

Векторизация в технологиях взаимодействия человека и искусственного интеллекта

Павлова Ксения Александровна

обучающаяся – студентка, бакалавриат, 1 курс, Институт экономики и управления, ФГБОУ ВО «Тверской государственный университет» г. Тверь, kсениya.pavlova2007@mail.ru

Пшеничных Ксения Александровна

обучающаяся – студентка, бакалавриат, 1 курс, Институт экономики и управления, ФГБОУ ВО «Тверской государственный университет» г. Тверь, Ksusha.phenitnih@mail.ru

Саркисян Ариана Арсеновна

обучающаяся – студентка, бакалавриат, 1 курс, Институт экономики и управления, ФГБОУ ВО «Тверской государственный университет» г. Тверь, ariano4ka_arsark@mail.ru

Научный руководитель: Васильева Екатерина Васильевна – старший преподаватель кафедры экономической теории, Институт экономики и управления, ФГБОУ ВО «Тверской государственный университет», г. Тверь, (170100, г. Тверь, ул. Желябова, д. 33), Vasileva.EV@tversu.ru, ORCID: 0000-0003-3248-0523, SPIN-код: 3334-9742.

Аннотация: в работе выполнен анализ векторизации данных как технологии, связывающей неструктурированный информационный мир человека (текст, образы, действия) с вычислительной средой искусственного интеллекта (ИИ). Рассматриваются эмбединги как ключевые элементы взаимодействия человека и ИИ. В работе разобрана суть понятия эмбединг и способы создания векторных представлений. Смоделирован пример поиска объектов с помощью векторизации и продемонстрирована необходимость предварительного анализа структуры данных перед выбором метода индексации в векторных базах данных.

Ключевые слова: векторизация, эмбединги, векторные базы данных, метрики семантической близости, нейросеть.

Современные методы анализа многомерных данных, широко применяемые в задачах машинного обучения и обработки естественного языка, базируются на фундаментальных понятиях линейной алгебры: векторных пространствах, эмбедингах и метриках расстояния. Преобразование объектов нечисловой природы – слов, изображений, а также физических артефактов с заданными качественными признаками – в векторы фиксированной

размерности открывает возможность количественного оценивания их семантической или структурной близости. Ключевым инструментом такого оценивания выступает выбор метрики, позволяющей вычислять расстояния между векторами в пространстве признаков. В работе рассматриваются три распространённые меры: евклидово расстояние, манхэттенское расстояние и косинусная близость.

Цель исследования – на примере малой выборки объектов (четыре условные единицы, характеристики которых заданы в четырёхмерном пространстве) проанализировать, как выбор метрики влияет на итоговые оценки близости и кластеризацию данных. Полученные результаты демонстрируют практическую значимость корректного выбора метрики при решении задач индексации, поиска аналогов и классификации в векторных базах данных.

Одно из важнейших понятий векторизации – эмбединг, определяемый как векторное представление или массив вещественных чисел фиксированного размера, в который преобразуются слово, предложение и изображение. Такие преобразования данных необходимы и важны для нейросетей и искусственного интеллекта (ИИ), так как именно благодаря им машины «понимают» семантические и контекстуальные отношения между объектами, отображая их в многомерном векторном пространстве. Каждый элемент вектора кодирует определенные признаки объекта. Размерность эмбединга равняется числу элементов вектора. Векторные представления позволяют словам со схожим значением иметь близкие векторные представления и улавливать смысл человеческих слов [1].

В векторном пространстве выполняются различные операции с векторами: сложение, умножение на число, вычисление расстояния между ними и другие. Для расчета примера применения эмбедингов на практике в технологиях машинного обучения и ИИ в данной работе будет использована операция вычисления расстояния между эмбедингами. Она производится при помощи различных формул: евклидово расстояние, манхэттенское расстояние, косинусная близость, косинусное расстояние.

Каждая из них имеет свои плюсы и минусы при сравнении эмбедингов. Например, минусом евклидового и манхэттенского расстояний является то, что, если все координаты двух векторов практически одинаковы, кроме одной координаты, расстояние между такими векторами может быть большим, поскольку учитывается координатное расстояние [1].

