

Федеральный исследовательский центр «Информатика и управление»  
Российской академии наук

На правах рукописи



Ватолин Алексей Сергеевич

**Обучение и оценивание мультиязычных нейросетевых моделей  
семантического векторного представления научных текстов**

Специальность 2.3.8 —  
«Информатика и информационные процессы»

Диссертация на соискание учёной степени  
кандидата технических наук

Научный руководитель:  
доктор физико-математических наук, доцент  
Абгарян Каринэ Карленовна

Москва — 2025

## Оглавление

	Стр.
<b>Введение . . . . .</b>	<b>5</b>
<b>Глава 1. Семантическое векторное представление текстов . . . . .</b>	<b>11</b>
1.1 Задача семантического векторного представления текстов . . . . .	12
1.2 Токенизация текстовых данных . . . . .	13
1.3 Архитектура трансформер-кодировщик . . . . .	16
1.4 Предобучение моделей на основе архитектуры трансформер . . . . .	20
1.5 Контрастивное дообучение для векторных представлений текста . .	23
1.6 Применение и оценка моделей в научной области . . . . .	28
1.7 Оценка качества моделей векторного представления текстов . . . . .	34
1.7.1 Бенчмарк SciDocs . . . . .	35
1.7.2 Бенчмарк SciRepEval . . . . .	37
1.7.3 Бенчмарк SciFact . . . . .	38
1.7.4 Универсальные бенчмарки: MTEB . . . . .	40
1.8 Основные выводы . . . . .	40
<b>Глава 2. Разработка и обучение двуязычных моделей векторизации научных текстов SciRus . . . . .</b>	<b>42</b>
2.1 Постановка задачи и существующие ограничения . . . . .	42
2.2 Наборы данных для обучения . . . . .	44
2.3 Архитектура моделей SciRus . . . . .	46
2.4 Методология обучения . . . . .	48
2.4.1 Предобучение с использованием Masked Language Modeling (MLM) . . . . .	48
2.4.2 Контрастивное дообучение . . . . .	51
2.5 Оценка качества моделей SciRus . . . . .	52
2.6 Оценка производительности . . . . .	57
2.7 Практическая апробация и внедрение модели SciRus-tiny . . . . .	58
2.8 Основные выводы . . . . .	60

<b>Глава 3. Мультизадачный бенчмарк для оценки моделей векторного представления русско- и англоязычных научных текстов . . . . .</b>	62
3.1 Источники данных и подготовка корпуса . . . . .	63
3.2 Состав и методология оценки в бенчмарке RuSciBench . . . . .	64
3.2.1 Задачи классификации документов . . . . .	66
3.2.2 Задачи регрессии . . . . .	73
3.2.3 Задачи информационного поиска . . . . .	77
3.2.4 Задачи кросс-языкового поиска . . . . .	80
3.3 Оценка моделей на RuSciBench . . . . .	83
3.3.1 Оценка степени языковой специализации моделей . . . . .	86
3.4 Интеграция в международный бенчмарк MTEB . . . . .	90
3.5 Основные выводы . . . . .	91
<b>Глава 4. Бенчмарк для оценки качества верификации научных фактов на русском языке . . . . .</b>	93
4.1 Постановка задачи верификации научных фактов . . . . .	93
4.2 Методология формирования набора данных RuSciFact . . . . .	95
4.3 Конвейер генерации и фильтрации данных . . . . .	98
4.3.1 Генерация подтверждающих утверждений . . . . .	99
4.3.2 Генерация противоречащих утверждений . . . . .	101
4.4 Экспертная валидация и характеристики набора данных . . . . .	103
4.5 Экспериментальная оценка и анализ результатов . . . . .	104
4.5.1 Оценка в задаче информационного поиска . . . . .	105
4.5.2 Оценка в задаче классификации . . . . .	108
4.5.3 Анализ сложности задачи в разрезе научных дисциплин . .	110
4.6 Основные выводы . . . . .	114
<b>Заключение . . . . .</b>	116
<b>Список литературы . . . . .</b>	118
<b>Приложение А. Промпты для формирования выборки в бенчмарке RuSciFact и примеры данных . . . . .</b>	126
A.1 Промпты для генерации подтверждающего утверждения в бенчмарке RuSciFact . . . . .	126

A.2 Промпт для классификации сложности факта . . . . .	129
A.3 Промпт для генерации опровергающего факта . . . . .	131
A.4 Промпт для оценки релевантности и степени подтверждения . . . . .	133
A.5 Примеры положительных и отрицательных утверждений из ruSciFact . . . . .	134

## Введение

**Актуальность** данной работы обусловлена кратным увеличением объема публикуемой научной информации. Исследование динамики наполнения крупных библиометрических баз данных подтверждает эту тенденцию. Так, согласно анализу базы данных Scopus, количество ежегодно индексируемых научных статей выросло с приблизительно 921 тысячи в 2000 году до более чем 2,57 миллиона в 2020 году, что свидетельствует о почти трехкратном увеличении за два десятилетия [1]. Общий объем публикаций в Scopus к 2020 году превысил 56 миллионов единиц. Аналогичные тенденции наблюдаются и в других международных научометрических системах, таких как Web of Science. Российская научная электронная библиотека eLibrary.ru, которая представляет материалы как на русском, так и на других языках, также демонстрирует значительный рост: количество публикаций в год увеличилось с 45,7 тысяч в 2000 году до более чем 4,76 миллиона в 2020 году [2]. Количество публикаций увеличивается не только на английском языке. Этот информационный поток делает задачу поиска релевантной информации для исследователей всё более трудной, а также ставит новые вызовы по эффективной обработке и анализу постоянно растущих текстовых массивов, что требует применения высокопроизводительных подходов, в том числе методов параллельной обработки данных [3].

Методы анализа и поиска информации постоянно совершенствуются. Традиционные подходы, основанные на статистическом анализе текстовых данных, такие как VSM [4], BM25 [5] и др., уступают место более сложным моделям, в частности, основанным на нейронных сетях. Современные нейросетевые модели, особенно архитектуры трансформер [6], демонстрируют преимущество над традиционными подходами, поскольку способны учитывать контекст, улавливать семантические связи между терминами, работать с синонимией и осуществлять эффективный многоязычный и кросс-язычный поиск. Внедрение таких моделей в научно-информационные системы позволяет существенно повысить качество и релевантность поиска, а также открывает новые возможности для анализа содержания научных текстов [7] [8]. В данной диссертации представлены нейросетевые модели SciRus [9], которые позволяют упростить работу с научными публикациями. Одна из разработанных моделей, SciRus-tiny, была внедрена на сервисе elibrary.ru.

Для объективной оценки и совершенствования моделей обработки естественного языка используют бенчмарки — специализированные наборы данных и задач. В последние годы для русского языка появились такие универсальные инструменты оценки, как RuSentEval [10] и encodechka [11]. Несмотря на это, наблюдается дефицит инструментов для русскоязычного научного домена. Научные тексты обладают рядом специфических характеристик, таких как информационная плотность и сложность текста, узкоспециализированная терминология, особая структура и стиль изложения. Из-за этого оценка на универсальных наборах для оценки не дает понимания о качестве работы модели на научных данных.

Отсутствие специализированных русскоязычных научных наборов данных для оценки затрудняет объективную оценку и сравнительный анализ как существующих, так и разрабатываемых моделей векторного представления текстов в данной предметной области. Как следствие, это сдерживает дальнейшее развитие алгоритмов для анализа русскоязычного научного контента. Еще одна задача таких наборов — помочь исследователям подобрать подходящую модель для своей задачи, связанной с научными текстами.

Разработка и предоставление научному сообществу открытых моделей и инструментариев для оценки, таких как SciRus и RuSciBench, отвечает целям и задачам развития искусственного интеллекта в Российской Федерации, перечисленным в «Национальной стратегии развития искусственного интеллекта на период до 2030 года» (с изменениями от 15 февраля 2024 г.) [12]. Это направление деятельности полностью соответствует концепции открытой науки, предполагающей свободный доступ к исследовательским данным, инструментам и результатам, что способствует ускорению научного прогресса и повышению прозрачности исследовательской деятельности.

**Целью** данной работы является разработка, исследование и апробация инструментов и моделей, предназначенных для решения задач эффективной обработки, анализа и оценки качества представления научных текстов на русском языке.

Для достижения поставленной цели необходимо было решить следующие **задачи**:

1. Разработать методику обучения легковесной двуязычной модели для эффективного векторного представления научных текстов на русском и английском языках. Исследовать подходы к обучению, основанные на

доступных данных из мультиязычных корпусов, без дополнительной разметки.

2. Разработать методологию и на ее основе создать инструментарий для оценки качества векторных представлений научных текстов на русском и английском языках. Данный инструментарий должен учитывать специфику научного дискурса и охватывать разнообразные задачи, используя данные из российской научной среды.
3. Исследовать проблему верификации научных фактов на русском языке. Разработать и апробировать методологию полуавтоматизированного формирования русскоязычного набора данных, включающую генерацию научных утверждений на основе аннотаций с использованием больших языковых моделей и их последующую экспертную валидацию. Разработать тестовый набор на основе данного набора для оценки способности моделей определять соответствие или противоречие утверждений.

#### **Основные положения, выносимые на защиту:**

1. Предложены компактные двуязычные модели SciRus-tiny (23 млн параметров) и SciRus-small (61 млн параметров) для представления научных текстов в векторном пространстве. Обучение проводится в два этапа: сначала модель обучается с помощью маскированного языкового моделирования, затем с помощью контрастивного дообучения на парах «заголовок-аннотация». Дополнительно, для формирования более сильного обучающего сигнала, при обучении используются пары «цитирующая статья — цитируемая статья», основанные на односторонней связи из графа цитирований. Эксперименты на русскоязычных и англоязычных научных наборах для оценки показали, что при числе параметров, в 24 и 9 раз меньшем по сравнению с multilingual-e5-large-instruct (560 млн параметров), предлагаемые модели демонстрируют сопоставимый, а на русскоязычных задачах — превосходящий уровень качества.
2. Разработан мультизадачный двуязычный бенчмарк RuSciBench, включающий задачи классификации, регрессии, моно- и кросс-языкового поиска на научных данных. Этот тестовый набор обеспечивает воспроизводимую процедуру тестирования, интегрированную в международный лидерборд MTEB.
3. Предложена полуавтоматическая методика формирования наборов данных для проверки научных фактов на русском языке, сочетающая ге-

нерацию утверждений с помощью LLM, многоступенчатую самооценку модели и экспертную верификацию. На её основе создан первый русскоязычный набор данных для проверки научных фактов RuSciFact.

