

ПРОГНОЗИРОВАНИЕ ОСТАТОЧНОГО РЕСУРСА НА ОСНОВЕ МЯГКИХ ВЫЧИСЛЕНИЙ

USING NEURAL NETWORKS WITH DEEP LEARNING TO PREDICT AND ASSESS THE ULTIMATE RESOURCE STRUCTURES OF BUILDINGS

D. Akimov
V. Kotelnikov
D. Skoseleva
A. Dyatchenkova

Summary. The task of prediction of a limit resource of constructions of steel concrete constructions on the basis of neural networks is considered. The analysis of results of application of a convolution neural network for prediction and assessment of a limit resource is carried out.

Keywords: limit resource, assessment of constructions, depth training, convolution neural networks, Kendall's correlation, deep learning.

Акимов Дмитрий Александрович

К.т.н.

Котельников Владимир Владимирович

К.т.н.

Скоселева Дарья Александровна

Аспирант

Дятченкова Анастасия Юрьевна

Аспирант (Москва)

darina.skipskay@gmail.com

Аннотация. Рассмотрена задача прогнозирования предельного ресурса конструкций железобетонных сооружений на основе нейронных сетей. Проведен анализ результатов применения сверточной нейронной сети для прогнозирования и оценки предельного ресурса.

Ключевые слова: предельный ресурс, оценка конструкций, глубинное обучение, свёрточные нейронные сети, корреляция Кендалла, deep learning.

Введение

Прогнозирование технического состояния конструкций, очень важный инструмент оценки остаточного ресурса конструкций. Как правило, оценка основывается на данных инструментальных измерений и описании визуального осмотра дефектов и состояния элементов конструкций. Контроль объектов может быть осуществлён с помощью различных инструментальных средств и методов основанных, на различных физических принципах: мониторинг влажности, радиоактивности, акустической и ультразвуковой дефектоскопии, и визуального контроля. Современный уровень развития технологии в области полупроводниковых компонентов позволяет создавать системы мониторинга, в которых обработка информации происходит по принципам самоорганизации и распределённых вычислений с помощью, так называемых интеллектуальных датчиков [3], которые взаимодействуют между собой, используя методы обработки информации, основанные на моделях интеллектуального мониторинга [4]. Такие интеллектуальные датчики принято называть сенсорными узлами. Подобная технология объединения маломощных беспроводных сенсорных узлов получила название беспроводных сенсорных сетей (БСС) [5], а основанные на этом принципе системы мониторинга принято называть беспроводными многоячеистыми системами мониторинга (БМСМ).

Подобные технологии измерения предоставляют много данных, однако в сыром виде такое количество

данных почти бесполезно. Для автоматизированного анализа необходимо применить интеллектуальные методы, среди которых сейчас выделяются своей эффективностью нейронные сети.

1. Формализация постановки задачи оценки и прогноза

Уровень повреждений и деформаций, при исследовании конструкций сложной формы, состоящей из множества узлов, имеет плохую степень формализации. При реальном обследовании измерения делаются только на части конструкции, поэтому определить причины достаточно сложно, на данный момент осуществляется только анализ существующих дефектов и делаются рекомендации по укреплению конструкций на основе экспертного мнения специалиста. Однако такой подход плох тем, что зависит от опыта конкретного человека или группы, а в ряде случаев осуществляется неправильная интерпретация результатов измерений и невозможно оценить полную картину, так как при аналитической работе человека упускаются возможные связи между данными.

2. Метод прогноза с помощью свёрточной нейронной сети

Для того что бы найти регрессию между прогнозируемым и текущем состоянием необходимо рассмотреть текущее состояние как вектор предикторов состояния дефектов и выбрать наиболее критичные из них.