Наиболее целесообразным для оценки близости эмбедингов представляется выбор косинусного расстояния, которое рассчитывает расстояние между векторами, с точки зрения их направления. То есть, если они

направлены в одну сторону, но какая-то координата сильно отличается, расстояние все равно будет относительно близким [1].

В современной практике машинного обучения и систем искусственного интеллекта классификация эмбеддингов осуществляется, прежде всего, по типу кодируемого объекта [2; 3]. Выделяют следующие основные категории.

- Текстовые эмбеддинги (Word и Sentence Embeddings, эмбеддинги слов и предложений) преобразуют отдельные слова или целые предложения в векторы фиксированной размерности. Именно текстовые эмбеддинги впервые позволили моделям машинного обучения фиксировать семантическую близость между лексическими единицами и стали фундаментом для систем обработки естественного языка [2; 4].

- Эмбеддинги изображений, получаемые с помощью свёрточных нейронных сетей (CNN, Convolutional Neural Network) или автоэнкодеров, сжимают визуальную информацию в компактный вектор, сохраняя значимые признаки (формы, текстуры, объекты). Данный подход применяется в задачах классификации изображений, поиска по визуальному сходству и детекции аномалий [3; 5].

- Эмбеддинги для графовых и последовательных структур. Графовые эмбеддинги представляют узлы и связи графа в виде векторов, что востребовано в рекомендательных системах, анализе социальных сетей и биоинформатике. Эмбеддинги последовательностей используются для анализа временных рядов, музыкальных последовательностей и поведенческих паттернов пользователей [3].

Таким образом, классификация эмбеддингов отражает не только разнообразие данных, но и эволюцию подходов к их машинной интерпретации – от изолированных слов до сложных мультимодальных и реляционных структур [5].

Эволюция технологий получения эмбеддингов наглядно демонстрирует прогресс в области обработки естественного языка и глубинного обучения.

Исторически первым упрощённым методом выступила модель «мешка слов» (Bag-of-Words), где каждому слову ставилось в соответствие число его вхождений, а порядок слов не учитывался. Дальнейшим этапом стала рекуррентная нейросетевая языковая модель (RNNLM, Recurrent Neural Network Language Model). Однако RNNLM обладала двумя существенными недостатками: высокой вычислительной стоимостью при работе с большими словарями и ограниченной способностью учитывать долгосрочный контекст [6; 7].

Переломным моментом стала модель BERT (Bidirectional Encoder Representations from Transformers), предложенная Google. В отличие от предшественников, обрабатывает последовательность слов не линейно, а одномоментно целиком, что позволяет учитывать контекст слова с обеих

сторон. В основе BERT лежит архитектура трансформера и механизм «внимания», который динамически взвешивает значимость слов друг относительно друга. Данное решение значительно повысило качество в задачах семантического анализа, вопросно-ответных систем и машинного перевода и сделало BERT первой по-настоящему двунаправленной моделью [8; 9; 10].

Вслед за BERT появились модели GPT (Generative Pre-trained Transformer), RoBERTa, DistilBERT, мультимодальные архитектуры, а также методы FastText, учитывающие субсловные единицы (n-граммы) [6].

Но эмбединги нужно не только создавать, но и хранить. Для этого используются векторные базы данных (ВБД), то есть базы данных, оптимизированные под хранение и поиск векторов [12].

Принцип работы ВБД заключается в следующем. Сначала для всех данных создаются эмбединги с помощью модели обработки изображений или текста (например, CLIP, BERT).

Далее векторы индексируют, что упрощает извлечение данных путем эффективной организации векторных вложений. Используется метод ближайших соседей для предварительного расчета расстояний между векторными вложениями, кластеризации схожих векторов и их хранения вблизи друг от друга. Хотя этот подход жертвует некоторой точностью ради скорости, он позволяет более быстро извлекать приблизительные результаты. Например, в векторной базе данных можно предварительно рассчитать кластеры, такие как "животные" и "фрукты". При запросе базы данных на "Котенка" поиск начинается с ближайших животных, избегая расчетов расстояний между фруктами и объектами, не относящимися к животным. Алгоритм начинает поиск в соответствующем регионе, таком как четырехногие животные, поддерживая близость к соответствующим результатам благодаря предварительно организованному сходству [11].