**Методы исследования.** В диссертационном исследовании использованы известные, достоверные и хорошо зарекомендовавшие себя на практике методы. В модели используется архитектура трансформер, она обучается с помощью маскированного языкового моделирования и с помощью контрастивного дообучения с применением функции потерь InfoNCE. В наборах для оценки используются распространенные критерии оценки качества, такие как Accuracy, F1-мера, NDCG@k, MRR@k, коэффициент корреляции Кенделла.

### **Научная новизна:**

1. Показана эффективность контрастивного дообучения модели векторизации текста на парах «заголовок-аннотация» и на парах цитирующая-цитируемая статья.
2. Разработаны легковесные модели векторизации научных текстов.
3. Разработан первый набор для оценки качества работы моделей с научными данными, состоящий из различных типов задач.
4. Впервые предложена полуавтоматизированная многоступенчатая методика формирования наборов данных для проверки научных фактов на русском языке, совмещающая генерацию утверждений с помощью LLM, самокритичную оценку модели-генератора и экспертную валидацию.
5. Разработан и опубликован первый набор данных для проверки научных фактов на русском языке RuSciFact.

**Практическая значимость** обусловлена разработкой открытых научных наборов для оценки, которые были внедрены в авторитетный международный бенчмарк MTEB (Massive Text Embedding Benchmark), что подтверждает их актуальность, а также существенно упрощает их использование для разработчиков моделей. Кроме того, данные, на основе которых был создан бенчмарк RuSciBench, послужили основой для одной из задач в мультиязычном наборе для оценки AIRBench[13], а также для одной из задач в русскоязычном тестовом наборе LIBRA[14], что подтверждает интерес научного сообщества к результатам работы.

Еще одним подтверждением практической значимости является внедрение модели векторизации научных текстов SciRus-tiny на российском научном портале elibrary.ru. Был разработан новый режим «нейропоиск», который позволяет

находить тематически близкие научные публикации, используя в качестве запроса аннотацию статьи. Это внедрение способствует упрощению анализа научной информации для широкого круга исследователей и специалистов, работающих с научной библиотекой elibrary.

**Достоверность** полученных результатов подтверждается следующим:

1. докладами и обсуждениями результатов на международных конференциях
2. публикациями результатов в рецензируемых научных изданиях, рекомендованных ВАК
3. открытым исходным кодом и воспроизводимостью результатов.

**Апробация работы.** Основные результаты работы докладывались на:

1. А. С. Ватолин. Сравнительный анализ современных мультиязычных моделей для векторизации текста на русском языке. *Международная научно-практическая конференция «Информационные технологии, искусственный интеллект, большие данные: актуальные тенденции, перспективные исследования»*, 2024
2. А. С. Ватолин. ruSciFact: Open Benchmark for Verifying Scientific Facts in Russian. *Международная конференция по компьютерной лингвистике и интеллектуальным технологиям «Диалог»*, 2025
3. А. С. Ватолин. Structured Sentiment Analysis with Large Language Models: A Winning Solution for RuOpinionNE-2024. *Международная конференция по компьютерной лингвистике и интеллектуальным технологиям «Диалог»*, 2025

**Личный вклад** соискателя в работах с соавторами заключается в следующем: [9] - предобучение маленькой версии модели (SciRus-tiny) с помощью маскированного языкового моделирования, дообучение обеих версий модели (SciRus-tiny и SciRus-small) на парах заголовок-аннотация, валидация моделей на наборе данных SciDocs. [15] - сбор датасетов для классификации по ГРНТИ, по типу публикации, для поиска цитирований, для регрессии по количеству цитат, для поиска английского перевода по тексту на русском языке. Также реализация исходного кода инструментария для оценки, валидация моделей, интеграция бенчмарка в международный бенчмарк МТЕВ. [16] - вклад соискателя является определяющим. [17] — в рамках работы над созданием и расширением международного многоязычного бенчмарка ММТЕВ соискателем проведена работа по добавлению новых задач на различных языках, включая задачи, разработанные

им самостоятельно. Также выполнен значительный вклад в обеспечение качества и корректности данных во всех задачах, вошедших в итоговый набор бенчмарка. В публикации [18] соискатель является единственным автором.

Содержание диссертации и положения, выносимые на защиту, отражают персональный вклад автора в опубликованных работах. Все представленные результаты получены лично автором.

**Публикации.** Основные результаты по теме диссертации изложены в 5 печатных изданиях, 4 — в периодических научных журналах, индексируемых Web of Science и Scopus, 1 — в тезисах докладов.

**Объем и структура работы.** Диссертация состоит из введения, 4 глав, заключения и 1 приложения. Полный объём диссертации составляет 136 страниц, включая 10 рисунков и 25 таблиц. Список литературы содержит 70 наименований.

## Глава 1. Семантическое векторное представление текстов

Настоящая глава посвящена систематическому обзору методов построения семантических векторных представлений текстов, являющихся основой для решения широкого спектра задач обработки естественного языка. Вначале формулируется сама задача векторизации, определяется ее цель — построение отображения из пространства текстов в векторное пространство, в котором геометрическая близость векторов отражает семантическую близость исходных текстов, и дается краткий исторический экскурс в развитие подходов к ее решению (раздел 1). Далее детально рассматривается технологический стек, лежащий в основе современных моделей. Описывается неотъемлемый этап предобработки — субсловная токенизация данных (раздел 1.2), после чего подробно излагается архитектура трансформер-кодировщика (раздел 1.3), ставшая стандартом в данной области.

Особое внимание уделяется современным парадигмам обучения. Рассматривается этап предобучения на больших неразмеченных корпусах текста с использованием таких задач, как маскированное языковое моделирование, на примере моделей BERT и RoBERTa (раздел 1.4). Затем анализируется ключевая проблема неприспособленности предобученных моделей к задачам семантического поиска и показывается необходимость дополнительного этапа дообучения (fine-tuning). Описываются архитектуры на основе сиамских сетей и контрастивные функции потерь, такие как Triplet Loss и InfoNCE, которые позволяют сформировать семантически структурированное векторное пространство (раздел 1.5).

После рассмотрения общих методов, фокус смещается на их применение и адаптацию для узкоспециализированной области научных текстов. Обсуждаются особенности научного дискурса, вызывающие доменный сдвиг, и рассматриваются передовые модели, разработанные для его преодоления, включая SPECTER, SPECTER2 и SciNCL (раздел 1.6). Наконец, приводится обзор ключевых бенчмарков и мер качества, используемых для всесторонней оценки моделей векторизации научных документов, таких как SciDocs, SciRepEval, SciFact и универсального набора MTEB (раздел 1.7).

## 1.1 Задача семантического векторного представления текстов

Одной из фундаментальных задач в области обработки естественного языка является векторизация, или получение семантических векторных представлений (эмбеддингов), текстовых данных. Суть этой задачи заключается в построении отображения текстовых единиц, будь то слова, предложения или целые документы, в многомерное векторное пространство  $\mathbb{R}^d$  фиксированной размерности. Такое отображение переводит исходные текстовые данные, являющиеся по своей природе дискретными и неструктурированными, в формат непрерывных векторов. Это позволяет формировать метрическое пространство, в котором геометрическая близость векторов соответствует семантической близости текстов. Появляется возможность количественно оценивать семантические отношения через вычисление расстояний и углов между векторами, что является математической основой для решения широкого спектра прикладных задач, включая информационный поиск, машинный перевод, классификацию документов, кластеризацию, ответы на вопросы и многие другие [19].

Формально, задачу векторизации можно поставить следующим образом. Пусть дана коллекция текстовых документов  $\mathcal{D} = \{x_i\}_{i=1}^N$ , где каждый документ  $x_i$  представляет собой последовательность токенов (слов или их частей)  $x_i = (w_{i,1}, w_{i,2}, \dots, w_{i,n_i})$ . Необходимо найти такое параметризованное отображение  $f(x, \alpha)$ , которое ставит в соответствие каждому документу  $x_i$  вещественный вектор  $\mathbf{v}_i \in \mathbb{R}^d$ :

$$\mathbf{v}_i = f(x_i, \alpha)$$

где  $\alpha$  - вектор обучаемых параметров модели. Основная цель обучения состоит в подборе таких параметров  $\alpha$ , при которых векторы  $\mathbf{v}_i$  наилучшим образом кодируют семантическую информацию, содержащуюся в исходных текстах  $x_i$ . Качество этого кодирования оценивается через успешность решения целевых прикладных задач.

Исторически первыми подходами к решению этой задачи были методы, основанные на дистрибутивной гипотезе, утверждающей, что слова, встречающиеся в схожих контекстах, имеют близкие значения [20]. Это привело к появлению статистических моделей, основанных на взвешивании термов, таких как TF-IDF (Term Frequency-Inverse Document Frequency) [21], и методов,

использующих матричные разложения для выявления скрытых тем, например, латентно-семантического анализа (LSA) [22]. Однако эти подходы не всегда эффективно улавливали тонкие семантические связи.

Прорыв в этой области был связан с появлением плотных векторных представлений (dense embeddings), обучаемых с помощью нейронных сетей [23]. Модели семейства word2vec [24] и GloVe [25] позволили получать векторные представления для отдельных слов. Однако они присваивали каждому слову единственный вектор, не учитывая многозначность и контекст его употребления. Развитием этой идеи стали модели, способные генерировать контекстуализированные векторные представления. Модель ELMo (Embeddings from Language Models) [26] использовала для этой цели двунаправленную рекуррентную нейронную сеть (LSTM), выходы которой на разных слоях объединялись для получения итогового вектора токена, зависящего от контекста. Несмотря на успех, рекуррентные архитектуры обрабатывают текст последовательно, что затрудняет распараллеливание вычислений и улавливание дальних зависимостей в тексте.

