

Мониторинг деформаций перегонных туннелей метрополитена с применением нейросетевого подхода

А.Д. Меллер¹✉, Р.Р. Галиева², А.В. Кулешова², А.К. Петросян², С.А. Глатко²

¹ Российский университет дружбы народов, г. Москва, Российская Федерация

² Национальный исследовательский технологический университет «МИСИС», г. Москва, Российская Федерация

✉ mellera33@gmail.com

Резюме: В статье рассматривается применение искусственных нейронных сетей и алгоритмов машинного обучения для мониторинга деформаций туннелей метрополитена, расположенных в сложных горно-геологических условиях. Особое внимание уделяется промышленной и экологической безопасности, а также современным методам измерения деформаций земной коры с использованием GPS/ГЛОНАСС-технологий, геодезической и маркшейдерской съемки. Описываются основные этапы работы искусственных нейронных сетей: обучение на основе данных о параметрах и состоянии туннелей, тестирование, валидация и эксплуатация для предсказания потенциальных деформаций. Рассмотрены ключевые архитектуры нейронных сетей, такие как глубокие, сверточные и рекуррентные сети, а также их возможности в обработке данных. Приведены примеры использования искусственных нейронных сетей для интерполяции данных, распознавания опасных зон и мониторинга колец туннелей. Отмечается важность качественных исходных данных, включающих геометрические параметры, физические характеристики материалов, климатические условия и исторические данные. В результате применения искусственных нейронных сетей обеспечивается оперативное обнаружение рисков, прогнозирование динамики деформаций и классификация их типов, что позволяет принимать своевременные меры для предотвращения аварийных ситуаций.

Ключевые слова: искусственные нейронные сети, деформации туннелей, мониторинг конструкций, машинное обучение, геодинамика, интерполяция данных

Для цитирования: Меллер А.Д., Галиева Р.Р., Кулешова А.В., Петросян А.К., Глатко С.А. Мониторинг деформаций перегонных туннелей метрополитена с применением нейросетевого подхода. *Горная промышленность*. 2025;(2):163–166. <https://doi.org/10.30686/1609-9192-2025-2-163-166>

Monitoring deformations of metro transit tunnels using a neural network approach

A.D. Meller¹✉, R.R. Galiyeva², A.V. Kuleshova², A.K. Petrosyan², S.A. Glatko²

¹ RUDN University, Moscow, Russian Federation

² National University of Science and Technology MISIS, Moscow, Russian Federation

✉ mellera33@gmail.com

Abstract: The article discusses application of artificial neural networks and machine learning algorithms for monitoring of deformations in subway tunnels located in complex mining and geological conditions. Particular attention is given to industrial and environmental safety, as well as modern methods for measuring crustal deformations using GPS/GLONASS technologies, geodetic, and mine surveying. The main stages of artificial neural networks operation are described, i.e. the training based on the tunnel parameters and conditions, testing, validation, and operation to predict the potential deformations. The key neural network architectures are considered such as the deep, convolutional, and recurrent networks along with their data processing capabilities. Examples are provided of artificial neural networks used for data interpolation, hazardous zone recognition, and tunnel ring monitoring. The importance of high-quality initial data, including geometric parameters, physical material properties, climatic conditions, and historical data, is emphasized. Implementation of artificial neural networks can help to promptly identify risks, predict the deformation dynamics, and classify the deformation types, enabling timely measures to prevent emergencies.

Keywords: artificial neural networks, tunnel deformations, structural monitoring, machine learning, geodynamics, data interpolation

For citation: Meller A.D., Galiyeva R.R., Kuleshova A.V., Petrosyan A.K., Glatko S.A. Monitoring deformations of metro transit tunnels using a neural network approach. *Russian Mining Industry*. 2025;(2):163–166. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-163-166>