Следующий этап, векторный поиск, происходит по метрикам для оценки расстояния между ними с целью определения семантической близости между соответствующими объектами.

Эмбединги используются в самых разных областях, от финансов до робототехники. В работе рассмотрен пример с оценкой семантической близости векторов из области рекомендательных систем для моделирования примера.

В работе рассмотрена модель сравнительного анализа близости эмбедингов на примере четырёхмерного пространства объектов – чашек, где 4 – количество ключевых признаков объекта, по которым задаются координаты. Размерный ряд для координат принимается равным от 1 до 5.

Ключевые признаки:

1 признак – материал, где глина обозначена цифрой 1, а фарфор цифрой 5;

2 признак – расцветка, где 1 – однотонная, 5 – содержащая несколько цветов;

3 признак – форма, где 1 – классическая без изменений, 5 – имеющая явные выпуклые изменения корпуса;

4 признак – объем, где 1 – 200 мл, 5 – 350 мл.

Для модели выбраны несколько чашек на просторах интернета [13–16], представленных на рис. 1–4.



Рис. 1. Объект А



Рис. 2. Объект В



Рис. 3. Объект Б



Рис. 4. Объект Г

Рис. 1-4. Модель сравнительного анализа близости эмбедингов на примере четырёхмерного пространства объектов

Заданные параметры для объектов, представленных на рис. 1–4, представлены в табл. 1.

Таблица 1

Параметры по каждому признаку для 4 объектов

№	Название	Материал	Расцветка	Форма	Объем
1	А	1	3	3	1
2	Б	2	1	1	2
3	В	5	1	4	5
4	Г	2	5	5	3

Таким образом, эмбединги принимают следующий вид: А (1, 3, 3, 1); Б (2, 1, 1, 2); В (5, 1, 4, 5); Г (2, 5, 5, 3).

Далее рассчитывается их расположение по формулам евклидова, манхэттенского расстояния и косинусной близости:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad \text{— евклидово расстояние (1.1).}$$

$$d(A, B) = \sqrt{\sum_{i=1}^4 (a_i - b_i)^2} = \sqrt{2 \times (1-2)^2 + 2 \times (3-1)^2} = \sqrt{10} = 3,16;$$

$$d(A, B) = \sqrt{\sum_{i=1}^4 (a_i - b_i)^2} = \sqrt{2 \times (1-5)^2 + (3-1)^2 + (3-4)^2} = \sqrt{37} = 6,08;$$

$$d(A, \Gamma) = \sqrt{\sum_{i=1}^4 (a_i - \gamma_i)^2} = \sqrt{(1-2)^2 + 2 \times (3-5)^2 + (1-3)^2} = \sqrt{13} = 3,6;$$

$$d(B, B) = \sqrt{\sum_{i=1}^4 (b_i - b_i)^2} = \sqrt{2 \times (2-5)^2 + (1-1)^2 + (1-4)^2} = \sqrt{27} = 5,196;$$

$$d(B, \Gamma) = \sqrt{\sum_{i=1}^4 (b_i - \gamma_i)^2} = \sqrt{2 \times (1-5)^2 + (2-2)^2 + (3-4)^2} = \sqrt{33} = 5,74;$$

$$d(B, \Gamma) = \sqrt{\sum_{i=1}^4 (b_i - \gamma_i)^2} = \sqrt{(1-5)^2 + (5-2)^2 + (4-5)^2 + (5-3)^2} = \sqrt{30} = 5,48.$$

Так, по формуле 1.1 наиболее близкие векторы А и Б, а наиболее далекие А и В.

