

НЕЙРОСЕТЕВЫЕ МОДЕЛИ ПРОГНОЗИРОВАНИЯ УРОВНЯ ЗАГРЯЗНЕНИЯ АТМОСФЕРНОГО ВОЗДУХА В ПРОМЫШЛЕННОМ ГОРОДЕ

NEURAL NETWORK MODELS FOR PREDICTION OF AIR POLLUTION INDEX IN AN INDUSTRIAL CITY

**A. Panchenko
P. Rahman
A. Safarov**

Summary. This scientific paper deals with use of the artificial neural networks for the ecological prediction of state of the atmospheric air of an industrial city. The authors offer two types of predictive models for determining of the level of air pollution on the basis of neural networks: a temporal (short-term forecast of the pollutants content in the air) and a spatial (forecast of atmospheric pollution index in any part of the city). The structure and parameters of the offered neural networks, and selection of the learning algorithms, which provides best adequacy of the models based on the neural networks are also observed.

Keywords: air basin, short-term air pollution forecast, neuron, neural network model, feed-forward neural network, Elman neural network, learning algorithm for neural network.

Панченко Алина Аликовна

Преподаватель, филиал Уфимского государственного
нефтяного технического университета
в г. Стерлитамаке, Российская Федерация
alina-8706@rambler.ru

Рахман Павел Азизурович

К.т.н., доцент, филиал Уфимского государственного
нефтяного технического университета
в г. Стерлитамаке, Российская Федерация
pavelar@yandex.ru

Сафаров Айрат Муратович

Д.т.н., доцент, Уфимский государственный нефтяной
технический университет, г. Уфа, Российская Федерация
safarov_a_m@mail.ru

Аннотация. Данная научная статья посвящена применению нейронных сетей для экологического прогнозирования состояния атмосферного воздуха промышленного города. Авторами предлагается два типа прогнозных моделей на базе нейронных сетей для определения уровня загрязнения воздуха: временная (краткосрочный прогноз содержания загрязнителей в воздухе) и пространственная (прогноз индекса загрязнения атмосферы в любой части города). Также рассматриваются структура и параметры предлагаемых нейронных сетей, а также выбор алгоритмов для их обучения, обеспечивающих наилучшую адекватность моделей на базе нейронных сетей.

Ключевые слова: воздушный бассейн, краткосрочный прогноз загрязнения воздуха, нейрон, нейросетевая модель, нейронная сеть прямого распространения, нейронная сеть Элмана, алгоритм обучения нейронной сети.

Введение

В настоящее время загрязнение воздушного бассейна отмечается практически во всех городах и промышленно развитых центрах химии и нефтехимии. В отдельные периоды в таких городах действуют неблагоприятные для рассеивания выбросов метеорологические условия, это способствует накоплению антропогенных выбросов в воздушном бассейне города. Во избежание повышения уровня загрязнения воздуха при таких условиях необходимо прогнозировать содержание загрязняющих веществ в воздухе с учетом этих условий. Вместе с тем, общеизвестные методы прогнозирования на основе экспоненциальных скользящих средних, анализа временных рядов, регрессионного анализа и т.д., не дают ощутимый результат, так как на процесс загрязнения воздуха действует множество неформализуемых и малоизученных факторов, которые трудно учесть в полученных моделях.

К тому же данные мониторинга загрязнения воздушного бассейна промышленного города характеризуются многомерностью и многосвязностью экологических данных, процессу загрязнения присущи нелинейность и неопределенность, что затрудняет оценку и прогнозирование оператором экологической ситуации. Для того чтобы повысить оперативность и точность принятия правильных управленческих решений в последнее время все чаще используются искусственные нейронные сети, способные работать в условиях нечеткой исходной информации и учитывать скрытые зависимости.

