

УДК 614.715

© Е. С. Кулакова, Г. А. Родионов, 2024

### Е.С. КУЛАКОВА

канд. техн. наук, доцент

Институт химических технологий и инжиниринга  
Уфимский государственный нефтяной технический  
университет, г. Стерлитамак  
e-mail: kulakova87@list.ru



### Г.А. РОДИОНОВ

магистрант

Институт химических технологий и инжиниринга  
Уфимский государственный нефтяной технический  
университет, г. Стерлитамак  
e-mail: gleb.rodionow@gmail.com



## ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ ПРОГНОЗИРОВАНИЯ КОНЦЕНТРАЦИИ ЗАГРЯЗНЯЮЩИХ ВЕЩЕСТВ АТМОСФЕРНОГО ВОЗДУХА НА РАЗЛИЧНОЙ ВЫСОТЕ

*В статье представлена разработка и применение искусственной нейронной сети для прогнозирования концентрации загрязняющих веществ в атмосферном воздухе на различных высотах. Объектами исследования являются концентрация  $NO_2$ ,  $SO_2$ ,  $C_6H_6$  в атмосферном воздухе г. Стерлитамака (Республика Башкортостан), метеорологические параметры. В качестве методов исследования применяется искусственная нейронная сеть. В качестве инструмента разработки использована библиотека TensorFlow на Python. Построена модель полносвязной сети с сигмоидальной функцией активации. Проведена нормализация входных данных, обучение нейронной сети. Результаты исследования показали высокую сходимость выходных данных на валидационной выборке. Полученная модель позволяет рассчитывать предикативные параметры качества воздуха со средней абсолютной ошибкой менее 0,1.*

Ключевые слова: НЕЙРОННЫЕ СЕТИ, ЗАГРЯЗНЕНИЕ, АТМОСФЕРНЫЙ ВОЗДУХ, ЭКОЛОГИЧЕСКИЙ МОНИТОРИНГ, TENSORFLOW, ОКРУЖАЮЩАЯ СРЕДА.

### ВВЕДЕНИЕ

В современном мире проблема загрязнения атмосферного воздуха становится все более актуальной и требует поиска эффективных методов контроля и прогнозирования концентрации вредных веществ [1].

В крупных городах России устанавливаются стационарные посты наблюдения [2–5]. Научно-исследовательские лаборатории разрабатывают алгоритмы и модели

прогнозирования концентрации загрязняющих веществ в жилых зонах [6–7]. Сегодня разработаны модели на основе данных экологического мониторинга г. Москвы, г. Санкт-Петербурга, г. Уфы, г. Казани и др. В них применяются методы статистического и корреляционно-регрессионного анализа, нейросетевого моделирования [8–9]. Объектами исследования научных коллективов являются массивы концентрации загрязняющих

веществ, выбрасываемых промышленными предприятиями и регистрируемых на автоматизированных станциях контроля, а также метеорологические параметры. Причем станции контроля осуществляют отбор пробы на высоте не выше 3,5 м. Таким образом, модели построены на основе данных, полученных на одной высоте.

Коллективом авторов разработана система многоуровневого мониторинга атмосферного воздуха, необходимая для оценки параметров качества на различных высотах [10]. Сегодня отсутствуют модели прогнозирования концентрации токсикантов на разных высотах.

В этой статье рассматривается возможность использования искусственных нейронных сетей для прогнозирования концентрации загрязняющих веществ на различных высотах в атмосферном воздухе. В современных исследованиях широко применяется предикативная аналитика на основе искусственных нейронных сетей. Машинное обучение сегодня используется для анализа сложных нелинейных зависимостей и прогнозирования различных физических, химических явлений и процессов [11–13]. В случае прогнозирования концентрации загрязняющих веществ в атмосфере искусственные нейронные сети могут быть эффективным инструментом благодаря своей способности к обучению на больших объемах данных и выявлению скрытых закономерностей.

