





РАЗРАБОТКА И ИССЛЕДОВАНИЕ 1D-CNN ДЛЯ ИДЕНТИФИКАЦИИ ГАЗОВЫХ СМЕСЕЙ ПО СПЕКТРАЛЬНЫМ ДАННЫМ МУЛЬТИСПЕКТРАЛЬНОГО ДАТЧИКА**¹Ж.А. Муканова , ²М.М. Есмагамбетова ✉, ²Т.У. Есмагамбетов , ¹А.Б. Байсымакова **¹Университет «Туран», Алматы, Казахстан,²Карагандинский университет Казпотребсоюза, Караганда, Казахстан✉ Корреспондирующий автор: marzhan1983@mail.ru

В статье рассматривается задача автоматической идентификации состава газовых смесей на основе данных мультиспектрального сенсора. Анализ газовых сред является важной задачей для промышленной безопасности, экологического мониторинга, медицинской диагностики и интеллектуальных сенсорных систем. Традиционные методы газового анализа, основанные на спектроскопии, обеспечивают высокую точность измерений, однако требуют сложного оборудования и трудоемкой обработки данных. В связи с этим актуальным направлением является применение методов искусственного интеллекта для обработки спектральных сигналов. Целью данной работы является разработка и исследование модели сверточной нейронной сети для идентификации газовых смесей по спектральным данным мультиспектрального датчика AS7265x. Для проведения экспериментов была создана лабораторная установка, включающая мультиспектральный сенсор и систему контроля условий эксперимента на основе датчика температуры и давления. В качестве входных данных использовались спектральные векторы, содержащие 18 каналов интенсивности, соответствующих различным длинам волн. Для обработки спектральных данных была разработана архитектура одномерной сверточной нейронной сети (1D-CNN), способная выявлять характерные спектральные признаки различных газов. Модель была обучена и протестирована на экспериментальном наборе данных, содержащем измерения воздуха, углекислого газа и смеси кислорода с азотом. Экспериментальные результаты показали высокую точность классификации, достигшую 100% на тестовой выборке. Полученные результаты подтверждают эффективность применения методов глубокого обучения для анализа спектральных данных и демонстрируют перспективность использования компактных мультиспектральных сенсоров в интеллектуальных системах газоанализа.

Ключевые слова: мультиспектральный сенсор, анализ газовых смесей, сверточные нейронные сети, глубокое обучение, спектральный анализ, интеллектуальные сенсорные системы, идентификация газов, обработка сенсорных данных.

DEVELOPMENT AND INVESTIGATION OF A 1D-CNN FOR GAS MIXTURE IDENTIFICATION BASED ON SPECTRAL DATA FROM A MULTISPECTRAL SENSOR**¹Zh.A. Mukanova, ²M.M. Yesmagambetova ✉, ²T.U. Yesmagambetov, ¹A.B. Baisymakova**¹Turan University, Almaty, Kazakhstan,²Karaganda University of Kazpotrebsoyuz, Karaganda, Kazakhstan,
e-mail: marzhan1983@mail.ru

This article addresses the problem of automatically identifying the composition of gas mixtures based on data from a multispectral sensor. The analysis of gaseous media is a critical task for industrial safety, environmental monitoring, medical diagnostics, and intelligent sensor systems. Traditional gas analysis methods based on spectroscopy provide high measurement accuracy but require complex equipment and labor-intensive data processing. In this regard, the application of artificial intelligence methods for processing spectral signals is a timely area of research. The aim of this work is to develop and investigate a convolutional neural network model for identifying gas mixtures based on spectral data from the AS7265x

multispectral sensor. A laboratory setup was created for conducting experiments, including a multispectral sensor and a system for controlling experimental conditions based on temperature and pressure sensors. Spectral vectors containing 18 intensity channels corresponding to different wavelengths were used as input data. To process the spectral data, a one-dimensional convolutional neural network (1D-CNN) architecture was developed, capable of identifying characteristic spectral features of various gases. The model was trained and tested on an experimental dataset containing measurements of air, carbon dioxide, and a mixture of oxygen and nitrogen. The experimental results showed high classification accuracy, reaching 100% on the test set. The results confirm the effectiveness of deep learning methods for analyzing spectral data and demonstrate the potential for using compact multispectral sensors in intelligent gas analysis systems.

Keywords: multispectral sensor, gas mixture analysis, convolutional neural networks, deep learning, spectral analysis, intelligent sensor systems, gas identification, sensor data processing.

МУЛЬТИСПЕКТРЛІ ДАТЧИКТИҢ СПЕКТРЛІК ДЕРЕКТЕРІ БОЙЫНША ГАЗ ҚОСПАЛАРЫН ИДЕНТИФИКАЦИЯЛАУ ҮШІН 1D-CNN ӘЗІРЛЕУ ЖӘНЕ ЗЕРТТЕУ

¹Ж.А. Муканова, ²М.М. Есмагамбетова✉, ²Т.У. Есмагамбетов, ¹А.Б. Байсымакова

¹«Тұран» университеті, Алматы, Қазақстан,

²Қазтұтынуодағы Қарағанды университеті, Қарағанды, Қазақстан,
e-mail: marzhan1983@mail.ru

