

Торайғыров университетінің хабаршысы
ҒЫЛЫМИ ЖУРНАЛЫ

НАУЧНЫЙ ЖУРНАЛ
Вестник Торайғыров университета

Торайғыров университетінің ХАБАРШЫСЫ

Энергетикалық сериясы
1997 жылдан бастап шығады



ВЕСТНИК Торайғыров университета

Энергетическая серия
Издается с 1997 года

ISSN 2710-3420

№ 3 (2025)

ПАВЛОДАР

НАУЧНЫЙ ЖУРНАЛ
Вестник Торайгыров университета

Энергетическая серия
выходит 4 раза в год

СВИДЕТЕЛЬСТВО

о постановке на переучет периодического печатного издания,
информационного агентства и сетевого издания

№ 14310-Ж

выдано

Министерство информации и общественного развития
Республики Казахстан

Тематическая направленность

публикация материалов в области электроэнергетики,
электротехнологии, автоматизации, автоматизированных и
информационных систем, электромеханики и теплоэнергетики

Подписной индекс – 76136

<https://doi.org/10.48081/TPDW7598>

Бас редакторы – главный редактор

Талипов О. М.

доктор PhD, ассоц. профессор (доцент)

Заместитель главного редактора

Калтаев А.Г., *доктор PhD*

Ответственный секретарь

Сағындық Ә.Б., *доктор PhD*

Редакция алқасы – Редакционная коллегия

Клецель М. Я.,	<i>д.т.н., профессор</i>
Никифоров А. С.,	<i>д.т.н., профессор</i>
Новожилов А. Н.,	<i>д.т.н., профессор</i>
Никитин К. И.,	<i>д.т.н., профессор (Российская Федерация)</i>
Алиферов А. И.,	<i>д.т.н., профессор (Российская Федерация)</i>
Кошеков К. Т.,	<i>д.т.н., профессор</i>
Приходько Е. В.,	<i>к.т.н., профессор</i>
Кислов А. П.,	<i>к.т.н., доцент</i>
Нефтисов А. В.,	<i>доктор PhD</i>
	<i>технический редактор</i>

За достоверность материалов и рекламы ответственность несут авторы и рекламодатели

Редакция оставляет за собой право на отклонение материалов

При использовании материалов журнала ссылка на «Вестник Торайгыров университета» обязательна

© Торайгыров университет

<https://doi.org/10.48081/TAXG1964>**И. Т. Утепбергенов¹, *А. М. Сейтбекова², Л. К. Абжанова³**^{1,2,3}Алматинский университет энергетики и связи

имени Гумарбека Даукеева, Республика Казахстан, г. Алматы

¹ORCID: <https://orcid.org/0000-0003-0758-4849>²ORCID: <https://orcid.org/0000-0002-2357-5937>³ORCID: <https://orcid.org/0000-0003-1781-269X>*e-mail: a.seitbekova@aues.kz

ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ПЕРЕХОДА К ПРОАКТИВНОЙ МОДЕЛИ УПРАВЛЕНИЯ ТЕПЛОВЫМИ СЕТЯМИ

Системы централизованного теплоснабжения в Республике Казахстан характеризуются высоким уровнем физического износа, что приводит к значительным тепловым потерям и высокой аварийности. Традиционные методы эксплуатации, основанные на реагировании по факту инцидента, являются экономически неэффективными и не обеспечивают должной надежности. Целью данного исследования является разработка подхода к применению методов машинного обучения (ML) для анализа и обнаружения аномалий в системах теплоснабжения, основываясь на реальных эксплуатационных данных для перехода к проактивной модели управления тепловыми сетями. Рассмотрены ключевые задачи предиктивного анализа, такие как прогнозирование тепловой нагрузки, и обнаружение аномалий для своевременного выявления утечек, порывов и отказов оборудования. Проводится сравнительное описание методов детекции: от классического порогового контроля до продвинутых алгоритмов, таких как кластеризация (DBSCAN), ансамблевые модели (Isolation Forest) и нейросетевые подходы (автоэнкодеры). Продемонстрированные возможности применения ML-моделей подтверждают реальность перехода от дорогостоящей модели «аварийного ремонта» к проактивному «обслуживанию по фактическому состоянию». Исследование показало, что для рассматриваемого вопроса наиболее перспективной является

гибридная стратегия искусственного интеллекта, сочетающая несколько методов машинного обучения.