## СБОР ДАННЫХ

Объектом исследования является атмосферный воздух г. Стерлитамака Республики Башкортостан [1–4]. Для создания DataSet собраны данные о концентрации загрязнителей ( $\text{NO}_2$ ,  $\text{SO}_2$ ,  $\text{C}_6\text{H}_6$ ) и метеорологических параметрах при различных погодных условиях на различной высоте с помощью переносных газоанализаторов ИКВ-8.

Параметрами на вход являются:

- атмосферное давление (мм. рт. ст.);
- температура окружающей среды ( $^{\circ}\text{C}$ );
- влажность воздуха (%);
- высота над уровнем моря (м);
- направление ветра (градус);

– скорость ветра (м/с).

Выходными параметрами являются измеренные концентрации загрязнителей ( $\text{мг}/\text{м}^3$ ).

Измерения проводились в диапазоне высот от 116,8 (на поверхности Земли) до 136,8 м (20 м от поверхности Земли). В данном диапазоне высот было установлено, что концентрация для разных газов составляет:

- диоксид азота ( $\text{NO}_2$ ) от 0 до 1,28  $\text{мг}/\text{м}^3$ ;
- диоксид серы ( $\text{SO}_2$ ) от 0 до 0,04  $\text{мг}/\text{м}^3$ ;
- бензол ( $\text{C}_6\text{H}_6$ ) от 0 до 0,22  $\text{мг}/\text{м}^3$ .

В разное время наблюдения устанавливались следующие метеорологические показатели:

- атмосферное давление 749,46–758,15 мм. рт. ст.;
- влажность воздуха 30,1–50,8 %;
- температура окружающей среды 16,08–27,42  $^{\circ}\text{C}$ ;
- направление ветра 1,42–358,85 $^{\circ}$ ;
- скорость ветра 0,01–2,65 м/с.

## АРХИТЕКТУРА НЕЙРОННОЙ СЕТИ

Определение архитектуры нейронной сети является ключевым этапом в процессе разработки и обучения нейронных сетей [14–18]. Архитектура определяет структуру и организацию нейронной сети, включая количество слоев, количество нейронов в каждом слое и типы активационных функций. Структура нейронной сети для прогнозирования концентрации веществ на заданной высоте представлена на рис. 1.

Входной слой получает данные, такие как атмосферное давление, высота над уровнем моря, влажность воздуха и температура окружающей среды. Выходной слой определяет выходное значение нейронной сети, а именно концентрацию диоксида азота, диоксида серы, бензола в атмосфере. Оба слоя используют функцию активации сигмоиду.

Для обучения нейронной сети применяется метод градиентного спуска. После завершения обучения модели необходимо провести тестирование на новых данных для оценки точности и эффективности. Валидация модели поможет определить, насколько успешно она работает на новых примерах и предотвращает переобучение.




Рис. 1. Архитектура нейронной сети

### ПОДГОТОВКА ДАННЫХ

По причине наличия очень больших значений в обучающем наборе данных, они могут привести к насыщению функции активации, где производная почти равна нулю. Для этого была проведена предварительная стандартизация входных и выходных значений по формуле:

$$x_c = \frac{x_i - x_{max}}{x_{max} - x_{min}} \quad (1)$$

где  $x_i$  — входное нормальное значение,  $x_{max}$  и  $x_{min}$  — максимальное и минимальное значение входного параметра из всего числового диапазона значения.

Стандартизация значений будет проходить внутри самого кода программы. То есть пользователь вводит нормальные данные, а уже при выполнении программы они будут стандартизироваться в диапазон от 0 до 1.

Выходные параметры этой обработки не требуют, так как они содержат небольшие значения.

Обучающая выборка считывается с файла (рис. 2), где по названиям столбцов распределяем входные и выходные параметры (рис. 3), а после создаем словарь со стандартизирующимися данными (рис. 4).

Следующим этапом в подготовке данных является создание функции, преобразующей фрейм данных в словарь, где каждая пара ключ-значение представляет столбец во фрейме данных (рис. 6). Затем производится преобразование данных из DataFrame в словарь, разделяя их на входные и выходные данные и возвращая результат в виде словаря с ключами «Inputs» и «Outputs» (рис. 7).

