

19. SOLIDWORKS is the Proven Solution for 3D CAD and Product Development. – Режим доступа: www.solidworks.com, свободный. – Заглавие с экрана. – Яз. англ.

20. Мэтьюз, Д. Г. Численные методы. Использование MATLAB = Numerical Methods: Using MATLAB / Д. Г. Мэтьюз, К. Д. Финк. – 3-е изд. – Москва : Вильямс, 2001. – 720 с.

21. Лобанов Д. К. Моделирование технических систем в Comsol Multiphysics. Практикум для студентов специальности 24.05.06 «Системы управления летательными аппаратами» очной формы обучения : учебное пособие / Д. К. Лобанов, Т. Г. Орешенко. – Красноярск : СибГУ им. академика М. Ф. Решетнева, 2023. – 70 с.

22. Abaqus: Finite Element Analysis for Mechanical Engineering and Civil Engineering. – Режим доступа: <https://www.3ds.com/products/simulia/abaqus>, свободный. – Заглавие с экрана. – Яз. англ.

© A. V. Sinelshchikov, Ye. V. Ponomareva, O. A. Khokhlova

Ссылка для цитирования:

Sinelshchikov A. V., Ponomareva Ye. V., Khokhlova O. A. Application of computer modeling in the study of mechanics // Инженерно-строительный вестник Прикаспия : научно-технический журнал / Астраханский государственный архитектурно-строительный университет. Астрахань: ГБОУ АО ВО «АГАСУ», 2025. № 3 (53). С. 81–87.

УДК 004.85

DOI 10.52684/2312-3702-2025-53-3-87-92

КОМПОЗИТНАЯ МЕТРИКА ЭМОЦИОНАЛЬНОЙ КОГЕРЕНТНОСТИ В СИСТЕМАХ ИЗВЛЕЧЕНИЯ КОНТЕКСТА

В. А. Наумушкин, В. А. Павлов

Наумушкин Василий Анатольевич, аспирант, Московский финансово-юридический университет, г. Москва, Российская Федерация, тел.: + 7 (980) 173-81-54; e-mail: naumushv@gmail.com; 29347568@s.mfua.ru;

Павлов Валерий Анатольевич, кандидат экономических наук, доцент кафедры «Информационные системы и технологии», Московский финансово-юридический университет, г. Москва, Российская Федерация; e-mail: naumushv@gmail.com; 29359332@s.mfua.ru

Исследование посвящено совершенствованию метрик релевантности эмоционального контекста в системах извлечения контекста для Retrieval-Augmented Generation. Современные подходы фокусируются на семантическом сходстве текстов, пропуская эмоциональную составляющую, когерентность, что критично для задач наиболее точного поиска в эмоционально окрашенных данных. Предложена композитная метрика, объединяющая семантическое сходство векторных эмбедингов и эмоциональную когерентность, оцениваемую как косинусное сходство текстов. Описана методология вычисления компонент метрики и их взвешивания, на основе которой проведен ряд экспериментов с целью выяснения способности предложенной метрики находить текст более точно, чем модель, основывающаяся на поиске только семантической составляющей. Оценка эффективности проведена на сэмплированном подмножестве датасета Stanford Sentiment Treebank 2 (SST-2). Композитная метрика продемонстрировала более высокую эффективность по метрикам Precision@5, Recall@5, NDCG@5 и MAP по сравнению с методами поиска, основанными исключительно на семантической составляющей. Проведенные эксперименты показали значительный прирост метрик для позитивных и негативных запросов. Проведен дальнейший анализ влияния коэффициентов предложенной метрики. При рассмотрении полученных результатов было установлено, что учет эмоциональной когерентности необходим для достижения оптимальной производительности метрики.

Ключевые слова: машинное обучение, обработка естественного языка, языковые модели, метрики обработки естественного языка, LLM, эмбединги.

