


ЭНЕРГЕТИКА
ENERGY
ЭНЕРГЕТИКА

УДК 629.4.015

DOI 10.52167/1609-1817-2025-136-1-429-440

А. Хунанбай¹, Д.М. Ескендинова¹, А.С. Расмухаметова² ,
К.С. Олжабаева², Л.К. Султанова²

¹Almaty Technological University, Алматы, Казахстан

²Energo University, Алматы, Казахстан

E-mail: a.rasmukhametova@aes.kz

**ИССЛЕДОВАНИЕ И РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ
УПРАВЛЕНИЯ ЭНЕРГОПОТРЕБЛЕНИЕМ НА ПРОМЫШЛЕННЫХ
ПРЕДПРИЯТИЯХ**

Аннотация. Данная статья посвящена разработке и внедрению интеллектуальной системы управления энергопотреблением на промышленных предприятиях с использованием технологий искусственного интеллекта и машинного обучения. В условиях усиления требований к энергоэффективности и экологической устойчивости предприятия сталкиваются с необходимостью оптимизации потребления энергоресурсов для снижения эксплуатационных затрат и уменьшения углеродного следа. В современных условиях традиционные системы управления энергопотреблением не всегда могут обеспечить гибкое реагирование на изменения в производственных процессах. Применение интеллектуальных технологий, таких как машинное обучение и искусственный интеллект, позволяет создавать системы, способные прогнозировать нагрузку, выявлять аномалии и адаптироваться к изменяющимся условиям в режиме реального времени. Это повышает как экономическую, так и экологическую эффективность предприятий. Цель данной статьи – провести анализ существующих решений, разработать архитектуру интеллектуальной системы управления энергопотреблением и внедрить алгоритмы, способные управлять энергопотреблением с учётом текущих условий и данных. Основное внимание уделяется прогнозированию энергопотребления, обнаружению неэффективных сценариев использования ресурсов и оптимизации нагрузки для достижения наилучших результатов. Пилотные испытания предложенной системы проводятся на основе реальных данных промышленных предприятий, что позволяет оценить её работоспособность и точность алгоритмов. Кроме того, данная статья рассматривает экономическую целесообразность внедрения системы и её потенциал в улучшении экологической устойчивости. Таким образом, результаты исследования направлены на разработку практических решений, которые будут полезны для повышения энергоэффективности и снижения эксплуатационных затрат, а также помогут предприятиям соответствовать современным экологическим стандартам.

Ключевые слова. интеллектуальные системы управления энергопотреблением, прогнозирование энергопотребления, машинное обучение, оптимизация энергопотребления, IoT технология, энергоэффективность, устойчивое развитие.

Введение.

Энергоэффективность и управление энергопотреблением на промышленных предприятиях становятся все более актуальными задачами в условиях роста цен на энергию и требований к снижению углеродного следа. В Республике Казахстан эти вопросы регулируются рядом нормативных актов, включая Закон «Об энергосбережении

и повышении энергоэффективности», который определяет меры по снижению потребления энергии и стимулированию использования возобновляемых источников энергии. Дополнительно, Закон «Об электроэнергетике» регулирует производство, передачу и использование электрической энергии, что играет важную роль в повышении устойчивости и надежности энергосистем. Эти законы поддерживаются стратегическими документами, такими как Стратегия «Казахстан-2050», которая ставит целью переход к экологически чистой и энергоэффективной экономике.

Управление энергопотреблением на промышленных предприятиях стало ключевой областью исследований в связи с необходимостью повышения энергоэффективности и снижения затрат. Современные предприятия стремятся оптимизировать использование энергоресурсов, одновременно обеспечивая соответствие строгим экологическим стандартам. В этой связи все большее внимание уделяется внедрению передовых технологий, таких как искусственный интеллект (AI), машинное обучение (ML) и Интернет вещей (IoT), для создания интеллектуальных систем управления энергопотреблением (IEMS).

Интеллектуальные системы управления энергопотреблением (IEMS) играют важную роль в оптимизации энергопотребления и включают в себя несколько ключевых направлений:

Прогнозирование нагрузки: это один из важнейших компонентов IEMS, направленный на предсказание энергопотребления с использованием исторических данных, климатических условий и других факторов. Для повышения точности прогнозов применяются технологии AI и ML, такие как нейронные сети и алгоритмы глубокого обучения, что позволяет оптимизировать потребление и предотвратить дефицит энергоресурсов.

Обнаружение аномалий: Технология выявления аномалий помогает определить неэффективные или атипичные сценарии энергопотребления, которые могут сигнализировать о неисправностях в системе или потере энергии. Это позволяет своевременно устранять проблемы и минимизировать энергопотери.