Далее создается функция для кодирования данных из словаря (рис. 8). Сначала формируется пустой список vectors. Затем происходит проход по элементам словаря, где data\_name — ключ, а data\_values — значение. Для каждого ключа вызывается функция encoders[data\_name] с аргументом data\_values, результат преобразуется в список и добавляется в vectors.

Затем создается пустой список formatted. Происходит итерация по zip(\*vectors), чтобы обойти каждый элемент вектора поочередно. Для каждого элемента вектора происходит проход по его элементам. Каждый элемент добавляется в отдельный список vector, который затем добавляется в formatted.

Завершающим действием в подготовке данных является создание массивов, содержащие закодированные значения входных и выходных данных (рис. 9)

	Davlenie	Vysota	Vlazhnost	...	N02	S02	C6H6
0	749.47	117.50	43.3	...	0.031906	0.002757	0.01903
1	749.48	117.47	43.6	...	0.011332	0.002987	0.01501
2	749.48	117.47	43.7	...	0.005717	0.002931	0.01820
3	749.48	117.47	43.9	...	0.015005	0.002542	0.02379
4	749.48	117.48	43.7	...	0.010284	0.002852	0.01325
...	...	...	...	...	...	...	...
358	758.15	136.80	34.3	...	0.006811	0.003098	0.01550
359	758.15	136.80	34.4	...	0.008422	0.009748	0.01577
360	758.15	136.80	33.8	...	0.008320	0.010757	0.01426
361	758.15	134.90	34.5	...	0.005518	0.005839	0.01590
362	758.15	136.80	34.7	...	0.008189	0.004266	0.01494

Рис. 2. Вывод данных с файла в рабочем терминале

```
data_input = ["Davlenie", "Vysota", "Vlazhnost", "Temperatura", "Napravlenie", "Skorost"]
data_output = ["N02", "S02", "C6H6"]
```

Рис. 3. Распределения данных на входные и выходные параметры

```
encoders = {"Davlenie": lambda pressure: [(pressure-pmin)/(pmax-pmin)],
            "Vysota": lambda altitude: [(altitude-amin)/(amax-amin)],
            "Vlazhnost": lambda humidity: [(humidity-hmin)/(hmax-hmin)],
            "Temperatura": lambda temperature: [(temperature-tmin)/(tmax-tmin)],
            "Napravlenie": lambda direction: [(direction-dmin)/(dmax-dmin)],
            "Skorost": lambda speed: [(speed-smin)/(smax-smin)],
            "N02": lambda N02_con: [N02_con],
            "S02": lambda S02_con: [S02_con],
            "C6H6": lambda C6H6_con: [C6H6_con]}
```

Рис. 4. Словарь со стандартизирующими данными в диапазон от 0 до 1

```
pmax = 758.15
pmin = 749.46
amax = 136.8
amin = 116.8
hmax = 50.8
hmin = 30.1
tmax = 27.42
tmin = 16.08
dmax = 358.85
dmin = 1.42
smax = 2.65
smin = 0.01
```

Рис. 5. Максимальные и минимальные значения параметров

```
def dataframe_to_dict(df):
    result = dict()
    for column in df.columns:
        values = data_frame[column].values
        result[column] = values
    return result
```

Рис. 6. Функция, преобразующая фрейм данных в словарь, где каждая пара ключ-значение представляет столбец во фрейме данных.

```
def make_supervised(df):
    raw_in = data_frame[data_input]
    raw_out = data_frame[data_output]
    return {"Inputs": dataframe_to_dict(raw_in),
            "Outputs": dataframe_to_dict(raw_out)}
```