A COMPOSITE METRIC FOR EMOTIONAL COHERENCE IN CONTEXT EXTRACTION SYSTEMS

V. A. Naumushkin, V. A. Pavlov

Naumushkin Vasiliy Anatolyevich, postgraduate student, Moscow Finance and Law University, Moscow, Russian Federation, phone: + 7 (980) 173-81-54; e-mail: naumushv@gmail.com; 29347568@s.mfua.ru;

Pavlov Valeriy Anatolyevich, Candidate of Economic Sciences, Associate Professor of Information Systems and Technologies Department, Moscow Finance and Law University, Moscow, Russian Federation; e-mail: naumushv@gmail.com; 29359332@s.mfua.ru

The research focuses on improving emotional context relevance metrics in context extraction systems for Retrieval-Augmented Generation (RAG) systems. Current approaches focus on semantic similarity of texts, missing the emotional component, coherence, which is critical for the task of the most accurate retrieval in emotionally colored data. We propose a composite metric that combines semantic similarity of vector embeddings and emotional coherence, evaluated as the cosine similarity of texts. A methodology for computing the components of the metric and weighting them is described, based on which a series of experiments were conducted to find out the ability of the proposed metric to find text more accurately than a model based on semantic component search alone. Performance evaluation was performed

on a sampled subset of the Stanford Sentiment Treebank 2 (SST-2) dataset. The composite metric demonstrated higher performance on Precision@5, Recall@5, NDCG@5, and MAP metrics compared to search methods based solely on the semantic component. The conducted experiments showed significant gains in metrics for positive and negative queries. Further analysis about the impact of the coefficients of the proposed metric was done. The results were analyzed and it was found that taking into account emotional coherence is necessary to achieve optimal performance of the metric.

Keywords: machine learning, natural language processing, language models, natural language processing metrics, LLM, embeddings.

Введение

Исследования показывают, что эмоциональная составляющая играет существенную роль в информационно-поисковом поведении пользователей [1]. И. В. Абакумова и ее соавторы отмечают влияние эмоциональных состояний на восприятие и обработку информации [2], а работы в области когерентности демонстрируют важность согласованности эмоциональных паттернов для эффективной коммуникации [3]. В контексте информационного поиска эмоциональная окраска контента оказывает значительное влияние на релевантность результатов [4].

Современные методы RAG, основанные на семантических моделях, не учитывают в явном виде эмоциональную когерентность между запросом и извлекаемыми документами. Мокалаза и соавторы продемонстрировали эффективность включения эмоциональной составляющей в системы вопросно-ответного поиска [5], а исследование эмоционального RAG показало улучшение качества взаимодействия с пользователем в ролевых агентах [6]. Подходы к распознаванию эмоций в диалоговых системах также подтверждают важность учета распределения эмоциональных состояний [7].

Объект исследования – процесс извлечения контекста в системах RAG с учетом эмоциональной когерентности.

Цель исследования – разработка композитной метрики, объединяющей семантическое сходство и эмоциональную когерентность, для повышения релевантности извлекаемого контекста в RAG-системах.

Задачи исследования:

- 1) определить понятие эмоциональной когерентности в контексте извлечения текста;
- 2) предложить метод количественной оценки эмоциональной когерентности;
- 3) интегрировать эту меру эмоциональной когерентности с существующими метриками семантического сходства для формирования композитной метрики;
- 4) оценить производительность композитной метрики по сравнению с традиционными методами, основанными только на семантическом сходстве, на датасете Stanford Sentiment Treebank 2 (SST-2).

Актуальность исследования

Многие практические применения RAG-систем, такие как чат-боты для обслуживания клиентов, инструменты поддержки психического

здоровья и анализ социальных сетей, работают с эмоционально окрашенным текстом, позволяет повысить контекстуальную уместность и опыт пользователей, открывает новые возможности в клиентской аналитике. Исследование фундаментально улучшает алгоритмы RAG за счет учета эмоционального контекста.

Математическая формализация проблемы

Проблему отсутствия эмоциональной составляющей в RAG-системах можно представить следующим образом. Пусть q – пользовательский запрос, а d – документ из корпуса D . Традиционная модель ранжирования в RAG-системах основана на функции релевантности $R(q, d)$, которая определяется как семантическое сходство:

$$R(q, d) = Sim_{sem}(q, d), \quad (1)$$

где Sim_{sem} – функция семантического сходства, например, косинусное сходство между векторными представлениями или функция лексического сходства типа BM25.

