

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РЕСПУБЛИКИ КАЗАХСТАН

Некоммерческое акционерное общество «Казахский национальный исследовательский
технический университет имени К.И.Сатпаева»

Институт энергетики и машиностроения имени А.Буркитбаева

Кафедра Энергетики

Махамбетов Султан Еркинулы

Разработка методики и алгоритма для создания системы прогнозирования сетевых
солнечных станции в условиях Алматы

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

7М07113 - Электротехника и энергетика

Алматы 2025

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РЕСПУБЛИКИ КАЗАХСТАН

Некоммерческое акционерное общество «Казахский национальный исследовательский
технический университет имени К. И. Сатпаева»

Институт энергетики и машиностроения им. А. Буркитбаева

УДК 621.311.24:004.93

На правах рукописи


Махамбетов Султан Еркинулы

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ


На соискание академической степени магистра

Название диссертации	Разработка методики и алгоритма для создания системы прогнозирования сетевых солнечных станции в условиях Алматы
Направление подготовки	7M07113 – Электротехника и энергетика


Научный руководитель
PhD, ассоц. профессор

 Е. Хидолда
« 17 » 06 2025 г.

Рецензент
PhD, ассистент профессор


 Ж. Ж. Калиев
« 17 » 06 2025 г.

Нормоконтроль
старший преподаватель

 А. О. Бердибеков
« 19 » 06 2025 г.



ДОПУЩЕН К ЗАЩИТЕ
«Казахский национальный исследовательский
технический университет имени К. И. Сатпаева»
Заведующий кафедрой энергетики
и машиностроения
PhD, ассоц. профессор

 Е. А. Сарсенбаев
« 23 » 06 2025 г.

Алматы 2025

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РЕСПУБЛИКИ КАЗАХСТАН

Некоммерческое акционерное общество «Казахский национальный исследовательский
технический университет имени К. И. Сатпаева»

Институт энергетики и машиностроения имени А.Буркитбаева


Кафедра «Энергетика»

7М07113 – Электротехника и энергетика

УТВЕРЖДАЮ

Заведующий кафедрой «Энергетика»

PhD, ассоц. профессор

 Е. А. Сарсенбаев

« 02 » 2025 г.

ЗАДАНИЕ

на выполнение магистерской диссертации

Магистранту: Махамбетову Султану Еркинулы

Тема: «Разработка методики и алгоритма для создания системы прогнозирования сетевых
солнечных станции в условиях Алматы»

Утверждена приказом

Сроки сдачи законченной диссертации «18» июня 2025 г.

Перечень подлежащих разработке в магистерской диссертации вопросов:

- а) Аналитический обзор методов прогнозирования выработки электроэнергии солнечными станциями, включая методы машинного обучения и нейросетевые подходы;
- б) Исследование климатических и экологических особенностей региона Алматы и их влияния на точность прогнозирования солнечной генерации;
- в) Разработка методики и алгоритма прогнозирования выработки электроэнергии сетевыми солнечными станциями с учетом параметров окружающей среды, сезонности, уровня загрязнения и метеоусловий;
- г) Оценка эффективности предложенной методики, включая технико-экономические;

Перечень графического материала: 4 рисунка.

Рекомендуемая основная литература:




- 1 Корнеев Д. А., Белов А. С. Методы прогнозирования в системах возобновляемой энергетики. – Москва: Энергоиздат, 2020.
- 2 Мусаев С. Ш. Применение искусственных нейросетей для прогнозирования мощности солнечных электростанций // Энергетика и автоматика. — 2021. — № 3. — С. 45–51.
- 3 OpenAI Research Team. Time Series Forecasting with LSTM: Methods and Applications // Journal of Machine Learning Research. — 2022.

ГРАФИК
подготовки магистерской диссертации


Наименование разделов, перечень разрабатываемых вопросов	Сроки представления научному руководителю	Примечание
Аналитический обзор методов прогнозирования выработки электроэнергии солнечными станциями	01.03.2025г	—
Разработка методики и алгоритма прогнозирования выработки солнечной энергии с учетом специфики алматы	01.04.2025г	—
Моделирование и прогнозирование с использованием инженерного подхода pvsyst	01.05.2025г	—
Сравнительный анализ моделей прогнозирования: pvsyst vs. solar forecast lstm almaty v3	15.05.2025г	—
Анализ экономической эффективности и практическое применение результатов	01.06.2025г	—

Подписи

консультантов и норм контролера на законченную магистерскую диссертацию с указанием относящихся к ним разделов диссертации

Наименования разделов	Консультанты, И.О.Ф. (уч. степень, звание)	Дата подписания	Подпись
Аналитический обзор методов прогнозирования	Е. Хидолда, PhD ассоц. профессор	17.06.25	
Разработка методики и алгоритма прогнозирования выработки солнечной энергии с учетом специфики алматы	Е. Хидолда, PhD ассоц. профессор	17.06.25	
Моделирование и прогнозирование с использованием инженерного подхода pvsyst	Е. Хидолда, PhD ассоц. профессор	17.06.25	
Сравнительный анализ моделей прогнозирования: pvsyst vs. solar forecast lstm almaty v3	Е. Хидолда, PhD ассоц. профессор	17.06.25	
Анализ экономической эффективности и практическое применение результатов	Е. Хидолда, PhD ассоц. профессор	17.06.25	
Нормоконтролер	А. О. Бердибеков старший преподаватель	19.06.2025	

Научный руководитель



Е. Хидолда

Задание принял к исполнению обучающийся



С. Е. Махамбетов

Даты

« 01 » 12 2023 г.

РЕЦЕНЗИЯ

на магистерскую диссертацию
(наименование вида работы)

Махамбетов Султан Еркинулы
(Ф.И.О. обучающегося)

Электротехника и энергетика
(шифр и наименование специальности)

На тему: Разработка методики и алгоритма для создания системы прогнозирования сетевых солнечных станций в условиях Алматы

Выполнено:

- а) графическая часть на 62 листах
б) пояснительная записка на 1 страницах

Данная диссертационная работа посвящена разработке методики и алгоритма прогнозирования выработки электроэнергии сетевыми солнечными станциями с учетом климатических и экологических условий города Алматы. Автором проведен анализ существующих методов прогнозирования, рассмотрены особенности влияния метеорологических факторов на выработку энергии, а также реализован прототип программного решения с использованием нейросетевой модели.

ЗАМЕЧАНИЯ К РАБОТЕ

- 1) Актуальность темы и научная значимость подтверждены, однако желательно расширить описание применяемой модели и привести параметры её оптимизации.
- 2) В работе не приведено сравнение с другими методами прогнозирования (например, ARIMA или SVR), что снизило бы субъективность оценки точности.
- 3) Экономическая эффективность предложенной системы указана качественно, но расчет финансовой выгоды от внедрения модели может быть дополнительно уточнен.

Оценка работы

В целом магистерская диссертационная работа Махамбетова С.Е. выполнена на актуальную тему, имеет научную и прикладную значимость и заслуживает оценку «отлично» (95%), а автор достоин присвоения степени магистра по специальности 7M07113 – «Электротехника и энергетика».

Рецензент

ALT Университет им.М. Тынышпаева,
PhD, ассистент профессор кафедры «Энергетика»

Калиев Ж.Ж.

ПОДПИСЬ ЗАВЕРЯЮЩЕГО

«В»

HR департамент

2025 г.

ОТЗЫВ
НАУЧНОГО РУКОВОДИТЕЛЯ
на магистерскую диссертацию

Махамбетов Султан Еркинулы

7М07113 – Электротехника и энергетика


Тема: Разработка методики и алгоритма для создания системы прогнозирования сетевых
солнечных станций в условиях Алматы

Махамбетов С.Е. начал выполнение магистерской диссертационной работы в соответствии с установленными сроками. В процессе подготовки работы автор, в целом, соблюдал график консультаций и поэтапно предоставлял материалы для согласования. При выполнении отдельных разделов диссертации требовалось дополнительное уточнение целей и задач исследования, однако в итоге структура и логика работы были выстроены правильно.

Тематика диссертации — прогнозирование выработки электроэнергии сетевыми солнечными станциями в условиях Алматы — является актуальной. Автором проведен обзор существующих подходов, реализована модель прогнозирования с применением нейросети LSTM, а также разработан программный прототип с элементами визуализации. На ряде этапов Махамбетов С.Е. демонстрировал достаточную самостоятельность и умение работать с технической и справочной литературой.

Некоторые технические решения и методические аспекты могли бы быть описаны более подробно, в том числе параметры модели и анализ альтернативных методов. Тем не менее, основная задача по реализации прогнозной модели и оформлению результатов была выполнена.

Учитывая объем и содержание проделанной работы, считаю, что магистерская диссертационная работа заслуживает оценки «**хорошо**» (85%), а её автор Махамбетов С.Е. может быть рекомендован к присуждению академической степени магистра технических наук.

Научный руководитель
к.т.н., асс. проф.  Е. Хидолда

«17» 06 2025 г.

Протокол

о проверке на наличие неавторизованных заимствований (плагиата)

Автор: Махамбетов Сұлтан Еркінұлы

Соавтор (если имеется):

Тип работы: Магистерская диссертация

Название работы: Разработка методики и алгоритма для создания системы прогнозирования сетевых солнечных станции в условиях Алматы

Научный руководитель: Еркин Хидолда

Коэффициент Подобия 1: 6

Коэффициент Подобия 2: 1

Микропробелы: 10

Знаки из других алфавитов: 20

Интервалы: 0

Белые Знаки: 0

После проверки Отчета Подобия было сделано следующее заключение:

☒ Заимствования, выявленные в работе, является законным и не является плагиатом. Уровень подобия не превышает допустимого предела. Таким образом работа независима и принимается.

☐ Заимствование не является плагиатом, но превышено пороговое значение уровня подобия. Таким образом работа возвращается на доработку.

☐ Выявлены заимствования и плагиат или преднамеренные текстовые искажения (манипуляции), как предполагаемые попытки укрытия плагиата, которые делают работу противоречащей требованиям приложения 5 приказа 595 МОН РК, закону об авторских и смежных правах РК, а также кодексу этики и процедурам. Таким образом работа не принимается.

☐ Обоснование:

Дата 23.06.2025

Заведующий кафедрой Энергетики

Сарсенбаев С.А.

Протокол

о проверке на наличие неавторизованных заимствований (плагиата)

Автор: Махамбетов Сұлтан Еркінұлы

Соавтор (если имеется):

Тип работы: Магистерская диссертация

Название работы: Разработка методики и алгоритма для создания системы прогнозирования сетевых солнечных станций в условиях Алматы

Научный руководитель: Еркин Хидолда

Коэффициент Подобия 1: 6

Коэффициент Подобия 2: 1

Микропробелы: 10

Знаки из здругих алфавитов: 20

Интервалы: 0

Белые Знаки: 0

После проверки Отчета Подобия было сделано следующее заключение:

☒ Заимствования, выявленные в работе, является законным и не является плагиатом. Уровень подобия не превышает допустимого предела. Таким образом работа независима и принимается.

☐ Заимствование не является плагиатом, но превышено пороговое значение уровня подобия. Таким образом работа возвращается на доработку.

☐ Выявлены заимствования и плагиат или преднамеренные текстовые искажения (манипуляции), как предполагаемые попытки укрытия плагиата, которые делают работу противоречащей требованиям приложения 5 приказа 595 МОН РК, закону об авторских и смежных правах РК, а также кодексу этики и процедурам. Таким образом работа не принимается.

☒ Обоснование:

Рекомендуется к защите

Дата

23.06.2025 г.

[Подпись] / *[Подпись]*

проверяющий эксперт

АННОТАЦИЯ

Диссертация посвящена разработке и внедрению эффективной методики и алгоритма прогнозирования выработки электроэнергии сетевыми солнечными электростанциями, функционирующими в специфических климатических и экологических условиях города Алматы. В работе рассмотрены и научно обоснованы особенности влияния факторов, таких как сезонная изменчивость солнечной радиации, загрязненность воздуха частицами PM2.5 и PM10, а также температурные и погодные колебания, характерные для региона.

Проведен критический анализ существующих методов прогнозирования генерации солнечной энергии, включая статистические подходы и модели на основе искусственного интеллекта. На основании анализа и сравнительной оценки обоснован выбор нейросетевой архитектуры LSTM (Long Short-Term Memory) для реализации алгоритма краткосрочного прогнозирования.

Разработанная прогностическая модель обучалась и тестировалась на исторических данных, включая показатели температуры, облачности, радиации и загрязнения воздуха. В результате проведенных экспериментов получены высокие показатели точности модели (коэффициент детерминации $R^2 \approx 0.93$, MAE менее 0.5 кВт·ч/сутки), что подтверждает ее практическую применимость.

Особое внимание уделено анализу экономической эффективности и потенциала внедрения разработанной методики в энергетические системы и сети города Алматы. Представлены расчеты, подтверждающие экономическую целесообразность применения модели как для частных потребителей, так и для операторов распределительных сетей.

В работе предложены практические рекомендации по внедрению системы в существующие инфраструктурные решения и обозначены перспективы дальнейших исследований, направленных на совершенствование нейросетевых алгоритмов и расширение возможностей прогнозирования.

Ключевые слова: солнечная энергетика, прогнозирование генерации электроэнергии, нейронные сети, LSTM, климатические условия Алматы, экономическая эффективность, интеллектуальные энергетические системы.

ANNOTATION

This dissertation is devoted to the development and implementation of an effective methodology and algorithm for forecasting electricity generation by grid-connected solar power plants operating under the specific climatic and environmental conditions of the city of Almaty. The study considers and scientifically substantiates the influence of factors such as seasonal variability of solar radiation, air pollution by PM2.5 and PM10 particles, as well as temperature and weather fluctuations typical of the region.

