

ПРИМЕНЕНИЕ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ В МОДЕЛИРОВАНИИ ПОВЕДЕНИЯ ЖЕЛЕЗОБЕТОННЫХ ПЛИТ ДОРОЖНЫХ ПОКРЫТИЙ

Введение

Железобетонные плиты дорожных покрытий на грунтовом основании обладают нелинейным поведением под нагрузкой со сложным напряженно-деформированным состоянием. Традиционно при проектировании железобетонных плит используют математические модели, метод конечных элементов (МКЭ) и экспериментальные испытания.

Математические модели сопротивления железобетонных плит не позволяют учесть большое количество переменных одновременно по причине сложности и трудоёмкости такого подхода [1].

Для решения сложных инженерных задач за последние два десятилетия многие исследователи предложили использовать методы мягких вычислений (*soft computing*) [2–4]. Наиболее популярными из них являются искусственные нейронные сети (*artificial neural networks*), методология поверхности отклика (*response surface methodology*), нечеткая логика (*fuzzy logic*), оптимизация роя частиц (*particle swarm optimization*) и генетические алгоритмы (*genetic algorithms*) [5].

Нейронные сети могут быть использованы в качестве альтернативы математическим моделям или экспериментальным испытаниям на начальной стадии проектирования для получения быстрого предсказания поведения железобетонных плит под нагрузкой, определения величины сопротивления и прогибов.

Постановка задачи и выбор вида нейронной сети

Конструкция железобетонного плитного фундамента на грунтовом основании состояла из двух железобетонных плит: нижней железобетонной плиты основания контейнерной площадки толщиной $h = 100$ мм, верхней железобетонной плиты покрытия толщиной $h = 250$ мм.

Для плиты основания в расчетах был принят бетон класса $C^{12}/_{15}$ согласно [6] с модулем упругости $E = 19000$ МПа, для плиты покрытия – бетон класса $C^{32}/_{40}$ согласно [6] с модулем упругости $E = 38000$ МПа. Коэффициент Пуассона для обеих плит был принят $\mu = 0,2$.

Взаимодействие верхней и нижней плит между собой моделировалось посредством упругих связей конечной жесткости.

Расчет плит на вертикальные нагрузки от колес перемещающегося по поверхности погрузочного транспортного средства (ричстакера) первоначально был выполнен в ПК ЛИРА-САПР.

Работу упругого основания учитывали при помощи встроенного в ПК ЛИРА-САПР алгоритма «Модель грунта», учитывающего упругую работу каждого слоя грунтового основания. Характеристики грунтов в слоях были приняты

на основании инженерно-геологических изысканий на территории контейнерной площадки в перевалочном парке станции Брест-Северный в г. Бресте.

Расчет выполняли на действие постоянной нагрузки от собственного веса плит основания и покрытия контейнерной площадки и кратковременной нагрузки на каждое переднее колесо от ричстакера FERRARI F500-RS2. Площадь приложения нагрузки от колес ричстакера, согласно его техническим характеристикам, была принята равной $A = 0,36 \text{ м}^2$. Величину нагрузки от колес ричстакера варьировали в пределах от 150 до 900 кН для формирования базы данных для обучения нейронной сети.

Так как распределение напряжений, деформаций или вертикальных перемещений по поверхности плиты имеет сходство с изображением, авторами работы было принято решение использовать для достижения поставленной цели сверточную нейронную сеть (CNN).

Архитектура и алгоритм работы нейронной сети

Для предсказания распределения напряжений на поверхности железобетонной плиты использовали сверточную нейронную сеть (CNN) с архитектурой U-Net, приведенную на рисунке 1. Она состоит из двух частей: encoder («сверточная») и decoder («разверточная»). Encoder преобразует входное изображение в многомерное представление признаков. Он выполняет функцию извлечения признаков. Decoder создает сегментированное изображение на основе признаков, полученных от сверточной части сети.

Использовали две модели. В модели 1 исходные данные подавались в виде четырех цифровых карт признаков размерностью 56×56 : карты признаков формы плиты; карты нагрузок; двух карт привязки расположения нагрузки от колёс ричстакера на поверхности плиты. В модели 2 исходные данные подавались в виде одной цифровой карты признаков размерностью 56×56 , в которой отображались координаты точек плиты с шагом 0,1 м и величина вертикальной сосредоточенной нагрузки на плиту в каждой координате.