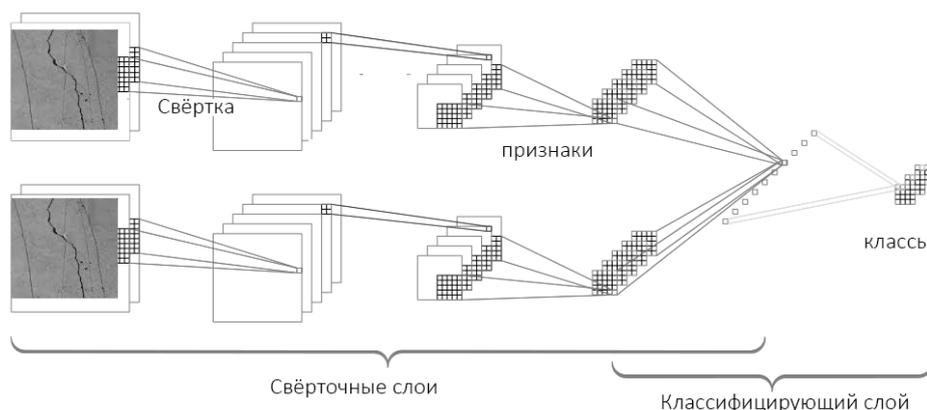


Рисунок 1. Свёрточная нейронная сеть

Классом моделей, успешно решающих задачу регрессии, являются сверточная нейронная сеть (Convolutional Neural Network, CNN) [2]. Сверточные нейронные сети относятся к парадигме машинного обучения «deep learning», которая очень хорошо зарекомендовала на различных задачах. Принцип ее использования заключается в последовательном применении операций свертки и выбора максимального значения (max-polling [3]). Схематически сверточная модель для анализа текстовых данных изображена на рисунке 1.

Рассмотрим основные гиперпараметры всех нейросетей:

- α — коэффициент обучения (learning rate);
- λ — коэффициент L2-регуляризации;
- w — размер векторного представления текстового токена;
- c — количество нейронов промежуточного слоя.

Чтобы получить данные о прогнозе, сверточную нейронную сеть необходимо проверить на практике, оценив возможность решать задачу прогнозирования на основе регрессии.

Свёрточные слои выделяют пространство признаков, позволяющее найти подходящую критическую причину дефекта.

Конфигурация нейронной сети с сверточными слоями:

- 1000 нейронов — входной слой,
- 128 нейронов — активация ReLU,
- 192 нейронов — активация ReLU,
- 128 нейронов — активация ReLU,
- 48 нейронов — активация ReLU,
- 7 нейронов — активация softmax.

На выходе будет вектор $K\{k_1, \dots, k_n\}$, коэффициенты k_n — вес прогнозного состояния, являются результатом работы нейронной сети.

Новые входные параметры нейронной сети образуют новые признаковые пространства в сверточном слое. На каждом уровне представлены абстрактные признаки конкретной причины дефекта, основанные на признаках предыдущего уровня, с более детализированным представлением. Таким образом, чем глубже мы продвигаемся, тем выше уровень абстракции. В нейронных сетях множество слоев представляет собой множество уровней с векторами признаков, которые генерируют выходные данные [1]. По результатам самообучения признакового пространства и результатом распознавания формируются новые укрупненные признаки причин дефектов.

3. Обучение сверточной нейронной сети

В качестве входных данных использовались замеры толщины трещин и карта их контуров, рисунок 2. Общая база содержала 650 записанных образов трещин. Для формирования обучающей и тестовой выборки образцы, соответствующие одному прогнозному образу, случайным образом были поделены на два равных подмножества.

Таким образом, и обучающая, и тестовая выборка содержала по 325 образцов трещин в виде оцифрованного изображения. Далее все образцы проходили этапы предобработки изображений трещин. Полученные матрицы признаков подавались на вход сверточной сети.

Основой для проверки правильности предсказания критериальной переменной (прогноза) от предиктора выбрана ошибка обучения:

$$E_k = \frac{1}{2} \sum_{i=0}^{N-1} (d_i - o_i)^2,$$

где N — число выходов сети, d_i — желаемое значение i -го выхода сети для k -го эталона, o_i — реальное значение

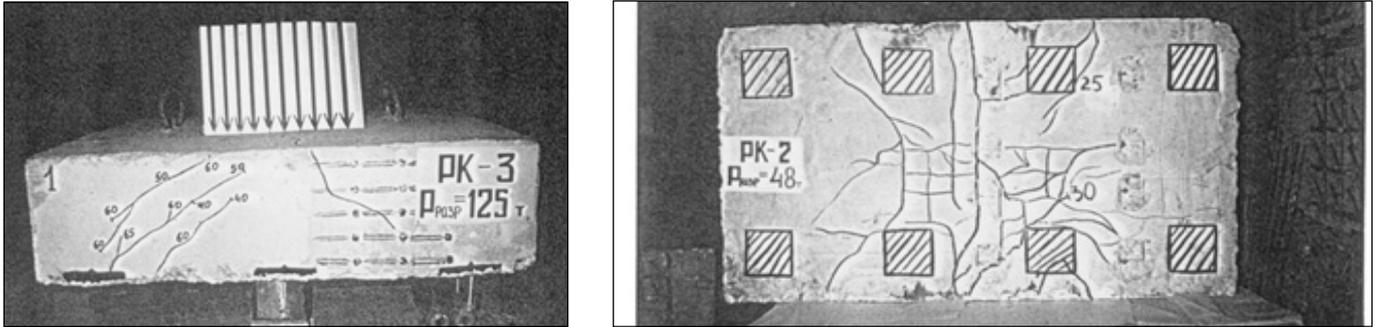


Рисунок 2. Замеры трещин и их параметризация

ние i -го выхода сети для k -го эталона. Величина E_k должна вычисляться для каждого элемента обучающей выборки. В исследовании использовался критерий величины средней ошибки при сравнении с каждым эталоном:

$$\bar{E}(n) = \frac{1}{S} \sum_{k=0}^{S-1} E_k,$$

где S — мощность обучающей выборки, $\bar{E}(n)$ — средняя ошибка сети для n -й эпохи обучения.

Использовался метод обратного распространения ошибки. При настройках нейронной сети использовалось условие, что значение средней ошибки обучения должно быть равным 0,001. На рисунке 3 представлена зависимость ошибки обучения от эпохи.

На выходе мы получаем ранги прогнозируемых состояний. Чем больше ранг на выходе, тем вероятнее, что именно в это прогнозируемое состояние попадет конструкция с течением времени. Однако набор прогнозируемых состояний изначально задан в базе знаний экс-

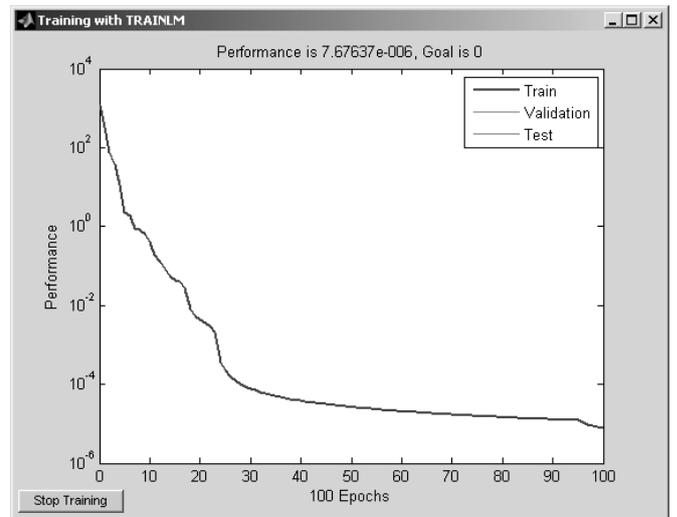


Рисунок 3. Зависимость ошибки обучения $\bar{E}(n)$ от количества пройденных эпох.

пертным методом. При таких данных можно проверить как коррелируют экспертные оценки с оценкой нейронной сети.

ЛИТЕРАТУРА

1. Distributed representations of words and phrases and their compositionality / T. Mikolov [et al.] // Advances in Neural Information Processing Systems. — 2013. — P. 3111–3119.
2. Kim, Y. Convolutional neural networks for sentence classification / Y. Kim // arXiv preprint arXiv:1408.5882. — 2014
3. Будадин О. Н., Каледин В. О., Кульков А. А., Пичугин А. Н., Нагайцева Теоретические и экспериментальные исследования возможности теплового контроля пространственной конструкции из полимерного композиционного материала в процессе одноосного силового нагружения. — Контроль. Диагностика. — № 5 (191), 2014, с. 72–81
4. Морозова Т. Ю., Бекаревич А. А., Будадин О. Н. Новый подход к идентификации дефектов материалов изделий. — Контроль. Диагностика. — № 8 (194), 2014, с. 42–48.
5. Акимов Д. А., Работкин В. Д. Терёхин И. В. Редькин О. К. Представление знаний в распределенных информационных системах промышленных предприятий. // Промышленные АСУ и контроллеры. Научтехлитиздат, 2013, № 1, С 33–38
6. Акимов Д. А., Сумкин К. С., Морозова Т. Ю. Автоматизация использования стереозрения по методам выделения управляющих воздействий и нечеткой логики. // Материалы международной научно-практической конференции «Современные проблемы и пути их решения в науке, транспорте, производстве и образовании 2012». — Выпуск 4. Том 12. — Одесса: С. 60–66.

© Акимов Дмитрий Александрович, Котельников Владимир Владимирович, Скоселева Дарья Александровна, Дятченкова Анастасия Юрьевна (darina.skipskay@gmail.com). Журнал «Современная наука: актуальные проблемы теории и практики»