

**А. С. Сильвестров, М. Е. Колпаков, С. И. Поникаров,
Р. Р. Шаймухаметов, Э. В. Осипов**

ИСКУССТВЕННЫЙ ТЕХНИЧЕСКИЙ ИНТЕЛЛЕКТ КАК ИНСТРУМЕНТАРИЙ ДЛЯ ПРОМЫШЛЕННОСТИ

Ключевые слова: искусственный интеллект, технический интеллект, машинное обучение, модульная аналитическая система, технологический процесс, безопасность, предотвращение аварий, конвергентная система.

Искусственный технический интеллект рассматривается как конвергентная система человека и искусственного интеллекта, представляющая собой комплексный инструментарий, объединяющий передовые технологии сбора, обработки, анализа данных и человеческие когнитивные способности (знания, опыт, интуиция). Анализируются ключевые вызовы, стоящие перед современными производствами: повышение эффективности, оптимизация технологических процессов, обеспечение промышленной безопасности. Показано, как искусственный технический интеллект может способствовать решению этих задач, предоставляя возможности для предиктивного обслуживания оборудования. Представлен конкретный пример применения искусственного технического интеллекта для идентификации ситуаций разгерметизации магистральных трубопроводов. Модульная аналитическая система основана на технологии искусственного интеллекта и глубокого машинного обучения, состоит из пяти различных нейросетевых моделей рекуррентного и сверточного типа. Результаты испытаний аналитической системы свидетельствуют о высокой эффективности используемых технических решений и возможности их применения для оптимизации технологического процесса перекачки жидкостей. Ключевыми преимуществами аналитической системы являются способность обучаться на больших объемах неструктурированных данных, извлекать сложные закономерности и зависимости, выявлять релевантные признаки для решения поставленной задачи с целью дальнейшего прогнозирования состояния трубопровода. В заключении делается вывод о том, что искусственный технический интеллект является критически важным инструментом для обеспечения конкурентоспособности и устойчивого развития объектов промышленных производств в условиях цифровой трансформации. Подчеркивается необходимость дальнейших исследований и разработок в области искусственного технического интеллекта, а также активного внедрения этих технологий на промышленных предприятиях.

**A. S. Silvestrov, M. E. Kolpakov, S. I. Ponikarov,
R. R. Shaimukhametov, E. V. Osipov**

ARTIFICIAL TECHNICAL INTELLIGENCE AS A TOOL FOR THE PETROCHEMICAL INDUSTRY

Keywords: artificial intelligence, machine learning, modular analytical system, technological process, safety, accident prevention, convergent system

Artificial technical intelligence is considered as a convergent system of humans and artificial intelligence, which is a comprehensive toolkit that combines advanced technologies for collecting, processing, analyzing data and human cognitive abilities (knowledge, experience, intuition). The key challenges facing modern industries are analyzed: increasing efficiency, optimizing technological processes, ensuring industrial safety. It is shown how artificial technical intelligence can contribute to solving these problems by providing opportunities for predictive equipment maintenance. A specific example of the use of artificial technical intelligence for identifying situations of depressurization of main pipelines is presented. The modular analytical system is based on artificial intelligence and deep machine learning technology, consists of five different neural network models of recurrent and convolutional types. The results of testing the analytical system indicate the high efficiency of the technical solutions used and the possibility of their application to optimize the technological process of pumping liquids. The key advantages of the analytical system are the ability to learn on large volumes of unstructured data, extract complex patterns and dependencies, identify relevant features to solve the task in order to further predict the state of the pipeline. In conclusion, it is concluded that artificial technical intelligence is a critical tool for ensuring the competitiveness and sustainable development of industrial production facilities in the context of digital transformation. The need for further research and development in the field of artificial technical intelligence, as well as the active implementation of these technologies in industrial enterprises is emphasized.

Введение

Теплоэнергоснабжение промышленности, сопряженное с транспортировкой, хранением и использованием пара, горячей воды, топливного мазута или газа, относится к числу рискованных отраслей [1]. Утечки, связанные с неисправностью трубопроводов, приводят к значительным экономическим потерям и наносят ущерб окружающей среде. Мероприятия по предотвращению потенциальных угроз, таких как пожары [2], включая лесные пожары [3], возникающие вследствие возгорания утечек энергоносителей, взрывы и токсичные выбросы, требуют постоянного

совершенствования систем безопасности и управления [4].

Развитие компьютерного оборудования, программного обеспечения и методов математического моделирования способствует росту популярности систем обнаружения утечек [5], основанных на анализе данных от датчиков давления, температуры и расхода, установленных на трубопроводах. Традиционные методы мониторинга, основанные на визуальном контроле и периодических обходах персонала, имеют существенные ограничения, связанные с человеческим фактором: утомляемость операторов при длительном наблюдении за показаниями приборов [6],

невозможность непрерывного контроля протяженных участков трубопроводов и субъективность оценки критичности отклонений параметров.

Для снижения ущерба и потерь от аварий, связанных с утечками, в системе трубопроводов теплоэнергетики устанавливаются датчики и программное обеспечение для мониторинга, позволяющие своевременно принимать меры в зависимости от местоположения точки утечки [7] и компенсировать ограничения, обусловленные утомляемостью человека при непрерывном мониторинге технологических параметров. Таким образом, ключом к предотвращению дальнейшего расширения опасности утечки является расчет местоположения точки утечки.

Анализ методов обнаружения утечек

Известные в настоящее время утечки в трубопроводах могут инициировать зависимые переменные сигналы:

- 1) волны отрицательного давления, распространяющиеся вдоль трубы [8];
- 2) акустические волны, распространяющиеся по трубе;
- 3) звук утечки (шум утечки в трубе из-за турбулентных струй вблизи отверстия утечки), распространяющийся вдоль трубы и грунта на короткие расстояния [9].

Поэтому разработан ряд технологий обнаружения утечек посредством выявления сигналов, вызванных утечками, в режиме реального времени или квазиреального времени.

Технологию мониторинга утечек в трубопроводах можно условно разделить на две категории: аппаратный и программный методы мониторинга.