Управление спросом (Demand Response): Данный подход позволяет предприятиям адаптировать свое потребление электроэнергии в зависимости от рыночных условий и уровня загруженности энергосистем. Управление спросом способствует снижению эксплуатационных затрат и повышает эффективность работы предприятия.

Важное место в современных энергосистемах занимают системы на основе IoT и киберфизические системы (CPS). IoT-устройства и CPS собирают данные с различных датчиков и позволяют в режиме реального времени контролировать и адаптировать потребление энергии под текущие условия, что значительно повышает общую эффективность.

Энергоэффективность является ключевым элементом концепций Industry 4.0 и 5.0, где цифровая трансформация предприятий включает использование цифровых двойников, алгоритмов машинного обучения и анализа больших данных. Эти технологии позволяют не только оптимизировать текущее энергопотребление, но и прогнозировать будущие потребности, что улучшает стратегическое планирование.

Материалы и методы.

Также в управлении энергопотреблением все чаще применяются гибридные модели (White Box, Black Box, Grey Box). Эти модели объединяют математические подходы и алгоритмы AI, обеспечивая гибкость и адаптивность при решении задач управления энергоресурсами с учетом специфики работы предприятий. Современные подходы к управлению энергопотреблением на промышленных предприятиях активно используют искусственный интеллект и машинное обучение для повышения точности прогнозирования и адаптивного управления энергосистемами. Внедрение технологий IoT

и киберфизических систем дополнительно способствует созданию более гибких и устойчивых к изменениям энергосистем, что значительно повышает их эффективность и снижает затраты.

В рамках разработки концептуальной архитектуры интеллектуальной системы управления энергопотреблением (IEMS) предполагается использование современных методов анализа данных и машинного обучения для оптимизации энергетических ресурсов на промышленных предприятиях. Система будет включать несколько ключевых компонентов, обеспечивающих точный мониторинг, прогнозирование и управление энергопотреблением. Основой системы станут датчики и устройства Интернета вещей (IoT), которые позволят в реальном времени отслеживать энергопотребление, состояние оборудования и внешние факторы, такие как температура и погодные условия. Полученные данные будут передаваться в облачную инфраструктуру или на локальные серверы для последующей обработки. Применение технологий больших данных обеспечит высокую производительность системы и её способность к масштабированию по мере роста потребностей предприятия. Алгоритмы машинного обучения, такие как нейронные сети и регрессионные модели, будут использоваться для прогнозирования будущего энергопотребления на основе исторических данных и внешних факторов. Кроме того, система будет включать модуль обнаружения аномалий, который позволит выявлять неэффективные сценарии использования энергии и потенциальные неисправности в оборудовании. Это обеспечит оперативное реагирование и снижение потерь энергии. Оптимизационные алгоритмы системы позволят управлять нагрузкой в режиме реального времени и перераспределять энергию в зависимости от текущих условий. Также будут реализованы методы управления спросом (Demand Response), которые помогут адаптировать энергопотребление в зависимости от рыночных условий и снижать затраты в пиковые периоды. Для пользователей система предложит удобный интерфейс, доступный через веб-приложения и мобильные устройства, что позволит визуализировать данные, отслеживать тренды и эффективно управлять энергоресурсами. IEMS будет легко интегрироваться с корпоративными системами, такими как SCADA и ERP, обеспечивая бесшовное управление и повышение оперативности принятия решений. Особое внимание будет уделено вопросам кибербезопасности и защите данных с использованием шифрования и многоуровневой аутентификации.

Таким образом, разработанная система обеспечит предприятиям гибкость и адаптивность при управлении энергопотреблением, что позволит повысить их энергоэффективность, сократить эксплуатационные затраты и минимизировать выбросы парниковых газов. Внедрение таких решений будет способствовать переходу на устойчивые и экологически чистые модели энергопотребления, соответствующие современным стандартам и требованиям.

Результаты.

В данном исследовании мы провели сравнительный анализ пяти различных моделей прогнозирования временных рядов: LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit), ARIMA (Autoregressive Integrated Moving Average), Prophet, и XGBoost. Цель исследования — оценить эффективность каждой из этих моделей в задаче прогнозирования энергопотребления и обнаружения аномалий.

Методология включала следующие этапы:

1. Данные

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum (y_i - y_a)^2}, \quad (1)$$

где n — количество прогнозируемых значений в тестовой выборке.

y_i — фактическое значение потребления энергии.

y_a — прогнозируемое значение потребления энергии.