Искусственные нейронные сети [1, 2] — это математические модели, а также их программные и аппаратные реализации, построенные по принципу организации и функционирования биологических нейронных сетей — сетей нервных клеток живого организма. Это понятие возникло при изучении процессов, протекающих в мозге при мышлении, и попытке смоделировать

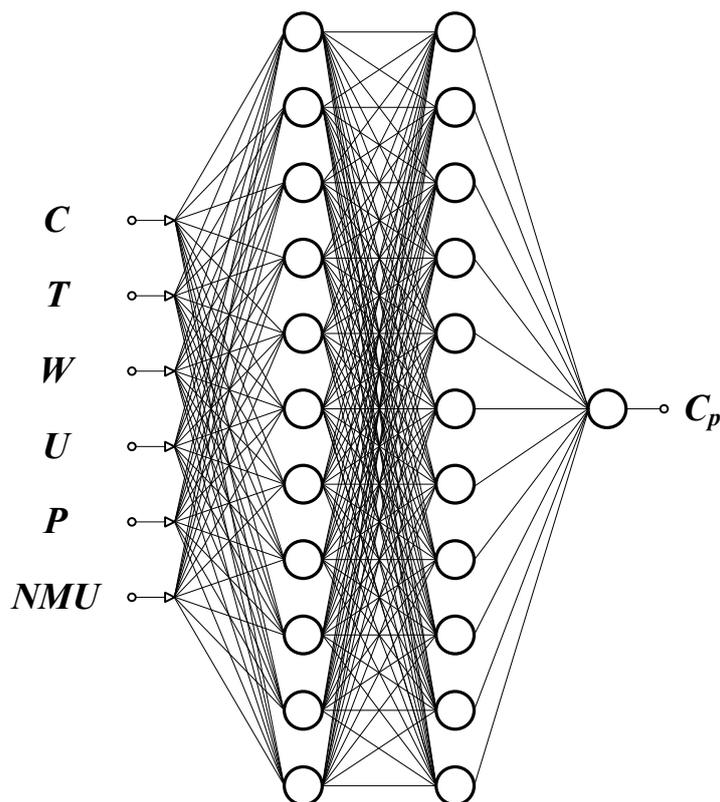


Рис. 1. Топология разработанной нейронной сети прямого распространения.

Где,

- C — текущее значение концентрации загрязняющего вещества;
- T — температура воздуха; W — направление ветра;
- U — скорость ветра; P — атмосферное давление;
- NMU — режим неблагоприятных метеоусловий;
- C_p — прогнозируемое значение концентрации загрязнителя.

эти процессы. Впоследствии эти модели стали использовать в практических целях, как правило, в задачах прогнозирования. Нейронные сети не программируются в привычном смысле этого слова, они обучаются. Возможность обучения — одно из главных преимуществ нейронных сетей перед традиционными алгоритмами. Технически обучение заключается в нахождении связей между нейронами. В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными данными и выходными. После обучения сеть способна предсказать будущие значения некой последовательности на основе нескольких предыдущих значений и существующих факторов.

В рамках научных исследований авторами были проанализированы существующие работы в области нейросетевых моделей прогнозирования загрязнения воздуха [3, 4] и была рассмотрена возможность применения нейронных сетей в прогнозировании уровня загрязнения атмосферного воздуха на примере промышленного города

Стерлитамак. Выбор данного города обусловлено тем, что это один из крупнейших промышленных центров химии и нефтехимии в Российской Федерации. В 2009–2010, 2013 гг. он входил в список российских городов с очень высоким уровнем загрязнения воздуха. Специфика его загрязнения и природных условий типична для целого ряда урбоэкосистем востока Европейской части России. В таких городах уже много лет ведётся мониторинг природной среды, однако обобщения всех этих наблюдений для построения математических моделей состояния среды обитания и краткосрочного прогнозирования ее загрязнения в будущем с целью принятия оперативных природоохранных мер пока не было сделано.

