

УДК 622.276  
МРНТИ 52.47.19

DOI: <https://doi.org/10.54859/kjogi108797>

Получена: 05.11.2024.

Одобрена: 22.04.2025.

Опубликована: 30.06.2025.

## Научный обзор

# Машинное обучение в системах мониторинга забойного давления в эксплуатационных скважинах: обзор

Д.К. Женис<sup>1</sup>, А.К. Касенов<sup>1</sup>, А.Е. Ибраев<sup>2</sup>, К.Н. Шаяхмет<sup>3</sup>

<sup>1</sup>Казахстанско-Британский технический университет, г. Алматы, Казахстан

<sup>2</sup>КМГ Инжиниринг, г. Астана, Казахстан

<sup>3</sup>ByteAll Energy, г. Астана, Казахстан

## АННОТАЦИЯ

В последние годы наблюдается стремительное внедрение технологий искусственного интеллекта в нефтегазовую промышленность, что обусловлено необходимостью повышения эффективности разработки месторождений и оптимизации производственных процессов. Одним из наиболее перспективных направлений применения искусственного интеллекта является анализ данных, получаемых с внутрискважинных систем мониторинга, в частности, систем забойного давления. Распространение стационарных датчиков давления позволяет получать непрерывные массивы информации об энергетическом состоянии пласта в реальном времени. Эти данные, будучи частью среды больших данных, требуют применения современных архитектур хранения, обработки и аналитики. Использование алгоритмов машинного обучения, включая нейронные сети и методы регрессионного анализа, позволяет выявлять скрытые закономерности, прогнозировать параметры пластов, проводить гидродинамические исследования без остановки скважин и повышать точность оперативного управления разработкой. В настоящей статье представлены принципы построения систем мониторинга давления, анализ современных архитектур обработки больших данных (включая лямбда-, каппа- и unified-архитектуры), а также рассмотрены примеры практической реализации алгоритмов машинного обучения на реальных промысловых и синтетических данных. Показана эффективность совмещения прокси-моделирования и машинного обучения в задачах определения межскважинного взаимодействия и прогнозирования режимов работы. Сделан акцент на актуальные кейсы из мировой и казахстанской практики, включая внедрение цифровых решений на базе CRMP-моделей и ансамблевых подходов.

**Ключевые слова:** системы мониторинга давления, телеметрические системы, машинное обучение, искусственный интеллект, нейронные сети, архитектура больших данных, прокси-моделирование, внутрискважинные датчики давления.

## Как цитировать:

Женис Д.К., Касенов А.К., Ибраев А.Е., Шаяхмет К.Н. Машинное обучение в системах мониторинга забойного давления в эксплуатационных скважинах: обзор // Вестник нефтегазовой отрасли Казахстана. 2025. Том 7, №2. С. 61–72. DOI: <https://doi.org/10.54859/kjogi108797>.

UDC 622.276  
CSCSTI 52.47.19

DOI: <https://doi.org/10.54859/kjogi108797>

Received: 05.11.2024.

Accepted: 22.04.2025.

Published: 30.06.2025.

## Review article

# A Review of Machine Learning Techniques for Bottomhole Pressure Monitoring in Production Wells

Dinmukhammed K. Zhenis<sup>1</sup>, Akzhan K. Kassenov<sup>1</sup>, Aktan Ye. Ibrayev<sup>2</sup>,  
Kaiyrgeldi N. Shayakhmet<sup>3</sup>

<sup>1</sup>Kazakh-British Technical University, Almaty, Kazakhstan

<sup>2</sup>KMG Engineering, Astana, Kazakhstan

<sup>3</sup>ByteAll Energy, Astana, Kazakhstan

## ABSTRACT

Artificial intelligence is rapidly gaining ground in the oil and gas industry, driven by the need to improve the efficiency of reservoir development and streamline production operations. One of the most promising applications of AI is the analysis of data collected by downhole monitoring systems – particularly those designed to measure bottomhole pressure. As more permanent downhole gauges are deployed across the industry, operators now have access to continuous, real-time insight into reservoir pressure behavior. The widespread use of permanent downhole pressure gauges enables continuous, real-time data collection on reservoir pressure dynamics. As part of a broader big data environment, these data sets require modern architectures for storage, processing and analysis. By applying machine learning algorithms – such as neural networks and regression models – engineers can uncover hidden patterns, predict reservoir parameters, perform transient pressure analysis without shutting down wells, and improve real-time decision making in field operations. This paper reviews the design principles of pressure monitoring systems and examines modern big data architectures, including lambda, kappa and unified frameworks. It also highlights practical applications of machine learning algorithms using both field data and synthetic datasets. The paper demonstrates the effectiveness of combining proxy modelling with machine learning to assess inter-well connectivity and predict production behavior. The discussion is based on real-world case studies from international and Kazakh oil fields, including the use of CRMP-based digital solutions and ensemble modelling approaches.

**Keywords:** *pressure monitoring systems; downhole telemetry systems; machine learning; artificial intelligence; neural networks; big data architecture; proxy modeling; permanent downhole gauges.*

## To cite this article:

Zhenis DK, Kassenov AK, Ibrayev AY, Shayakhmet KN. A Review of Machine Learning Techniques for Bottomhole Pressure Monitoring in Production Wells. Kazakhstan journal for oil & gas industry. 2025;7(2):61–72. DOI: <https://doi.org/10.54859/kjogi108797>.

ӨЖ 622.276  
ГТАХР 52.47.19

DOI: <https://doi.org/10.54859/kjogi108797>

Қабылданды: 05.11.2024.

Мақұлданды: 22.04.2025.

Жарияланды: 30.06.2025.