Основными разработанными программными методами мониторинга являются: метод баланса трубопровода, метод переходной модели, метод статистического анализа, метод волн отрицательного давления [10]. Среди них метод волн отрицательного давления получил гораздо больше внимания в исследованиях по обнаружению утечек в трубопроводах из-за его простоты внедрения и обслуживания, низкой стоимости, приемлемой чувствительности обнаружения и точности определения местоположения.

Современные методы можно разделить на [11]:

- анализ переходных процессов в жидкости;
- анализ изменения сигнала.

Основной принцип методов определения местоположения утечек, основанных на переходных процессах в жидкости, заключается в решении уравнений неразрывности, баланса массы и импульса, а также баланса энергии жидкости в трубопроводе. Рассматривая эквивалентность в устойчивом состоянии утечки, разработана параметризованная переходная модель для определения местоположения точки утечки в трубопроводе [12]. На основе базового выражения переходного потока был также предложен набор из двух связанных одномерных гиперболических уравнений в частных производных первого порядка для описания поведения динамики потока и последующей оценки положения точки утечки [13]. Также была предложена энергетическая модель трубопровода для

непрерывного обнаружения, оценки размера и определения местоположения утечек в трубопроводе [14].

Методы обработки согласованного поля также использовались для определения места утечки с помощью матрицы анализа переходных процессов [15]. Для определения местоположения утечки в трубопроводе было предложено теоретическое уравнение, позволяющее определить положение точки утечки через изменение скорости звука на концах трубопровода [16]. Хотя вышеперечисленные методы позволяют определить место утечки с использованием преимуществ переходного отклика жидкости, изменение сигнала может быть заглушено фоновым шумом сложной среды, и тогда соответствующие методы могут не сработать.

Методы, основанные на анализе изменения сигнала, привлекают внимание исследователей из-за небольшого количества предположений, меньших ограничений и простоты понимания [17]. Если происходит утечка, такие методы позволяют рассчитать положение места утечки на основе разницы между настоящим и прошлым значениями собранных переменных, таких как данные о давлении и другие параметры трубопровода.

В работе [18] для решения проблемы определения местоположения утечки был предложен метод, основанный на отрицательной волне давления.

Для нелинейных нестационарных сигналов, собираемых датчиками, был представлен метод кросс-корреляции, основанный на оценке временной задержки, для уменьшения ошибки определения местоположения утечки [19]. Используя разницу во времени между двумя волнами, доходящими до насосной станции, для расчета места утечки трубопровода применен кросс-спектральный анализ собранных данных [20]. Аналогичным образом, была также представлена взаимная корреляция для оценки временной задержки сигнала источника утечки для определения местоположения утечки [21].

В работе [22] было предложено уравнение распространения отрицательной волны давления с использованием уравнения импульса и уравнения непрерывности, а затем точка утечки была подтверждена изменением входного давления и изменением выходного давления. Для того чтобы напрямую оценить задержку времени на основе исходных данных давления, методы вейвлет-преобразования сначала получают грубую оценку разницы во времени на основе коэффициентов аппроксимации для исходных данных давления в наибольшем масштабе, затем продолжают уточнять оценку с использованием коэффициентов в меньших и меньших масштабах. Как только масштаб становится меньше 0, процесс оценки прекращается. Соответствующее значение разницы во времени получается через максимум модуля вейвлет-преобразования, и положение точки утечки может быть рассчитано.

В статье [23] рассматривается применение дискретного wavelet-преобразования, в частности вейвлетов Добеши, с целью повышения точности и чувствительности системы обнаружения утечек в магистральном трубопроводном транспорте. Исследование открывает перспективы для дальнейшего развития и

адаптации представленных методов для передачи технологической информации по каналам связи.

Метод обнаружения утечек, основанный на пороговом вейвлет-шумоподавлении и сети глубокого обучения [24], обладает мощными возможностями извлечения признаков и возможностью выражения сложных нелинейных отношений, а также может хорошо различать аномальные состояния между различными классами и имеет более высокий процент правильных ответов по сравнению с методами машинного обучения.

Возможно также объединение акустических методов и машинного обучения [25]. Для проведения классификационных экспериментов с помощью алгоритмов случайного леса и экстремального градиентного подъема (Xgboost) в качестве основного объекта исследования использовали спектр акустических сигналов. Эти алгоритмы имеют высокую точность обнаружения, когда трубопровод находится под низким давлением, но может оказать большое влияние на результаты эксперимента, когда давление резко меняется.

В работе [26] представлена модель 2D-сверточной нейронной сети и автоэнкодера с длинной краткосрочной памятью, который получает сигналы от акселерометров, установленных на стенке трубопровода. Авторы [27] предложили новую сверточную нейронную архитектуру, которая может автоматически извлекать признаки утечек и осуществлять их диагностику.

Предложена модель сверточной нейронной сети для обнаружения утечек в трубопроводах из ПВХ, которая использует изображения сигналов вибрации, собранных с акселерометров, прикрепленных к поверхности трубопровода [28]. Этот подход может быть адаптирован для эффективного обнаружения утечек в реальных сценариях с минимальным вмешательством человека.

Однако из-за большого сходства между сигналом насоса и сигналом утечки, по-прежнему остается актуальной проблемой повышение точности традиционного метода волн отрицательного давления для мониторинга утечек в трубопроводах [22].

В настоящее время, с развитием теории глубокого обучения, результаты исследований показали, что алгоритмы глубокого обучения имеют более высокую точность [29]. Поэтому актуальна разработка модульной аналитической системы идентификации ситуаций разгерметизации трубопроводов на фактических данных средств измерений.

Модульная аналитическая система

Силами ООО «Астрапроект» (г. Казань) в 2024 году разработана и испытана модульная аналитическая система идентификации ситуаций разгерметизации трубопроводов. Система, основанная на технологии искусственного интеллекта и глубокого машинного обучения, состоит из пяти различных нейросетевых моделей рекуррентного и сверточного типа.