Рис. 7. Преобразование данных из DataFrame в словарь, разделяя их на входные и выходные данные и возвращая результат в виде словаря с ключами «Inputs» и «Outputs».

```
def encode(data):  
    vectors = []  
    for data_name, data_values in data.items():  
        encoded = list(map(encoders[data_name], data_values))  
        vectors.append(encoded)  
    formatted = []  
    for vector_raw in list(zip(*vectors)):  
        vector = []  
        for element in vector_raw:  
            for e in element:  
                vector.append(e)  
        formatted.append(vector)  
    return formatted
```

Рис. 8. Функция для кодирования данных из словаря

```
supervised = make_supervised(data_frame)  
  
encoded_inputs = np.array(encode(supervised["Inputs"]))  
encoded_outputs = np.array(encode(supervised["Outputs"]))
```

Рис. 9. Создание массивов с закодированными значениями входных и выходных данных

```
model = Sequential()  
model.add(Dense(units=6, activation='sigmoid'))  
model.add(Dense(units=3, activation='sigmoid'))  
model.compile(loss='mse', optimizer='sgd', metrics='mae')  
res = model.fit(x=train_x, y=train_y, epochs=200, batch_size=20, validation_split=0.2)
```

Рис. 10. Нейросетевая модель

```
Epoch 152/200  
15/15 [=====] - 0s 6ms/step - loss: 0.0140 - mae: 0.1112 - val_loss: 0.0299 - val_mae: 0.1264  
Epoch 153/200  
15/15 [=====] - 0s 5ms/step - loss: 0.0139 - mae: 0.1108 - val_loss: 0.0298 - val_mae: 0.1260  
Epoch 154/200  
15/15 [=====] - 0s 6ms/step - loss: 0.0138 - mae: 0.1103 - val_loss: 0.0297 - val_mae: 0.1256  
Epoch 155/200  
15/15 [=====] - 0s 5ms/step - loss: 0.0137 - mae: 0.1098 - val_loss: 0.0297 - val_mae: 0.1252  
Epoch 156/200  
15/15 [=====] - 0s 5ms/step - loss: 0.0136 - mae: 0.1094 - val_loss: 0.0296 - val_mae: 0.1248
```

Рис. 11. Процесс обучения нейронной сети

```
7/7 [=====] - 0s 2ms/step - loss: 0.0186 - mae: 0.1089
```

Рис. 14. Оценка производительности модели

## ОБУЧЕНИЕ МОДЕЛИ

Нейросетевая модель для прогнозирования концентрации загрязнителя в атмосферном воздухе на различной высоте (рис. 10) состоит из двух слоев Dense (полносвязных). Первый слой содержит 6 нейрона с активацией сигмоидальной функции, второй слой имеет 3 нейрона и также использует сигмоидальную функцию активации.

Затем модель компилируется. В данном случае функция потерь (loss) выбрана как среднеквадратичная ошибка (MSE), оптимизатор (optimizer) установлен как стохастический градиентный спуск (SGD), а метрика (metrics) установлена как средняя абсолютная ошибка (MAE).

После компиляции производится процесс обучения нейронной сети на данных train\_x и train\_y с помощью метода fit (рис. 11). Установлено 200 эпох обучения, размер пакета (batch\_size) равен 20 и 20 % данных для валидации.

## ОЦЕНКА РЕЗУЛЬТАТОВ

Построены графики зависимостей значения функции потерь (loss) для обучающего и валидационного наборов данных (рис. 12) и значения средней абсолютной ошибки (mae) для обучающего и валидационного наборов данных (рис. 13).




Рис. 12. График зависимости значения функции потерь (loss) для обучающего и валидационного наборов данных в течении 200 эпох.

Как показывают рис. 12 и 13, значения функции потерь и средней абсолютной ошибки для обучающего и валидационного набора данных в течение 200 эпох снижаются равномерно, стремясь к нулю, без помех и скачков возрастания. Это свидетельствует о том, что нейронная сеть для прогнозирования концентрации загрязняющих веществ атмосферного воздуха на различной высоте является работоспособной.

Также была проведена оценка производительности модели (рис. 14). Как показывают значения loss и mae, их значение ближе к нулю, что указывает на хорошую производительность нейросетевой модели.