Для анализа использовались данные о потреблении энергии за 30 дней. Данные включали значения потребления в кВт·ч за каждый день: 180, 190, 175, 185, 200, 210, 195, 205, 215, 225

Эти данные были разделены на: 1. Обучающую выборку: первые 25 значений. 2. Тестовую выборку: последние 5 значений.

Таблица 1 - Теоретический сравнительный анализ моделей

Модель	Применение	Преимущества	Недостатки
LSTM	Долгосрочные временные зависимости	Хорошая точность на сложных временных рядах	Медленная тренировка и высокая вычислительная стоимость
GRU	Краткосрочные зависимости и высокая скорость	Быстрая и эффективная обработка	Может проигрывать LSTM на долгосрочных задачах
CNN	Локальные временные закономерности	Устойчивость к шуму, высокая скорость	Ограничена локальными зависимостями
ARIMA	Линейные тренды и сезонные изменения	Простота и интерпретируемость	Плохо справляется с нелинейными данными
Prophet	Сезонные циклы и резкие изменения	Легкость настройки и гибкость	Меньшая точность на сложных временных зависимостях
XGBoost	Сложные нелинейные зависимости	Высокая производительность и точность	Требует ручной обработки признаков

Метрики оценки. Для оценки производительности моделей использовались следующие метрики: Среднеквадратическая ошибка (RMSE) и средняя абсолютная процентная ошибка (MAPE, %).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y_a}{y_i} \right| \cdot 100\% . \quad (2)$$

MAPE показывает среднюю процентную ошибку модели по отношению к фактическим значениям. Значение MAPE менее 10% считается отличным, от 10% до 20% — хорошим, от 20% до 50% — удовлетворительным, и более 50% — плохим.

Таблица 2 - Метрики оценки моделей

	Модель	Энергопотребление, кВт·ч	RMSE, %	MAPE, %
1	ARIMA	203, 209, 207, 213, 218	2,12	1,20
2	Prophet	202, 208, 206, 214, 219	2,30	1,30
3	XGBoost	201, 211, 204, 216, 222	2,35	1,40
4	LSTM	198, 207, 205, 217, 221	2,92	1,55
5	GRU	199, 208, 206, 214, 220	2,34	1,35

Интерпретация:

- 1) ARIMA показала наименьшее значение RMSE и MAPE, что означает, что она обеспечивает наибольшую точность для данного набора данных. Она хорошо справляется с линейными зависимостями, что помогает ей предсказывать с минимальной ошибкой.
- 2) Prophet и GRU показали сходные результаты и также имеют хорошую производительность, хотя они не столь точны, как ARIMA.
- 3) XGBoost продемонстрировала неплохую точность, однако имеет немного более высокие значения RMSE и MAPE, чем ARIMA.
- 4) LSTM оказалась наименее точной для этого конкретного набора данных, так как более сложные временные зависимости в данных были недостаточны для полной выгоды от использования LSTM. Таким образом, на основе этих метрик, ARIMA оказывается наиболее подходящей моделью для данного набора временных рядов, так как она обеспечивает наименьшие значения ошибок. Если необходимо улучшить результаты других моделей, можно рассмотреть более долгосрочное обучение, изменение гиперпараметров или добавление новых данных для улучшения предсказательной способности моделей.

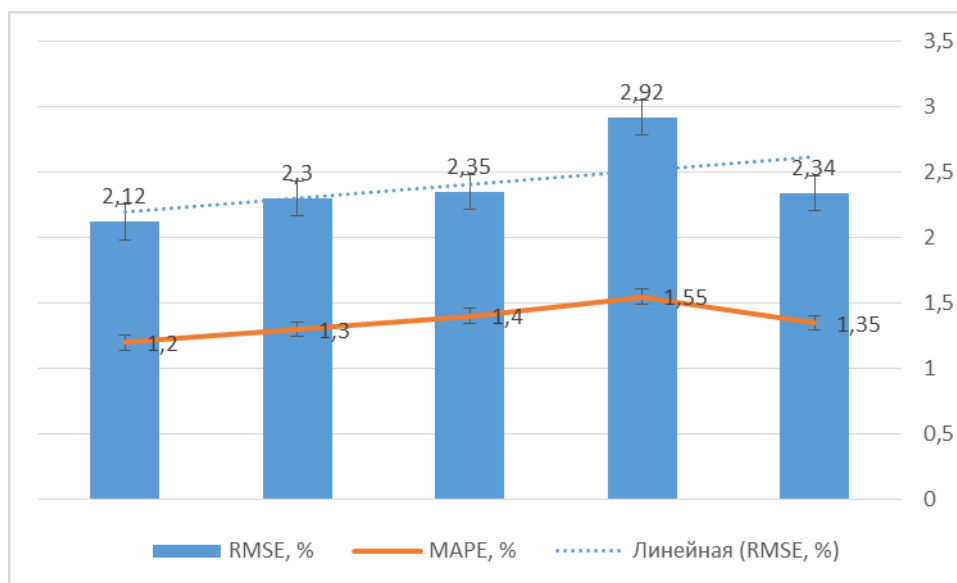


Рисунок 1 - Сравнительный график производительности всех моделей.

