

**ПРИМЕНЕНИЕ 3D-СВЕРТОЧНОЙ НЕЙРОСЕТИ
ПРИ ПРОГНОЗИРОВАНИИ УСАДОЧНЫХ НАПРЯЖЕНИЙ
И ПЕРЕМЕЩЕНИЙ В МОНОЛИТНЫХ БЕТОННЫХ ПЛИТАХ
НА ОСНОВАНИИ**

***Zheltkovich¹ A., Molosh² V., Marmysh³ D., Parchotz⁴ K.
Ren Yuhang⁵, Huang Zien⁶***

*¹Associate professor. Ph.D, Brest State Technical University
Department of Theoretical and Applied Mechanics
Brest, Republic of Belarus 224017, gelpek@mail.ru*

*²Associate professor. Ph.D, Brest State Technical University
Department of Theoretical and Applied Mechanics
Brest, Republic of Belarus 224017, m.vic@rambler.ru*

*³Associate professor, Ph.D, Belarusian State University Head of BSU-DTU Joint Institute
Department of Theoretical and Applied Mechanics, Minsk. Republic of Belarus 670000
marmyshdenis@mail.ru*

⁴Master, artificial intelligence, konstantinparhoc@gmail.com

*⁵Master student, Nanchang Hangkong University, School of Civil Engineering
and Architecture, Nanchang Jiangxi China 330063
Belarusian National Technical University, Faculty of Civil Engineering
Minsk Belarus 220002, reny23312@gmail.com*

⁶449766175@qq.com

Целью настоящего исследования является демонстрация возможностей искусственных сверточных нейросетей (CNN) в задачах, связанных с механикой, в частности при проектировании монолитных плит на основании. В работе впервые предложен подход, базирующийся на использовании воксельного описания исследуемого объекта. В ряде случаев еще на этапе проектирования предусматривается наличие технологических отверстий различной формы, поверхность плиты может иметь сложную геометрическую форму. Определение напряженно-деформированного состояния (НДС) в замкнутом виде в таких случаях весьма трудоемко либо вовсе недостижимо. В данной работе представлен альтернативный подход, основанный на применении 3D-CNN с архитектурой U-Net, который позволяет получить достаточно точные прогнозы усадочных напряжений и перемещений в плитах более простым способом по сравнению с методами конечных элементов. В работе отмечен перспективный потенциал нейросетей U-Net архитектуры.

Основные предпосылки

Как сообщают многие исследовательские работы, моделирование поведения инженерных конструкций с помощью нейронных сетей намного проще, чем с помощью традиционных математических моделей.

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.

Нейронные сети способны моделировать поведение систем при ограниченных затратах на проектирование и предоставлять быстрые и достаточно точные решения в сложных и неопределенных ситуациях. Применение метода конечных элементов является достаточно трудоемким, так как требует высокого уровня квалификации инженеров-проектировщиков и значительных временных и трудовых затрат.

Постановка задачи и подготовка образцов для обучения

В процессе работы была создана пятимерная матрица в которой были внесены 21 параметр, определяющий поведение плиты при усадке. Матрица состояла из следующих измерений: 1 – номер образца, 2 – адрес (координата) «X», 3 – адрес (координата) «Y», 4 – адрес (координата) «Z», 5 – вектор из 17 параметров (физико-механические характеристики плиты, контактного слоя, армирования, окружающей среды, напряжения и перемещения в плите). Пятым измерением признаков являлись установленные связи между НДС каждого вокселя плиты и физико-механическими характеристиками бетона.

Из-за особенностей работы архитектуры «voxel-to-voxel» данные, представляющие собой воксели (формат данных представлен через объемные элементы – кубики), перед подачей на обучение в CNN были увеличены до количества 64x64x4 (итого оценивалось 16384 voxels). Для тренировки CNN было создано 45 плит и 11 плит для тестирования и анализа.

Применение сверточной нейросети с U-Net архитектурой

Одной из причин высокой производительности CNN является использование одинаковых нейронов в каждом перцептивном ядре, что позволяет уменьшить количество настраиваемых связей сети по сравнению с персепtronами. При обучении было назначено 1000 эпох. Для оптимальной регуляризации случайнym образом отбиралось 70 % исходных данных из обучающего набора, а 30 % оставлялось для проверки качества модели.