Первым шагом в этом направлении стала разработка нейросетевых моделей временного и пространственного прогнозирования уровня загрязнения воздушного бассейна промышленного города Стерлитамак с использованием результатов прежних научных исследований авторов в области загрязнения атмосферного воздуха

Таблица 1. Параметры нейросетевой модели

Параметры нейронной сети	Значение	Примечание
Количество входов сети	6	концентрация вещества по состоянию на момент применения модели, метеорологические характеристики следующего дня: направление и скорость ветра, температура, давление, режим неблагоприятных метеорологических условий.
количество скрытых слоев	2	в первом слое в качестве функции активации используется «гиперболический тангенс», во втором слое — «линейная функция».
количество нейронов в скрытом слое	11	–
Количество выходов сети	1	прогнозное значение содержания загрязняющего вещества в атмосферном воздухе.

для данного города [5, 6]. Временное прогнозирование сводится к способности осуществлять краткосрочный прогноз уровня загрязнения воздуха поллютантами на ближайшие сутки. Пространственное же прогнозирование сводится к определению индекса загрязнения атмосферы в любой точке города с учетом ее орографических особенностей.

Модель краткосрочного прогнозирования уровня загрязнения атмосферного воздуха

На первом этапе научных исследований авторами была разработана нейросетевая модель прогнозирования содержания специфических для города с развитой химической и нефтехимической промышленностью загрязняющих веществ — в рамках данного исследования: пыль, аммиак, сероводород, фенол, винилхлорид, диоксид азота, в атмосферном воздухе с заблаговременностью до нескольких суток в зависимости от метеорологических характеристик в последующие дни.

Важным моментом на этапе разработки являлся выбор входных данных для нейросетевой модели — в данном случае это концентрации поллютантов в воздухе в предшествующие периоды и метеорологические параметры: концентрация вещества по состоянию на момент применения модели, метеорологические характеристики следующего дня: направление и скорость ветра, температура, давление, режим неблагоприятных метеорологических условий, что обусловлено высокой теснотой связи между ними.

В рамках исследований авторами были апробированы различные виды нейронных сетей, и наилучшие результаты прогнозирования показала многослойная нейронная сеть прямого распространения [7, 8].

Также авторами дополнительно была проведена работа по определению оптимального количества ней-

ронов в скрытых слоях, однако, вариация количества нейронов в скрытых слоях не привела к существенному изменению качества нейросетевой модели. Топология разработанной нейронной сети для различных загрязняющих веществ получилась идентичной. На рисунке 1 представлена итоговая, выбранная авторами, топология нейронной прямого распространения сети, а ее параметры приведены в таблице 1.

В рамках научных исследований авторами также были апробированы различные алгоритмы обучения нейронной сети прямого распространения с оценкой адекватности нейросетевой модели, построенной на базе обученной нейронной сети.

Для каждого рассматриваемого алгоритма оценивалась адекватность нейросетевой модели путем подачи в обученную нейронную сеть входных значений $[x_{1(q)}, \dots, x_{6(q)}]$ и сопоставления получаемых на выходе нейронной сети значений $y_{(q)}$ с заданными эталонными значениями $d_{(q)}$ в контрольной выборке

$$\{[x_{1(q)}, \dots, x_{6(q)}], d_{(q)}\}_{q=1}^Q,$$

с последующим вычислением корреляции r между двумя рядами значений:

$$r = \frac{\sum_{q=1}^Q (d_{(q)} - \bar{d})(y_{(q)} - \bar{y})}{\sqrt{\sum_{q=1}^Q (d_{(q)} - \bar{d})^2} \sqrt{\sum_{q=1}^Q (y_{(q)} - \bar{y})^2}}. \quad (1)$$

Где, \bar{d} — среднее по всем эталонным значениям $d_{(q)}$ в выборке, \bar{y} — среднее по всем выходным значениям $y_{(q)}$ в выборке, Q — размер выборки.

