

ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ ПРИМЕНЕНИЯ ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ПРОИЗВОДИТЕЛЬНОСТИ СУПЕРЭВМ



А. В. Смирнов, студент магистратуры 2-го курса
E-mail: aleksandr.smirnov@digital-klgtu.ru
ФГБОУ ВО «Калининградский государственный
технический университет»



И. А. Шикота, студент магистратуры 2-го курса
E-mail: ilya.shickota@yandex.ru
ФГБОУ ВО «Калининградский государственный
технический университет»

В. Д. Штерцер, студент магистратуры 2-го курса
E-mail: vadsterz2.0@gmail.com
ФГБОУ ВО «Калининградский государственный
технический университет»

А. В. Снытников, д. т. н., научный руководитель
E-mail: aleksej.snytnikov@klgtu.ru
ФГБОУ ВО «Калининградский государственный
технический университет»

В последние годы глубокое обучение стало мощным инструментом прогностического моделирования, позволяющим изучать сложные закономерности и взаимосвязи на основе данных. Однако такие методы не очень используются в прогнозировании одномерных данных. Целью нашей работы является исследование возможности использования моделей глубокого обучения для прогнозирования производительности СуперЭВМ.

Ключевые слова: СуперЭВМ, регрессия, машинное обучение, многослойный перцептрон Румельхарта, сверточная нейронная сеть.

ВВЕДЕНИЕ

В последние годы глубокое обучение стало мощным инструментом прогностического моделирования, позволяющим изучать сложные закономерности и взаимосвязи на основе данных. Модели глубокого обучения, такие как сверточные нейронные сети (CNN) и многослойные перцептроны (MLP), продемонстрировали значительный успех в различных областях, включая распознавание изображений, обработку естественного языка и прогнозирование временных рядов. Способность глубокого обучения улавливать нелинейные взаимосвязи делает его перспективным подходом для прогнозирования.

ОБЪЕКТ ИССЛЕДОВАНИЯ

Объектом данного исследования является *эффективность применения методов глубокого обучения для прогнозирования производительности СуперЭВМ.*

ЦЕЛЬ И ЗАДАЧИ ИССЛЕДОВАНИЯ

Целью данного исследования является определение возможности использования моделей глубокого обучения для прогнозирования производительности СуперЭВМ на основе списка TOP500 и сравнение с популярными видами регрессии – линейной регрессией, регрессией деревом решений, регрессией методом случайного леса.

ДЕТАЛИ ИССЛЕДОВАНИЯ

Для проведения исследования была использована таблица производительности СуперЭВМ TOP500 за июнь 2024 г.[1].

Набор данных состоит из 38 атрибутов, многие из этих атрибутов не несут полезной информации для нашего исследования, поэтому необходимо было очистить таблицу от лишних данных, а также нормализовать оставшиеся данные.

Таблица 1 – Очищенные и нормализованные данные

Total Cores	Cores per Socket	Processor Speed	Rmax [TFlop/s]
0.816894	0.234375	0.28	1.000000
0.869884	0.187500	0.44	0.838853
0.194586	0.171775	0.28	0.464394
0.716494	0.171775	0.36	0.365388
...	...	...	...

Исследование было разделено на две части:

1. Прогнозирование производительности СуперЭВМ на основе базовых регрессионных моделей:
 - a. Линейная регрессия[5];
 - b. Метод случайного леса[6]:
 - i. Количество деревьев: 100
 - ii. Функция потерь: Среднеквадратичная ошибка
 - c. Дерево решений:
 - i. Функция потерь: Среднеквадратичная ошибка
2. Прогнозирование производительности СуперЭВМ на основе моделей глубокого обучения:
 - a. Трапециевидная сверточная нейронная сеть[4]:
 - i. Сетка(kernel size): 2
 - ii. Количество фильтров: [512, 128]
 - iii. Количество нейронов: [512, 256, 128, 64, 32]
 - iv. Функция оптимизации: Adam[2]
 - v. Функция потерь: Средняя абсолютная ошибка
 - vi. Количество эпох: 200

- б. Многослойный перцептрон Румельхарта[3]:
- i. Количество нейронов: [512, 256, 128, 64, 32]
 - ii. Функция оптимизации: Adam[2]
 - iii. Функция потерь: Средняя абсолютная ошибка
 - iv. Количество эпох: 200

Структуры используемых моделей глубокого обучения показаны на рисунках 1 и 2.




Рисунок 1 – Структура используемого многослойного перцептрона Румельхарта




Рисунок 2 – Структура используемой трапециевидной сверточной нейронной сети

ОПИСАНИЕ МЕТОДОВ АНАЛИЗА

Для проведения исследования мы использовали следующие методы:

- **Коэффициент детерминации**

Рассчитывается следующим образом:

$$R^2 = 1 - \frac{RSS}{TSS},$$

где RSS – сумма квадратов остатков, TSS – общая сумма квадратов.