Данная формулировка не учитывает эмоциональную когерентность между запросом и документом. Предлагаем расширить функцию релевантности:

$$R'(q, d) = \alpha \times Sim_{sem}(q, d) + (1 - \alpha) \times Coh_{emo}(q, d), \quad (2)$$

где Coh_{emo} – функция эмоциональной когерентности, $\alpha \in [0, 1]$ – коэффициент, регулирующий баланс между семантическим сходством и эмоциональной когерентностью.

Эмоциональную когерентность определим через сходство распределений эмоциональных профилей запроса E_q и документа E_d :

$$Coh_{emo}(q, d) = Sim(E_q, E_d), \quad (3)$$

где E_q и E_d – векторы эмоциональных профилей, элементы которых соответствуют различным эмоциональным категориям, а Sim – функция сходства распределений, например, косинусное сходство или расстояние Кульбака – Лейблера.

Анализ модели BM25

BM25 является одной из наиболее эффективных классических моделей информационного поиска [8]. Данная модель оценивает релевантность документа запросу на основе частоты встречаемости терминов в документе с учетом их редкости в коллекции.

Формула BM25 для оценки релевантности документа d запросу q :

$$BM25(q, d) = \sum_{t \in q} IDF(t) \times \frac{f(t, d) \times (k_1 + 1)}{f(t, d) + k_1 \times (1 - b + b \times \frac{|d|}{avgdl})}, \quad (4)$$

где t – термин из запроса q ; $f(t, d)$ – частота термина t в документе d ; $|d|$ – длина документа в терминах; $avgdl$ – средняя длина документа в коллекции; k_1 и b – параметры (обычно $k_1 \in [1.2, 2.0]$, $b = 0.75$); $IDF(t)$ – обратная документная частота термина t , вычисляемая как I :

$$DF(t) = \log \left(\frac{N - n(t) + 0.5}{n(t) + 0.5} \right), \quad (5)$$

где N – общее количество документов в коллекции, $n(t)$ – количество документов, содержащих термин t .

BM25 эффективно оценивает лексическое сходство между запросом и документом, но не учитывает эмоциональную окраску терминов. Рагхаван и Джонсон представляют модификацию оценки term frequency (TF) с учетом сентимента, что является шагом к интеграции эмоциональной составляющей в системы поиска [9]. Как можно заметить, в формуле отсутствует коэффициент, как-либо учитывающий эмоциональную составляющую, что приводит к низкой точности к текстам, где учет этой составляющей критичен.

Метод

Разработанная композитная метрика основывается на взвешенной комбинации двух ключевых компонентов: семантического сходства и эмоциональной когерентности. Для заданного запроса q и потенциально релевантного документа d , композитная оценка $S_{composite}(q, d)$ вычисляется по формуле:

$$S_{composite}(q, d) = \alpha \cdot S_{semantic}(q, d) + \beta \cdot S_{emotional}(q, d), \quad (6)$$

где α и β – весовые коэффициенты, определяющие относительную важность семантического и эмоционального компонентов ($\alpha, \beta \in [0, 1]$, $\alpha + \beta = 1$). В рамках экспериментальной оценки для базового сравнения было использовано сочетание $\alpha = 0.7$ и $\beta = 0.3$. Анализ влияния весовых коэффициентов проводился путем варьирования α в диапазоне от 0.0 до 1.0 с шагом 0.1.

Семантическое сходство $S_{semantic}(q, d)$ рассчитывается как косинусное сходство между векторными представлениями (эмбедами) запроса q и документа d . Для получения этих эмбеддингов использовалась предобученная модель sentence-transformers/all-MiniLM-L6-v2, способная эффективно кодировать смысл предложений в плотные векторы фиксированной размерности.

$S_{semantic}(q, d) = \cos \sim (Emb(q), Emb(d))$, (7) где $Emb()$ – функция получения эмбеда текста с использованием выбранной модели.

