

МОДЕЛИРОВАНИЕ СОПРОТИВЛЕНИЯ ПРОДАВЛИВАНИЮ ПЛОСКИХ ЖЕЛЕЗОБЕТОННЫХ ПЛИТ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

В.В. Молош¹, А.Е. Желткович², К. Паршиц³, И.Г. Томашев⁵

¹К.т.н., доцент, доцент кафедры прикладной механики УО «Брестский государственный технический университет», Брест, Беларусь, e-mail: m.vic@rambler.ru

²К.т.н., доцент, доцент кафедры прикладной механики УО «Брестский государственный технический университет», Брест, Беларусь, e-mail: gelpk@mail.ru

³Инженер программист, Беларусь, e-mail: konstantinparhoc@gmail.com.

⁵Магистр технических наук, старший преподаватель кафедры прикладной механики УО «Брестский государственный технический университет», Брест, Беларусь, e-mail: tomashev@mail.ru

Аннотация.

Предмет исследования: величина результирующей равнодействующей поперечной силы в расчётах сопротивления продавливанию плоской железобетонной плиты.

Цели: разработать расчётную модель сопротивления продавливанию железобетонной монолитной плиты, в основу которой положен современный альтернативный подход, базирующийся на применении полносвязной нейронной сети; выявить оптимальное количество промежуточных слоёв и нейронов в каждом слое нейронной сети; проверить точность разработанной модели.

Материалы и методы: методы алгоритмизации обучения полносвязной нейронной сети, пред назначенной для предсказания величины результирующей равнодействующей поперечной силы, а также методы статистического оценивания ошибки расчётной модели.

Результаты: в исследовании применены обучаемые нейронные сети с целью определения сопротивления продавливанию железобетонных плит перекрытий и фундаментов без поперечной арматуры; разработана достоверная расчётная модель, базирующаяся на алгоритме работы полносвязной искусственной нейронной сети (персептрон), которая значительно быстрее, а в ряде случаев и проще, в сравнении с известными методами предсказывает величину предельной продавливающей силы в расчётах сопротивления продавливанию железобетонных плит перекрытий и фундаментов без поперечной арматуры и обладает относительной высокой точностью, которая превышает точность большинства известных в настоящее время расчётных моделей сопротивления продавливанию.

Выводы: Модели, базирующиеся на применении нейронной сети с полносвязной архитектурой, обладают достаточно высокой способностью для предсказания величины сопротивления продавливанию плоских железобетонных монолитных плит и могут быть использованы в ситуациях, когда необходимо получить предварительное быстрое оценивание величины сопротивления продавливанию. Данное направление требует дальнейшего углубленного анализа с целью получения надёжных расчётных моделей, позволяющих выполнять цифровое моделирование и прогнозирование предельных величин сопротивления продавливанию.

ТЕКСТ ТЕЗИСОВ ДОКЛАДА

ВВЕДЕНИЕ

В соединении железобетонной монолитной плиты перекрытия и колонны под нагрузкой возникает сложное напряжённо-деформированное состояние, в результате которого в предельном состоянии плита хрупко разрушается с выделением из неё части бетона конической формы (пирамиды продавливания). Многочисленные экспериментальные и теоретические исследования, направленные на изучение сопротивления продавливанию, привели к возникновению целого ряда расчётных моделей. Однако вышеупомянутые расчётные модели имеют относительно не высокую точность предсказания.

Развитие нейросетевых технологий, которые получают в последние годы всё большее применение во всех отраслях техники, позволило использовать в решении огромного количества инженерных задач, в том числе и задачи сопротивления продавливанию, алгоритмы, в основе которых лежат методы обработки данных [1, 2] и машинное обучение (machine learning, ML) [1, 3, 4, 8].

ОБЗОР ЛИТЕРАТУРЫ

Задача сопротивления железобетонных плит продавливанию исследуется с начала прошлого столетия. Тем не менее к настоящему времени она остаётся не решённой в полной мере и в области теории железобетонных конструкций с точки зрения значимости является одной из наиболее актуальных. Продолжается поиск не только традиционных методов решения задачи сопротивления продавливанию, но также разрабатываются новые альтернативные подходы, к которым относятся методы машинного обучения.