Мақалада мультиспектрлік датчиктің деректеріне негізделген газ қоспаларының құрамын автоматты түрде анықтау мәселесі қарастырылады. Газ ортасын талдау өнеркәсіптік қауіпсіздік, экологиялық мониторинг, медициналық диагностика және интеллектуалды сенсорлық жүйелер үшін маңызды міндет болып табылады. Спектроскопияға негізделген газды талдаудың дәстүрлі әдістері өлшеудің жоғары дәлдігін қамтамасыз етеді, бірақ күрделі жабдықты және көп уақытты қажет ететін деректерді өңдеуді қажет етеді. Осыған байланысты, жасанды интеллект әдістерін спектрлік сигналды өңдеуге қолдану зерттеудің өзекті саласы болып табылады. Бұл жұмыстың мақсаты - AS7265x мультиспектральды датчигінен алынған спектрлік деректер негізінде газ қоспаларын анықтауға арналған конволюциялық нейрондық желі моделін әзірлеу және бағалау. Эксперименттер жүргізу үшін мультиспектралды сенсорды және температура мен қысым сенсорына негізделген эксперимент шарттарын бақылау жүйесін қамтитын зертханалық қондырғы жасалды. Кіріс ақпараты ретінде ретінде әр түрлі толқын ұзындығына сәйкес келетін 18 қарқындылық арнасы бар спектрлік векторлар қолданылды. Спектрлік деректерді өңдеу үшін әртүрлі газдарға тән спектрлік белгілерді анықтауға қабілетті бір өлшемді конволюциялық нейрондық желі (1D-CNN) архитектурасы жасалды. Модель ауаның, көмірқышқыл газының және оттегі-азот қоспасының өлшемдерін қамтитын тәжірибелік деректер жиынтығында оқытылды және сыналды. Эксперименттік нәтижелер сынақ үлгісінде 100% жеткен жоғары жіктеу дәлдігін көрсетті. Алынған нәтижелер спектрлік деректерді талдау үшін терең оқыту әдістерінің тиімділігін растайды және интеллектуалды газ талдау жүйелерінде ықшам мультиспектральды сенсорларды пайдалану перспективасын көрсетеді.

Түйін сөздер: мультиспектрлік сенсор, газ қоспасын талдау, конволюциялық нейрондық желілер, терең оқыту, спектрлік талдау, интеллектуалды сенсорлық жүйелер, газдарды идентификациялау, сенсорлық деректерді өңдеу.

Введение. Анализ состава газовых смесей представляет собой одну из ключевых задач в таких критически важных областях, как промышленная безопасность [1], охрана окружающей среды [2], медицина [3] и агротехнологии. Традиционные методы газового анализа основаны на спектроскопии в инфракрасном диапазоне и позволяют проводить высокоточное определение молекулярного состава веществ [4,5]. Однако такие методы требуют дорогостоящего оборуду-

дования, длительной постобработки и высокой квалификации персонала.

В последние годы активно развиваются интеллектуальные методы анализа данных, основанные на алгоритмах машинного и глубокого обучения [6]. Использование нейронных сетей (НС) позволяет автоматизировать интерпретацию спектральных сигналов и ускорить процесс распознавания состава газовых смесей. Особенно перспективным направлением является применение сверточных нейронных сетей (CNN), которые способны эффективно извлекать информативные признаки из структурированных сенсорных данных.

Современные компактные газоаналитические системы часто используют мультиспектральные оптические датчики, позволяющие регистрировать интенсивность отражения или поглощения в нескольких спектральных диапазонах. Одним из таких устройств является сенсор AS7265x, обеспечивающий измерение интенсивностей в нескольких каналах спектра. При этом на точность измерений могут влиять внешние условия, такие как температура и давление. Поэтому использование дополнительных сенсоров окружающей среды (например, барометрических датчиков) позволяет повысить устойчивость моделей и учитывать физические условия измерений.

Целью данной работы является разработка и исследование модели сверточной нейронной сети для идентификации состава газовых смесей на основе данных мультиспектрального датчика и датчика температуры и давления. В рамках работы спектральные измерения использовались в качестве входных данных нейронной сети, тогда как параметры температуры и давления применялись для контроля и стабилизации условий проведения эксперимента.

Ожидается, что применение CNN позволит эффективно извлекать закономерности из спектральных сигналов и повысить устойчивость системы к шумам и изменениям внешних условий. Полученные результаты могут быть использованы при разработке интеллектуальных сенсорных систем нового поколения для мониторинга газовых сред как в лабораторных, так и в поле-

вых условиях.

Обзор литературы. В последние годы наблюдается стремительное развитие интеллектуальных систем газоанализа, объединяющих сенсорные технологии с методами искусственного интеллекта (ИИ). Такие системы находят применение в мониторинге окружающей среды, промышленной безопасности, медицинской диагностике и умных городах [7-11]. Особое внимание уделяется системам, способным к распознаванию сложных смесей газов в условиях высокой зашумленности и ограниченных вычислительных ресурсах. В данном разделе рассмотрены современные исследования, использующие как числовые спектры, так и визуальные изображения, а также архитектуры глубокого и мультимодального обучения.

Спектроскопия в сочетании с глубоким обучением.

Методы инфракрасной и оптической спектроскопии широко используются для анализа состава газов. В сочетании с алгоритмами машинного обучения такие методы позволяют автоматизировать процесс интерпретации спектров.

В работе Ding и др. [12] предложена архитектура многозадачного обучения для задач обнаружения газов, объединяющая рекуррентные нейронные сети типа LSTM и остаточную одномерную сверточную нейронную сеть. Предложенная модель Multi-task learning LACNet позволяет одновременно выполнять классификацию газов и прогнозирование их концентрации. Дополнительный модуль внимания обеспечивает автоматическое выделение наиболее информативных признаков сенсорных данных, что способствует повышению точности анализа. Экспериментальные результаты, полученные на открытых наборах данных электронных носов, показали высокую эффективность предложенного метода: точность классификации достигла 98–99 %, а коэффициент детерминации при оценке концентрации газов превысил 0.98. Полученные результаты подтверждают перспективность применения методов глубокого обучения для интеллектуальной обработки данных газовых сенсорных систем.