На входе в нейронную сеть подавали изображение загруженной внешними силами плиты размерами $5,6 \times 5,6 \text{ м}$, которые были преобразованы в три карты признаков размерами 64×64 . Карту признаков формы плиты не учитывали так как форма плиты не менялась. Свертка представляет цифровой фильтр, в котором обучение осуществляли методом «скользящего окна» [7] посредством взвешенного суммирования значений в ячейках карты (нейронах) и весовых коэффициентов – коэффициентов ядра свертки.

Результат «скольжения» ядра, в нашем случае размерами 4×4 с шагом 2, по всему изображению записывается в новое изображение (новую карту признаков). На каждом слое блок кодирования сворачивает трехмерную матрицу, уменьшая количество точек дискретизации карты в два раза и увеличивая количество признаков (каналов). Для сохранения размеров выходных данных карты признаков и захвата крайних значений, в карте признаков добавляли строки и столбцы справа и слева, а также сверху и снизу, заполненные нулями (процедура *padding*). Схема применяемой модели CNN с архитектурой U-Net с одним пикселем в самом низком разрешении указана на рисунке 1.

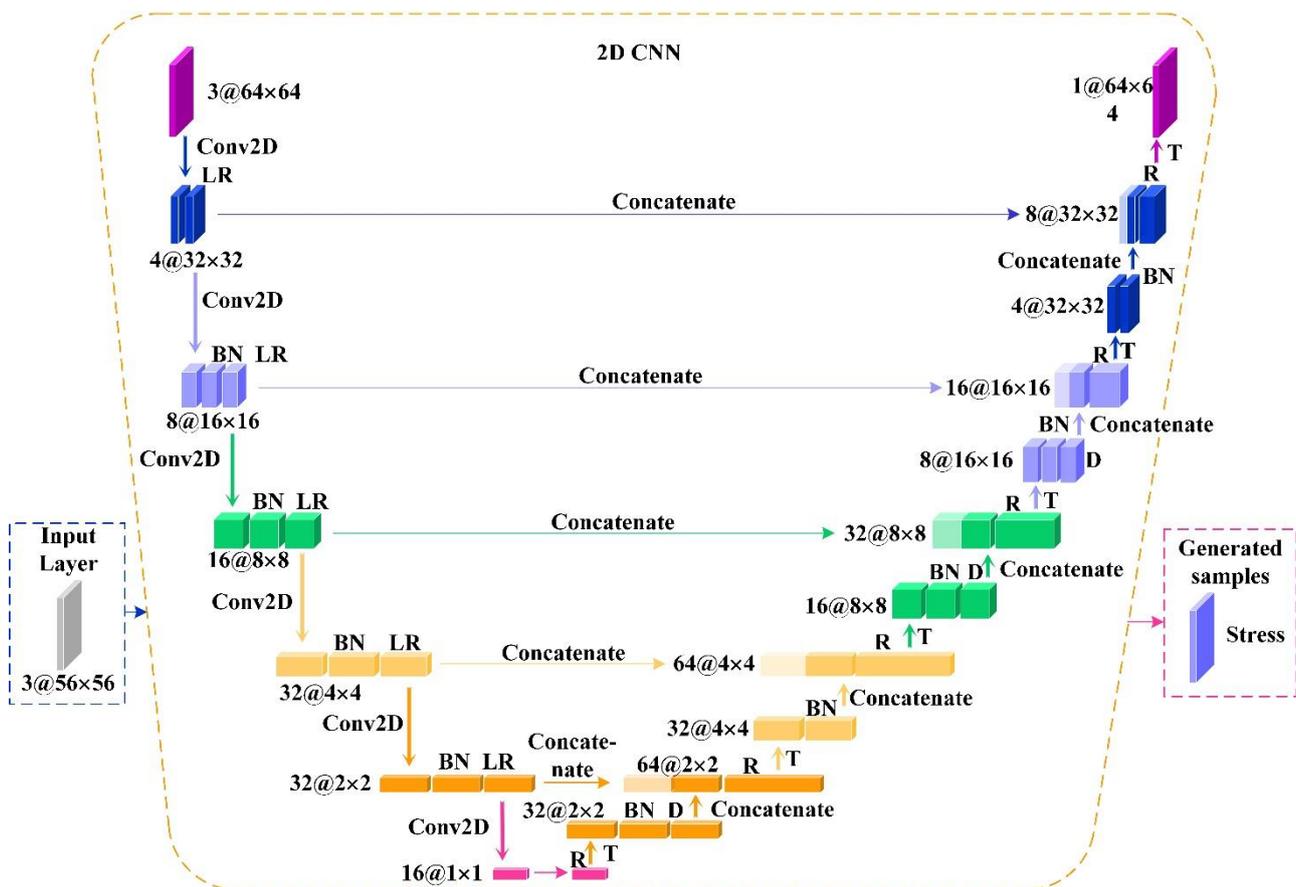


Рисунок 1 – Схема применяемой модели CNN с архитектурой U-Net с одним пикселем в самом низком разрешении

Каждый цветной параллелепипед соответствует многоканальной карте признаков. Количество каналов обозначено первой цифрой (перед @) в подписи параметров карты. Размеры карты указаны за знаком @ в подписи параметров карты. Прозрачные поля представляют собой скопированные карты признаков для операции объединения (concatenate). Буквами обозначены следующие параметры: Conv 2D – Convolution 2D – двумерная свертка; BN – Batch Normalization – пакетная нормализация данных; LR – Leaky ReLU – функция активации; R – ReLU – функция активации; T – Conv2DTranspose – 2D транспонированный сверточный слой; D – Dropout – метод регуляризации, предназначенный для уменьшения переобучения сети.

На каждом этапе свертки выполнялись пакетная нормализация полученных данных (англ. Batch Normalization – BN на рисунке 1), позволяющая повысить производительность и стабилизировать работу сети, и выпрямление линейным блоком активации Leaky ReLU (LR на рисунке 1). Алгоритм проведения Batch Normalization подробно изложен в [8].