## РАБОТА НЕЙРОННОЙ СЕТИ

После того, как нейросетевая модель обучилась, пользователю необходимо ввести значения давления, температуры, высоты над уровнем моря, влажности, скорости и направления ветра в рабочий терминал (рис. 15).

На основании этих данных, программа вычислит прогнозируемую концентрацию диоксида азота, диоксида серы и бензола в атмосфере (рис. 16).

## ЗАКЛЮЧЕНИЕ

Разработана концептуальная модель нейронной сети системы усредненного отбора




Рис. 13. График зависимости значения средней абсолютной ошибки (mae) для обучающего и валидационного наборов данных в течении 200 эпох.

пробы воздушной среды на различной высоте, которая учитывает как измеренные значения концентрации, так и метеорологические параметры.

На основе полученной концептуальной модели была разработана нейросетевая модель системы усредненного отбора пробы воздушной среды на различной высоте, которая позволяет прогнозировать значения концентрации загрязнителя на различных высотах с учетом метеорологических условий. Полученная модель позволяет рассчитывать предикативные параметры качества воздуха со средней абсолютной ошибкой менее 0,1.

Данная система может быть использована для автоматизированного контроля качества атмосферного воздуха и прогнозирования концентрации загрязнителей на различных высотах в воздухе населенных мест.

#### СПИСОК ЛИТЕРАТУРЫ

1. Jennings Rh. Science and urgency in the Glasgow Climate Pact. Environmental Liability — Law, Policy and Practice // Science and urgency in the Glasgow climate pact: Jennings. 2022. Vol. 27. № 2. P. 35–41.
2. Kulakova E. S., Safarov A. M., Malkova M. A. [et al.] Phenol monitoring in the air of the city residential part // IOP Conference Series: Earth and Environmental Science. 2020. P. 012102.
3. Кулакова Е. С. Бензол и его гомологи в атмосферном воздухе города Бельской мегавпадины Предуральяского прогиба восточно-Европейской равнины // Вестник Научного центра ВостНИИ по промышленной и экологической безопасности. 2022. № 4. С. 115–124.
4. Kulakova E. S., Safarov A. M. Automated control and control system of emissions into the atmospheric air of thermoelectric-power industries // Journal of Physics: Conference Series: III International Conference on Metrological Support of Innovative Technologies (ICMSIT-III-2022). 2022. Vol. 2373. P. 82001.
5. Kulakova E. S., Safarov A. M., Kantor E. A. [et al.] The influence of the wind regime on the methanol concentration change in the atmospheric air of the city residential area // International scientific and practical conference «Ensuring sustainable development in the context of agriculture, green energy, ecology and earth science». London: IOP Publishing Ltd, 2021. P. 042048.
6. Puvvula J., Poole J., Gonzalez S., Rogan E., Gwon Y., Rorie A., Ford L., Bell J. Joint association between ambient air pollutant mixture and pediatric asthma exacerbations // Environmental Epidemiology. 2022. Vol. 5. No. 6. P. 225.
7. Volkodaeva M., Volodina Ya. Control of pollutants in the atmospheric air on the example of an automated monitoring system in // St. Petersburg. IOP Conference Series: Earth and Environmental Science. 2022. Vol. 1061. No. 1. P. 012023.
8. Dean J. Air Sampling // Extraction Techniques for Environmental Analysis: Wiley. 2022. Vol. 14. P. 239–252.

```
Enter the barometric pressure value:
750
Enter your altitude above sea level:
140
Enter the air humidity value:
45
Enter the air temperature value:
15
Enter the wind direction value:
270
Enter the wind speed value:
1
```

Рис. 15. Ввод данных в рабочем терминале

```
Concentration NO2, SO2, C6H6:
[[0.1411144 0.09536629 0.11303627]]
```

Рис. 16. Полученная концентрация в результате выполнения программы.