Zhang и его коллеги [13] предложили систему обнаружения газов, основанную на спектроскопии модуляции длины волны (Wavelength Modulation Spectroscopy, WMS) с использованием сигналов $2f/1f$. В работе была разработана модель прогнозирования концентрации на основе сверточной нейронной сети, предназначенная для компенсации перекрытия спектральных линий различных газовых компонентов. Для решения проблемы ограниченного объема экспериментальных данных авторы применили генеративно-сопоставительную сеть (GAN), позволяющую выполнять эффективное расширение обучающей выборки. Предложенный подход позволил одновременно определять концентрации углекислого газа (CO_2) и метана (CH_4) с высокой точностью. Полученные результаты продемонстрировали высокие коэффициенты детерминации при сравнении прогнозируемых и эталонных значений концентрации, а также низкие пределы обнаружения, что подтверждает перспективность применения методов глубокого обучения для спектроскопического анализа многокомпонентных газовых смесей.

В работе Mou и Zhu [14] предложен спектральный attention-модуль для анализа гиперспектральных данных, позволяющий выделять наиболее информативные спектральные полосы и снижать влияние шума.

Дополнительно исследования показывают эффективность интеллектуальной обработки сенсорных сигналов высокой частоты. В работе [15] предложен метод аппаратно-программной обработки высокочастотных данных, позволяющий улучшить качество анализа сенсорных измерений и повысить надежность интерпретации сигналов.

Сенсорные системы и интеллектуальный газоанализ.

Современные интеллектуальные газоаналитические системы объединяют данные различных сенсоров для повышения точности измерений. Помимо спектральных характеристик часто используются дополнительные параметры окружающей среды, такие как температура, давление и влажность.

Nasri и др. в обзорной работе [16] рассматривают различные типы газовых сенсоров, включая электрохимические, резистивные, ёмкостные и акустические датчики, а также методы их изготовления и повышения чувствительности. Авторы отмечают, что одной из ключевых проблем современных сенсорных систем является недостаточная селективность сенсоров и сложность распознавания газовых компонентов в условиях шумных и многокомпонентных данных. В работе показано, что использование алгоритмов машинного обучения позволяет значительно улучшить обработку сенсорных сигналов и повысить точность классификации газов. Кроме того, обсуждаются основные алгоритмы распознавания образов и их применение для интеллектуальной обработки данных газовых сенсорных систем. Полученные результаты подтверждают важность интеграции методов машинного обучения с современными сенсорными технологиями для разработки высокочувствительных и селективных систем обнаружения газов.

Отдельные исследования также рассматривают применение нейронных сетей для обработки данных мультиспектральных газоанализаторов и анализа спектральных сигналов сенсорных систем. Так, в работе [17] предложена нейросетевая модель обработки данных мультиспектрального газоанализатора, демонстрирующая перспективность использования методов машинного обучения для интерпретации спектральной информации и повышения точности распознавания газовых компонентов.

Таким образом, интеграция мультиспектральных сенсоров с алгоритмами глубокого обучения является перспективным направлением развития интеллектуальных систем газоанализа.

Материалы и методы. *Экспериментальная установка и сбор данных.*

Для проведения экспериментальных исследований была собрана лабораторная установка, представляющая собой компактную газодинамическую систему замкнутого цикла. Установка предназначена для регистрации спектральных характеристик газовых смесей и последующего

анализа их состава.

Основу экспериментального комплекса составляет микроконтроллерная плата Arduino, обеспечивающая управление сенсорами и сбор данных. Для регистрации спектральных характеристик использовался многоканальный оптический сенсор AS7265x, способный измерять интенсивности отражения в диапазоне длин волн от 410 до 940 нм. Сенсор регистрирует значения интенсивности в 18 спектральных каналах, формируя спектральный вектор измерений.

Для контроля условий проведения эксперимента применялся барометрический датчик BMP180, который использовался для мониторинга температуры и атмосферного давления в измерительной камере. Эти параметры фиксировались в ходе экспериментов для обеспечения стабильности условий измерений, однако не использовались в качестве входных данных нейронной сети.

Схема лабораторного стенда представлена на рисунке 1.

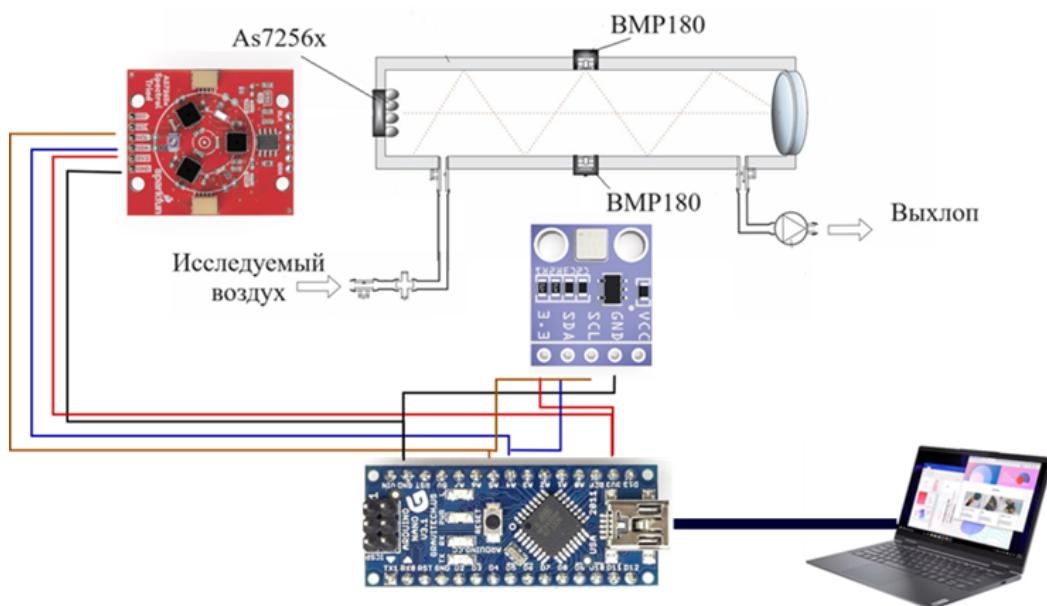


Рис.1 - Схема экспериментального стенда

Газовая смесь циркулировала внутри контейнера, снабженного параболическим диффузором и камерой генерации газа, где происходило насыщение воздуха исследуемыми компонентами. Движение газового потока обеспечивалось циркуляционным насосом, поддерживающим равномерную прокачку через измерительную ячейку.