Результаты испытаний модульной аналитической системы свидетельствуют о высокой эффективности используемых технических решений и возможности их применения для оптимизации технологического

процесса перекачки жидкостей. Ключевыми преимуществами модульной аналитической системы являются способность обучаться на больших объемах плохо структурированных данных, извлекать сложные закономерности и зависимости, выявлять релевантные признаки для решения поставленной задачи с целью дальнейшего прогнозирования состояния трубопровода.

Использование существующих аналитических зависимостей, таких как формула Дарси-Вейсбаха, не дает однозначного прогноза давления в трубопроводе. Погрешности формулы Дарси-Вейсбаха и других аналитических зависимостей для расчёта давления в трубопроводах обусловлены несколькими ключевыми факторами:

1) Идеализация свойств жидкости и потока. Большинство аналитических формул, включая формулу Дарси-Вейсбаха, выводятся для идеализированных условий: стационарного, одномерного, изотермического течения ньютоновской жидкости в гладкой трубе круглого сечения. В реальных условиях поток может быть нестационарным, турбулентным, с изменяющимися по длине трубы температурой и вязкостью. Жидкость может быть неньютоновской, содержать примеси, а стенки трубы – иметь шероховатость, отличную от предполагаемой.

2) Неточность определения коэффициента гидравлического трения (λ). Коэффициент λ , входящий в формулу Дарси-Вейсбаха, зависит от режима течения (числа Рейнольдса) и относительной шероховатости трубы. Его определение, особенно для турбулентного режима, часто производится по эмпирическим формулам или диаграммам, которые сами по себе имеют погрешность. Кроме того, шероховатость трубы может изменяться со временем из-за коррозии, отложений и т.д.

3) Влияние местных сопротивлений. Аналитические формулы обычно учитывают только потери давления на трение по длине трубы. Однако в реальных трубопроводах присутствуют местные сопротивления (задвижки, отводы, тройники, клапаны и т.п.), которые вносят дополнительный вклад в потери давления. Учет местных сопротивлений часто осуществляется с помощью коэффициентов местных сопротивлений, которые также определяются эмпирически и имеют погрешность.

4) Многофазность потока. Если в трубопроводе присутствует многофазный поток (например, газожидкостная смесь), то применение формулы Дарси-Вейсбаха, предназначенной для однофазного потока, может приводить к значительным ошибкам. Для многофазных потоков требуются более сложные модели, учитывающие взаимодействие фаз.

5) Инструментальные погрешности. При проведении измерений давления, расхода и других параметров, необходимых для расчетов, неизбежно возникают инструментальные погрешности, связанные с точностью средств и методик измерений.

6) Упрощения в геометрии трубопровода. Реальные трубопроводы практически не бывают идеально прямыми и с постоянным диаметром. Изменение диаметра, уклоны, изгибы – всё это усложняет расчеты и

вносит дополнительные погрешности, если не используется численное моделирование.

Погрешность существующих аналитических зависимостей для оценки значений давления в трубопроводе составляет 3-5 % и может составлять 10-15 % в случае проявления неньютоновских свойств жидкости. Кроме того, погрешность измерения расхода составляет 1-2 % измеряемой величины, что имеет порядок 10^{-2} . Согласно требованиям промышленной безопасности допустимым риском является 10^{-6} аварий/год. То есть построение систем обнаружения утечек должно ориентироваться как минимум на трех независимых источниках данных для перемножения вероятностей и получения допустимого риска.

Существующие системы обнаружения утечек (СОУ) представлены волновыми и параметрическими, они также имеют погрешность, связанную со средствами измерений давления и расхода. В связи с большой протяженностью расстановка датчиков по всему трубопроводу технически невозможна. Использование протяженных оптических датчиков в комбинированных СОУ затруднено тем, что проходящие вблизи трубопровода автомобильные и железные дороги могут также вызывать возмущения.

Волновые СОУ имеют очень высокую чувствительность и ввиду того, что течение жидкости по трубопроводу является процессом во многом стохастическим, изменение характера течения жидкости может вызывать значительное число ложных срабатываний.

Точность аналитических зависимостей для оценки давления в трубопроводах зависит от множества факторов, включая методические погрешности, влияние внешних условий и ограничения измерительных технологий. Для трубопроводных систем с этим составляющим добавляются погрешности моделей (1-3 %) и ошибки монтажа (до 1,5 %).

Основываясь на том, что погрешность датчиков давления составляет 0,1 % от максимально измеряемой величины можно предположить, что существующие параметрические СОУ должны использовать как минимум два соседних датчика для исключения погрешностей измерения давления и принципиально не могут выявить утечки менее 1 мм. Падение давления от малой утечки может быть таким, что не вызовет падения давления на соседних датчиках. Таким образом, хотя математическое моделирование позволяет создавать СОУ, имеющие достаточную для обнаружения малых утечек точность, погрешность средств измерений и случайный характер измеряемых величин не позволяют однозначно идентифицировать утечки диаметром менее 1 мм.

Поэтому в настоящее время всё еще остро стоит задача создания интеллектуальных систем обнаружения утечек трубопроводов, которые будут объединять в себе одновременный анализ как минимум трех независимых источников данных с погрешностью 10^{-2} . Также интеллектуальные системы должны сохранять, анализировать и накапливать данные в реальном времени, а также выдавать предупреждения в случае, если изменяется плотность вероятности показаний датчиков давления в сторону уменьшения. Данные интеллектуальные системы должны работать с необработанным сигналом, то есть быть установленными

в пунктах контроля и управления (ПКУ), и могут быть связаны между собой для выявления аномального поведения отдельного датчика давления.

Согласно проведенному анализу рекуррентные и сверточные сети показывают положительные результаты при анализе временных рядов датчиков давления.

В созданной ООО «Астрапроект» модульной аналитической системе использовали следующий принцип обнаружения утечек трубопровода:

1) Обучение на экспериментальных данных независимых нейросетевых моделей для выявления закономерностей. Для прогноза давления применяли рекуррентные сети типа LSTM (Long Short-Term Memory), которые специально разработаны для обучения последовательностям данных. Добавление в скрытые слои данных о высоте и километраже датчика давления позволило повысить метрики производительности на 20 % (таблица 1). Для прогноза данных расхода использовали сверточные нейросети типа CNN (Convolutional Neural Networks), которые работают по принципу автоматического извлечения признаков.

