

Сравнительный анализ использования нейронной сети в задаче идентификационных свойств материалов

Н.Е. Бабушкина, А.А. Ляпин

Донской государственной технической университет, Ростов-на-Дону

Аннотация: Статья посвящена вопросу использования средств искусственного интеллекта для решения технических задач в строительной отрасли. Отмечается, что применение нейронных сетей позволит учесть особенности поведения материалов при определении их прочностных свойств инструментальными методами неразрушающего контроля в различных условиях проведения эксперимента. Авторами представлен сравнительный анализ подходов к обучению нейронной сети, в частности, рассмотрены структуры многослойных и LSTM сетей. Установлено, что LSTM сети более эффективны в решении задач идентификационных свойств материалов.

Ключевые слова: нейронная сеть, неразрушающий контроль, задача идентификации, многослойная сеть, LSTM сеть, ударное вдавливание, индентирование, прочностные свойства материалов, нейросетевые технологии, статистическое распределение.

Одной из важных задач исследований последних лет является задача оценки технического состояния строительных конструкций. Особое внимание уделяется определению механических и прочностных свойств материалов этих конструкций в условиях воздействий эксплуатационных статических и динамических нагрузок [1]. Зная механические свойства, возможно определить степень сопротивления материала разрушению. К таким механическим свойствам относят твердость, пластичность, упругость, ударную вязкость и др. [2] Источниками получения указанных свойств является проведение эксперимента в лабораторных условиях. С помощью методов контроля осуществляется техническая экспертиза исследуемого объекта. Эти методы разделяют на 2 вида: разрушающие и неразрушающие.

Методы разрушающего контроля применяются только к контрольным образцам и способны выявить общие механические свойства объекта. Метод является достаточно дорогостоящим, а из-за проведения только выборочных испытаний - обладает низкой достоверностью. При этом, разрушающий контроль позволяет получить точные показатели прочности, жесткости,

плотности конструкции. Применение данного метода в реальных условиях эксплуатации объекта требует существенных материальных и трудовых затрат [3].

Неразрушающие методы предполагают определение прочностных характеристик конструкций обследуемого здания без их непосредственного разрушения, при этом получаемые результаты достаточно достоверны. Данный метод контроля дает возможность проводить обследование ответственных конструкций зданий, для которых отбор отдельных образцов не представляется возможным. Таким образом, в ходе исследования образцов двумя методами выявляются основные свойства и характеристики материалов, после чего производится статистическая обработка полученного результата.

В настоящее время перспективным способом обработки информации выступает искусственный интеллект [4,5]. Как показал анализ литературных источников, нейронные сети набирают большую популярность среди исследователей, особенно для решения ряда технических задач. Это обусловлено тем, что в процессе обучения нейронная сеть способна выявлять сложные зависимости между входными и выходными параметрами, а также выполнять обобщение [6, 7].

Следует особенно отметить активное применение нейросетевых технологий в области строительной механики. По мнению коллектива авторов [8], нейронные сети обладают широкими возможностями для решения задач проектирования, оптимизации и диагностики строительных конструкций.

Исследователь Аверин П.И. приводит попытки определения признаков разрушения металлов с помощью нейронных вычислений на основе данных акустической эмиссии [9].

В своей работе Порошин И.Е. подчеркивает, что искусственные нейронные сети могут эффективно применяться в задачах параметрической идентификации объектов, в том числе технологических объектов [10]. Зачастую, для решения таких задач, применяют рекуррентные сети (RNN), что обусловлено их способностью аппроксимировать любую непрерывную функцию с некоторой наперед заданной точностью. Рекуррентная нейронная сеть представляет собой искусственную сеть, специализирующуюся на обработке последовательностей. RNN – это попытка реализации краткосрочной памяти в нейронных сетях, когда на вход нейрона вместе с информацией о текущем состоянии системы подается и предыдущее состояние этого же нейрона.