## Ғылыми шолу

# Пайдалану ұңғымаларындағы кенжар қысымының мониторингі жүйелерінде машиналық оқыту: шолу

Д.К. Жеңіс<sup>1</sup>, А.Қ. Қасенов<sup>1</sup>, А.Е. Ибраев<sup>2</sup>, Қ.Н. Шаяхмет<sup>3</sup>

<sup>1</sup>Қазақстан-Британ техникалық университеті, Алматы қаласы, Қазақстан

<sup>2</sup>ҚМГ Инжиниринг, Астана қаласы, Қазақстан

<sup>3</sup>ByteAll Energy, Астана қаласы, Қазақстан

## АННОТАЦИЯ

Соңғы жылдары мұнай-газ өнеркәсібіне жасанды интеллект технологияларының қарқынды енгізілуі байқалады, бұл үрдіс кен орындарын игеру тиімділігін арттыру және өндірістік процестерді оңтайландыру қажеттілігімен тығыз байланысты. Жасанды интеллектті қолданудың ең перспективалы бағыттарының бірі ұңғымаішілік мониторинг жүйелерінен, атап айтқанда, кенжар қысымы жүйелерінен алынған деректерді талдау болып табылады. Стационарлық қысым датчиктерінің таралуы нақты уақыт режимінде қабаттың энергетикалық күйі туралы үздіксіз ақпарат алуға мүмкіндік береді. Бұл деректер үлкен деректер ортасының бөлігі бола отырып, қазіргі заманғы сақтау, өңдеу және талдау архитектураларын қолдануды талап етеді. Машиналық оқыту алгоритмдерін, соның ішінде нейрондық желілерді және регрессиялық талдау әдістерін қолдану жасырын заңдылықтарды анықтауға, қабат параметрлерін болжауға, ұңғымаларды тоқтатпай гидродинамикалық зерттеулер жүргізуге және дамуды жедел басқарудың дәлдігін арттыруға мүмкіндік береді. Бұл мақалада қысымды бақылау жүйелерін құру принциптері, үлкен деректерді өңдеудің заманауи архитектураларын талдау (лямбда-, каппа- и unified-архитектурасын қоса алғанда), сонымен қатар нақты коммерциялық және синтетикалық мәліметтерде машиналық оқыту алгоритмдерін практикалық іске асырудың мысалдары қарастырылған. Ұңғымааралық өзара әрекеттесуді анықтау және жұмыс режимдерін болжау міндеттерінде прокси-модельдеу мен машиналық оқытуды біріктірудің тиімділігі көрсетілген. CRMP-модельдер мен ансамбльдік тәсілдердің негізінде цифрлық шешімдерді енгізуді қоса алғанда, әлемдік және қазақстандық тәжірибенің өзекті кейстеріне баса назар аударылды.

**Негізгі сөздер:** қысымды бақылау жүйелері, телеметриялық жүйелер, машиналық оқыту, жасанды интеллект, нейрондық желілер, үлкен деректер архитектурасы, прокси-модельдеу, ішкі ұңғымалық қысым датчиктері.

## Дәйексөз келтіру үшін:

Жеңіс Д.К., Қасенов А.Қ., Ибраев А.Е., Шаяхмет Қ.Н. Пайдалану ұңғымаларындағы кенжар қысымының мониторингі жүйелерінде машиналық оқыту: шолу // Қазақстанның мұнай-газ саласының хабаршысы. 2025. 7 том, №2, 61–72 б. DOI: <https://doi.org/10.54859/kjogi108797>.

## Введение

Одно из перспективных направлений развития нефтегазового сектора – применение алгоритмов искусственного интеллекта (далее – ИИ) и машинного обучения (далее – МО) в сочетании с системами учёта и мониторинга показателей работы скважин. Такие системы получили широкое распространение в последнее время.

Стационарные системы внутрискважинного мониторинга (Permanent Downhole Gauge, далее – PDG) – это манометр и/или датчик температуры, стационарно установленный в нефтяной или газовой скважине. Обычно они устанавливаются в колонне насосно-компрессорных труб (далее – НКТ) и могут измерять давление в трубном и затрубном пространстве. Также доступны системы, устанавливаемые в обсадной колонне для непосредственного измерения пластового давления, подвесные системы и системы, встроенные в гибкие трубы. Данные, которые

предоставляют такие датчики, полезны инженерам-разработчикам при определении наилучших и эффективных режимов работы скважин.

В системах скважинного мониторинга и контроля алгоритмы ИИ могут применяться для выработки рекомендаций, которые могут быть использованы при оперативном и проактивном контроле за разработкой месторождений. В данной статье приведены принципы построения архитектуры и примеры комплексного применения систем учёта мониторинга давления и МО на нефтегазовых месторождениях.

## Системы учёта и мониторинга давления в скважинах

Системы внутрискважинного мониторинга используются в нефтяных и газовых скважинах для контроля и оптимизации процессов [1]. Для решения задач по учёту и мониторингу давления в скважинах применяются погружные телеметрические системы (рис. 1).

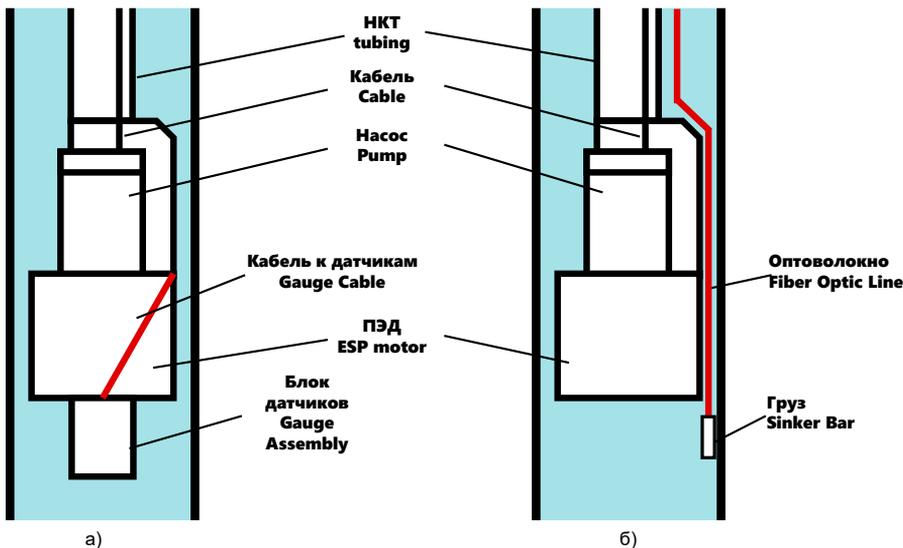


Рисунок 1. Схема погружной телеметрии  
Figure 1. Downhole telemetry system diagram

а) дискретная / discrete; б) непрерывная / continuous

ПЭД / ESP motor – погружной электродвигатель / electric submersible pump motor

Важнейшей функцией приборов, установленных в скважине, является измерение давления в одной или нескольких контрольных точках. На втором месте по степени контроля – температура. Современные датчики для скважин продолжают развиваться и дополняться новыми функциями для измерения различных параметров:

- распределение температур по стволу скважины;
- вибрации;
- напряжение;

- расход и состав жидкости.