Эмоциональная когерентность $S_{emotional}(q, d)$ [10] оценивает, насколько совпадают эмоциональные характеристики запроса и документа. Этот компонент требует предварительного определения эмоциональных профилей для q и d . Эмоциональный профиль текста представляет собой вектор вероятностей принадлежности текста к раз-

личным эмоциональным категориям. Для получения этих профилей использовалась модель классификации текста j-hartmann/emotion-english-distilroberta-base [11], обученная на наборе эмоциональных категорий. Данная модель возвращает распределение вероятностей по всем предопределенным эмоциям [12]. Если модель распознает N -эмоций, эмоциональный профиль текста x представляется вектором $P_x = [p_1, p_2, \dots, p_N]$, где p_i – вероятность того, что текст x выражает i -ю эмоцию и $\sum_{i=1}^N p_i = 1$.

Эмоциональная когерентность $S_{emotional}(q, d)$ затем вычисляется как косинусное сходство между векторами эмоциональных профилей запроса и документа:

$$S_{emotional}(q, d) = \cosine_similarity(P_q, P_d), \quad (8)$$

где P_q и P_d – эмоциональные профили запроса и документа соответственно. Такой подход позволяет оценить выравнивание не только доминирующей эмоции, но и всего спектра эмоциональных оттенков, выраженных в текстах. Математически косинусное сходство между векторами профилей P_q и P_d в N -мерном эмоциональном пространстве определяется как:

$$\begin{aligned} cosine_similarity(P_q, P_d) &= \frac{P_q \cdot P_d}{\|P_q\| \|P_d\|} = \\ &= \frac{\sum_{i=1}^N p_{q,i} \cdot p_{d,i}}{\sqrt{\sum_{i=1}^N p_{q,i}^2} \sqrt{\sum_{i=1}^N p_{d,i}^2}}. \end{aligned} \quad (9)$$

Таким образом, композитная метрика $S_{composite}(q, d)$ объединяет оценку смыслового совпадения (на основе семантических эмбеддингов) и оценку согласованности эмоциональных распределений (на основе эмоциональных профилей).

Экспериментальная оценка проводилась на подмножестве датасета Stanford Sentiment Treebank 2 (SST-2) [13]. Датасет SST-2 является стандартизированным ресурсом для бинарной классификации тональности текста, основанным на предложениях из рецензий к фильмам, размеченных как позитивные или негативные. Полный датасет содержит более 67 тыс. обучающих, 872 валидационных и 1821 тестовых примеров предложений. В данном исследовании было использовано подмножество, выбранное случайным образом размером в 10000 предложений, а для тестирования метрик извлечения было выбрано около 20 тестовых запросов из валидационной части SST-2.

Эффективность метрик извлечения (семантической и композитной) оценивалась с использованием стандартных метрик информационного поиска: Precision@k (P@k), Recall@k (R@k), Normalized Discounted Cumulative Gain @ 5 (NDCG@5) и Mean Average Precision (MAP) [14-16]. P@k измеряет долю релевантных документов среди первых k извлеченных, R@k – долю найденных релевантных документов среди всех

релевантных, NDCG@5 определяет качество ранжирования первых пяти результатов с учетом их позиции, а MAP усредняет метрику точности в точках, где были найдены релевантные документы, по всем запросам.

Результаты и обсуждение

Экспериментальная оценка проводилась путем построения простой RAG-системы с индексом, содержащим сэмпированное подмножество документов из датасета SST-2. Для каждого тестового запроса система выполняла извлечение документов, ранжируя их либо по чисто семантическому сходству (базовая линия), либо по предложенной композитной метрике. Коэффициенты, на которых была произведена оценка, выбраны эмпирическим путем $\alpha = 0.7, \beta = 0.3$. Полученные ранжированные списки сравнивались с истинными метками для вычисления метрик эффективности.

Сравнительный анализ усредненных метрик извлечения для всех тестовых запросов (таблица результатов не представлена полностью в тексте статьи) показал, что композитная метрика с ве-

сами $\alpha = 0.7, \beta = 0.3$ превзошла базовую семантическую по всем стандартным показателям эффективности информационного поиска. Наиболее существенный прирост наблюдался в метриках, оценивающих качество первых результатов ранжирования. Например, Precision@5 увеличился с 0.5200 (семантическая метрика) до 0.6600 (композитная), что соответствует относительному приросту на 26.9 %. NDCG@5, показатель, чувствительный к позициям релевантных документов в топе, также продемонстрировал значительное улучшение. Он вырос с 0.5191 до 0.6405, что составляет прирост на 23.4 %. Улучшение показателей Recall@k при $k = 5$ и $k = 10$ (прирост на 27.1 и 11.7 % соответственно) указывает на то, что композитная метрика позволяет находить больше релевантных документов в топ-листе. Общий показатель MAP также показал рост с 0.5025 до 0.5354 (+6.6 %).