Современный этап развития методов векторизации неразрывно связан с архитектурой трансформер (Transformer) [6], которая полностью отказалась от рекуррентных связей в пользу механизма внимания (attention mechanism). Этот подход продемонстрировал выдающуюся эффективность и масштабируемость, лег в основу большинства передовых моделей обработки естественного языка.

## 1.2 Токенизация текстовых данных

Первым и обязательным шагом при обработке текста нейросетевыми моделями является **токенизация** — процесс разбиения сплошного текста на последовательность элементарных единиц, называемых токенами. Эти токены затем отображаются в числовые идентификаторы в соответствии с заранее определенным словарем  $\mathcal{V}$ , что позволяет представить исходную текстовую последовательность в виде вектора целых чисел, пригодного для подачи на вход нейронной сети.

Простейшим подходом является токенизация по словам, где словарь состоит из всех уникальных слов, встретившихся в обучающем корпусе. Однако этот метод сталкивается с серьезной проблемой «неизвестных слов» (out-of-

vocabulary, OOV), когда в обрабатываемом тексте появляются слова, отсутствовавшие в обучающих данных. Эта проблема особенно остра для морфологически богатых языков, таких как русский, где одно и то же слово может иметь множество форм.

Для решения этой проблемы были разработаны алгоритмы **субсловной токенизации** (subword tokenization), которые разбивают слова на более мелкие, но семантически значимые части. Такой подход позволяет, с одной стороны, сохранить в словаре наиболее частотные слова целиком, а с другой — представить редкие и неизвестные слова как последовательность известных субсловесных единиц. Это не только решает проблему OOV, но и позволяет модели улавливать морфологические связи между словами (например, «обучение» и «обучать» будут иметь общие токены). К наиболее известным алгоритмам субсловной токенизации относятся Byte-Pair Encoding (BPE) [27], WordPiece [28] и Unigram Language Model [29].

**Алгоритм Byte-Pair Encoding (BPE)**, изначально разработанный для сжатия данных, был успешно адаптирован для задач обработки естественного языка в работе [27]. Процесс его применения состоит из двух этапов: обучения словаря и токенизации нового текста.

Процесс формирования словаря является итеративным.

1. **Инициализация.** Исходный словарь состоит из всех уникальных символов (символьный алфавит), встречающихся в обучающем корпусе. Весь текст корпуса разбивается на последовательности этих символов.
2. **Итеративное слияние.** На каждой итерации в корпусе находится наиболее часто встречающаяся пара соседних токенов (например, пара символов 'т' и 'о').
3. **Обновление.** Эта пара объединяется в новый, единый токен ('то'), который добавляется в словарь. Все вхождения исходной пары в корпусе заменяются на новый токен.
4. **Повторение.** Шаги 2 и 3 повторяются заданное число раз. Это число (количество слияний) является гиперпараметром, который определяет итоговый размер словаря.

В результате получается словарь, состоящий из исходных символов и наиболее частотных субсловесных единиц различной длины.

Для токенизации нового текста выполняются те же операции слияния в том порядке, в котором они были выучены на этапе обучения. Текст сначала разбивается на символы, а затем к нему последовательно применяются правила слияния до тех пор, пока не останется пар, подлежащих объединению.

**Токенизация на уровне байтов (Byte-level BPE)** Стандартный алгоритм BPE, работающий на уровне символов, все еще может столкнуться с проблемой OOV, если во входном тексте встретится символ, отсутствовавший в обучающих данных (например, редкий иероглиф или эмодзи). Чтобы полностью устранить эту проблему, была предложена модификация **byte-level BPE**, которая используется в таких моделях, как RoBERTa [30] и GPT-2 [31].

Ключевая идея этого подхода состоит в том, чтобы работать не с символами Unicode, а с их байтовым представлением в кодировке UTF-8. Это гарантирует, что любой текст может быть представлен без потерь и без использования специального токена неизвестного слова.

Принцип работы:

1. **Инициализация.** Начальный словарь состоит из всех 256 возможных значений байтов (от 0x00 до 0xFF). Таким образом, любой текст, представленный в виде последовательности байтов, может быть изначально токенизирован без потерь.
2. **Обучение.** Процесс обучения полностью аналогичен стандартному BPE. Алгоритм итеративно находит наиболее частую пару соседних байтов или уже объединенных субсловных токенов и сливает их, добавляя новый токен в словарь. Например, если в тексте часто встречается слово «текст», которое в UTF-8 представляется последовательностью байтов, то алгоритм сначала объединит байты, соответствующие паре символов ‘т’ и ‘е’, затем, возможно, байты для ‘к’ и ‘с’, а потом и более крупные фрагменты.
3. **Обработка Unicode.** Многобайтовые символы UTF-8 просто рассматриваются как последовательности их составляющих байтов. Алгоритм BPE автоматически обучается объединять эти последовательности байтов обратно в осмысленные единицы, если они достаточно часто встречаются в корпусе.

Таким образом, byte-level BPE создает универсальную систему токенизации, способную обрабатывать любой текст на любом языке, включая код, специальные

символы и эмодзи, не требуя специальной предобработки или токена ‘`<unk>`’. Это делает его особенно мощным инструментом для современных многоязычных и многозадачных моделей.

### 1.3 Архитектура трансформер-кодировщик

Архитектура трансформер, предложенная в работе [6], изначально состояла из кодировщика (encoder) и декодировщика (decoder) для задач машинного перевода. Для задач векторизации, где требуется получить семантические представления для последовательности токенов, используется только кодирующая часть, называемая трансформер-кодировщиком.

Результатом работы трансформер-кодировщика  $f_b(x_i, \alpha)$  является последовательность контекстуализированных векторных представлений  $\mathbf{H}^{(L)} = (\mathbf{h}_1^{(L)}, \dots, \mathbf{h}_{n_i}^{(L)})$ , по одному вектору для каждого входного токена. Модель можно представить как композицию двух основных компонентов: слоя векторизации токенов  $f_e$  и последовательности из  $L$  идентичных трансформер-блоков  $f_{\text{TB}}^{(l)}$ :

$$\mathbf{H}^{(L)} = f_b(x_i, \alpha) = f_{\text{TB}}^{(L)} \left( \dots f_{\text{TB}}^{(1)} \left( f_e(x_i, \alpha_e), \alpha_{\text{TB}}^{(1)} \right) \dots, \alpha_{\text{TB}}^{(L)} \right).$$

Рассмотрим каждый компонент подробнее.

**Слой векторизации (Embedding Layer).** На вход модели подается последовательность токенов  $x_i = (w_{i,1}, \dots, w_{i,n_i})$ . Сначала каждый токен отображается в вектор с помощью обучаемой матрицы эмбеддингов  $E$ . Процесс получения векторов начинается с токенизации, где входная текстовая последовательность преобразуется в последовательность целочисленных идентификаторов  $(id_1, \dots, id_{n_i})$  в соответствии с предопределенным словарем  $\mathcal{V}$  размером  $|\mathcal{V}|$ . Каждый уникальный токен в словаре имеет свой уникальный числовой идентификатор.

Сама матрица эмбеддингов  $E \in \mathbb{R}^{|\mathcal{V}| \times d}$  по своей сути является таблицей поиска (lookup table), где каждой  $k$ -й строке,  $k \in \{1, \dots, |\mathcal{V}|\}$ , соответствует плотный вектор  $\mathbf{v}_k \in \mathbb{R}^d$  для токена с идентификатором  $k$ . Таким образом, операция получения эмбеддинга для одного токена сводится к извлечению соответствующей строки из этой матрицы.

Формально эту операцию можно выразить через умножение матрицы  $E$  на one-hot-вектор. Для токена с идентификатором  $k$  создается вектор  $\mathbf{e}_k \in \{0, 1\}^{|\mathcal{V}|}$ , у которого  $k$ -я компонента равна 1, а все остальные — 0. Тогда векторное представление токена  $\mathbf{v}_k$  вычисляется как:

$$\mathbf{v}_k = \mathbf{e}_k^\top E.$$

Элементы матрицы  $E$  являются обучаемыми параметрами модели, которые настраиваются в процессе обучения методом обратного распространения ошибки. Применение этой операции ко всем токенам последовательности  $x_i$  порождает матрицу токеновых эмбеддингов  $E(x_i) \in \mathbb{R}^{n_i \times d}$ , которая и служит входом для дальнейших преобразований.

Поскольку модель не содержит рекуррентных или сверточных слоев, для внесения информации о порядке токенов используется матрица позиционных эмбеддингов  $P$ . Итоговое представление для входной последовательности, обозначаемое как  $\mathbf{H}^{(0)}$ , получается путем суммирования токеновых и позиционных эмбеддингов. В работе [6] предлагается также масштабировать токеновые эмбеддинги:

$$\mathbf{H}^{(0)} = E(x_i)\sqrt{d} + P,$$

где

$E \in \mathbb{R}^{|\mathcal{V}| \times d}$  — матрица эмбеддингов токенов,  $|\mathcal{V}|$  — размер словаря.

$d$  — размерность векторного представления.

$P \in \mathbb{R}^{n_{\max} \times d}$  — матрица позиционных эмбеддингов,  $n_{\max}$  — максимальная длина последовательности.

Компоненты матрицы позиционных эмбеддингов  $P$  вычисляются с использованием синусоидальных функций разной частоты:

$$P_{pos,2k} = \sin(pos/10000^{2k/d}), \quad P_{pos,2k+1} = \cos(pos/10000^{2k/d}),$$

где

$pos$  — позиция токена в последовательности  $(0, 1, \dots, n_i - 1)$ .

$k$  — индекс размерности вектора  $(0, 1, \dots, d/2 - 1)$ .

Такой выбор позволяет модели легко обучаться на относительных позициях, поскольку для любого фиксированного смещения  $j$  позиционный эмбеддинг  $P_{pos+j}$  может быть выражен как линейная функция от  $P_{pos}$ .

