

УДК 004.032.26

DOI 10.52167/1609-1817-2024-132-3-350-360

Ж.А. Муканова¹, С.К. Атанов²

¹Turan University, Алматы, Казахстан

²Евразийский национальный университет им. Л.Н. Гумилева, Астана, Казахстан.

E-mail: Zhanna.Mukanova.83@mail.ru

РАЗРАБОТКА МОДЕЛИ НЕЙРОННОЙ СЕТИ ДЛЯ АНАЛИЗА ГАЗОВЫХ СМЕСЕЙ

Аннотация. Проблема производственных травм остается значимой в Казахстане и мировом масштабе. Исследования отечественных ученых показывают, что основными лидирующими отраслями с наиболее высокими показателями производственного травматизма уже многие годы стабильно остаются обрабатывающая, горнодобывающая и строительная отрасли, а одной из причин является высокий уровень загазованности рабочих помещений. Целью данного исследования являются выбор архитектуры и разработка нейронной сети для мультиспектрального газоанализатора, способная проводить качественный анализ газовых смесей в воздушной среде на наличие опасных газов, которую в дальнейшем планируется использовать при разработке газоанализатора. В работе показан процесс разработки однослойного персептрона, предназначенного для анализа предварительно обработанных спектральных данных, с одним входным слоем, одним скрытым слоем и одним выходным слоем. Представлена математическая модель предложенной архитектуры нейронной сети. А также реализован программный код на языке программирования Python для построения, обучения и тестирования нейронной сети. Исследования показали, что в выходном слое наиболее подходящей функцией активации является функция Softmax. В скрытом слое может быть применена любая из рассмотренных функций. Однако, наилучшие результаты показала функция активации ReLU. При этом количество нейронов в скрытом слое – 45, а для обучения данной нейронной сети достаточно 37 итераций.

Ключевые слова. Искусственная нейронная сеть, нейрон; функция активации, газовая смесь, газоанализатор.

Введение.

Проблема производственного травматизма многие годы остается актуальной как в Казахстане, так и во всем мире. Недостаточное соблюдение норм и правил безопасности на производстве, недостаточное обучение и информирование, плохие условия труда, связанные, например, с отсутствием необходимого оборудования или его неисправностью, может привести к серьезным травмам, которые оказывают негативное воздействие на здоровье и благосостояние работников, а также вызывает значительные экономические потери для компаний и государств.

Н.Ж. Ердесов, Е.Н. Сраубаев и Б. Серик в своей работе «Производственный травматизм и профессиональная заболеваемость в Республике Казахстан» провели анализ производственного травматизма и профессиональной заболеваемости в Республике Казахстан за период с 2008 по 2018 гг. и представили данные по отраслям с неблагоприятными и вредными условиями труда. Исследование показало, что обрабатывающая, горнодобывающая и строительная отрасли постоянно оставались в роли основных лидеров с наивысшими показателями производственного травматизма на протяжении всего анализируемого периода [1].

Анализируя статистические данные о случаях производственного травматизма в Республике Казахстан, исследователи Н.Ж. Ердесов, Е.Н. Сраубаев и Б. Серик отмечают, что наибольшее количество пострадавших на производстве за последние десятилетия зарегистрировано в Карагандинской, Восточно-Казахстанской, Павлодарской и Костанайской областях. Количество пострадавших в данных регионах в среднем за 10 лет составляет чуть менее 50% от общего числа пострадавших в республике. Такая ситуация объясняется присутствием в указанных регионах крупных промышленных предприятий, включая металлургические, горнодобывающие и химические компании. Эти предприятия, помимо того, что являются источниками выбросов вредных веществ в атмосферу, также представляют собой места повышенного риска, где может существовать опасность накопления вредных газов в закрытых помещениях, таких как цехи и склады [1].

В качестве одной из рекомендаций для улучшения сложившейся ситуации можно предложить исследование новых методов мониторинга загрязнения воздуха, чтобы обеспечить более точную и эффективную оценку уровня загрязнения воздуха. Производственные предприятия должны быть оснащены высококачественным оборудованием (газоанализаторами), способным давать сигнал тревоги заранее, то есть до достижения загазованности, соответствующей нижнему концентрационному пределу воспламенения.

