

12. Becker G.S. Human Capital. New York: Columbia University Press, 1964. 534 p.
13. Kotler P., Turner R.E. Marketing Management: Analysis, Planning, Implementation and Control. Scarborough, Ont.: Prentice Hall Canada, 1998. 896 p. URL: <https://archive.org/details/marketingmanagem0000koti/mode/2up> (дата обращения: 03.02.2025).

УДК 004.85:338.3

**БОЙКОВА Анна Викторовна** – профессор, д. э. н., доцент кафедры экономики и управления производством ТвГТУ, Тверь (alexmaria@mail.ru)  
**КУЗНЕЦОВ Кирилл Сергеевич** – магистрант кафедры экономики и управления производством ТвГТУ, Тверь (kirill.kuznetsov.95@yandex.ru)

## **ФАКТОРЫ, ВЛИЯЮЩИЕ НА СТОИМОСТЬ ОБУЧЕНИЯ БОЛЬШИХ ЯЗЫКОВЫХ МОДЕЛЕЙ**

© Бойкова А.В., Кузнецов К.С., 2025

**Аннотация.** Указано, что процесс создания больших языковых моделей сопряжен с трудоемкими операциями, значительными затратами и высокими техническими требованиями. Отмечены проблемы развития данных моделей. Перечислены ключевые факторы, обуславливающие итоговую стоимость модели.

**Ключевые слова:** затраты, модели обучения, искусственный интеллект, обучение моделей, большие языковые модели, капитальные затраты, эксплуатационные затраты, облачные технологии.

**Boikova A.V.** – Professor, Doctor of Economics, Associate Professor of the Department of Economics and Production Management of TvSTU, Tver (alexmaria@mail.ru)

**Kuznetsov K.S.** – Graduate Student of the Department of Economics and Production Management of TvSTU, Tver (kirill.kuznetsov.95@yandex.ru)

## **FACTORS AFFECTING THE COST OF TRAINING LARGE LANGUAGE MODELS**

**Abstract.** It is stated that the process of creating large language models involves time-consuming operations, significant costs and high technical requirements. The problems of the development of these models are noted. The key factors determining the final cost of the model are listed.

**Keywords:** costs, AI learning models, artificial intelligence, AI model training, large language models, capital costs, operating costs, cloud technology.

Модели типа Gemini и GPT-4 произвели революцию во взаимодействии людей с технологиями. С помощью таких моделей можно генерировать текст, улучшать поиск и решать творческие задачи. Данные модели облегчают работу клиентских служб.

Большие языковые модели (Large language models, или LLMs) представляют собой сложные системы, функционирующие на основе глубоких нейронных сетей, создающие и распознающие различные тексты. Они обучаются на огромных объемах данных, включающих сотни миллиардов предложений из открытых источников (интернета и т. п.).

Концепция языковых моделей базируется на прогнозировании вероятной последовательности слов, благодаря чему значительно улучшается способность машин понимать контекст и смысл. Технологии эволюционировали постепенно: сначала они представляли собой системы, основанные на правилах, затем превратились в статистические модели, а потом стали современными нейросетями. Сегодня доминируют трансформеры, которые благодаря глубокому обучению могут производить невероятно точные анализ и генерацию языка [2].

Большие языковые модели, о чем мы вскользь говорили выше, обучаются на значительных объемах данных из разных источников, что позволяет им глубже «понимать» языковые структуры, грамматику и особенности использования языка. Благодаря этому они выполняют широкий спектр задач, имитируя человеческое восприятие. Последнее делает взаимодействие индивида с технологиями более естественным и удобным, чем когда-либо [2].

В 2024 году Стэнфордским университетом была опубликована седьмая редакция отчета о ключевых тенденциях и достигнутых результатах в области искусственного интеллекта AI Index Report 2024 [1]. В нем, в частности, среди проблем развития LLMs эксперты отмечают недостаток информации для их обучения. За последние несколько лет чат-боты, функционирующие на базе искусственного интеллекта, стали крайне прогрессивными. Это стало возможным во многом благодаря тому, что LLMs обучались на все возрастающем количестве источников данных, таких как книги, статьи и т. д. Однако усиливающаяся зависимость моделей искусственного интеллекта от информации привела к возникновению опасений, что будущие поколения исследователей будут испытывать нехватку сведений для дальнейшего масштабирования и совершенствования своих систем [4].