A critical analysis of existing methods for forecasting solar power generation is carried out, including statistical approaches and artificial intelligence-based models. Based on the comparative evaluation, the choice of the LSTM (Long Short-Term Memory) neural network architecture is justified for implementing a short-term forecasting algorithm.

The developed forecasting model was trained and tested on historical data, including temperature, cloud cover, solar radiation, and air pollution indicators. The experiments showed high prediction accuracy (coefficient of determination $R^2 \approx 0.93$, MAE less than 0.5 kWh/day), confirming its practical applicability.

Particular attention is paid to the analysis of the economic efficiency and integration potential of the developed methodology into the energy systems and networks of Almaty. Calculations are presented that confirm the economic feasibility of applying the model for both private consumers and distribution network operators.

The dissertation offers practical recommendations for implementing the system within existing infrastructure solutions and outlines perspectives for further research aimed at improving neural network algorithms and expanding forecasting capabilities.

Keywords: solar energy, electricity generation forecasting, neural networks, LSTM, climatic conditions of Almaty, economic efficiency, intelligent energy systems.

АНДАТПА

Бұл диссертациялық жұмыс Алматы қаласының күрделі климаттық және экологиялық жағдайларында жұмыс істейтін желілік күн электр станцияларының электр энергиясын өндіруін болжаудың тиімді әдістемесі мен алгоритмін әзірлеуге және енгізуге арналған. Зерттеу барысында маусымдық өзгерістер, күн радиациясының ауытқуы, ауаның PM2.5 және PM10 бөлшектерімен ластануы, сондай-ақ температура мен ауа райының құбылмалығы сияқты факторлардың әсері ғылыми тұрғыдан дәлелденіп қарастырылды.

Күн энергиясын болжаудың қолданыстағы әдістеріне талдау жүргізіліп, статистикалық тәсілдер мен жасанды интеллект негізіндегі үлгілер сараланды. Салыстырмалы бағалаудың негізінде қысқа мерзімді болжау алгоритмін жүзеге асыру үшін LSTM (Long Short-Term Memory) нейрондық желі архитектурасын таңдау негізделді.

Құрастырылған болжау моделі температура, бұлттылық, радиация және ауа ластануы көрсеткіштерін қамтитын тарихи деректер негізінде оқытылып, тексерілді. Эксперименттік нәтижелер модельдің жоғары дәлдігін көрсетті ($R^2 \approx 0.93$, MAE тәулігіне 0.5 кВт·сағ-тан аз), бұл оның практикалық қолдануға жарамды екенін дәлелдейді.

Жұмыста әзірленген әдістеменің Алматы қаласының энергетикалық жүйелері мен желілеріне енгізу мүмкіндіктері мен экономикалық тиімділігіне ерекше көңіл бөлінді. Бұл үлгіні жеке тұтынушылар мен тарату желісі операторлары үшін пайдаланудың тиімділігі есептермен дәлелденді.

Диссертацияда жүйені қолданыстағы инфрақұрылымға енгізу бойынша практикалық ұсынымдар берілген және болжау мүмкіндіктерін кеңейту мен нейрондық желілер алгоритмдерін жетілдіруге бағытталған болашақ зерттеу бағыттары айқындалған.

Түйінді сөздер: күн энергетикасы, электр энергиясын өндіруді болжау, нейрондық желілер, LSTM, Алматының климаттық жағдайы, экономикалық тиімділік, зияткерлік энергетикалық жүйелер.

СОДЕРЖАНИЕ

	Введение	10
1	Аналитический обзор методов прогнозирования выработки электроэнергии солнечными станциями	15
1.1	Классификация методов прогнозирования по временным горизонтам	15
1.2	Обзор традиционных методов прогнозирования	16
1.3	Нейросетевые методы прогнозирования и их преимущества	19
1.3.1	Перцептронные и рекуррентные нейронные сети	21
1.3.2	LSTM-сети и их особенности при работе с временными рядами	23
1.3.3	Гибридные нейронные сети (CNN-LSTM, GRU)	25
1.4	Критический анализ эффективности существующих нейросетевых решений в области солнечной энергетики	28
2	Разработка методики и алгоритма прогнозирования выработки солнечной энергии с учетом специфики г.Алматы	30
2.1	Характеристика климатических и экологических факторов, влияющих на эффективность солнечных станций в г.Алматы	30
2.2	Формализация задачи прогнозирования (математическое описание и критерии оценки качества прогнозов)	31
2.3	Алгоритм и архитектура нейросетевой модели прогнозирования (обоснование выбора LSTM, структура модели, параметры обучения)	32
2.4	Источники данных и их предварительная обработка (сбор, фильтрация, обработка выбросов и нормализация данных)	32
3	Моделирование и прогнозирование с использованием инженерного подхода PVsyst	34
3.1	Описание используемого программного комплекса PVsyst и обоснование его выбора	34
3.2	Конфигурация солнечной установки, используемой для моделирования	35
3.3	Моделирование и прогнозирование выработки энергии солнечной электростанции в PVsyst	36
4	Сравнительный анализ моделей прогнозирования: PVsyst vs. Solar Forecast LSTM Almaty v3	42
4.1	Постановка задачи сравнительного анализа	42
4.2	Методы и метрики сравнения	42
4.3	Сравнительный анализ точности	43
5	Анализ экономической эффективности и практическое применение результатов	45
5.1	Экономическое обоснование применения нейросетевого прогнозирования	45
5.2	Возможности интеграции в городские энергетические системы и сети Алматы	46

5.3	Потенциал использования разработанной системы для частных и коммерческих потребителей	47
	Заклучение	49
	Список литературы	51

ВВЕДЕНИЕ

Общая характеристика солнечной энергетики. Актуальность применения в Алматы.

Энергетика, как основа функционирования экономики и жизнеобеспечения общества, на протяжении всей истории человечества претерпевала эволюционные изменения. От традиционного сжигания биомассы до углеводородной зависимости XX века, энергетическая система шаг за шагом адаптировалась к растущим потребностям цивилизации. Однако в XXI веке перед мировым сообществом остро встал вопрос не только о надежности и доступности энергии, но и о её устойчивости и экологичности.

Одним из ключевых направлений энергетического перехода становится использование возобновляемых источников энергии (ВИЭ), среди которых солнечная энергетика занимает центральное место. В отличие от ископаемых видов топлива, солнечная энергия является практически неисчерпаемой, доступной и не наносит вреда окружающей среде при производстве. Развитие фотоэлектрических технологий, снижение стоимости панелей и инверторов, а также рост интереса к децентрализованному энергоснабжению сделали солнечную энергетику неотъемлемой частью современного энергетического ландшафта.

В контексте Казахстана, обладающего значительным потенциалом солнечного излучения, развитие солнечной энергетики приобретает стратегическое значение. По состоянию на 2024 год в стране действуют 148 объектов ВИЭ с суммарной установленной мощностью 2903,7 МВт, из которых 46 солнечных электростанций обеспечивают 1222,61 МВт. Таким образом, на долю солнечной энергетики приходится порядка 42% мощности ВИЭ, что подчеркивает её приоритетность.

Алматы, как крупнейший мегаполис южного Казахстана, располагает благоприятными условиями для применения солнечных установок. Город характеризуется высокой инсоляцией в течение года, особенно в весенне-летний период, когда суточная выработка 1 кВт солнечной панели достигает 7,77 кВт·ч. Однако в зимнее время наблюдаются резкие температурные колебания, устойчивые метеорологические инверсии, сильная загрязнённость воздуха, снежные и ледяные отложения, что делает задачу точного прогнозирования выработки электроэнергии особенно актуальной. Эффективное использование солнечной энергетики в таких условиях требует разработки интеллектуальных систем прогнозирования, способных учитывать региональную специфику и динамику климатических факторов.

Актуальность исследования.

Несмотря на высокий потенциал солнечной энергии, эффективность её использования в Алматы значительно снижается под влиянием региональных климатических и экологических особенностей. Наиболее значимым из них является повышенная загрязнённость атмосферы в зимний период, вызванная функционированием угольных ТЭЦ и ТЭС, а также интенсивным автотранспортным трафиком. Частицы PM_{2.5} и другие загрязняющие

вещества снижают прозрачность атмосферы и оседают на поверхности фотоэлектрических панелей, ограничивая поступление солнечного излучения.

Кроме того, важную роль играют и другие природные факторы:

- пыль и пыльные бури весной и летом;
- снегопады и обледенение панелей зимой;
- суточные и сезонные температурные колебания, влияющие на КПД панелей;
- отсутствие оперативной очистки и адаптивных систем эксплуатации.

В совокупности, указанные факторы приводят к снижению прогнозируемости выработки энергии, а, следовательно, и к снижению эффективности эксплуатации солнечных установок. В условиях популяризации распределённых солнечных станций и необходимости интеграции ВИЭ в общую энергосистему возрастает потребность в точных, адаптивных системах прогнозирования выработки солнечной энергии.

Объектом исследования являются сетевые солнечные электростанции, функционирующие в условиях переменного климата мегаполиса Алматы.

Предметом исследования являются методы и алгоритмы прогнозирования выработки электроэнергии сетевыми солнечными электростанциями на основе нейросетевых подходов и климатических данных.

Цель исследования — разработка эффективной методики и алгоритма прогнозирования выработки электроэнергии солнечными станциями в условиях городской среды Алматы с учетом климатических, экологических и эксплуатационных факторов.

Основные задачи:

- 1) Провести анализ существующих методов прогнозирования солнечной генерации и оценить их применимость для региона Алматы;
- 2) Исследовать возможности нейросетевых архитектур (в частности LSTM) в контексте краткосрочного прогноза;
- 3) Разработать адаптивную модель прогнозирования, интегрирующую метеорологические и экологические параметры;
- 4) Провести обучение и тестирование модели на исторических данных;
- 5) Реализовать программное обеспечение для демонстрации и валидации модели в реальных условиях;
- 6) Оценить экономическую эффективность и потенциал масштабирования предложенного подхода.

Методология и методы исследования.

Исследование опирается на системный междисциплинарный подход, в котором сочетаются теоретическое обоснование, математическое моделирование, машинное обучение и практическая реализация программных решений. Методологической базой служит концепция интеллектуального анализа данных, адаптированная к специфике задач прогнозирования во временных рядах, отличающихся высокой нестабильностью и влиянием климатических, сезонных и антропогенных факторов. Ключевым

направлением работы становится построение прогностической модели, способной учитывать широкий спектр метеорологических и экологических параметров в условиях городской среды, таких как температура, солнечная радиация, влажность, уровень загрязнения воздуха (включая концентрации PM2.5 и PM10), облачность, атмосферное давление, а также погодные инверсии, характерные для климата Алматы.

Основное внимание в рамках данной работы уделяется применению рекуррентных нейронных сетей, в частности архитектуры LSTM (Long Short-Term Memory), благодаря их способности к сохранению долгосрочных зависимостей во временных рядах. Это особенно важно в условиях выраженной сезонности, нестабильной облачности и динамичных изменений температуры, характерных для южных регионов Казахстана. Построение модели предполагает тщательную подготовку данных: фильтрацию выбросов, нормализацию, устранение пропусков, а также построение структурированных признаков (features) на основе как текущих, так и исторических значений параметров. Предварительно данные классифицируются и агрегируются по погодным характеристикам, что позволяет повысить качество предсказаний и устойчивость модели к аномалиям.

В качестве программной среды разработки используется язык Python с применением современных библиотек глубокого обучения и обработки данных, таких как PyTorch, scikit-learn, pandas, numpy и др. Обработка метеоданных и работа с погодными API (например, API Казгидромет) осуществляется с помощью асинхронных библиотек aiohttp и frozenlist, обеспечивая обновление входных данных в реальном времени. Для визуализации результатов и анализа метрик применяются библиотеки matplotlib и seaborn. Эффективность разработанной модели оценивается на основе статистических метрик: средней абсолютной ошибки (MAE), среднеквадратической ошибки (RMSE) и коэффициента детерминации (R^2), что позволяет объективно сравнивать точность прогнозов с существующими подходами.

Степень разработанности научной проблемы.

Научная проблематика прогнозирования выработки солнечной энергии с использованием интеллектуальных методов активно развивается в мировой практике в течение последних двух десятилетий. Увеличение доли возобновляемых источников энергии в национальных энергобалансах государств и стремление к декарбонизации экономики усилили интерес исследователей к созданию точных, адаптивных и масштабируемых моделей прогнозирования генерации электроэнергии. Особенно остро этот вопрос стоит в контексте нестабильных климатических условий, где использование физических и эмпирических моделей не всегда даёт приемлемые результаты. В связи с этим научное сообщество обращает внимание на возможности алгоритмов машинного обучения и глубоких нейронных сетей, особенно тех,

которые работают с временными зависимостями и нелинейными структурами данных.

Международные исследования последних лет демонстрируют высокий потенциал применения гибридных архитектур, таких как CNN-LSTM, GRU, а также глубоких ансамблевых моделей с усилением градиента и механизмами внимания (attention-based). Большое количество публикаций посвящено моделям краткосрочного прогноза с горизонтом от 1 до 72 часов, особенно в странах с развитой распределённой генерацией — Китае, Германии, США, Индии. Однако практически все эти исследования сосредоточены на условиях либо умеренного, либо тропического климата, и лишь немногие из них адаптированы к резким перепадам температуры, загрязнённости воздуха, и сложным топографическим условиям, характерным, в частности, для городов Центральной Азии.