Вторая часть сети – «decoder» (развертывание) – является зеркальным отражением первой. Размер изображения необходимо восстановить до исходного. С этой целью применяются слои повышающей дискретизации (upsampling) в комбинации со сверточными слоями. Каждый слой в развертывании представляет процесс обратный свертке карты признаков, сопровождающийся увеличением её размеров вдвое и уменьшением вдвое количества каналов признаков с последующей пакетной нормализацией (англ. Batch Normalization). Следующий

за пакетной нормализацией слой «dropout» «выключает» в случайном порядке (временно исключает из обучения) определенный процент нейронов в сети на каждом шаге обучения, что помогает предотвратить чрезмерную зависимость модели от конкретных путей и узлов в сети, ведущую к переобучению [9]. Полученную на данном слое карту признаков объединяют (англ. *concatenate*) с соответствующим образом обрезанной картой признаков из сверточного слоя и выполняют выпрямление линейным блоком активации ReLU.

Обучение нейронной сети

Следует отметить, что в настоящем исследовании количество обучаемых параметров, которое составило 98673 в МОДЕЛИ 1 и 98545 в МОДЕЛИ 2, превышает количество образов, на которых обучалась модель, что, по мнению многих исследователей, является недостатком модели.

Существует мнение, что объем обучающей выборки должен быть равен объему обучаемых параметров с целью предотвращения переобучения сети. Некоторые современных исследования отмечают, что деление изображений на локальные области (патчи – англ. *patch*) выполняет более точную сегментацию изображений и приводит к уменьшению обучающей выборки при сохранении предсказательной способности.

В данной работе авторы использовали для предсказания распределения напряжений на поверхности железобетонной плиты двухмерную сверточную нейронную сеть (CNN) с архитектурой U-Net используя при обучении метод стохастического градиентного спуска (SGD).

В обеих моделях было назначено 300 эпох обучения. Для обучения нейросети использовали 100 образцов с соотношением между обучающими и валидационными выборками составляющим 97 % к 3 %. Для проверки точности предсказания моделей использовали дополнительную тестовую выборку из 25 образцов, не использованных в обучении сети.

При тестировании нейронной сети использовалась средняя абсолютная ошибка с нормой L1 [10], так как эта метрика хорошо отражает точность результата предсказания.