По заявлениям компании Epoch AI, опубликованным в 2022 году, высококачественные языковые данные могут быть полностью исчерпаны к 2024 году, а резерв низкокачественных, согласно прогнозам, будет полностью использован в течение следующих двух десятилетий, ресурсы изображений и графической информации будут потрачены к концу 2030-х или середине 2040-х годов. Одним из решений указанной проблемы может стать обучение LLMs на синтетических данных, которые модели создают самостоятельно. По мнению исследователей из Стэнфордского университета, такой подход не только поможет справиться с возможным истощением данных, но и позволит генерировать информацию там, где ее с самого начала недостаточно [4]. Однако некоторые ученые отмечают, что существуют ограничения, связанные с обучением моделей на синтетических данных. Например, в определенный момент такие LLMs «теряют способность запоминать истинные распределения данных и начинают выдавать узкий диапазон результатов» [4].

Обучение больших языковых моделей, характеризующихся миллионами параметров, требует значительных вычислительных мощностей. В первую очередь последнее связано с необходимостью обрабатывать огромные массивы данных и оптимизировать параметры модели для повышения точности прогнозов. Вычислительные затраты на обучение модели зависят от ряда факторов:

1) объема данных (значительный объем информации, необходимый для обучения, может перегружать вычислительные ресурсы);

2) ограниченности ресурсов (нехватка памяти, дефицит графических процессоров и даже высокие тарифы на электроэнергию могут замедлить обучение);

3) качества данных (является ключевым моментом; плохие или предвзятые сведения могут привести к ошибочным результатам) [6].

Размеры нейронных сетей, используемых в LLMs, растут в геометрической прогрессии. Например, если ранние модели, такие как GPT-2, содержали около 1,5 млрд параметров, что соответствует мозгу небольшого животного (например, медоносной пчелы), то последние модели (допустим, GPT-4) имеют около триллиона параметров, что приближает их по масштабу к человеческому мозгу. Экспоненциальный рост размеров и сложности моделей привели к увеличению затрат на обучение. Так, для моделей типа GPT-3 и PaLM нужен примерно 1 терабайт памяти. С усилением спроса на вычислительные мощности несоответствие между требованиями искусственного интеллекта и возможностями оборудования становится все более очевидным [6].

Увеличение возможностей моделей ведет к росту затрат на их обучение и дальнейшую эксплуатацию [4]. Это вызывает интерес у теоретиков и беспокойство у практиков. Согласно закону Мура,

производительность моделей может повышаться только за счет роста вычислительных мощностей. Однако в то время как потребность в вычислительных ресурсах увеличивается в 10 раз каждый год, производительность оборудования – лишь в 3 раза каждые два года. Этот разрыв приводит к необходимости использовать больше машин, что еще сильнее повышает стоимость обучения, особенно LLMs. Для решения указанной проблемы необходимо искать более экономичные подходы [6].

По мнению директора лаборатории искусственного интеллекта в компании Anthropic Д. Амодя, в ближайшие два года расходы на обучение моделей вышеназванного интеллекта могут достичь примерно 10 млрд долл. [4; 5]. Такие расходы будут по карману только крупным организациям. Если эта тенденция сохранится, то к 2027 году стоимость обучения моделей искусственного интеллекта, согласно прогнозам специалистов Epoch AI, превысит 1 млрд долл. [8]. По их наблюдениям, ежегодные затраты увеличиваются в среднем в 2,4 раза [2]. В связи с этим имеет смысл выделить основные факторы, которые влияют на этот процесс. К таким факторам относятся:

1. Запуск больших языковых моделей (требует огромных вычислительных мощностей; большая часть (47–67 %) совокупных затрат приходится на аппаратное обеспечение (из них на серверные компоненты – 15–22 %; межсоединения на уровне кластера – 9–13 %); 29–49 % составляют расходы на персонал; 2–6 % – затраты на электроэнергию [8]).