Введение

При проектировании, строительстве и эксплуатации опасных производственных объектов (ОПО) и объектов гражданского строительства, находящихся в сложных горно-геологических условиях, особое внимание уделяется их промышленной и экологической безопасности [1]. Обязательными являются исследования современных деформаций и движений земной коры на промышленных и строительных площадках объектов атомной энергетики, гидротехнических сооружений, горных работ в оползнеопасных и сейсмических районах [2–10]. Современные движения земной коры (СДЗК) во многом определяют геодинамическую обстановку исследуемого района [4] и позволяют определить инженерные критерии безопасности эксплуатации предприятия. Для мониторинга скоростей СДЗК на геодинамических полигонах, промышленных и строительных площадках применяются GPS/ГЛОНАСС-технологии, геодезическая и маркшейдерская съемки [1]. По данным инструментальных исследований проводится линейная (вдоль профильных линий) или площадная интерполяция компонент смещений и деформаций пунктов наблюдений на основе уже известных математических подходов (способ нахождения промежуточных значений величины по имеющемуся дискретному набору известных значений) – усреднение векторов смещений, интерполяция полиномами, тригонометрическая интерполяция, методы кригинга и др.

Одним из возможных путей решения является применение другого широко известного математического аппарата для обработки данных инструментальных наблюдений – искусственных нейронных сетей (ИНС) и машинного обучения (МО) [1–7; 10–12]. Алгоритмы машинного обучения работают на основе анализа данных и поиска закономерностей в них, чтобы строить модели, способные делать предсказания или классифицировать новую информацию. Общий принцип заключается в обучении модели на большом количестве примеров, где для каждого объекта известен результат (обучающие данные). Алгоритм «учится» выявлять скрытые связи и зависимости между входными данными и результатом, чтобы затем применять эти знания для обработки новых данных.

В процессе обучения модель настраивает свои гиперпараметры, минимизируя ошибки прогнозов. Основные этапы включают сбор и подготовку данных, обучение модели, оценку её точности и при необходимости дообучение. Алгоритмы могут быть «с учителем» (supervised learning), когда есть размеченные данные, и «без учителя» (unsupervised learning), где алгоритм ищет паттерны в данных без заранее заданных ответов.

Основные архитектуры машинного обучения включают в себя классические алгоритмы, глубокие нейронные сети, конволюционные и рекуррентные нейронные сети и генеративно-состязательные нейронные сети [2].

Классические алгоритмы машинного обучения включают в себя [6]:

1. Классификация – распределение данных по категориям (например, определение типа объекта на изображении).
2. Кластеризация – группировка схожих объектов без предварительно заданных меток (например, выявление регионов с общими характеристиками).
3. Регрессия – предсказание числовых значений на основе входных данных (например, прогноз изменения температуры).

Методология

ИНС представляют собой определенную математическую систему соединённых и взаимодействующих между собой простых процессоров (далее – нейронов) [4] (рис. 1). Каждый нейрон сети имеет дело только с сигналами, которые он получает, и сигналами, которые он посылает другим нейронам. Будучи соединёнными в достаточно большую сеть такие по отдельности простые нейроны вместе способны выполнять довольно сложные задачи. У сети имеются взаимосвязи между нейронами (синапсы), и сила этих взаимосвязей выражена определенными весовыми коэффициентами. Полная матрица таких весовых коэффициентов представляет собой аналитический аппарат ИНС, в некотором роде «мозг» сети.

Взаимодействующие между собой нейроны представляются в виде слоев (выделяют нейроны входящего, скрытого и выходящего слоя) [10]. Задача нейронов входящего слоя – получить, нормализовать и передать информацию на скрытые слои. Далее в скрытых слоях ИНС происходит расчет сигналов, передаваемых на следующие скрытые слои или на выходящий слой. Выходящий слой преобразует конечные сигналы в выходящую информацию для пользователя ИНС.