На рис. 2 представлена конструкция погружного датчика давления и температуры с кварцевым сенсором. Такие типы датчиков используют пьезоэлектрические свойства кварца для регистрации давления на забое скважины [2].

Применение внутрискважинных датчиков даёт возможность для формирования стабильного информационного потока, по которому показатели работы скважин поступают непосредственно на диспетчерские

пункты и в центры обработки данных в режиме реального времени. Системы внутрискважинного мониторинга генерируют огромные объёмы данных, которые могут достигать нескольких миллионов замеров температуры и давления для одной скважины в течение года. В статье [3] сообщается, что на месторождении Керн Ривер в США ежедневно регистрируется более 1 млн параметров с 9000 эксплуатационных скважин. В связи с этим важное значение имеют системы хранения, обработки и анализа данных.

### Архитектуры обработки и хранения больших данных

Архитектура больших данных представляет собой концептуальную модель, предназначенную для управления, хранения, обработки и анализа больших и сложных наборов данных [4]. В практическом смысле архитектуру данных можно рассматривать как совокупность решений по сбору, хранению и трансформации информации. Современные платформы ориентированы на решение ключевых задач при работе с большими данными, включая:

- распределенные вычисления: разные узлы системы могут параллельно выполнять операции по обработке данных для повышения производительности;
- распределенное хранение: большие пакеты данных реплицируются на различные устройства для независимого хранения;
- разделение задач по извлечению и хранению: аналитические инструменты оптимизируются для вычислений, но плохо подходят для хранения данных. Хранилища данных ответственны за сохранность информации, но замедляют процессы обработки из-за большого количества метаданных. В связи этим два этих процесса разделены и выполняют обособленно друг от друга.

Входной точкой в систему является сбор исходных данных. В зависимости от источника и типа данных различают потоковую передачу и пакетные данные. Под потоковой передачей понимают данные, непрерывно генерируемые датчиками. К пакетным данным относятся данные, собранные за определённый промежуток времени либо в определённом объёме. Исходные данные далее поступают в хранилища данных.

Выбор правильного решения для хранения имеет решающее значение для эффективного управления собранными данными и доступа к ним. В настоящее время применяются следующие решения:

- реляционные базы данных. Такие традиционные системы применяются для структурированных табулированных данных с заданными схемами;

- базы данных NoSQL (*англ.* not only SQL1 – «не только SQL»). Были разработаны для работы с неструктурированными данными (изображения, аудио, видео). Отличаются масштабируемостью, гибкостью и высокой производительностью при работе с большими данными;

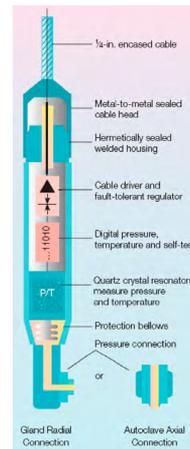


Рисунок 2. Погружной датчик давления и температуры [2]

Figure 2. Downhole Pressure and Temperature Gauge [2]

- распределённые файловые системы. Позволяют хранить и обрабатывать данные в больших объёмах на нескольких узлах. За счёт распределения данных отличаются отказоустойчивостью и повышенной производительностью.

Из хранилищ данные извлекаются для обработки, анализа и визуализации. При подготовке данных выполняются такие задачи, как удаление дубликатов, обработка пропущенных значений, очистка данных от шума, нормализация данных, кодирование категориальных признаков. В зависимости от целей анализа на основе бизнес-процессов, логических и математических алгоритмов формируются потоки обработки данных с использованием программных продуктов или скриптов на языках программирования. На этом этапе возможно применение алгоритмов машинного обучения для решения широкого спектра задач.

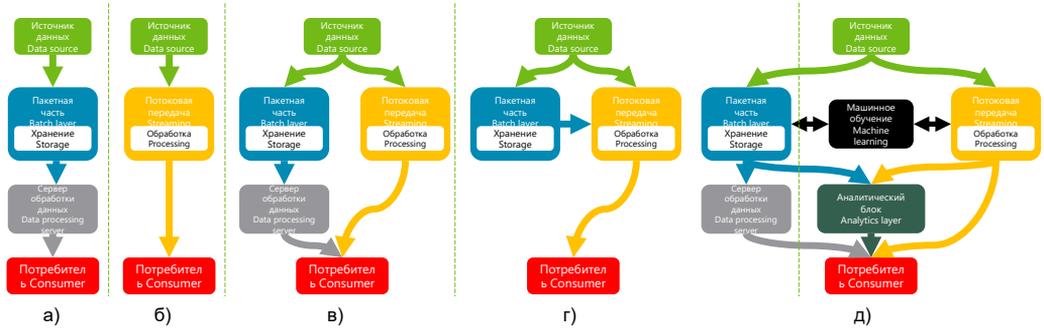
В зависимости от состава и порядка компонентов можно выделить следующие виды архитектур [5] (рис. 3):

- традиционная архитектура. Этот тип архитектуры построен на процессах, обеспечивающих попадание данных в реляционное хранилище. Такая модель отличается относительной простотой реализации и используется для пакетной обработки данных;

<sup>1</sup> SQL (*англ.* Structured Query Language – язык структурированных запросов) – декларативный язык программирования, применяемый для создания, модификации и управления данными в реляционной базе данных, управляемой соответствующей системой управления базами данных.

- архитектура потоковой передачи данных. Данная модель применяется для потоковой обработки и не содержит в себе часть по хранению пакетов данных. Информация напрямую подаётся к потребителям. Отсутствие пакетной части не даёт проводить анализ исторических данных, в связи с этим такая архитектура применяется только для определенных бизнес-процессов;
- лямбда-архитектура. Включает в себя потоковую передачу данных и пакетный блок для хранения исторических данных. В модели имеется доступ к обеим частям, которые, в свою очередь, выполняют разные функции;

- каппа-архитектура. Основана на лямбда-архитектуре и отличается тем, что пакетная и потоковая части объединены, при этом хранение организовано в виде озёр данных. Для анализа исторических данных пакеты выгружаются в виде последовательных сообщений;
- unified-архитектура. Предназначена для применения машинного обучения. Модель также основана на лямбда-архитектуре. К системе добавляется слой машинного обучения, который использует потоковые данные для постоянного обновления обучающей части.