Ключевые слова: централизованное теплоснабжение, аномалий, машинное обучение, анализ, предиктивная диагностика.

Введение.

Теплоснабжение является важнейшей частью городской инфраструктуры, особенно в регионах с холодным климатом. Однако традиционные системы управления теплоснабжением сталкиваются с рядом проблем, таких как неравномерное распределение тепла, большие потери энергии и сложность обнаружения и устранения сбоев в работе. Ключевым фактором в энергосбережении и повышении энергоэффективности является эффективная работа автоматизированной системы управления тепловых пунктов. Внедрение искусственного интеллекта (ИИ) и методов анализа аномалий может значительно повысить эффективность управления тепловыми сетями, улучшить диагностику неисправностей и минимизировать затраты на эксплуатацию. Применение таких передовых технологий в теплоснабжении существенно влияет на развитие топливно-энергетического комплекса страны.

В реализуемой Концепции развития топливно-энергетического комплекса Республики Казахстан на 2023–2029 годы отражены основные проблемы в секторе теплоснабжения. Согласно документу [1] в производстве тепловой энергии в Казахстане функционирует 37 ТЭЦ, из которых 15 находятся в государственной собственности, а также примерно 2500 котельных. По состоянию на 1 января 2023 года средний износ оборудования ТЭЦ составляет 66 % (в 2020 году – 60 %, в 2021 году – 62 %). В некоторых городах этот показатель превышает 80 %. Из общего числа ТЭЦ 76 % старше 50 лет, а 24 % – старше 30 лет. Средний возраст ТЭЦ составляет 61 год. Количество аварийных остановок за 2022 год (1789) увеличилось на 23 % по сравнению с 2021 годом (1456). Для обеспечения энергетической безопасности остро стоят вопросы модернизации, реконструкции, замены физически и морально устаревшего оборудования [2].

В рамках цифровизации экономики [3] технологии машинного обучения (ML) открывают новые возможности для перехода к предиктивному (прогнозному) управлению. Целью данного исследования является разработка подхода к применению методов ML для анализа и обнаружения аномалий в системах теплоснабжения, основываясь на реальных эксплуатационных данных.

Эффективное управление невозможно без достоверных данных, однако на практике операционные сводки часто содержат ошибки и аномалии, которые затрудняют анализ и могут скрывать зарождающиеся аварии.

В настоящее время в разных сферах для предиктивного анализа на основе аномальных событий активно применяются методы машинного обучения. Так авторами работы [4] предложено проводить распознавание локального перегрева в процессе высокоомощного микроволнового нагрева с помощью глубокого обучения. Авторами работы [5] сделан анализ методов обнаружения аномалий и предложен способ выявления утечек в системе централизованного теплоснабжения с помощью тепловизионных снимков. В работе [6] подробно анализированы различные методы обнаружения аномалий с приведением статистики опубликованных статей в БД Thomson Reuters по запросу «Обнаружение аномалий».

Материалы и методы

Рассмотрим в качестве примера типичную ведомость суточных параметров теплопотребления за январь 2022 года ТЭЦ-1 г. Алматы [7] (таблица 1).

Таблица 1 – Фрагмент ведомости учета параметров теплопотребления за январь 2022 г