В настоящее время наблюдается технологический рост в области проектирования искусственного интеллекта [2] и, в частности, искусственных нейронных сетей (ИНС) [3]. Исследования в этой области представляют собой значительный вклад в развитие промышленности, научного и технологического секторов, а также обладают высоким экономическим значением [4]. Применение ИНС в газоанализаторах позволит расширить разновидность определяемых газов [5, 6].

Цель данного исследования – выбор архитектуры и разработка нейронной сети (НС) для мультиспектрального газоанализатора, способная проводить качественный анализ газовых смесей в воздушной среде на наличие опасных газов. Результаты данного исследования планируется применить при разработке прототипа интеллектуального газоанализатора по формуле, представленной в патенте на полезную модель «Интеллектуальный газоанализатор» №8288 от 21.03.2023 [7], использующий НС для анализа решений

Материалы и методы.

Нейронная сеть — это громадный параллельный процессор, состоящий из элементарных единиц обработки информации, накапливающих экспериментальные знания и предоставляющих их для последующей обработки [8]. В последнее время искусственные нейронные сети стали популярной и полезной моделью для классификации, кластеризации, распознавания образов и прогнозирования во многих дисциплинах [9, 10].

На рисунке 1 представлена многоспектральная сенсорная система с поддержкой искусственного интеллекта (ИИ) для определения типа газовой смеси. Полученные спектральные данные сохраняются для предварительной обработки. Предварительно обработанные данные выборки передаются в нелинейную нейронную сеть для дальнейшего анализа. Эти предварительно обработанные данные используются для обучения, тестирования и проверки нейронной сети. Более подробное описание лабораторного стенда, процесса сбора и обработки данных представлено в работе [11].

Математическая модель и архитектура сети. В рамках данного исследования был построен однослойный персептрон, предназначенный для анализа предварительно обработанных спектральных данных, с одним входным слоем, одним скрытым слоем и одним выходным слоем (рисунок 3).

Входной слой состоит из 20 нейронов (по числу каналов). Поскольку НС строится для решения задач многоклассовой классификации, то количество нейронов (o_i) в выходном слое соответствует количеству видов газовых смесей в обучающем наборе и равно 3, поскольку мы определяем 3 типа воздушно-газовых смесей: проба воздуха в помещении лаборатории, углекислый газ (CO_2) и смесь, состоящая из чистого кислорода (O_2) с азотом (N_2) в соотношении 9:1.

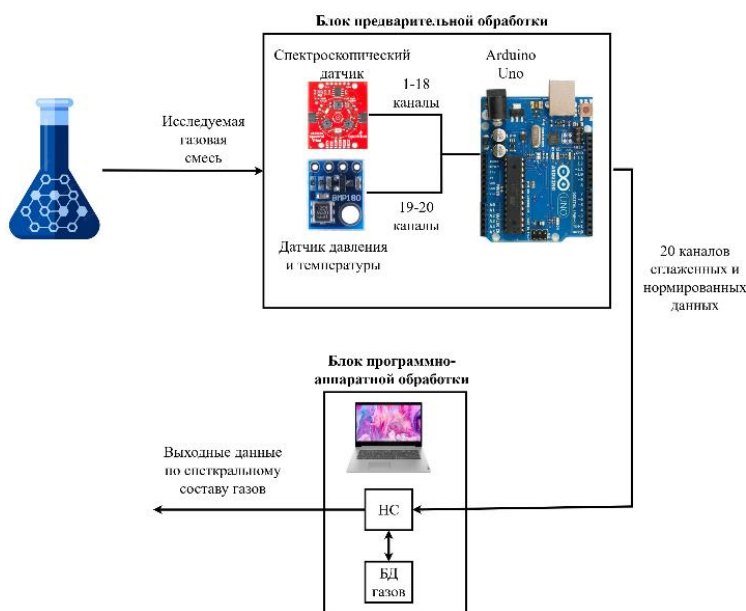


Рисунок 1 - Многоспектральная сенсорная система с поддержкой искусственного интеллекта (ИИ)

Введем некоторые обозначения.