**трансформер-блок.** Ядром архитектуры является трансформер-блок, который состоит из двух основных подслоев: механизма многоголового внимания (Multi-Head Attention) и полносвязной нейронной сети прямого распространения (Feed-Forward Network). Вокруг каждого из этих подслоев применяется остаточное соединение (residual connection) с последующей послойной нормализацией (Layer Normalization). Для  $l$ -го блока ( $l = 1, \dots, L$ ) преобразование матрицы представлений  $\mathbf{H}^{(l-1)}$  в  $\mathbf{H}^{(l)}$  выглядит следующим образом:

$$\mathbf{Z}^{(l)} = \text{LayerNorm}(\mathbf{H}^{(l-1)} + \text{MHAtt}^{(l)}(\mathbf{H}^{(l-1)})),$$

$$\mathbf{H}^{(l)} = \text{LayerNorm}(\mathbf{Z}^{(l)} + \text{FF}^{(l)}(\mathbf{Z}^{(l)})).$$

**Механизм внимания (Scaled Dot-Product Attention).** Это ключевой компонент, который позволяет модели взвешивать важность различных токенов в последовательности при формировании представления для каждого конкретного токена. Входными данными для него служат три матрицы: запросов (Query,  $Q$ ), ключей (Key,  $K$ ) и значений (Value,  $V$ ). В режиме самовнимания (self-attention), который используется в кодировщике, все три матрицы получаются путем линейного проецирования матрицы выходов предыдущего слоя  $\mathbf{H}^{(l-1)}$  с помощью индивидуальных обучаемых весовых матриц для каждого типа проекции.

Формально, для  $l$ -го трансформер-блока эти преобразования записываются следующим образом:

$$\begin{aligned} Q &= \mathbf{H}^{(l-1)} W^{Q,(l)}, \\ K &= \mathbf{H}^{(l-1)} W^{K,(l)}, \\ V &= \mathbf{H}^{(l-1)} W^{V,(l)}, \end{aligned} \tag{1.1}$$

где

$\mathbf{H}^{(l-1)} \in \mathbb{R}^{n_i \times d}$  — матрица векторных представлений всех  $n_i$  токенов, полученная на выходе  $(l-1)$ -го блока. Каждая строка этой матрицы — это вектор  $\mathbf{h}_j^{(l-1)}$  для  $j$ -го токена.

$W^{Q,(l)}, W^{K,(l)} \in \mathbb{R}^{d \times d_k}$  — обучаемые матрицы весов для линейного проецирования в пространства запросов и ключей соответственно.

$W^{V,(l)} \in \mathbb{R}^{d \times d_v}$  — обучаемая матрица весов для линейного проецирования в пространство значений.

$d, d_k, d_v$  — размерности пространств исходных представлений, ключей/запросов и значений. В архитектуре трансформер принято, что  $d_k = d_v$ .

Таким образом, каждая из матриц  $Q, K, V$  содержит проекции всех токенов последовательности в соответствующее семантическое подпространство. После вычисления этих матриц применяется функция внимания:

$$\text{Attn}(Q, K, V) = \text{softmax} \left( \frac{QK^\top}{\sqrt{d_k}} \right) V$$

Результатом операции  $\text{Attn}(Q, K, V)$  является матрица  $\mathbb{R}^{n_i \times d_v}$ , содержащая обновленные представления для каждого токена, где каждый вектор является взвешенной суммой всех векторов из матрицы значений  $V$ . Веса в этой сумме определяются степенью «совместимости» (измеряемой скалярным произведением) вектора запроса каждого токена с векторами ключей всех остальных токенов в последовательности. Масштабирующий множитель  $1/\sqrt{d_k}$  вводится для стабилизации градиентов, предотвращая их затухание при больших значениях  $d_k$ .

**Многоголовое внимание (Multi-Head Attention).** Вместо одного механизма внимания, трансформер использует  $H$  «голов» внимания параллельно. Входные векторы  $\mathbf{H}^{(l-1)}$  линейно проецируются  $H$  раз с помощью разных матриц весов. Затем для каждой головы вычисляется функция внимания. Полученные выходы конкатенируются и снова подвергаются линейному преобразованию:

$$\text{head}_h = \text{Attn}(\mathbf{H}^{(l-1)}W_h^{Q,(l)}, \mathbf{H}^{(l-1)}W_h^{K,(l)}, \mathbf{H}^{(l-1)}W_h^{V,(l)}),$$

$$\text{MHAtt}^{(l)}(\mathbf{H}^{(l-1)}) = \text{Concat}(\text{head}_1, \dots, \text{head}_H)W^{O,(l)},$$

где  $h = 1, \dots, H$  — номер головы. Это позволяет модели одновременно фокусироваться на различных аспектах информации из различных подпространств представлений.

**Полносвязная сеть (Feed-Forward Network).** Этот подслой применяется к каждому векторному представлению токена независимо и состоит из двух линейных преобразований с нелинейной функцией активации между ними. В качестве функции активации используется ReLU (Rectified Linear Unit)[32], которая определяется как  $\text{ReLU}(z) = \max(0, z)$  и применяется поэлементно. Преобразование для матрицы  $\mathbf{Z}$  имеет вид:

$$\text{FF}^{(l)}(\mathbf{Z}) = \text{ReLU}(\mathbf{Z}W_1^{(l)} + \mathbf{b}_1^{(l)})W_2^{(l)} + \mathbf{b}_2^{(l)}.$$

**Послойная нормализация (Layer Normalization) [33].** Используется для стабилизации обучения. Нормализация происходит по размерности эмбеддинга

для каждого токена отдельно:

$$\text{LayerNorm}(\mathbf{x}) = \gamma \frac{\mathbf{x} - \mu(\mathbf{x})}{\sqrt{\sigma^2(\mathbf{x}) + \epsilon}} + \beta,$$

где  $\mu(\mathbf{x})$  и  $\sigma^2(\mathbf{x})$  — среднее и дисперсия по компонентам вектора  $\mathbf{x}$ , а  $\gamma$  и  $\beta$  — обучаемые параметры масштаба и сдвига.

## 1.4 Предобучение моделей на основе архитектуры трансформер

Модель **BERT** (Bidirectional Encoder Representations from Transformers) [34] стала революционным шагом в обработке естественного языка. Ее архитектура представляет собой описанный в разделе 1.3 трансформер-кодировщик. Ключевое нововведение BERT заключается в методологии его **предобучения** на огромных объемах неразмеченных текстовых данных, включающей две задачи: маскированное языковое моделирование (MLM) и предсказание следующего предложения (NSP). В качестве обучающих данных использовались большие объемы англоязычных текстов, а именно, корпус BooksCorpus [34] (около 800 млн слов) и англоязычная Википедия (2.5 млрд слов). Совокупный объем данных (около 16 ГБ текста) и их тематическое разнообразие (художественная литература, научные и энциклопедические статьи) позволили модели изучить широкий спектр языковых явлений и закономерностей, создав универсальные представления.

В отличие от предыдущих моделей, таких как GPT, которые были односторонними, BERT является глубоко двунаправленной моделью, то есть при построении представления каждого токена он одновременно учитывает как левый, так и правый контекст на всех слоях.

**Маскированное языковое моделирование (Masked Language Modeling, MLM).** Эта задача позволяет обучать двунаправленные представления. Во входной последовательности токенов  $x_i$  случайным образом выбирается подмножество позиций  $M_i$  (15%) для маскирования. Для каждой позиции  $j$  из этого

подмножества токен  $w_{i,j}$  заменяется по следующему правилу:

$$w'_{i,j} = \begin{cases} [\text{MASK}], & \text{с вероятностью } 80\%; \\ u \sim \mathcal{U}(\mathcal{V}), & \text{с вероятностью } 10\%; \\ w_{i,j}, & \text{с вероятностью } 10\%. \end{cases}$$

Формально, схема маскирования описывается как

$$m_{i,j} \sim \text{Bernoulli}(0.15), \quad r \sim \mathcal{U}(0,1),$$

$$w'_{i,j} = \begin{cases} [\text{MASK}], & m_{i,j} = 1 \text{ и } r < 0.8; \\ u \sim \mathcal{U}(\mathcal{V}), & m_{i,j} = 1 \text{ и } 0.8 \leq r < 0.9; \\ w_{i,j}, & \text{иначе,} \end{cases}$$

где  $m_{i,j}$  — индикатор маскирования,  $r$  — равномерно распределенная случайная величина,  $\mathcal{U}(\mathcal{V})$  — равномерное распределение по словарю  $\mathcal{V}$ . В оригинальной реализации BERT [34] используется **статическое маскирование**: для каждого обучающего примера маска создается однократно и остается неизменной на протяжении всех эпох обучения. Задача модели — на основе маскированной последовательности  $x'_i = (w'_{i,1}, \dots, w'_{i,n_i})$  предсказать исходные токены в позициях  $j \in M_i = \{j \mid m_{i,j} = 1\}$ . Для этого выходы кодировщика  $\mathbf{h}_j^{(L)}$  подаются на классификационный слой:

$$p_{ij} = \text{softmax}(\mathbf{h}_j^{(L)} \mathbf{W}_{\text{MLM}}^\top + \mathbf{b}_{\text{MLM}}),$$

где  $\mathbf{W}_{\text{MLM}} \in \mathbb{R}^{|\mathcal{V}| \times d}$  и  $\mathbf{b}_{\text{MLM}} \in \mathbb{R}^{|\mathcal{V}|}$  — обучаемые параметры. Функция потерь MLM минимизирует перекрестную энтропию по маскированным токенам:

$$\mathcal{L}_{\text{MLM}} = -\frac{1}{\sum_{i=1}^B |M_i|} \sum_{i=1}^B \sum_{j \in M_i} \log p_{ij}[y_{ij}] \longrightarrow \min,$$

где  $B$  — размер мини-выборки,  $y_{ij}$  — индекс истинного токена в позиции  $j$  последовательности  $x_i$ .

**Предсказание следующего предложения (Next Sentence Prediction, NSP).** Эта задача была введена для того, чтобы модель могла улавливать связи между предложениями, что важно для таких задач, как ответы на вопросы и определение логического следования. Для формирования обучающей выборки создаются пары

предложений ( $A, B$ ). В 50% случаев предложение  $B$  является фактическим следующим предложением за  $A$  в исходном корпусе (метка ‘IsNext’), а в остальных 50% случаев  $B$  является случайным предложением из корпуса (метка ‘NotNext’).