В качестве исследуемых веществ использовались:

- воздух;
- углекислый газ (CO₂);
- смесь кислорода и азота в соотношении 9:1.

Измерения проводились в лабораторном по-

мещении площадью 20 м². Для калибровки и проверки точности использовался портативный газоанализатор Vosean K-600.

Каждому измерению соответствовал вектор из 18 спектральных значений, полученных с мультиспектрального сенсора AS7265x.

Предобработка данных. Полученные спектральные данные представляли собой одномерные векторы интенсивности, соответствующие различным длинам волн. В отличие от некоторых подходов, где спектры преобразуются в изображения или спектрограммы, в данной работе данные использовались непосредственно в виде спектральных векторов, что позволяет сохранить исходную физическую структуру сигнала.

ла.

Перед обучением модели данные проходили стандартную предварительную обработку, включающую:

- проверку корректности измерений;
- нормализацию спектральных значений;
- формирование обучающего набора данных.

Общий объём экспериментального набора данных составил 3192 спектральных измерения, полученных для трёх классов газовых сред:

- воздух - 1644 образца;
- CO₂ - 1116 образцов;
- O₂-N₂ - 432 образца.

Набор данных был разделён на три части:

- обучающая выборка - 70%,
- валидационная выборка - 15%,
- тестовая выборка - 15%.

Валидационная выборка использовалась для настройки гиперпараметров модели и контроля процесса обучения, тогда как тестовая выборка применялась исключительно для финальной оценки качества модели. Стратифицированное разбиение позволило сохранить исходное распределение классов во всех подвыборках.

Архитектура модели. Для идентификации со-

става газовых смесей была разработана модель одномерной сверточной нейронной сети (1D-CNN), предназначенная для обработки спектральных данных.

Входной слой сети принимает одномерный вектор из 18 спектральных значений, соответствующих каналам сенсора AS7265x. Эти данные представляют собой спектральную последовательность, в которой соседние элементы соответствуют близким диапазонам длин волн.

Архитектура сети включает следующие основные компоненты:

- сверточные слои Conv1D, извлекающие локальные спектральные признаки;
- слои подвыборки MaxPooling, уменьшающие размерность признакового пространства;
- полносвязные слои Dense, объединяющие извлечённые признаки;
- выходной слой Softmax, выполняющий классификацию типа газа.

Использование сверточных слоев позволяет автоматически выявлять характерные спектральные паттерны, соответствующие различным газам и их смесям.

На рисунке 2 представлена архитектура нейронной сети.

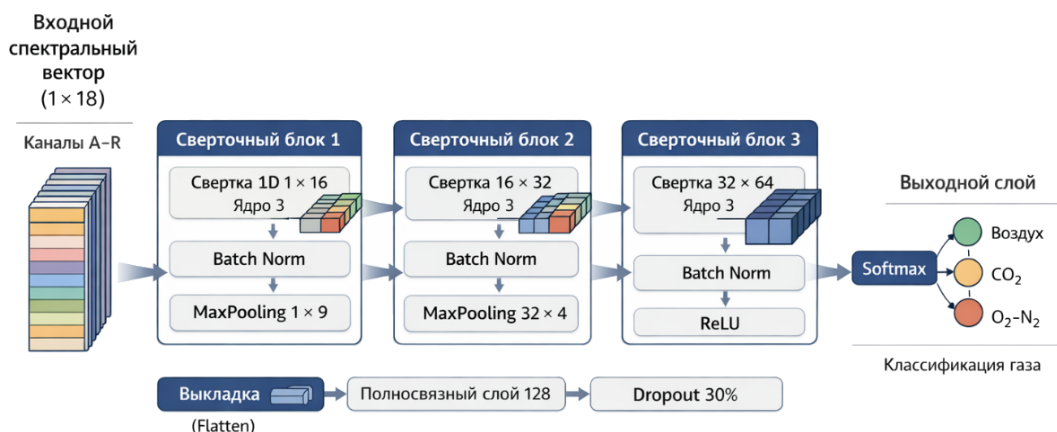


Рис.2 - Архитектура нейронной сети

Обучение и оценка модели. Модель была реализована с использованием библиотеки PyTorch и обучена на наборе данных, полученных в ре-

зультате лабораторных экспериментов.

Обучение проводилось с использованием оптимизатора Stochastic Gradient Descent (SGD) со

следующими параметрами:

- learning rate - 0.001
- momentum - 0.9
- batch size - 32

Для задачи классификации применялась функция потерь CrossEntropyLoss.

В процессе обучения на каждой эпохе оценивались показатели качества модели на обучающей и валидационной выборках. Основной метрикой выступала Точность (Accuracy), характеризующая долю правильно классифицированных образцов.

Дополнительно рассчитывались следующие метрики:

- Precision;
- Recall;
- F1-score

После завершения обучения финальная оценка модели проводилась на тестовой выборке. Для анализа результатов также строилась матрица ошибок (confusion matrix), позволяющая оценить точность распознавания различных типов газов.

В ходе обучения сохранялись графики изменения функции потерь и точности, что позволило контролировать динамику обучения и выявлять признаки возможного переобучения модели.