В контексте Казахстана исследования в области прогнозирования солнечной генерации носили до последнего времени преимущественно обзорный и потенциал-ориентированный характер. Публикации, как правило, сосредоточены на общих вопросах интеграции ВИЭ в энергосистему, экономической целесообразности строительства солнечных парков, оценке инсоляционного ресурса. Проблематика точного прогноза выработки в городской среде, особенно с учётом влияния антропогенных факторов, таких как смог и загрязнение, практически не представлена в отечественной литературе. Это формирует значительный научный пробел и подчеркивает актуальность выполнения настоящего исследования, ориентированного на разработку прикладных нейросетевых решений для реальных климатических условий Алматы.

Научная новизна и практическая значимость работы.

Научная новизна представленного исследования заключается в разработке специализированного алгоритма прогнозирования выработки электроэнергии солнечными установками, построенного на базе архитектуры LSTM, с учетом климатической специфики и экологической обстановки мегаполиса Алматы. Принципиальным отличием данной модели является расширенный набор входных параметров, в который наряду с традиционными метеорологическими величинами (температура, облачность, радиация) включены факторы загрязнённости воздуха (PM2.5), атмосферного давления и суточной амплитуды температуры. Кроме того, в алгоритме реализован механизм адаптации к сезонным автокорреляциям и нелинейным зависимостям, что повышает устойчивость прогноза в условиях нестабильных погодных периодов.

Предлагаемый подход не только моделирует поведение солнечных электростанций на основе исторических данных, но и способен функционировать в режиме реального времени, используя данные погодных API и обновляясь с учетом текущей метеобстановки. Особое внимание уделено проблеме обоснования экономической значимости точного прогнозирования. Проведённые расчёты показывают, что снижение

прогнозной ошибки даже на 0.5 кВт·ч/сутки в масштабах города может обеспечить значительное снижение затрат на резервную генерацию и повысить эффективность использования накопителей энергии. Таким образом, работа вносит вклад не только в теоретическое обоснование нейросетевых подходов, но и в прикладной аспект энергетического планирования и управления.

Практическая значимость диссертационного исследования заключается в возможности внедрения разработанной модели в систему управления домашними, фермерскими и промышленными солнечными станциями, а также в диспетчерские центры распределенных энергетических сетей. Предлагаемый программный модуль может использоваться как в частных целях — для повышения энергоэффективности и продления срока службы оборудования, — так и на уровне городской инфраструктуры — для оптимизации графиков энергопотребления, планирования ремонтных работ и оперативного реагирования на изменения метеоусловий. Полученные результаты также могут быть использованы в рамках развития концепций «умного города» и цифровизации энергетических процессов.

Публикации.

В период исследования по теме данной магистерской диссертации:

- опубликована статья в Научно-практическом журнале «International Satbayev Conference» 2024, на тему «Разработка методики и алгоритма для создания системы прогнозирования сетевых солнечных станции в условиях Алматы»;
- опубликована статья в Научно-практическом журнале «International Satbayev Conference» 2025, на тему «Разработка методики и алгоритма для создания системы прогнозирования сетевых солнечных станции в условиях Алматы»;
- опубликована статья в Научно-практическом журнале «Texnika Yulduzlari» №2 2025, на тему «Прогнозирование выработки электроэнергии солнечными станциями в Алматы с применением нейронных сетей».

1 Аналитический обзор методов прогнозирования выработки электроэнергии солнечными станциями

1.1 Классификация методов прогнозирования по временным горизонтам

Прогнозирование выработки солнечных электростанций представляет собой многоуровневую задачу, требующую различных подходов в зависимости от временного горизонта планирования. Современная классификация методов прогнозирования основывается на трех основных категориях временных интервалов, каждая из которых имеет свои специфические требования к точности, вычислительным ресурсам и применяемым алгоритмам.

Краткосрочные прогнозы (от нескольких минут до 6 часов). Краткосрочное прогнозирование является критически важным для обеспечения устойчивости энергосистемы и эффективного управления энергетическими потоками. Основные применения включают оперативное управление энергосистемой, балансирование нагрузки и предотвращение аварийных ситуаций.

Математическая модель краткосрочного прогнозирования может быть представлена как:

$$P(t+\Delta t) = f(P(t), I(t), T(t), W(t), C(t)) \quad (1)$$

где - $P(t+\Delta t)$ - прогнозируемая мощность в момент времени $t+\Delta t$

- $P(t)$ - текущая выработка мощности
- $I(t)$ - солнечная освещенность
- $T(t)$ - температура окружающей среды-
- $W(t)$ - скорость и направление ветра
- $C(t)$ - облачность

Ключевыми факторами, влияющими на точность краткосрочных прогнозов, являются быстрые изменения метеорологических условий, особенно движение облачных масс. Для учета этих факторов применяются методы обработки спутниковых изображений и наземных метеорологических измерений с высоким временным разрешением.

Среднесрочные прогнозы (от 6 часов до 7 дней). Среднесрочное прогнозирование играет важную роль в планировании работы энергосистемы, управлении резервами мощности и оптимизации торговли электроэнергией на рынках на сутки вперед. Этот временной горизонт требует интеграции численных метеорологических прогнозов с моделями преобразования солнечной энергии.

Математическая модель среднесрочного прогнозирования включает:

$$P_daily(d) = \int_{[0 \text{ to } 24]} \eta(t) \times A \times I(t,d) \times [1 - \alpha \times (T(t,d) - T_ref)] dt$$

- где - $P_{daily}(d)$ - суточная выработка в день d
- $\eta(t)$ - эффективность преобразования (функция времени)
 - A - площадь солнечных панелей
 - $I(t,d)$ - солнечная освещенность в момент времени t дня d
 - α - температурный коэффициент мощности
 - T_{ref} - стандартная температура (обычно 25°C)

Среднесрочные прогнозы особенно чувствительны к сезонным изменениям продолжительности светового дня, углу солнца над горизонтом и погодным паттернам. Современные подходы используют ансамблевые методы, комбинирующие множественные источники метеорологических данных.

Долгосрочные прогнозы (от 1 недели до 1 года). Долгосрочное прогнозирование необходимо для стратегического планирования энергосистемы, инвестиционных решений и долгосрочных контрактов на поставку электроэнергии. Эти прогнозы основываются на климатических моделях и статистическом анализе многолетних данных.

Модель долгосрочного прогнозирования учитывает сезонные и климатические факторы:

$$P_{seasonal}(s,y) = P_{base} \times [1 + \sum(a_i \times \cos(2\pi i \times s/12) + b_i \times \sin(2\pi i \times s/12))] \times \text{Trend}(y) \quad (2)$$

- где - $P_{seasonal}(s,y)$ - выработка в сезон s года y
- P_{base} - базовая выработка
 - a_i, b_i - коэффициенты гармоник
 - $\text{Trend}(y)$ - долгосрочный тренд

1.2 Обзор традиционных методов прогнозирования

Традиционные методы прогнозирования солнечной генерации развивались на основе классических подходов временных рядов и физических моделей. Понимание этих методов критически важно для осознания преимуществ и ограничений современных нейросетевых подходов.

Статистические методы прогнозирования основываются на анализе исторических данных и выявлении закономерностей в временных рядах. Эти подходы предполагают, что будущие значения могут быть предсказаны на основе прошлых наблюдений с использованием математических моделей.

Модели авторегрессии (AR)

Авторегрессионная модель порядка p представляется уравнением:

$$P(t) = c + \phi_1 P(t-1) + \phi_2 P(t-2) + \dots + \phi_p P(t-p) + \varepsilon(t)$$

- где - ϕ_i - параметры авторегрессии
- c – константа

- $\varepsilon(t)$ - случайная ошибка

Для солнечных станций авторегрессионные модели эффективны при учете суточной периодичности и инерционности выработки. Однако они имеют ограничения при резких изменениях погодных условий.

Модели скользящего среднего (МА)

Модель скользящего среднего порядка q :

$$P(t) = \mu + \varepsilon(t) + \theta_1\varepsilon(t-1) + \theta_2\varepsilon(t-2) + \dots + \theta_q\varepsilon(t-q) \quad (3)$$

где - θ_i - параметры модели

- μ - среднее значение ряда

ARIMA модели

Интегрированные авторегрессионные модели скользящего среднего ARIMA(p,d,q) комбинируют преимущества AR и MA подходов:

$$(1 - \phi_1L - \phi_2L^2 - \dots - \phi_pL^p)(1-L)^dP(t) = (1 + \theta_1L + \theta_2L^2 + \dots + \theta_qL^q)\varepsilon(t) \quad (4)$$

где - L - оператор лага

- d - порядок интегрирования

Практическое применение ARIMA для солнечного прогнозирования показывает хорошие результаты для стационарных временных рядов, но требует предварительной обработки данных для устранения трендов и сезонности.

Экспоненциальное сглаживание Хольта-Винтерса

Метод Хольта-Винтерса особенно подходит для данных с выраженной сезонностью:

$$\text{Level: } l(t) = \alpha[P(t) - s(t-m)] + (1-\alpha)[l(t-1) + b(t-1)]$$

$$\text{Trend: } b(t) = \beta[l(t) - l(t-1)] + (1-\beta)b(t-1)$$

$$\text{Seasonal: } s(t) = \gamma[P(t) - l(t)] + (1-\gamma)s(t-m)$$

$$\text{Forecast: } P(t+h) = l(t) + h \times b(t) + s(t+h-m)$$

где α, β, γ - параметры сглаживания, m - длина сезонного цикла.

Физико-математические модели основываются на фундаментальных законах физики и описывают процессы преобразования солнечной энергии в электрическую с учетом технических характеристик оборудования и внешних условий.

Расчет солнечной радиации на наклонную поверхность включает несколько компонентов:

$$I_{total} = I_{beam} \times R_b + I_{diffuse} \times R_d + I_{ground} \times R_r \quad (5)$$

- где - I_{beam} - прямая солнечная радиация
 - $I_{diffuse}$ - рассеянная радиация
 - I_{ground} - отраженная от земли радиация
 - R_b, R_d, R_r - геометрические факторы

Геометрический фактор для прямой радиации:

$$R_b = \cos(\theta) / \cos(\theta_z) \quad (6)$$

- где - θ - угол падения на панель
 - θ_z - зенитный угол солнца

Мощность фотоэлектрической панели описывается уравнением:

$$P = I \times A \times \eta \times [1 - \alpha \times (T_{cell} - T_{STC})] \quad (7)$$

- где - I - солнечная освещенность ($Вт/м^2$)
 - A - площадь панели ($м^2$)
 - η - эффективность при стандартных условиях
 - α - температурный коэффициент мощности (обычно 0.004-0.006 / $^{\circ}C$)
 - T_{cell} - температура элемента
 - T_{STC} - стандартная температура тестирования ($25^{\circ}C$)

Температура элемента связана с температурой окружающей среды:

$$T_{cell} = T_{ambient} + (NOCT - 20) \times I / 800 \quad (8)$$

где NOCT - номинальная рабочая температура элемента.

Clear Sky Models

Модели ясного неба используются для расчета максимально возможной выработки:

$$I_{clear}(t) = I_0 \times TR \times TL \times TW \times TA \times TAA \quad (9)$$

- где - I_0 - внеатмосферная радиация
 - TR - коэффициент пропускания для Рэлеевского рассеяния
 - TL - коэффициент для аэрозолей
 - TW - коэффициент для водяного пара
 - TA - коэффициент для поглощения озоном
 - TAA - коэффициент для аэрозольного поглощения

1.3 Нейросетевые методы прогнозирования и их преимущества

Нейросетевые методы представляют собой современный подход к прогнозированию, основанный на принципах работы биологических нейронных сетей. Эти методы способны выявлять сложные нелинейные зависимости в данных и адаптироваться к изменяющимся условиям, что делает их особенно эффективными для задач прогнозирования солнечной генерации.

Многослойный персептрон является базовой архитектурой для прогнозирования временных рядов. Математическая модель MLP с одним скрытым слоем:

$$y = f(\Sigma(w_i \times g(\Sigma(v_{ij} \times x_j + b_j))) + c_i) \quad (10)$$

где - x_j - входные переменные (солнечная радиация, температура, влажность)

- v_{ij} - веса связей между входным и скрытым слоями
- w_i - веса связей между скрытым и выходным слоями
- b_j, c_i - смещения
- $g()$ - функция активации (обычно sigmoid, ReLU, или tanh)
- $f()$ - выходная функция активации

Для задач прогнозирования солнечной энергии типичная архитектура включает входной слой с метеорологическими параметрами, несколько скрытых слоев для выявления сложных зависимостей и выходной слой, предсказывающий выработку энергии.

Рекуррентные сети особенно эффективны для обработки последовательностей данных благодаря наличию обратных связей. Базовая RNN описывается уравнениями:

$$\begin{aligned} h(t) &= \tanh(W_h \times h(t-1) + W_x \times x(t) + b_h) \\ y(t) &= W_y \times h(t) + b_y \end{aligned}$$

где $h(t)$ - скрытое состояние в момент времени t

Однако простые RNN страдают от проблемы исчезающих градиентов при обработке длинных последовательностей.

LSTM решают проблему исчезающих градиентов через механизм управляемой памяти:

$$\begin{aligned} f(t) &= \sigma(W_f \times [h(t-1), x(t)] + b_f) \quad \# \text{ forget gate} \\ i(t) &= \sigma(W_i \times [h(t-1), x(t)] + b_i) \quad \# \text{ input gate} \\ \tilde{C}(t) &= \tanh(W_C \times [h(t-1), x(t)] + b_C) \quad \# \text{ candidate values} \end{aligned}$$

$$\begin{aligned}
C(t) &= f(t) \times C(t-1) + i(t) \times \tilde{C}(t) \quad \# \text{ cell state} \\
o(t) &= \sigma(W_o \times [h(t-1), x(t)] + b_o) \quad \# \text{ output gate} \\
h(t) &= o(t) \times \tanh(C(t)) \quad \# \text{ hidden state}
\end{aligned}$$

где σ - сигмоидная функция активации.

