

УДК 004.051:004.855.5

## МЕТОДИКА ОЦЕНКИ ВЫЧИСЛИТЕЛЬНОЙ ЭФФЕКТИВНОСТИ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ И НЕЙРОННЫХ СЕТЕЙ

**Аристов А.И.** (Федеральное государственное бюджетное образовательное учреждение высшего образования «Тюменский индустриальный университет»)

**Научный руководитель – доктор технических наук, профессор Туренко С.К.**  
(Федеральное государственное бюджетное образовательное учреждение высшего образования «Тюменский индустриальный университет»)

**Введение.** Машинное обучение и нейросетевые технологии повсюду окружают нас во множестве крупных организаций. Число кейсов использования искусственного интеллекта растет стремительно по мере быстрого развития сложных вычислений, удорожания вычислительной техники и роста информационной нагрузки. В каждой отрасли есть целевые применения для машинного обучения и нейронных сетей: от управления банковскими активами до геолого-геофизических исследований. Трудность во всех этих предприятиях совершенно разных отраслей составляют текущие исследования и состояние отрасли для оценки сложности алгоритмов машинного обучения. Задачи искусственного интеллекта связаны с чрезвычайно высокой степенью вычислительной сложности, что требует использования, в первую очередь, новых алгоритмических методов и понимания оценки сложности вычислений [1].

### **Основная часть.**

Существует множество различных подходов к оценке вычислительной эффективности. В статье Аверьяновой Ю. А. и соавторов предложена методика оценки успешности программирования нейронной сети типа многослойного персептрона для выполнения задач классификации изображений и распознавания рукописных цифр [2]. Используя этот метод, можно перейти от многокритериального пространства (частных показателей «затрат») к двумерному пространству, где применяется общий критерий "стоимости" для генерации нейронной сети, решая проблему выбора типа, топологии и процесса обучения нейронной сети и того, как она работает. Для этого пространства используется оптимизация по Парето.

Antonino Laudani и соавторы в своей работе провели тщательный анализ вопроса выбора подходящей функции активации для скрытого слоя многослойной нейронной сети [3]. Функция активации может быть выбрана в соответствии с различными критериями. Отмечено, что наиболее часто используемыми критериями являются эффективность обучения и стоимость вычислений, однако авторы утверждают, что оптимальное соотношение между точностью, пропускной способностью и объемом памяти не может быть обобщено. Таким образом, предполагается, что не существует общепризнанного эталона, который можно было бы использовать для тестирования и сравнения различных решений.

В статье Roi Livni и соавторов исследуются следующие основные вопросы касательно выбора архитектуры нейросетевой модели и формирования выборки данных: вопрос выбора количества обучающих примеров, определение оптимальной функции активации, оценка времени обучения [4].

Вышеперечисленные подходы к оценке вычислительной эффективности имеют ряд недостатков. В первом случае методика ориентирована на решение узкоспециализированной задачи и учитывает специфические показатели качества, в то же время достаточно сложна для вычисления, поскольку ее детальная реализация скрыта от потенциального пользователя. Во втором случае, как и в третьем, отсутствует системность оценки показателей вычислительной эффективности и авторами не предложены подходы, позволяющие в целом обобщить данные показатели в единый критерий.

Таким образом, возникает необходимость формирования единого и универсального критерия оценки алгоритмов с точки зрения выходных результатов и состояния их функционирования. Решением данной проблемы является показатель оценки вычислительной эффективности,

рассчитываемый путем суммы рангов значений отдельных показателей качества и производительности.

В качестве базовых параметров в данной работе используются следующие:

- 1) точность модели алгоритма на тестовой выборке;
- 2) точность модели алгоритма на валидационной выборке;
- 3) время обучения модели алгоритма в секундах;
- 4) время тестирования модели алгоритма в секундах;
- 5) время валидации модели алгоритма в секундах;
- 6) место на диске, занимаемое моделью алгоритма в мегабайтах;
- 7) потребление пространства оперативной памяти моделью алгоритма в мегабайтах;
- 8) процент потребления ресурсов центрального процессора в процессе работы алгоритма в процентах.

Эксперименты проводились при различном количестве входных нейронов, скрытых слоев нейронов, нейронов в скрытом слое; при различном количестве примеров входных данных, вариации объема тестовой выборки, числа базовых решателей (алгоритм “AdaBoost”).

Среди выполненных экспериментов наиболее благоприятным отмечается тот из них, при котором значение суммы рангов измерений (параметров) составляет минимальную величину. Преимуществом данной методики является возможность беспрепятственного добавления других неучтенных показателей и факторов, которые оказывают непосредственное влияние на вычислительную эффективность, без необходимости внесения поправочных коэффициентов и нормировки показателей, а также выполнения громоздких вычислений.

Новизна методики заключается в простоте реализации и возможности расчета во множестве алгоритмов.

**Выводы.** Расчет итогового показателя был выполнен на примере алгоритмов многослойного перцептрона и деревьев решений “AdaBoost” в среде программирования Python при решении задачи классификации. Определено, что наиболее предпочтительным алгоритмом по значению оценки вычислительной эффективности является “AdaBoost”.

Таким образом, использование предлагаемой методики позволяет выбирать оптимальный вариант конфигурации алгоритма.

#### **Список использованных источников:**

1. Baskakov D., Arseniev D. On the computational complexity of deep learning algorithms // Proceedings of International Scientific Conference on Telecommunications, Computing and Control: TELECCON 2019. – Singapore : Springer Singapore, 2021. – pp. 343-356;

2. Аверьянова Ю. А., Емельянов Р. В., Сташенко В. В., Строцев А. А. Оценка эффективности обучения нейронных сетей, реализующих выполнение функций автоматизированных систем управления // I-methods. – 2017. – Т. 9. – №. 4. – С. 32-41. – URL: <https://cyberleninka.ru/article/n/otsenka-effektivnosti-obucheniya-neyronnyh-setey-realizuyuschih-vypolnenie-funktsiy-avtomatizirovannyh-sistem-upravleniya> (дата обращения: 09.01.2023);

3. Laudani A., Lozito G. M., Fulginei F. R., Salvini A. On training efficiency and computational costs of a feed forward neural network: a review. – Text : electronic // Computational intelligence and neuroscience. – 2015. – URL: <https://downloads.hindawi.com/journals/cin/2015/818243.pdf> (date of the application: 08.02.2023);

4. Livni R., Shalev-Shwartz S., Shamir O. On the computational efficiency of training neural networks // Advances in neural information processing systems. – 2014. – vol. 27 – 9 p.

Аристов А.И. (автор)

Туренко С.К. (научный руководитель)