9. Gallego E., Perales J. F., Josep M. C. Continuous monitoring of volatile organic compounds through sensorization. Automatic sampling during pollution/odour/nuisance episodic events // *Atmospheric Environment*. 2023. No. 299. P. 119657.
10. Патент 2804767 Российская Федерация, МПК G01N 1/26. Система отбора пробы атмосферного воздуха для автоматизированного контроля качества воздуха / А. М. Сафаров, Е. С. Кулакова; заявитель Федеральное государственное бюджетное образовательное учреждение высшего образования «Уфимский государственный нефтяной технический университет» — № 2022128882; заявл. 07.11.2022; опубл. 05.10.2023.
11. Хайкин С. Нейронные сети: полный курс, 2-е издание. Издательский дом Вильямс, 2008. 1104 с.
12. Леванов А. М. Особенности языка программирования Python // Редакционная коллегия. 2021. 123 с.
13. Комзалов Е. А. Автоматизация процесса предприятия используя язык программирования Python // Внедрение передового опыта и практическое применение результатов инновационных исследований. 2021. С. 68–71.
14. Manaswi N. K., Manaswi N. K. Understanding and working with Keras // *Deep learning with applications using Python: Chatbots and face, object, and speech recognition with TensorFlow and Keras*. 2018. P. 31–43.
15. Kumar A. et al. Image Classification in Python Using Keras // *Proceedings of Data Analytics and Management: ICDAM*, 2021. 2022. Vol. 1. P. 541–556.
16. Бербасов В. Д. Сравнительный обзор библиотек нейронных сетей Keras и PyTorch // *Экономика и социум*. 2023. № 8 (111). С. 423–426.
17. Соболев А. А., Демидова А. В. Практические аспекты компьютерной реализации методов машинного обучения // *Системы управления, технические системы: устойчивость, стабилизация, пути и методы исследования*. 2019. С. 107–111.
18. Бурхонов Р. А. Сравнительный анализ библиотек для глубокого обучения свёрточных нейронных сетей // SCVRT2018 Международная научная конференция Московского физико-технического института (государственного университета) Института физико-технической информатики. 2018. С. 235–240.

---

**UDC 614.715**

© E. S. Kulakova, G. A. Rodionov, 2024

**E.S. KULAKOVA**

Candidate of Engineering Sciences, Associate Professor  
Institute of Chemical Technologies and Engineering  
Ufa State Petroleum Technical University, Sterlitamak  
e-mail: kulakova87@list.ru

**G.A. RODIONOV**

Master Student  
Institute of Chemical Technologies and Engineering  
Ufa State Petroleum Technical University, Sterlitamak  
e-mail: gleb.rodionow@gmail.com

## ARTIFICIAL NEURAL NETWORK FOR PREDICTING THE CONCENTRATION OF ATMOSPHERIC POLLUTANTS AT DIFFERENT HEIGHTS

*The article presents the development and application of an artificial neural network to predict the concentration of pollutants in the atmospheric air at various altitudes. The objects of the study are the concentration of NO<sub>2</sub>, SO<sub>2</sub>, C<sub>6</sub>H<sub>6</sub> in the atmospheric air of Sterlitamak (Republic of Bashkortostan), meteorological parameters. An artificial neural network is used as research methods. The TensorFlow library in Python is used as a development tool. A model of a fully connected network with a sigmoidal activation function is constructed. Input data normalization and neural network training were carried out. The results of the study showed high convergence of the output data on the validation sample. The resulting model allows us to calculate predicative air quality parameters with an average absolute error of less than 0.1.*

Keywords: NEURAL NETWORKS, POLLUTION, ATMOSPHERIC AIR, ENVIRONMENTAL MONITORING, TENSORFLOW, ENVIRONMENT.