Но, как отмечено в ряде работ [11-13], такой подход к реализации нейронной сети не слишком эффективен на длительном отрезке времени, что ведет к затуханию сигнала при увеличении его цикличности. Для решения этой проблемы был предложен алгоритм долгой краткосрочной памяти LSTM (Long short-term memory). В настоящее время данный алгоритм признается учеными как наиболее эффективный инструмент для решения задач классификации и прогнозирования временных рядов.

Целью исследования является сравнительный анализ двух подходов реализации нейронной сети к задаче идентификации материалов по параметру твердости (НВ): стандартной многослойной сети прямого распространения и LSTM архитектуры нейронной сети. Топологии разработанных нейронных сетей представлены на рис.1.

Исходные данные для исследования получены в ходе ударного индентирования поверхности нескольких образцов металла.

В качестве установки выбрано оборудование с конусоидальным индентором, описанное в работе [14]. Результатом проведения эксперимента и обработки экспериментальных данных является временная характеристика

скорости внедрения индентора в исследуемую поверхность образца или конструкции в реальных условиях ее эксплуатации $v(t)$.

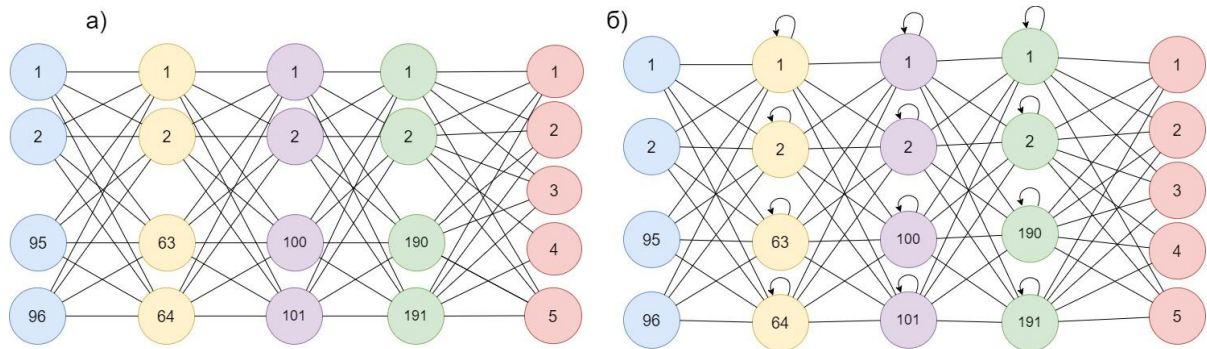


Рис.1. – Топологии нейронных сетей
а) 1 подход б) 2 подход

При обработке данных, полученных с частотой 100 кГц, фиксируются величины $v(t_k)$, $k = 1, \dots, 96$ с применением операций фильтрации, осреднения, смещения и временного интегрирования.

Для использования в качестве входов нейронной сети результаты эксперимента нормируются с изменением в диапазоне от 0 до 1.

Выборка данных состоит из 42 измерений, из них 32 измерения составляют обучающее множество, оставшиеся 10 - тестовое. Тестовое и обучающее множества сформированы из случайно отобранных измерений. Размерность одного измерения состоит из 96 характеристик. На рис. 2 представлены измерения, используемые в качестве обучающего множества нейронной сети. Выборка распределена на 5 групп твердости по Бринеллю: 1 группа - 88-125 НВ, 2 группа - 172-191 НВ, 3 группа - 198-217 НВ, 4 группа - 271-284 НВ, 5 группа - 321-425 НВ. Размер пакета обучения сети равен 4, количество эпох обучения - 180. Количество слоев в двух рассматриваемых подходах одинаково и равно трем. Расположение нейронов в каждом слое показано на рис.1.

В качестве функции активации в скрытых слоях многослойной сети применяется функция ReLU. Для представления категориального распределения по выделенным классам в выходном слое сети использована функция softmax.




Рис.2. - Обучающее множество нейронной сети

Результаты проведенных исследований представлены на рис.3-4.