Представим входы как x_1, x_2, \dots, x_{20} , где каждый x_i представляет собой значение входного канала, а y_1, y_2, y_3 – выходы НС.

Скрытый слой предназначен для извлечения более сложных признаков. Обозначим нейроны скрытого слоя как a_1, a_2, \dots, a_h , где h – количество нейронов в скрытом слое. Веса между входным и скрытым слоями представляют собой весовую матрицу $w^{(1)} = \{w_{ij}\}$, где $i = \overline{1, 20}$ – индекс входного нейрона, $j = \overline{1, h}$ – индекс нейрона в скрытом слое. Веса между скрытым и выходным слоями представляют собой весовую матрицу $w^{(2)} = \{w_{ij}\}$, где $i = \overline{1, h}$ – индекс входного нейрона, $j = \overline{1, 3}$ – индекс нейрона в скрытом слое.

На рисунке 2 представлена архитектура НС.




Рисунок 2 - Архитектура нейронной сети

Значения нейронов в скрытом слое вычисляются по формулам (1) и (2).

$$z_j^{(1)} = \sum_{i=1}^{20} x_i w_{ij} + b^{(1)}, j = \overline{1, h}, \quad (1)$$

$$a_j = f_1(z_j^{(1)}), j = \overline{1, h}, \quad (2)$$

где $b^{(1)}$ - смещение первого слоя, f_1 – функция активации.

Значения нейронов в скрытом слое вычисляются по формулам (3) и (4).

$$z_j^{(2)} = \sum_{i=1}^h a_i w_{ij} + b^{(2)}, j = \overline{1, 3}, \quad (3)$$

$$y_j = f_2(z_j^{(2)}), j = \overline{1, 3}, \quad (4)$$

где $b^{(2)}$ - смещение второго слоя, f_2 – функция активации.

Функция активации называется математическая функция, которая вычисляет значения выходного сигнала нейрона на основе входных данных и весов [12]. Выбор активационной функции одна из первоочередных задач для построения правильной НС, однако, не существует единого правила, в каком случае какую из функций применять.

Процесс обучения нейронной сети выполняется с использованием метода обратного распространения ошибки [13]. В ходе обучения происходит коррекция весов сети таким образом, чтобы определенное множество входных данных соответствовало желаемому множеству выходных данных. При этом предполагается, что каждой группе входных данных соответствует соответствующая целевая группа, определяющая требуемый результат. Вместе они формируют обучающую пару.

Первоначально значения веса и смещения назначаются случайным образом и обрабатываются вместе с входными данными методом прямого распространения. Значение выходной ошибки вычисляется путем сравнения фактического значения и прогнозируемого значения, так что выходная ошибка будет минимизирована с помощью алгоритма градиентного спуска. Перекрестная энтропия используется как функция потерь.

На начальном этапе построения НС определяется объем обучающей, проверочной, а также тестовой выборки. По обучающей выборке производится настройка НС. Проверочная выборка используется, чтобы оценить обобщающие свойства сети и остановить обучение, когда обобщение прекращает улучшаться. Тестовая выборка не оказывает влияние на обучение, а служит для проверки качества обучения на данных, которые не использовались в обучении сети. Чем больше объем выборки, тем более точные результаты будет выдавать нейронная сеть.

Также необходимо указать количество нейронов на скрытом слое. Количество нейронов влияет на точность расчетов с помощью будущей НС. Однако, здесь нет точной настройки и количество нейронов выбирается методом проб и ошибок индивидуально для каждой поставленной задачи.

Таким образом для построения НС необходимо определиться с количеством нейронов на скрытом слое, а также функциями активации f_1 и f_2 .

Результаты.

Поскольку НС строится для решения задачи многоклассовой классификации, то наиболее подходящей функцией активации на выходном слое является функция Softmax [14]. После Softmax обычно выбирается класс с максимальной вероятностью в качестве предсказания.