**Рисунок 3. Погружной датчик давления и температуры**  
**Figure 3. Downhole Pressure and Temperature Gauge**

a) традиционная архитектура / traditional architecture; б) архитектура потоковой передачи / streaming architecture; в) лямбда-архитектура / lambda architecture; а) каппа-архитектура / kappa architecture; д) unified-архитектура / unified architecture

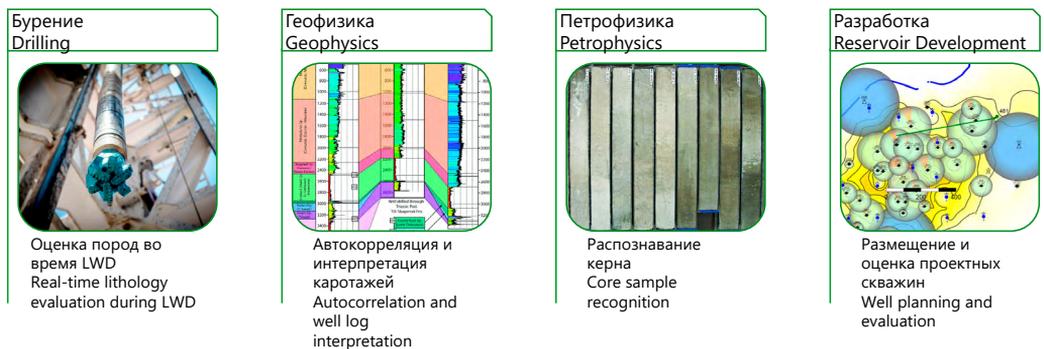
**Применение машинного обучения в системах мониторинга забойного давления**

Ключевой особенностью МО является способность обучаться на множестве схожих задач для последующего решения конкретной проблемы. [6]. Принципы МО базируются на инструментах математической статистики, теории вероятностей и алгоритмов работы с данными в цифровом виде.

МО и ИИ нашли широкое применение в нефтегазовой отрасли [7]. МО может

ускорить каротаж скважин или интерпретацию сейсмических данных (рис. 4). ИИ активно применяется при проведении каротажа во время бурения LWD (англ. Log While Drilling – «регистрация во время бурения») для идентификации пород в режиме реального времени. Другие варианты использования МО включают определение оптимального количества скважин, мест или последовательности бурения.

Машинное обучение может помочь выявить геологические зоны и определить прибыльность каждой зоны.

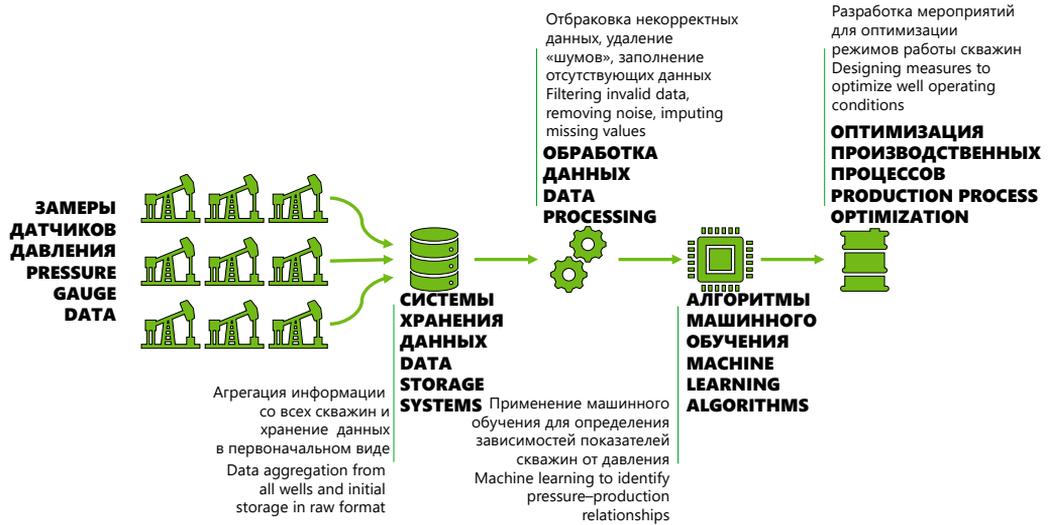


**Рисунок 4. Примеры применения машинного обучения в нефтегазовой отрасли**  
**Figure 4. Examples of Machine Learning Applications in the Oil and Gas Industry**

Общая схема применения МО с использованием систем мониторинга давления представлена на рис. 5. Интеграция датчиков давления с ИИ позволяет решать такие важные инженерные задачи, как гидродинамические исследования (далее –

ГДИС) на неустановившихся режимах и оценка взаимовлияния добывающих и нагнетательных скважин.

Традиционно, проведение ГДИС на неустановившихся режимах приводит к необходимости остановки скважин, что, в свою

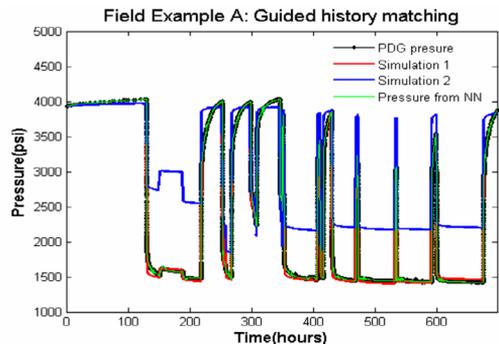


**Рисунок 5. Схема применения машинного обучения с использованием систем мониторинга давления**

**Figure 5. Diagram of Machine Learning Applications in Pressure Monitoring Systems**

очередь, может привести к потерям добычи нефти. Альтернативным источником информации о геолого-физических параметрах пласта могут послужить данные, непрерывно получаемые с датчиков давления. Пример такого исследования подробно описан в работе Zheng Sh., Li X.G. [8]. Авторами предложен алгоритм применения нейронных сетей для определения гидродинамических свойств пластов, которые были использованы для уточнения геологической модели. Тестирование алгоритма проводилось на синтетических геологических моделях и реальных данных, полученных со скважин. В качестве параметров для обучения ИИ были поданы замеры давления и дебитов. На основе трендов, выявленных нейронной сетью, были определены параметры пластов. Далее с помощью этих параметров был выполнен прогноз забойных давлений и проведено сравнение с историческими данными. Полученные на синтетических моделях алгоритмы были протестированы на реальных данных. В качестве объектов исследования послужили газоконденсатные скважины в акватории Северного моря. Авторы отмечают высокую сходимость расчётных и фактических данных (рис. 6). Это свидетельствует о том, что применение нейронных сетей позволило с высокой точностью определить гидродинамические характеристики

пластов и использовать их для прогнозирования изменения давления во времени.