Таблица 1 - Метрики производительности моделей

Table 1 – Model performance metrics

Параметр*	Модель 1	Модель 2	Модель 3	Модель 4
MSE	0,0000	0,0052	0,0041	0,0005
RMSE	0,0024	0,0721	-	0,0225
MAE	0,0018	0,0494	0,0146	0,0181
R ² Score	0,9956	0,7304	0,9981	0,9361
Correlation	0,9986	0,9921	0,9905	0,9757

*MSE (Mean Squared Error) - средняя квадратичная ошибка; RMSE (Root Mean Squared Error) - квадратный корень из средней квадратичной ошибки; MAE (Mean Absolute Error) - средняя абсолютная ошибка; R² Score - коэффициент детерминации; Correlation - коэффициент корреляции.

2) Показания каждого датчика давления в реальном времени передаются в формате временных рядов в модульную аналитическую систему (МАС) для прогноза показаний.

3) В случае, если предсказанное значение в каком-либо модуле прогноза давления отличается в меньшую сторону от измеренных показателей (падение давления на отдельном датчике - «отрицательная аномалия давления») и появляется максимум отрицательной аномалии на каком-либо датчике, МАС выдает цветовую индикацию датчика давления.

4) В случае, если отрицательная аномалия распространяется на соседние два датчика, МАС выдает сообщение об утечке. Кроме того, если прогнозное значение расхода отличается от измеренного значения, которое можно назвать «отрицательная аномалия расхода», МАС достаточно двух соседних «отрицательных аномалий давления» для выдачи сообщения об утечке.

5) Вычисление по известному времени распространения падения давления, которое обычно равно скорости звука в веществе, конкретного участка трубопровода, на котором возникла утечка.

Показатели производительности CNN относятся только к расходу, поэтому приведены в отдельной

таблице 2. Эта архитектура специально разработана для извлечения временных паттернов из последовательностей данных с помощью сверточных слоев, а затем преобразования этих признаков через полносвязные слои в конечный прогноз. Данный модуль был добавлен в каждую модель, как дополнительная подпрограмма для прогнозирования расхода.

Таблица 2 - Метрики производительности модели 5, основанной на CNN

Table 2 – Performance metrics of the CNN-based Model 5

Параметр	Модель 5
MSE	86,0303
RMSE	9,2753
MAE	5,0284
R ² Score	0,9972

Показатели производительности для предсказания потока с использованием CNN указывают на точность и эффективность модели 5 в прогнозировании расхода.

Среднеквадратичная ошибка 86,0303 указывает на то, что в среднем квадрат ошибки между предсказанными и фактическими значениями составляет 86 м³/ч. Это значение может быть оценено в контексте среднего расхода 2700 м³/ч. В данном случае MSE составляет примерно 3,19 % от среднего расхода, что говорит о том, что модель демонстрирует приемлемую точность при предсказании потока.

Квадратный корень из средней квадратичной ошибки 9,2753 м³/ч указывает на то, что в среднем предсказания отклоняются от фактических значений примерно на 9,28 м³/ч. В контексте среднего значения расхода (2700 м³/ч), это отклонение составляет менее 0,35 %. Модель очень точно предсказывает значения потока относительно его среднего уровня.

Средняя абсолютная ошибка 5,0284 указывает на то, что в среднем предсказания отличаются от фактических значений на 5,03 м³/ч. При среднем расходе 2700 м³/ч это отклонение составляет менее 0,19 %, что также подтверждает высокую точность модели в предсказании.

Значение коэффициента детерминации 0,9972 указывает на то, что модель объясняет около 99,72 % вариации в данных по расходу. Это значение остается высоким и свидетельствует о том, что модель эффективно захватывает основные закономерности, даже с учетом среднего значения расхода.

Низкие значения MSE, RMSE и MAE в сочетании с высоким коэффициентом детерминации R² Score подтверждают высокую точность и надежность модели для предсказания расхода.

Эти результаты подчеркивают эффективность использования CNN для прогнозирования расхода в условиях динамики жидкостей и подтверждают, что модель способна точно оценивать изменения даже при наличии значительных средних значений расхода.

Модель 1 прогнозирования давления в трубопроводах (с атрибутами расстояния и высоты) представляет собой систему, использующую архитектуру LSTM - разновидность рекуррентных нейронных сетей показала улучшение метрик производительности

относительно модели 2, которая имеет идентичную архитектуру, но не учитывает пространственное положение датчика на трубопроводе. Модель 1 эффективна для задач, где учитываются только данные давления, и показала лучшие результаты среди первых трех моделей.

Модель 2, несмотря на сложную архитектуру с использованием LSTM и GRU, показала большую погрешность. Это, вероятно, связано с неоднородностью данных или особенностями их нормализации.

Модель 3 основана на нейросети типа Bidirectional LSTM и дает большую погрешность относительно Модели 1. Показала хорошие результаты, особенно в сценариях, когда данные собираются с нескольких датчиков давления одновременно. Однако, показатели аномалий меньше соответствуют физическому смыслу (наличию насосных станций и резервных ниток).

Модель 4 основана на Модели 1 с добавлением в обучение данных по расходу. Показывает ухудшение метрик производительности ввиду разнородности данных. Поэтому прогнозирование расхода выделено в отдельную Модель 5 по типу сверточной нейросети CNN.

Таким образом, Модель 1 является наиболее универсальной и точной для применения в реальных условиях эксплуатации.

МАС позволяет сократить число ложных срабатываний системы обнаружения утечек и обеспечить требуемую точность. Кроме того, по результатам исследований получены метрики производительности (таблица 1), превышающие по точности имеющиеся аналитические зависимости, что говорит о необходимости развития данного метода. Например, для повышения точности обнаружения малых утечек может быть использована дополнительная нейросетевая модель для прогноза энергопотребления насосов. Диссипация энергии на утечке, приводящая к росту энергопотребления, может стать независимым источником данных и увеличить точность обнаружения малых утечек.

