

### 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

плит контейнерной площадки от перемещающегося по поверхности ричстакера (транспортного средства для погрузки контейнеров). Сложность проектирования таких плит заключается в том, чтобы исходя из надёжности и долговечности, правильно подобрать конструкцию дорожного полотна: геометрические и конструктивные характеристики слоев и прочностные характеристики материалов. Применение метода конечных элементов в таких задачах является достаточно трудоемким, так как требует высокого уровня квалификации инженеров-проектировщиков и значительных временных и трудовых затрат, что делает проектирование рутинным и мало целесообразным. В данной работе исследован альтернативный подход, основанный на применении искусственной сверточной нейронной сети (CNN) с архитектурой U-Net, позволяющий получить достаточно точное предсказание напряжений в плите значительно быстрее и проще в сравнении с методом конечных элементов.

### ***Данные для обучения нейронной сети***

Набор данных, используемый в этом исследовании для обучения CNN, был получен посредством параметрического моделирования в ПК ЛИРА-САПР. Всего было выполнено 125 численных расчетов (образов) с заложенной изначально возможностью варьирования на разных уровнях трех параметров: 1) величины нагрузки от колес, передвигающегося по поверхности плиты покрытия контейнерной площадки ричстакера с контейнером; 2) расположения двух передних наиболее нагруженных колес на поверхности плиты; 3) форма плиты покрытия контейнерной площадки в плане. 125 численных расчетов были разделены на две группы: 100 расчетов были предназначены для обучения CNN с целью предсказания величины напряжений в плите, распределенных по ее поверхности; 25 расчетов были предназначены для оценки точности разработанной модели CNN.

Исходные данные, предназначенные для формирования карт признаков CNN, характеризующих распознаваемый образ, формировали двумя различными методами, что позволило рассмотреть две расчетных нейросетевых модели.

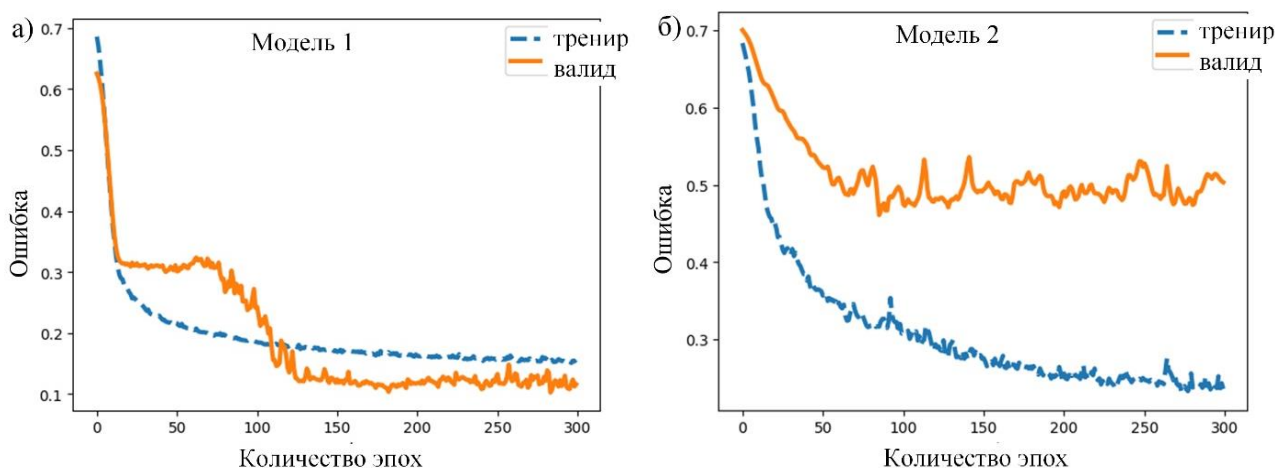
В модели 1 исходные данные подавались в виде четырех цифровых карт признаков размерностью  $56 \times 56$ : карты признаков формы плиты; карты нагрузок; двух карт привязки расположения нагрузки от колес ричстакера на поверхности плиты. В модели 2 исходные данные подавались в виде одной цифровой карты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

На выходе необходимо было получить напряжения в плите, распределенные по площади ее поверхности. Полученные для обучения CNN в ПК ЛИРА-САПР напряжения были сформированы в карту напряжений, в которой каждый элемент представлял напряжения в соответствующей точке железобетонной плиты.

### ***Результаты расчетов и их анализ***

В результате проведенного исследования установлено, что в модели 1 компоновка входных данных была выполнена лучше, чем в модели 2. Об этом свидетельствует скорость и качество обучения нейронной сети, а также численная статистическая оценка достоверности совпадения тренировочных,

полученных при расчете методом конечных элементов, и предсказанных нейросетью значений напряжений. Достаточно близкое совпадение ошибок тренировочной и валидационной выборки в модели 1 наблюдается после 120 эпох обучения и сохраняется до конца обучения (рисунок 1, а). Расхождение ошибок тренировочной и валидационной выборок составляет около 17 %.




