

Прогнозирование ухудшения эксплуатационного состояния дорожных одежд с использованием алгоритмов искусственного интеллекта

М.М.М. Елшамы^{1,2}, А.Н. Тиратурян¹, Е.В. Углова¹

¹Донской государственной технической университет, Ростов-на-Дону

²Аль-Азхар университет, Арабская Республика Египет / Египет

Аннотация: Задача поддержания действующей транспортной сети в удовлетворительном состоянии является одной из важнейших функций, к которой стремятся все дорожные органы. Для достижения этой цели требуется наличие данных многих параметров, связанных с текущим состоянием дорожной одежды, классом дороги, погодными условиями, объём движения и т. д. В последнее время наблюдается высокая тенденция использования подхода искусственного интеллекта для решения таких сложных задач, поскольку они связаны с разными параметрами. В этой работе исследуется возможность использования искусственных нейронных сетей (ИНС) для оценки текущих характеристик дорожного одежда и их потенциального применения при разработке стратегий обслуживания дорог. Результаты моделей показали сходимость между предполагаемыми значениями состояния дорожных одежд и фактическими значениями на всех этапах обучения. Результаты показывают, что органы дорожного хозяйства общего пользования могут использовать разработанные модели для определения оптимального подхода к содержанию дорог и определения наиболее эффективных мероприятий по восстановлению их пропускной способности и эксплуатационного состояния.

Ключевые слова: искусственные нейронные сети, алгоритм обратного распространения, дефлектометр падающего веса, дорожной одежд технического обслуживания, система управления состоянием дорожной одежды.

Введение

Дорожная инфраструктура является одним из жизненно важных ресурсов для любого сообщества, поэтому необходимо подумать о способах поддержания ее эффективности. Однако со временем состояние дорог ухудшается в результате воздействия различных механизмов износа [1]. В результате крайне важно стратегически управлять этими ресурсами, чтобы максимально увеличить срок их службы и технические показатели при одновременном снижении затрат на техническое обслуживание [2].

Важность работ по планированию технического обслуживания заключается в выборе подходящего времени и метода для снижения скорости износа участков дорожного одежда в соответствии с имеющимся бюджетом. Для достижения этой цели необходимо разработать модели, которые помогут

улучшить процесс разработки и учитывают факторы, влияющие на выбор решения о техническом обслуживании [3,4].

Многокритериальные модели обычно используются в сложных ситуациях принятия решений, например, связанных с обслуживанием дорожной инфраструктуры в масштабах всей сети [5]. Многокритериальные модели возникают как научный подход к оценке множества альтернативных вмешательств в рамках реабилитации дороги с учетом свойств участков дорожного одежда [6].

За последние два десятилетия стало ясно, что традиционных знаний о содержании дорог недостаточно, и существует настоятельная необходимость в разработке новых методов, которые помогают собирать и обрабатывать данные для использования в управлении дорожным одеждам [7]. Из-за быстрого развития в области информационных технологий и сетей искусственного интеллекта было предоставлено много возможностей для решения слишком многих проблем в различных областях, включая дорожное строительство.

Модели искусственных нейронных сетей (ИНС) — это приложение в области искусственного интеллекта, используемое для решения нелинейных геометрических моделей, таких, как прогнозирование, распознавание и оценка различных закономерностей [8,9].

Цель работы – совершенствование механизмов управления жизненным циклом автомобильных дорог путем разработки комплексного метода прогнозирования состояния дорожных одежд, основанного на использовании моделей искусственных нейронных сетей и позволяющего оценивать фактическое состояние конструктивных и эксплуатационных элементов дорожной одежды, а также планирование сроков и видов мероприятий по текущему и капитальному ремонту.

2. Подготовка базы данных

Данные, полученные для построения модели ИНС, были собраны в ходе исследования, проведенного Российской дорожной корпорацией по развитию автомагистрали М4 между Москвой и Краснодаром. Доступные данные включают дату осмотра, температуру воздуха, толщину слоя асфальта, толщину базового слоя, объем трафика, а также значения осадков и значения прогиба, основанные на испытаниях дефлектометра падающего веса.