Дата	$W_{11},$ Гкал	$M_{11},$ т	$V_{11},$ м ³	$t_{вэл1},$ °C	$P_{11},$ МПа	$W_{12},$ Гкал	$M_{12},$ т	$V_{12},$ м ³	$t_{вэл2},$ °C	$P_{12},$ МПа
01.01.22	310, 262	26769, 330	26778, 580	11,48	0,31	34, 038	3037, 772	3038, 416	11,05	0,50
02.01.22	272, 261	23401, 150	23409, 570	11,53	0,30	30, 420	2726, 979	2727, 558	11,01	0,49
03.01.22	278, 173	23798, 710	23807, 380	11,58	0,30	28, 137	2515, 710	2516, 254	11,03	0,49
04.01.22	366, 170	31430, 750	31441, 710	11,54	0,32	9, 097	812, 895	813, 072	11,04	0,47
05.01.22	366, 368	31557, 380	31568, 440	11,50	0,31	13, 254	1192, 432	1192, 684	10,97	0,47
06.01.22	339, 520	29051, 660	29062, 260	11,58	0,29	20, 329	1824, 372	1824, 770	11,00	0,47
07.01.22	280, 329	23847, 480	23856, 540	11,65	0,28	30, 557	2724, 366	2724, 966	11,07	0,49
08.01.22	271, 400	23021, 660	23030, 630	11,69	0,27	31, 602	2804, 517	2805, 148	11,12	0,49
09.01.22	281, 552	23977, 430	23986, 440	11,64	0,29	28, 573	2537, 761	2538, 330	11,11	0,49
10.01.22	285, 541	24281, 160	24290, 290	11,66	0,29	30, 884	2746, 172	2746, 784	11,10	0,49
11.01.22	280, 017	23967, 550	23976, 310	11,58	0,29	29,682	2643, 043	2643, 626	11,08	0,49

12.01.22	336,032	28735,310	28745,600	11,58	0,31	17,219	1538,411	1538,750	11,04	0,48
13.01.22	338,913	29039,700	29050,020	11,56	0,31	13,064	1171,941	1172,190	11,00	0,49
14.01.22	332,501	28555,110	28565,340	11,54	0,30	25,523	2286,564	2287,066	11,02	0,48
15.01.22	299,747	25726,590	25736,080	11,55	0,28	30,289	2709,279	2709,872	11,03	0,48
16.01.22	337,505	29052,530	29063,240	11,52	0,27	30,482	2722,867	2723,476	11,05	0,48
17.01.22	332,326	28392,310	28402,810	11,60	0,29	27,581	2466,966	2467,512	11,03	0,48
18.01.22	336,194	28731,740	28742,170	11,59	0,30	22,426	1995,085	1995,540	11,09	0,48
19.01.22	308,789	26531,470	26541,090	11,53	0,29	25,997	2313,981	2314,502	11,09	0,48
20.01.22	278,548	23988,240	23997,010	11,51	0,28	31,988	2858,191	2858,814	11,04	0,49
21.01.22	276,955	23807,070	23815,840	11,53	0,28	32,491	2893,292	2893,938	11,08	0,48
22.01.22	294,027	25221,510	25230,880	11,56	0,28	31,108	2782,127	2782,724	11,03	0,49
23.01.22	315,109	27286,750	27296,310	11,44	0,30	21,392	1917,173	1917,586	11,01	0,49
24.01.22	301,907	26615,320	26624,170	11,24	0,29	31,239	2839,162	2839,736	10,86	0,48
25.01.22	326,612	28932,740	28941,880	11,18	0,31	36,997	3372,497	3373,176	10,82	0,48
26.01.22	304,698	26936,760	26945,730	11,21	0,28	39,210	3579,837	3580,532	10,80	0,49
27.01.22	290,251	25646,440	25654,870	11,21	0,29	38,612	3528,507	3529,154	10,79	0,51
28.01.22	290,123	25708,680	25716,970	11,18	0,30	38,655	3530,008	3530,670	10,80	0,50
29.01.22	291,360	25837,510	25845,760	11,17	0,30	39,427	3612,539	3613,222	10,76	0,49
30.01.22	294,269	26123,510	26131,920	11,16	0,29	38,348	3510,066	3510,748	10,78	0,48
31.01.22	295,505	26243,010	26251,460	11,16	0,29	38,414	3521,633	3522,278	10,76	0,50
Итого	9512,962	822216,560	822507,300	11,47	0,29	897,035	80716,145	80733,094	10,98	0,48

Где W – тепловая энергия, M – масса теплоносителя, $t_{вз}$ – температура, P – давление. Индексы 11 и 12 обозначают подающий и обратный трубопроводы.

Даже поверхностный анализ данных выявляет критические аномалии:

Инверсия давления: Давление в обратном трубопроводе ($P_{12} \approx 0.49$ МПа) стабильно выше, чем в подающем ($P_{11} \approx 0.30$ МПа). Это физически невозможно в стандартной циркуляционной системе и указывает на грубую ошибку: неисправность или неверное подключение датчиков.