**Рисунок 6. Сравнительные результаты фактических замеров и данных, рассчитанных нейронной сетью [8]**

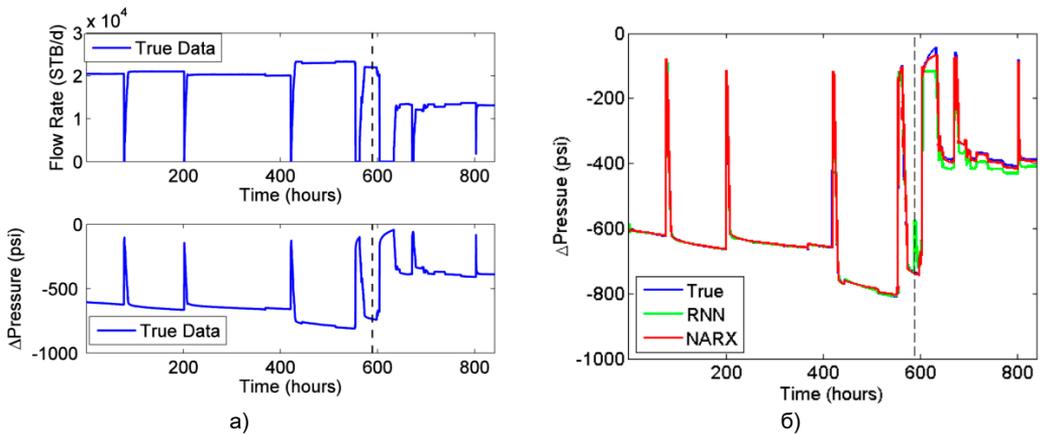
**Figure 6. Comparison of Measured Data and Neural Network Prediction [8]**

Tian C., Roland N. в своем исследовании [9] предоставили аналогичный пример использования рекуррентных нейронных сетей (RNN, англ. Recurrent Neural Network) и нелинейных авторегрессионных экзогенных моделей (NARX, англ. Nonlinear Autoregressive Exogenous Model) для выявления трендов в замерах давления, получаемых со скважинных датчиков [9]. Ис-

ходными данными послужили 4660 замеров, полученных в течение 850 ч. На основе обучающей выборки была проведена настройка двух типов алгоритмов RNN и NARX. В результате авторами были получены практические модели

на основе ИИ, которые также показали высокую сходимость с реальными данными (рис. 7).

В 2019 г. Pan Y., et al [10] предложили интересный вариант применения систем замеров давления и МО. Они использовали исторические дан-



**Рисунок 7. Исходные данные и результаты, полученные на нейронных сетях [9]**  
**Figure 7. Input Data and Results Obtained Using Neural Networks [9]**

а) реальные данные по расходу и давлению, использованные для обучения / actual flow rate and pressure data used for training; б) точность воспроизведения линейной регрессией профиля давления по обучающим данным без добавления искусственного шума / accuracy of linear regression in reproducing the pressure profile based on training data without added artificial noise

ные с датчиков для обучения нейронной сети, которая позволяла заполнять отсутствующие замеры на коротких промежутках времени. Сглаженные с помощью алгоритма Савицки-Голэя кривые по историческим данным дебитов и давлений были использованы для самообучения ИИ. Далее ИИ восполнял недостающую информацию и показатели скважин отправлялись для детального анализа.

Одним из наиболее перспективных направлений для МО являются задачи определения взаимосвязи скважин в реальном времени. Большое количество исследований в последнее время посвящено этой теме. К примеру, Silva V.C.D. в своей работе от 2019 г. [11] разработал математические алгоритмы для оценки взаимовлияния нагнетательных и добывающих скважин на основе больших данных. Используя трансформации уравнения материального баланса, автором были получена математическая модель для определения степени связанности скважин (1):

$$w_i = \alpha_i \bar{q}_i - \beta_i \sum_i \left| \frac{\partial}{\partial t} q_i \right| \quad (1)$$

где  $w_i$  – коэффициент гидравлической связи между нагнетающей/добывающей скважиной  $i$  и наблюдаемой скважиной (обобщённая мера влияния);

$\alpha_i$  – вес низкочастотной компоненты, отражающий влияние среднего дебита  $i$ -й скважины на давление в наблюдаемой;

$\bar{q}_i$  – средний дебит (или закачка) скважины  $i$  за интервал наблюдения;

$\beta_i$  – вес высокочастотной компоненты, отражающий чувствительность наблюдаемой скважины  $k$  изменениям дебита скважины  $i$ ;

$\sum_i \left| \frac{\partial}{\partial t} q_i \right|$  – суммарная вариативность потоков всех взаимодействующих скважин, абсолютное значение отражает общий эффект изменения на систему.

Коэффициенты  $\alpha_i$  и  $\beta_i$  определялись путём решения оптимизационной задачи по минимизации функции ошибки (2):

$$res_j = \sqrt{\sum_i \left[ \frac{\partial}{\partial t} P_j - \left( \sum_i \alpha_{ij} q_i - \sum_i \beta_{ij} \frac{\partial}{\partial t} q_i \right) \right]^2} \quad (2)$$

где  $P_j$  – данные, полученные с систем мониторинга давления;

$res_j$  – остаточная функция (residual) для наблюдаемой скважины  $j$ , минимизируемая в процессе оптимизации;

$\frac{\partial P_j}{\partial t}$  – производная давления по времени в наблюдаемой скважине  $j$ , рассчитанная на основе фактических данных;

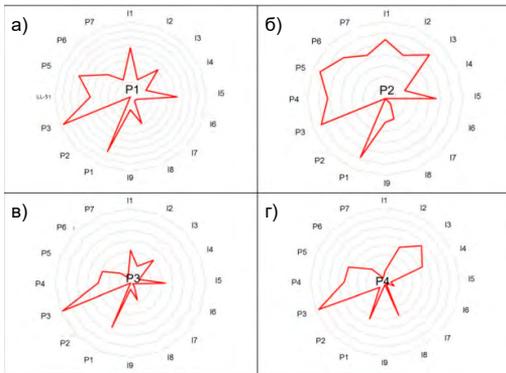
$\sum_i \alpha_{ij} q_i$  – низкочастотный вклад от дебита скважин  $i$ , отражающий общее влияние плавных изменений дебита.