### REFERENCES

1. Jennings Rh. Science and urgency in the Glasgow Climate Pact. Environmental Liability — Law, Policy and Practice // Science and urgency in the Glasgow climate pact: Jennings. 2022. Vol. 27. № 2. P. 35–41.
2. Kulakova E. S., Safarov A. M., Malkova M. A. [et al.] Phenol monitoring in the air of the city residential part // IOP Conference Series: Earth and Environmental Science. 2020. P. 012102.
3. Kulakova E. S. Benzene and its homologues in the atmospheric air of the city of the Belsky megawall of the Pre-Ural trough of the East European plain // Bulletin of the VostNII Scientific Center for Industrial and Environmental Safety [Vestnik Nauchnogo tsentra VostNII po promyshlennoy i ekologicheskoy bezopasnosti]. 2022. No. 4. P. 115–124. [In Russ.].
4. Kulakova E. S., Safarov A. M. Automated control and control system of emissions into the atmospheric air of thermoelectric-power industries // Journal of Physics: Conference Series: III International Conference on Metrological Support of Innovative Technologies (ICMSIT-III-2022). 2022. Vol. 2373. P. 82001.
5. Kulakova E. S., Safarov A. M., Kantor E. A. [et al.] The influence of the wind regime on the methanol concentration change in the atmospheric air of the city residential area // International scientific and practical conference «Ensuring sustainable development in the context of agriculture, green energy, ecology and earth science». London: IOP Publishing Ltd, 2021. P. 042048.
6. Puvvula J., Poole J., Gonzalez S., Rogan E., Gwon Y., Rorie A., Ford L., Bell J. Joint association between ambient air pollutant mixture and pediatric asthma exacerbations // Environmental Epidemiology. 2022. Vol. 5. No. 6. P. 225.
7. Volkodaeva M., Volodina Ya. Control of pollutants in the atmospheric air on the example of an automated monitoring system in // St. Petersburg. IOP Conference Series: Earth and Environmental Science. 2022. Vol. 1061. No. 1. P. 012023.
8. Dean J. Air Sampling // Extraction Techniques for Environmental Analysis: Wiley. 2022. Vol. 14. P. 239–252.
9. Gallego E., Perales J. F., Josep M. C. Continuous monitoring of volatile organic compounds through sensorization. Automatic sampling during pollution/odour/nuisance episodic events // Atmospheric Environment. 2023. No. 299. P. 119657.
10. Patent 2804767 Russian Federation, IPC G01N 1/26. Atmospheric air sampling system for automated air quality control / A. M. Safarov, E. S. Kulakova; applicant Federal State Budgetary Educational Institution of Higher Education «Ufa State Petroleum Technical University» — No. 2022128882; application 07.11.2022; publ. 05.10.2023. [In Russ.].

11. Haikin S. Neural networks: a complete course, 2nd edition. Williams Publishing House, 2008. 1104 p. [In Russ.].
12. Levanov A. M. Features of the Python programming language // Editorial Board. 2021. 123 p. [In Russ.].
13. Kozlov E. A. Automation of the enterprise process using the Python programming language // Introduction of best practices and practical application of the results of innovative research. 2021. P. 68–71. [In Russ.].
14. Manaswi N. K., Manaswi N. K. Understanding and working with Keras // Deep learning with applications using Python: Chatbots and face, object, and speech recognition with TensorFlow and Keras. 2018. P. 31–43.
15. Kumar A. et al. Image Classification in Python Using Keras // Proceedings of Data Analytics and Management: ICDAM, 2021. 2022. Vol. 1. P. 541–556.
16. Berbasov V. D. Comparative review of Keras and PyTorch neural network libraries // Economics and Society [Ekonomika i sotsium]. 2023. No. 8 (111). P. 423–426. [In Russ.].
17. Sobolev A. A., Demidova A. V. Practical aspects of computer implementation of machine learning methods // Control systems, technical systems: stability, stabilization, ways and methods of research. 2019. P. 107–111. [In Russ.].
18. Burkhanov R. A. Comparative analysis of libraries for deep learning of convolutional neural networks // SCVRT2018 International Scientific Conference of the Moscow Institute of Physics and Technology (State University) Institute of Physics and Technology Informatics. 2018. P. 235–240. [In Russ.].