

**Т. В. Сограби**  
**T. V. Sograbi**  
sograbi\_tv@usue.ru  
**С. В. Зуйко**  
**S. V. Zuiko**  
sofzui5676@gmail.com  
**В. А. Каткова**  
**V. A. Katkova**  
nknk060606@gmail.com  
**А. А. Ускова**  
**A. A. Uskova**  
uskova.ash@gmail.com  
**Ю. В. Устюжанина**  
**Y. V. Ustuzhanina**  
16122006ys@mail.ru

ФГАОУ ВО «Уральский государственный  
экономический университет», г. Екатеринбург  
Russian State University of Economics, Yekaterinburg

## КОНТРОЛЬ ЗАГРЯЗНЕНИЯ АТМОСФЕРЫ ПРИ ПОМОЩИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

**Аннотация:** в данной работе представлено современное состояние проблемы экологического мониторинга с использованием нейронных сетей, обобщены результаты предшествующих исследований других авторов. В кратком изложении освещены базовые принципы построения нейронных сетей, их структура, а также обсуждаются основные трудности, связанные с использованием искусственного интеллекта для анализа атмосферы, с предложением путей их решения. В работе также демонстрируется эффективность применения нейронных сетей для прогнозирования загрязнения воздуха.

**Ключевые слова:** нейросети, атмосферный мониторинг, прогнозирование, RNN, LSTM, загрязнение атмосферы.

## CONTROL OF AIR POLLUTION USING ARTIFICIAL INTELLIGENCE

**Abstract:** The paper presents the current state of the problem of environmental monitoring using neural networks and summarizes the results of some works by other authors. The basic principles of constructing neural networks and their structure are briefly described, the main problems that arise when using artificial intelligence to analyze the atmosphere are discussed, and ways to solve them are proposed. The effectiveness of using neural networks in forecasting atmospheric pollution is shown.

**Keywords:** neural networks, atmospheric monitoring, forecasting, RNN, LSTM, atmospheric pollution.

**Введение.** Уже несколько десятилетий проблема загрязнения атмосферы является одной из глобальных проблем человечества. Она вызвана и природными, и техногенными факторами. Сажа, парниковые газы, вулканический пепел, выбросы от сгорания топлива и бытовых отходов — все эти вещества являются составляющими загрязненной атмосферы [1]. Постоянное вдыхание такого воздуха приводит к развитию хронических заболеваний и высокой смертности в регионах с высоким уровнем загрязнения, оказывая серьезный вред природе и экономике [2–3]. Поэтому, использование перспективных технологических решений для мониторинга экологии является одной из актуальных тем исследований.

**Основная часть.** На сегодняшний день одной из перспективных технологий для экологического мониторинга могут служить искусственный интеллект и нейросети. Нейросеть представляет собой математическую модель, работающую по принципу живого организма и направленную на решение конкретной задачи, поставленной человеком. Основными преимуществами данной технологии являются возможность решать проблемы, не имеющие четкого алгоритма и predetermined исхода, а также способность к обучению, как под руководством человека, так и самостоятельно [4]. Нейросети могут быть задействованы в сборе и обработке данных об атмосферном загрязнении, качестве воздуха, изменениях климата и других приложениях. Ниже рассмотрим некоторые примеры нейросетей их наиболее перспективные приложения в экологическом мониторинге.

Рекуррентные нейронные сети (RNN) — это класс нейронных сетей, специально разработанных для работы с последовательностями данных. Данная сеть появилась в 1980 году. Хопфилд Джон, создатель данной сети, заметил, что данные, сохраненные в нейронах, могут быть использованы для моделирования ассоциативной памяти. Основной идеей Хопфилда было то, что нейроны могут сохранять информацию в своем внутреннем состоянии, которое потом можно использовать для воспроизведения запомненных образов [5].

Рекуррентные нейронные сети (RNN) получили свое название благодаря их способности к повторению — они выполняют одинаковую операцию для каждого элемента последовательности, и результат зависит от предыдущих вычислений. Способностью RNN является сохранять информацию о предшествующих шагах обработки, что делает их весьма гибкими в анализе контекста и временных зависимостей в последовательных данных.

Важно отметить, что порог активации каждого нейрона изменяется по мере времени и представляет собой вещественное число. Каждое соединение между нейронами имеет свой вес, который также является переменным и вещественным. Узлы в сети разделяются на три основные категории: входные, выходные и скрытые [6].

1. Входные узлы — это узлы, которые принимают на вход данные или признаки, которые подаются на вход нейронной сети. Количество входных узлов зависит от числа признаков, которые используются в задаче обучения.

2. Скрытые узлы — это узлы, которые находятся между входными и выходными узлами и выполняют преобразование входных данных. Количество скрытых узлов и слоев скрытых узлов может варьироваться в зависимости от сложности модели и задачи.

3. Выходные узлы — это узлы, которые представляют собой результат работы нейронной сети и выдают предсказание или классификацию в зависимости от задачи [7].

Рекуррентные нейронные сети (RNN) имеют несколько преимуществ, которые делают их полезными в различных задачах [8].