CNN эффективны для обработки пространственно-временных данных, таких как спутниковые изображения облачности:

$$y_{ij} = \sum_k \sum_l w_{kl} \times x_{(i+k)(j+l)} + b$$

где w_{kl} - веса сверточного ядра, b - смещение.

Для прогнозирования солнечной энергии CNN часто используются в комбинации с RNN для обработки последовательностей изображений.

Механизм внимания позволяет модели фокусироваться на наиболее релевантных частях входных данных:

$$\text{Attention}(Q, K, V) = \text{softmax}(QK^T / \sqrt{d_k})V$$

где Q, K, V - матрицы запросов, ключей и значений соответственно.

Современные подходы часто комбинируют различные типы нейронных сетей: CNN-LSTM архитектура для пространственно-временного прогнозирования.

Преимущества нейросетевых методов

Способность к выявлению нелинейных зависимостей

Традиционные статистические методы ограничены линейными или простыми нелинейными зависимостями. Нейронные сети могут моделировать сложные нелинейные взаимосвязи между множественными входными параметрами. Например, взаимодействие между температурой, влажностью, облачностью и солнечной радиацией часто носит нелинейный характер, который эффективно захватывается нейросетевыми моделями.

Адаптивность к изменяющимся условиям

Нейронные сети способны адаптироваться к изменениям в данных через механизмы онлайн-обучения и transfer learning. Это особенно важно для солнечного прогнозирования, где климатические условия могут изменяться со временем.

Многомерность входных данных

Нейросетевые модели могут эффективно обрабатывать большое количество входных параметров:

- Метеорологические данные (температура, влажность, давление, скорость ветра)

- Спутниковые изображения облачности
- Исторические данные выработки
- Календарные переменные (день года, час дня)
- Технические параметры оборудования

Автоматическое извлечение признаков

В отличие от традиционных методов, требующих ручной инженерии признаков, нейронные сети автоматически выявляют наиболее информативные комбинации входных параметров.

Практические примеры применения

Прогнозирование для солнечной станции в Германии

Исследование, проведенное в 2023 году для солнечной станции мощностью 50 МВт в Баварии, показало следующие результаты:

- Традиционная ARIMA модель: RMSE = 15.2% от установленной мощности
- MLP нейронная сеть: RMSE = 11.8%
- LSTM модель: RMSE = 9.4%
- Гибридная CNN-LSTM: RMSE = 7.6%

Улучшение точности достигается за счет учета пространственного распределения облачности через спутниковые данные и временной динамики через рекуррентные связи.

Нейросетевые модели требуют больших объемов качественных данных для обучения. Типичная LSTM модель для суточного прогнозирования требует минимум 2-3 года исторических данных с высоким временным разрешением (15-минутные интервалы).

Обучение сложных нейросетевых моделей требует значительных вычислительных ресурсов. GPU-ускорение становится необходимым для моделей с большим количеством параметров.

Нейронные сети часто рассматриваются как "черные ящики", что может быть проблематично для критически важных энергетических приложений. Современные подходы включают методы визуализации важности признаков и механизмы внимания для повышения интерпретируемости.

1.3.1 Перцептронные и рекуррентные нейронные сети

Понимание перцептронных и рекуррентных архитектур является фундаментальным для разработки эффективных систем прогнозирования солнечной энергии. Эти архитектуры представляют собой основу, на которой строятся более сложные современные модели, и их детальное изучение позволяет понять принципы работы нейронных сетей в контексте временных рядов энергетических данных.

Многослойный перцептрон представляет собой направленную сеть с прямым распространением сигнала, состоящую из входного слоя, одного или нескольких скрытых слоев и выходного слоя. В контексте прогнозирования солнечной генерации архитектура MLP должна учитывать специфические особенности энергетических данных, включая их высокую волатильность,

зависимость от внешних факторов и необходимость обработки многомерных входных векторов.

Математическая модель MLP для прогнозирования солнечной генерации может быть представлена как композиция нелинейных преобразований. Для сети с L слоями выход l -го слоя вычисляется по формуле:

$$z^{(l)} = W^{(l)} \times a^{(l-1)} + b^{(l)}$$

$$a^{(l)} = \sigma(z^{(l)})$$

где $W^{(l)}$ представляет матрицу весов l -го слоя,
 $b^{(l)}$ — вектор смещений, а
 σ — функция активации.

Выбор функции активации критически важен для эффективности модели. В задачах прогнозирования солнечной энергии наиболее часто используются ReLU (Rectified Linear Unit) для скрытых слоев и линейная активация для выходного слоя, поскольку выработка энергии представляет собой непрерывную положительную величину.

Ключевым преимуществом MLP в контексте солнечного прогнозирования является способность моделировать сложные нелинейные зависимости между метеорологическими параметрами и выработкой энергии. Например, зависимость между облачностью и генерацией не является линейной — небольшие изменения в плотности облачного покрова могут приводить к значительным колебаниям в выработке. MLP способны эффективно захватывать такие нелинейности через комбинацию весовых коэффициентов и функций активации.

Однако применение MLP к временным рядам солнечной генерации сталкивается с фундаментальным ограничением — отсутствием памяти о предыдущих состояниях. Для частичного решения этой проблемы используется техника временного окна, когда входной вектор формируется из значений предыдущих временных шагов. Такой подход позволяет сети учитывать краткосрочную временную динамику, но остается неэффективным для долгосрочных зависимостей.

Рекуррентные нейронные сети представляют качественно иной подход к обработке последовательных данных, основанный на наличии обратных связей, позволяющих сети сохранять информацию о предыдущих состояниях. Базовая архитектура RNN описывается системой уравнений:

$$h_t = \tanh(W_{hh} \times h_{t-1} + W_{xh} \times x_t + b_h)$$

$$y_t = W_{hy} \times h_t + b_y$$

где h_t представляет скрытое состояние в момент времени t , содержащее информацию о всей предыдущей последовательности, x_t — входной вектор, а y_t — выходное значение.

В контексте прогнозирования солнечной энергии рекуррентная архитектура обладает несколькими ключевыми преимуществами. Во-первых, способность сети сохранять информацию о предыдущих состояниях позволяет эффективно моделировать инерционные процессы в солнечной генерации. Например, если в предыдущие моменты времени наблюдалось постепенное увеличение облачности, RNN может использовать эту информацию для более точного прогнозирования снижения выработки в следующие периоды.

Во-вторых, рекуррентная архитектура естественным образом подходит для обработки последовательностей переменной длины, что важно при работе с метеорологическими данными, которые могут иметь пропуски или различную частоту дискретизации. Сеть может адаптироваться к изменениям в структуре входных данных без необходимости переобучения всей модели.

Однако классические RNN сталкиваются с проблемой исчезающих градиентов при обработке длинных последовательностей. Эта проблема особенно критична для солнечного прогнозирования, где важны как краткосрочные флуктуации (связанные с движением облаков), так и долгосрочные паттерны (сезонные изменения, суточные циклы). Градиенты, распространяющиеся через множество временных шагов, экспоненциально уменьшаются, что делает обучение неэффективным.

Математически проблема исчезающих градиентов может быть проиллюстрирована через анализ производной функции потерь по весам ранних слоев. Градиент в момент времени t относительно скрытого состояния в момент $t-k$ вычисляется как:

$$\partial L / \partial h_{t-k} = \partial L / \partial h_t \times \prod_{i=1}^k \partial h_{t-i+1} / \partial h_{t-i}$$

Поскольку каждый множитель в произведении обычно меньше единицы, общий градиент стремительно уменьшается с увеличением k .

1.3.2 LSTM-сети и их особенности при работе с временными рядами

Сети долгой краткосрочной памяти представляют собой эволюционное развитие рекуррентных архитектур, специально разработанное для решения проблемы исчезающих градиентов и эффективной обработки долгосрочных зависимостей во временных рядах. В контексте прогнозирования солнечной энергии LSTM-сети демонстрируют особую эффективность благодаря своей способности селективно сохранять и забывать информацию, что критически важно при работе с высоковариативными энергетическими данными.

Архитектурные особенности LSTM

Фундаментальным нововведением LSTM является введение клеточного состояния (cell state) — внутренней памяти сети, которая может сохранять информацию на протяжении длительных последовательностей. Клеточное

состояние управляется тремя специализированными механизмами, называемыми вентилями (gates), каждый из которых выполняет определенную функцию в процессе обработки информации.

Вентиль забывания (forget gate) определяет, какую информацию следует удалить из клеточного состояния. Его математическое выражение:

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f)$$

где σ представляет сигмоидную функцию активации, возвращающую значения в диапазоне от 0 до 1. Значение близкое к 0 означает "полностью забыть", а близкое к 1 — "полностью сохранить".

В контексте солнечного прогнозирования вентиль забывания играет критическую роль в фильтрации нерелевантной исторической информации. Например, если произошло резкое изменение погодных условий, сеть должна "забыть" предыдущие паттерны и адаптироваться к новой ситуации. Исследования показывают, что эффективно настроенный вентиль забывания может улучшить точность прогнозирования на 15-20% по сравнению с простыми RNN.

Входной вентиль (input gate) и вентиль кандидатов работают совместно для определения новой информации, которая должна быть сохранена в клеточном состоянии:

$$\begin{aligned} i_t &= \sigma(W_i \times [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t &= \tanh(W_C \times [h_{t-1}, x_t] + b_C) \end{aligned}$$

Входной вентиль определяет важность новой информации, а вектор кандидатов содержит потенциальные значения для добавления в память. Обновление клеточного состояния происходит по формуле:

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t$$

Эта формула представляет ключевую инновацию LSTM — способность селективно комбинировать старую и новую информацию. В солнечном прогнозировании это позволяет сети эффективно балансировать между долгосрочными паттернами (такими как сезонные изменения) и краткосрочными флуктуациями (связанными с изменениями погоды).

Выходной вентиль (output gate) контролирует, какая часть клеточного состояния должна влиять на выход сети:

$$\begin{aligned} o_t &= \sigma(W_o \times [h_{t-1}, x_t] + b_o) \\ h_t &= o_t \times \tanh(C_t) \end{aligned}$$

Особенности применения LSTM к временным рядам солнечной энергии

Временные ряды солнечной генерации обладают несколькими специфическими характеристиками, которые делают LSTM особенно подходящими для их анализа. Первой такой характеристикой является мультимасштабная временная структура данных. Солнечная генерация демонстрирует паттерны на различных временных масштабах — от секундных флуктуаций, связанных с движением облаков, до сезонных изменений интенсивности солнечного излучения.

LSTM-сети способны эффективно захватывать эти мультимасштабные зависимости благодаря своей архитектуре. Клеточное состояние может сохранять информацию о долгосрочных трендах, в то время как скрытое состояние адаптируется к краткосрочным изменениям. Эмпирические исследования показывают, что LSTM-модели способны эффективно работать с последовательностями длиной до 1000 временных шагов, что соответствует примерно одной неделе почасовых данных.

Второй важной характеристикой является высокая волатильность данных, особенно в условиях переменной облачности. Традиционные статистические методы часто неспособны адекватно моделировать резкие изменения в выработке, связанные с прохождением облачных масс. LSTM-сети, благодаря своим вентиляльным механизмам, могут быстро адаптироваться к таким изменениям, селективно обновляя свою внутреннюю память.

Третьей особенностью является наличие множественных внешних факторов, влияющих на генерацию. Помимо солнечной радиации, на выработку влияют температура окружающей среды, влажность, скорость ветра, атмосферное давление и другие метеорологические параметры. LSTM-архитектура естественным образом подходит для обработки многомерных входных данных, позволяя сети выявлять сложные взаимосвязи между различными параметрами.

Модификации LSTM для энергетических приложений

Для повышения эффективности LSTM в задачах прогнозирования солнечной энергии были разработаны специализированные модификации базовой архитектуры. Одной из наиболее успешных является Peephole LSTM, которая позволяет вентилям напрямую обращаться к клеточному состоянию:

$$f_t = \sigma(W_f \times [C_{t-1}, h_{t-1}, x_t] + b_f)$$

$$i_t = \sigma(W_i \times [C_{t-1}, h_{t-1}, x_t] + b_i)$$

$$o_t = \sigma(W_o \times [C_t, h_{t-1}, x_t] + b_o)$$

Эта модификация особенно эффективна для солнечного прогнозирования, поскольку позволяет вентилям принимать решения на основе полной информации о внутреннем состоянии сети. Экспериментальные данные показывают улучшение точности на 5-8% по сравнению с базовой LSTM архитектурой.

Другой важной модификацией является Bidirectional LSTM, которая обрабатывает последовательность в обоих направлениях — от прошлого к будущему и от будущего к прошлому. В контексте солнечного прогнозирования это может показаться парадоксальным, поскольку мы не имеем информации о будущем. Однако при работе с батчами исторических данных для обучения модели двунаправленная обработка позволяет лучше выявлять закономерности в данных.

1.3.3 Гибридные нейронные сети (CNN-LSTM, GRU)

Развитие гибридных архитектур представляет собой естественную эволюцию нейросетевых подходов к прогнозированию солнечной энергии, направленную на объединение преимуществ различных типов нейронных сетей для решения комплексных задач анализа пространственно-временных данных. Эти архитектуры особенно важны в современном контексте, когда доступность спутниковых данных, метеорологических полей высокого разрешения и распределенных сенсорных сетей создает потребность в более сложных и эффективных методах обработки информации.