$$d(x, y) = \sum_{i=1}^n |x_i - y_i| \quad \text{— манхэттенское расстояние (1.2).}$$

$$d(A, B) = \sum_{i=1}^4 |a_i - b_i| = |1-2| \times 2 + |3-1| \times 2 = 6,$$

$$d(A, B) = \sum_{i=1}^4 |a_i - b_i| = |1-5| \times 2 + |3-1| + |3-4| = 11,$$

$$d(A, \Gamma) = \sum_{i=1}^4 |a_i - \gamma_i| = |3-5| \times 2 + |1-2| + |1-3| = 7,$$

$$d(B, B) = \sum_{i=1}^4 |b_i - b_i| = |2-5| \times 2 + |1-1| + |1-4| = 9,$$

$$d(B, \Gamma) = \sum_{i=1}^4 |b_i - \gamma_i| = |1-5| \times 2 + |2-2| + |3-4| = 9,$$

$$d(B, \Gamma) = \sum_{i=1}^4 |b_i - \gamma_i| = |1-5| + |5-2| + |4-5| + |5-3| = 10.$$

Из результата расчётов по формуле 1.2 следует, что наиболее близкие и далекие пары сохранились, но поменялись промежуточные значения, например, расстояния между Б и Г, Б и В одинаковы, а отдаленность В и Г почти сравнялась с А и В.

$$\cos(x, y) = \frac{\sum_{i=1}^n x_i \times y_i}{\sqrt{\sum_{i=1}^n (y_i)^2} \times \sqrt{\sum_{i=1}^n (x_i)^2}} \quad \text{— косинусная близость (1.3).}$$

$$\cos(A, B) = \frac{\sum_{i=1}^4 a_i \times b_i}{\sqrt{\sum_{i=1}^4 (a_i)^2} \times \sqrt{\sum_{i=1}^4 (b_i)^2}} = \frac{2 \times 1 \times 2 + 2 \times 3 \times 1}{\sqrt{1 \times 2 + 9 \times 2} \times \sqrt{1 + 1 + 8}} = 0,71;$$

$$\cos(A, B) = \frac{\sum_{i=1}^4 a_i \times b_i}{\sqrt{\sum_{i=1}^4 (a_i)^2} \times \sqrt{\sum_{i=1}^4 (b_i)^2}} = \frac{2 \times 1 \times 5 + 3 \times 1 + 3 \times 4}{\sqrt{1 \times 2 + 9 \times 2} \times \sqrt{25 + 25 + 17}} = 0,68;$$

$$\cos(A, \Gamma) = \frac{\sum_{i=1}^4 a_i \times z_i}{\sqrt{\sum_{i=1}^4 (a_i)^2} \times \sqrt{\sum_{i=1}^4 (z_i)^2}} = \frac{2 \times 3 \times 5 + 2 \times 1 + 1 \times 3}{\sqrt{1 \times 2 + 9 \times 2} \times \sqrt{25 + 25 + 9 + 4}} = 0,98;$$

$$\cos(B, B) = \frac{\sum_{i=1}^4 b_i \times b_i}{\sqrt{\sum_{i=1}^4 (b_i)^2} \times \sqrt{\sum_{i=1}^4 (b_i)^2}} = \frac{2 \times 2 \times 5 + 1 \times 1 + 1 \times 4}{\sqrt{2 \times 4 + 1 \times 2} \times \sqrt{25 + 25 + 17}} = 0,96;$$

$$\cos(B, \Gamma) = \frac{\sum_{i=1}^4 b_i \times z_i}{\sqrt{\sum_{i=1}^4 (b_i)^2} \times \sqrt{\sum_{i=1}^4 (z_i)^2}} = \frac{2 \times 1 \times 5 + 2 \times 2 + 2 \times 3}{\sqrt{2 \times 4 + 1 \times 2} \times \sqrt{25 + 25 + 9 + 4}} = 0,797;$$

$$\cos(B, \Gamma) = \frac{\sum_{i=1}^4 b_i \times z_i}{\sqrt{\sum_{i=1}^4 (b_i)^2} \times \sqrt{\sum_{i=1}^4 (z_i)^2}} = \frac{2 \times 5 + 1 \times 5 + 4 \times 5 + 5 \times 3}{\sqrt{25 + 25 + 17} \times \sqrt{25 + 25 + 9 + 4}} = 0,769.$$

Исходя из расчетов по формуле 1.3, наиболее близкие векторы А и В, наиболее далекие А и Г. Значит, формула 1.3 дает результат, разительно отличающийся от двух предыдущих.