Конкретно для загрязняющего вещества аммиак результаты обучения нейронной сети прямого распро-

Таблица 2. Результаты обучения нейронной сети прямого распространения различными алгоритмами (на примере аммиака)

Алгоритм обучения	Адекватность полученной модели
Алгоритм Бройдена — Флетчера — Гольдфарба — Шанно (BFGS)	72%
Алгоритм CGB Пауэлла — Биеле	73%
Алгоритм GD градиентного спуска	2%
Алгоритм GDA градиентного спуска с выбором параметра скорости настройки	67%
Алгоритм LM Левенберга–Марквардта	43%
Пороговый алгоритм Rprop обратного распространения ошибки	70%

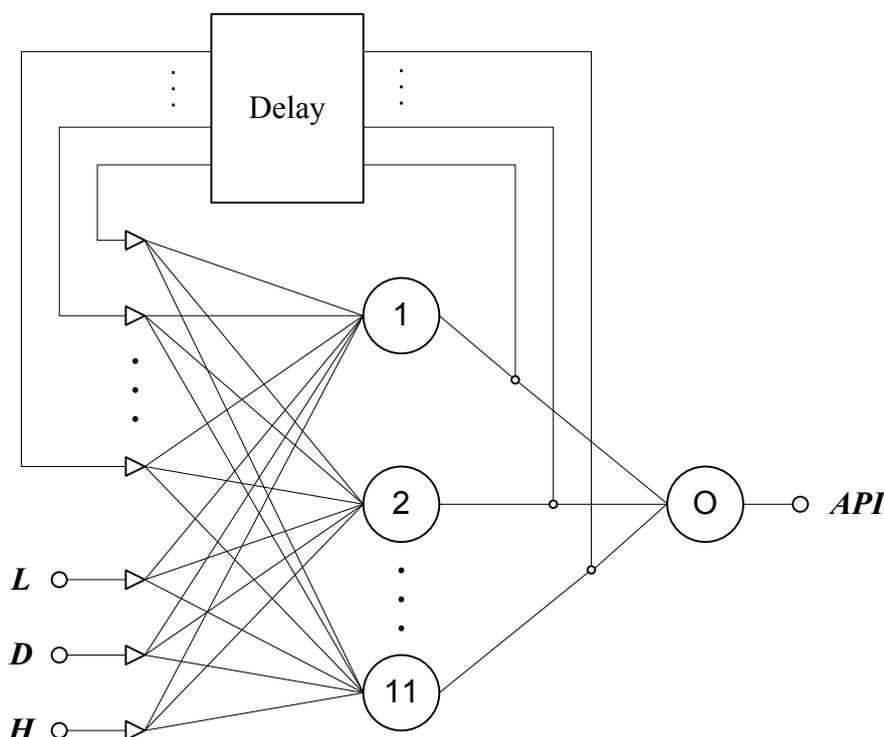


Рис. 2. Топология разработанной нейронной сети Элмана.

L — отметка рельефа в любой интересующей пользователя точке города;
 D — показатель токсичности проб, полученный с использованием кресс-салата;
 H — показатель токсичности проб, полученный с использованием дафний магна;
 API (air pollution index) — показатель индекса загрязнения атмосферного воздуха;
 Delay — блок задержки на один временной интервал, используемый в контуре обратной связи в нейронной сети Элмана.

странения при помощи различных алгоритмов обучения представлены в таблице 2.

Таким образом, очевидно, что конкретно для загрязняющего вещества аммиак наилучшая адекватность нейросетевой модели прогнозирования достигается при использовании многослойной нейронной сети прямого распространения с алгоритмом обучения Пауэлла-Биеле.

Для возможности использования разработанной нейросетевой модели в практических расчетах уровня загрязнения воздуха (на примере аммиака) авторами также была разработана программная реализация в математической среде MatLab со встроенным пакетом Neural Networks Toolbox.