Достаточно большое количество исследований связано с разработкой расчётных моделей сопротивления продавливанию железобетонных плит, в основу которых положены нейросетевые алгоритмы: A.N.D. Hoang [5], Nguyen H.D. и др. [6], Mangalathu S. и др. [7], Shen, Y.X. и др. [1], Truong, G.T. и др. [8].

МАТЕРИАЛЫ И МЕТОДЫ

Для предсказания сопротивления продавливанию железобетонных монолитных плит применяли полносвязную нейросеть (персептрон).

При обучении искусственный нейрон (рисунок 1, а) выполняет операцию нелинейного преобразования суммы произведений входных сигналов x_i на весовые коэффициенты ω_{ij} (взвешенное суммирование) с добавлением порога нейронного элемента T , характеризующего расположение функции активации по оси абсцисс [9]. Взвешенная сумма S рассчитывается по формуле (1):

$$S = \sum \omega_{ij} x_i - T. \quad (1)$$

Для активации нейрона использовали ректификационную функцию (*ReLU*):

$$F(S) = \begin{cases} S, & S > 0, \\ 0, & \text{otherwise.} \end{cases} \quad (2)$$

Такие вычисления выполняются для каждого из нейронов скрытых и выходного слоёв (рисунок 1, б). В результате в выходном слое получается некоторое значение искомой величины Y , которое сравнивается с действительным эталонным значением E – сопротивление срезу при продавливании $V_{u,exp}$, полученное

при экспериментальном исследовании фактических образцов железобетонных плит. В процесс обучения нейронной сети изменяются весовые коэффициенты методом обратного распространения ошибки (англ. backpropagation).

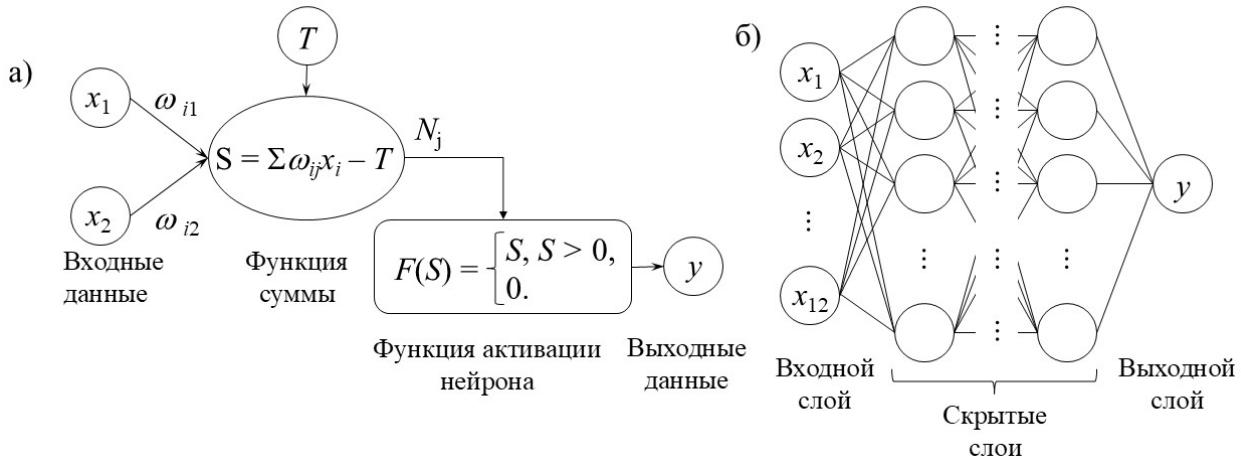


Рисунок 1 – Архитектура нейросети:

- а) – структура персептрана, имитирующая один биологический нейрон [9];
- в) – общая принципиальная схема персептрана с несколькими скрытыми слоями, используемая в данном исследовании.

В качестве ошибки модели использовали среднеквадратичную ошибку:

$$E_s = \frac{1}{n} \sum_j (y_j^k - e_j^k)^2 \quad (3)$$

где n – размерность обучающей выборки.