В таблице 1 представлен сравнительный анализ известных на настоящий момент функций активации, которые применяются в скрытом слое в том числе.

Выбор конкретной функции активации зависит от конкретной задачи и того, как хорошо она сочетается с данными. Рекомендуется проводить эксперименты и тестировать различные функции активации для определения наилучшего варианта в конкретном случае [15]. В рамках данного исследования был написан программный код на языке программирования Python по построению, обучению и тестированию НС. Фрагмент кода представлен на рисунке 3.

Таблица 1 – Сравнительный анализ функций активации

Функция активации	Формула	Достоинства	Недостатки
Sigmoid (сигмоид)	$f(x) = \frac{1}{1 + e^{-x}}$	Экономия времени за счет упрощения математических операций	1. Может вызывать проблему затухания градиента. 2. Выходные значения сигмоиды не центрированы нулем. 3. Требуется больших вычислительных мощностей.
Tanh (гиперболический тангенс)	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Экономия времени за счет упрощения математических операций	1. Может вызывать проблему затухания градиента. 2. Требуется больших вычислительных мощностей.
ReLU (Rectified Linear Unit) или линейный выпрямитель	$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases}$	1. Экономия времени за счет упрощения математических операций. 2. Обеспечивает быстрый пересчет времени на одну итерацию за счет возможности инактивации некоторых нейронов.	Отрицательные входные значения дают на выходе нулевой градиент, что негативно сказывается на процессе обучения нейронной сети из-за отсутствия обновления весовых коэффициентов.
Leaky ReLU	$f(x) = \max(0.01x, x)$	1. Решает проблему «умерших нейронов», предоставляя небольшой, но ненулевой градиент для отрицательных входов. 2. Проста в реализации.	1. Не всегда дает лучшие результаты по сравнению с другими активациями, такими как PReLU и ELU. 2. Небольшая утечка может быть нежелательной в некоторых сценариях.
PReLU (Parametric ReLU)	$f(x) = \max(\alpha x, x)$, где α - обучаемый параметр	1. Аналогично Leaky ReLU, но с параметром, который можно настроить в процессе обучения, что делает его более гибким. 2. Параметр α может быть обучаемым, что позволяет сети настраивать уровень утечки для каждого нейрона.	Может быть более сложным в реализации и требует дополнительных вычислительных ресурсов.
ELU (Exponential Linear Unit)	$f(x) = \begin{cases} x, & x > 0 \\ \alpha(e^x - 1), & x \leq 0 \end{cases}$, где α - обучаемый параметр	Решает проблему «умерших нейронов» с помощью отрицательных значений, но с более гладкими отрицательными значениями.	Может привести к более высоким требованиям к памяти и вычислительным ресурсам.

```
# Определение класса нейронной сети
class Net(nn.Module):
    def __init__(self, input_size, num_classes):
        super(Net, self).__init__()
        self.fc1 = nn.Linear(input_size, hidden_neurons)
        self.norm1 = nn.LayerNorm(hidden_neurons)
        self.activation = nn.ReLU()
        self.fc2 = nn.Linear(hidden_neurons, num_classes)
        self.softmax = nn.Softmax(dim=1)

    def forward(self, x):
        x = self.fc1(x)
        x = self.norm1(x)
        x = self.activation(x)
        x = self.fc2(x)
        x = self.softmax(x)
        return x

# Инициализация параметров
input_size = len(predictorNames)
num_classes = len(classNames)
```

Рисунок 3 - Фрагмент программного кода

В программе поочередно подставлялись функции активации из таблицы 1. Для выбора оптимальной функции при обучении и тестировании НС фиксировались минимальные потери, максимальные потери и точность, а также время обучения НС в секундах. Для определения количества нейронов использовался метод перебора. Результаты отражены в таблице 2.