Дальнейший анализ эффективности проводился с разбивкой по оригинальным типам запросов (позитивные и негативные в рамках SST-2). Результаты сравнения NDCG@5 для различных типов запросов представлены на рисунке 1.




Рис. 1. Сравнение NDCG@5 для различных типов запросов (иллюстрация авторов)

Fig. 1. Comparison of NDCG@5 for different query types (illustration by the authors)

Как видно на рисунке 1, предлагаемая метрика (с $\alpha = 0.7, \beta = 0.3$) показывает более высокие значения NDCG@5 как для «негативных», так и для «позитивных» запросов по сравнению с чисто семантическим подходом. Это подтверждает гипотезу о том, что учет эмоциональной когерентности особенно важен для эмоционально окрашенных запросов. Прирост NDCG@5 для позитивных запросов (с 0.5771 до 0.7306) составил 26.6 %, а для негативных (с 0.4804

до 0.5805) – 20.8 %. Хотя оба типа запросов выиграли от композитного подхода, позитивные показали несколько больший относительный прирост в данном эксперименте.

Для исследования влияния весовых коэффициентов α и β на производительность композитной метрики была проанализирована зависимость NDCG@5 от значения α (при $\beta = 1 - \alpha$) для различных типов запросов. Результаты представлены на рисунке 2.




Рис. 2. Влияние весовых коэффициентов на NDCG@5 (иллюстрация авторов)

Fig. 2. Influence of weight coefficients on NDCG@5 (illustration by the authors)

На рисунке 2 показано, как изменяется усредненное значение NDCG@5 для позитивных и негативных запросов при варьировании коэффициента α . Значение $\alpha = 1.0$ регулирует влияние семантической составляющей, так $\alpha = 0.0$ – соответствует ранжированию, основанному исключительно на эмоциональной когерентности. График демонстрирует, что для обоих типов запросов пик эффективности (по NDCG@5) достигается при значениях α меньше 1.0, что говорит о том, что наиболее полезно включать эмоциональную когерентность как компонент и коэффициент ($\beta > 0$) больше нуля. В данном эксперименте для позитивных запросов оптимальное (с точки зрения прироста точности вышеупомянутых метрик) значение α приходится на 0.7, а для негативных – на 0.1. Это может свидетельствовать о том, что оптимальное соотношение имеет контекстную зависимость и варьируется от одного к другому корпусам текстов и методам классификаций. Для поиска наиболее оптимальных значений α и β требуется разработка и поиск наиболее подходящего метода определения коэффициентов. Если использовать только эмоциональную составляющую, результат будет не оптимален, а значит, необходимо комбинировать оба подхода.

Заключение

Проведенное исследование продемонстрировало потенциал композитной метрики, объединяющей семантическое сходство и эмоциональную когерентность, для улучшения качества извлечения контекста в RAG-системах [17–18]. Показано, что стандартные методы, основанные исключительно на семантическом анализе, игнори-

руют важный аспект эмоционального соответствия, что может приводить к извлечению менее релевантных документов для эмоционально окрашенных запросов.

Предложенная композитная метрика, использующая косинусное сходство как в пространстве семантических эмбедингов [19], показала статистически значимое улучшение по сравнению с базовой семантической метрикой на сэмпированном подмножестве датасета SST-2. Наиболее заметный прирост эффективности наблюдался в метриках [20], оценивающих верхние позиции в ранжированном списке (Precision@5, NDCG@5), а также в Recall@k, что указывает на улучшение способности системы находить релевантные документы в топе.