Дисбаланс масс: Масса теплоносителя в подающем трубопроводе (M_{11}) многократно превышает массу в обратном (M_{12}). Например, за 01.01.22 разница составляет $\Delta M = 26769 - 3037 = 23732$ тонны. Такой колоссальный дисбаланс, если он не обусловлен технологическими особенностями (например, M_{12} – это лишь малая часть возврата), свидетельствует либо о гигантской утечке, либо о полной расконфигурации измерительного комплекса.

Аномальный температурный режим: Температура ~ 11.5 °C не соответствует нормативному графику для отопления в январе, а разница температур $\Delta t \approx 0.5$ °C говорит об отсутствии теплосъема.

Традиционные системы контроля, основанные на простых пороговых значениях, могут пропустить комплексный характер этих проблем. Это обуславливает необходимость применения интеллектуальных методов анализа.

Рассмотрим, как различные ML-алгоритмы могут быть применены для автоматического выявления аномалий на примере данных из Таблицы 1.

1 Пороговый контроль (Baseline-метод). Задание статических правил на основе физических законов и экспертных знаний. Например:

- правило 1: $P_{11} > P_{12}$;
- правило 2: $|M_{11} - M_{12}| / M_{11} < 5\%$.

Этот метод легко обнаружит инверсию давления и грубый дисбаланс масс. Однако он негибок, требует ручной настройки порогов и не способен выявлять аномалии в совокупности параметров, каждый из которых по отдельности может находиться в пределах нормы.

2 Методы кластеризации Density-Based Spatial Clustering of Applications with Noise (DBSCAN) также используются для обнаружения аномалий, так, например авторами работы [8] изучено процесс принятия решений при выборе параметров алгоритмов кластеризации, применяемых к данным моделей энергетических систем.

Алгоритм DBSCAN группирует вместе точки, которые лежат близко друг к другу в многомерном пространстве признаков, помечая как «шум» (аномалии) точки, которые лежат одиноко в областях с низкой плотностью.

Для применения данного подхода обнаружения аномалий согласно цели данной работы создается пространство признаков, например, $[P_{11}, P_{12}, \Delta]$. При нормальной работе все точки данных будут формировать плотный

кластер, где $P11 > P12$ и Δt имеет положительное значение в соответствии с температурным графиком. Все точки из Таблицы 1 окажутся далеко от этого «нормального» кластера и будут помечены DBSCAN как аномалии. Этот метод хорош для общей оценки состояния системы: если большинство точек помечается как шум, вся система работает нештатно.

3. Ансамблевые древовидные методы (Isolation Forest). С помощью данного алгоритма строится ансамбль случайных деревьев. Его ключевая идея в том, что аномальные точки легче «изолировать» от остальных. Чем меньше случайных разделений требуется для изоляции точки, тем выше ее «показатель аномальности» [9].

Этот метод чрезвычайно эффективен для поиска аномалий в реальном времени. Точка данных за 01.01.22 с вектором признаков, включающим $P11=0.31$ и $P12=0.50$, будет изолирована очень быстро, так как признак $P12 > P11$ является редким. Алгоритм не требует знания точных порогов, он учится на распределении данных и эффективно подсвечивает нетипичные наблюдения.

4 Автоэнкодеры – это нейросеть, которая обучается сжимать (кодировать) входные данные в скрытое представление меньшей размерности, а затем восстанавливать (декодировать) их обратно в исходный вид [10; 11]. Сеть обучается только на данных нормальной работы системы. В процессе обучения она запоминает сложные нелинейные зависимости между параметрами (например, как W зависит от M и Δt). Когда на вход обученной сети подаются аномальные данные, она не может их качественно восстановить, что приводит к высокой ошибке реконструкции. Это наиболее мощный подход для анализа данных из Таблицы 1.

Модель обучается на большом архиве данных, где $P11 > P12$, $M11 \approx M12$, а температура $tv311$ соответствует нормативному графику.

При подаче на вход модели вектора данных за любой день из Таблицы 1, ошибка реконструкции будет аномально высокой. Это произойдет не только из-за одного неверного параметра, а из-за нарушения всей совокупности физических зависимостей: давление инвертировано, температура не соответствует норме, а потребленная энергия $W11$ не согласуется с нулевым теплосъемом (малым Δt). Таким образом, автоэнкодер выявляет не просто выброс, а «слово» физической модели работы объекта, что позволяет диагностировать комплексные нештатные ситуации.