Обсуждение и результаты. *Результаты обучения модели.* Для оценки эффективности предложенной архитектуры 1D сверточной нейронной сети была проведена серия экспериментов на наборе спектральных данных, полученных с мультиспектрального сенсора. Данные были разделены на обучающую, валидационную и тестовую выборки. Обучение модели проводилось в течение 50 эпох с использованием оптимизатора стохастического градиентного спуска (SGD).

На рисунке 3 представлен график изменения функции потерь в процессе обучения. Можно наблюдать быстрое уменьшение значения функции потерь на первых эпохах обучения, что свидетельствует об эффективном процессе оптимизации параметров модели. После примерно 15–20 эпох значение функции потерь стабилизируется и постепенно приближается к нулю. При этом кривые обучающих и валидационных потерь практически совпадают, что указывает на отсутствие переобучения и хорошую способность модели к обобщению.

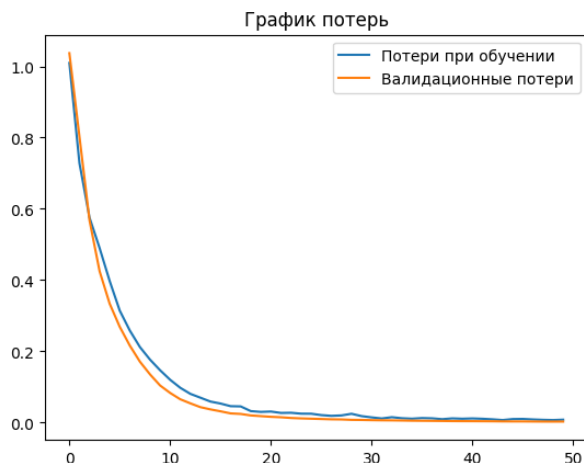


Рис.3 - График потерь

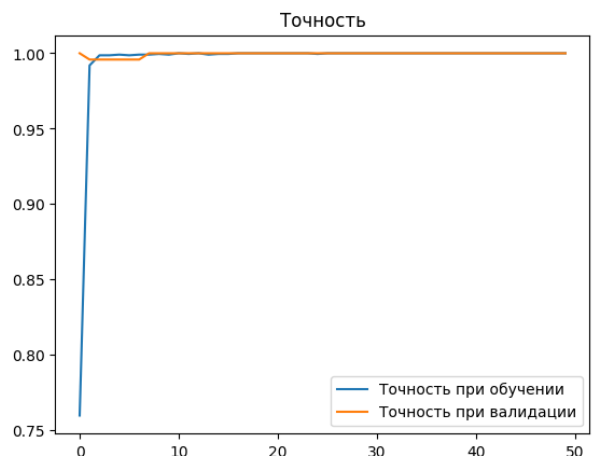


Рис.4 - График точности

Динамика изменения точности классификации показана на рисунке 4. Уже в первые эпохи наблюдается значительный рост точности, по-

сле чего точность быстро достигает значений, близких к 1.0. После примерно 10 эпох обучения точность на обучающей и валидационной

выборках стабилизируется на уровне 100%.

Оценка качества классификации. Финальная оценка эффективности модели проводилась на тестовой выборке, содержащей 479 образцов. Матрица ошибок представлена на рисунке 5.

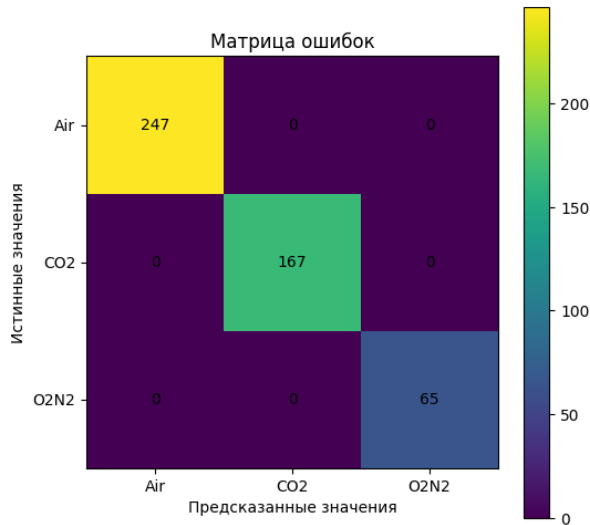


Рис.5 - Матрица ошибок

Как видно из матрицы ошибок, модель корректно классифицировала все образцы тестовой выборки. Для каждого класса все предсказания оказались правильными, а ошибки классификации отсутствуют. Количество правильно классифицированных образцов составило:

- Air - 247
- CO₂ - 167
- O₂N₂ - 65

Таким образом, предложенная модель успешно различает спектральные сигнатуры всех исследуемых газов.

Метрики качества модели. Для количественной оценки эффективности модели были рассчитаны стандартные метрики классификации: precision, recall и F1-score. Результаты приведены в таблице 1.

Таблица 1 - Метрики классификации

Класс	Precision	Recall	F1-score	Количество
Air	1.00	1.00	1.00	247
CO ₂	1.00	1.00	1.00	167
O ₂ -N ₂	1.00	1.00	1.00	65

Общая точность классификации составила:

Accuracy = 1.00 (100%)

Также были получены следующие агрегированные показатели:

Macro average F1-score = 1.00

Weighted average F1-score = 1.00

Для дополнительной оценки эффективности предложенной архитектуры 1D-CNN было проведено сравнение с рядом классических алгоритмов машинного обучения, широко применяемых для задач классификации сенсорных данных. В качестве базовых моделей использовались:

- метод опорных векторов (Support Vector Machine, SVM);

- Random Forest;

- многослойный перцептрон (MLP).