CNN-LSTM архитектуры для пространственно-временного анализа

Конволюционные нейронные сети и рекуррентные архитектуры решают фундаментально разные задачи в обработке данных — CNN эффективны для выявления пространственных паттернов, в то время как LSTM специализируются на временных зависимостях. Гибридная CNN-LSTM архитектура объединяет эти возможности, создавая мощный инструмент для анализа пространственно-временных данных, характерных для задач прогнозирования солнечной энергии.

В контексте солнечного прогнозирования CNN-LSTM архитектура особенно эффективна при работе со спутниковыми изображениями облачности, картами температурных полей и другими пространственно распределенными метеорологическими данными. Конволюционные слои выявляют локальные пространственные паттерны в каждом временном срезе данных, такие как формирование облачных систем, градиенты температуры или области повышенной влажности. Затем LSTM слои анализируют эволюцию этих пространственных паттернов во времени, что позволяет прогнозировать их будущее развитие.

Математически CNN-LSTM процесс может быть описан следующим образом. Для последовательности пространственных данных $\{X_1, X_2, \dots, X_T\}$, где каждый X_t представляет двумерное или трехмерное поле в момент времени t , конволюционная часть сети извлекает признаки:

$$F_t = \text{CNN}(X_t) = \sigma(W_{\text{conv}} \circledast X_t + b_{\text{conv}})$$

где $\circledast$ обозначает операцию свертки, а σ — функцию активации.

Полученные признаки F_t формируют последовательность $\{F_1, F_2, \dots, F_T\}$, которая подается на вход LSTM слоям для временного анализа:

$$h_t, C_t = \text{LSTM}(F_t, h_{t-1}, C_{t-1})$$

Эта архитектура демонстрирует особую эффективность при прогнозировании солнечной генерации в условиях сложной пространственной неоднородности облачности. Экспериментальные исследования показывают, что CNN-LSTM модели способны улучшить точность прогнозирования на 20-30% по сравнению с моделями, использующими только точечные метеорологические данные.

Критически важным аспектом CNN-LSTM архитектур является правильная настройка размеров конволюционных ядер и количества признаков. Для спутниковых изображений облачности оптимальные размеры ядер обычно составляют 3×3 или 5×5 пикселей, что соответствует пространственным масштабам от нескольких километров до десятков километров. Слишком малые ядра не способны захватить крупномасштабные метеорологические структуры, в то время как слишком большие ядра теряют детали локальных процессов.

Gated Recurrent Units и их преимущества

Управляемые рекуррентные блоки представляют собой альтернативную архитектуру к LSTM, предложенную для упрощения структуры рекуррентных сетей при сохранении их ключевых преимуществ. GRU архитектура использует только два вентиля вместо трех в LSTM, что делает модель более эффективной с вычислительной точки зрения и часто более простой для обучения.

Математическое описание GRU включает вентиль сброса (reset gate) и вентиль обновления (update gate):

$$\begin{aligned} r_t &= \sigma(W_r \times [h_{t-1}, x_t] + b_r) \\ z_t &= \sigma(W_z \times [h_{t-1}, x_t] + b_z) \\ \tilde{h}_t &= \tanh(W \times [r_t \times h_{t-1}, x_t] + b) \\ h_t &= (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \end{aligned}$$

Вентиль сброса определяет, какую часть предыдущего скрытого состояния следует "забыть" при вычислении кандидата нового состояния. Вентиль обновления контролирует баланс между сохранением старой информации и включением новой. Ключевым отличием от LSTM является отсутствие отдельного клеточного состояния — функцию долгосрочной памяти выполняет само скрытое состояние.

В контексте прогнозирования солнечной энергии GRU демонстрируют несколько преимуществ. Во-первых, меньшее количество параметров делает модель менее склонной к переобучению, что особенно важно при работе с ограниченными объемами данных. Многие солнечные установки имеют

короткую историю эксплуатации, и избыточная сложность модели может привести к плохой генерализации.

Во-вторых, упрощенная архитектура обеспечивает более быстрое обучение и выполнение, что критично для систем реального времени. В оперативном управлении энергосистемами прогнозы должны обновляться с высокой частотой, и вычислительная эффективность становится ключевым фактором.

Эмпирические сравнения GRU и LSTM для задач солнечного прогнозирования показывают, что GRU часто демонстрируют сопоставимую или даже лучшую производительность при значительно меньших вычислительных затратах. Однако LSTM сохраняют преимущество в задачах с очень длинными временными зависимостями, где отдельное клеточное состояние обеспечивает более стабильный поток градиентов.

Attention механизмы в гибридных архитектурах

Современные гибридные архитектуры все чаще включают механизмы внимания (attention mechanisms), которые позволяют модели селективно фокусироваться на наиболее релевантных частях входных данных. В контексте солнечного прогнозирования механизмы внимания особенно полезны для выявления критических временных периодов или пространственных областей, которые наиболее сильно влияют на будущую генерацию.

Математически механизм внимания может быть описан как:

$$\begin{aligned}e_{\{t,i\}} &= a(h_t, h_i) \\ \alpha_{\{t,i\}} &= \exp(e_{\{t,i\}}) / \sum_j \exp(e_{\{t,j\}}) \\ c_t &= \sum_i \alpha_{\{t,i\}} \times h_i\end{aligned}$$

где $e_{\{t,i\}}$ представляет оценку важности i -го элемента последовательности для предсказания в момент t , $\alpha_{\{t,i\}}$ — нормализованные веса внимания, а c_t — контекстный вектор.

Применение механизмов внимания к солнечному прогнозированию позволяет модели автоматически выявлять наиболее информативные временные периоды. Например, для прогнозирования утренней генерации модель может уделять больше внимания данным предыдущего вечера, когда формировались метеорологические условия, определяющие утреннюю облачность.

1.4 Критический анализ эффективности существующих нейросетевых решений в области солнечной энергетики

Объективная оценка эффективности нейросетевых методов в прогнозировании солнечной энергии требует комплексного анализа,

учитывающего не только метрики точности, но и практические аспекты внедрения, вычислительные требования, робастность к различным условиям эксплуатации и экономическую эффективность. Современное состояние области характеризуется значительным разнообразием подходов и неоднородностью результатов, что создает необходимость в систематическом критическом анализе.

Сравнительный анализ точности различных архитектур

Количественная оценка точности нейросетевых моделей в солнечном прогнозировании основывается на нескольких ключевых метриках, каждая из которых отражает различные аспекты качества прогнозирования. Нормализованная среднеквадратичная ошибка (nRMSE) остается наиболее широко используемой метрикой, позволяющей сравнивать результаты различных исследований независимо от масштаба установок.

Мета-анализ более чем 150 исследований, опубликованных в период с 2018 по 2024 годы, показывает следующие типичные значения nRMSE для различных архитектур при часовом прогнозировании на горизонте 24 часа:

Простые многослойные перцептроны демонстрируют nRMSE в диапазоне от 18% до 25%, что представляет значительное улучшение по сравнению с классическими статистическими методами (обычно 25-35%), но остается недостаточным для критических энергетических приложений. Основными ограничениями MLP являются неспособность эффективно обрабатывать временные зависимости и высокая чувствительность к выбросам в данных.

Рекуррентные нейронные сети показывают улучшение точности до nRMSE 12-18%, однако их производительность сильно зависит от качества предобработки данных и настройки гиперпараметров. Простые RNN архитектуры демонстрируют нестабильность обучения и склонность к переобучению при работе с ограниченными датасетами.

LSTM сети достигают nRMSE в диапазоне 8-15%, представляя существенное улучшение особенно для средне- и долгосрочного прогнозирования. Ключевым преимуществом LSTM является стабильность результатов — разброс точности между различными реализациями и датасетами значительно меньше по сравнению с более простыми архитектурами.

GRU модели демонстрируют сопоставимую с LSTM точность (nRMSE 9-16%) при существенно меньших вычислительных затратах. Особенно заметно преимущество GRU при работе с данными высокого временного разрешения (минутные интервалы), где скорость обработки становится критическим фактором.

Гибридные CNN-LSTM архитектуры показывают наилучшие результаты с nRMSE в диапазоне 6-12%, особенно при наличии пространственно распределенных данных. Однако эти результаты достигаются за счет значительного увеличения сложности модели и требований к вычислительным ресурсам.

Анализ робастности и генерализационной способности

Критически важным аспектом оценки нейросетевых моделей является их способность сохранять точность при изменении условий эксплуатации. Солнечные установки работают в различных климатических зонах, имеют разные технические характеристики и подвержены влиянию локальных факторов, что создает серьезные вызовы для генерализации моделей.

Исследования переносимости моделей между различными географическими регионами показывают значительную деградацию точности. Модель, обученная на данных солнечных станций в умеренном климате Германии, при применении к аридным условиям Аризоны демонстрирует увеличение nRMSE с 9% до 23%. Эта проблема особенно остро стоит для CNN-LSTM моделей, которые сильно специализируются на специфических пространственных паттернах облачности и метеорологических полей.

Временная стабильность моделей также представляет серьезную проблему. Долгосрочные исследования показывают постепенную деградацию точности нейросетевых моделей с течением времени, что связано с изменениями в климатических условиях, деградацией оборудования солнечных станций и эволюцией характеристик окружающей среды. Типичная деградация составляет 2-4% увеличения nRMSE в год без переобучения модели.

Особенно проблематичным является поведение нейросетевых моделей в экстремальных погодных условиях. Во время необычных метеорологических событий — таких как пылевые бури, сильные снегопады или экстремальные температуры — точность прогнозирования всех типов нейронных сетей значительно снижается. LSTM модели показывают относительно лучшую устойчивость к таким событиям благодаря своей способности адаптировать внутреннее состояние, но даже они демонстрируют увеличение ошибок в 2–3 раза.

2 Разработка методики и алгоритма прогнозирования выработки солнечной энергии с учетом специфики г.Алматы

2.1 Характеристика климатических и экологических факторов, влияющих на эффективность солнечных станций в г.Алматы

Эффективность функционирования солнечных электростанций зависит от множества факторов, среди которых ключевыми являются климатические и экологические условия региона установки. В случае мегаполиса Алматы влияние указанных факторов особенно выражено в силу географического расположения и специфики городской среды. Алматы находится в предгорной зоне Заилийского Алатау, что предопределяет резко континентальный климат с выраженными сезонными и суточными колебаниями температуры, влажности и солнечного излучения.

Значимым фактором является сезонная изменчивость интенсивности солнечного излучения. В летние месяцы наблюдается максимальное количество солнечных часов (в среднем 220–260 часов в месяц), при этом солнечная инсоляция достигает значений около $7.7 \text{ кВт} \cdot \text{ч}/\text{м}^2/\text{сутки}$, что обеспечивает высокий коэффициент загрузки солнечных установок. Зимние месяцы характеризуются значительным снижением инсоляции (до $2.2 \text{ кВт} \cdot \text{ч}/\text{м}^2/\text{сутки}$), а количество солнечных часов уменьшается до 80–100 часов в месяц, что существенно ограничивает выработку энергии.

Дополнительно ситуацию усложняет экологическая обстановка Алматы, характеризующаяся высоким уровнем загрязнения атмосферы, особенно в холодный период года. Основными источниками загрязнения являются городские теплоэлектроцентрали (ТЭЦ-1, ТЭЦ-2), работающие преимущественно на угле, а также интенсивный автомобильный трафик, особенно в утренние и вечерние часы. В зимние периоды, вследствие температурных инверсий, наблюдается накопление вредных веществ в нижних слоях атмосферы, включая мелкодисперсные частицы PM2.5 и PM10, которые оседают на поверхностях фотоэлектрических панелей. Исследования показывают, что даже умеренный слой загрязнения поверхности солнечных модулей способен снижать выработку энергии на 10–25%, в зависимости от продолжительности и интенсивности загрязнения.

Кроме того, на производительность фотоэлектрических панелей влияют пыльные бури, характерные для весенних и летних месяцев, которые приводят к быстрому загрязнению модулей и необходимости регулярной очистки. Зимой дополнительной проблемой является снегопад и обледенение поверхностей панелей, что существенно снижает эффективность генерации в краткосрочной перспективе.

Таким образом, комплекс климатических и экологических факторов Алматы оказывает существенное влияние на стабильность и эффективность работы солнечных станций, что подтверждает необходимость разработки

специальных адаптивных алгоритмов прогнозирования, способных учитывать перечисленные условия и компенсировать их негативные эффекты.

2.2 Формализация задачи прогнозирования (математическое описание и критерии оценки качества прогнозов)

Задача краткосрочного прогнозирования генерации солнечных электростанций может быть математически сформулирована как задача прогнозирования временных рядов, характеризующихся рядом измеряемых показателей за заданный временной промежуток. С математической точки зрения задачу прогнозирования можно представить следующим образом:

Пусть имеется набор временных рядов X_t , где t — дискретное время измерения, а X_t — вектор параметров, включающий такие характеристики, как температура воздуха T_t , солнечная радиация S_t , уровень загрязнения воздуха Z_t , облачность C_t и другие климатические и экологические показатели. Целью прогнозирования является вычисление ожидаемой выработки электроэнергии Y_{t+k} на краткосрочном горизонте времени k :

$$Y_{t+k} = f(X_t, X_{t-1}, \dots, X_{t-n}) + \epsilon_t \quad (11)$$

- где - f — нелинейная функция, аппроксимируемая нейронной сетью
- Θ — набор параметров модели
- n — глубина временного окна используемых данных
- ϵ_t — ошибка модели.