На вход модели подается конкатенированная последовательность: ‘[CLS]’  $A$  ‘[SEP]’  $B$  ‘[SEP]’. Для решения этой задачи бинарной классификации используется векторное представление специального токена [CLS], а именно вектор  $\mathbf{h}_{\text{CLS}}^{(L)}$ , который подается на простой классификатор:

$$p_{\text{NSP}} = \text{softmax}(\mathbf{h}_{\text{CLS}}^{(L)} \mathbf{W}_{\text{NSP}}^\top + \mathbf{b}_{\text{NSP}}).$$

Функция потерь  $\mathcal{L}_{\text{NSP}}$  вычисляется как стандартная перекрестная энтропия для бинарной классификации.

**Совместное обучение.** Процесс предобучения BERT заключается в одновременной минимизации суммарной функции потерь по обеим задачам. Обучение ведется на мини-выборках (mini-batches) — небольших случайных подмножествах данных. Итоговая функция потерь, градиент которой вычисляется на каждом шаге, представляет собой сумму функций потерь MLM и NSP:

$$\mathcal{L}_{\text{total}}(\alpha, \theta_{\text{MLM}}, \theta_{\text{NSP}}) = \mathcal{L}_{\text{MLM}} + \mathcal{L}_{\text{NSP}} \longrightarrow \min_{\alpha, \theta_{\text{MLM}}, \theta_{\text{NSP}}},$$

где  $\alpha$  обозначает параметры трансформер-кодировщика, а  $\theta_{\text{MLM}} = \{\mathbf{W}_{\text{MLM}}, \mathbf{b}_{\text{MLM}}\}$  и  $\theta_{\text{NSP}} = \{\mathbf{W}_{\text{NSP}}, \mathbf{b}_{\text{NSP}}\}$  — параметры классификационных слоев для каждой из задач.

**Модель RoBERTa.** Развивая идеи BERT, модель RoBERTa (A Robustly Optimized BERT Approach) [30] не вводит новой архитектуры, а представляет собой тщательное исследование и оптимизацию процесса обучения BERT. Авторы показали, что производительность BERT сильно зависит от гиперпараметров и стратегии обучения. Ключевые отличия RoBERTa от BERT:

- **Динамическое маскирование.** В RoBERTa маска генерируется заново для каждой последовательности при каждой ее подаче в модель, что существенно увеличивает разнообразие обучающих данных.
- **Отказ от задачи NSP.** Авторы показали, что исключение этой задачи улучшает качество итоговых представлений на многих задачах.
- **Обучение на больших батчах и данных.** RoBERTa обучалась на значительно больших мини-выборках (размером до 8000 примеров) и на большем объеме текстовых данных (160 ГБ текста против 16 ГБ у BERT).

- **Токенизация.** Вместо токенизатора WordPiece [35], RoBERTa использует алгоритм byte-level Byte-Pair Encoding (BPE) [27] с большим размером словаря (50 тыс. токенов против 30 тыс. токенов у модели BERT), что позволяет избежать токенов неизвестных слов.

Эти изменения позволили моделям RoBERTa существенно превзойти по качеству оригинальные модели BERT на широком спектре задач и установили новый стандарт для предобученных трансформер-кодировщиков.

## 1.5 Контрастивное дообучение для векторных представлений текста

Предобученные трансформер-кодировщики, такие как BERT [34], продемонстрировали высокую эффективность в задачах классификации для отдельный текстов или пар текстов, задаче ответа на вопрос и тегирования слов. Однако практические задачи, такие как семантический поиск, кластеризация или обнаружение дубликатов, требуют решения другой, хотя и связанной, проблемы: для данного текста-запроса  $x_q$  найти наиболее семантически близкий текст в большой коллекции  $\mathcal{D} = \{x_i\}_{i=1}^N$ .

Прямолинейный подход, следующий из оригинальной архитектуры BERT, заключается в использовании так называемой архитектуры перекрестного кодировщика (cross-encoder). В этой схеме пара текстов, запрос  $x_q$  и документ  $x_i$ , конкатенируется в одну общую последовательность  $x_{q,i}$ , разделенную специальным токеном [SEP]:

$$x_{q,i} = ([CLS], x_q, [SEP], x_i, [SEP]).$$

Эта последовательность подается на вход трансформер-кодировщика  $f_b(x, \alpha)$ . Выходной вектор  $\mathbf{h}_{\text{CLS}}^{(L)}$ , соответствующий специальному токену [CLS], агрегирует информацию обо всей паре и используется для предсказания оценки их близости  $s_{q,i}$  с помощью простого регрессионного слоя с параметрами  $\Theta_{reg} = \{\mathbf{w}, b\}$ :

$$\hat{s}_{q,i} = \mathbf{w}^\top \mathbf{h}_{\text{CLS}}^{(L)} + b,$$

где

$\mathbf{h}_{\text{CLS}}^{(L)} \in \mathbb{R}^d$  — выходной вектор кодировщика для токена [CLS] при подаче на вход последовательности  $x_{q,i}$ .

$\mathbf{w} \in \mathbb{R}^d, b \in \mathbb{R}$  — обучаемые параметры регрессионного слоя.

Процесс дообучения такой модели заключается в совместном подборе параметров кодировщика  $\alpha$  и регрессионного слоя  $\theta_{reg}$  путем минимизации функции потерь на специализированном наборе данных, на корпусе семантической близости текстов (Semantic Textual Similarity, STS) [36]. Для каждой обучающей пары  $(x_q, x_i)$  с известной экспертной оценкой близости  $s_{q,i}$  минимизируется среднеквадратичная ошибка:

$$\mathcal{L}(\alpha, \theta_{reg}) = \sum_{(x_q, x_i, s) \in \text{STS}} (\hat{s}_{q,i} - s_{q,i})^2 \longrightarrow \min_{\alpha, \theta_{reg}} .$$

Несмотря на то, что такой подход позволяет достичь высокой точности, его вычислительная сложность делает его неприменимым для большинства реальных сценариев. Поиск наиболее похожего текста для одного запроса  $x_q$  в коллекции из  $N$  документов потребует выполнения  $N$  прямых проходов через модель трансформера.

Фундаментальное ограничение перекрестного кодировщика состоит в том, что он не порождает независимого векторного представления для каждого отдельного текста. Оценка близости вычисляется «с нуля» для каждой новой пары. Подход, лишённый этого вычислительного недостатка, заключается в построении архитектуры, которая позволяет заранее отобразить каждый текст  $x_i$  из коллекции  $\mathcal{D}$  в его собственный вектор  $\mathbf{v}_i = f(x_i, \alpha)$ . В этом случае вся коллекция текстов может быть векторизована однократно. Процесс поиска для нового запроса  $x_q$  сводится к вычислению его вектора  $\mathbf{v}_q$  и последующему поиску ближайшего соседа в уже готовом векторном пространстве с помощью мер близости, например косинусной. Этот подход, известный как архитектура с двумя кодировщиками (bi-encoder) или сиамская сеть (siamese network), кардинально снижает сложность поиска. Он требует лишь одного применения модели для векторизации запроса, в отличие от  $N$  применений у перекрестного кодировщика.

Следовательно, для создания практических и масштабируемых систем семантического поиска необходимо отказаться от схемы перекрестного кодировщика в пользу архитектуры, способной генерировать высококачественные независимые векторные представления текстов. Далее рассмотрим, как можно дообучить модели типа BERT для решения именно этой задачи.

Несмотря на то, что предобученные на задаче маскированного языкового моделирования (MLM) трансформер-кодировщики, такие как BERT [34] и

RoBERTa [30], способны генерировать контекстуализированные векторные представления для каждого токена, они изначально не оптимизированы для задачи получения единого, семантически осмысленного вектора для целого предложения или документа. Как было показано в разделе 1.3, результатом работы кодировщика является матрица векторов  $\mathbf{H}^{(L)} \in \mathbb{R}^{n_i \times d}$ . Для решения прикладных задач, таких как семантический поиск, кластеризация или верификация фактов, необходимо агрегировать эту последовательность векторов в единственный вектор  $\mathbf{v}_i \in \mathbb{R}^d$ . Этот шаг, однако, не является тривиальным и вскрывает фундаментальное несоответствие между целями предобучения и целями векторизации.

Простейшие стратегии агрегации, или пулинга, включают усреднение векторов всех токенов (Mean Pooling) или использование выходного вектора специального токена [CLS] (CLS Pooling), который добавляется в начало каждой последовательности. В первом случае вектор документа вычисляется как:

$$\mathbf{v}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{h}_j^{(L)},$$

где  $\mathbf{h}_j^{(L)}$  — векторное представление  $j$ -го токена на выходе последнего слоя кодировщика. Во втором случае в качестве вектора документа используется вектор, соответствующий позиции токена [CLS]:

$$\mathbf{v}_i = \mathbf{h}_{\text{CLS}}^{(L)}.$$

Ключевая проблема этих подходов заключается в том, что ни один из этапов предобучения BERT-подобных моделей не ставит своей явной целью формирование семантически структурированного пространства векторов на уровне предложений. Функция потерь MLM, как было описано в разделе 1.4, оптимизирует параметры модели для предсказания маскированных токенов, но не содержит компоненты, которая бы сближала векторы семантически похожих предложений и отдала векторы разных по смыслу. Задача предсказания следующего предложения (NSP) в оригинальном BERT формально обучала вектор  $\mathbf{h}_{\text{CLS}}^{(L)}$  для бинарной классификации, однако, как показали авторы RoBERTa [30], эта задача является слишком грубой и её исключение из процесса предобучения зачастую приводит к улучшению качества итоговых представлений. Таким образом, в современных моделях, отказавшихся от NSP, вектор [CLS] не несет специальной семантической нагрузки на уровне предложения.