Все этапы создания CNN, обучения и проверки были реализованы с помощью языка программирования Python и открытой программной библиотеки для машинного обучения, разработанная компанией Google для решения задач построения и тренировки нейронной сети Tensorflow [11].

Выводы

Нейронные сети могут быть использованы в качестве альтернативы математическим моделям или экспериментальным испытаниям на начальной стадии проектирования для получения быстрого предсказания поведения железобетонных плит под нагрузкой, определения величины сопротивления и прогибов.

Нейронные сети способны моделировать поведение систем при ограниченных затратах на проектирование и предоставлять быстрые и достаточно точные решения в сложных, неопределенных и индивидуальных ситуациях.

Так как распределение напряжений, деформаций или вертикальных перемещений по поверхности плиты имеет сходство с изображением, авторами работы было принято решение использовать для достижения поставленной цели сверточную нейронную сеть (CNN).

Список цитированных источников

1. Tully, S. H. A neural network approach for predicting the structural behavior of concrete slabs : a thesis submitted for the degree of master of engineering : 06.1997 / S. H. Tully. – New-foundlan, 1997. – 126 p.
2. Ahmad, A. Neural Network-Based Prediction: The Case of Reinforced Concrete Members under Simple and Complex Loading / A. Ahmad, N. D. Lagaros, D. M. Cotsovos // Appl. Sci. – 2021. – 11, 4975.
3. Bamiyo, S. Philip Prediction of Load deflection Behaviour of two way Rc Slab using Neural Network Approach / S. P. Bamiyo, O. A. Uche, M. Adamu // Int. J. Optim. Civil Eng. – 2017. – 7(4). – P. 633–644.
4. Lagaros, N. D. Learning improvement of neural networks used in structural optimization / N. D. Lagaros, M. Papadrakakis // Adv. Eng. Softw. – 2004. – 35. – P. 9–25.
5. Volna, E. Introduction to Soft Computing / E. Volna // 1st ed. ; Dept. of Computer Science University of Ostrava: Ostrava, Czechia. – 2013. – P. 137.
6. Бетонные и железобетонные конструкции = Бетонныя і жалезабетонныя канструкцыі : СП 5.03.01-2020. – Введ. 16.09.2020. – Минск : РУП «Стройтехнорм» : Мин. арх. и стр. Республики Беларусь, 2020. – 244 с.
7. Головки, В. А. Нейросетевые технологии обработки данных / В. А. Головки, В. В. Краснопрошин. – Минск : Бел. гос. ун-т, 2017. – 264 с.
8. Ioffe, S. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift / S. Ioffe, Ch. Szegedy // International Conference on Machine Learning, Lille, France, 2015. – JMLR: W&CP volume 37. – P. 9.
9. Dropout и Batch normalization. Блог компании М. Видео-Эльдорадо [Электронный ресурс]. – Режим доступа: <https://habr.com/ru/companies/mvideo/articles/782360/>. – Дата доступа: 22.05.2024.
10. Barrodale, I. L1 Approximation and the Analysis of Data. Applied Statistics. 17 (1). – 1968. – P. 51–57.
11. Python programming language and the Tensorflow framework [Electronic resource]. – Access mode: <https://www.tensorflow.org/about/bib>. – Date of access: 22.10.2023.

УДК 624.012.45:625:004.8

Михаевич В. В.

Научные руководители: к. т. н., доцент Молош В. В.;

к. т. н., доцент Желткович А. Е.

РАСЧЕТ НАПРЯЖЕНИЙ В ЖЕЛЕЗОБЕТОННЫХ ПЛИТАХ ДОРОЖНЫХ ПОКРЫТИЙ С ПРИМЕНЕНИЕМ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

Введение

В основу проектирования железобетонных плит фундаментов, перекрытий, дорожных покрытий положены расчетные модели, которые разработаны на относительно ограниченном количестве экспериментальных исследований, в большинстве случаев требующих достаточно больших материальных и временных затрат. Сложное напряженно-деформированное состояние в таких железобетонных плитах, в особенности подверженных циклическим динамическим нагрузкам, часто может приводить к образованию трещин и разрушению плит. В работе исследовалось поведение под нагрузкой жестких железобетонных