$\sum_i \beta_{ij} \frac{\partial}{\partial t} q_i$  – высокочастотный вклад, учитывающий эффект быстрых изменений дебита скважин  $i$ .

Оценка математического аппарата выполнялась на синтетических геолого-гидродинамических моделях (далее – ГДМ) и на ре-

альных промысловых данных. Был рассмотрен участок с 16 действующими скважинами на одном из месторождений компании Petrobras. В результате расчётов для каждой скважины получены графики степени влияния соседних скважин на поведение давления (рис. 8). Автор отмечает, что его исследование может найти практическое применение при планировании мероприятий по поддержанию пластового давления.

В контексте использования МО для определения гидродинамической связи между скважинами одним из наиболее примечательных исследований является работа Жетруова Ж.Т., и др. [12]. Целью исследования является создание решения для прогнозирования показателей разработки на основе имеющихся исторических данных по добыче, закачке и забойному давлению, получаемых с систем телеметрии. В данном труде описаны подходы по комплексному использованию прокси-моделирования и МО. Как известно, МО основано на методах математического и статистического анализа и не учитывают физических явлений, обуславливающих физику пласта. По этой причине прокси-моделирование служит для физического обоснования и ограничения результатов МО. В качестве упрощенных физических моделей использовались модели Capacitance-Resistance Model (ёмкостно-резистивные модели, далее – CRM). Данная модель была предложена в 2003 г. учеными Albertoni A., Lake L.W [13].



**Рисунок 8. Результаты расчётов взаимовлияния скважин, полученных в исследовании Silva V.C.D., 2019 г. [11]**

**Figure 8. Results of well interaction calculations obtained in the study by Silva V.C.D., 2019 [11]**

а) скважина P1 / Well P1; б) скважина P2 / Well P2;  
в) скважина P3 / Well P3; г) скважина P4 / Well P4

Межскважинное взаимодействие оценивается на основе многомерной линейной регрессии. Отличительной особенностью CRM-моделей является то, что для расчётов показателей скважин используются только исторические данные по добыче, закачке и забойным давлениям. При этом учёт геологических свойств пласта реализуется через ввод параметров сжимаемости

и проницаемости в качестве входных данных для модели. Каждая пара скважин характеризуется двумя параметрами:

- коэффициент взаимовлияния  $f_{ij}$ ;
- временная константа, зависящая от степени накопления жидкости между скважинами.

Математическим базисом модели является совместное применение уравнения Дюпюи и материального баланса (3):

$$\tau \frac{dq}{dt} + q(t) = w(t) - \tau J \frac{dp_{wf}}{dt} \quad (3)$$

где  $q$  – дебит жидкости;  $J$  – коэффициент продуктивности добывающей скважины;  $p_{wf}$  – забойное давление;  $t$  – временная константа, которая выражается следующей формулой (4):

$$\tau = \frac{c_t V_p}{J} \quad (4)$$

где  $c_t$  – общая сжимаемость;  $V_p$  – поровый объём.

В ходе своих работ авторы разработали следующую методологию:

- построение синтетических геологических моделей;
- адаптация CRM-модели на синтетических моделях;
- обучение нейронной сети для определения коэффициентов взаимовлияния;
- разработка программных пакетов и архитектуры обработки данных;
- создание программного продукта для оценки работы скважин в режиме реального времени.

В качестве объекта исследования было использовано нефтяное месторождение, расположенное в Кызылординской области Республики Казахстан. Начальные геологические запасы – 19,8 млн т, начальные извлекаемые запасы – 7,5 млн т. На начало 2022 г. остаточные извлекаемые запасы составляли 3,5 млн т с накопленной компенсацией 32% и обводнённостью 76%. На объекте работает 64 добывающие скважины и 12 нагнетательных скважин. Используя реальные геолого-физические свойства пластов месторождения, было построено 18 различных секторных ГДМ, на которых была проведена оценка применимости алгоритмов CRM. Для расчёта прогнозных показателей предложена физическая прокси-модель CRMP (*англ.* Capacitance-Resistance Model Producer based – Модель ёмкостного сопротивления, основанная на добыче) + BFGS (*англ.* Broyden – Fletcher – Goldfarb – Shanno algorithm – метод численной оптимизации Бройдена – Флетчера – Гольдфарба – Шанно) + WOR (*англ.* Water-Oil-Ratio – водонефтяной фактор) + Ensemble (ансамбль моделей МО). На синтетических моделях получены

расхождения по дебиту жидкости на уровне 9%, что считается удовлетворительным результатом. Далее алгоритмы были перенесены на реальные данные. Для этого 1 объект месторождения был разделен на 12 ячеек разработки с одной нагнетательной и девятью добывающими скважинами. Задача МО заключалась в подборе оптимальных значений параметров. Авторы отмечают, что на реальных данных расхождения по дебитам жидкости составили от 7% до 32%. Высокие значения по некоторым скважинам обусловлены погрешностями приборов.

Критически важными данными для имплементации предложенного подхода являются данные с датчиков давления, которые установлены в компоновках глубинно-насосного оборудования добывающих скважин. При разработке модели использовалась традиционная архитектура данных. Замеры с датчиков автоматически регистрировались в хранилище, откуда с помощью программных скриптов на языке Python извлекались данные для датасетов. На основе open-source (открытых) решений был разработан пакет с ансамблем алгоритмов МО для решения оптимизационных задач. Переобучение МО проводится ежемесячно. Для пользователей было создано веб-приложение, позволяющее производить настройки расчётов и визуализировать результаты МО. На данный момент данная модель активно применяется на производстве в виде специализированного программного про-

дукта и используется для повышения уровней добычи нефти путём точного прогнозирования требуемых технологических режимов добывающих и нагнетательных скважин. За время применения данного продукта получены реальные объёмы дополнительной добычи нефти и финансовые выгоды.