Искусственный технический интеллект

Индустрия 5.0 - новая парадигма промышленного развития, ориентированная на сотрудничество человека и интеллектуальных технологий, таких как искусственный интеллект, киберфизические системы, цифровые двойники и робототехника, с акцентом на устойчивость, гуманизацию производства и индивидуализацию решений.

Если Индустрия 4.0 была сосредоточена на полной автоматизации, цифровизации и объединении систем в «умное» производство, то Индустрия 5.0 делает акцент на симбиоз человека и машины, где технологии усиливают творческий, критический и экспертный потенциал человека, а не заменяют его.

В контексте анализа безопасности технологических объектов Индустрия 5.0 приводит к переходу от статичных и формальных моделей оценки риска к динамичным, человеко-ориентированным и адаптивным системам, использующим искусственный интеллект, цифровые двойники и когнитивные технологии для прогнозирования, предотвращения и управления рисками в реальном времени.

Системы искусственного интеллекта демонстрируют высокую эффективность в анализе и синтезе данных, открывая новые возможности для повышения безопасности и эффективности. Однако внедрение элементов машинного обучения в управление технологическими объектами и производственными процессами предъявляет особые требования: обеспечение полного контроля со стороны владельца, гарантирование установленных уровней надежности и риска, а также защита от несанкционированного вмешательства. Именно эти задачи решает искусственный технический интеллект (ИТИ), который нацелен на применение ИИ в управлении, при безусловном соблюдении вышеупомянутых требований безопасности и контроля. Он представляет собой следующий этап развития систем управления, где ИИ используется не автономно, а как инструмент, усиливающий возможности человека и повышающий надежность системы в целом.

В ГОСТ Р 71476-2024 система ИИ определяется как техническая система, которая порождает такие конечные результаты, как контент, прогнозы, рекомендации или решения для заданного набора определенных человеком целей.

Системы ИИ не обладают способностью к понижению в человеческом смысле и зависят от человеческого участия на этапах проектирования, разработки и эксплуатации. Это участие включает в себя принятие проектных решений, а также осуществление надзора за функционированием системы. Степень и характер надзора могут варьироваться в зависимости от конкретного сценария применения.

Конвергентная система человека и искусственного интеллекта представляет собой интегрированную человеко-машинную систему, в которой человеческие когнитивные способности (знания, опыт, интуиция) и возможности искусственного интеллекта (анализ данных, моделирование, прогнозирование) объединяются в рамках единого процесса для совместного анализа, принятия решений и управления рисками.

На рисунке 1 представлена предлагаемая функциональная схема ИТИ, в котором используется конвергентная система человека и ИИ.

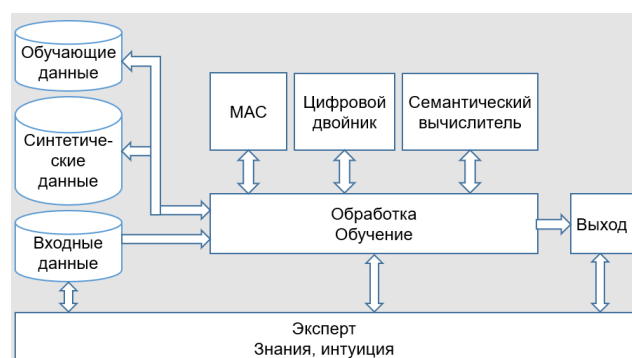


Рис. 1 – Функциональное представление системы искусственного технического интеллекта

Fig. 1 – Functional representation of an artificial technical intelligence system

Такой тип системы не предполагает замены человека ИИ, а наоборот - строится на взаимодополнении

и кооперации: ИИ обрабатывает большие объемы данных, распознает скрытые закономерности, формирует прогнозы и сценарии; человек интерпретирует результаты, верифицирует выводы, учитывает контекст, принимает обоснованные решения.

Входные данные (input data) - данные, на основе которых система ИИ получает в качестве результата прогноз или логический вывод. Входные данные - отправная точка для работы ИИ, это весь спектр информации о состоянии оборудования, веществ, процессов и окружающей среды, на основе которых ИИ-модель может оценить текущие риски и прогнозировать возможные аварийные ситуации.

Обучающие данные (training data) - данные, используемые для обучения модели машинного обучения. Это набор информации, на основе которого модель машинного обучения учится выявлять закономерности и принимать решения. Примером обучающих данных могут быть записи параметров технологического процесса (давление, температура, концентрация веществ и т. д.), сопровождающиеся метками о том, произошел ли инцидент (например, утечка, взрыв, отказ оборудования) или процесс прошел штатно.

Синтетические данные - искусственно сгенерированные данные, которые имитируют реальные данные, но создаются с помощью моделирования, симуляций или алгоритмов, а не получаются напрямую из реальных наблюдений. Они используются для обучения и тестирования моделей, особенно в тех случаях, когда реальные данные недоступны, неполны или чувствительны. Синтетические данные могут использоваться для моделирования аварийных сценариев, которые редко происходят в реальности, но имеют высокую критичность. Это позволяет обучить системы ИИ предсказывать и предотвращать потенциально опасные ситуации. Синтетические данные, полученные на основе HAZOP-анализа, позволяют обучать ИИ-системы и модели машинного обучения выявлению и прогнозированию опасных отклонений, даже если в реальности они ещё не происходили. Это особенно важно для объектов повышенной опасности, где предотвращение инцидентов критически важно, а реальные данные об авариях ограничены.

Модульная аналитическая система - интегрированная совокупность взаимосвязанных программных и аппаратных модулей, предназначенная для сбора, обработки, анализа и визуализации данных с целью поддержки принятия решений. По результатам вышеуказанной работы рассматривается возможность использования аналогичных решений для промышленных производств. Отмечено, что модульная аналитическая система технологического процесса способна адаптироваться к изменениям объемов производства, замене оборудования и катализаторов, что позволит оптимизировать качество продукта. Аналитическая система может быть встроена как рекомендательная система, которая обучается в процессе эксплуатации.