Все модели обучались и тестировались на одном и том же наборе спектральных данных с использованием одинакового разбиения на обучающую, валидационную и тестовую выборки. Для обеспечения корректности сравнения применялась одинаковая предварительная обработка данных, включающая нормализацию спектральных признаков.

Результаты сравнительного анализа показали, что все исследованные модели продемонстрировали очень высокую точность классификации (таблица 2).

Таблица 2 - Сравнение алгоритмов классификации

Модель	Accuracy	Precision	Recall	F1-score
SVM	1.00	1.00	1.00	1.00
Random Forest	1.00	1.00	1.00	1.00
MLP	1.00	1.00	1.00	1.00
1D-CNN	1.00	1.00	1.00	1.00

Несмотря на одинаковые итоговые значения accuracy, использование архитектуры 1D-CNN является перспективным для дальнейшего масштабирования системы на более сложные многокомпонентные смеси, поскольку сверточные сети способны автоматически извлекать локальные спектральные признаки и учитывать взаимосвязи между соседними спектральными каналами.

Анализ устойчивости моделей к шумовым искажениям. Дополнительно была проведена оценка устойчивости моделей к шумовым ис-

кажениям спектральных данных. Для этого в тестовые спектры добавлялся гауссов шум различной интенсивности. Полученные результаты позволили оценить влияние уровня шума на качество классификации различных моделей.

Результаты эксперимента показали, что при небольшом уровне шумов все исследованные модели сохраняют высокую точность классификации (таблица 3). Однако при увеличении интенсивности шумовых искажений наблюдалось постепенное снижение качества распознавания для всех алгоритмов.

Таблица 3 - Устойчивость моделей к шумовым искажениям

Noise STD	SVM	Random Forest	MLP	1D-CNN
0.1	1.000	1.000	1.000	1.000
0.2	1.000	0.996	1.000	1.000
0.3	1.000	0.990	0.998	0.979
0.5	0.987	0.952	0.956	0.894
1.0	0.839	0.800	0.862	0.668

Полученные результаты показывают, что при небольшом и умеренном уровне шумов все исследованные модели демонстрируют высокую устойчивость к искажениям спектральных сигналов. Однако при значительном увеличении уровня шума более устойчивые результаты продемонстрировали классические алгоритмы машинного обучения, в частности метод опорных векторов (SVM).

Вероятно, это связано с относительно небольшой размерностью входных спектральных данных (18 спектральных каналов), при которой

классические методы машинного обучения могут демонстрировать более высокую устойчивость к сильным шумовым искажениям по сравнению с глубокими сверточными архитектурами.

Полученные результаты свидетельствуют о том, что эффективность конкретной модели зависит не только от архитектуры алгоритма, но и от структуры спектральных данных, уровня шумов и сложности рассматриваемой задачи. Проведенный анализ подтверждает перспективность применения как глубоких нейронных

сетей, так и классических методов машинного обучения для задач интеллектуального анализа спектральных данных газовых сенсоров. Одновременно результаты показывают необходимость дальнейших исследований, направленных на повышение устойчивости моделей к шумовым искажениям и расширение числа анализируемых газовых смесей.

Анализ полученных результатов. Полученные результаты показывают, что исследуемые спектральные данные обладают высокой степенью разделимости для рассматриваемых классов газов. Все исследованные модели машинного обучения, включая SVM, Random Forest, MLP и предложенную архитектуру 1D-CNN, продемонстрировали высокую точность классификации на тестовой выборке.

Высокие значения ассигасу могут быть объяснены выраженными различиями спектральных характеристик исследуемых газов, а также тем, что данные были получены в контролируемых лабораторных условиях с относительно низким уровнем шумов и помех. Несмотря на небольшую размерность входных данных (18 спектральных каналов), модели смогли эффективно выявлять закономерности, соответствующие различным газовым компонентам.

Проведённый анализ устойчивости моделей к шумовым искажениям показал, что при небольшом уровне шумов все исследованные алгоритмы сохраняют высокую точность классификации. Однако при значительном увеличении уровня шума более устойчивые результаты продемонстрировали классические методы машинного обучения, в частности SVM. Вероятно, это связано с относительно небольшой размерностью входных спектральных данных, при которой классические алгоритмы могут быть менее чувствительны к сильным случайным искажениям по сравнению с глубокими сверточными архитектурами.

Следует учитывать, что достигнутая точность классификации была получена на ограниченном экспериментальном наборе данных в контролируемых условиях. Поэтому полученные результаты требуют дальнейшей проверки на более

сложных многокомпонентных газовых смесях и различных концентрациях компонентов.

Выводы. В данной работе была разработана и исследована архитектура сверточной нейронной сети для идентификации газов на основе данных мультиспектрального сенсора. В качестве входных данных использовались спектральные значения, полученные с сенсора AS7265x, регистрирующего интенсивности в 18 спектральных каналах. Дополнительные параметры окружающей среды, такие как температура и давление, применялись для контроля условий проведения эксперимента.

Предложенная модель одномерной сверточной нейронной сети позволила эффективно извлекать информативные признаки из спектральных данных и продемонстрировала высокую точность классификации исследуемых газов. Экспериментальные результаты показали, что модель способна корректно различать спектральные сигнатуры воздуха, углекислого газа и смеси кислорода с азотом. При тестировании на независимой выборке была достигнута точность классификации 100%, а значения метрик precision, recall и F1-score также составили 1.00 для всех классов.

Полученные результаты демонстрируют высокую эффективность применения сверточных нейронных сетей для анализа спектральных данных мультиспектральных сенсоров. Несмотря на относительно небольшое количество входных признаков, модель способна выявлять устойчивые спектральные закономерности, соответствующие различным газовым компонентам.