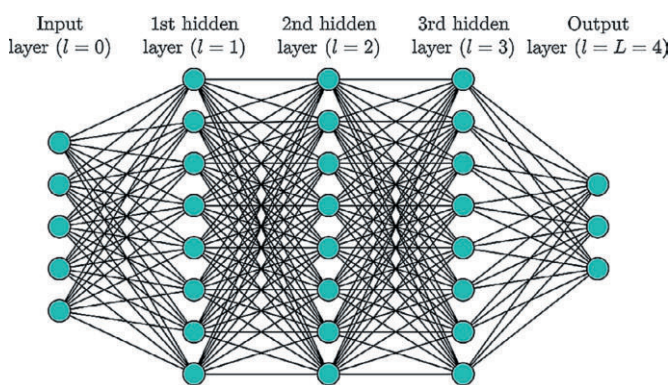


Рис. 1
Структура искусственной нейронной сети

Fig. 1
Structure of an artificial neural network

Результаты

Алгоритм работы искусственных нейронных сетей начинается с фазы обучения. На этом этапе сети предоставляются наборы данных, которые содержат информацию о параметрах туннелей, их текущем состоянии, а также исторические данные о деформациях. Каждый элемент данных связан с определенным результатом или ответом, который сеть должна научиться предсказывать. Со временем, проходя через множество итераций обучения и корректируя веса своих связей, ИНС формирует модель, способную с высокой точностью предсказывать исход, исходя из вводных данных. После обучения ИНС переходят к этапу тестирования и валидации. На этом этапе сеть подвергается тестовым вычислениям с использованием новых наборов данных, которые не использовались при обучении. Это позволяет оценить способность сети к генерализации и её эффективность в задаче прогнозирования деформаций туннелей. В процессе эксплуатации ИНС анализирует поступающую в реальном времени информацию о состоянии туннелей. Осуществляется сбор данных с датчиков, установленных вдоль туннелей, которые мониторят

перемещения, вибрации и другие параметры, связанные с целостностью конструкций [7]. Эта информация подается на вход ИНС, которая, опираясь на ранее накопленные знания, предсказывает потенциальные деформации и условия, которые могут привести к ним. Таким образом, система обеспечивает оперативность обнаружения рисков и позволяет принимать меры по их предотвращению или минимизации уже на ранней стадии развития.

Для успешного мониторинга деформаций перегонных туннелей метрополитена с использованием алгоритмов искусственных нейронных сетей критически важно иметь качественные исходные данные [2]. Эти данные не только обеспечивают точность и достоверность результатов, но и напрямую влияют на способность алгоритма обучаться, адаптироваться и точно предсказывать потенциальные деформации и их развитие во времени. Первоначально исходные данные для такого типа мониторинга обычно включают в себя информацию, собранную с помощью разнообразных датчиков и измерительных инструментов, размещенных в критических точках туннеля. К этим данным относятся:

1. Геометрические параметры туннеля, включая первоначальные размеры и форму структуры, которые являются основой для определения отклонений и изменений.
2. Физические характеристики материалов, из которых построен туннель, включая их возраст, состав, прочность на сжатие и предыдущие данные о деформациях.
3. Данные о нагрузках, влияющих на туннель, включая статические (вес самого туннеля, грунтовые нагрузки) и динамические (например, движение поездов, сейсмическая активность).
4. Информация о влажности, температуре и других климатических условиях вокруг и внутри туннеля, так как эти факторы могут существенно влиять на его деформации.
5. Исторические данные о предыдущих деформациях и ремонтных работах, выполняемых в туннеле.

После сбора и предварительной обработки этих данных приступают к формированию обучающего набора для ИНС. Важным шагом здесь является выбор характеристик, которые будут использоваться в качестве входных данных для

обучения нейросети. Отбор производится на основе статистического анализа и экспертных знаний о ключевых факторах, оказывающих наибольшее влияние на состояние и деформации туннеля. Кроме того, в процессе подготовки исходных данных большое значение имеет этап нормализации данных, который позволяет привести различные масштабы измерений к единому виду, что необходимо для эффективного обучения ИНС. Также применяются методы для устранения шумов и выбросов в данных, чтобы минимизировать их искажающее влияние на процесс обучения и повысить точность предсказаний нейронной сети [5].

Выводы

Результатом работы нейронных сетей при мониторинге деформаций перегонных туннелей метрополитена являются данные, позволяющие оценить текущее состояние конструкций, выявить места наиболее вероятных деформаций и предсказать динамику их развития в будущем.