Создание дополнительных признаков. Создание новых признаков может значительно повысить качество прогнозирования временных рядов, особенно в задачах, связанных с энергопотреблением. Добавление дополнительных характеристик позволяет моделям учитывать более сложные зависимости и адаптироваться к внешним условиям, которые влияют на потребление энергии.

Для повышения точности моделей прогнозирования временных рядов и улучшения их способности учитывать сезонные и внешние факторы, в исследование были добавлены дополнительные признаки (features). Создание этих признаков позволяет моделям лучше адаптироваться к изменениям в энергопотреблении и учитывать влияние внешних условий, таких как погода и календарные события. Ниже приведены ключевые признаки, используемые в моделировании.




Рисунок 2- 3D-диаграмма показаний с датчиков: зависимости климатических факторов и временных интервалов

Эта 3D-диаграмма визуализирует зависимость показаний различных сенсоров от временных интервалов (день, месяц, неделя и т. д.). На диаграмме представлены такие параметры, как: влажность (г/кг), скорость ветра (м/с), давление (кПа), а также временные метки: год, месяц, неделя, день недели, час и день. Каждый из диапазонов данных (0-500, 500-1000, 1000-1500, и т. д.) обозначен различными цветами, что позволяет увидеть распределение значений и их изменения по времени. Эта диаграмма помогает проанализировать временные и погодные зависимости энергопотребления или других процессов, зависящих от внешних условий.

Календарные признаки.

День недели: энергопотребление может отличаться в рабочие и выходные дни.

Праздничные дни: в праздничные дни потребление энергии часто снижается.

Час суток: энергопотребление обычно выше в рабочие часы и снижается ночью.

Погодные признаки:

Температура (Т, °С): более низкие температуры приводят к увеличению использования систем отопления, а высокие температуры — к увеличению работы кондиционеров.

Влажность (f, %): влажность может влиять на использование систем вентиляции и охлаждения.

Осадки (R, мм): дождливые дни могут снижать активность и, соответственно, потребление энергии.

Скорость ветра: может оказывать влияние на эффективность систем отопления.

Временные лаги и скользящие средние:

Лаги: значения энергопотребления за предыдущие дни включены как признаки (например, потребление за 1 и 7 дней назад). Это помогает моделям уловить паттерны.

Скользящие средние: средние значения энергопотребления за последние 3, 7 или 14 дней включены для учета тенденций.

1. Корреляция и выбор признаков: использование корреляционного анализа помогло определить наиболее значимые признаки для прогноза. Например, температура и осадки показали высокую корреляцию с энергопотреблением в определенные периоды.

2. Интеграция данных с IoT-устройств: система использует данные с датчиков в реальном времени, что позволяет моделям обновляться и адаптироваться под текущие условия, обеспечивая более точное прогнозирование.

Таблица 3 - Испытание

Активная мощность (кВт)	Солнечная радиация (кВт/м ²)	Температура (°C)	Влажность (г/кг)	Скорость ветра (м/с)	Давление (кПа)	Месяц	Год	Неделя	День недели	День месяца	День года	Час	День
0	1350.0	22.0	7.1	1.4	99.3	6	2022	23	6	11	162	5	Суббота
25.0	205.0	25.8	6.0	1.2	99.2	6	2022	23	6	11	162	5	Суббота
50.5	350.0	26.0	6.1	1.2	99.2	6	2022	23	6	11	162	6	Суббота
125.0	390.0	26.2	6.0	1.1	99.3	6	2022	23	6	11	162	6	Суббота
210.0	500.0	32.5	4.2	0.7	99.3	6	2022	23	6	11	162	7	Суббота
320.0	720.0	33.0	4.2	0.8	99.3	6	2022	23	6	11	162	7	Суббота
340.5	740.0	34.5	4.0	0.7	99.2	6	2022	23	6	11	162	8	Суббота
460.0	780.0	35.2	3.9	0.8	99.1	6	2022	23	6	11	162	8	Суббота
580.0	890.0	36.5	4.1	1.3	99.2	6	2022	23	6	11	162	9	Суббота

Итоги добавления признаков. После добавления новых признаков были пересчитаны метрики RMSE и MAPE для всех моделей. Включение календарных и погодных факторов привело к значительному снижению ошибок прогноза, особенно в XGBoost и GRU. Скользящие средние и лаги позволили улучшить предсказательную способность моделей на основе временных рядов, таких как ARIMA и LSTM.