1. Учет контекста задачи, то есть способность нейросети адаптировать алгоритм под распознавание текста, образов, временных рядов и т. д.;

2. Обработка последовательностей переменной длины. К таковым могут относиться текст, аудио и прочие;

3. Совместное использование весовых параметров, благодаря чему размер модели перестает зависеть от длины последовательности.

Несмотря на свои преимущества, RNN также имеют некоторые недостатки:

1. Ограниченная память. Традиционные RNN имеют ограниченный запас памяти и плохо подходят для сохранения информации на большое количество временных шагов;

2. Вычислительная сложность и проблемы в обучении вследствие рекуррентной природы;

3. Неэффективность в обработке параллельных данных.

Существует множество работ, посвященных использованию RNN – сетей при анализе качества воздуха. В результате показана эффективность RNN-сетей для анализа качества воздуха. В тоже время отмечается, что архитектура нейросети нуждается в дальнейшей доработке, чтобы иметь возможность захватывать больше информации для анализа. В качестве такой доработки предлагается использовать двунаправленную RNN-архитектуру [9].

Работа [10] посвящена применению модифицированных RNN-сетей для прогнозирования прозрачности атмосферы в центральном и восточном Китае. В основе метода лежит распознавание фотоснимков нейросетью.

Нейросети на основе длинной цепи элементов краткосрочной памяти (англ. Long short-term memory; LSTM), впервые представленные в [8], специально разработаны для работы с долговременными зависимостями. В связи с этим такие нейросети эффективно используются при решении задач классификации, а также обработке и прогнозировании временных рядов со значительными и/или неравномерными временными промежутками между событиями.

В качестве основных составляющих LSTM-сети обычно выделяют ячейку и следующие фильтры: входной, выходной и забывания. Через фильтры в ячейку поступает вводная информация, которая изменяет ее состояние по заданному алгоритму.

К преимуществам LSTM-сетей относят следующие:

1. Эффективная работа с большими массивами данных;

2. Контроль вводной информации с помощью фильтров;
3. Динамическая модификация состояния ячеек с учетом длины вводных данных.

Вместе с тем, следует отметить недостатки LSTM-сетей. К таковым относятся:

1. Высокая расчетная сложность по сравнению с другими видами нейросетей;
2. Проблемы с обучением при недостаточности данных;
3. Сложность в настройке гиперпараметров.

Примером применения LSTM-сети для экологического мониторинга может служить работа по определению ключевых загрязнителей в атмосфере Красноярска [11]. Использовалась тренировочная модель с десятью вводными параметрами. Авторы отмечают, что нейросеть может адекватно предсказывать загрязнение вплоть до 5-10 часов, однако далее производительность нейросети падает. На результат работы нейросети могут влиять посторонние внешние факторы среды, такие как скорость и направление ветра и температура.

Работа посвящена совмещению LSTM-архитектуры с метаэвристическими алгоритмами для оценки загрязнения воздуха [12]. Как и в предыдущей работе, отмечается сильная зависимость LSTM-сети от гиперпараметров. Для решения этой проблемы используется генетический алгоритм, по утверждению авторов улучшающий производительность нейросети. С помощью него нейросеть удовлетворительно предсказывает загрязнение воздуха вплоть до одного дня.

Первое введение сверточных нейронных сетей (CNN, Convolutional Neural Network) в литературе было представлено в работе [13]. Их применяют для задачи распознавания изображений и видео.

Название сверточная сеть получила по названию главной операции – свертки. Во время свертки происходит очистка исходных данных от лишней информации, оставляя данные только с определенными признаками. В основе работы CNN-сети лежат следующие этапы:

1. Входной слой функционирует как приемник "сырых" данных изображения и состоит из нескольких сверточных слоев, которые выполняют первичную обработку входных данных;
2. Сверточный слой – основной элемент сети, отвечающий за извлечение признаков из входного изображения. Состоит из набора фильтров, каждый из которых обрабатывает изображение и составляет карту признаков;
3. Слой подвыборки – используется для снижения размерности карт признаков и выделения наиболее важных признаков изображения;

4. Полносвязный слой – обрабатывает результат слоя подвыборки, на основании чего делает финальное предсказание.

Преимуществами CNN – сетей являются:

1. Отсутствие человеческого контроля при работе;
2. Автоматическое извлечение признаков с высокой точностью;
3. Возможность работать с большим объемом данных;
4. Иерархическая модель обучения;
5. Низкая чувствительность к шумам и паразитным данным.

К недостаткам таких сетей относят:

1. Высокие расчетные требования;
2. Сложности в интерпретировании;
3. Долгое время обучения;
4. Необходимость в большом объеме отсортированных данных;
5. Низкую скорость работы.

Что касается экологического мониторинга, CNN-сети представляют собой перспективное направление. Они способны распознавать спутниковые и высотные снимки атмосферы, а также определять концентрацию ключевых загрязнителей.