Получаемые с помощью нейронных сетей данные включают в себя детальную картину деформаций стен, потолков и основания туннеля с максимально точным указанием локализации проблемных участков. Это достигается за счет обработки больших объемов информации, собранной с датчиков в реальном времени, что позволяет проводить динамический анализ изменений структуры объекта. Анализируя исторические данные, нейросеть способна предсказывать вероятные сценарии развития структурных изменений, оценивая такие параметры, как скорость деформаций и их потенциальные причины. Это даёт возможность принимать превентивные меры до того, как деформации достигнут критического уровня. Нейросети могут с высокой точностью прогнозировать риски, основываясь на сочетании текущих данных о состоянии объекта и исторически накопленной информации о его поведении в аналогичных условиях. Не менее важным является возможность классификации типов деформаций с помощью нейронных сетей. Анализируя данные, система может отличить, к примеру, усадочные деформации от деформаций, вызванных подтеканием воды или нарушением целостности грунта. Это позволяет более точно подбирать методы укрепления и ремонта, а также реализовывать целенаправленные инженерные решения для каждого конкретного случая.

Список литературы / References

1. Manevich A.I., Losev I.V., Avdonina A.M., Shevchuk R.V., Kaftan V.I., Tatarinov V.N. Modeling the horizontal velocity field of the earth's crust in a regular grid from GNSS measurements. *Russian Journal of Earth Sciences*. 2023;23(6):ES6002. <https://doi.org/10.2205/2023es000885>
2. Boubou R., Emeriault F., Kastner R. Artificial neural network application for the prediction of ground surface movements induced by shield tunnelling. *Canadian Geotechnical Journal*. 2010;47(11):1214–1233. <https://doi.org/10.1139/t10-023>
3. Grishchenkova E.N. Development of a neural network for earth surface deformation prediction. *Geotechnical and Geological Engineering*. 2018;36:1953–1957. <https://doi.org/10.1007/s10706-017-0438-y>
4. Татаринов В.Н., Маневич А.И., Лосев И.В. Системный подход к геодинамическому районированию на основе искусственных нейронных сетей. *Горные науки и технологии*. 2018;(3):14–25. <https://doi.org/10.17073/2500-0632-2018-3-14-25>
Tatarinov V.N., Manevich A.I., Losev I.V. A system approach to geodynamic zoning based on artificial neural networks. *Mining Science and Technology (Russia)*. 2018;(3):14–25. (In Russ.) <https://doi.org/10.17073/2500-0632-2018-3-14-25>

5. Замараев Р.Ю., Гречишкин П.В., Гиниятуллина О.Л. Повышение оперативности прогноза сейсмической активности при отработке запасов угля на шахтах с применением алгоритмов нейронных сетей. *Горная промышленность*. 2024;(3S):57–62. <https://doi.org/10.30686/1609-9192-2024-3S-57-62>
Zamaraev R.Y., Grechishkin P.V., Giniyatullina O.L. Improving the efficiency of forecasting seismic activity during mining of coal reserves in mines using neural network algorithms. *Russian Mining Industry*. 2024;(3S):57–62. (In Russ.) <https://doi.org/10.30686/1609-9192-2024-3S-57-62>
6. Suwansawat S., Einstein H.H. Artificial neural networks for predicting the maximum surface settlement caused by EPB shield tunneling. *Tunnelling and Underground Space Technology*. 2006;21(2):133–150. <https://doi.org/10.1016/j.tust.2005.06.007>
7. Yoo C., Kim J.-M. Tunneling performance prediction using an integrated GIS and neural network. *Computers and Geotechnics*. 2007;34(1):19–30. <https://doi.org/10.1016/j.compgeo.2006.08.007>
8. Kasper T., Meschke G. A numerical study of the effect of soil and grout material properties and cover depth in shield tunnelling. *Computers and Geotechnics*. 2006;33(4-5):234–247. <https://doi.org/10.1016/j.compgeo.2006.04.004>
9. Kasper T., Meschke G. On the influence of face pressure, grouting pressure and TBM design in soft ground tunnelling. *Tunnelling and Underground Space Technology*. 2006;21(2):160–171. <https://doi.org/10.1016/j.tust.2005.06.006>
10. Kim C.Y., Bae G.J., Hong S.W., Park C.H., Moon H.K., Shin H.S. Neural network based prediction of ground surface settlements due to tunnelling. *Computers and Geotechnics*. 2001;28(6-7):517–547. [https://doi.org/10.1016/S0266-352X\(01\)00011-8](https://doi.org/10.1016/S0266-352X(01)00011-8)
11. Великанов В.С., Дремин А.В., Чернухин С.А., Ломовцева Н.В. Технологии нейронных сетей в интеллектуальном анализе данных гранулометрического состава взорванных пород. *Горная промышленность*. 2024;(4):90–94. <https://doi.org/10.30686/1609-9192-2024-4-90-94>
Velikanov V.S., Dremine A.V., Chernukhin S.A., Lomovtseva N.V. Neural network technologies in mining data on particle size distribution of muck pile rocks. *Russian Mining Industry*. 2024;(4):90–94. (In Russ.) <https://doi.org/10.30686/1609-9192-2024-4-90-94>
12. Javadi A.A. Estimation of air losses in compressed air tunneling using neural network. *Tunnelling and Underground Space Technology*. 2006;21(1):9–20. <https://doi.org/10.1016/j.tust.2005.04.007>