На рис.3 отражено графическое представление результата, полученного нейронной сетью с простой многослойной структурой, которое позволяет зрительно оценить распределение статистических данных. Из полученных результатов видно, что нейронная сеть относит образцы достаточно точно по выделенным группам твердости. Однако, можно заметить, что сеть не достигла полного обучения. Некоторые значения тестового множества сеть идентифицирует недостаточно точно, распределяя их в разные группы.

Анализируя результат LSTM сети, представленный на рис.4, можно утверждать обратное. Нейронная сеть точно определяет принадлежность

тестового значения к выделенной группе. Точность классификации при 180 эпохах обучения достигает практически 100%.



Рис.3. - Результат работы многослойной сети




Рис.4. - Результат работы LSTM сети

Из полученных результатов видно, что при использовании LSTM сети уменьшается разброс образцов по группам. Наблюдается высокая степень точности.

Авторами были опробованы различные вариации количества слоев LSTM сети. По результатам эксперимента, можно утверждать, что для

данных исследования достаточно 1 слоя LSTM. Данная сеть достаточно точно идентифицирует проверочные значения к выделенным группам твердости.

Подводя итоги анализа, следует отметить что в процессе исследования авторы столкнулись с эргодическими процессами с произвольной вероятностной структурой. В ряде измерений, принадлежащих 2 и 3 группам двух подходов, нейронная сеть выдавала неоднозначный результат. В некоторых случаях система вела себя хаотически.

Проведенные исследования позволяют сделать вывод, что LSTM сеть показывает более высокую точность на тестовом множестве по сравнению с многослойной сетью. В данном случае можно говорить о том, что сеть приобрела обобщающую способность. Предлагается развивать предлагаемый подход в направлении накопления данных эксперимента и улучшения точности предсказания прочностных свойства материалов путем увеличения объема обучающей выборки в различных условиях проведения эксперимента.

Литература

1. Мандрица Д.П. Оценка свойств материалов инженерных конструкций специальных сооружений // Труды Военно-космической академии имени А.Ф. Можайского, 2017. № 656. С. 166-169.
2. Малеткина Т.Ю. Механические свойства металлов и сплавов и методы их определения: методические указания. Томск: Издательство Томского государственного университета, 2015. 27 с.
3. Новоселова И.В., Нестеров Н.А., Корниенко Э.Г., Хамраш Ф.Л. Неразрушающий и разрушающий методы контроля в судебной строительной технической экспертизе // Наука и образование в современном мире: методология, теория и практика: материалы II Международной научно-практической конференции, Чебоксары, 30 марта 2020 года, Чебоксары:

Негосударственное образовательное частное учреждение дополнительного профессионального образования «Экспертно-методический центр», 2020. С. 16-19.

4. Алферьев Д.А. Использование искусственных нейронных сетей в современном обществе // Социальное пространство, 2020. Т. 6. № 3. С. 6. DOI 10.15838/sa.2020.3.25.6.

5. Цаунит А.Н., Гладков Е.А., Логинова А.В. Использование нейронных сетей в различных сферах человеческой деятельности // Наукосфера, 2021. № 7-1. С. 214-218.

6. Рудаков А.С. Подходы к решению задачи прогнозирования временных рядов с помощью нейронных сетей // Бизнес-информатика, 2008. № 4(6). С. 29-34.

7. Лабинский А.Ю., Уткин О.В. К вопросу аппроксимации функции нейронной сетью // Природные и техногенные риски (физико-математические и прикладные аспекты), 2016. № 1(17). С. 5-10.

8. Абовский Н.П., Белобородова Т.В., Максимова О.М., Смолянинова Л.Г. Нейросетевые модели в задачах строительной механики // Известия вузов. Строительство, 2000. № 7. С. 6–14.

9. Аверин П.И. Вариант решения задачи вычисления признаков разрушения металлов с помощью нейронных сетей на основе данных кластерного анализа импульсов акустической эмиссии // Информационные системы и технологии: управление и безопасность, 2012. № 1. С. 39-42.