Цифровой двойник технологического процесса - виртуальная модель реального технологического процесса, которая точно отражает его структуру, поведение и динамику на основе данных с физических объектов, математических моделей и алгоритмов обра-

ботки информации. Цифровой двойник функционирует в тесной связи с физическим процессом, обеспечивая непрерывный обмен данными в реальном времени для мониторинга, анализа, прогнозирования и оптимизации работы системы. В контексте анализа безопасности цифровой двойник служит инструментом для раннего выявления рисков, прогнозирования аварийных ситуаций, оценки эффективности защитных мер и повышения надежности принятия решений.

Семантический вычислитель - интеллектуальная система, способная интерпретировать и обрабатывать информацию на основе её смысла и контекста с использованием формализованных знаний (онтологий, семантических правил, логических связей). В области анализа безопасности технологического объекта семантический вычислитель применяется для идентификации и интерпретации рисков, автоматического выявления отклонений, контекстного анализа аварийных сценариев и поддержки принятия решений, обеспечивая более глубокое и обоснованное понимание сложных производственных ситуаций.

Семантические вычисления направлены на сопоставление семантики обрабатываемого контента с человеческими намерениями. В ходе семантических вычислений создаются представления для описания информации, которые затем используются для извлечения и создания контента, а также управления и манипулирования им. Семантическое описание контента позволяет уменьшить неопределенность в когнитивных процессах и в логических рассуждениях на основе информации. Это, в свою очередь, помогает обеспечить обогащение информации, устранение конфликтов, реферирование и сравнение. Таким образом, семантические вычисления - подход, который сочетает в себе использование априорной информации и обучения.

Эксперт - специалист, обладающий глубокими теоретическими знаниями, практическим опытом, интуицией и компетенциями в области промышленной безопасности, позволяющими ему обоснованно анализировать сложные ситуации, формулировать суждения, давать заключения и принимать решения в условиях неопределённости.

Обработка и обучение производятся ИИ, который использует для порождения прогнозов, а эти прогнозы, в свою очередь, используются для того, чтобы с помощью человека последовательно выдавать рекомендации, решения и выполнять действия.

Выход - итоговая информация, формируемая в результате совместной аналитической деятельности человека и системы искусственного интеллекта, включающая прогнозы, оценки рисков, диагностические заключения, рекомендации или управленческие решения. Такой выход является результатом интеграции вычислительных возможностей ИИ (обработки данных, моделирования, прогнозирования) и экспертных знаний человека (интерпретации, верификации, контекстуализации), что позволяет учитывать как формализованные, так и неформализуемые аспекты анализа риска.

Пример применения предлагаемого ИТИ на объекте. ИИ-модель:

- по данным датчиков системы АСУТП анализирует данные (давление, температура, расход и т.д.);
- формирует рекомендации по корректировке ведения технологического процесса;
- обнаруживает аномалию (рост давления выше нормы, отклонения по температурному режиму, снижения выхода продукта или ухудшение качества);
- формирует прогноз развития течения технологического процесса и предлагает сценарии реагирования.

Оператор (эксперт) оценивает ситуацию:

- сравнивает с предыдущими (или регламентными) данными по технологическому процессу;
- учитывает контекст (например, плановое техническое обслуживание, переход с одного вида сырья на другое, изменение продуктовой линейки, смена режима работы установки);
- принимает решение (скорректировать технологические параметры, определить время перехода на новый технологический режим, остановить установку, переключиться на резервный контур, провести осмотр и т.д.).

Результат - совместное решение, сочетающее точность ИИ и опыт человека, снижающее вероятность аварии.

Приведенные выше функции охватывают основные особенности ИТИ и соответствуют показателям классификации ИИ по ГОСТ Р 59277-2020. Таким образом, предлагаемый ИТИ - специализированный узконаправленный ИИ, основанный на глубоком обучении по эксплуатационным и синтетическим многомерным данным, является экспертно-аналитической системой принятия решений с функциями многоуровневого аудита, интегрируемой в системы контроля и управления технологическими процессами и промышленной безопасностью, адаптивной для различных технических решений в промышленности.

Развитие искусственного технического интеллекта открывает перед промышленностью принципиально новые возможности для решения целого комплекса важнейших задач. Одно из ключевых направлений – это предиктивная аналитика. Системы ТИ, непрерывно анализируя данные с многочисленных датчиков, способны не просто фиксировать текущее состояние оборудования, но и выявлять скрытые аномалии, предсказывая потенциальные отказы задолго до их фактического проявления. Такой проактивный подход позволяет перейти от реактивного обслуживания к превентивному, своевременно проводя необходимые ремонтные работы, избегая тем самым дорогостоящих простоев и, что самое главное, предотвращая аварийные ситуации, связанные с утечками опасных веществ, взрывами и выбросами.

Помимо повышения безопасности, искусственный технический интеллект обеспечивает значительную оптимизацию самих технологических процессов. Благодаря возможностям ИИ, параметры процессов, такие как температура, давление и состав сырья, могут регулироваться в режиме реального времени с учетом множества переменных факторов. Это позволяет достигать максимальной эффективности производства: снижать потребление энергии, минимизировать количество отходов, повышать качество конечной продук-

ции и, в конечном итоге, увеличивать общую прибыльность предприятия.

Скорейшее внедрение в систему автоматизации интеллектуальных систем является наиболее важной задачей, так как создание цифровой модели позволит накапливать опыт эксплуатации, чтобы наиболее точно выявить аномальное поведение на данном технологическом режиме, что возможно только в случае наличия достаточного объема статистических данных. Кроме того, эта система позволит давать рекомендации по устранению выявленных инцидентов и отклонений технологического процесса. Управляющие сигналы в систему автоматизации при этом должен подавать диспетчер, так как сам принцип машинного обучения содержит в себе вероятностный характер. Модульный принцип организации структуры позволяет осуществлять внедрение системы локально на ответственных участках, с последующим наращиванием в цельную систему любого технологического процесса.

Внедрение искусственного технического интеллекта – это не просто следование технологическим трендам, а стратегическая необходимость, обусловленная сложностью и опасностью производственных процессов, а также растущими требованиями к эффективности, безопасности и экологичности. ТИ выступает в роли ключевого инструмента, обеспечивающего устойчивое развитие и конкурентоспособность предприятий в современных условиях.