Предлагаемая архитектура (рис. 1) включает три уровня, которые обрабатывают данные, аналогичные представленным в Таблице 1:




Рисунок 1 – Концептуальная архитектура интеллектуальной системы

1 Уровень сбора данных. Данный уровень реализует агрегацию данных с приборов учета.

2 Аналитическое ядро. При данном уровне ML-модели анализируют данные на предмет аномалий и строятся прогнозы. Система выявляет не только явные аномалии (как инверсия давления), но и скрытые, например, медленные утечки, которые проявляются в виде постепенного расхождения масс $M11$ и $M12$ с течением времени.

3 Уровень поддержки решений. Данный уровень интегрируется с существующими системами SCADA и происходит визуализация данных и генерация алертов для диспетчеров. Например: «Обнаружена аномалия: инверсия давления P11/P12. Рекомендуется проверка датчиков на узле учета №...».

Результаты и обсуждение

В рамках данного исследования была проведена симуляция применения описанных методов машинного обучения к операционным данным, представленным в Таблице 1. Целью симуляции являлась оценка способности моделей выявлять различные типы аномалий и проверка гипотезы о превосходстве комплексных подходов над пороговым контролем.

Результаты применения моделей по обнаружению грубых ошибок и проблем качества данных. Все протестированные методы, от простейшего порогового контроля ($P11 > P12$) до нейросетевых моделей, успешно идентифицировали аномалию инверсии давления. Модель Isolation Forest присвоила всем точкам данных высокий «показатель аномальности» именно из-за этого признака. Автоэнкодер, обученный на корректных данных, показал высокую ошибку реконструкции, так как физическая зависимость давлений в его скрытом представлении была нарушена.

Это подтверждает, что ML-системы могут эффективно использоваться в качестве первого барьера для автоматизированного аудита качества данных,

выявляя неисправности или некорректную конфигурацию датчиков, что является фундаментальной задачей перед любым дальнейшим анализом.

Идентификация комплексных операционных аномалий. Наиболее показательные результаты были получены при анализе совокупности параметров. В то время как пороговые методы могли бы сигнализировать о каждом нарушении отдельно (низкая температура, малый Δt , дисбаланс масс ΔM), автоэнкодер продемонстрировал способность распознать всю ситуацию как единую комплексную аномалию. Высокая ошибка реконструкции была вызвана неспособностью модели согласовать всю совокупность входных векторов (P_{11} , P_{12} , M_{11} , M_{12} , tv_{311} , tv_{312}) с каким-либо известным ей паттерном нормальной работы.

Это демонстрирует ключевое преимущество нейросетевых подходов: они анализируют не отдельные параметры, а взаимосвязи между ними. Система понимает, что при таком малом Δt не может быть такого потребления W_{11} , а при таком M_{11} масса M_{12} не может быть настолько низкой. Это позволяет выявлять сложные нештатные ситуации, которые не являются простыми выбросами.

Симуляция предиктивного обнаружения утечек. Была проведена симуляция работы LSTM-модели для прогнозирования дисбаланса масс ($\Delta M = M_{11} - M_{12}$). В тестовые данные была искусственно внесена медленно растущая утечка (постепенное увеличение ΔM на 0.5 % в сутки). Модель, обученная на данных, где $\Delta M \approx 0$, начала показывать систематически растущее расхождение между своим прогнозным значением ΔM и фактическим. Превышение этим расхождением заданного порога позволило бы сгенерировать превентивное оповещение об утечке задолго до того, как она достигнет критических значений.

Обсуждение результатов и практические выводы. Полученные результаты позволяют сделать несколько важных выводов для контекста модернизации систем теплоснабжения в Казахстане.

Переход от реакции к проактивности. Продемонстрированные возможности применения ML-моделей подтверждают реальность перехода от дорогостоящей модели «аварийного ремонта» к проактивному «обслуживанию по фактическому состоянию». Система, способная предсказывать утечки и выявлять аномалии на ранней стадии, является ключевым инструментом для такого перехода. При этом наиболее перспективной является гибридная стратегия, сочетающая несколько методов.