База данных использовалась для расчета трех критериев, выражающих состояние асфальтового покрытия, которые представляют собой вероятность успеха участков дорожной одежды в отношении следующих трех дефектов: усталости, неровности и колености [10], а также модуля упругости слоев дорожной одежды (слой асфальта, базовый слой и слой земляного полотна), которые были определены с использованием пакета программного обеспечения PRIMAX в качестве входных данных и в отношении расчета входного параметра “срок службы поверхности дорожной одежды”, он был определен путем учета разницы между датой обследования отклонения и датой строительства или последней датой восстановления. Кроме того, исходное состояние дорожной одежды использовалось в качестве выходных данных для обучения моделей (ИНС) для прогнозирования значений индекса состояния дорожной одежды (PCI – pavement condition index).

2.1 Исходная база данных для нейронных сетей

База данных для входа в нейронную сеть состоит из набора входных данных и набора выходных данных. Входными данными являются измеренные значения следующих параметров: долговечность покрытия, толщина слоя асфальта, толщина основного слоя, p (усталость), r (шероховатость), r (колейность), модуль упругости (поверхностный слой, базовый слой, и слой земляного полотна), показанные, как их среднее

значение для отдельного сегмента дорожной одежды. Выходные данные модели представляют собой значения индекса состояния дорожных одежд для участков дорожной одежды, доступных в базе данных. Целью этой базы данных является подготовка и сортировка данных в формате, подходящем для ввода их в нейронную сеть.

2.2 Применение искусственных нейронных сетей

Для целей данной работы используются искусственные нейронные сети с алгоритмами обратного распространения, в которых разное количество нейронов (8, 9, 10, 11, 12, 13 и 14) в двух скрытых слоях были применены с помощью программного обеспечения MATLAB. Общее количество инспекционных данных, использованных при построении модели ИНС, составило 1614, представляющих 51 различных сектор вдоль автомагистрали М4. Данные, использованные в процессе обучения, включали минимальные и максимальные значения переменных для повышения эффективности моделей.

База данных была случайным образом разделена на три группы: 70 % данных нейронная сеть использует для процесса обучения, 15 % базы представляет собой процесс валидации, а оставшиеся 15 % — для тестирования разработанной сети. На (рис.1) показана конфигурация для одной из созданных нейронных сетей для обучения.

Каждый из входных параметров представлен одним из девяти нейронов во входном слое. Одиннадцать нейронов нанесены в скрытые слои, разделенные на семь нейронов в первом скрытом слое и четыре нейрона во втором слое. Выходной слой включает в себя один нейрон, который представляет количество выходных данных. Из рисунка 1 видно направление передачи данных от входного слоя к выходному слою через два скрытых слоя и наоборот, для исправления частоты ошибок в значениях выходных данных до достижения допустимого предела.

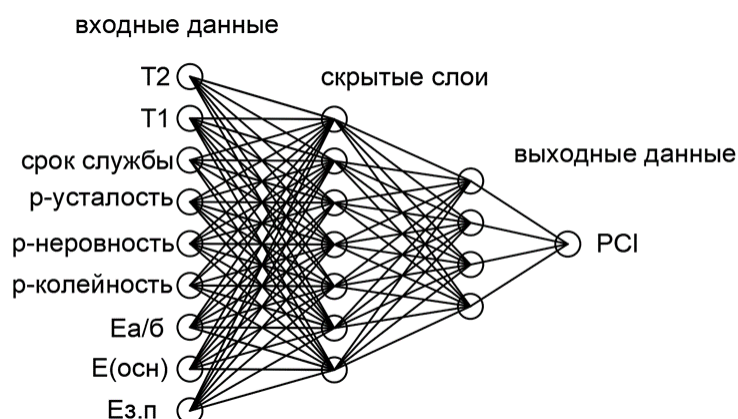


Рис. 1. – Структура применяемой искусственной нейронной модели

Для повышения производительности разработанной сети было применено несколько слоев и разное количество нейронов внутри скрытых слоев. Процедура обучения повторяется несколько раз, пока не будет найдена оптимальная модель, которая точно выражает взаимосвязь между входными и выходными данными. Эффективность обученных моделей сравнивается с использованием статистического анализа выходных данных, которые представлены средней абсолютной ошибкой (MAE – Mean Absolute Error) и коэффициентом множественных корреляций (R^2 – coefficient of multiple correlation) и среднеквадратичной ошибкой (RMSE – Root Mean Square Error).