2. Использование для обучения LLMs графических процессоров высшего класса, приобретение или аренда которых обходится довольно дорого. По оценке Д. Хуанга, генерального директора NVIDIA, для обучения языковой модели Generative Pre-trained Transformer Mixture of Experts потребовалось привлечь в течение 3–5 месяцев 25 тыс. графических процессоров на базе Ampere [8].

3. Повышение интеллектуальности модели (часто связано с применением крайне сложных архитектур или крупных моделей (например, масштабирование с 7 до 300 млрд параметров) или с одновременным задействованием большего числа экспертов (допустим, в модели Mixture of Experts, или MoE). Очевидно, что такие модели стоят дороже [3]).

4. Количество токенов, которое поступает на вход модели и которое получает пользователь на выходе (оно влияет на время обработки и требуемые вычислительные ресурсы, расход энергии для обработки. Все это в конечном счете вызывает рост затрат [3]).

5. Тип обрабатываемых моделью данных: текст, графика, аудио или видео (он влияет на стоимость; для обработки аудио и видео обычно требуется затратить больше ресурсов, чем для обработки текста [3]).

На данный момент для оценки затрат на обучение моделей искусственного интеллекта, в том числе и больших языковых моделей, используются, как правило, два подхода. В рамках первого из них обучение проводится на собственном или арендованном оборудовании; второго – с применением технологий облачных вычислений. Некоторые ученые пришли к выводу, что величина затрат, определенная согласно второму подходу, обычно намного выше, чем установленная по первому [4].

Таким образом, был рассмотрен инструментарий, позволяющий выяснить, какой из вариантов (локальный вычислительный кластер или облачная инфраструктура) является более экономичным решением для реализации обучения больших языковых моделей.

### **Библиографический список**

1. AI Index Report 2024. URL: <https://hai.stanford.edu/ai-index> (дата обращения: 14.01.2025).
2. Epoch AI: официальный сайт. URL: <https://epoch.ai/> (дата обращения: 14.01.2025).
3. Benram G. Understanding the cost of Large Language Models (LLMs). URL: <https://www.tensorops.ai/post/understanding-the-cost-of-large-language-models-llms> (дата обращения: 14.01.2025).
4. The rising costs of training frontier AI models / B. Cottier, R. Rahman, L. Fattorini, N. Maslej, D. Owen. URL: <https://arxiv.org/html/2405.21015v1#abstract> (дата обращения: 14.01.2025).
5. Grinkevičius P. The cost of training AI models is rising exponentially. URL: <https://cybernews.com/tech/rising-cost-of-training-ai/> (дата обращения: 14.01.2025).
6. Juhasz Z. Quantitative cost comparison of on-premise and cloud infrastructure based EEG data processing. URL: [https://www.researchgate.net/publication/342545255\\_Quantitative\\_cost\\_comparison\\_of\\_on-premise\\_and\\_cloud\\_infrastructure\\_based\\_EEG\\_data\\_processing](https://www.researchgate.net/publication/342545255_Quantitative_cost_comparison_of_on-premise_and_cloud_infrastructure_based_EEG_data_processing) (дата обращения: 14.01.2025).
7. What if Dario Amodei Is Right about A.I.? URL: <https://www.nytimes.com/2024/04/12/opinion/ezra-klein-podcast-dario-amodei.html?showTranscript=1> (дата обращения: 15.01.2025).
8. Luccioni A.S., Viguiet S., Ligozat A.-L. Estimating the Carbon Footprint of BLOOM, a 176B Parameter Language Model. URL: [https://www.researchgate.net/publication/365081230\\_Estimating\\_the\\_Carbon\\_Footprint\\_of\\_BLOOM\\_a\\_176B\\_Parameter\\_Language\\_Model](https://www.researchgate.net/publication/365081230_Estimating_the_Carbon_Footprint_of_BLOOM_a_176B_Parameter_Language_Model) (дата обращения: 15.01.2025).