Алгоритм выполняется до тех пор, пока суммарная квадратичная ошибка сети не станет меньше заданной, т. е.

$$E_s \leq E_e \quad (4)$$

Нейронная сеть была реализована с помощью открытой программной библиотеки для машинного обучения TensorFlow, разработанной компанией Google для решения задач построения и обучения нейронных сетей.

Для обучения нейронной сети была сформирована база экспериментальных данных, взятых из доступных литературных источников, которая включала сведения о 248 экспериментальных образцах плит, испытанных зарубежными и отечественными авторами, которая была разделена на две части: 200 образцов были предназначены для обучения нейросетевой модели; 48 образцов, неиспользованных в обучении, составили тестовую выборку.

Входной слой включал двенадцать нейронов (факторы, влияющие на сопротивление продавливанию): X_1 – форма колонны в плане; X_2, X_3 – размеры сторон экспериментальной железобетонной плиты (a, b); X_4 – высота плиты (h); X_5, X_6 – размеры колонны (r, a_k, b_k); X_7 – рабочая эффективная высота плиты (d); X_8, X_9 – средние соответственно прочность (f_{cm}) и модуль упругости (E_{cm}) бетона; X_{10} – коэффициент продольного армирования плиты (ρ); X_{11}, X_{12} – средние соответственно прочность (f_s) и модуль упругости (E_s) арматуры.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

С целью определения оптимального количества скрытых слоёв и нейронов в каждом из них были разработаны несколько нейросетевых моделей, в которых количество промежуточных слоёв варьировалось от 1 до 39, а количество нейронов в слое от 6 до 45.

Средствами оценивания достоверности нейросетевых моделей были выбраны следующие статистические параметры: средняя абсолютная ошибка (MAE), стандартное отклонение ($RMSE$), коэффициент корреляции Пирсона (r), коэффициента детерминации (R^2), величина поправочного коэффициента b , характеризующая насколько в среднем исследуемая модель безопасна или небезопасна, а также значения средней ошибки моделей (Δ), полученное по вектору ошибок (δ), и коэффициент вариации (V_δ) вектора ошибок δ , рассчитанные в соответствии с процедурой, приведенной в приложении Д СН 2.01.01 [10]. Критериями наибольшей точности исследуемых моделей считали наименьшие значения средней абсолютной ошибки (MAE), стандартного отклонения ($RMSE$), значения средней ошибки (Δ) и коэффициент вариации (V_δ), а также наиболее близкие к 1 значения коэффициент корреляции Пирсона (r) и коэффициента детерминации (R^2).

Для моделей с количеством промежуточных слоёв 8 и более отмечена меньшая стабильность в обучении, о чём свидетельствует менее гладкая поверхность изменения кривой изменения ошибки модели в процессе её обучения (рисунок 3).

С увеличением количества нейронов в слое в среднем наблюдается улучшение всех исследуемых статистик, которое тем не менее имеет вероятностный характер. Увеличение количества нейронов в слое практически не влияет на изменение ошибки (δ) и коэффициента вариации вектора ошибок (V_δ) в моделях с одним промежуточным слоем нейронов. Но в модели с 39 промежуточными слоями наблюдается в среднем значительное снижение этих параметров.