Дополнительно следует отметить, что предложенная архитектура 1D-CNN является развитием ранее исследованной модели многослойного перцептрона (MLP), применявшейся для анализа спектральных данных мультиспектрального газоанализатора. В отличие от полносвязных архитектур, сверточная нейронная сеть позволяет более эффективно учитывать локальные взаимосвязи между спектральными каналами, что делает её более перспективной для дальнейшего масштабирования при увеличении числа исследуе-

мых газов и газовых смесей.

Следует учитывать, что текущий эксперимент проводился на ограниченном количестве газов и газовых смесей в контролируемых лабораторных условиях. Поэтому полученные результаты не следует напрямую обобщать на произвольные многокомпонентные смеси без проведения дополнительных исследований. Кроме того, достигнутая точность классификации характеризует эффективность модели в рамках рассматриваемого экспериментального сценария и требует дальнейшей проверки на более сложных наборах данных, содержащих большее число газов и различные концентрации компонентов.

Несмотря на указанные ограничения, результаты исследования подтверждают перспективность применения методов глубокого обучения в сочетании с компактными мультиспектральными сенсорами для создания интеллектуальных систем газоанализа. Полученные результаты создают основу для дальнейших исследований, направленных на расширение набора анализируемых газов, увеличение количества газовых смесей и повышение устойчивости моделей к изменениям внешних условий.

Перспективным направлением дальнейших исследований является развитие более сложных архитектур анализа данных, в частности мультимодальных моделей. В будущей работе планируется разработка и исследование мультимодальной нейросетевой архитектуры для идентификации состава газовых смесей на основе объединения числовых спектров и их визуальных представлений в виде спектрограмм. Предполагается, что такой подход позволит объединить преимущества классических полносвязных моделей (MLP), эффективно работающих с числовыми векторными данными, и сверточных нейронных сетей (CNN), способных извлекать пространственные признаки из изображений спектров. В рамках этой работы также планируется провести сравнительный анализ мультимодальной архитектуры с базовыми моделями, использующими только числовые спектры или только визуальные представления данных.

Таким образом, данная работа является следующим этапом развития интеллектуальной системы анализа газовых смесей, основанной на применении мультиспектральных сенсоров и методов глубокого обучения.

Литература

1. Maasakkers J.D. et al. Using satellites to uncover large methane emissions from landfills //Science Advances. -2022. -Vol.8 (32): eabn9683. DOI 10.1126/sciadv. abn9683.
2. Mei Y., et al. Convolution theorem associated with the QWFRFT //Chinese Journal of Electronics. -2023. -Vol.32 (3). -P.485-492. DOI 10.23919/cje.2021.00.225.
3. Mahapatra C. Recent advances in medical gas sensing with artificial intelligence-enabled technology //Medical Gas Research. -2025. -Vol. 15(2). -P.318-326. DOI 10.4103/mgr.MEDGASRES-D-24-00113.
4. Zhang W. et al. A review of machine learning for near-infrared spectroscopy //Sensors. -2022. -Vol.22 (24): 9764. DOI 10.3390/s22249764.
5. Guan G., et al. Near-infrared off-axis cavity-enhanced optical frequency comb spectroscopy for CO₂/CO dual-gas detection assisted by machine learning //ACS sensors. -2024. -Vol.9 (2). -P.820-829. DOI 10.1021/acssensors.3c02146.
6. Chowdhury M.A.Z., Oehlschlaeger M.A. Deep learning for gas sensing via infrared spectroscopy //Sensors. -2024. -Vol.24 (6): 1873. DOI 10.3390/s24061873.
7. Chowdhury M.A.Z., Oehlschlaeger M.A. Artificial intelligence in gas sensing: a review //ACS sensors. -2025. -Vol.10 (3). -P.1538-1563. DOI 10.1021/acssensors.4c02272.
8. Zong B., et al. Smart gas sensors: recent developments and future prospective //Nano-Micro Letters. -2025. -Vol.17(1). -P.54. DOI 10.1007/s40820-024-01543-w.

9. Gu Y., Huang B., Zhu H. Smart gas sensors toward signal and data processing: A review //IEEE Sensors Journal. - 2024. - Vol.25(2). - P. 2125-2140. DOI 10.1109/JSEN.2024.3507195.
10. Feng S., et al. Review on smart gas sensing technology //Sensors. -2019. -Vol.19(17): 3760. DOI 10.3390/s19173760.
11. Chen Z., et al. Smart gas sensor arrays powered by artificial intelligence //Journal of Semiconductors. -2019. -Vol.40 (11): 111601. DOI 10.1088/1674-4926/40/11/111601.
12. Ding Y., et al. Multi-task learning with attention for efficient gas classification and concentration prediction in sensor arrays //Measurement Science and Technology. -2026. -Vol.37(2): 025102. DOI 10.1088/1361-6501/ae2b8f.
13. Zhang H. Et al. Deep Learning-Enhanced Dual-Component Gas Sensor Based on Wavelength Modulation Spectroscopy //Analytical Chemistry. -2025. -Vol.97 (40). -P.22032-22040. DOI 10.1021/acs.analchem.5c03438.
14. Mou L., Zhu X. X. Learning to pay attention on spectral domain: A spectral attention module-based convolutional network for hyperspectral image classification //IEEE Transactions on Geoscience and Remote Sensing. -2019.-Vol.58(1). -P.110-122. DOI 10.1109/TGRS.2019.2933609.
15. Mukanova Z., Atanov S., Jamshidi M. Intelligent hardware-software processing of high-frequency scanning data //Journal of Robotics and Control (JRC). -2023. -Vol.4 (5). -P.600-611. DOI 10.18196/jrc.v4i5.18915.
16. Nasri A., et al. A smart gas sensor using machine learning algorithms: sensor types based on IED configurations, fabrication techniques, algorithmic approaches, challenges, progress, and limitations: a review //IEEE Sensors Journal. -2023. -Vol.23 (11). -P. 11336-11355. DOI 10.1109/JSEN.2023.3268342.
17. Муканова Ж., Атанов С. Разработка модели нейронной сети для анализа газовых смесей //Вестник КазАТК. -2024. -Т.132(3). - С.350-360. DOI 10.52167/1609-1817-2024-132-3-350-360.