Эмпирические исследования подтверждают теоретические недостатки наивных стратегий агрегации. В работе по модели Sentence-BERT [37] было экспериментально показано, что векторные представления, полученные напрямую из BERT без специального дообучения, непригодны для задач семантического поиска. Качество таких векторов оказывается крайне низким, уступая даже более простым неконтекстуализированным моделям, таким как усредненные векторы GloVe[25].

Для преодоления этих ограничений необходим дополнительный этап обучения — дообучение (fine-tuning), направленный на формирование такой структуры векторного пространства, в которой геометрическая близость векторов напрямую соответствует семантической близости текстов. Идея состоит в том, чтобы оптимизировать параметры модели  $\alpha$  с помощью новой функции потерь, которая явно поощряет нужное расположение векторов. Для этого используются обучающие наборы данных, состоящие из пар или троек текстов с известными семантическими отношениями. Архитектурно эта задача решается с помощью сиамских (siamese) сетей, в которых два или более экземпляра одной и той же модели-кодировщика  $f(x, \alpha)$  с общими параметрами  $\alpha$  параллельно обрабатывают входные тексты. Использование общих весов гарантирует, что все тексты отображаются в единое векторное пространство, где их можно сравнивать.

Существует множество подходов к реализации контрастивного дообучения, которые можно разделить на две основные группы в зависимости от структуры используемых обучающих примеров: методы, основанные на тройках текстов, и методы, работающие с парами и формирующие отрицательные примеры динамически.

Первая группа методов оперирует тройками  $(x_a, x_p, x_n)$ , где  $x_a$  — опорный текст («якорь», anchor),  $x_p$  — семантически схожий с ним текст («положительный пример», positive), а  $x_n$  — семантически непохожий текст («отрицательный пример», negative). Цель обучения — минимизировать расстояние между векторами якоря и положительного примера, одновременно максимизируя расстояние между векторами якоря и отрицательного примера. Классическим представителем этого семейства является триплетная функция потерь (Triplet Loss), представленная в работе [38] и успешно адаптированная для текстов в работе [37]. Она формализует требование, чтобы расстояние до отрицательного примера было больше расстояния до положительного как минимум на некоторую величину  $\epsilon > 0$ .

$$\mathcal{L}_{\text{triplet}} = \sum_{i=1}^B \max(0, d(\mathbf{v}_{a,i}, \mathbf{v}_{p,i}) - d(\mathbf{v}_{a,i}, \mathbf{v}_{n,i}) + \varepsilon) \longrightarrow \min_{\alpha}, \quad (1.2)$$

где

$B$  — размер мини-выборки (mini-batch).

$\mathbf{v}_{a,i}, \mathbf{v}_{p,i}, \mathbf{v}_{n,i}$  — векторные представления якоря, положительного и отрицательного примеров из  $i$ -й тройки, полученные с помощью кодировщика  $f(x, \alpha)$ .

$d(\cdot, \cdot)$  — функция расстояния, например, евклидово расстояние.

$\varepsilon > 0$  — гиперпараметр, задающий минимально допустимый зазор (margin).

Основная сложность этого подхода заключается в необходимости формирования качественных троек, в частности, в подборе «трудных» отрицательных примеров (hard negatives), которые не слишком далеки от якоря и заставляют модель изучать тонкие семантические различия.

Вторая, более современная группа методов использует для обучения только положительные пары  $(x_a, x_p)$  и формирует отрицательные примеры «на лету» из других примеров в той же мини-выборке. Такой подход, известный как обучение с отрицательными примерами из выборки (in-batch negatives), значительно эффективнее, так как не требует явного конструирования троек. Одним из наиболее распространенных вариантов является функция потерь InfoNCE (Noise-Contrastive Estimation) [39]. Идея состоит в том, чтобы научиться отличать «настоящий» положительный пример от «шумовых» отрицательных примеров. В контексте векторизации текстов это сводится к различию истинной положительной пары от пар, составленных с отрицательными примерами. Для мини-выборки из  $B$  положительных пар  $\{(x_{a,i}, x_{p,i})\}_{i=1}^B$  функция потерь имеет вид:

$$\mathcal{L}_{\text{InfoNCE}} = -\frac{1}{B} \sum_{i=1}^B \log \frac{e^{s(\mathbf{v}_{a,i}, \mathbf{v}_{p,i})/\tau}}{e^{s(\mathbf{v}_{a,i}, \mathbf{v}_{p,i})/\tau} + \sum_{j=1, j \neq i}^B e^{s(\mathbf{v}_{a,i}, \mathbf{v}_{p,j})/\tau}} \rightarrow \min_{\alpha}, \quad (1.3)$$

где

$\mathbf{v}_{a,i}, \mathbf{v}_{p,i}$  — векторы для  $i$ -й положительной пары.

$\mathbf{v}_{p,j}$  — вектор для  $j$ -го примера из мини-выборки, используемого в качестве отрицательного для  $i$ -й пары.

$s(\cdot, \cdot)$  — функция оценки близости, как правило, косинусная близость.

$\tau > 0$  — температурный коэффициент, который масштабирует распределение оценок. Малые значения  $\tau$  делают распределение более резким, заставляя модель сильнее различать примеры.

Ключевым теоретическим свойством функции InfoNCE является то, что ее минимизация эквивалентна максимизации нижней оценки взаимной информации между представлениями якоря и положительного примера [39]. Это придает подходу прочное теоретическое основание.

## 1.6 Применение и оценка моделей в научной области

После того как модель векторного представления  $f(x, \alpha)$  прошла этапы предобучения и дообучения, ее основной целью становится применение для решения прикладных задач. Ценность современных моделей, основанных на архитектуре трансформер, заключается в том, что масштабное предобучение на гигантских текстовых корпусах позволяет им накопить фундаментальные знания о языке, синтаксисе и семантике. Это знание, закодированное в параметрах  $\alpha$ , может быть эффективно перенесено на новые, в том числе узкоспециализированные, задачи, даже при наличии очень малого количества размеченных данных или вовсе без них. Парадигмы применения в режиме «нулевого выстрела» или с обучением легковесной «головы», описанные в следующем разделе, являются ключевыми инструментами для такого переноса знаний и оценки его успешности.

Существует множество мощных моделей общего назначения, обученных на гетерогенных корпусах огромного объема, таких как веб-страницы (например, Common Crawl) и Wikipedia. Такие модели демонстрируют способность к обобщению и служат надежной отправной точкой для широкого круга задач. Однако их эффективность может снижаться при переносе в предметные области, лексические, стилистические и структурные особенности которых существенно отличаются от усредненного «общего» языка обучающих данных.

Одним из наиболее ярких примеров такой узкоспециализированной области является научный дискурс [40]. Научные тексты обладают рядом уникальных характеристик, отличающих их от новостных статей, художественной литературы или веб-контента.

- **Лексика:** Научные тексты насыщены узкоспециализированной терминологией, обилием акронимов и устойчивых словосочетаний (коллокаций), которые редко встречаются в общеупотребительной лексике.
- **Структура:** Структура научной публикации строго регламентирована (Аннотация, Введение, Методы, Результаты, Заключение). Эта структура сама по себе несет важную семантическую нагрузку, определяя роль и взаимосвязь различных частей текста.
- **Синтаксис и стиль:** Синтаксис зачастую усложнен, с преобладанием длинных предложений, страдательного залога и безличных конструкций. Стиль изложения стремится к максимальной точности, объективности и однозначности формулировок, избегая метафор и многозначности, присущих другим стилям речи.
- **Семантические связи:** Тексты характеризуются высокой плотностью информации и сложными логическими связями между утверждениями. Особую роль играют цитирования, которые формируют неявную семантическую сеть, связывая работы между собой и определяя научный контекст [41].

Это лексическое, структурное и семантическое расхождение создает так называемый доменный сдвиг (domain shift) [42], из-за которого модели общего назначения могут неверно интерпретировать контекст, вес терминов или семантические связи в научной статье.

Таким образом, несмотря на фундаментальную пользу универсальных моделей, для достижения максимального качества в задачах обработки научных текстов предпочтительной является доменная адаптация. Это привело к созданию специализированных моделей, которые либо изначально предобучаются на больших корпусах научных статей, либо проходят дополнительный этап дообучения на них. Такой подход приводит к формированию более качественных векторных представлений. Далее мы рассмотрим конкретные модели, разработанные для научного домена, и способы их оценки.

## Модель SPECTER

Одной из первых моделей, реализующих доменный подход к векторизации научных текстов, стала **SPECTER** (Scientific Paper Embeddings using Citation-informed Transformers) [41]. Ключевая идея авторов заключается в использовании естественного и семантически богатого сигнала, присущего научной среде - цитирований. В отличие от общих задач семантической близости, где пары похожих текстов часто подбираются эвристически или с помощью разметки методами краудсорсинга, граф цитирований предоставляет масштабный и объективный источник информации о смысловой связи между документами.

Модель SPECTER использует в качестве основы трансформер-кодировщик SciBERT [43], предобученный на научных текстах, и дообучает его с помощью триплетной функции потерь. В качестве входных данных для каждой научной статьи  $x_i$  используется конкатенация ее заголовка и аннотации. Обучающие тройки  $(x_q, x_p, x_n)$  формируются непосредственно из графа цитирований:

- **Опорный текст (якорь)**  $x_q$ : произвольная научная статья.
- **Положительный пример**  $x_p$ : статья, которую цитирует якорь  $x_q$ .
- **Отрицательный пример**  $x_n$ : статья, которую якорь  $x_q$  не цитирует.

Процесс дообучения заключается в минимизации триплетной функции потерь, аналогичной выражению (1.2), где в качестве меры расстояния  $d(\cdot, \cdot)$  используется евклидово расстояние ( $L_2$ -норма) между векторными представлениями статей.

$$\mathcal{L}_{\text{SPECTER}} = \max(0, \|\mathbf{v}_q - \mathbf{v}_p\|_2 - \|\mathbf{v}_q - \mathbf{v}_n\|_2 + m) \longrightarrow \min_{\alpha},$$

где  $\mathbf{v}_q, \mathbf{v}_p, \mathbf{v}_n$  — векторные представления, полученные из модели  $f(x, \alpha)$ , а  $m$  — гиперпараметр зазора.