Полученные результаты подчеркивают важность явного учета эмоциональной составляющей при оценке и построении систем извлечения контекста, особенно в задачах, связанных с анализом или генерацией эмоционально окрашенных текстов. Разработанная композитная метрика может служить основой для создания более тонких и контекстно-зависимых механизмов ранжирования.

Перспективы дальнейших исследований включают изучение адаптивных стратегий определения весовых коэффициентов в зависимости от характеристик запроса; исследование влияния более детализированных моделей эмоций (например, с более широким спектром эмоций или учетом интенсивности); тестирование композитной метрики на более крупных и разнообразных датасетах, включая многоязычные и предметно-специфичные корпуса; а также проведение сквозной оценки влияния качества извлечения на качество сгенерированных RAG-системой ответов.

Список литературы

1. Стратегии онлайн-поиска информации как предмет психологического исследования: теоретическая модель // Первое сентября. – Режим доступа: <https://rffi.1sept.ru/article/424>, свободный. – Заглавие с экрана. – Яз. рус.

2. Абакумова И. В. Психологические особенности переживания студентами ограничения доступа к социальным сетям / И. В. Абакумова, Н. Е. Комерова, С. Н. Рягин // Российский психологический журнал. – 2023. – № 3. – С. 24–36. – DOI: 10.21702/grj.2023.3.2.
3. Когерентность: ключ к эмоциональному исцелению и личностному росту // Менталзон. – Режим доступа: <https://yagla.tv/cG8CB7D>, свободный. – Заглавие с экрана. – Яз. рус.
4. Artem. Анализ сентимента и эмоционального окраса текстов с помощью SQL // Хабр. – Режим доступа: <https://habr.com/ru/companies/otus/articles/757042/>, свободный. – Заглавие с экрана. – Яз. рус.
5. Zhang H. Retrieval-Based Question Answering Based on Emotion-Aware Graph Attention Network / H. Zhang, F. Li, Q. Ling // 2023 International Conference on Culture-Oriented Science and Technology (CoST) : Proceedings of the International Conference. – [S. l.] : IEEE, 2023. – P. 47–51. – DOI: 10.1109/CoST60752.2023.00017.
6. Huang L. Emotional RAG: Enhancing Role-Playing Agents through Emotional Retrieval / L. Huang, H. Lan, Z. Sun, C. Shi, T. Bai. – arXiv preprint, 2024. – 13 p. – DOI: 10.48550/arXiv.2410.23041. – Режим доступа: <http://arxiv.org/pdf/2410.23041.pdf>, свободный. – Заглавие с экрана. – Яз. англ.
7. Wu W. Distribution-based Emotion Recognition in Conversation / W. Wu, C. Zhang, P. C. Woodland // 2022 IEEE Spoken Language Technology Workshop (SLT) : Proceedings of the Workshop. – [S. l.] : IEEE, 2023. – P. 860–867. – DOI: 10.1109/SLT54892.2023.10023185.
8. Fraser D. J. Choosing Math Features for BM25 Ranking with Tangent-L / D. J. Fraser, A. Kane, F. W. Tompa // Proceedings of the ACM Symposium on Document Engineering 2018 : DocEng '18. – [S. l.] : ACM, 2018. – 4 p. – DOI: 10.1145/3209280.3209525.
9. Bahrani M. Opinion-Aware Retrieval Models Based on Sentiment and Intensity of Lexical Features / M. Bahrani, T. Roelleke // MMBD / MLIS : Proceedings of the International Conference on Multimedia Big Data and Machine Learning and Information Security. – [S. l.] : [s. n.], 2021. – Режим доступа: <https://www.semanticscholar.org/paper/234931b2746f541b7c90177dcc69d00d9f7ae5fb>, свободный. – Заглавие с экрана. – Яз. англ.