Данные – основа и одновременно главный барьер. Обсуждаемый пример (Таблица 1) наглядно показывает, что главной проблемой на пути внедрения ИИ является не столько сложность алгоритмов, сколько качество и полнота исходных данных. Прежде чем внедрять сложные нейросетевые

модели, необходимо решить базовые задачи: провести аудит, калибровку и дооснащение сетей первичными средствами измерения (датчиками). Без достоверных данных любая ML-модель будет генерировать ложные результаты.

Экономическая целесообразность. Несмотря на значительные первоначальные инвестиции в инфраструктуру сбора данных и программное обеспечение, долгосрочный экономический эффект очевиден. Он складывается из прямого сокращения потерь теплоносителя и энергии, снижения затрат на ликвидацию крупных аварий, оптимизации режимов работы источников тепла и, как следствие, уменьшения расхода топлива.

Ограничения исследования. Следует признать, что данная работа носит концептуальный характер. Результаты получены на ограниченном наборе данных путем симуляции. Для подтверждения выводов и оценки реальной точности моделей необходимо проведение пилотного проекта на реальном участке тепловой сети с верифицированными и полными данными за длительный период, охватывающий разные сезоны.

Информация о финансировании

Статья выполнена в рамках исследования, финансируемого Комитетом науки Министерства науки и высшего образования Республики Казахстан (АР 25795155 «Разработка интеллектуальной системы автоматизированного управления и анализа аномалий в теплоснабжении городских районов с применением технологий искусственного интеллекта»).

Выводы

Анализ реальных эксплуатационных данных систем ЦТ в Казахстане подтверждает острую необходимость во внедрении автоматизированных систем диагностики. Продемонстрированные аномалии (инверсия давления, дисбаланс масс) свидетельствуют о глубоких проблемах с качеством данных и состоянием оборудования.

Методы машинного обучения предлагают иерархический подход к обнаружению аномалий.

Isolation Forest может служить системой быстрого реагирования для выявления отдельных нетипичных измерений в реальном времени.

Автоэнкодеры являются мощным инструментом для глубокой диагностики, позволяя обнаруживать комплексные сбои и нарушения физических законов в работе системы.

Наиболее перспективной является гибридная стратегия, сочетающая несколько методов. Однако ее внедрение требует предварительного этапа по аудиту и модернизации измерительной инфраструктуры, без которого невозможно обеспечить необходимое для обучения ML-моделей качество данных.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- 1 Концепция развития топливно-энергетического комплекса Республики Казахстан на 2023 – 2029 годы.
- 2 Официальные отчеты Комитета по делам строительства и жилищно-коммунального хозяйства Министерства промышленности и строительства РК.
- 3 Национальный проект «Технологический рывок за счет цифровизации, науки и инноваций» (ранее ГП «Цифровой Казахстан»).
- 4 Wang, K., Ma, L., Xiong, Q., Liang, S., Sun, G., Yu, X., Liu, T. Learning to detect local overheating of the high-power microwave heating process with deep learning // IEEE Access. – 2018. – Vol. 6. – P. 10288–10296.
- 5 Protić, M. P., Ilić Z. M., Krstić, V., Stojanović, M. B. Utilizing Unmanned Aerial Vehicles for Detecting Heat Losses in District Heating Networks // 2024 59th International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST). – IEEE, 2024. – P. 1–4.
- 6 Утепбергенов, И. Т., Сейтбекова, А. М. Анализ методов обнаружения аномалий в данных для использования в задачах аналитики и управления теплоснабжением города // Вестник АУЭС. – 2022. – Т. 3. – № 58.
- 7 Архив ОСВ от города – [Электронный ресурс]. – URL: <https://clc.is/p5wm> (Дата обращения: 12.06.2025).
- 8 Cassetti, L. A., Fattori, F., Dénarié, A., Pozzi, M., Spirito, G., Motta, M. Spatial clustering in energy system modelling: application to the case study of District heating // Energy Systems. – 2025. – P. 1–36.
- 9 Vollmer, E. M., Ruck, J., Volk, R., Schultmann, F. Detecting district heating leaks in thermal imagery: A Comparison of anomaly detection methods // Automation in Construction. – 2024. – Vol. 168. – Part A. – Art. 105709.
- 10 Tarkhan N., Drury B. Crawley, Linda, K. Lawrie, Christoph Reinhart. Generation of representative meteorological years through anomaly-based detection of extreme events // Journal of Building Performance Simulation. – 2025. – P. 1–18.
- 11 An, J., Cho, S. Variational autoencoder based anomaly detection using reconstruction probability // Special Lecture on IE. – 2015. – Vol. 2(1). – P. 1–18.