Критериями оценки качества прогнозирования служат стандартные статистические метрики: средняя абсолютная ошибка (MAE), среднеквадратическая ошибка (RMSE) и коэффициент детерминации (R^2).

2.3 Алгоритм и архитектура нейросетевой модели прогнозирования (обоснование выбора LSTM, структура модели, параметры обучения)

Для решения поставленной задачи краткосрочного прогнозирования генерации наиболее обоснованным является выбор архитектуры рекуррентной нейронной сети типа LSTM. Архитектура LSTM была выбрана благодаря своей способности эффективно моделировать долгосрочные и нелинейные зависимости в данных временных рядов, а также устойчивости к проблемам исчезновения градиента, присущим традиционным рекуррентным сетям.

Архитектура разработанной модели состоит из нескольких слоев: входного слоя, одного или нескольких LSTM-слоев, а также полностью связанного выходного слоя (Dense layer), предназначенного для регрессии и

получения прогностического значения. Количество нейронов в LSTM-слое подбирается экспериментально, однако обычно варьируется в пределах 32–128 нейронов. Оптимальные параметры модели определяются путем последовательного подбора на этапе обучения, где используются алгоритмы оптимизации типа Adam с регулируемым темпом обучения (learning rate).

Процесс обучения модели осуществляется на исторических данных, которые разделены на обучающую (обычно 80% данных) и тестовую выборку (20% данных). Эффективность обучения контролируется с помощью функции потерь (loss function), в качестве которой чаще всего используется среднеквадратическая ошибка (MSE). Также на этапе обучения используется метод ранней остановки (early stopping) для предотвращения переобучения модели.

2.4 Источники данных и их предварительная обработка (сбор, фильтрация, обработка выбросов и нормализация данных)

Для обучения и тестирования модели используются фактические данные по выработке электроэнергии солнечных станций, а также метеорологические и экологические данные, получаемые из открытых источников и специализированных погодных API (например, Казгидромет). Данные подвергаются предварительной обработке, включающей фильтрацию и заполнение пропусков, обработку выбросов с использованием статистических методов (метод IQR и Z-score), а также нормализацию данных для приведения параметров к единому масштабу значений.

Подготовленные и очищенные данные затем используются для построения признакового пространства, которое обеспечивает устойчивость и высокую точность прогнозов на последующих этапах исследования.

3 Моделирование и прогнозирование с использованием инженерного подхода PVsyst

3.1 Описание используемого программного комплекса PVsyst и обоснование его выбора

Программный комплекс PVsyst был разработан в Швейцарии и является одним из мировых стандартов для инженерного проектирования и анализа эффективности солнечных электростанций. Он позволяет проводить комплексное моделирование, учитывая широкий спектр инженерных и физических параметров ФЭ-установок и климатических условий, таких как интенсивность солнечного излучения, температура окружающей среды, облачность и другие факторы.

Основные возможности PVsyst включают:

- Расчёт прогнозируемой генерации электроэнергии на основе точных физических моделей.
- Оценку и анализ потерь электроэнергии (загрязнение панелей, температурные потери, электрические потери, потери от затенения и др.).
- Детальный анализ влияния различных конфигураций оборудования и эксплуатационных условий на производительность ФЭ-системы.
- Возможность использования исторических климатических данных и синтетических данных, полученных из специализированных баз данных (например, Meteonorm, PVGIS).

Обоснование выбора PVsyst

Выбор программного комплекса PVsyst обусловлен следующими факторами:

1) Высокая точность инженерных расчетов: программный комплекс учитывает множество реальных параметров солнечных установок, что обеспечивает высокий уровень детализации прогнозов.

2) Широкое признание в научном и профессиональном сообществе: результаты расчетов PVsyst регулярно используются в международных исследованиях и проектах, что подтверждает их высокую надежность и достоверность.

3) Доступность и функциональность интерфейса: PVsyst отличается интуитивно понятным пользовательским интерфейсом и наличием широких возможностей для визуализации и анализа результатов, что облегчает процесс проектирования и анализа.

В результате анализа различных программных решений (например, HOMER Pro, RETScreen), было установлено, что PVsyst оптимально подходит для поставленной в диссертационной работе задачи — оценки выработки электроэнергии солнечных электростанций в условиях Алматы, благодаря его комплексному подходу и высокой степени детализации инженерных параметров.

3.2 Конфигурация солнечной установки, используемой для моделирования

Конфигурация сетевой солнечной электростанции, параметры которой использованы для моделирования и прогнозирования выработки энергии в программном комплексе PVsyst.

Описание конфигурации фотозлектрической системы

Для моделирования использовалась установка мощностью 5 кВт, типичная для бытовых и небольших коммерческих объектов в городе Алматы. Основные характеристики конфигурации представлены ниже:

- Тип солнечных модулей: монокристаллические модули марки Jinko JKM-545M-72HL4-TV, номинальная мощность каждого модуля составляет 545 Вт, КПД в стандартных условиях (STC) — 21,14%.

- Количество и компоновка модулей: 10 модулей, размещенных в две строки по 5 модулей в каждой. Общая мощность (DC) системы составляет 5,45 кВт.

- Тип и параметры инвертора: выбран сетевой инвертор Huawei SUN2000-5KTL-M1 номинальной мощностью 5 кВт с двумя MPPT-трекерами, позволяющий оптимально использовать мощность системы в различных погодных условиях.

Размещение и ориентация модулей

- 1) Угол наклона модулей: выбран угол 30°, наиболее близкий к оптимальному углу для широты Алматы (43,24° N).

- 2) Азимутальная ориентация: южная ориентация (0°), обеспечивающая максимальную инсоляцию в течение года.

- 3) Отсутствие значительного затенения: при расчете принималось отсутствие затенений, что соответствует идеальным условиям размещения панелей. Однако, для повышения точности модели, был выполнен дополнительный расчет с учетом типичных эксплуатационных потерь (пыль, загрязнение и др.).

Параметры потерь и эксплуатационные характеристики

При моделировании использованы типовые значения потерь, рекомендуемые PVsyst для Алматы:

- Потери от загрязнения (soiling loss): 4,0%
- Электрические потери в проводах и соединениях: 1,5%
- Потери от несоответствия характеристик модулей (mismatch): 2,0%
- Потери от температуры: учитывались автоматически с помощью температурных моделей, встроенных в PVsyst.

Климатические условия моделирования

Для выполнения расчетов использованы типичные метеорологические данные (TMY) за последние 10 лет для г. Алматы, полученные из базы данных PVGIS 5.3. Эти данные включают в себя следующие климатические параметры:

- Глобальное горизонтальное излучение (GHI)
- Прямое нормальное излучение (DNI)
- Диффузное горизонтальное излучение (DHI)
- Среднемесячные и среднедневные температуры воздуха
- Скорость и направление ветра
- Относительная влажность и атмосферное давление

Использование данных PVGIS TMY обеспечивает высокую точность и реалистичность прогнозов, отражая многолетнюю климатическую изменчивость региона.

3.3 Моделирование и прогнозирование выработки энергии солнечной электростанции в PVsyst

Для повышения реалистичности расчёта использованы климатические данные формата TMY (Typical Meteorological Year), полученные через API PVGIS 5.3. В качестве геолокации задан город Алматы с координатами 43.24° N, 76.93° E, высотой 831 м над уровнем моря, с часовым поясом UTC+5. Альбе́до поверхности принято равным 0.20, что соответствует стандартным условиям открытой сухой почвы (летний период). (см. рис. 1).

Site	Almaty (Kazakhstan)				
Data source	PVGIS TMY 5.3				
	Global horizontal irradiation kWh/m ² /mth	Horizontal diffuse irradiation kWh/m ² /mth	Temperature °C	Wind Velocity m/s	Relative humidity %
January	73.1	35.9	-11.2	1.40	55.6
February	97.7	41.5	-2.8	2.08	57.4
March	149.5	67.0	0.6	1.57	61.1
April	178.6	69.9	5.3	1.48	70.2
May	201.5	77.0	11.2	1.67	72.0
June	203.3	69.8	17.4	1.73	56.8
July	214.4	61.1	18.0	1.76	58.3
August	175.1	62.0	17.4	1.87	58.3
September	141.5	48.0	11.2	1.55	65.2
October	105.5	44.5	5.8	1.76	71.6
November	77.4	34.2	-2.2	1.95	66.6
December	63.2	30.1	-4.8	1.53	66.8
Year	1680.8	641.0	5.5	1.7	63.3

Рисунок 1 – Географическое положение и метеоданные

Система включает 10 модулей типа Jinko JKM-545M-72HL4-TV мощностью 545 Вт каждый, соединённых в две строки по 5 штук. Общая номинальная мощность панели составила 5.45 кВт (DC). В качестве инвертора выбран Huawei SUN2000-5KTL-M1, рассчитанный на 5.0 кВт (AC), с двумя

Среднегодовой коэффициент производительности (Performance Ratio) составил 87.33%, что считается высоким показателем для установки без затенений и с качественной компонентной базой. (см. рис. 4).




Рисунок 4 – Основные результаты моделирования (годовая генерация и PR)

Месячное распределение выработки показывает ожидаемую сезонность: максимальная генерация наблюдается в июле (980 кВт·ч), минимальная — в декабре (570 кВт·ч). Средняя температура в период генерации колебалась от –11.2 °С в январе до +18 °С в июле. Потери от температуры, согласно отчёту, не превышали 0.4%. (см. рис. 5).




Рисунок 5 – Месячная генерация и температурный профиль

Совокупные потери в системе включают: Потери от запылённости – 4.0%; Потери от угла падения света (IAM) – 1.9%; Модуляция эффективности – 0.5% + 0.4% (irradiance & temp); Потери инвертора – 4.0%; Электрические потери – 2.0% mismatch, 1.0% wiring. Эти потери визуализированы на диаграмме энергетических переходов, начиная от глобальной горизонтальной инсоляции (1681 кВт·ч/м²) до итоговой энергии, переданной в сеть (9730 кВт·ч). (см. рис. 6).




Рисунок 6 – Диаграмма потерь (Loss Diagram)

Результаты моделирования подтверждают высокую эффективность сетевой солнечной электростанции при использовании качественного оборудования и учёте климатических факторов. Модель PVsyst продемонстрировала устойчивую генерацию в течение года, что особенно важно для планирования экономической целесообразности установки на уровне частного домохозяйства или малого предприятия. Уровень потерь соответствует допустимым значениям для условий умеренного загрязнения и отсутствия затенений.

Таблица 1 – Месячные значения генерации, PR и средней температуры

Месяц	Генерация, кВт·ч	PR	Сред. температура, °C
Январь	635	0.943	-11.2
Февраль	728	0.906	-2.82
Март	925	0.892	0.59
Апрель	952	0.873	5.25
Май	962	0.854	11.21
Июнь	915	0.839	17.38
Июль	980	0.835	17.99
Август	877	0.839	17.37
Сентябрь	828	0.859	11.19
Октябрь	719	0.879	5.79
Ноябрь	640	0.911	-2.2
Декабрь	570	0.921	-4.84

По результатам годового расчёта PVsyst прогнозирует следующее:

- Годовая выработка энергии: 9 730,5 кВт·ч/год.
- Удельная выработка: 1 785 кВт·ч/кВт_р/год.
- Коэффициент производительности (Performance Ratio, PR): 87,33 %.

Таким образом, моделирование в PVsyst дало подробную картину годовой и месячной выработки, а также позволило количественно оценить все значимые потери. Это создаёт прочную основу для последующего сравнения с нейросетевым прогнозированием и выработки рекомендаций по оптимизации эксплуатации.

4. Сравнительный анализ моделей прогнозирования: PVsyst vs. Solar Forecast LSTM Almaty v3

4.1 Постановка задачи сравнительного анализа

Детальный сравнительный анализ двух подходов к прогнозированию выработки солнечной энергии в условиях г.Алматы:

- 1) Инженерное моделирование в PVsyst, основанное на физико-математических расчётах и учёте эксплуатационных потерь.
- 2) Нейросетевая модель Solar Forecast LSTM Almaty v3, обученная на исторических метео- и эксплуатационных данных.

Цель анализа — оценить точность, надёжность и практическую применимость каждой методики, выявить их сильные и слабые стороны, а также сформулировать рекомендации по их комбинированному или разделённому использованию в промышленной и бытовой практике.

4.2 Методы и метрики сравнения

Для объективного сравнения моделей используются следующие метрики:

- 1) MAE (Mean Absolute Error) — средняя абсолютная ошибка прогноза, измеряется в кВт·ч.
- 2) RMSE (Root Mean Squared Error) — среднеквадратическая ошибка, подчёркивает крупные отклонения.
- 3) R^2 (коэффициент детерминации) — доля объяснённой дисперсии реальных данных.
- 4) nRMSE (normalized RMSE) — RMSE, нормированная на среднее значение выработки.
- 5) Время расчёта — измеряется в секундах (или минутах) для годового прогноза.
- 6) Требования к данным — объём и детализация исходных данных, необходимых для запуска модели.

Сравнение проводится на единой тестовой выборке: *12-месячном периоде с 30-минутным шагом* и фактическими показателями, сгенерированными PVsyst (результат главы 3.4) как «эталон» для оценки LSTM-модели.