3. Результаты обучения моделей

После этапа обучения нейронные сети были подвергнуты тестированию. В процессе тестирования вес был зафиксирован на значениях, принятых в конце процесса обучения. В сети была предложена новая группа входных и выходных данных. Результаты сетевого вывода сравнивались с требуемым выходом и статистически анализировались.

На следующем графике регрессии и производительности иллюстрируют результаты сетевой модели, касающиеся обучения, проверки и наборов тестов. Наилучшая производительность проверки продемонстрированной модели составила 0,0344, что было достигнуто после

22 повторений для модели со структурой (9-9-1), как показано на (рис.2). Низкое значение MSE указывает на то, что состояние дорожной одежды дорог в том же пределах может быть предсказано более точно.




Рис. 2. – Графики регрессии и производительности для лучшей модели

Затем был назначен новый набор данных из 37 разделов, присвоенный асфальтовому покрытию, чтобы оценить способность разработанных нейронных сетей, использованных в предыдущем разделе, прогнозировать выходные значения. На этом этапе для моделей определяются входные данные только для указанных значений параметров, а именно: (возраст поверхности, толщина слоя асфальта, толщина базового слоя, p (усталость), p (шероховатость), p (колеиность), E (асфальт), E (основание) и E (земляное полотно). В результате созданные сети смогли предвидеть выходные данные (индекс состояния дорожной одежды - PCI) на основе раннего опыта.

В таблице 1 приведены значения статистических параметров ожидаемых результатов для каждой модели расчета PCI.

Таблица № 1

Статистическая оценка результатов созданных моделей

№ п/п	Статистические параметры	Индекс состояния дорожной одежды - PCI						
		8n	9n	10n	11n	12n	13n	14n
1	MAE	0.141	0.124	0.118	0.131	0.136	0.159	0.119
2	R^2	0.920	0.949	0.945	0.936	0.934	0.868	0.948
3	RMSE	0.205	0.165	0.171	0.184	0.186	0.276	0.167

Мы обнаружили, что модели имеют приемлемую способность прогнозировать состояние дорожной одежды на основе переменных, которые использовались для обучения моделей.

Оценка износа дорожной одежды

Чтобы оценить возможность разработанных нейросетевых моделей помочь в прогнозировании скорости ухудшения состояния дорожной одежды, было выбрано несколько участков эксплуатируемых дорог и определено влияние изменения срока службы на состояние каждого сектора. Для достижения этой цели каждая модель определила входные значения для каждого сектора и зафиксировала их, за исключением одной переменной, которая является сроком службы. Затем мы оставили моделям возможность рассчитать выходные значения на основе их предыдущего опыта. Из секторов, которые были подвергнуты этому эксперименту, были номера 504 и 1227, как показано на (рис.3).




Рис. 3. – Ухудшение состояния дорожной одежды на этапе эксплуатации

Из предыдущих рисунков видно, что разработанные модели обладают способностью прогнозировать состояние асфальта в результате изменения срока службы, где значение PCI уменьшается по мере увеличения срока службы, что соответствует тому, что происходит в полевых условиях.

Заключение

Результаты используемых моделей ИНС, включающих разное количество нейронов в скрытых слоях, показали высокую точность и скорость расчета состояния дорожной одежды, о чем свидетельствуют небольшие различия между расчетными и фактическими значениями, а также высокое значение коэффициента детерминации (R^2) для всех разработанных моделей, в дополнение к возможности использования моделей для прогнозирования скорости ухудшения в течение срока службы.

Благодарность

Исследователь Елиами Мохамед Мостафа финансируется за счет стипендии в рамках исполнительской программы между Арабской Республикой Египет и Российской Федерацией; я выражаю им свою благодарность и признательность.