REFERENCES

- 1 Konceptsiya razvitiya toplivno-energeticheskogo kompleksa Respubliki Kazakhstan na 2023–2029 gody [Concept of development of fuel and energy complex of the Republic of Kazakhstan for 2023 – 2029].
- 2 Oficial'nye otchety Komiteta po delam stroitel'stva i zhilishchno-kommunal'nogo hozyajstva Ministerstva promyshlennosti i stroitel'stva RK

[Official reports of the Committee for Construction and Housing and Communal Services of the Ministry of Industry and Construction of the RK].

3 Nacional'nyj proekt «Tekhnologicheskij ryvok za schet cifrovizacii, nauki i innovacij» (ranee GP «Cifrovoy Kazakhstan») [National project «Technological breakthrough through digitalization, science and innovations» (formerly SE «Digital Kazakhstan»)].

4 Wang, K., Ma, L., Xiong, Q., Liang, S., Sun, G., Yu, X., Liu, T. Learning to detect local overheating of the high-power microwave heating process with deep learning // IEEE Access. – 2018. – Vol. 6. – P. 10288-10296.

5 Protić, M. P., Ilić Z. M., Krstić, V., Stojanović M. B. Utilizing Unmanned Aerial Vehicles for Detecting Heat Losses in District Heating Networks // 2024 59th International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST). – IEEE, 2024. – P. 1–4.

6 Utepbergenov, I. T., Sejtbekova, A. M. Analiz metodov obnaruzheniya anomalij v dannyh dlya ispol'zovaniya v zadachah analitiki i upravleniya teplosnabzheniem goroda [Analyzing data anomaly detection methods for use in analytics and urban heat control tasks] // Vestnik AUES. – 2022. – T. 3. – № 58.

7 Arhiv OSV ot goroda [OSV archive from the city]. [Electronic resource]. – URL: <https://clc.is/p5wm>

8 Casseti, L. A., Fattori, F., Dénarié, A., Pozzi, M., Spirito, G., Motta, M. Spatial clustering in energy system modelling: application to the case study of District heating // Energy Systems. – 2025. – P. 1–36.

9 Vollmer, E. M., Ruck, J., Volk, R., Schultmann, F. Detecting district heating leaks in thermal imagery: A Comparison of anomaly detection methods // Automation in Construction. – 2024. – Vol. 168, Part A. – Art. 105709.

10 Tarkhan N., Drury B. Crawley, Linda K. Lawrie, Christoph Reinhart. Generation of representative meteorological years through anomaly-based detection of extreme events // Journal of Building Performance Simulation. – 2025. – P. 1–18.

11 An, J., Cho, S. Variational autoencoder based anomaly detection using reconstruction probability // Special Lecture on IE. – 2015. – Vol. 2(1). – P. 1–18.

Поступило в редакцию 02.07.25.

Поступило с исправлениями 22.07.25.

Принято в печать 05.09.25.

И. Т. Утепбергенов¹, *А. М. Сейтбекова², Л. К. Абжанова³

^{1,2,3}Ғұмарбек Дәукеев атындағы Алматы энергетика және байланыс университеті, Қазақстан Республикасы, Алматы қ.

02.07.25 ж. баспаға түсті.

22.07.25 ж. түзетулерімен түсті.

05.09.25 ж. басып шығаруға қабылданды.