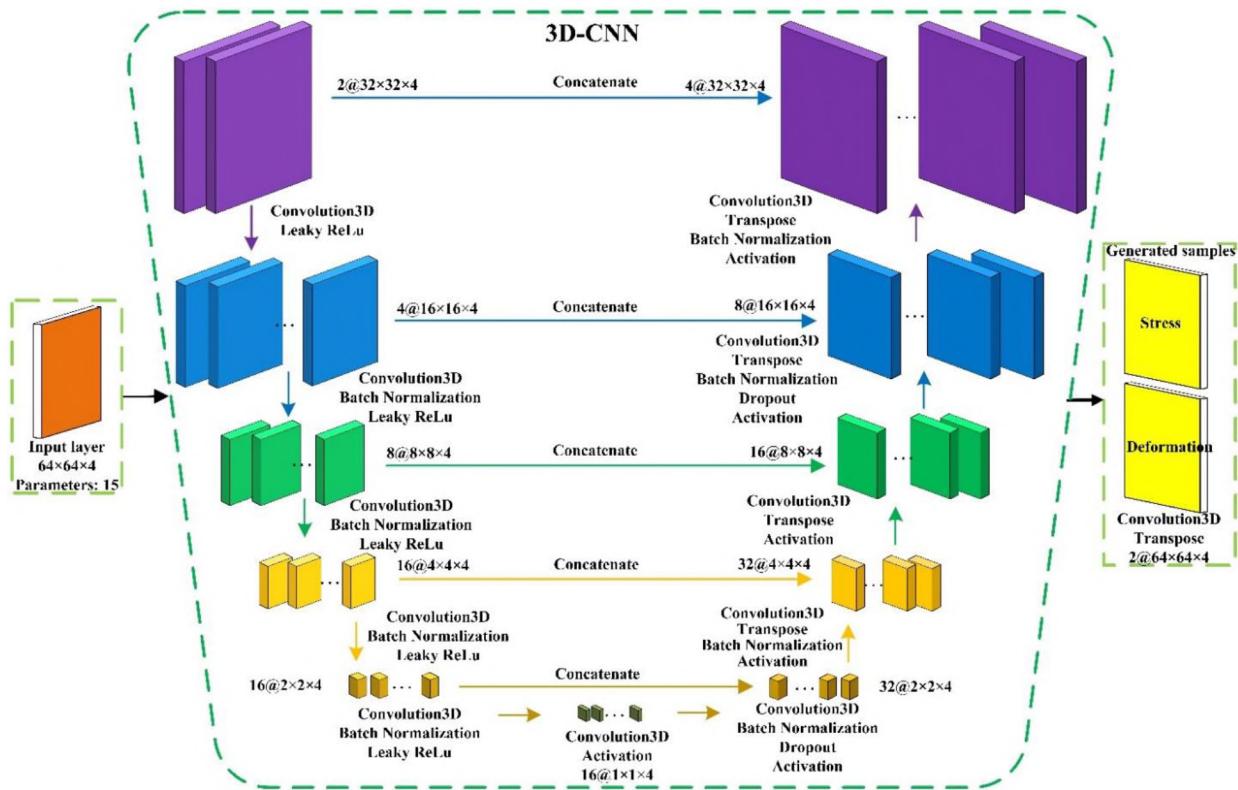


Рис. 2 – 3D-CNN Нейронная сеть с архитектурой U-Net

Усадочные напряжение и перемещения в железобетонных плитах на основании

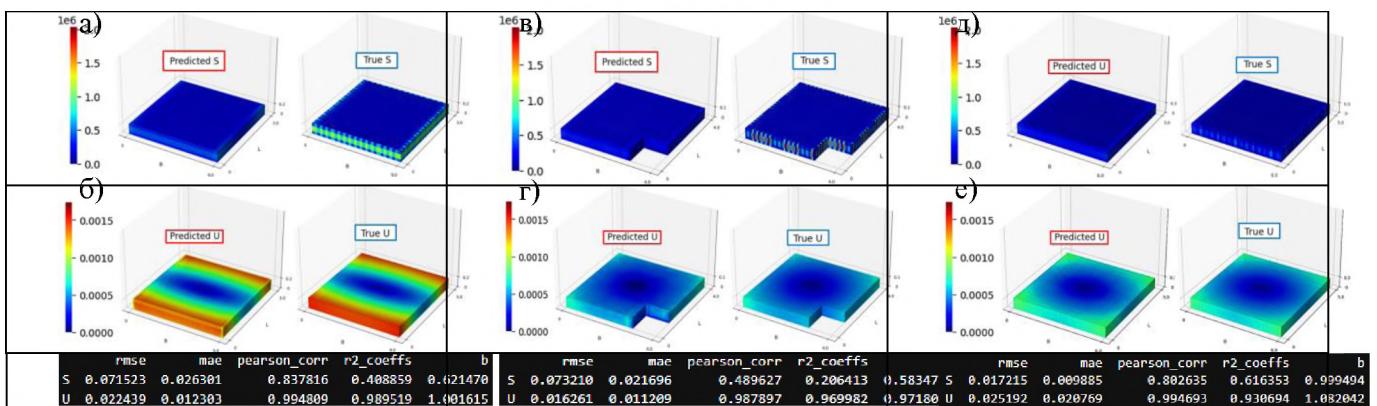


Рисунок 3 – Усадочные: (a, б, д) – напряжения, (в, г, е) – перемещения

Выводы

В среднем предсказанные значения напряжений превышают тренировочные на 24 %, а перемещения меньше тренировочных на 0,3 % о чем свидетельствует величина поправочного коэффициента b в таблицах рисунка 3.

Величина средней абсолютной ошибки по напряжениям $MAE = 0,0193$, а для перемещений – $MAE = 0,0147$. Это составляет соответственно 1,93 % и 1,47 % от максимальных значений. Стандартное отклонение (оцениваемое по $RMSE$), равное для напряжений и перемещений соответственно – 3 % и 2,1 %.

Принято считать достаточно хорошими расчетные модели с коэффициентом детерминации выше 0,8 и коэффициентом корреляции выше 0,9. В нашем исследовании, при сравнении тестовых и предсказанных значений напряжений и перемещений соответственно, коэффициент корреляции (коэффициент Пирсона) – 0,701; 0,99. Коэффициент детерминации соответственно ($R^2 = 0,55$; 0,963) для напряжений и перемещений соответствуют приведенным выше критериям только для перемещений.

Основная причина погрешности моделей заключается в небольшом объеме выборки обучающих данных, что требует пополнения указанной выборки, переобучения нейронной сети и последующей оценке ее достоверности.