Математическим «ядром» программы является экспортированная из MatLab обученная нейронная сеть,

Таблица 3. Параметры нейронной сети Элмана

Параметры нейронной сети	Значение	Примечание
Количество входов сети	3	Вход 1: Отметка рельефа в любой интересующей пользователя точке города; Вход 2: Показатель токсичности проб, полученный с использованием кресс-салата; Вход 3: Показатель токсичности проб, полученный с использованием дафний магна.
Количество скрытых слоев	1	–
Количество нейронов в скрытом слое	11	–
Количество контуров обратных связей	1	В контуре используются выходные значения нейронов скрытого слоя, которые задерживаются на один временной интервал и далее по обратной связи подаются на входы нейронов скрытого слоя со своими весовыми коэффициентами.
Количество выходов сети	1	Выход: Показатель индекса загрязнения атмосферного воздуха.

Таблица 4. Результаты обучения сети Элмана различными алгоритмами

Алгоритм обучения	Адекватность полученной модели
Метод градиентного спуска	66,1
Метод градиентного спуска с адаптивным обучением	76,2
Метод градиентного спуска с учетом моментов	21,3
Метод градиентного спуска с учетом моментов и с адаптивным обучением	86,7
Регуляризация Bayesian	33,6

которая и используется как ключевой блок обработки входных значений и расчета результата.

Применение программы для прогнозирования уровня загрязнения атмосферного воздуха города Стерлитамак оказалось достаточно результативным. Точность прогноза составляет более 70%.

Модель прогнозирования пространственного загрязнения

Второй этап научных исследований авторов свелся к проектированию нейросетевой модели, описывающей уровень загрязнения воздуха в любой точке города с учетом ее локальных орографических характеристик.

В качестве входных данных в нейросетевой модели были использованы отметка рельефа в месте отбора проб, показатели токсичности проб, полученных с использованием кресс-салата и дафний магна. В качестве выходного значения был принят показатель индекса загрязнения атмосферного воздуха в месте отбора пробы снега.

В рамках исследований были авторами апробированы различные типы нейронных сетей, и наилучшие результаты прогнозирования показала рекуррентная нейронная сеть Элмана [9, 10].

На рисунке 2 представлена итоговая, выбранная авторами, топология рекуррентной нейронной сети Элмана, а ее параметры приведены в таблице 3.

Кроме того, дополнительно была проведена работа по определению оптимального количества нейронов в скрытом слое, однако, вариация количества нейронов в скрытом слое не привела к существенному изменению качества нейросетевой модели.

В рамках научных исследований также были апробированы различные алгоритмы обучения нейронной сети Элмана с оценкой адекватности нейросетевой модели, построенной на базе обученной нейронной сети. Адекватность нейросетевой модели оценивалась путем подачи в обученную нейронную сеть входных значений $[x_1(t), x_2(t), x_3(t)]$ и сопоставления получаемых на выходе нейронной сети значений $y(t)$ с заданными эталонными значениями $O(t)$ в контрольной выборке

$$\{[x_1(t), x_2(t), x_3(t)], O(t)\}_{t=1}^Q,$$

с последующим вычислением корреляции r между ними:

$$r = \frac{\sum_{t=1}^Q (O(t) - \bar{O})(y(t) - \bar{y})}{\sqrt{\sum_{t=1}^Q (O(t) - \bar{O})^2} \sqrt{\sum_{t=1}^Q (y(t) - \bar{y})^2}}. \quad (2)$$

Где \bar{O} — среднее по всем эталонным значениям $O(t)$ в выборке, \bar{y} — среднее по всем выходным значениям $y(t)$ в выборке, Q — размер выборки.

Результаты оценок адекватности нейросетевой модели на базе нейронной сети Элмана при использовании тех или иных алгоритмов обучения приведены в таблице 4.

Достаточно очевидно, что наилучшие показатели достигаются в рекуррентной нейронной сети Элмана с алгоритмом обучения на базе градиентного спуска с учетом моментов и с адаптивным обучением.