Таблица 2 – Результаты обучения и тестирования НС

Функция активации	Sigmoid	Tanh	ReLU	LeakyReLU	PReLU	ELU
Количество нейронов	46	48	45	44	39	31
Минимальные потери при обучении	0,5527	0,5515	0,5515	0,5517	0,5515	0,5515
Минимальные потери при тестировании	0,5526	0,5515	0,5516	0,5518	0,5516	0,5516
Максимальная точность при обучении	1,0	1,0	1,0	1,0	1,0	1,0
Максимальная точность при тестировании	1,0	1,0	1,0	1,0	1,0	1,0
Максимальная полнота при обучении	1,0	1,0	1,0	1,0	1,0	1,0
Максимальная полнота при тестировании	1,0	1,0	1,0	1,0	1,0	1,0
Время обучения (сек)	0,12	0,08	0,07	0,13	0,11	0,11

Для визуальной оценки работоспособности НС были построены графики потерь, точности и полноты для каждой из нейронных сетей. Графики потерь показали, что все построенные нейронные сети хорошо обучаемы, а полнота и точность практически сразу принимают значения 1. На рисунках 4 и 5 приведены примеры графиков для НС с сигмоидальной функцией активации (Sigmoid) и функцией ReLU в скрытом слое.




Рисунок 4 - Графики потерь, точности и полноты для НС с сигмоидальной функцией активации (Sigmoid) в скрытом слое

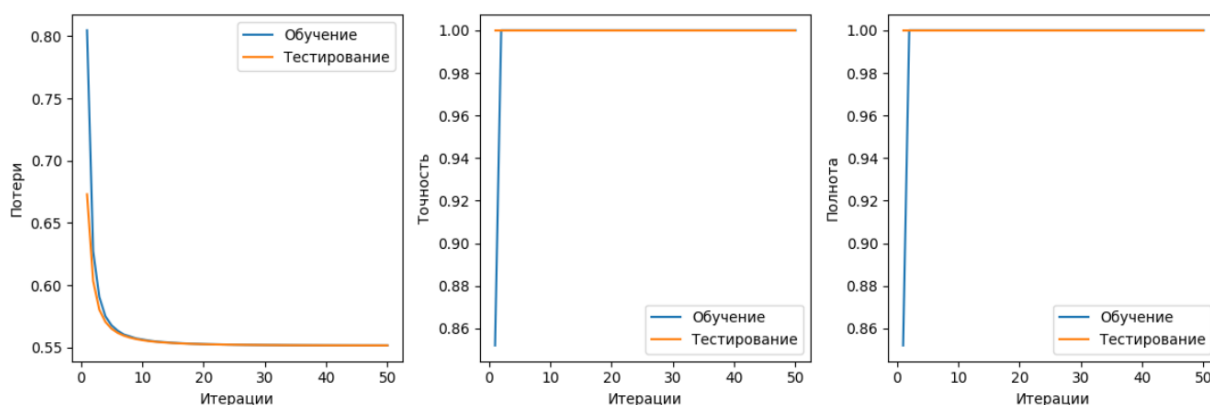


Рисунок 5 - Графики потерь, точности и полноты для НС с функцией активации ReLU в скрытом слое

Заклучение.

Исследование показало, что все исследуемые функции активации могут быть применены в задаче многоклассовой классификации при определении типа воздушно-газовой смеси. При обучении и тестировании все построенные нейронные сети достигают точности равной 1. При этом на графиках видно, что нейронные сети с функциями активации ReLU, LeakyReLU и PreLU достигают данной точности практически сразу.

Минимальные потери при обучении и тестировании у каждой из рассмотренных нейронных сетей имеют схожие значения с погрешностью 0,001. Графики потерь при обучении и тестировании показывают, что все нейронные сети хорошо обучаемы. Однако наименьшее время на обучение (0,07 сек) требуется НС с функцией активации ReLU на скрытом слое.

Таким образом можно сделать вывод, что в предложенной архитектуре НС в качестве функции активации на скрытом слое можно использовать любую из рассмотренных функций, но наилучшие показатели у НС с функцией активации ReLU. При этом количество нейронов в скрытом слое – 45, для обучения данной НС достаточно 37 итераций.