ЖЫЛУ ЖЕЛІЛЕРІН БАСҚАРУДЫҢ БЕЛСЕНДІ МОДЕЛІНЕ КӨШУ ҮШІН ЖАСАНДЫ ИНТЕЛЛЕКТТІ ҚОЛДАНУ

Қазақстан Республикасында орталықтандырылған жылумен жабдықтау жүйелері физикалық тозудың жоғары деңгейімен сипатталады, бұл айтарлықтай жылу шығынына және жоғары апаттылыққа әкеледі. Оқиға бойынша әрекет етуге негізделген дәстүрлі пайдалану әдістері экономикалық тұрғыдан тиімсіз және тиісті сенімділікті қамтамасыз етпейді. Бұл зерттеудің мақсаты жылу желілерін басқарудың проактивті моделіне көшу үшін нақты операциялық деректерге сүйене отырып, жылумен жабдықтау жүйелеріндегі ауытқуларды талдау және анықтау үшін машиналық оқыту әдістерін (ML) қолдану тәсілін әзірлеу болып табылады. Жылу жүктемесін болжау және жабдықтың ағып кетуін, екпінін және істен шығуын уақтылы анықтау үшін ауытқуларды табу сияқты болжамды талдаудың негізгі міндеттері қарастырылған. Классикалық шекті бақылаудан бастап кластерлеу (DBSCAN), ансамбльдік модельдер (Isolation Forest) және нейрондық желілік тәсілдер (автоэнкодерлер) сияқты жетілдірілген алгоритмдерге дейін анықтау әдістерінің салыстырмалы сипаттамасы жасалған. ML модельдерін қолданудың көрсетілген мүмкіндіктері қымбат «апаттық жөндеу» моделінен «нақты жағдай бойынша қызмет көрсету» проактивті моделіне көшудің шындығын растайды. Зерттеу көрсеткендей, қарастырылып отырған мәселе үшін машиналық оқытудың бірнеше әдістерін біріктіретін гибриді жасанды интеллект стратегиясы ең тиімді болып табылады.

Кілтті сөздер: орталықтандырылған жылумен жабдықтау, ауытқулар, машиналық оқыту, талдау, болжамды диагностика.

*I. T. Utepbergenov*¹, **A. M. Seitbekova*², *L. K. Abzhanova*³

^{1, 2, 3}Almaty University of Power Engineering and Telecommunications named after Gumarbek Daukeyev, Republic of Kazakhstan, Almaty.

Received 02.07.25.

Received in revised form 22.07.25.

Accepted for publication 05.09.25.

APPLICATION OF ARTIFICIAL INTELLIGENCE FOR TRANSITION TO A PROACTIVE MODEL OF HEAT NETWORK OPERATION

District heating systems in the Republic of Kazakhstan are characterized by a high level of physical deterioration, which leads to significant heat losses and high accident rates. Traditional methods of operation based on incident response are economically inefficient and do not provide proper reliability. The aim of this research is to develop an approach to apply machine learning (ML) techniques for analyzing and detecting anomalies in heat supply systems based on real operational data to move towards a proactive model of heat network management. Key tasks of predictive analysis such as heat load forecasting and anomaly detection for timely detection of leaks, gaps and equipment failures are reviewed. A comparative description of detection methods is provided: from classical threshold control to advanced algorithms such as clustering (DBSCAN), ensemble models (Isolation Forest) and neural network approaches (autoencoders). The demonstrated applications of ML models confirm the reality of moving from a costly «emergency repair» model to a proactive «maintenance by actual condition» model. The study has shown that for the issue at hand, a hybrid artificial intelligence strategy combining several machine learning methods is the most promising.

Keywords: district heating, anomalies, machine learning, analysis, predictive diagnostics.

Теруге 09.09.2025 ж. жіберілді. Басуға 30.09.2025 ж. қол қойылды.

Электронды баспа

29.9 Mb RAM

Шартты баспа табағы 22,2. Таралымы 300 дана. Бағасы келісім бойынша.

Компьютерде беттеген: А. К. Мыржикова

Корректор: А. Р. Омарова, Д. А. Кожас

Тапсырыс № 4447

Сдано в набор 09.09.2025 г. Подписано в печать 30.09.2025 г.

Электронное издание

29.9 Mb RAM

Усл. печ. л. 22,2. Тираж 300 экз. Цена договорная.

Компьютерная верстка: А. К. Мыржикова

Корректор: А. Р. Омарова, Д. А. Кожас

Заказ № 4447

«Toraighyrov University» баспасынан басылып шығарылған

Торайғыров университеті

140008, Павлодар қ., Ломов к., 64, 137 каб.

«Toraighyrov University» баспасы

Торайғыров университеті

140008, Павлодар қ., Ломов к., 64, 137 каб.

67-36-69

E-mail: kereku@tou.edu.kz

www.vestnik-energy.tou.edu.kz