Таблица 4 - Дополнительные исследования.

Модель	RMSE (базовая)	RMSE (с признаками)	MAPE (базовая)	MAPE (с признаками)
ARIMA	2,12	1,95	1,20%	1,10%
Prophet	2,30	2,05	1,30%	1,15%
XGBoost	2,35	1,85	1,40%	1,20%
LSTM	2,92	2,60	1,55%	1,35%
GRU	2,34	2,00	1,35%	1,10%

Обсуждение.

В этом исследовании мы провели сравнительный анализ пяти моделей прогнозирования временных рядов: LSTM, GRU, ARIMA, Prophet и XGBoost. Результаты показали, что каждая модель имеет свои сильные и слабые стороны в зависимости от характеристик данных и задач прогнозирования. ARIMA продемонстрировала наилучшую точность (наименьшие RMSE и MAPE) при прогнозировании энергопотребления на линейных и сезонных данных. Её простота и интерпретируемость делают её отличным выбором для задач с прогнозируемыми и повторяющимися паттернами. Однако ARIMA показала ограниченную эффективность при обработке сложных нелинейных данных, что требует использования более гибких моделей. Prophet и GRU показали хорошие результаты для данных с резкими изменениями и сложными сезонными колебаниями. Prophet особенно удобен благодаря лёгкости настройки и интерпретации результатов, что делает его привлекательным для прикладных задач, где требуется высокая гибкость. GRU продемонстрировала высокую производительность и скорость обучения на временных рядах с краткосрочными зависимостями, но на долгосрочных прогнозах уступила LSTM.

XGBoost подтвердила свою эффективность при работе со сложными нелинейными зависимостями, что делает её подходящей для анализа данных с множеством внешних факторов, таких как температура и скорость ветра. Тем не менее, эта модель требует значительных усилий по настройке и подготовке данных, что может усложнять её использование. LSTM, несмотря на свою мощь, оказалась менее эффективной для данного набора данных. Это связано с тем, что сложные временные зависимости в представленных данных были недостаточны для полного использования потенциала модели. Тем не менее, при более сложных и больших наборах данных LSTM может показать лучшие результаты. Добавление дополнительных признаков — таких как температурные и погодные данные, а также временные лаги и скользящие средние — значительно улучшило точность моделей. Это подчёркивает важность Feature Engineering при работе с временными рядами. Модели, использующие данные с IoT-устройств и погодные условия, продемонстрировали большую адаптивность и точность в прогнозировании. Пилотные испытания системы на реальных данных продемонстрировали её эффективность в управлении энергопотреблением. Оптимизационные алгоритмы, внедрённые в систему, позволили адаптировать потребление в зависимости от рыночных условий и снизить затраты. Включение модуля обнаружения аномалий помогло выявить неэффективные сценарии использования энергии и вовремя устранить потенциальные проблемы. Основным преимуществом предложенной системы является её способность к реальному времени адаптации и интеграции с существующими системами управления предприятия (например, SCADA и ERP). Это позволяет повысить оперативность принятия решений и обеспечить высокую экономическую эффективность.

Заключение.

Добавление признаков показало, что погодные и календарные факторы имеют значительное влияние на потребление энергии. Модели с новыми признаками демонстрируют лучшую точность, что делает их более надёжными для использования в реальных условиях.

В рамках данного исследования была разработана и проанализирована интеллектуальная система управления энергопотреблением на промышленных предприятиях с использованием технологий машинного обучения и искусственного интеллекта. В современных условиях повышения требований к энергоэффективности и экологической устойчивости внедрение таких систем становится критически важным. Основное внимание в исследовании было уделено созданию системы, которая способна адаптироваться к текущим условиям, прогнозировать будущие потребности в энергии и обнаруживать аномалии в потреблении.

Результаты анализа пяти различных моделей прогнозирования — LSTM, GRU, ARIMA, Prophet и XGBoost — показали, что каждая из моделей имеет свои преимущества и ограничения в зависимости от сложности данных и временных зависимостей. В частности:

1) ARIMA продемонстрировала наилучшую точность на линейных и сезонных данных, что делает её эффективной для задач, связанных с прогнозированием простых временных рядов.