### Заключение

В статье рассмотрены реальные примеры использования комплекса внутрискважинных датчиков, формирования архитектуры данных и прикладных решений на основе МО в Казахстане и за рубежом. Результаты работ, описанные в мировой научной литературе, позволяют оценить, насколько вариативными могут быть такие решения, и какой широкий спектр задач может быть охвачен при совместном использовании больших данных с систем учёта давления и алгоритмов ИИ. Системы внутрискважинного мониторинга доказали свою эффективность и становятся одним из обязательных конструктивных решений при эксплуатации скважин. Применение систем учёта и мониторинга давления в скважинах позволяет получить доступ к огромному массиву данных об энергетическом состоянии пластов в режиме реального времени. Эта информация даёт возможность оперативного контроля над разработкой месторождения с целью повышения качества и точности принимаемых решений.

### ДОПОЛНИТЕЛЬНО

**Источник финансирования.** Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

**Конфликт интересов.** Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

**Вклад авторов.** Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределён следующим образом: Женис Д.К. – формулирование научной концепции, анализ архитектур обработки данных, подготовка текста статьи, координация работы соавторов; Касенов А.К. – технический обзор систем внутрискважинного мониторинга, структурирование раздела по архитектурам хранения данных, редактирование статьи; Ибраев А.Е. – сбор и анализ данных по применению машинного обучения, описание практических кейсов и алгоритмов МО, участие в написании раздела по CRMP-моделированию; Шаяхмет К.Н. – анализ казахстанского производственного опыта, адаптация результатов под отраслевые условия, участие в формировании выводов и заключения.

### ADDITIONAL INFORMATION

**Funding source.** This study was not supported by any external sources of funding.

**Competing interests.** The authors declares that they have no competing interests.

**Authors' contribution.** All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. The largest contribution is distributed as follows: Dinmukhammed K. Zhenis – development of the scientific concept, analysis of data processing architectures, drafting of the manuscript, coordination of co-author contributions; Akzhan K. Kassenov – technical review of downhole monitoring systems, structuring of the data storage architecture section, manuscript editing; Aktan Ye. Ibrayev – data collection and analysis on machine learning applications, description of practical case studies and ML algorithms, contribution to the CRMP modeling section; Kaiyrgeldi N. Shayakhmet – analysis of Kazakhstan's operational experience, adaptation of results to industry-specific conditions, participation in the formulation of conclusions and recommendations.

## СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Mohamed H., Jakeman S., Al Azawi B., et al. Engineering Aspects in the Design and Implementation of Onshore Smart Oil Fields // *Oil & Gas Fac.* 2013. Vol. 2, Iss 05. P. 80–84. doi: [10.2118/161083-PA](https://doi.org/10.2118/161083-PA).
2. Marcuccio S., Flygare J., Konopczynski M. Application of Pressure-Monitoring Data in Land-Based Unconventionals // SPE/CSUR Unconventional Resources Conference; October 20–22, 2015; Calgary, Alberta, Canada. Available from: <https://onepetro.org/SPEURCC/proceedings-abstract/15URC/15URC/D021S009R006/183658>.
3. Charalampos Ch., Jing Zh., Sorathia V., et al. Toward an Automatic Metadata Management Framework for Smart Oil Fields // *SPE Econ & Mgmt.* 2013. Vol. 5, Iss 01. P. 33–43. doi: [10.2118/153271-PA](https://doi.org/10.2118/153271-PA).
4. Nadal S., Jovanovic P., Bilalli B., Romero O. Operationalizing and automating Data Governance // *Journal of Big Data.* 2022. Vol. 9. [10.1186/s40537-022-00673-5](https://doi.org/10.1186/s40537-022-00673-5).
5. Yang X., Bello O., Yang L., et al. Intelligent Oilfield – Cloud Based Big Data Service in Upstream Oil and Gas // The International Petroleum Technology Conference; March 26–28, 2019; Beijing, China. Available from: <https://onepetro.org/IPTCONF/proceedings-abstract/19IPTC/1-19IPTC/D011S002R001/154285>.
6. Müller A.C., Guido S. Introduction to Machine Learning with Python. Sebastopol : O'Reilly Media, Inc., 2016. 392 p.
7. Zangl G., Hannerer J. *Data Mining: Applications in the Petroleum Industry.* Katy, TX : Round Oak Publishing, 2003. 222 p.
8. Zheng Sh.-Y., Li X.G. Transient pressure analysis of 4D reservoir system response from permanent down hole gauges (PDG) for reservoir monitoring, testing and management // The Asia Pacific Oil and Gas Conference and Exhibition; October 30 –November 1, 2007; Jakarta, Indonesia. Available from: <https://onepetro.org/SPEAPOG/proceedings-abstract/07APOGCE/07APOGCE/SPE-109112-MS/142768>.
9. Tian Ch., Horne R.N. Applying Machine Learning Techniques to Interpret Flow Rate, Pressure and Temperature Data from Permanent Downhole Gauges // SPE Western Regional Meeting; April 27–30, 2015; Garden Grove, California, USA. Available from: <https://onepetro.org/SPEWRM/proceedings-abstract/15WRM/15WRM/SPE-174034-MS/182820>.
10. Pan Yu., Ran B., Peng Zh., et al. An Effective Physics-Based Deep Learning Model for Enhancing Production Surveillance and Analysis in Unconventional Reservoirs // SPE/AAPG/SEG Unconventional Resources Technology Conference; July, 2019; Denver, Colorado, USA. Available from: <https://chooser.crossref.org/?doi=10.15530%2Furtec-2019-145>.
11. Silva V.C.D. Big Data Approach for Assessing Hydraulic Interference Between Wells in Not-Controlled Systems // The Offshore Technology Conference Brasil; October 29–31, 2019; Rio de Janeiro, Brazil. Available from: <https://onepetro.org/OTCBRASIL/proceedings-abstract/19OTCB/1-19OTCB/D011S013R006/180771>.
12. Zhethruov Zh.T., Shayakhmet K.N., Karsybayev K.K., et al. Application of proxy models for oil reservoirs performance prediction // *Kazakhstan journal for oil & gas industry.* 2022. Vol. 4, N. 2. P. 47–56. doi: [10.54859/kjogi108021](https://doi.org/10.54859/kjogi108021).
13. Albertoni A., Lake L.W. Inferring interwell connectivity only from well-rate fluctuations in waterfloods // *SPE Reserv. Eval. Eng.* 2003. Vol. 6, Iss 01. P. 6–16. doi: <https://doi.org/10.2118/83381-PA>.