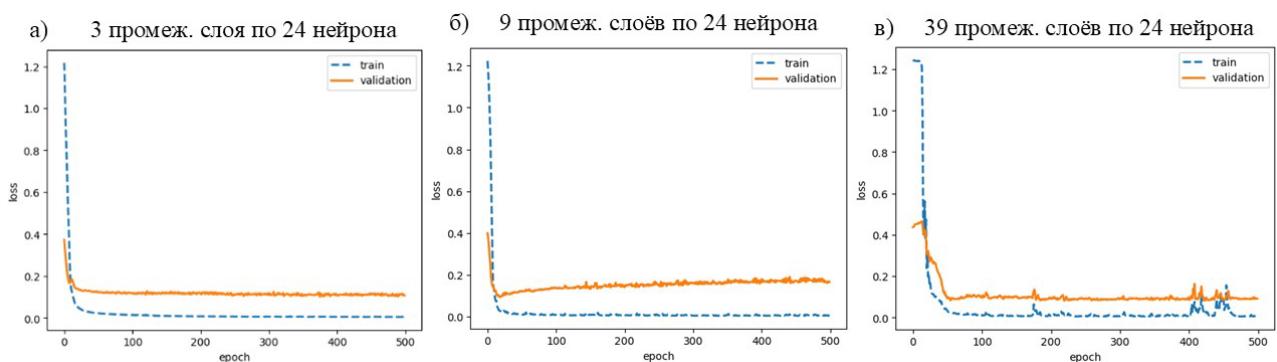


Рисунок 3 – Параметры обучения моделей нейронной сети

Увеличение количества промежуточных слоёв ведёт в среднем к уменьшению коэффициента корреляции Пирсона и коэффициента детерминации и увеличению средней абсолютной ошибки и стандартного отклонения. Что свидетельствует об ухудшении моделей при увеличении промежуточных слоёв. В общем ухудшение статистических параметров отмечено для моделей, у которых количество промежуточных слоёв нейронов больше 18.

ВЫВОДЫ

Модели, базирующиеся на применении нейронной сети с полносвязной архитектурой, обладают достаточно высокой способностью для предсказания величины сопротивления продавливанию плоских железобетонных монолитных плит перекрытий и покрытий.

Наилучшая предсказательная способность была отмечена для моделей с 12-18 промежуточными слоями по 20-24 нейрона в каждом слое.

Изменение всех статистических параметров, а следовательно, и точность моделей, имеет вероятностный характер и сильно зависит от удачного подбора весовых коэффициентов в самом начале обучения, который осуществляется программой путём случайной генерации. При условии удачно сгенерированных весовых коэффициентах процесс обучения нейронной сети протекает более предсказуемо и стабильно, а результаты предсказаний, полученные после обучения, обладают высокой достоверностью.

ЛИТЕРАТУРА

1. Shen, Y. Interpretable Machine Learning Models for Punching Shear Strength Estimation of FRP Reinforced Concrete Slabs / Y. Shen, J. Sun, S. Liang // Crystals, 2022. – № 259.
2. Geetha, N. K. Overview of machine learning and its adaptability in mechanical engineering / N. K. Geetha, P. Bridjesh // Mater. Today 2020, – 4. [Google Scholar] [CrossRef]
3. Mangalathu, S. Machine-learning interpretability techniques for seismic performance assessment of infrastructure systems / S. Mangalathu, K. Karthikeyan, D. C. Feng, J. S. Jeon // Eng. Struct., 2022. – 250, 112883
4. Chen, S. Z. Development of data-driven prediction model for CFRP-steel bond strength by implementing ensemble learning algorithms / S.Z. Chen, D. C. Feng, W. S. Han, G. Wu // Constr. Build. Mater., 2021. – 303, 124470.
5. Hoang, A. N. D. Estimating punching shear capacity of steel fibre reinforced concrete slabs using sequential piecewise multiple linear regression and artificial neural network Measurement / A. N. D. Hoang // 2019. – 137, 58–70.
6. Nguyen, H. D. Development of extreme gradient boosting model for prediction of punching shear resistance of r/c interior slabs / H. D. Nguyen, G. T. Truong, M. Shin // Eng. Struct., 2021. – 235, 112067.
7. Mangalathu, S. Explainable machine learning models for punching shear strength estimation of flat slabs without transverse reinforcement / S. Mangalathu, H. Shin, E. Choi, J. S. Jeon // J. Build. Eng. 2021. – 39, 102300.
8. Truong, G. T. Assessment of punching shear strength of FRP-RC slab-column connections using machine learning algorithms / G. T. Truong, H. J. Hwang, C. S. Kim // Eng. Struct. 2022, 255, 113898.
9. Головко, В.А. Нейросетевые технологии обработки данных / В. А. Головко, В. В. Краснопрошин. – Минск : Бел. гос. ун-т, 2017. – 264 с.
10. Основы проектирования строительных конструкций = Асновы праектавання будаўничых канструкцый : СН 2.01.01. – Введ. 16.19.2019. – Минск : РУП «Стройтехнорм»: Мин. арх. и стр. Республики Беларусь, 2020. – 89 с.