Сравнительный анализ расстояний между эмбедингами по нескольким формулам метрик в приведённом примере показывает, что выбор метрики расстояния между векторами существенно влияет на определение семантической близости объектов в многомерном пространстве признаков. Евклидово и манхэттенское расстояния, учитывающие абсолютные значения координат, дали сходные результаты по идентификации наиболее близкой пары векторов А и Б, однако показали различную чувствительность к промежуточным значениям и координатным выбросам. Косинусная близость, ориентирующаяся на угол между векторами, а не на их модули, привела к принципиально иному ранжированию пар, в частности, определив векторы А и Г как наиболее удалённые. Это подтверждает теоретическое положение о том, что выбор метрики должен определяться конкретной задачей: при анализе направленности признаков предпочтительно использовать косинусные меры,

тогда как для оценки абсолютных различий – метрики на основе норм L1 или L2. Практическая значимость работы заключается в демонстрации необходимости предварительного анализа структуры данных перед выбором метода индексации в векторных базах данных.

Список литературы

1. Максимов М. Что такое эмбединги и как с ними работать. [Электронный ресурс]: Habr.com // URL: <https://habr.com/ru/articles/947216/> (дата обращения 25.11.25).
2. Эмбединги: что это и зачем нужны. [Электронный ресурс]: Habr.com // URL: <https://habr.com/ru/companies/otus/articles/787116/> (дата обращения: 26.04.2026).
3. Эмбединги: полная энциклопедия [Электронный ресурс]: Habr.com // URL: <https://textarget.ru/encyclopedia/jembedding/> (дата обращения: 26.04.2026).
4. Word Embeddings: векторные представления слов. [Электронный ресурс]: Deep Machine Learning // URL: <https://deeptomachinelearning.ru/docs/Neural-networks/Embeddings/Word-embeddings> (дата обращения: 26.04.2026).
5. Как нейросети понимают изображения. [Электронный ресурс]: RBC Trends // URL: <https://trends.rbc.ru/trends/industry/6893388d9a7947bb1f3eb830> (дата обращения: 26.04.2026).
6. Обзор четырёх популярных NLP-моделей. [Электронный ресурс]: Proglib // URL: <https://proglib.io/p/obzor-chetyreh-populyarnyh-nlp-modeley-2020-04-21> (дата обращения: 26.04.2026).
7. Recurrent neural network-based language model (RNNLM) [Электронный ресурс]: SpringerOpen // URL: <https://asmp-eurasipjournals.springeropen.com/articles/10.1186/1687-4722-2013-220> (дата обращения: 26.04.2026).
8. BERT (языковая модель). [Электронный ресурс]: Рувики // URL: [https://ru.ruwiki.ru/wiki/BERT_\(языковая_модель\)](https://ru.ruwiki.ru/wiki/BERT_(языковая_модель)) (дата обращения: 26.04.2026).
9. BERT: как работает языковая модель Google. [Электронный ресурс]: Наука и жизнь. // URL: <https://www.nkj.ru/open/36052/> (дата обращения: 26.04.2026).
10. Трансформеры и механизм внимания. [Электронный ресурс]: Habr. com // URL: <https://habr.com/ru/companies/otus/articles/702838/> (дата обращения: 26.04.2026).
11. Нахождение объекта на картинках. [Электронный ресурс]: Блог компании Joom. // URL: <https://habr.com/ru/companies/joom/articles/445354/> (дата обращения 19.04.2026).
12. Векторизация. [Электронный ресурс]: Глоссарий Contented. // URL: <https://media.contented.ru/glossary/vektORIZatsiya/> (дата обращения 12.03.2026).
13. Чайная пара DB НОММЕ "Сердечки", керамическая, использование в СВЧ, 1 персоны, красная. [Электронный ресурс]: Яндекс Маркет