Заключение

Представлена модульная аналитическая система идентификации ситуаций разгерметизации трубопроводов, основанная на технологиях глубокого машинного обучения и объединяющая пять нейросетевых моделей рекуррентного и сверточного типа. Применение архитектур LSTM с учетом пространственных характеристик датчиков позволило повысить метрики производительности прогнозирования давления на 20 %, а использование сверточных нейронных сетей для прогнозирования расхода обеспечило коэффициент детерминации 0,9972, что подтверждает возможность преодоления ограничений традиционных аналитических зависимостей с погрешностью 3-15 %. Введена концепция искусственного технического интеллекта как специализированного узконаправленного ИИ, интегрируемого в системы контроля и управления с безусловным соблюдением требований промышленной безопасности, реализующего конвергентную систему человека и искусственного интеллекта в парадигме Индустрии 5.0. Модульный принцип организации системы обеспечивает поэтапное внедрение и масштабирование, способность к обучению в процессе эксплуатации гарантирует непрерывное повышение точности обнаружения аномалий, а применимость разработанных решений для широкого спектра технологических процессов промышленности открывает перспективы создания адаптивных экспертно-аналитических систем принятия решений с интеграцией цифровых двойников и семантических вычислителей для обеспечения безопасности, эффективности и конкурентоспособности промышленных предприятий.

Литература

1. Р.Р. Гаязов, Ю.А. Знаемский Ю.А., В.С. Кадышев, В.И. Лопатин, И.А. Маринин, *ГИАБ*, S11–52, 3-8 (2015).
2. И.С. Ризаев, Д.Н. Зарипова, М.С. Осипова, Н.В. Андреев, *Вестник Технологического университета*, **28**, 8, 119-123 (2025).
3. А.С. Катасёв, Д.В. Катасёва, Ю.Н. Смирнов, Д.Д. Насибуллина, *Вестник Технологического университета*, **27**, 7, 115-119 (2024).
4. Д.И. Шигабетдинова, З.М. Гизатуллин, М.П. Шлеймович, *Вестник Технологического университета*, **28**, 5, 123-128 (2025).
5. А.В. Григорьевых, *Наука и технологии трубопроводного транспорта нефти и нефтепродуктов*, **14**, 6, 506-513 (2024).
6. Д.П. Никоноров, А.С. Катасёв, *Вестник Технологического университета*, **28**, 6, 110-114 (2025).
7. X. Zheng, F. Hu, Y. Wang, L. Zheng, X. Gao, H. Zhang, S. You, B. Xu, *Energy*, **237**, 121604 (2021).
8. B.X. Liu, Z. Jiang, W. Nie, Y.J. Ran, H. Lin, *Measurement*, **186**, 110235 (2021).
9. J.Y. Lu, J.K. Yue, L.J. Zhu, D.M. Wang, G.F. Li, *Measurement*, **185**, 110107 (2021).
10. X.H. Pan, M.N. Karim, *Computer Aided Chemical Engineering*, **37**, 1787-1792 (2015).
11. D. Zaman, M.K. Tiwari, A.K. Gupta, D. Sen, *Eng. Fail. Anal.*, **109**, 104264 (2020).
12. C. Verde, L. Molina, L. Torres, *J. Loss. Prev. Process. Ind.*, **29**, 177-185 (2014).
13. O.M. Aamo, *IEEE Trans. Autom. Control*, **61**, 246-251 (2016).
14. R. Lopezlena, S. Sadovnychiy, *J. Pipeline Syst. Eng. Pract.*, **10**, 04019017 (2019).
15. A. Keramat, H-F. Duan, *Mech. Syst. Signal Process.*, **161**, 107940 (2021).
16. X. Lang, P. Li, Y. Guo, J. Cao, S. Lu, *IEEE Trans. Instrum. Meas.*, **69**, 5010-5017 (2020).
17. X. Hu, H. Zhang, D. Ma, R. Wang, T. Wang, X. Xie, *IEEE Trans. Neural. Netw. Learn. Syst.*, **34**, 7004-7013 (2023).
18. B. Liu, Z. Jiang, W. Nie, Y. Ran, H. Lin, *Measurement*, **186**, 110235 (2021).
19. L. Mei, S. Li, C. Zhang, M. Han, *IEEE Sens. J.*, **21**, 24601-24612 (2021).
20. Q. Meng, *IEEE Trans. Instrum. Meas.*, **71**, 9501209 (2022).
21. S. Li, M. Cai, M. Han, Z., *IEEE Sens. J.*, **22**, 13030-13042 (2022).
22. J. Li, Q. Zheng, Z. Qian, X. Yang, *Process. Saf. Environ. Prot.*, **123**, 309-316 (2019).
23. Р.Р. Уликанов, Т.А. Ижбулдин, *Проблемы машиностроения и автоматизации*, 3, 144-150 (2024).
24. Q. Li, R.Q. Lin, Y. Zhang, W. Ba, W. Lu, *Non-Destructive Testing and Condition Monitoring*, **63**, 610-617 (2021).
25. R.P. da Cruz, F.V. da Silva, A.M.F. Fileti, *Clean Technologies and Environmental Policy*, **22**, 627-638 (2020).
26. C. Spandonidis, P. Theodoropoulos, F. Giannopoulos, N. Galiatsatos, A. Petsa, *Engineering Applications of Artificial Intelligence*, **113**, 104890 (2022).
27. F.L. Ning, Z.H. Cheng, D. Meng, S. Duan, J. Wei, *Process Safety and Environmental Protection*, **146**, 726-735 (2020).
28. H. Shukla, K. Piratla, *Automation in Construction*, **17**, 103256 (2020).
29. Q.L. Xie, G.Q. Tao, B. He, Z.F. Wen, *Measurement*, **200**, 111624 (2022).

References

1. R.R. Gayazov, Yu.A. Znaemsky Yu.A., V.S. Kadysev, V.I. Lopatin, I.A. Marinin, *GIAB*, S11–52, 3-8 (2015).
2. I.S. Rizaev, D.N. Zaripova, M.S. Osipova, N.V. Andreyanov, *Herald of Technological University*, **28**, 8, 119-123 (2025).