## REFERENCES

1. Mohamed H, Jakeman S, Al Azawi B, et al. Engineering Aspects in the Design and Implementation of Onshore Smart Oil Fields. *Oil & Gas Fac.* 2013;2(05):80–84. doi: [10.2118/161083-PA](https://doi.org/10.2118/161083-PA).
2. Marcuccio S, Flygare J, Konopczynski M. Application of Pressure-Monitoring Data in Land-Based Unconventionals. SPE/CSUR Unconventional Resources Conference; 2015 Oct 20–22, 2015; Calgary, Alberta, Canada. Available from: <https://onepetro.org/SPEURCC/proceedings-abstract/15URC/15URC/D021S009R006/183658>.
3. Charalampos C, Jing Z, Sorathia V, et al. Toward an Automatic Metadata Management Framework for Smart Oil Fields. *SPE Econ & Mgmt.* 2013;5(01):33–43. doi: <https://doi.org/10.2118/153271-PA>.
4. Nadal S, Jovanovic P, Bilalli B, Romero O. Operationalizing and automating Data Governance. *Journal of Big Data.* 2022;9:117. [10.1186/s40537-022-00673-5](https://doi.org/10.1186/s40537-022-00673-5).
5. Yang X, Bello O, Yang L, et al. Intelligent Oilfield – Cloud Based Big Data Service in Upstream Oil and Gas. The International Petroleum Technology Conference; 2019 March 26–28; Beijing, China. Available from: <https://onepetro.org/IPTCONF/proceedings-abstract/19IPTC/1-19IPTC/D011S002R001/154285>.
6. Müller AC, Guido S. *Introduction to Machine Learning with Python.* Sebastopol: O'Reilly Media, Inc.; 2016. 392 p.
7. Zangl G, Hannerer J. *Data Mining: Applications in the Petroleum Industry.* Katy, TX: Round Oak Publishing; 2003. 222 p.
8. Zheng S-Y, Li XG. Transient pressure analysis of 4D reservoir system response from permanent down hole gauges (PDG) for reservoir monitoring, testing and management. The Asia Pacific Oil and Gas Conference and Exhibition; 2007 Oct 30 – Nov 1, 2007; Jakarta, Indonesia. Available from: <https://onepetro.org/SPEAPOG/proceedings-abstract/07APOGCE/07APOGCE/SPE-109112-MS/142768>.
9. Tian C, Horne RN. Applying Machine Learning Techniques to Interpret Flow Rate, Pressure and Temperature Data from Permanent Downhole Gauges // SPE Western Regional Meeting; 2015 Apr 27–30; Garden Grove, California, USA. Available from: <https://onepetro.org/SPEWRM/proceedings-abstract/15WRM/15WRM/SPE-174034-MS/182820>.
10. Pan Y, Ran B, Peng Z, et al. An Effective Physics-Based Deep Learning Model for Enhancing Production Surveillance and Analysis in Unconventional Reservoirs. SPE/AAPG/SEG Unconventional Resources Technology Conference; 2019 July; Denver, Colorado, USA. Available from: <https://chooser.crossref.org/?doi=10.15530%2Furtec-2019-145>.
11. Silva VCD. Big Data Approach for Assessing Hydraulic Interference Between Wells in Not-Controlled Systems. The Offshore Technology Conference Brasil; 2019 Oct 29–31; Rio de Janeiro, Brazil. Available from: <https://onepetro.org/OTCBRASIL/proceedings-abstract/19OTCB/1-19OTCB/D011S013R006/180771>.
12. Zhethruov ZT, Shayakhmet KN, Karsybayev KK, et al. Application of proxy models for oil reservoirs performance prediction. *Kazakhstan journal for oil & gas industry.* 2022;4(2):47–56. doi: [10.54859/kjogi108021](https://doi.org/10.54859/kjogi108021).
13. Albertoni A, Lake LW. Inferring interwell connectivity only from well-rate fluctuations in waterfloods. *SPE Reserv. Eval. Eng.* 2003;6(01):6–16. doi: <https://doi.org/10.2118/83381-PA>.

**ИНФОРМАЦИЯ ОБ АВТОРАХ****\*Женис Динмухаммед Канатулы**ORCID [0009-0003-4934-7347](https://orcid.org/0009-0003-4934-7347)e-mail: [dimashzhenis.pe@gmail.com](mailto:dimashzhenis.pe@gmail.com).**Касенов Акжан Кайнуллаевич**

PhD, ассоциированный профессор

ORCID [0000-0002-1007-1481](https://orcid.org/0000-0002-1007-1481)e-mail: [a.kasenov@kbtu.kz](mailto:a.kasenov@kbtu.kz).**Ибраев Актан Ермакович**ORCID [0009-0005-1731-7092](https://orcid.org/0009-0005-1731-7092)e-mail: [ak.ibrayev@kmge.kz](mailto:ak.ibrayev@kmge.kz).**Шаяхмет Кайыргельди Нурланулы**ORCID [0000-0001-9269-4545](https://orcid.org/0000-0001-9269-4545)e-mail: [kairgeldi.shayakhmet@byteallenergy.com](mailto:kairgeldi.shayakhmet@byteallenergy.com).**AUTHORS' INFO****\*Dinmukhammed K. Zhenis**ORCID [0009-0003-4934-7347](https://orcid.org/0009-0003-4934-7347)e-mail: [dimashzhenis.pe@gmail.com](mailto:dimashzhenis.pe@gmail.com).**Akzhan K. Kassenov**

PhD, Associate Professor

ORCID [0000-0002-1007-1481](https://orcid.org/0000-0002-1007-1481)e-mail: [a.kasenov@kbtu.kz](mailto:a.kasenov@kbtu.kz).**Aktan Ye. Ibrayev**ORCID [0009-0005-1731-7092](https://orcid.org/0009-0005-1731-7092)e-mail: [ak.ibrayev@kmge.kz](mailto:ak.ibrayev@kmge.kz).**Kaiyrgeldi N. Shayakhmet**ORCID [0000-0001-9269-4545](https://orcid.org/0000-0001-9269-4545)e-mail: [kairgeldi.shayakhmet@byteallenergy.com](mailto:kairgeldi.shayakhmet@byteallenergy.com).

\*Автор, ответственный за переписку/Corresponding Author