Особое внимание в работе уделено стратегии выбора отрицательных примеров. Помимо случайного выбора из корпуса, авторы вводят понятие «трудных отрицательных примеров» (hard negatives). Такими примерами для якоря  $x_q$  являются статьи, которые цитируются его положительными примерами  $x_p$ , но не самим якорем. Формально, если существует цепочка цитирования  $x_q \rightarrow x_p \rightarrow x_{n'}$ , но при этом отсутствует прямое цитирование  $x_q \not\rightarrow x_{n'}$ , то статья  $x_{n'}$  считается трудным отрицательным примером. Такие примеры семантически близки к яко-

рю, что заставляет модель изучать более тонкие различия между документами, повышая ее разрешающую способность.

## SPECTER2 и мультиформатное обучение

Дальнейшим развитием идей доменной адаптации стала модель **SPECTER2** [44]. Работа над этой моделью была мотивирована важным наблюдением: универсальное векторное представление, даже полученное на основе семантически богатого сигнала цитирований, не может быть одинаково эффективным для решения разнородных прикладных задач. Например, задачи классификации, поиска и регрессии требуют от векторного пространства различной структуры. Для классификации важно, чтобы документы одного класса образовывали линейно разделимые кластеры, тогда как для поиска (ранжирования) первостепенное значение имеет точное сохранение локальной структуры и относительных расстояний между документами.

Модель SPECTER2 отходит от парадигмы «один документ — один вектор» и предлагает концепцию **мультиформатного обучения**. Идея заключается в том, чтобы для одного и того же документа генерировать несколько различных векторных представлений, каждое из которых специализировано для своего формата задач: классификации (Classification, CLF), регрессии (Regression, RGN), поиска по близости (Proximity, PRX) и поиска по произвольному запросу (Ad-hoc Search, SRCH).

Для реализации этого подхода авторы исследовали два основных механизма.

- **Управляющие коды (Control Codes).** Этот метод заключается в добавлении в начало входной последовательности специального токена, соответствующего целевому формату задачи. Например, для получения вектора, оптимизированного для классификации, на вход модели подается последовательность  $x'_i = ([\text{CLF}], x_i)$ , где  $x_i$  — конкатенированные заголовок и аннотация. В качестве итогового представления документа для данного формата используется выходной вектор трансформера, соответствующий позиции этого управляющего токена. Этот подход является

вычислительно эффективным, так как требует лишь добавления нескольких новых токенов в словарь без изменения архитектуры самой модели.

- **Адаптеры (Adapters).** Этот механизм относится к техникам параметро-эффективного дообучения (Parameter-Efficient Fine-Tuning, PEFT) [45]. В каждый слой замороженной базовой модели-кодировщика встраиваются небольшие, легковесные нейросетевые модули — адаптеры. Для каждого формата задач создается свой, независимый набор адаптеров. В процессе обучения настраиваются только параметры этих адаптеров, в то время как основная часть модели остается неизменной. Этот подход позволяет более гибко специализировать модель под каждый формат, хотя и является более сложным в реализации.

Процесс обучения SPECTER2 представляет собой многозадачное обучение с гетерогенной функцией потерь. Обучение происходит на мини-выборках, каждая из которых относится к одному из четырех форматов. В зависимости от формата выборки для вычисления градиента используется своя функция потерь:

- для задач **классификации** — перекрестная энтропия (Cross-Entropy Loss):

$$\mathcal{L}_{\text{CE}} = -\frac{1}{B} \sum_{i=1}^B \sum_{k=1}^K y_{ik} \log(p_{ik}) \longrightarrow \min,$$

где  $B$  — размер мини-выборки,  $K$  — число классов,  $y_{ik}$  — индикатор истинного класса (1, если  $i$ -й пример принадлежит классу  $k$ , и 0 иначе), а  $p_{ik}$  — предсказанная моделью вероятность принадлежности  $i$ -го примера к классу  $k$ .

- для задач **регрессии** — среднеквадратичная ошибка (Mean Squared Error, MSE):

$$\mathcal{L}_{\text{MSE}} = \frac{1}{B} \sum_{i=1}^B (\hat{y}_i - y_i)^2 \longrightarrow \min,$$

где  $\hat{y}_i$  — предсказанное моделью значение для  $i$ -го примера, а  $y_i$  — истинное значение.

- для задач **поиска** (proximity и ad-hoc) — триплетная функция потерь, определенная в выражении (1.2).

## SciNCL: Контрастивное обучение на соседях в графе цитирований

Несмотря на успех модели SPECTER, ее подход к формированию обучающих троек имеет фундаментальное ограничение: он основан на **дискретном сигнале** — факте наличия или отсутствия прямой цитаты. Такой бинарный подход является упрощением, поскольку семантическая близость — это непрерывная величина. Две статьи могут быть очень близки по теме, но не цитировать друг друга, в то время как некоторые цитаты могут быть сделаны из вежливости или для указания на контраргументы, не подразумевая сильной семантической связи [46]. Кроме того, односторонность сигнала (рассматриваются только исходящие цитаты) может приводить к «коллизиям», когда одна и та же пара статей в разных тройках может быть интерпретирована и как положительная, и как отрицательная, что вносит шум в процесс обучения.

Для решения этих проблем была предложена модель SciNCL (Neighborhood Contrastive Learning for Scientific Document Representations with Citation Embeddings) [47]. Ключевое нововведение SciNCL — переход от дискретного сигнала цитирования к мере близости, полученной из структуры всего графа цитирований. Это позволяет реализовать более гибкую и теоретически обоснованную стратегию сэмплирования обучающих примеров.

Подход SciNCL состоит из двух этапов. Сначала на всем графике цитирований научных статей обучается отдельная графовая модель векторного представления, с помощью алгоритма PyTorch BigGraph [48]. Результатом этого этапа является построение вспомогательного пространства векторов  $\{\mathbf{c}_i\}_{i=1}^N$ , где каждый вектор  $\mathbf{c}_i$  кодирует исключительно структурную позицию статьи  $x_i$  в графике цитирований, а расстояние между векторами является мерой их близости. На втором этапе происходит дообучение основной модели-кодировщика  $f(x, \alpha)$  с помощью триплетной функции потерь. В отличие от SPECTER, выбор положительных и отрицательных примеров для опорной статьи  $x_q$  производится на основе ее соседей во вспомогательном пространстве векторов  $\{\mathbf{c}_i\}$ .

Такая двухэтапная схема позволяет реализовать гибкую стратегию выбора примеров, контролируя их сложность. Положительные примеры  $x_p$  сэмплируются из «ближнего» окружения якоря  $x_q$  во вспомогательном пространстве. Это позволяет выбирать не только ближайших и тривиальных соседей, но и так называемые «трудные положительные примеры» (hard positives) — статьи, которые доста-

точно близки, чтобы быть релевантными, но не идентичными. В свою очередь, отрицательные примеры  $x_n$  также могут быть как «легкими» (случайные статьи, далекие от якоря), так и «трудными» (статьи, находящиеся близко к границе, отделяющей положительные примеры).

Ключевым элементом является введение «отступа, определяемого примером» (sample-induced margin) — гиперпараметра, который определяет «мертвую зону» во вспомогательном пространстве между областями сэмплирования положительных и отрицательных примеров. Это гарантирует отсутствие коллизий и чистоту обучающего сигнала.

Итоговая функция потерь идентична той, что используется в SPECTER, — это триплетная функция потерь (1.2). Однако ее эффективность кардинально повышается за счет более совершенного метода формирования троек. Этот метод позволяет модели обучаться на более гладком и непрерывном семантическом сигнале, что приводит к формированию более качественных и робастных векторных представлений научных текстов.

## 1.7 Оценка качества моделей векторного представления текстов

Создание эффективных моделей векторного представления текстов требует не только разработки новых архитектур и методов обучения, но и наличия надежных инструментов для их объективной оценки и сопоставления. Стандартизованные наборы данных и согласованные меры качества, объединенные в так называемые бенчмарки, играют в этом процессе ключевую роль. Они позволяют воспроизведимо и непредвзято сравнивать различные подходы, выявлять их сильные и слабые стороны и направлять дальнейшие исследования. В данной главе рассматриваются основные бенчмарки и меры качества, используемые для оценки моделей в области обработки научных текстов, начиная с основополагающих работ и заканчивая современными комплексными наборами задач.

### 1.7.1 Бенчмарк SciDocs

Одним из первых комплексных инструментов, разработанных специально для оценки качества векторных представлений научных документов, стал бенчмарк **SciDocs** [41]. Его создание было мотивировано тем, что существующие на тот момент наборы данных для оценки семантической близости были либо слишком малы, либо задачи на них были практически решены (меры качества достигали 99%), что не позволяло адекватно сравнивать новые, более мощные модели. SciDocs был предложен как более сложный и разносторонний набор задач, призванный оценить способность моделей к обобщению.

Ключевой принцип, заложенный в SciDocs, — это оценка моделей в режиме «как есть» (as features), то есть без дополнительного дообучения параметров самого кодировщика на задачах бенчмарка. Полученные векторные представления подаются на вход простым, легковесным моделям (например, линейному классификатору), и оценивается именно качество этих представлений как признаков для решения целевых задач. Бенчмарк включает семь задач, сгруппированных в четыре категории.

**Классификация документов.** Эта категория содержит две задачи, проверяющие, насколько хорошо векторное представление кодирует тематическую принадлежность документа. Качество решения в обеих задачах оценивается с помощью **макро-усредненной F1-меры** (Macro F1-score), которая является стандартной мерой для многоклассовой классификации, устойчивой к дисбалансу классов.

- **MeSH Classification.** Задача классификации медицинских статей по 11 высокоуровневым классам заболеваний (например, «сердечно-сосудистые заболевания», «диабет») из тезауруса Medical Subject Headings (MeSH) [49].
- **Paper Topic Classification.** Задача классификации статей по 19 предметным областям первого уровня (например, «Физика», «Математика», «Информатика») из иерархии Microsoft Academic Graph (MAG) [50].