Так, в работе с использованием глубокого обучения предсказана почасовая концентрация загрязнителей воздуха [14]. Обучение осуществлялось с использованием временных рядов данных. Данные собирались из 77 различных локаций из официальных источников.

Работа посвящена использованию CNN-сети для прогнозирования качества воздуха в городских районах Индии [15]. В качестве вводных данных использовались годовые измерения основных загрязнителей – аммиака, диоксида серы, оксида углерода и т. д. Использовалась регрессионная модель для форматирования данных перед последующим вводом в алгоритм нейросети.

В работе применено глубокое обучение CNN – сети с использованием изображений атмосферы реального времени. Построена трехмерная сверточная сеть с механизмом внимания [16]. Показано, что такой подход позволяет извлечь скрытые признаки из многомерных массивов данных и распознать актуальные данные окружающей среды.

Таким образом, искусственные нейронные сети могут играть важную роль при обработке данных мониторинга атмосферы, распознавании очагов загрязнения и прогнозировании качества воздуха.

**Список литературы**

1. Иванов М. А. Загрязнение атмосферного воздуха // Инновационные научные исследования. 2020. № 12-1 (2). С. 99–106. <http://doi.org/10.5281/zenodo.4444613>.
2. Каирова Ж. О., Цудиева З. Б., Оказова З. П. Экологические аспекты утилизации твердых бытовых отходов // Наука и образование в жизни современного общества: сборник научных трудов по материалам Международной научно-практической конференции, Тамбов, 30 декабря 2014 г. Тамбов: Консалтинговая компания Юком, 2015. Ч. 5. С. 51–53.
3. Котенев И. А. Экономическая оценка ущерба от загрязнения атмосферного воздуха автотранспортом // Качество науки – качество жизни. 2018. № 11. С. 107–109.
4. Кан А. К. Нейронные сети. Эволюция. SelfPub, 2018. 376 с. URL: <https://www.litres.ru/book/kania-alekseevich-kan/neyronnye-seti-evoluciya-31735262/>.
5. Hopfield J. J. Neural networks and physical systems with emergent collective computational abilities // Proceedings of National Academy of Sciences. 1982. Vol. 79, iss. 8. P. 2554–2558.
6. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9, iss. 8. P. 1735–1780.
7. DeepAirNet: Applying Recurrent Networks for Air Quality Prediction / Athira V., Geetha P., Vinayakumar R., Soman K. P. // Procedia Computer Science. 2018. № 132. P. 1394–1403. <http://doi.org/10.1016/j.procs.2018.05.068>.
8. Рекуррентные нейронные сети: основные принципы и применение // Научные Статьи.Ру – портал для студентов и аспирантов. URL: <https://nauchniestati.ru/spravka/rekurrentnye-nejronnye-seti/> (дата обращения: 11.05.2024).
9. A Deep Recurrent Neural Network for Air Quality Classification / X. Zhao, R. Zhang, W. Jheng-Long, C. Pei-Chann // Journal of Information Hiding and Multimedia Signal Processing. 2018. Vol. 9, no. 2. P. 346–354.
10. A Modified RNN-Based Deep Learning Method for Prediction of Atmospheric Visibility / Z. Zengliang, B. Xulun, L. Yi et al. // Remote sensing. 2023. Vol. 15, iss. 3. P. 553–569. <http://doi.org/10.3390/rs15030553>.
11. Kulagina L. V., Kulagina T. A. LSTM Forecasting: Time Series Forecasting to Predict Concentration of Air Pollutants (CO, SO<sub>2</sub>, NO and NO<sub>2</sub>) in Krasnoyarsk, Russia // Lecture Notes in Networks and Systems. 2021. Vol. 228. P. 191–198. [http://doi.org/10.1007/978-3-030-77448-6\\_17](http://doi.org/10.1007/978-3-030-77448-6_17).

12. Ghufuran I. D., Riyadh J. A.-B. Air pollution prediction using LSTM deep learning and metaheuristics algorithms // Measurement: Sensors. 2022. Vol. 24, iss. 1. P. 100546. <http://dx.doi.org/10.1016/j.measen.2022.100546>.

13. Backpropagation Applied to Handwritten Zip Code Recognition / Y. LeCun, Boser B., Dencor J. S. et al. // Neural Computation. 1989. Vol. 1, iss. 4. P. 541–551. <http://doi.org/10.1162/neco.1989.1.4.541>.

14. Yushun M., Shiejue L. Deep Convolutional Neural Network for Air Quality Prediction // Journal of Physics Conference Series. 2019. Vol. 1302. iss. 3. P. 032046. <http://doi.org/10.1088/1742-6596/1302/3/032046>.

15. Chauhan R., Kaur H., Alankar B. Air Quality Forecast using Convolutional Neural Network for Sustainable Development in Urban Environments // Sustainable Cities and Society. 2021. Vol. 75. P. 103239. <http://doi.org/10.1016/j.scs.2021.103239>.

16. Air-pollution prediction in smart city, deep learning approach / Bekkar A., Hssina B., Douzi S., Douzi K. // Journal of Big Data. 2021. Vol. 8. P. 161.