Для возможности использования разработанной нейросетевой модели в практических расчетах уровня индекса загрязнения воздуха авторами также была разработана программная реализация в математической среде MatLab со встроенным пакетом Neural Networks Toolbox.

Математическим «ядром» программы является экспортированная из MatLab обученная нейронная сеть Элмана, которая и используется как ключевой блок обработки входных значений и расчета результата.

Применение программы для прогнозирования уровня загрязнения атмосферного воздуха города Стерлитамак оказалось достаточно результативным. Точность прогноза составляет более 83%.

Заключение

Разработанные авторами нейросетевые модели прогнозирования уровня загрязнения атмосферного воздуха являются достаточно результативными. Ежедневное получение новых данных об уровне загрязнения воздуха доказывают состоятельность разработанных моделей.

Необходимо также отметить наличие возможности периодического дополнительного обучения нейронных сетей на дополнительных новых данных экспериментальных наблюдений. Внедрение нейросетевой модели в систему мониторинга воздушного бассейна города несомненно повысит качество работы как государственных органов, так и отделов экологической безопасности крупных промышленных предприятий города. Но, несмотря на очевидные достоинства нейросетевых моделей, не стоит считать их некой «панацеей». Наилучшим для достижения природоохранных результатов является использование нейросетевых моделей в совокупности с грамотной стратегией природоохранного управления.

ЛИТЕРАТУРА

1. M. Caudill and C. Butler. Understanding Neural Networks: Computer Explorations, Cambridge, MIT Press, 1992.
2. Berndt Müller, Joachim Reinhardt and Michael T. Strickland, Neural Networks: An Introduction, Springer-Verlag Berlin Heidelberg, 1995.
3. A. Kurt, B. Gulbagci, F. Karaca and O. Alaghab, An online air pollution forecasting system using neural networks, Environment International, 2008, Vol. 34 (5), pp. 592–598.
4. G. Ibarra-Berastegi, A. Elias, A. Barona, J. Saenz, A. Ezcurra and J. D. Argandona, From diagnosis to prognosis for forecasting air pollution using neural networks: Air pollution monitoring in Bilbao, Environmental Modelling and Software, 2008, Vol. 23 (5), pp. 622–637.
5. Сафаров А.М., Рахман П. А., Панченко А. А., Маннанов А. Х. Разработка нейросетевой модели краткосрочного прогноза загрязнения атмосферного воздуха города Стерлитамак Республики Башкортостан // Нефтегазовое дело. — 2016. — Т. 14. — № 1. — С. 206–212.
6. Панченко А.А., Рахман П. А., Сафаров А. М., Асфандиярова Л. Р., Сафаров М. Р. Разработка метода оценки загрязнения атмосферного воздуха на базе нейронной сети Элмана для промышленного города Стерлитамак // Нефтегазовое дело. — 2017. — Т. 15. — № 2. — С. 203–208.
7. Terrence L. Fine, Feedforward Neural Network Methodology, Springer-Verlag New York, 1999.
8. M. Hagan and M. Menhaj. Training feedforward networks with the Marquardt algorithm, IEEE Transactions on Neural Networks, 1994, Vol. 5 (6), pp. 989–993.
9. J. L. Elman. Finding structure in time, Cognitive Science, 1990, Vol. 14 (2), pp. 179–211.
10. Wu Wei, Xu Dong-Po and Li Zheng-xue. Convergence of gradient method for Elman networks, Applied Mathematics and Mechanics, 2008, Vol. 29 (9), pp. 1231–1238.

© Панченко Алина Аликовна (alina-8706@rambler.ru),

Рахман Павел Азизурович (pavelar@yandex.ru),

Сафаров Айрат Муратович (safarov_a_m@mail.ru).

Журнал «Современная наука: актуальные проблемы теории и практики»