При дальнейшей работе по данному исследованию планируется увеличить количество скрытых слоев НС, что позволит улучшить работоспособность сети. А также для количественного анализа газовой смеси планируется добавить еще один выходной слой, который позволит вычислять процентное содержание опасных газовых смесей в воздушной среде.

ЛИТЕРАТУРА

- [1] Ердесов Н. Ж., Сраубаев Е. Н., Серик Б. Производственный травматизм и профессиональная заболеваемость в Республике Казахстан. Медицина и экология, 2020, 4(97), С. 38–45.
- [2] Ahmed, I., Jeon, G., Piccialli, F. From Artificial Intelligence to Explainable Artificial Intelligence in Industry 4.0: A Survey on What, How, and Where. IEEE Transactions on Industrial Informatics, 2022, 18(8), С. 5031–5042. <https://doi.org/10.1109/tii.2022.3146552>
- [3] Kim, B., Lee, S., Kim, J. Inverse design of porous materials using artificial neural networks. Science advances, 2020, 6(1), eaax9324. <https://www.science.org/doi/10.1126/sciadv.aax9324>
- [4] Asteris, P. G., Mokos, V. G. Concrete compressive strength using artificial neural networks. Neural Computing and Applications, 2020, 32(15), С. 11807-11826. <https://doi.org/10.1007/s00521-019-04663-2>
- [5] Trunin, A. M., Ragozin, A. N., Darovskih, S. N. An Investigation of the Application of an Artificial Neural Network and Machine Learning to Improve the Efficiency of Gas Analyzer Systems in Assessing the State of the Environment. In 2021 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM), 2021, С. 571-575. <https://ieeexplore.ieee.org/document/9446406>
- [6] Zhang, G., Wu, X. A novel CO₂ gas analyzer based on IR absorption. Optics and Lasers in Engineering, 2004, 42(2), С. 219-231. <https://doi.org/10.1016/j.optlaseng.2003.08.001>
- [7] Муканова, Ж.А., Атанов С.К. Интеллектуальный газоанализатор. Патент РК на полезную модель № 8288, 2023, Бюл. № 29
- [8] Ghani, F. A., Rivaie, M., Yusoff, M., Puteh, M. A Review of Artificial Neural Network Applications in Variants of Optimization Algorithms. 2022 International Visualization, Informatics and Technology Conference (IVIT), 2022. <https://doi.org/10.1109/ivit55443.2022.10033339>
- [9] Gunawan, T. S., Mohd Noor, A. F. R., Kartiwi, M. Development of English Handwritten Recognition Using Deep Neural Network. Indonesian Journal of Electrical Engineering and Computer Science, 2018, 10(2), С. 562. <https://doi.org/10.11591/ijeecs.v10.i2.pp562-568>
- [10] Saranya, G., Pravin, A. A comprehensive study on disease risk predictions in machine learning. International Journal of Electrical and Computer Engineering (IJECE), 2020, 10(4), С. 4217. <https://doi.org/10.11591/ijece.v10i4.pp4217-4225>
- [11] Mukanova, Z., Atanov, S., Jamshidi, M. Features of Hardware and Software Smoothing of Experimental Data of Gas Sensors. 2021 IEEE International Conference on Smart Information Systems and Technologies (SIST), 2021. <https://doi.org/10.1109/sist50301.2021.9465981>
- [12] Sharma, S., Sharma, S., Athaiya, A. Activation functions in neural networks. Towards Data Sci, 2017, 6(12), С. 310-316.
- [13] Li, J., Cheng, J., Shi, J., Huang, F. Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement. Advances in Computer Science and Information Engineering, 2012, С. 553–558. https://doi.org/10.1007/978-3-642-30223-7_87
- [14] Wang, M., Lu, S., Zhu, D., Lin, J., Wang, Z. A High-Speed and Low-Complexity Architecture for Softmax Function in Deep Learning. 2018 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS), 2018. <https://doi.org/10.1109/apccas.2018.8605654>
- [15] Agostinelli, F., Hoffman, M., Sadowski, P., Baldi, P. Learning activation functions to improve deep neural networks. arXiv preprint arXiv:1412.6830, 2014. <https://doi.org/10.48550/arXiv.1412.6830>