10. Порошин И.Е., Титов М.А. Использование искусственных нейронных сетей для параметрической идентификации объектов // Молодой ученый, 2020. № 26 (316). С. 39-42.

11. Батурина Н.Ю. Нейросетевые модели в задачах исследования строительных конструкций // Инженерный вестник Дона, 2013, № 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2085.

12. Babushkina N., Lyapin A., Kovaleva A. Analysis of neural network results based on experimental data during indentation // E3S Web of Conferences, Moscow, 2020. – P. 01018. – DOI 10.1051/e3sconf/202022401018.

13. Beskopylny A., Lyapin A., Beskopylny N., Kadomtseva E. Comparison of the efficiency of neural network algorithms in recognition and classification problems // E3S Web of Conferences, Moscow, 2020. – P. 01025. – DOI 10.1051/e3sconf/202022401025.

14. Бескопыйный А.Н., Веремеенко А.А., Копылов Ф.С., Крымский В.С. Задача о статическом внедрении конического индентора в область с поверхностным упрочнением // Инженерный вестник Дона, 2018, № 4. URL: ivdon.ru/ru/magazine/archive/N2y2018/4720.

References

1. Mandrica D.P. Trudy Voenno-kosmicheskoy akademii imeni A.F. Mozhajskogo, 2017. № 656. pp. 166-169.

2. Maletkina T.Ju. Metodicheskie ukazaniya [Mechanical properties of metals and alloys and methods of their determination: guidelines]. Tomsk: Izdatel'stvo Tomskogo gosudarstvennogo universiteta, 2015. 27 p.

3. Novoselova I.V., Nesterov N.A., Kornienko Je.G., Hamrash F.L. Nauka i obrazovanie v sovremennom mire: metodologija, teorija i praktika: materialy II Mezhdunarodnoj nauchno-prakticheskoy konferencii, Cheboksary, 30 marta 2020 goda, Cheboksary: Negosudarstvennoe obrazovatel'noe chastnoe uchrezhdenie dopolnitel'nogo professional'nogo obrazovaniya «Jekspertno-metodicheskij centr», 2020. pp. 16-19.

4. Alfer'ev D.A. Social'noe prostranstvo, 2020. Т. 6. № 3. P. 6. DOI 10.15838/sa.2020.3.25.6.

5. Caunit A.N., Gladkov E.A., Loginova A.V. Naukosfera, 2021. № 7-1. pp. 214-218.

6. Rudakov A.S. Biznes-informatika, 2008. № 4(6). pp. 29-34.



7. Labinskij A.Ju., Utkin O.V. Prirodnye i tehnogennye riski (fiziko-matematicheskie i prikladnye aspekty), 2016. № 1(17). pp. 5-10.
8. Abovskij N.P., Beloborodova T.V., Maksimova O.M., Smoljaninova L.G. Izvestija vuzov. Stroitel'stvo, 2000. № 7. pp. 6–14.
9. Averin P.I. Informacionnye sistemy i tehnologii: upravlenie i bezopasnost', 2012. № 1. pp. 39-42.
10. Poroshin I.E., Titov M.A. Molodoj uchenyj, 2020. № 26 (316). pp. 39-42.
11. Baturina N.Ju. Inzhenernyj vestnik Dona. 2013. № 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2085.
12. Babushkina N., Lyapin A., Kovaleva A. E3S Web of Conferences, Moskva, 2020. P. 01018. DOI 10.1051/e3sconf/202022401018.
13. Beskopylny A., Lyapin A., Beskopylny N., Kadomtseva E. E3S Web of Conferences, Moskva, 2020. P. 01025. DOI 10.1051/e3sconf/202022401025.
14. Beskopylnyj A.N., Veremeenko A.A., Kopylov F.S., Krymskij V.S. Inzhenernyj vestnik Dona. 2018. № 4. URL: ivdon.ru/ru/magazine/archive/N2y2018/4720.