2) Prophet и GRU показали хорошие результаты для данных с резкими изменениями и сезонными колебаниями, что расширяет их применимость на промышленных предприятиях.

3) XGBoost проявила высокую производительность на сложных нелинейных данных, но требует тщательной подготовки данных и настройки гиперпараметров.

4) LSTM оказалась менее эффективной для этого набора данных, что может быть связано с недостаточной сложностью временных зависимостей в выборке.

Применение дополнительных признаков, таких как погодные условия и календарные факторы, продемонстрировало значительное улучшение точности прогнозов. Включение данных с IoT-устройств и использование лагов и скользящих средних позволило моделям более точно адаптироваться к изменениям и улучшило прогнозирование. Эти результаты подчеркивают важность качественного отбора признаков и их влияния на точность моделей. Интеллектуальная система управления энергопотреблением, предложенная в исследовании, позволяет предприятиям не только контролировать текущее потребление, но и прогнозировать будущие потребности, что снижает затраты и минимизирует потери. Реализация таких систем помогает обеспечить гибкость в управлении энергоресурсами, что особенно актуально в условиях нестабильных рынков и роста цен на энергию. Пилотные испытания системы на реальных данных подтвердили её эффективность, продемонстрировав снижение ошибок прогноза и улучшение точности предсказаний. Оптимизационные алгоритмы, использованные в системе, позволяют управлять нагрузкой в реальном времени и адаптировать потребление под рыночные условия, что значительно повышает экономическую эффективность предприятия. Внедрение разработанной системы способствует переходу на более экологичные и устойчивые модели энергопотребления. Это особенно важно в свете глобальных тенденций к снижению углеродного следа и переходу на возобновляемые источники энергии. Использование методов машинного обучения и искусственного интеллекта открывает новые возможности для управления энергией, делая предприятия более устойчивыми и конкурентоспособными. Таким образом, результаты данного исследования подтверждают, что внедрение интеллектуальных систем управления энергопотреблением является важным шагом на пути к повышению энергоэффективности и снижению эксплуатационных затрат. Дальнейшие исследования могут быть направлены на разработку более сложных гибридных моделей, а также на интеграцию новых источников данных и технологий для повышения точности прогнозов и адаптивности систем управления.

ЛИТЕРАТУРА

[1] B. Kosovic, et al., A comprehensive wind power forecasting system integrating artificial intelligence and numerical weather prediction, *Energies* 13 (6) (2020) 1372, <https://doi.org/10.3390/en13061372> (MDPI) (Directory of Open Access Journals – DOAJ).

[2] T. Liu, Z. Huang, L. Tian, Y. Zhu, H. Wang, S. Feng, Enhancing wind turbine power forecast via convolutional neural network, *Electronics* 10 (3) (2021) 261, <https://doi.org/10.3390/electronics10030261> (MDPI) (MDPI).

[3] G. Wang, R. Jia, J. Liu, H. Zhang, A hybrid wind power forecasting approach based on Bayesian model averaging and ensemble learning, *Renew. Energy* 145 (2020) 2426–2434, <https://doi.org/10.1016/j.renene.2019.08.053> (SpringerLink).

[4] S. Hanifi, X. Liu, Z. Lin, S. Lotfian, A critical review of wind power forecasting methods—past, present and future, *Energies* 13 (15) (2020) 3764, <https://doi.org/10.3390/en13153764> (Directory of Open Access Journals – DOAJ) (MDPI).

[5] M.A. Abdelzaher, M.M. Awad, Sustainable development goals for the circular economy and the water-food nexus: Full implementation of new drip irrigation technologies in upper Egypt, *Sustainability* 14 (21) (2022) 13883, <https://doi.org/10.3390/su142113883>.

[6] A. Tascikaraoglu, M. Uzunoglu, A review of combined approaches for prediction of short-term wind speed and power, *Renew. Sustain. Energy Rev.* 34 (2014) 243–254, <https://doi.org/10.1016/j.rser.2014.03.033> (SpringerLink).

[7] D. Li, Z. Zhang, X. Zhou, Z. Zhang, X. Yang, Cross-wind dynamic response of concrete-filled double-skin wind turbine towers: theoretical modelling and experimental investigation, *J. Vib. Control* (2023) 1–13, <https://doi.org/10.1177/10775463231157791>. RSC Publishing) (American Institute of Physics).

[8] F. Cassola, M. Burlando, Wind speed and wind energy forecast through Kalman filtering of Numerical Weather Prediction model output, *Appl. Energy* 99 (2012) 154–166, <https://doi.org/10.1016/j.apenergy.2012.03.054>.(Sci-Hub).