REFERENCES*

- [1] Erdesov, N. J., Sraubaev, E. N., Serik, B. Occupational traumatism and occupational morbidity in the Republic of Kazakhstan. *Medicine and Ecology*, 2020, 4(97), pp. 38-45.
- [2] Ahmed, I., Jeon, G., Piccialli, F. From Artificial Intelligence to Explainable Artificial Intelligence in Industry 4.0: A Survey on What, How, and Where. *IEEE Transactions on Industrial Informatics*, 2022, 18(8), pp. 5031–5042. <https://doi.org/10.1109/tii.2022.3146552>
- [3] Kim, B., Lee, S., Kim, J. Inverse design of porous materials using artificial neural networks. *Science advances*, 2020, 6(1), eaax9324. <https://www.science.org/doi/10.1126/sciadv.aax9324>
- [4] Asteris, P. G., Mokos, V. G. Concrete compressive strength using artificial neural networks. *Neural Computing and Applications*, 2020, 32(15), pp. 11807-11826. <https://doi.org/10.1007/s00521-019-04663-2>
- [5] Trunin, A. M., Ragozin, A. N., Darovskih, S. N. An Investigation of the Application of an Artificial Neural Network and Machine Learning to Improve the Efficiency of Gas Analyzer Systems in Assessing the State of the Environment. In *2021 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*, 2021, pp. 571-575. <https://ieeexplore.ieee.org/document/9446406>
- [6] Zhang, G., Wu, X. A novel CO₂ gas analyzer based on IR absorption. *Optics and Lasers in Engineering*, 2004, 42(2), pp. 219-231. <https://doi.org/10.1016/j.optlaseng.2003.08.001>
- [7] Mukanova, J.A., Atanov S.K. Intelligent gas analyzer. Patent RK on useful model № 8288? 2023, Bul. no. 29.
- [8] Ghani, F. A., Rivaie, M., Yusoff, M., Puteh, M. A Review of Artificial Neural Network Applications in Variants of Optimization Algorithms. *2022 International Visualization, Informatics and Technology Conference (IVIT)*, 2022. <https://doi.org/10.1109/ivit55443.2022.10033339>
- [9] Gunawan, T. S., Mohd Noor, A. F. R., Kartiwi, M. Development of English Handwritten Recognition Using Deep Neural Network. *Indonesian Journal of Electrical Engineering and Computer Science*, 2018, 10(2), pp. 562. <https://doi.org/10.11591/ijeecs.v10.i2.pp562-568>
- [10] Saranya, G., Pravin, A. A comprehensive study on disease risk predictions in machine learning. *International Journal of Electrical and Computer Engineering (IJECE)*, 2020, 10(4), pp. 4217. <https://doi.org/10.11591/ijece.v10i4.pp4217-4225>
- [11] Mukanova, Z., Atanov, S., Jamshidi, M. Features of Hardware and Software Smoothing of Experimental Data of Gas Sensors. *2021 IEEE International Conference on Smart Information Systems and Technologies (SIST)*, 2021. <https://doi.org/10.1109/sist50301.2021.9465981>
- [12] Sharma, S., Sharma, S., Athaiya, A. Activation functions in neural networks. *Towards Data Sci*, 2017, 6(12), pp. 310-316.
- [13] Li, J., Cheng, J., Shi, J., Huang, F. Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement. *Advances in Computer Science and Information Engineering*, 2012, pp. 553–558. https://doi.org/10.1007/978-3-642-30223-7_87
- [14] Wang, M., Lu, S., Zhu, D., Lin, J., Wang, Z. A High-Speed and Low-Complexity Architecture for Softmax Function in Deep Learning. *2018 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS)*, 2018. <https://doi.org/10.1109/apccas.2018.8605654>
- [15] Agostinelli, F., Hoffman, M., Sadowski, P., Baldi, P. Learning activation functions to improve deep neural networks. *arXiv preprint arXiv:1412.6830*, 2014. <https://doi.org/10.48550/arXiv.1412.6830>