References

1. Maasackers J.D. et al. Using satellites to uncover large methane emissions from landfills //Science Advances. -2022. -Vol.8 (32): eabn9683. DOI 10.1126/sciadv. abn9683.
2. Mei Y., et al. Convolution theorem associated with the QWFRFT //Chinese Journal of Electronics. -2023. -Vol.32 (3). -P.485-492. DOI 10.23919/cje.2021.00.225.
3. Mahapatra C. Recent advances in medical gas sensing with artificial intelligence-enabled technology //Medical Gas Research. -2025. -Vol. 15(2). -P.318-326. DOI 10.4103/mgr.MEDGASRES-D-24-00113
4. Zhang W. et al. A review of machine learning for near-infrared spectroscopy //Sensors. -2022. -Vol.22 (24): 9764. DOI 10.3390/s22249764.
5. Guan G., et al. Near-infrared off-axis cavity-enhanced optical frequency comb spectroscopy for CO₂/CO dual-gas detection assisted by machine learning //ACS sensors. -2024. -Vol.9 (2). -P.820-829. DOI 10.1021/acssensors.3c02146.
6. Chowdhury M.A.Z., Oehlschlaeger M.A. Deep learning for gas sensing via infrared spectroscopy //Sensors. -2024. -Vol.24 (6): 1873. DOI 10.3390/s24061873.
7. Chowdhury M.A.Z., Oehlschlaeger M.A. Artificial intelligence in gas sensing: a review //ACS sensors. -2025. -Vol.10 (3). -P.1538-1563. DOI 10.1021/acssensors.4c02272.
8. Zong B., et al. Smart gas sensors: recent developments and future prospective //Nano-Micro Letters. -2025. -Vol.17(1). -P.54. DOI 10.1007/s40820-024-01543-w.

9. Gu Y., Huang B., Zhu H. Smart gas sensors toward signal and data processing: A review //IEEE Sensors Journal. - 2024. - Vol.25(2). - P. 2125-2140. DOI 10.1109/JSEN.2024.3507195.
10. Feng S., et al. Review on smart gas sensing technology //Sensors. -2019. -Vol.19(17): 3760. DOI 10.3390/s19173760.
11. Chen Z., et al. Smart gas sensor arrays powered by artificial intelligence //Journal of Semiconductors. -2019. -Vol.40 (11): 111601. DOI 10.1088/1674-4926/40/11/111601.
12. Ding Y., et al. Multi-task learning with attention for efficient gas classification and concentration prediction in sensor arrays //Measurement Science and Technology. -2026. -Vol.37(2): 025102. DOI 10.1088/1361-6501/ae2b8f.
13. Zhang H. Et al. Deep Learning-Enhanced Dual-Component Gas Sensor Based on Wavelength Modulation Spectroscopy //Analytical Chemistry. -2025. -Vol.97 (40). -P.22032-22040. DOI 10.1021/acs.analchem.5c03438.
14. Mou L., Zhu X. X. Learning to pay attention on spectral domain: A spectral attention module-based convolutional network for hyperspectral image classification //IEEE Transactions on Geoscience and Remote Sensing. -2019.-Vol.58(1). -P.110-122. DOI 10.1109/TGRS.2019.2933609.
15. Mukanova Z., Atanov S., Jamshidi M. Intelligent hardware-software processing of high-frequency scanning data //Journal of Robotics and Control (JRC). -2023. -Vol.4 (5). -P.600-611. DOI 10.18196/jrc.v4i5.18915.
16. Nasri A., et al. A smart gas sensor using machine learning algorithms: sensor types based on IED configurations, fabrication techniques, algorithmic approaches, challenges, progress, and limitations: a review //IEEE Sensors Journal. -2023. -Vol.23 (11). -P. 11336-11355. DOI 10.1109/JSEN.2023.3268342.
17. Mukanova Zh., Atanov S. Razrabotka modeli nejronnoj seti dlja analiza gazovyh smesej //Vestnik KazATK. -2024. -T.132(3). - S. 350-360. DOI 10.52167/1609-1817-2024-132-3-350-360. [in Russian]

Сведения об авторах

Муканова Ж.А.- PhD, Университет «Туран», Алматы, Казахстан, e-mail: Zhanna.Mukanova.83@mail.ru;

Есмагамбетова М.М.- PhD, Карагандинский университет Казпотребсоюза, Караганда, Казахстан, e-mail: marzhan1983@mail.ru;

Есмагамбетов Т.У.- магистр, Карагандинский университет Казпотребсоюза, Караганда, Казахстан, e-mail: Timur198300@mail.ru;

Байсымакова А.Б.- студентка, Университет «Туран», Алматы, Казахстан, e-mail: anelya.baisymakova.2004@gmail.com.

Information about the authors

Mukanova Zh.- PhD, Turan University, Almaty, Kazakhstan, e-mail: Zhanna.Mukanova.83@mail.ru;

Yesmagambetova M.- PhD, Karaganda University of Kazpotrebsoyuz, Karaganda, Kazakhstan, e-mail: marzhan1983@mail.ru;

Yesmagambetov T. - Master' s degree, Karaganda University of Kazpotrebsoyuz, Karaganda, Kazakhstan, e-mail: Timur198300@mail.ru;

Baisymakova A.- a student, Университет «Туран», Алматы, Казахстан, e-mail: anelya.baisymakova.2004@gmail.com.