

Вибродиагностика стержневых конструкций с применением нейросетевых методов машинного обучения

М.И. Кадомцев, И.Ф. Развеева

Донской государственной технической университет

Аннотация: В настоящей статье изучается использования методов машинного обучения в вибродиагностике. Для оценки эффективности применения нейронной сети выдвинута гипотеза о возможности выявления скрытых закономерностей, свидетельствующих о наличии дефекта, для конструкций одного типа, обладающих различными параметрами. Выделение этих признаков путем визуального анализа графиков затруднительно в силу большого объема данных, что указывает на актуальность решения задачи классификации с помощью нейросети. В результате исследования получена полносвязная двухслойная нейронная сеть, показывающая достаточную точность предсказаний, что подтверждает принципиальную возможность применения методов машинного обучения для мониторинга состояния типовых конструкций.

Ключевые слова: вибродиагностика, строительная конструкция, здание, сооружение, дефект, повреждение, машинное обучение, нейронная сеть.

В последние годы существенно возросло количество уникальных и высотных зданий и сооружений, для которых крайне актуально применение мониторинга состояния строительных конструкций. Одними из основных параметров, в соответствии с ГОСТ 31937-2011, являются основные тоны и декременты затухания ускорений колебаний (ГОСТ 31937-2011. Здания и сооружения. Правила обследования и мониторинга технического состояния). Однако ГОСТ 31937-2011 не дает оценку состояния конструкции в зависимости от изменения параметров. Поэтому представляется актуальной разработка методов, позволяющих по записи ускорений колебаний оценить степень повреждения сооружения и локализацию дефекта [1,2]. В настоящий момент существуют неразрушающие методы, не связанные с применением машинного обучения, например, методы семейства Modal Assurance Criteria [3,4,5]. Однако применение этих методов требует использования эталонной конструкции (натурной или математической модели). В этом случае для каждой исследуемой конструкции мы должны найти в точности такую же неповрежденную, либо разработать математическую модель конструкции. С

учетом разнообразия существующих зданий и сооружений, это может оказаться весьма трудозатратно [6].

В основе настоящего исследования лежит гипотеза о том, что для различных конструкций одного типа можно выделить характерные признаки, свидетельствующие о типовых повреждениях. Однако выделение этих признаков путем визуального анализа графиков в силу большого объема информации представляется затруднительным. Аппарат нейронных сетей в данном случае дает возможность выявить скрытые закономерности при наличии достаточного количества данных.

Применение нейронных сетей при вибродиагностике зданий и сооружений в последнее десятилетие широко рассматривается в научных публикациях. Из наиболее близких подходов можно выделить исследование состояния железнодорожных мостов при колебаниях, возбуждаемых проездом железнодорожного транспорта [7,8], исследование системы мониторинга зданий на основе нейронных сетей для модели многоэтажного здания [9]. Кроме того, интенсивно развиваются направления, использующие отличные от нейронных сетей методы машинного обучения для мониторинга состояния сооружений [10]. Однако в перечисленных работах практически не исследуется возможность использования тренировочного набора данных, полученного на различных конструкциях одного типа, при обучении нейронной сети.

В настоящей работе в качестве объекта исследования взята рама на жестком основании. Дефекты моделируются областями, имеющими меньший модуль упругости по сравнению с основной конструкцией. При составлении тренировочного набора варьируются размеры рамы, механические характеристики рамы, положение и размер дефекта. Дефект может быть расположен на правой или левой опорах, или перекладине. С точки зрения машинного обучения ставится задача классификации – нейронная сеть

должна определить наличие дефекта и его положение. Под положением дефекта мы в данном случае понимаем то, на какой из частей рамы он находится.

Рама моделируется в программном комплексе ANSYS 19 R3, используются балочные элементы BEAM3, количество степеней свободы – 120. Перемещение точек среды удовлетворяют уравнениям Ламе

$$\mu \nabla^2 u + (\lambda + \mu) \text{grad div } u = \rho \frac{\partial^2 u}{\partial t^2}$$

где ∇ - оператор Лапласа.

