deep learning model and Variational Mode Decomposition //Energy Reports. - 2023. - Vol. 9. - pp. 712-717. <https://doi.org/10.1016/j.egy.2023.05.154>.

References

1. Lott M. C., Pye S., Dodds P. E. Quantifying the co-impacts of energy sector decarbonization on outdoor air pollution in the United Kingdom //Energy Policy. - 2017. - Vol. 101. - pp. 42-51.

<https://doi.org/10.1016/j.enpol.2016.11.028>.

2. Marchesoni-Acland F., Alonso-Suárez R. Intra-day solar irradiation forecast using RLS filters and satellite images //Renewable Energy. - 2020. - Vol. 161. - pp. 1140-1154. <https://doi.org/10.1016/j.renene.2020.07.101>.

3. Notton G. et al. Intermittent and stochastic character of renewable energy sources: Consequences, cost of intermittence and benefit of forecasting //Renewable and sustainable energy reviews. - 2018. - Vol. 87. - pp. 96-105. <https://doi.org/10.1016/j.rser.2018.02.007>.

4. Rodríguez F. et al. Very short-term temperature forecaster using MLP and N-nearest stations for calculating key control parameters in solar photovoltaic generation //Sustainable Energy Technologies and Assessments. - 2021. - Vol. 45. - p. 101085. <https://doi.org/10.1016/j.seta.2021.101085>.

5. Alahyari A., Ehsan M., Mousavizadeh M. S. A hybrid storage-wind virtual power plant (VPP) participation in the electricity markets: A self-scheduling optimization considering price, renewable generation, and electric vehicles uncertainties //Journal of Energy Storage. - 2019. - Vol. 25. - p. 100812.

<https://doi.org/10.1016/j.est.2019.100812>.

6. Adu-Kankam K. O., Camarinha-Matos L. M. Towards collaborative virtual power plants: Trends and convergence //Sustainable Energy, Grids and Networks. - 2018. - Vol. 16. - pp. 217-230.

<https://doi.org/10.1016/j.segan.2018.08.003>.

7. Wen L. et al. Optimal load dispatch of community microgrid with deep learning based solar power and load forecasting //Energy. - 2019. - Vol. 171. - pp. 1053-1065. <https://doi.org/10.1016/j.energy.2019.01.075>.

8. Sobri S., Koochi-Kamali S., Rahim N. A. Solar photovoltaic generation forecasting methods: A review //Energy conversion and management. - 2018. - Vol. 156. - pp. 459-497. <https://doi.org/10.1016/j.enconman.2017.11.019>.

9. Antonopoulos I. et al. Artificial intelligence and machine learning approaches to energy demand-side response: A systematic review //Renewable and Sustainable Energy Reviews. - 2020. - Vol. 130. - p. 109899.

<https://doi.org/10.1016/j.rser.2020.109899>.

10. Li Z. et al. A hierarchical approach using machine learning methods in solar photovoltaic energy production forecasting //Energies. - 2016. - Vol. 9. - №. 1. - pp. 55. <https://doi.org/10.3390/en9010055>.

11. Zhang J. et al. Deep photovoltaic nowcasting //Solar Energy. - 2018. - Vol. 176. - pp. 267-276.

<https://doi.org/10.1016/j.solener.2018.10.024>.

12. Chu Y., Li M., Coimbra C. F. M. Sun-tracking imaging system for intra-hour DNI forecasts //Renewable Energy. - 2016. - Vol. 96. - pp. 792-799. <https://doi.org/10.1016/j.renene.2016.05.041>.

13. Jamal T. et al. An energy flow simulation tool for incorporating short-term PV forecasting in a diesel-PV-battery off-grid power supply system //Applied Energy. - 2019. - Vol. 254. - p. 113718.

<https://doi.org/10.1016/j.apenergy.2019.113718>.

14. Kaur A. et al. Benefits of solar forecasting for energy imbalance markets //Renewable energy. - 2016. - Vol. 86. - pp. 819-830. <https://doi.org/10.1016/j.renene.2015.09.011>.

15. Aguiar L. M. et al. Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting //Renewable Energy. - 2016. - Vol. 97. - pp. 599-610.

<https://doi.org/10.1016/j.renene.2016.06.018>.

16. Sperati S., Alessandrini S., DelleMonache L. An application of the ECMWF Ensemble Prediction System for short-term solar power forecasting //Solar Energy. - 2016. - Vol. 133. - pp. 437-450.

<https://doi.org/10.1016/j.solener.2016.04.016>.

17. Gürtler M., Paulsen T. The effect of wind and solar power forecasts on day-ahead and intraday electricity prices in Germany //Energy Economics. - 2018. - Vol. 75. - pp. 150-162.

<https://doi.org/10.1016/j.eneco.2018.07.006>.

18. Liu L. M. et al. Dual-dimension Time-GGAN data augmentation method for improving the performance of deep learning models for PV power forecasting //Energy Reports. - 2023. - Vol. 9. - pp. 6419-6433.

<https://doi.org/10.1016/j.egyr.2023.05.226>.

19. Khan W., Walker S., Zeiler W. Improved solar photovoltaic energy generation forecast using deep learning-based ensemble stacking approach //Energy. - 2022. - Vol. 240. - p. 122812.

<https://doi.org/10.1016/j.energy.2021.122812>.

20. Etxegarai G. et al. An analysis of different deep learning neural networks for intra-hour solar irradiation forecasting to compute solar photovoltaic generators' Energy for

Sustainable Development. - 2022. - Vol. 68. - pp. 1-17. <https://doi.org/10.1016/j.esd.2022.02.002>.

21. Trong T. N. et al. Short-term PV power forecast using hybrid deep learning model and Variational Mode Decomposition //Energy Reports. - 2023. - Vol. 9. - pp. 712-717. <https://doi.org/10.1016/j.egyr.2023.05.154>.

Сведения об авторах

Құттыбай Н.Б. - и.о. доцент, PhD, Казахский Национальный Университет им. аль-Фараби, Алматы, Казахстан, e-mail: Nurjigit.10.93@gmail.com;

Айтбекова Ш.Б.- магистрант, Казахский Национальный Университет имени аль-Фараби, Алматы, Казахстан, e-mail: aitbekovashapa@gmail.com;

Қошқарбай Н.Ж. - докторант, Казахский Национальный Университет имени аль-Фараби, Алматы, Казахстан, e-mail: Koshkarbay.n@kaznu.kz;

Болатбек А.Б. - докторант, Казахский Национальный Университет имени аль-Фараби, Алматы, Казахстан, e-mail: bolatbekaskhat98@gmail.com;

Жоламанов Б.Н.- докторант, Казахский Национальный Университет имени аль-Фараби, Алматы, Казахстан, e-mail: batyrbek149@gmail.com.

Information about the authors

Kuttybay N.- acting associate professor, PhD, Kazakh National University named after al-Farabi, Almaty, Kazakhstan, e-mail: Nurjigit.10.93@gmail.com;

Aitbekova Sh.- Master's student, Al-Farabi Kazakh National University, Almaty, Kazakhstan, e-mail: :aitbekovashapa@gmail.com;

Koshkarbay N.-doctoral student, Al-Farabi Kazakh National University, Almaty, Kazakhstan, e-mail: Koshkarbay.n@kaznu.kz;

Bolatbek A.- doctoral student, Al-Farabi Kazakh National University, Almaty, Kazakhstan, e-mail: bolatbekaskhat98@gmail.com;

Zholamanov B. doctoral student, Al-Farabi Kazakh National University, Almaty, Kazakhstan, e-mail :batyrbek149@gmail.com.