**Рисунок 1 – Параметры обучения нейронной сети по модели 1 (а) и модели 2 (б)**

Оценивая точность предсказанных с применением нейронной сети напряжений в железобетонных плитах, использовали известные математические статистики: среднюю абсолютную ошибку ( $MAE$ ), стандартное отклонение ( $RMSE$ ), коэффициент корреляции Пирсона ( $r$ ), коэффициента детерминации ( $R^2$ ). Кроме этого были определены величина поправочного коэффициента  $b$  для среднего отклонения тренировочных и предсказанных значений напряжений, значения средней ошибки моделей  $\Delta$ , полученное по вектору ошибок  $\delta$ , и коэффициент вариации  $V_\delta$  вектора ошибок  $\delta$ , рассчитанные в соответствии с процедурой, приведенной в приложении Д ТКП EN 1990 [2]. Указанные статистические параметры приведены в таблице 1.


**Таблица 1 – Статистические параметры, характеризующие степень точности разработанных моделей нейронной сети**

Модель	$RMSE$	$MAE$	$r$	$R^2$	$b$	$\delta$	$V_\delta$
Модель 1	0,478	0,305	0,924	0,854	0,928	0,428	0,015
Модель 2	0,637	0,424	0,862	0,733	0,853	0,658	0,146

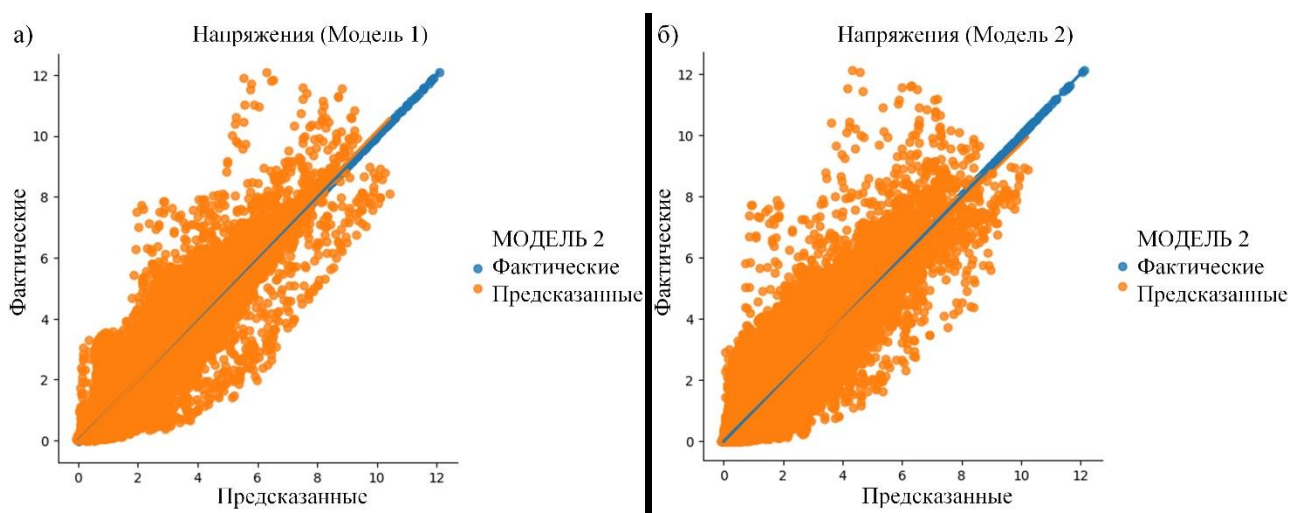
Картина распределения напряжений в железобетонных плитах приведена на рисунках 2 и 3, а соотношение тренировочных и предсказанных напряжений в железобетонных плитах – на рисунке 4.



**Рисунок 2 – Распределение предсказанных по модели 1 (а) и тренировочных (б) напряжений в железобетонных плитах**



**Рисунок 3 – Распределение предсказанных по модели 2 (а) и тренировочных (б) напряжений в железобетонных плитах**



**Рисунок 4 – Соотношение тренировочных и предсказанных с применением модели 1 (а) и модели 2 (б) напряжений в железобетонных плитах**

В среднем предсказанные значения напряжений превышают тренировочные на 7 % по модели 1 и на 15 % по модели 2, о чем свидетельствует величина поправочного коэффициента  $b$  для среднего отклонения (рисунок 4, таблица 1), определяемая по выражению

$$b = \frac{\sum \sigma_a \sigma_p}{\sum \sigma_p^2}, \quad (1)$$

где  $\sigma_a$ ,  $\sigma_p$  – соответственно тренировочные и предсказанные напряжения в железобетонной плите [2].