Расчет ведется с использованием гармонического анализа, результатом расчета являются спектры Фурье ускорений, взятые в трех точках по двум компонентам. На вход нейронной сети подаются амплитуды спектров Фурье, нормированные по максимуму каждой компоненты. Таким образом, определяющими параметрами, влияющими на классификацию, являются основные тоны колебаний и декременты затухания.

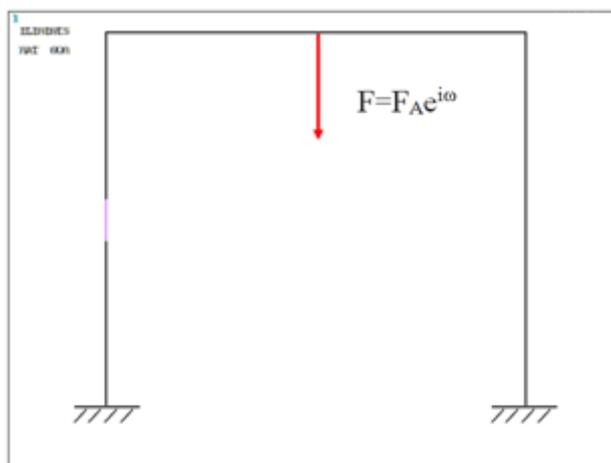


Рис. 1. – Моделирование рамы в расчетном комплексе ANSYS

Программирование нейронной сети осуществлялось на высокоуровневом языке Python, в качестве инструментов использовались комплексная платформа с открытым исходным кодом для машинного обучения TensorFlow и надстройка Keras.

Полученная нейронная сеть представляет собой полносвязную двухслойную сеть, выходной слой которой содержит 4 нейрона, что соответствует количеству возможных классов при решении задачи классификации (положений дефекта в данном случае). В качестве функции активации на входном слое используется функция Rectified Linear Unit (полулинейная функция), на выходном SoftMax (нормализованная экспоненциальная функция). При обучении модели в качестве оптимизатора был выбран стохастический градиентный спуск (SGD), выполняющий обновление параметров для каждого примера обучения, в качестве функции ошибки применена категориальная перекрестная энтропия. Согласно многочисленным исследованиям, подобная архитектура хорошо зарекомендовала себя для решения задач классификации.

В ходе исследования было оценено влияние размера мини-выборки на качество обучения сети, а также количество эпох. Оптимальными значениями для данной нейронной сети является выборка из 5 экземпляров при количестве эпох равном 1000.

Полученные в результате моделирования данные были разделены на обучающую и тестовую выборку в соотношении 80 на 20. Точность предсказания нейронной сети составила 76,47% (рис.2).

Точность: 76.4706	
Предсказания	Реальное положение дефекта
0 нет дефекта	нет дефекта
1 нет дефекта	нет дефекта
2 нет дефекта	нет дефекта
3 нет дефекта	нет дефекта
4 левая опора	левая опора
5 перекладина	левая опора
6 перекладина	левая опора
7 левая опора	левая опора
8 перекладина	перекладина
9 перекладина	перекладина
10 перекладина	перекладина
11 перекладина	перекладина
12 правая опора	правая опора
13 правая опора	правая опора
14 правая опора	правая опора
15 левая опора	правая опора
16 левая опора	правая опора

Рис. 2. – Точность предсказания нейронной сети

В результате проведенного исследования была подтверждена гипотеза о том, что для конструкций одного типа, обладающих разными параметрами, нейронная сеть позволяет выявить скрытые закономерности, свидетельствующие о типовых повреждениях при наличии достаточного количества данных. Решение модельной задачи показывает, что существует принципиальная возможность создания базы данных конечного числа обученных нейронных сетей для мониторинга состояния типовых конструкций. С учетом современных направлений исследований, результаты которых отражены в публикациях ведущих журналов, для улучшения быстродействия и точности предсказания можно применить сверточные нейронные сети, кроме того, для окончательного подтверждения гипотезы необходимо применить рассмотренный алгоритм для более сложных конструкций с использованием результатов натурного эксперимента.

Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 18-01-00715-А.

Литература

1. Кадомцев М.И., Ляпин А.А., Шатилов Ю.Ю. Вибродиагностика строительных конструкций // Инженерный вестник Дона, 2012, №3. URL: ivdon.ru/ru/magazine/archive/n3y2012/941.
2. Кадомцев М.И., Ляпин А.А., Шатилов Ю.Ю. Математическая реализация вибрационного метода идентификации повреждений в пролетных строительных конструкциях // Инженерный вестник Дона, 2012, №3. URL: ivdon.ru/ru/magazine/archive/n4y2013/2178.
3. Кадомцев М.И., Развеева И.Ф. Оптимизация параметров измерений при обследовании зданий и сооружений с помощью методов MAC // Вестник Евразийской науки, 2018 №2. URL: esj.today/PDF/50SAVN218.pdf



4. Allemang, R.J. 2002. The modal assurance criterion (MAC): twenty years of use and abuse. Proceedings of the 20th International Modal Analysis Conference, LosAngeles, Calif., pp. 397-405.
5. Khoshnoudian F, Esfandiari, Structural damage diagnosis using modal data. Sharif Univ Technol. 2011, p. 860.
6. Zhou Z. Vibration-based damage detection of bridge superstructures. VDM Verlag, 2008. 300 с.
7. Chalouhia Elisa Khouri, Gonzaleza Ignacio, Gentileb Carmelo, Karoumi Raid. Damage detection in railway bridges using Machine Learning: application to a historic structure. Procedia Engineering. Volume 199, 2017, pp 1931-1936.
8. Hea X., Kawatani M., Hayashikawa T., Furuta H., Matsumoto T. A Bridge Damage Detection Approach using Train-Bridge Interaction Analysis and GA Optimization. Procedia Engineering 14, 2011, pp 769–776.
9. Smarsly Kay, Dragos Kosmas, Wiggenbrock Jens. Machine learning techniques for structural health monitoring. 8th European Workshop On Structural Health Monitoring (EWSHM 2016), 5-8 July 2016, Spain, Bilbao.
10. Shanthi B, Mahalakshmi N, Shobana M. Structural Health Monitoring using Varied Machine Learning Algorithms. International Journal of Engineering & Technology, 7 (3.12), 2018, pp. 793 -796.

References

1. Kadomtsev M.I., Lyapin A.A., Shatilov Yu.Yu. Inzhenernyj vestnik Dona, 2012, №3. URL: ivdon.ru/ru/magazine/archive/n3y2012/941.
2. Kadomtsev M.I., Lyapin A.A., Shatilov Yu.Yu. Inzhenernyj vestnik Dona, 2012, №3. URL: ivdon.ru/ru/magazine/archive/n4y2013/2178.
3. Kadomtsev M.I., Razveeva I.F. Vestnik Evraziyskoy nauki, 2018 №2, URL: esj.today/PDF/50SAVN218.pdf
4. Allemang, R.J. 2002. Proceedings of the 20th International Modal Analysis Conference, LosAngeles, Calif., pp. 397-405



5. Khoshnoudian F, Esfandiari. Sharif Univ Technol. 2011, p. 860.
6. Zhou Z. Vibration-based damage detection of bridge superstructures. VDM Verlag, 2008. 300 p.
7. Chalouhia Elisa Khouri, Gonzaleza Ignacio, Gentileb Carmelo, Karoumi Raid. Procedia Engineering. Volume 199, 2017, pp. 1931-1936.
8. Hea X., Kawatani M., Hayashikawa T., Furuta H., Matsumoto T. Procedia Engineering 14, 2011, pp. 769–776.
9. Smarsly Kay, Dragos Kosmas, Wiggenbrock Jens. 8th European Workshop On Structural Health Monitoring (EWSHM 2016), 5-8 July 2016, Spain, Bilbao.
10. Shanthi B, Mahalakshmi N, Shobana M. International Journal of Engineering & Technology, 7 (3.12), 2018, pp. 793 -796.