Информация об авторах

Меллер Александр Дмитриевич – аспирант департамента недропользования и нефтегазового дела, Российский университет дружбы народов, г. Москва, Российская Федерация; e-mail: meller33@gmail.com

Галиева Рита Ришатовна – аспирант кафедры энергоэффективных и ресурсосберегающих промышленных технологий, Национальный исследовательский технологический университет «МИСИС», г. Москва, Российская Федерация; e-mail: jebulcan@gmail.com

Кулешова Анастасия Владимировна – аспирант кафедры энергоэффективных ресурсосберегающих промышленных технологий, Национальный исследовательский технологический университет «МИСИС», г. Москва, Российская Федерация; e-mail: nastya.kramar98@gmail.com

Петросян Артур Карленович – аспирант кафедры энергоэффективных ресурсосберегающих промышленных технологий, Национальный исследовательский технологический университет «МИСИС», г. Москва, Российская Федерация; e-mail: petrosyan98.archi@yandex.ru

Глатко Светлана Андреевна – аспирант кафедры геологии и маркшейдерского дела, Национальный исследовательский технологический университет «МИСИС», г. Москва, Российская Федерация; e-mail: taratorina.svetlana99@mail.ru

Информация о статье

Поступила в редакцию: 06.01.2025

Поступила после рецензирования: 05.03.2025

Принята к публикации: 17.03.2025

Information about the authors

Alexander D. Meller – Postgraduate Student, Department of Subsoil Use and Oil and Gas Engineering, RUDN University, Moscow, Russian Federation; e-mail: meller33@gmail.com

Rita R. Galiyeva – Postgraduate Student, Department of Energy-Efficient and Resource-Saving Industrial Technologies, National University of Science and Technology MISIS, Moscow, Russian Federation; e-mail: jebulcan@gmail.com

Anastasia V. Kuleshova – Postgraduate Student, Department of Energy-Efficient and Resource-Saving Industrial Technologies, National University of Science and Technology MISIS, Moscow, Russian Federation; e-mail: nastya.kramar98@gmail.com

Artur K. Petrosyan – Postgraduate Student, Department of Energy-Efficient and Resource-Saving Industrial Technologies, National University of Science and Technology MISIS, Moscow, Russian Federation; e-mail: petrosyan98.archi@yandex.ru

Svetlana A. Glatko – Postgraduate Student, Department of Geology and Surveying, College of Mining, National University of Science and Technology MISIS, Moscow, Russian Federation; e-mail: taratorina.svetlana99@mail.ru

Article info

Received: 06.01.2025

Revised: 05.03.2025

Accepted: 17.03.2025