Исследования проводятся в рамках гранта Президента Российской Федерации для государственной поддержки молодых российских ученых - кандидатов наук (соглашение 075-15-2022-584).

Литература

1. Uddin W., Hudson W. R., Haas R. Public infrastructure asset management, McGraw-Hill Education, 2013. 544 p.
2. Zhao J., Fu X., Zhang Y. Research on risk assessment and safety management of highway maintenance project // Procedia engineering. 2016. (137). p. 434–441.
3. Ameri M., Jarrahi A. An executive model for network-level pavement maintenance and rehabilitation planning based on linear integer programming // Journal of Industrial & Management Optimization. 2020. № 2 (16). pp. 795–811.

4. Углова Е.В., Васильев Д.С. Разработка эффективных решений ремонта дорожной одежды на городских магистралях // Инженерный вестник Дона, 2015, №2, ч.2 URL: ivdon.ru/ru/magazine/archive/n2p2y2015/3072

5. Karleuša B., Dragičević N., Deluka-Tibljaš A. Review of multicriteria-analysis methods application in decision making about transport infrastructure // Journal of the croatian Association of civil engineering. 2013. pp. 619-631.

6. Dabous S. A., Zeiada W., Zayed T., Al-Ruzouq R. Sustainability-informed multi-criteria decision support framework for ranking and prioritization of pavement sections // Journal of Cleaner Production. 2020. (244) URL: doi.org/10.1016/j.jclepro.2019.118755.

7. Sundin S., Braban-Ledoux C. Artificial intelligence-based decision support technologies in pavement management // Computer-Aided Civil and Infrastructure Engineering. 2001. № 2 (16). pp. 143–157.

8. Bosurgi G., Trifirò F. A model based on artificial neural networks and genetic algorithms for pavement maintenance management // International Journal of Pavement Engineering. 2005. № 3 (6). pp. 201–209.

9. Елшами М. М. М., Тиратурян А. Н., Канищев А. Н. Использование искусственных нейронных сетей для определения модулей упругости конструктивных слоев нежестких дорожных одежд по натурным данным // Научный журнал строительства и архитектуры. – 2020. – № 2 (58). – С. 111–120.

10. Тиратурян А.Н., Симакова А.А., Бодров И.В., Фарниева М.В. Оценка надежности дорожной одежды на стадии эксплуатации // Инженерный вестник Дона, 2017, №4 URL: ivdon.ru/ru/magazine/archive/n4y2017/4509

References

1. Uddin W., Hudson W. R., Haas R. Public infrastructure asset management, McGraw-Hill Education, 2013. 544 p.



2. Zhao J., Fu X., Zhang Y. Procedia engineering. 2016. (137). pp. 434–441.
3. Ameri M., Jarrahi A. Journal of Industrial & Management Optimization. 2020. № 2 (16). pp. 795–811
4. Uglova E.V., Vasil'ev D.S. Inzhenernyj vestnik Dona, 2015, №2, part 2. URL: ivdon.ru/ru/magazine/archive/n2p2y2015/3072
5. Karleuša B., Dragičević N., Deluka-Tibljaš A. Journal of the croatian Association of civil engineering. 2013. pp. 619-631.
6. Dabous S. A., Zeiada W., Zayed T., Al-Ruzouq R. Journal of Cleaner Production. 2020. (244). URL: doi.org/10.1016/j.jclepro.2019.118755.
7. Sundin S., Braban- Ledoux C. Computer- Aided Civil and Infrastructure Engineering. 2001. № 2 (16). pp. 143–157.
8. Bosurgi G., Trifirò F. International Journal of Pavement Engineering. 2005. № 3 (6). pp. 201–209.
9. Elshamy M. M. M., Tiraturian A. N., Kanishchev A. N. Scientific journal of construction and architecture. 2020. № 2 (58). pp. 111–120.
10. Tiraturian A.N., Simakova A.A., Bodrov I.V., Farnieva M.V. Inzhenernyj vestnik Dona, 2017, №4. URL: ivdon.ru/ru/magazine/archive/n4y2017/4509