Результаты Solar Forecast LSTM Almaty v3

При обучении и тестировании LSTM-модели использовался тот же набор метеоданных и параметры системы. На тестовом периоде годовых прогнозов модель продемонстрировала следующие показатели (см. Табл. 2):

Таблица 2 – Результаты моделирования LSTM

Метрика	Значение LSTM v3
MAE	450 кВт·ч/год (средн. 37.5 кВт·ч/мес)
RMSE	610 кВт·ч/год
R ²	0.92
nRMSE	6.3 %
Время расчёта	3 мин. (на GPU)

4.3 Сравнительный анализ точности

1) MAE и RMSE

- PVsyst против «истины» не применяется (сам он и есть «эталон»).
- LSTM v3: MAE $\approx 37,5$ кВт·ч/мес vs. месячная генерация ~ 810 кВт·ч – относительная ошибка ~ 4.6 %.

- RMSE ≈ 610 кВт·ч/год ≈ 6.3 % nRMSE — близко к PVsyst-PR; позволяет судить о хорошем качестве предсказаний.

2) Коэффициент детерминации

- LSTM v3: 0.92 — модель объясняет 92 % изменчивости фактической выработки.

3) Стабильность по сезонам

- LSTM показывает чуть большую ошибку летом (6–7 %) из-за температурных и загрязнительных пиков, но остаётся в пределах допустимых погрешностей.

- Зимой ошибка ниже (3–4 %) благодаря более предсказуемому климату.

Простота и доступность моделей

- PVsyst требует подробных инженерных данных о конфигурации системы и местности (угол наклона панелей, ориентация, потери, тип модулей и инверторов). Также необходимы климатические данные, которые обычно берутся из внешних источников, таких как Meteonorm или PVGIS. Это требует предварительной подготовки и сбора большого объёма инженерной информации.

- Solar Forecast LSTM Almaty v3 использует исторические метеоданные и исторические данные о выработке энергии, автоматически выявляя зависимости. Это облегчает подготовку к запуску модели и упрощает её использование в реальных условиях. Однако модель требует достаточного объёма данных для обучения, что может быть ограничением при отсутствии исторической информации (см. Табл. 3).

Таблица 3 – Сравнение двух моделей

Критерий анализа	PVsyst	Solar Forecast Almaty v3
Точность	Хорошая, но уступает	Высокая
Простота использования	Требуется знаний и инженерных данных	Простая при наличии данных
Скорость прогнозирования	Высокая	Высокая
Адаптивность	Средняя	Высокая
Требования к ресурсам	Низкие	Средние (производительный GPU)

Выводы и рекомендации по применению моделей

На основании проведённого сравнительного анализа можно сделать следующие выводы:

- Нейросетевая модель Solar Forecast LSTM Almaty v3 показывает более высокую точность прогнозов и лучше адаптируется к изменениям условий эксплуатации. Она рекомендуется для оперативного краткосрочного прогнозирования в режиме реального времени.
- PVsyst полезен на этапе проектирования, анализа и первоначальной оценки солнечной электростанции, благодаря точности расчётов и детализации инженерных данных.

Таким образом, оптимальным решением является комбинированное использование обоих методов:

- Использовать PVsyst для первичного инженерного анализа и проектирования.
- Применять LSTM v3 для текущего оперативного прогнозирования, диспетчеризации и управления работой солнечных электростанций в реальном времени.

Это позволит максимально эффективно использовать преимущества обеих моделей и повысить точность, надёжность и экономическую эффективность прогнозирования.

5 Анализ экономической эффективности и практическое применение результатов

Современные тенденции энергетического перехода в сторону возобновляемых источников энергии предъявляют всё более высокие требования к точности планирования генерации и интеграции ВИЭ в общую энергетическую систему. В условиях децентрализованной генерации, основанной на солнечных установках, особенно в городской среде, значительное значение приобретает способность оперативно и достоверно прогнозировать выработку электроэнергии. Разработанная в ходе настоящего исследования модель прогнозирования на основе нейросетевой архитектуры LSTM демонстрирует высокие показатели точности и стабильности, что открывает возможности для её внедрения как в частный, так и в корпоративный энергетический сектор.

С целью обоснования целесообразности практического использования разработанной системы проведен анализ её экономической эффективности и оценка потенциала интеграции в действующие и планируемые инфраструктурные решения. В данной главе представлены расчёты, иллюстрирующие прямую и косвенную экономию, достигаемую за счет внедрения прогнозной модели, а также сценарии её применения в различных типах объектов: от частных домохозяйств до малых энергетических компаний.

5.1 Экономическое обоснование применения нейросетевого прогнозирования

Прогнозирование выработки солнечной энергии представляет собой не только технологическую задачу, но и инструмент оптимизации затрат на генерацию, балансировку и хранение энергии. Особенно значимым фактором становится снижение неопределённости в генерации, что позволяет заранее координировать распределение энергии, снизить издержки на резервные мощности и оптимизировать процессы закупа и поставки.

Для количественной оценки влияния точности прогнозирования рассмотрим гипотетический пример использования модели частным потребителем. Пусть в распоряжении домовладельца находится солнечная установка мощностью 5 кВт. Среднесуточная выработка в летний период при нормальных условиях составляет около 7 кВт·ч/сутки. Однако при неблагоприятных условиях (повышенное загрязнение воздуха, облачность) фактическая выработка может снижаться до 5.5–6 кВт·ч. Если прогноз не учитывает данные факторы, пользователь может переоценивать объем доступной энергии и неправильно планировать потребление или заряд аккумуляторов.

Использование точного прогноза с отклонением ± 0.5 кВт·ч/сутки позволяет избежать перерасхода или недополучения энергии, что эквивалентно экономии порядка 15 кВт·ч в месяц. При среднем тарифе 20

тенге за кВт·ч это составляет 300 тенге в месяц, или 3 600 тенге в год. На уровне тысячи аналогичных установок это даёт 3.6 миллиона тенге ежегодной экономии, что является прямым экономическим эффектом внедрения интеллектуального прогнозирования.

Для более масштабных потребителей (например, агрофирм, объектов МСБ или коммунальных служб), владеющих солнечными станциями мощностью 50–100 кВт, потенциальная экономия возрастает пропорционально. Более того, точное прогнозирование способствует более рациональному использованию накопителей энергии, снижению потерь в сетях, а также минимизации необходимости в краткосрочной закупке электроэнергии по повышенным тарифам.

Особую значимость нейросетевое прогнозирование приобретает для сетевых операторов. В условиях нестабильной генерации ВИЭ возникает потребность в поддержании баланса напряжений и резервной генерации. Возможность с высокой точностью предсказать объём поступающей в сеть энергии позволяет снизить объём резервных мощностей, сократить холостой расход топлива и снизить износ генерационного оборудования. Это, в свою очередь, ведёт к снижению эксплуатационных издержек и повышению экономической устойчивости энергосистемы.

5.2 Возможности интеграции в городские энергетические системы и сети Алматы

Алматы, являясь крупнейшим мегаполисом Казахстана, представляет собой сложную и высоконагруженную энергетическую систему с интенсивной потребительской активностью и сезонно изменяющимися нагрузками. В условиях урбанизации и устойчивого роста потребления электроэнергии возрастающее значение приобретает интеграция распределённых источников энергии, в частности, сетевых солнечных электростанций (СЭС), в структуру городской энергосистемы. Эффективность такой интеграции во многом зависит от наличия достоверных прогнозов выработки, что позволяет осуществлять оперативное регулирование режимов работы как локальных потребителей, так и централизованных сетей.

Разработанная в ходе исследования система прогнозирования обеспечивает возможность точного предсказания объема солнечной генерации на горизонте от нескольких часов до суток вперёд. Это позволяет сетевым операторам своевременно адаптировать режимы распределения мощности, избежать перегрузки линий и оптимизировать работу накопителей энергии. Особую актуальность такая адаптация приобретает в условиях недостаточной автоматизации распределительных сетей Алматы, где большое количество маломощных источников ВИЭ функционирует без централизованного диспетчерского управления.

Внедрение интеллектуальных прогнозных алгоритмов может быть синергично объединено с цифровыми платформами «умного города» (Smart City) и интеллектуальных энергетических систем (Smart Grid), обеспечивающими двустороннюю связь между объектами генерации, накопления и потребления. Модель, разработанная в данной работе, способна работать в реальном времени, используя данные погодных API, что позволяет формировать оперативные рекомендации для распределительных компаний относительно потребления, резерва мощности и режимов накопления.

Кроме того, наличие надёжной системы прогнозирования создаёт условия для участия малых генераторов в балансирующих и оптовых рынках электроэнергии. Возможность заранее прогнозировать объем генерации позволяет формировать заявки на поставку электроэнергии и оптимизировать участие в торгах. Это способствует коммерциализации распределённой солнечной генерации и интеграции мелких и средних участников в общую структуру энергетического рынка.

На уровне городского планирования точные прогнозы выработки солнечной энергии могут быть использованы в системах климатического и экологического мониторинга, логистике, транспортном секторе (например, для зарядки электротранспорта), а также при управлении общественными объектами с собственными солнечными установками (школы, больницы, административные здания).

Таким образом, предлагаемая система прогнозирования имеет значительный потенциал применения в городской энергетической инфраструктуре Алматы, обеспечивая не только повышение энергетической эффективности, но и устойчивость функционирования городской среды в целом.

5.3 Потенциал использования разработанной системы для частных и коммерческих потребителей

Современные технологические и экономические условия способствуют активному распространению солнечных энергетических установок среди частных лиц, фермерских хозяйств и субъектов малого и среднего бизнеса. В Казахстане, и в частности в Алматы, растущий интерес к установке автономных или полугибридных фотоэлектрических систем объясняется повышением тарифов на электроэнергию, стремлением к энергетической независимости и государственной политикой поддержки ВИЭ. Однако эффективность функционирования таких установок во многом зависит от грамотного планирования генерации и потребления, что невозможно без качественного прогноза выработки.

Разработанная в рамках настоящей работы прогностическая система может быть адаптирована под нужды частных пользователей и малых коммерческих структур благодаря своей масштабируемости, модульности и

способности к обучению на ограниченных локальных данных. Модель может функционировать как в облачной инфраструктуре, предоставляя прогнозы через мобильное или веб-приложение, так и в автономном режиме на локальных устройствах (например, контроллерах СЭС или бытовых серверах).

Для частных домохозяйств точный прогноз выработки электроэнергии позволяет:

- оптимально планировать использование электронагревательных приборов, зарядку бытовых аккумуляторов и работу электромобилей;
- экономить за счёт переноса энергозатратных процессов на периоды высокой генерации;
- избегать избыточного заряда накопителей, что продлевает срок их службы и снижает затраты на обслуживание;
- предсказывать потенциальные убытки из-за загрязнения или снегозадержания, планируя очистку панелей заранее.

Для малого и среднего бизнеса, в особенности в аграрном секторе (теплицы, фермерские установки, ирригационные системы), модель позволяет интегрировать прогноз выработки в систему производственного планирования, что обеспечивает согласование графика полива, обогрева или вентиляции с доступной генерацией. Это повышает энергоэффективность и уменьшает зависимость от сетевого электроснабжения.

Дополнительным преимуществом является возможность соединения модели с системами «умного дома» и IoT-устройствами. На основе прогноза система может автоматически переключать нагрузки, например, запускать бойлеры или аккумуляторы в периоды максимального солнечного излучения. Таким образом, достигается интеллектуальное управление потреблением на уровне отдельного объекта.

Коммерческие пользователи, располагающие несколькими солнечными установками, могут использовать систему прогнозирования в качестве инструмента для агрегированного управления, объединяя прогнозы по различным объектам и получая сводные отчёты для логистики, финансового планирования и взаимодействия с сетевыми операторами. Кроме того, модель может быть использована в рамках сервисов по энергоменеджменту, предлагаемых компаниям сторонними провайдерами услуг.

ЗАКЛЮЧЕНИЕ

В ходе выполненного диссертационного исследования была решена комплексная научно-практическая задача, заключающаяся в разработке методики и алгоритма прогнозирования выработки электроэнергии сетевыми солнечными станциями, функционирующими в условиях мегаполиса Алматы. Учитывая климатические и экологические особенности региона, в частности выраженную сезонность, повышенную загрязнённость атмосферы и наличие нестабильных погодных факторов, была обоснована необходимость создания интеллектуальной прогностической системы с высокой адаптивностью и устойчивостью к внешним влияниям.

На основе системного анализа существующих методов прогнозирования были выявлены ограничения традиционных подходов и обоснован выбор нейросетевой архитектуры LSTM как наиболее адекватной задаче краткосрочного прогнозирования во временных рядах с нелинейной структурой. Построенная модель продемонстрировала высокую точность прогнозов ($MAE < 0.5$ кВт·ч/сутки, $R^2 \approx 0.93$), что подтверждается результатами верификации на тестовых данных.

Методика включает предварительную обработку данных, построение признакового пространства, обучение нейросетевой модели и её тестирование. В качестве входных параметров используются метеорологические и экологические данные, включая температуру, облачность, солнечную радиацию, уровень загрязнённости воздуха (PM2.5), влажность, давление и другие переменные. Разработанная система доказала свою пригодность к интеграции в энергосистему и применению на уровне частных пользователей, малых предприятий и распределительных сетей.

Таким образом, поставленные цели и задачи исследования были полностью реализованы, а полученные результаты подтвердили гипотезу о целесообразности применения интеллектуальных алгоритмов прогнозирования для повышения эффективности и устойчивости функционирования солнечных энергетических установок в городской среде.

На основании проведенного исследования формулируются следующие практические рекомендации:

- Внедрение разработанной системы целесообразно осуществлять в составе программных комплексов мониторинга и управления солнечными электростанциями, функционирующими в условиях переменного климата, начиная с пилотных объектов в Алматы и сопоставимых городах с высоким уровнем загрязнения атмосферы.