- // URL: <https://market.yandex.ru/card/chaynaya-para-db-homme-serdechki-keramicheskaya-ispolzovaniye-v-svch-1-persony-krasnaya/5029518913?do-waremd5=nF1A3olmLQaAnB0yXizHLw&ogV=-12> (дата обращения 12.04.2026).
14. 1 шт. Креативная кофейная кружка. Чисто белая керамическая кружка. Чайная кружка. Кружка для молока. Кофейная чашка. Уникальный неровный дизайн. Фарфоровая кружка. Подарок. [Электронный ресурс]: Joom.ru
// URL: https://www.joom.ru/ru/products/68f8bdbea15af7014d8813c1?variant_id=68f8bdbea15af7944d8813c6 (дата обращения 12.04.2026).
15. Кружка черная, керамическая. [Электронный ресурс]: Ozon
// URL: https://www.ozon.ru/product/chashka-kofeynaya-250-ml-1-sht-1394183811/?rr=1&abt_att=1&origin_referer=yandex.ru&sh=T65uKdtxQ (дата обращения 12.04.2026).
16. 280/300 мл Flower Mark керамическая чашка и тарелка набор. Винтажная тюльпановая кофейная чашка. [Электронный ресурс]: Joom.ru
// URL: https://www.joom.ru/ru/products/66c7db812bd1cc0165ec9a37?variant_id=66c7db812bd1ccf765ec9a3b
(дата обращения 12.04.2026).

Vectorization in human–computer interaction technologies

Pavlova Ksenia Alexandrovna

student – student, undergraduate, 1st year, Institute of Economics and Management, FGBOU VO "Tver State University," Tver, kseniya.pavlova2007@mail.ru

Pshenichnykh Ksenia Alexandrovna

student – student, undergraduate, 1st year, Institute of Economics and Management, FGBOU VO "Tver State University," Tver, Ksusha.phenitnih@mail.ru

Sarksyan Ariana Arsenovna

student – student, undergraduate, 1st year, Institute of Economics and Management, FGBOU VO "Tver State University," Tver, ariano4ka_arsark@mail.ru

Supervisor: Vasilyeva Ekaterina Vasilievna – Senior Lecturer, Department of Economic Theory, Institute of Economics and Management, FGBOU VO "Tver State University," Tver, (170100, Tver, ul. Zhelyabova, 33), e-mail: Vasileva.EV@tversu.ru, ORCID: 0000-0003-3248-0523, SPIN-код: 3334-9742.

Abstract: The paper analyzes data vectorization as a technology that connects the unstructured information world of humans (text, images, and actions) with the computational environment of artificial intelligence (AI). It examines embeddings as key elements of human–AI interaction. The paper explores the concept of embeddings and the methods of creating vector representations. It simulates an example of object search using vectorization and demonstrates the need for preliminary data structure analysis before selecting an indexing method in vector databases.

Keywords: *vectorization, embeddings, interactions, features, technologies, artificial intelligence, neural network.*

About the authors:

PAVLOVA Ksenia Alexandrovna – student, undergraduate, 1st year, Institute of Economics and Management, FGBOU VO "Tver State University," Tver, kseniya.pavlova2007@mail.ru

PSHENICHNYKH Ksenia Alexandrovna – student, undergraduate, 1st year, Institute of Economics and Management, FGBOU VO "Tver State University," Tver, Ksusha.phenitnih@mail.ru

SARKSYAN Ariana Arsenovna – student, undergraduate, 1st year, Institute of Economics and Management, FGBOU VO "Tver State University," Tver, ariano4ka_arsark@mail.ru

About the research supervisor:

VASILYEVA Ekaterina Vasilievna – Senior Lecturer, Department of Economic Theory, Institute of Economics and Management, FGBOU VO "Tver State University," Tver, (170100, Tver, ul. Zhelyabova, 33), e-mail: Vasileva.EV@tversu.ru, ORCID: 0000-0003-3248-0523, SPIN-код: 3334-9742.

Дата поступления рукописи в редакцию 05.12.2025.

Дата принятия в печать 10.05.2026