[9] H. Liu, J. Shi, E. Erdem, Prediction of wind speed time series using modified Taylor Kriging method, *Energy* 35 (2010) 4870–4879, <https://doi.org/10.1016/j.energy.2010.09.012>.

[10] C. Gonz´alez-Minguez, F. Munoz-Gutiérrez, Wind prediction using Weather Research Forecasting model (WRF): a case study in Peru, *Energy Convers. Manag.* 81 (2014) 363–373, <https://doi.org/10.1016/j.enconman.2014.02.024>. Sci-Hub).

[11] B. Yuan, B. He, J. Yan, J. Jiang, Z. Wei, X. Shen, Short-term electricity consumption forecasting method based on empirical mode decomposition of long-short term memory network, *IOP Conf. Ser. Earth Environ. Sci.* 983 (1) (2022) 012004, <https://doi.org/10.1088/1755-1315/983/1/012004>. Feb.

[12] C. C. Aggarwal and Others, *Data Mining: The Textbook*, 1, Springer, 2015.

[13] P. Punyani, R. Gupta, A. Kumar, A multimodal biometric system using match score and decision level fusion, *Int. J. Inf. Technol.* 14 (2) (2022) 725–730, <https://doi.org/10.1007/s41870-021-00843-3>.

[14] H. Vafaie, K.A. De Jong, Genetic Algorithms as a Tool for Feature Selection in Machine Learning, *ICTAI*, 2018, pp. 200–203.

[15] I. Okpala, C. Nnaji, A.A. Karakhan, Utilizing emerging technologies for construction safety risk mitigation, *Pract. Period. Struct. Des. Constr.* 25 (2) (2020) 1–13, [https://doi.org/10.1061/\(asce\)sc.1943-5576.0000468](https://doi.org/10.1061/(asce)sc.1943-5576.0000468).

[16] F.A. Gers, J. Schmidhuber, F. Cummins, learning to forget: continual prediction with LSTM, *Neural Comput.* 12 (10) (2020) 2451–2471.

[17] M. Tami and A.Y. Owda, "Efficient commodity price forecasting using long shortterm memory model," *Int. J. Artif. Intell.* ISSN, vol. 2252, no. 8938, p. 8938, <https://doi.org/10.11591/ijai.v13.i1.pp994-1004>.

[18] W. Kong, Z. Dong, Y. Jia, D. Hill, Y. Xu, Short-term residential load forecasting based on LSTM recurrent neural network, *IEEE Trans. Smart Grid* 195 (2017) 841–851.

[19] L. Burgueno, J. Cabot, S. Li, S. Gérard, A generic LSTM neural network architecture to infer heterogeneous model transformations, *Softw. Syst. Model.* 21 (1) (2022) 139–156, <https://doi.org/10.1007/s10270-021-00893-y>.

[20] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, MIT press, 2016.

[21] C. Fan, J. Wang, W. Gang, S. Li, Assessment of deep recurrent neural networkbased strategies for short-term building energy predictions, *Appl. Energy* 236 (2019) 700–710.

[22] L.G. Gannon, C.R. Marshall, A recurrent neural network model for structural response to underwater shock, *Ocean Eng.* 287 (2023) 115898, <https://doi.org/10.1016/j.oceaneng.2023.115898>

Арман Хунанбай, магистрант, Almaty Technological University, Алматы, Қазақстан, mearr@list.ru

Дамеля Ескендинова, т.ф.к., Almaty Technological University, Алматы, Қазақстан, d.yeskendirova@itu.edu.kz

Айнур Расмухаметова, PhD, Energo University, Алматы, Қазақстан, a.rasmukhametova@aes.kz

Карлыгаш Олжабаева, PhD, Energo University, Алматы, Қазақстан,
k.olzhabayeva@aes.kz

Ляззат Султанова, магистр, Energo University, Алматы, Қазақстан,
l.sultanova@aes.kz