10. Warikoo N. NLP meets psychotherapy: Using predicted client emotions and self-reported client emotions to measure emotional coherence / N. Warikoo, T. Mayer, D. Atzil-Slonim, A. Eliassaf, S. Haimovitz, I. Gurevych. – arXiv preprint, 2022. – 10 p. – DOI: 10.48550/arXiv.2211.12512. – Режим доступа: <http://arxiv.org/pdf/2211.12512.pdf>, свободный. – Заглавие с экрана. – Яз. англ.
11. j-hartmann/emotion-english-distilroberta-base // Hugging Face. URL: <https://huggingface.co/j-hartmann/emotion-english-distilroberta-base> Режим доступа: <http://arxiv.org/pdf/2211.12512.pdf>, свободный. – Заглавие с экрана. – Яз. англ.
12. Mattiazzi M. On a new statistical technique for the real-time recognition of ultra-low multiplicity astrophysical neutrino burst / M. Mattiazzi, M. Lamoureux, G. Collazuol. – arXiv preprint, 2021. – 10 p. – DOI: 10.48550/arXiv.2106.12345. – Режим доступа: <https://arxiv.org/pdf/2106.12345.pdf>, свободный. – Заглавие с экрана. – Яз. англ.
13. stanfordnlp/sst2 // Hugging Face. – Режим доступа: <https://huggingface.co/datasets/stanfordnlp/sst2>, свободный. – Заглавие с экрана. – Яз. англ.
14. Verma S. Evaluating Semantic and Personalized Information Retrieval with Deep Learning Models: A Performance Metrics Analysis / S. Verma, S. Sharma, S. P. Panda // Tuijin Jishu/Journal of Propulsion Technology. – 2023. – Vol. 44, № 4. – Режим доступа: <https://www.semanticscholar.org/paper/7b45feea21bc0ddd2779c09db310e0846f32435c>, свободный. – Заглавие с экрана. – Яз. англ.
15. Kumar R. Hybrid optimized query expansion strategy for semantic information retrieval using spatial bound whale and binary moth flame optimization algorithm / R. Kumar, S. C. Sharma // Concurrency and Computation: Practice and Experience. – 2022. – Vol. 34, № 8. – P. e6778. – DOI: 10.1002/cpe.6778.
16. Tasche D. A plug-in approach to maximising precision at the top and recall at the top / D. Tasche. – arXiv preprint, 2018. – 24 p. – DOI: 10.48550/arXiv.1804.03077. – Режим доступа: <https://arxiv.org/pdf/1804.03077.pdf>, свободный. – Заглавие с экрана. – Яз. англ.
17. Gupta S. A comprehensive survey of retrieval-augmented generation (rag): Evolution, current landscape and future directions / S. Gupta, R. Ranjan, S. N. Singh. – arXiv preprint, 2024. – 35 p. – DOI: 10.48550/arXiv.2410.12837. – Режим доступа: <https://arxiv.org/pdf/2410.12837.pdf>, свободный. – Заглавие с экрана. – Яз. англ.
18. Verma S. Contextual Compression in Retrieval-Augmented Generation for Large Language Models: A Survey / S. Verma. – arXiv preprint, 2024. – 16 p. – DOI: 10.48550/arXiv.2409.13385. – Режим доступа: <https://arxiv.org/pdf/2409.13385.pdf>, свободный. – Заглавие с экрана. – Яз. англ.
19. Gendron B. Context-Aware Siamese Networks for Efficient Emotion Recognition in Conversation / B. Gendron, G. Guibon. – arXiv preprint, 2024. – 9 p. – DOI: 10.48550/arXiv.2404.11141. – Режим доступа: <https://arxiv.org/pdf/2404.11141.pdf>, свободный. – Заглавие с экрана. – Яз. англ.
20. Dellis S. Self-Adaptive Optimization of Coefficients in Multi-Objective Loss Functions / S. Dellis, E. Ricci, D.-P. Gerakinis, N. Vergadou, G. Giannakopoulos // Proceedings of the 13th Hellenic Conference on Artificial Intelligence : SETN 2024. – [S. l.] : ACM, 2024. – 7 p. – DOI: 10.1145/3664621.3664633.

© В. А. Наумушкин, В. А. Павлов

Ссылка для цитирования:

Наумушкин В. А., Павлов В. А. Композитная метрика эмоциональной когерентности в системах извлечения контекста // Инженерно-строительный вестник Прикаспия : научно-технический журнал / Астраханский государственный архитектурно-строительный университет. Астрахань: ГБОУ АО ВО «АГАСУ», 2025. № 3 (53). С. 87–92.