3. A.S. Katasev, D.V. Kataseva, Yu.N. Smirnov, D.D. Nasibullina, *Herald of Technological University*, **27**, 7, 115-119 (2024).
4. D.I. Shigabedinova, Z.M. Gizatullin, M.P. Shleimovich, *Herald of Technological University*, **28**, 5, 123-128 (2025).
5. A.V. Grigoriev, *Science and technology of pipeline transportation of oil and petroleum products*, **14**, 6, 506-513 (2024).
6. D.P. Nikonorov, A.S. Katasev, *Herald of Technological University*, **28**, 6, 110-114 (2025).
7. X. Zheng, F. Hu, Y. Wang, L. Zheng, X. Gao, H. Zhang, S. You, B. Xu, *Energy*, **237**, 121604 (2021).
8. B.X. Liu, Z. Jiang, W. Nie, Y.J. Ran, H. Lin, *Measurement*, **186**, 110235 (2021).
9. J.Y. Lu, J.K. Yue, L.J. Zhu, D.M. Wang, G.F. Li, *Measurement*, **185**, 110107 (2021).
10. X.H. Pan, M.N. Karim, *Computer Aided Chemical Engineering*, **37**, 1787-1792 (2015).
11. D. Zaman, M.K. Tiwari, A.K. Gupta, D. Sen, *Eng. Fail. Anal.*, **109**, 104264 (2020).
12. C. Verde, L. Molina, L. Torres, *J. Loss. Prev. Process. Ind.*, **29**, 177-185 (2014).
13. O.M. Aamo, *IEEE Trans. Autom. Control.*, **61**, 246-251 (2016).
14. R. Lopezlena, S. Sadovnychiy, *J. Pipeline Syst. Eng. Pract.*, **10**, 04019017 (2019).
15. A. Keramat, H-F. Duan, *Mech. Syst. Signal Process*, **161**, 107940 (2021).
16. X. Lang, P. Li, Y. Guo, J. Cao, S. Lu, *IEEE Trans. Instrum. Meas.*, **69**, 5010-5017 (2020).
17. X. Hu, H. Zhang, D. Ma, R. Wang, T. Wang, X. Xie, *IEEE Trans. Neural. Netw. Learn Syst.*, **34**, 7004-7013 (2023).
18. B. Liu, Z. Jiang, W. Nie, Y. Ran, H. Lin, *Measurement*, **186**, 110235 (2021).
19. L. Mei, S. Li, C. Zhang, M. Han, *IEEE Sens. J.*, **21**, 24601-24612 (2021).
20. Q. Meng, *IEEE Trans. Instrum. Meas.*, **71**, 9501209 (2022).
21. S. Li, M. Cai, M. Han, Z., *IEEE Sens. J.*, **22**, 13030-13042 (2022).
22. J. Li, Q. Zheng, Z. Qian, X. Yang, *Process. Saf. Environ. Prot.*, **123**, 309-316 (2019).
23. R.R. Ulikanov, T.A. Izhbuldin, *Problems of machine building and automation*, **3**, 144-150 (2024).
24. Q. Li, R.Q. Lin, Y. Zhang, W. Ba, W. Lu, Non-Destructive Testing and Condition Monitoring, **63**, 610-617 (2021).
25. R.P. da Cruz, F.V. da Silva, A.M.F. Fileti, *Clean Technologies and Environmental Policy*, **22**, 627-638 (2020).
26. C. Spandonidis, P. Theodoropoulos, F. Giannopoulos, N. Galiatsatos, A. Petsa, *Engineering Applications of Artificial Intel-ligence*, **113**, 104890 (2022).
27. F.L. Ning, Z.H. Cheng, D. Meng, S. Duan, J. Wei, *Process Safety and Environmental Protection*, **146**, 726-735 (2020).
28. H. Shukla, K. Piratla, *Automation in Construction*, **17**, 103256 (2020).
29. Q.L. Xie, G.Q. Tao, B. He, Z.F. Wen, *Measurement*, **200**, 111624 (2022).

© **А. С. Сильвестров** – канд. техн. наук, главный инженер ООО «Астрапроект», Казань, Россия, silvestrovas@mail.ru; **М. Е. Колпак**ов – доктор хим. наук, профессор кафедры Аналитической химии, сертификации и менеджмента качества, Казанский национальный исследовательский технологический университет (КНИТУ), Казань, Россия, KolpakovME@corp.knrtu.ru; **С. И. Поникаров** – доктор техн. наук, профессор, заведующий кафедрой Машин и аппаратов химических производств (МАХП), КНИТУ, PonikarovSI@corp.knrtu.ru; **Р. Р. Шаймухаметов** – канд. физ.-мат. наук, доцент кафедры Системного анализа и информационных технологий, Казанский федеральный университет, ramil.shai@mail.ru; **Э. В. Осипов** – доктор хим. наук, доцент кафедры МАХП, КНИТУ, evosipov@kstu.ru

© **A. S. Silvestrov** – PhD (Technical Sci.), Chief Engineer of Astraproekt LLC, Kazan, Russia, silvestrovas@mail.ru; **M. E. Kolpakov** – Doctor of Sciences (Chemical Sci.), Professor of the Analytical Chemistry, Certification and Quality Management department, Kazan National Research Technological University (KNRTU), Kazan, Russia, KolpakovME@corp.knrtu.ru; **S. I. Ponikarov** – Doctor of Sciences (Technical Sci.), Full Professor, Head of the Department of Machines and Apparatus for Chemical Production (MACP), KNRTU, PonikarovSI@corp.knrtu.ru; **R. R. Shaimukhametov** – PhD (Physical and Mathematical Sci.), Associate Professor of the Department of System Analysis and Information Technology, Kazan Federal University, ramil.shai@mail.ru; **E. V. Osipov** – Doctor of Sciences (Chemical Sci.), Associate Professor of the MACPO department, KNRTU, evosipov@kstu.ru.

Дата поступления рукописи в редакцию – 03.06.25.

Дата принятия рукописи в печать – 07.11.25