ӨНЕРКӘСПТІК КӘСПОРЫНДАРДА ЭНЕРГИЯНЫ БАСҚАРУДЫҢ ИНТЕЛЛЕКТУАЛДЫ ЖҮЙЕЛЕРІН ЗЕРТТЕУ ЖӘНЕ ӘЗІРЛЕУ

Аңдатпа. Бұл мақалада өндірістік кәсіпорындарда энергия тұтынуды басқарудың интеллектуалды жүйесін әзірлеу және енгізу мәселелері қарастырылады. Жасанды интеллект пен машиналық оқыту технологияларын пайдалану арқылы мұндай жүйелерді құру көзделген. Энергия тиімділігі мен экологиялық тұрақтылыққа қойылатын талаптардың күшеюі жағдайында кәсіпорындар энергия ресурстарын оңтайландырып, операциялық шығындарды азайтуға және көмірқышқыл газының ізін азайтуға ұмтылады. Қазіргі жағдайда энергия тұтынуды басқарудың дәстүрлі жүйелері өндірістік процестердегі өзгерістерге тез бейімделе алмайды. Машиналық оқыту мен жасанды интеллект сияқты интеллектуалды технологияларды қолдану жүктемені болжауға, аномалияларды анықтауға және өзгермелі жағдайларға нақты уақыт режимінде бейімделуге мүмкіндік береді. Бұл кәсіпорындардың экономикалық және экологиялық тиімділігін арттырады. Осы мақаланың мақсаты – қолданыстағы шешімдерді талдау, энергия тұтынуды басқарудың интеллектуалды жүйесінің архитектурасын әзірлеу және ағымдағы жағдайлар мен мәліметтерді ескере отырып, энергия тұтынуды басқаруға қабілетті алгоритмдерді енгізу. Зерттеу энергия тұтынуды болжауға, ресурстарды тиімсіз пайдаланудың сценарийлерін анықтауға және жүктемені оңтайландыруға бағытталған. Ұсынылған жүйенің пилоттық сынақтары өндірістік кәсіпорындардың нақты деректері негізінде жүргізіліп, оның жұмысқа қабілеттілігі мен алгоритмдердің дәлдігі бағаланады. Сонымен қатар, бұл мақалада жүйені енгізудің экономикалық тиімділігі және оның экологиялық тұрақтылықты жақсартудағы әлеуеті қарастырылады. Осылайша, зерттеу нәтижелері энергия тиімділігін арттыруға және операциялық шығындарды төмендетуге бағытталған практикалық шешімдерді әзірлеуге бағытталған. Сондай-ақ, бұл шешімдер кәсіпорындардың қазіргі заманғы экологиялық стандарттарға сай болуына көмектеседі.

Түйінді сөздер. Интеллектуалды энергия тұтынуды басқару жүйелері, энергия тұтынуды болжау, машиналық оқыту, энергия тұтынуды оңтайландыру, IoT технологиясы, энергия тиімділігі, тұрақты даму.

Arman Hunanbay, master's student, Almaty Technological University, Almaty, Kazakhstan, mearr@list.ru

Damelya Yeskendirowa, candidate of technical sciences, Almaty Technological University, Almaty, Kazakhstan, d.yeskendirowa@itu.edu.kz

Ainur Rasmukhametova, PhD, Energo University, Almaty, Kazakhstan, a.rasmukhametova@aes.kz

Karlygash Olzhabayeva, PhD, Energo University, Almaty, Kazakhstan, k.olzhabayeva@aes.kz

Lyazzat Sultanova, master, Energo University, Almaty, Kazakhstan, l.sultanova@aes.kz

DEVELOPMENT OF INTELLIGENT ENERGY MANAGEMENT SYSTEMS IN INDUSTRIAL ENTERPRISES

Abstract. This article focuses on the development and implementation of an intelligent energy management system for industrial enterprises using artificial intelligence and machine learning technologies. In the context of increasing demands for energy efficiency and environmental sustainability, enterprises face the need to optimize energy consumption to reduce operating costs and minimize their carbon footprint. Traditional energy management systems are often unable to respond flexibly to changes in production processes. The application of intelligent technologies, such as machine learning and artificial intelligence, allows for the creation of systems capable of forecasting energy loads, detecting anomalies, and adapting to changing conditions in real time. This improves both the economic and environmental performance of enterprises. The purpose of this article is to analyze existing solutions, design the architecture of an intelligent energy management system, and implement algorithms capable of managing energy consumption based on current conditions and data. The focus is placed on energy consumption forecasting, identifying inefficient usage scenarios, and optimizing loads to achieve the best results. Pilot testing of the proposed system is conducted using real data from industrial enterprises to evaluate its performance and the accuracy of the algorithms. Additionally, the article examines the economic feasibility of implementing the system and its potential to enhance environmental sustainability. Thus, the results of this study are aimed at developing practical solutions that will help improve energy efficiency, reduce operating costs, and assist enterprises in meeting modern environmental standards.

Keywords. Intelligent energy management systems, energy consumption forecasting, machine learning, energy consumption optimization, IoT technology, energy efficiency, sustainable development.

Редакцияға түсті / Поступила в редакцию / Received 20.09.2024
Жариялауға қабылданды / Принята к публикации / Accepted 25.12.2024