Коэффициент детерминации обозначается как (R^2) и может принимать значения от 0 до 1. Чем ближе значение коэффициента к 1, тем сильнее зависимость между действительными и предсказанными значениями. При оценке моделей это интерпретируется как соответствие модели данным. Для приемлемых моделей предполагается, что коэффициент детерминации должен быть хотя бы не меньше 50 %. Модели с коэффициентом детерминации выше 80 % можно признать достаточно качественными.

- **Среднеквадратичная ошибка**

Рассчитывается следующим образом:

$$MSE = \frac{1}{n} * \sum (y_i - \hat{y}_i)^2,$$

где n – количество наблюдений, y_i – фактическое значения, $\hat{y}_i$ – предсказанное значение.

MSE измеряет среднее значение квадратичной разницы между прогнозируемыми и фактическими значениями. Благодаря возведению разностей в квадрат, MSE придает больший вес большим ошибкам, что делает его чувствительным к промахам. Более низкий MSE указывает на то, что прогнозы модели ближе к истинным значениям, что отражает лучшую общую производительность. Чем меньше MSE, тем выше точность прогнозирования модели.

- **Средняя абсолютная ошибка**

Рассчитывается следующим образом:

$$MAE = \frac{1}{n} * \sum |y_i - \hat{y}_i|,$$

где n – количество наблюдений, y_i – фактическое значения, $\hat{y}_i$ – предсказанное значение.

Средняя абсолютная ошибка измеряет среднюю абсолютную разницу между фактическими и прогнозными значениями. В отличие от среднеквадратических ошибок, где используется квадрат разности, MAE является линейной оценкой, поэтому вес разностей одинаков, независимо от диапазона. Чем меньше значение MAE, тем ближе предсказанные значения к фактическим и тем выше точность модели.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Результаты исследования представлены в таблице 2 и на рисунках 3, 4.

Таблица 2 – Сравнительная таблица

Название	Коэффициент детерминации	Среднеквадратичная ошибка	Средняя абсолютная ошибка
Трапеционная сверточная нейронная сеть	0.820	0.002	0.010
Трапеционный многослойный персептрон	0.750	0.003	0.011
Регрессия методом случайного леса	0.658	0.004	0.014
Регрессия деревом решений	0.541	0.005	0.014
Линейная регрессия	0.574	0.005	0.021




Рисунок 3 – График сравнения коэффициента детерминации: чем выше значение, тем лучше



Рисунок 4 – График сравнения среднеквадратичных ошибок: чем ниже значение, тем лучше

В результате исследования был сделан вывод, что методы глубокого обучения могут быть использованы для прогнозирования и даже показывать более высокую точность, чем базовые регрессионные модели.

ЗАКЛЮЧЕНИЕ

В ходе исследования были созданы несколько моделей глубокого обучения, на основе которых были сделаны следующие выводы: методы глубокого обучения могут быть использованы для прогнозирования, а также даже показывать более высокую точность, чем базовые регрессионные модели.

СПИСОК ЛИТЕРАТУРЫ

1. Информационная таблица производительности TOP500 [Электронный ресурс]. – URL: <https://www.top500.org/lists/top500/2024/06/> (дата обращения: 30.11.2024).
2. Adam: A method for stochastic optimization / P. Diederik, Kingma, J. Lei Ba. – 2014.
3. Learning Internal Representations by Error Propagation / D. E. Rumelhart, G. E. Hilton, R. J. Williams. – 1986.
4. Архитектура сверточных нейронных сетей / Д. А. Маршалко, О. В. Кубанских. – 2019.
5. Linear Hypotheses / W. H. Kruskal, J. M. Tanur. – 1978.
6. Random Decision Forest / T. K. Ho. – 1995.

STUDY OF THE EFFECTIVENESS OF APPLYING DEEP LEARNING FOR PERFORMANCE PREDICTION

A. V. Smirnov, 2nd year master degree student
E-mail: aleksandr.smirnov@digital-klgtu.ru
Kaliningrad State Technical University

I. A. Shikota, 2nd year master degree student
E-mail: ilya.shickota@yandex.ru
Kaliningrad State Technical University

V. D. Shterzer, 2nd year master degree student
E-mail: vadsterz2.0@gmail.com
Kaliningrad State Technical University

A. V. Snytnikov, Professor
E-mail: aleksej.snytnikov@klgtu.ru
Kaliningrad State Technical University

In recent years, deep learning has become a powerful predictive modelling tool to learn complex patterns and relationships from data. However, these methods are not very much used in predicting univariate data. The aim of our work is to investigate the possibility of using deep learning models to predict the performance of Supercomputers.

Keywords: *Supercomputer, regression, machine learning, multilayer perceptron, convolutional neural network.*