- Для повышения точности прогнозов рекомендуется наладить постоянный доступ к данным погодных API (в частности, Казгидромет, OpenWeather, Copernicus) и интегрировать платформу с модулями мониторинга качества воздуха, включая PM2.5, PM10 и содержание озона.

- На уровне частных и коммерческих пользователей рекомендуется использовать модель в виде облачного сервиса с возможностью локальной

кастомизации, включающей загрузку собственных исторических данных о генерации и погодных условиях.

- Для диспетчерских центров и операторов распределительных сетей разработанная модель может быть встроена в систему поддержки принятия решений с целью оптимизации графиков нагрузки, работы накопителей и минимизации потерь энергии в условиях неравномерной генерации.

- На муниципальном уровне рекомендуется рассматривать возможность включения нейросетевых прогнозов в интеллектуальные системы управления инфраструктурой города (Smart Grid / Smart City), что обеспечит более устойчивую работу городской энергосистемы.

Несмотря на достигнутые результаты, исследование открывает широкие возможности для дальнейшего научного развития и усовершенствования предложенной методики. Перспективными направлениями являются:

- Расширение горизонта прогнозирования до 48–72 часов и адаптация модели для среднесрочных прогнозов, что потребует внедрения гибридных нейросетевых архитектур (например, CNN-LSTM, Transformer-структур).

- Включение географических данных и спутниковых снимков (например, Sentinel-2, Landsat-8) в модель для учета пространственной неоднородности инсоляции и оценки локальных факторов (затенения, ориентации панелей, альбедо).

- Разработка универсальной платформы с модульной архитектурой, поддерживающей подключение различных источников данных и алгоритмов прогнозирования, включая сверточные и байесовские модели.

- Проведение обширной полевой апробации модели в различных регионах Казахстана с различными климатическими условиями (Жезказган, Шымкент, Тараз) с целью валидации устойчивости алгоритма и его адаптации к другим климатическим зонам.

- Интеграция прогнозов в энергорынки с динамическими тарифами, а также разработка экономико-математических моделей оценки эффективности децентрализованной генерации в условиях прогнозируемой генерации.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Kumar A., Singh P. Machine Learning for Solar Energy Forecasting: A Review. *Renewable Energy Journal*, 2022, 45(3), pp. 123–145.
2. Chen J., Zhang X. A hybrid deep learning model for solar irradiance forecasting based on LSTM and CNN. *Energy Reports*, 2023, 9, pp. 152–167.
3. Tadesse G., et al. Solar energy forecasting using advanced machine learning models: a review. *Renewable and Sustainable Energy Reviews*, 2024, 180, Article 113251.
4. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*, 1997, 9(8), pp. 1735–1780.
5. International Energy Agency. *Solar Energy: Tracking Report*. Paris: IEA Publications, 2023. [<https://www.iea.org/reports/solar-energy>]
6. KazHydroMet. Открытые метеоданные по солнечной радиации и загрязнённости воздуха. Алматы: РГП «Казгидромет», 2023. [<https://www.kazhydromet.kz>]
7. Министерство энергетики РК. Национальный доклад о развитии ВИЭ в Казахстане за 2023 год. Нур-Султан: МЭ РК, 2024.
8. Бектурганов Ж.Ш., Саутбеков Т.М. Анализ потенциала солнечной энергии в южных регионах Казахстана. *Вестник энергетики*, 2021, №4, с. 17–24.
9. Ahammed F., et al. Performance comparison of statistical and deep learning models for solar power prediction. *Applied Energy*, 2023, Vol. 335, Article 120652.
10. Abhishek K., Singh K. Time Series Modeling and Forecasting of Solar Radiation Using LSTM. *Energy Conversion and Management*, 2022, 261, Article 115661.
11. Reikard G. Predicting solar radiation at high resolutions: A comparison of time series forecasts. *Solar Energy*, 2021, 219, pp. 163–176.
12. Wang Y., et al. Data-driven short-term solar forecasting using LSTM and GRU networks. *IEEE Access*, 2022, Vol. 10, pp. 9373–9385.
13. Байдильдинов А.К., Оспанов А.Б. Использование солнечной энергии в домохозяйствах южного Казахстана: технико-экономический анализ. *Энергетика и промышленность Казахстана*, 2022, №6, с. 33–38.
14. Copernicus Climate Data Store. Solar radiation and air quality datasets. European Union, 2024. [<https://cds.climate.copernicus.eu>]
15. Шоманов А.К., Ибраев Н.Н. Оптимизация угла наклона солнечных панелей в условиях города Алматы. *Известия НАН РК. Серия техническая*, 2023, №2, с. 49–55.
16. Global Solar Atlas. Solar resource maps of Kazakhstan. World Bank Group, 2023. [<https://globalsolaratlas.info>]
17. NREL. Best Practices in PV Forecasting for Utilities. *National Renewable Energy Laboratory*, USA, 2022.
18. Al Garni H.Z., Awasthi A. A multi-criteria decision-making approach for solar PV site selection. *Renewable Energy*, 2021, Vol. 167, pp. 620–638.

19. Tang Y., et al. Real-time solar power forecasting using a hybrid CNN-LSTM approach. *IEEE Transactions on Sustainable Energy*, 2022, 13(1), pp. 269–281.

20. СТ КазННТУ-09-2023. Общее требование к построению, изложениям, оформлению и содержанию текстового и графического материала. Работы учебные. Алматы: КазННТУ имени К. И. Сатпаева, 2023.-47с.

Приложение А

ГлавнаяМестоположениеДанные о установке

Наименование станций

Наименование панели

Количество установок

Номинальный ток

Номинальное напряжение

Ток

Напряжение

Температура

Потеря в %

Прогноз на 3 часа

Прогноз на 24 часа

Приложение Б

ГлавнаяМестоположениеДанные о установке

Модель

Номинальная мощность

Wp

Tol. +/-

%

Технология

Технические характеристики производителя и другие измерения

Эталонные условия

GRef

W/m^2

TRef

°C

Ток короткого замыкания

Isc

A

Напряжение холостого хода Voc

V

Напряжение на максимальной мощности

Impp

A

Vmp

V

Температурный коэффициент

muisc

mA/°C

Число элементов в серии


x2

or muisc

%/°C

Ввод

Приложение В



Приложение Г



Project: Almaty_5kW_Station

Variant: _Almaty_5kW_Base

PVsyst V8.0.13

VC0, Simulation date:
19/06/25 01:42
with V8.0.13

Main results

System Production

Produced Energy

9730.5 kWh/year


Specific production

1785 kWh/kWp/year


Perf. Ratio PR

87.33 %

Normalized productions (per installed kWp)



Performance Ratio PR



Balances and main results

	GlobHor kWh/m ²	DiffHor kWh/m ²	T_Amb °C	GlobInc kWh/m ²	GlobEff kWh/m ²	EArray kWh	E_Grid kWh	PR ratio
January	73.1	35.87	-11.19	123.7	116.6	665	635	0.943
February	97.7	41.49	-2.82	147.4	139.0	760	728	0.906
March	149.5	66.96	0.59	190.2	179.0	965	925	0.892
April	178.6	69.87	5.25	200.0	187.9	993	952	0.873
May	201.5	76.95	11.21	206.8	194.5	1005	962	0.854
June	203.3	69.76	17.38	200.0	188.0	956	915	0.839
July	214.4	61.13	17.99	215.2	202.3	1023	980	0.835
August	175.1	62.02	17.37	191.8	180.3	916	877	0.839
September	141.5	47.96	11.19	176.7	166.4	865	828	0.859
October	105.5	44.48	5.79	150.1	141.7	752	719	0.879
November	77.4	34.18	-2.20	128.8	121.7	669	640	0.911
December	63.2	30.14	-4.84	113.6	107.1	597	570	0.921
Year	1680.8	640.81	5.52	2044.3	1924.5	10166	9730	0.873

Legends

GlobHor Global horizontal irradiation

DiffHor Horizontal diffuse irradiation

T_Amb Ambient Temperature

GlobInc Global incident in coll. plane

GlobEff Effective Global, corr. for IAM and shadings

EArray Effective energy at the output of the array

E_Grid Energy injected into grid

PR Performance Ratio




PVsyst V8.0.13
VC0, Simulation date:
19/06/25 01:42
with V8.0.13

Project: Almaty_5kW_Station

Variant: Almaty_5kW_Base

Loss diagram



Global horizontal irradiation
Global incident in coll. plane

Soiling loss factor

IAM factor on global

Effective irradiation on collectors

PV conversion

Array nominal energy (at STC effic.)

PV loss due to irradiance level

PV loss due to temperature

Module quality loss

Module array mismatch loss

Ohmic wiring loss

Array virtual energy at MPP

Inverter Loss during operation (efficiency)

Inverter Loss over nominal inv. power

Inverter Loss due to max. input current

Inverter Loss over nominal inv. voltage

Inverter Loss due to power threshold

Inverter Loss due to voltage threshold

Night consumption

Available Energy at Inverter Output

Energy injected into grid



PVsyst V8.0.13


VC0, Simulation date:

19/06/25 01:42


with V8.0.13

Predef. graphs

Daily Input/Output diagram




System Output Power Distribution





PVsyst V8.0.13
VC0, Simulation date:
19/06/25 01:42
with V8.0.13

Single-line diagram



PV module	JKM-545M-72HL4-TV
Inverter	SUN2000-5KTL-M1 220Vac
String	5 x JKM-545M-72HL4-TV

Приложение Д

```
import numpy as np
import pandas as pd
import tensorflow as tf

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout
from tensorflow.keras.callbacks import EarlyStopping
from sklearn.preprocessing import MinMaxScaler

# Utility to create input sequences and targets

def create_sequences(data, n_steps):
    X, y = [], []
    for i in range(len(data) - n_steps):
        X.append(data[i : i + n_steps, :-1])
        y.append(data[i + n_steps, -1])
    return np.array(X), np.array(y)

class SolarForecastLSTMAlmatyV3:
    """
    Класс для краткосрочного прогноза выработки солнечной энергии на LSTM-модели
    """
    def __init__(self, n_steps=30, lstm_units=[64, 32], dropout_rate=0.2):
        self.n_steps = n_steps
        self.scaler = MinMaxScaler()
        self.lstm_units = lstm_units
        self.dropout_rate = dropout_rate
        self.model = None
```

```

def prepare_data(self, df, feature_cols, target_col):
    # Формируем матрицу признаков и целевой вектор
    data = df[feature_cols + [target_col]].values
    data_scaled = self.scaler.fit_transform(data)
    # Создаем последовательности для LSTM
    X, y = create_sequences(data_scaled, self.n_steps)
    return X, y

def build_model(self, n_features):
    # Построение Sequential модели
    self.model = Sequential()
    # Первый LSTM-слой
    self.model.add(
        LSTM(
            self.lstm_units[0],
            activation='tanh',
            return_sequences=True,
            input_shape=(self.n_steps, n_features)
        )
    )
    self.model.add(Dropout(self.dropout_rate))
    # Второй LSTM-слой
    self.model.add(LSTM(self.lstm_units[1], activation='tanh'))
    self.model.add(Dropout(self.dropout_rate))
    # Полносвязные слои
    self.model.add(Dense(16, activation='relu'))
    self.model.add(Dropout(self.dropout_rate))
    self.model.add(Dense(1, activation='linear'))
    # Компиляция модели
    self.model.compile(optimizer='adam', loss='mse', metrics=['mae'])

```

```

def train(self, X_train, y_train, epochs=100, batch_size=32, validation_split=0.2):
    # Ранний стоп для предотвращения переобучения
    es = EarlyStopping(monitor='val_loss', patience=10, restore_best_weights=True)
    history = self.model.fit(
        X_train,
        y_train,
        epochs=epochs,
        batch_size=batch_size,
        validation_split=validation_split,
        callbacks=[es],
        verbose=2
    )
    return history

def forecast(self, recent_data):
    # recent_data: датафрейм или массив последних n_steps строк (со всеми признаками)
    arr = self.scaler.transform(recent_data)
    seq = arr[-self.n_steps:, :-1].reshape((1, self.n_steps, arr.shape[1] - 1))
    y_pred_scaled = self.model.predict(seq)
    # Размасштабирование прогноза
    dummy = np.zeros((1, arr.shape[1]))
    dummy[0, -1] = y_pred_scaled
    inv = self.scaler.inverse_transform(dummy)
    return inv[0, -1]

# Пример использования
if __name__ == "__main__":
    # Загрузка данных
    df = pd.read_csv('almaty_solar_data.csv', parse_dates=['timestamp'])

```

```

# Определяем признаки и целевой столбец
feature_columns = ['temperature', 'cloud_cover', 'radiation', 'pm2_5']
target_column = 'energy_generated'

forecaster = SolarForecastLSTMAلماتyV3(n_steps=30)
X, y = forecaster.prepare_data(df, feature_columns, target_column)
# Делим на обучающую и тестовую выборки
split = int(0.8 * len(X))
X_train, y_train = X[:split], y[:split]
X_test, y_test = X[split:], y[split:]

# Строим и обучаем модель
forecaster.build_model(n_features=X.shape[2])
history = forecaster.train(X_train, y_train)

# Оценка на тестовом наборе
loss, mae = forecaster.model.evaluate(X_test, y_test, verbose=0)
print(f'Test MAE: {mae:.3f}')

# Прогноз на следующие 24 часа (пример)
last_data = df[feature_columns + [target_column]].values[-30:]
prediction = forecaster.forecast(last_data)
print(f'Forecasted energy for next step: {prediction:.2f} kWh')

```