Жанна Муканова, магистр, сениор лектор, Университет Туран, Алматы, Казахстан, Zhanna.Mukanova.83@mail.ru

Сабыржан Атанов, т.ғ.д., профессор, Л.Н.Гумилев атындағы Еуразия ұлттық университеті, Астана, Қазақстан, Atanov5@mail.ru

ГАЗ ҚОСПАЛАРЫН ТАЛДАУДЫҢ НЕЙРОНДЫҚ ЖЕЛІСІНІҢ МОДЕЛІН ЖАСАУ

Аңдатпа. Өндірістік жарақаттар мәселесі Қазақстанда және әлемдік ауқымда маңызды болып қала береді. Отандық ғалымдардың зерттеулері көрсеткендей, өңдеу, тау-кен және құрылыс салалары көптеген жылдар бойы тұрақты түрде өндірістік жарақаттанудың ең жоғары көрсеткіштерін көрсететін негізгі жетекші салалар болып табылады, осының бір себебі ретінде - жұмыс бөлмелерінің газдануының жоғары деңгейін көрсетуге болады. Бұл зерттеудің мақсаты архитектураны таңдау және болашақта газ анализаторын жасау кезінде пайдаланылатын, ауа ортасындағы қауіпті газдардың бар болуын тексеретін газ қоспаларына сапалы талдау жүргізуге қабілетті мультиспектрлі газ анализаторына арналған нейрондық желіні әзірлеу болып табылады. Жұмыста алдын ала өңделген спектрлік деректерді талдауға арналған бір қабатты перцептронды әзірлеу процесі көрсетілген, бір кіріс қабаты, бір жасырын қабат және бір шығыс қабаты бар. Ұсынылған нейрондық желі архитектурасының математикалық моделі ұсынылған. Сондай-ақ, нейрондық желіні құру, оқыту және тестілеу үшін Python бағдарламалау тілінде бағдарламалық код енгізілді. Зерттеулер көрсеткендей, Шығыс қабатындағы ең қолайлы белсендіру функциясы Softmax функциясы болып табылады. Жасырын қабатта қарастырылған функциялардың кез келгені қолданылуы мүмкін. Алайда, ReLU белсендіру функциясы жақсы нәтиже көрсетті. Бұл жағдайда жасырын қабаттағы нейрондардың саны 45 құрайды, бұл нейрондық желіні оқыту үшін 37 итерация жеткілікті.

Түйінді сөздер. Жасанды нейрондық желі; нейрон; белсендіру функциясы; газ қоспасы; газ анализаторы.

Zhanna Mukanova, master, Senior Lecturer, Turan University, Almaty, Kazakhstan, Zhanna.Mukanova.83@mail.ru

Sabyrzhhan Atanov, doctor of technical sciences, professor, L.N. Gumilev Eurasian National University, Astana, Kazakhstan, Atanov5@mail.ru

DEVELOPMENT OF A NEURAL NETWORK MODEL FOR ANALYZING GAS MIXTURES

Abstract. The problem of occupational injuries remains significant in Kazakhstan and globally. Studies of domestic scientists show that the main leading industries with the highest rates of occupational injuries for many years have consistently remained the manufacturing, mining and construction industries, and one of the reasons is the high level of gassiness of working premises. The purpose of this study is to select an architecture and develop a neural network for a multispectral gas analyzer capable of qualitative analysis of gas mixtures in the air environment for the presence of hazardous gases, which is further planned to be used in the development of a gas analyzer. The paper shows the process of developing a single-layer perceptron designed to analyze pre-processed spectral data, with one input layer, one hidden layer and one output layer. A mathematical model of the proposed neural network architecture is

presented. And also implemented the program code in Python programming language to construct, train and test the neural network. The research shows that in the output layer, the most suitable activation function in the output layer is Softmax function. Any of the considered functions can be applied in the hidden layer. However, the ReLU activation function showed the best results. The number of neurons in the hidden layer is 45, and 37 epochs are enough to train this neural network.

Keywords. Artificial neural network; neuron; activation function; gas mixture; gas analyzer.