Учитывая малочисленность обучающей выборки, это характеризует предсказательную способность моделей как относительно высокую, но недостаточно безопасную. Также нельзя говорить о высокой плотности распределения предсказанных значений напряжений вдоль прямой тренировочных значений. Большинство предсказанных значений, а это около 85–90 %, отклоняются от нее в пределах 25 %. Максимальное отклонение, больше характерное для низких величин напряжений, составляет около 80 % (рисунок 4).

Об относительно невысокой плотности данных свидетельствует также среднее значение напряжений в железобетонных плитах, которое составило для тестовой выборки 0,938 МПа. Величина средней абсолютной ошибки для модели 1 получена  $MAE = 0,305$ , а для модели 2 –  $MAE = 0,424$ . Это составляет соответственно 33 % и 45 % от максимального напряжения. Стандартное отклонение, равное для моделей 1 и 2 соответственно  $RMSE = 0,478$  и  $RMSE = 0,637$ , составляет 51 % и 68 % максимального напряжения.

Принято считать достаточно хорошими расчетные модели с коэффициентом детерминации выше 0,8 и коэффициентом корреляции выше 0,9. При коэффициенте детерминации равном 1 имеется функциональная зависимость между сравниваемыми величинами. В нашем исследовании при сравнении тренировочных и предсказанных напряжений значения коэффициента корреляции (для моделей 1 и 2  $r = 0,924$ ;  $0,862$ ) и коэффициента детерминации (для моделей 1 и 2  $R^2 = 0,854$ ;  $0,733$ ) соответствуют приведенным выше критериям только для модели 1 (таблица 1).

Коэффициент вариации вектора ошибок  $\delta$ , равных для моделей 1 и 2 соответственно 0,015 и 0,146, меньше величины 0,33, что свидетельствует о достаточно высокой однородности исследуемой совокупности данных [3].

Анализ результатов статистического исследования показывает, что модель 1 точнее предсказывает величину напряжений в плите. Причина этого может заключаться в том, что исходные данные для первой модели, которые подаются в виде карт признаков, формируют общий многослойный образ объекта. Каждая карта признаков передает параметры одного слоя этого образа. Все карты объединены в единый образ общей геометрической формой объекта. Во второй модели имеется только одна карта признаков, а общая геометрия образа просматривается лишь косвенно посредством координат пространства, которые наделены необходимыми признаками.

В целом можно отметить, что несмотря на то, что большинство статистических параметров имеют не самые лучшие значения, предсказательную способность моделей, построенных на базе сверточной нейронной сети с архитектурой u-net, можно считать достаточно высокой. Авторы считают, что основная причина погрешности моделей заключается в небольшом объеме выборки обучающих данных.

## Выводы

Анализ результатов статистического исследования показывает, что модель 1 точнее предсказывает величину напряжений в плите по причине более эффективной подачи исходных данных.

В целом, несмотря на то, что большинство статистических параметров имеют не самые лучшие значения, предсказательную способность моделей, построенных на базе сверточной нейронной сети с архитектурой u-net, можно считать достаточно высокой. Авторы считают, что основная причина погрешности моделей заключается в небольшом объеме выборки обучающих данных.

## Список цитированных источников

1. Бетонные и железобетонные конструкции = Бетонныя і жалезабетонныя канструкцыі : СП 5.03.01-2020. – Введ. 16.09.2020. – Минск : РУП «Стройтехнорм» : Мин. арх. и стр. Респ. Беларусь, 2020. – 244 с.

2. Основы проектирования строительных конструкций = Асновы праектавання будаўнічых канструкцый : ТКП EN 1990-2011. – Введ. 15.11.2012. – Минск : СЕН/ТС 250 Конструкционные Еврокоды : Мин. арх. и стр. Респ. Беларусь, 2011. – 70 с.

3. Коэффициент вариации (Variation coefficient) [Электронный ресурс]. – Режим доступа: <https://wiki.loginom.ru/articles/variation-coefficient.html>. – Дата доступа: 28.02.2024.

УДК 624.04(75.8)

Никитина А. А.

Научный руководитель: к. т. н., доцент Игнатюк В. И.

## ВНУТРЕННИЕ СИЛЫ В ДВУХШАРНИРНЫХ КРУГОВЫХ АРКАХ ПРИ ДЕЙСТВИИ ВЕРТИКАЛЬНОЙ НАГРУЗКИ, РАСПРЕДЕЛЕННОЙ ПО ПАРАБОЛИЧЕСКОЙ ЗАВИСИМОСТИ

Рассматриваются двухшарнирные арки кругового очертания постоянной жесткости пролетом  $l$ , нагруженные статическими вертикальными распределенными по параболической зависимости нагрузками (рисунок 1).




Рисунок 1 – Расчетная схема арки