**Предсказание цитирований.** Эти задачи напрямую оценивают способность модели воспроизводить семантический сигнал, заложенный в цитированиях. Обе задачи сформулированы как задачи ранжирования, и их качество оценивается

с помощью стандартных для информационного поиска мер: **средней точности (Mean Average Precision, MAP)** и **нормализованного дисконтированного совокупного выигрыша (Normalized Discounted Cumulative Gain, nDCG)**.

- **Direct Citations.** Для данной статьи-запроса необходимо ранжировать предложенный набор статей-кандидатов таким образом, чтобы цитируемые ею статьи оказались выше в списке, чем случайно выбранные нецитируемые.
- **Co-Citations.** Задача аналогична предыдущей, но вместо прямых цитирований требуется предсказать статьи, которые часто цитируются совместно с запросной статьей, что является сильным индикатором тематической близости.

**Анализ пользовательской активности.** В этой категории в качестве косвенного индикатора семантической близости используется поведение пользователей на крупном научном поисковом портале. Поскольку эти задачи также являются задачами ранжирования, для их оценки применяются те же меры качества: **MAP** и **nDCG**.

- **Co-Views.** Модель должна ранжировать статьи, которые пользователи часто просматривали в рамках одной и той же поисковой сессии, выше, чем случайные статьи.
- **Co-Reads.** Более сильный сигнал, основанный на кликах по PDF-файлам. Предполагается, что если пользователи скачивают несколько статей в одной сессии, эти статьи с высокой вероятностью тесно связаны по теме.

**Рекомендация статей.** Наиболее прикладная задача, в которой векторное представление используется не изолированно, а как один из признаков (feature) в существующей промышленной рекомендательной системе. В качестве мер качества используются **нормализованный дисконтированный совокупный выигрыш (nDCG)** и **точность на первой позиции (Precision@1)**, скорректированные с учетом смещения. Для корректной оценки используется механизм корректировки на основе оценок склонности (propensity scores), чтобы нивелировать смещение, возникающее из-за того, что пользователи чаще кликают на элементы вверху списка.

Таким образом, SciDocs предоставляет разносторонний набор тестов, проверяющих различные аспекты качества векторных представлений, от те-

матической классификации до воспроизведения сложных семантических связей, отраженных в поведении научного сообщества.

### 1.7.2 Бенчмарк SciRepEval

В бенчмарке SciDocs был выявлен ряд ограничений, послуживших предпосылкой для создания более совершенных инструментов оценки. Было показано, что задачи в SciDocs недостаточно разнообразны, а некоторые из них, в частности, задачи поиска со случайно выбранными отрицательными примерами, оказались слишком простыми для современных моделей. Важным недостатком также являлось то, что все задачи в SciDocs были предназначены исключительно для оценки, что не позволяло исследовать эффекты многозадачного обучения на разнообразных данных.

Для устранения этих недостатков был предложен бенчмарк **SciRepEval** [44]. Он включает 24 разноформатные задачи, отражающие практические сценарии использования векторных представлений.

Центральной идеей бенчмарка является разделение задач на четыре концептуальных формата, основанное на гипотезе, что единое векторное представление не может быть оптимальным для всех типов задач одновременно:

- **Классификация (Classification, CLF):** задачи, требующие отнесения документа к одной или нескольким категориям.
- **Регрессия (Regression, RGN):** задачи, где необходимо предсказать непрерывную величину, связанную с документом (например, число цитирований).
- **Поиск по близости (Proximity, PRX):** задачи, где запросом является один документ, и требуется найти другие, семантически близкие к нему документы.
- **Поиск по произвольному запросу (Ad-hoc Search, SRCH):** классические задачи информационного поиска, где запрос представляет собой короткую текстовую строку.

Другим важным нововведением является разделение наборов данных на две группы: **In-Train** и **Out-of-Train**. Это разделение напрямую связано с подходом, предложенным в модели SPECTER2, где для одного документа предлагается

генерировать несколько векторных представлений, каждое из которых специализировано под свой формат задач. Для обучения таких формат-специфичных представлений необходимы соответствующие обучающие данные. Именно для этой цели в SciRepEval были собраны и выделены крупные наборы данных ‘In-Train’, которые авторы предоставили в открытом доступе как часть бенчмарка. Задачи из группы ‘Out-of-Train’ являются полностью отложенными и используются исключительно для оценки способности моделей, обученных на ‘In-Train’ задачах, обобщаться на новые данные и домены.

Для оценки качества в рамках SciRepEval используется широкий спектр мер, соответствующих каждому формату задач. Для классификации применяются бинарная и макро-усредненная **F1-мера**. Для задач регрессии используется ранговая **корреляция Кендалла ( $\tau$ )**, устойчивая к выбросам и нелинейным зависимостям. Качество решения задач поиска оценивается с помощью стандартных мер ранжирования, таких как **MAP** и **nDCG**.

### 1.7.3 Бенчмарк SciFact

В то время как бенчмарки SciDocs и SciRepEval сосредоточены на оценке семантической близости и решении задач классификации или ранжирования, существует качественно иной тип задач, требующий от моделей не простого со-поставления текстов, а логического вывода и верификации фактов. Для оценки моделей в этом, более сложном, сценарии был разработан бенчмарк **SciFact** [51].

Задача, которую ставит SciFact, — это **верификация научного утверждения**. Модели необходимо для заданного утверждения (claim), представляющего собой атомарное, проверяемое высказывание, найти в корпусе научных статей релевантные аннотации и определить, **подтверждает (SUPPORTS)** или **опровергает (REFUTES)** текст аннотации данное утверждение.

Таким образом, задача верификации в SciFact является двухэтапной и включает в себя:

1. **Поиск доказательств (Evidence Retrieval).** На первом этапе для заданного утверждения с модель должна произвести поиск по всему корпусу аннотаций  $\mathcal{A}$  и найти небольшое подмножество  $\mathcal{E}(c) \subset \mathcal{A}$ , содержащее релевантные доказательства.

2. **Предсказание отношения (Stance Prediction).** На втором этапе для каждой найденной пары (утверждение  $c$ , аннотация  $a \in \mathcal{E}(c)$ ) модель должна вынести вердикт, классифицировав их отношение как ‘SUPPORTS’ или ‘REFUTES’.

**Формальная постановка задачи.** В обобщенном виде задачу можно сформулировать следующим образом.

**Дано:** Утверждение  $c$  и корпус аннотаций  $\mathcal{A} = \{a_i\}_{i=1}^N$ .

**Найти:** Множество предсказаний  $\mathcal{S}_{\text{pred}} = \{(a_j, l_j, R_j)\}$ ,

где для каждого предсказания  $j$ :

- $a_j \in \mathcal{A}$  — аннотация, найденная как содержащая доказательство.
- $l_j \in \{\text{SUPPORTS}, \text{REFUTES}\}$  — предсказанное отношение между  $c$  и  $a_j$ .
- $R_j \subseteq \text{sentences}(a_j)$  — предсказанный рациональ, т.е. подмножество предложений из  $a_j$ , обосновывающее метку  $l_j$ .

Ключевой особенностью и усложняющим фактором бенчмарка SciFact является введение понятия **рационаля (rationale)**. Для каждой пары (утверждение, аннотация) с меткой ‘SUPPORTS’ или ‘REFUTES’ в наборе данных также размечен «рациональ» — минимальный набор предложений из аннотации, который является достаточным для эксперта, чтобы обосновать вынесенный вердикт. Это требование подталкивает к созданию интерпретируемых моделей, способных не просто классифицировать, но и указывать на конкретные фрагменты текста, послужившие основанием для вывода.

Оценка качества моделей на бенчмарке SciFact производится на двух уровнях детализации, и в качестве основной меры качества на обоих уровнях используется **F1-мера**.

- **Уровень аннотаций (Abstract Level).** Оценивается способность системы в целом правильно находить аннотации с доказательствами и корректно их классифицировать. Предсказание считается верным, если модель нашла релевантную аннотацию и правильно определила ее отношение к утверждению (‘SUPPORTS’ или ‘REFUTES’).
- **Уровень предложений (Sentence Level).** Более строгая оценка, которая дополнительно проверяет, смогла ли модель правильно выделить рациональ. Предсказание засчитывается, только если помимо правильного поиска и классификации аннотации модель также корректно определила набор предложений, составляющих рациональ.

SciFact представляет собой важный шаг в развитии методов оценки, смещающая фокус с задач семантического сопоставления на задачи, требующие от моделей логического анализа, поиска доказательств и интерпретируемости результатов.

#### 1.7.4 Универсальные бенчмарки: МТЕВ

Проблему фрагментированной оценки, когда модели тестируются лишь на нескольких специфичных задачах (например, только на поиске или только на определении семантической близости), решают универсальные наборы для оценки. Ключевым из них на сегодняшний день является **МТЕВ** (Massive Text Embedding Benchmark) [52].

МТЕВ не вводит принципиально новых задач, а объединяет и стандартизирует большое число уже известных и проверенных научным сообществом наборов данных, включая многие из рассмотренных ранее. Он охватывает широкий спектр из 8 типов задач.

Основной вклад МТЕВ заключается в предоставлении единого программного интерфейса (API) и открытой библиотеки, которая позволяет с минимальными усилиями оценить любую модель векторного представления на всем многообразии задач. Результаты всех моделей собираются в публичную таблицу лидеров, которая служит общепринятым стандартом для сравнения и выбора оптимальной модели для конкретного прикладного сценария.

### 1.8 Основные выводы

Проведенный анализ литературы показал, что современные методы построения семантических векторных представлений основаны на архитектуре Трансформер и двухэтапной парадигме обучения. Она включает масштабное самоконтролируемое предобучение и последующее контрастивное дообучение на сиамских сетях, которое формирует семантически структурированное пространство векторов. Для узкоспециализированных областей, таких как научный дискурс, ключевую роль играет доменная адаптация с использованием специ-

фических сигналов, например графа цитирований, как в моделях SPECTER и SciNCL.

Вместе с тем, обзор выявил ряд фундаментальных ограничений. Во-первых, все рассмотренные передовые модели и бенчмарки (SciDocs, SciRepEval) являются англоязычными, что препятствует их применению к научным корпусам на других языках, включая русский. Во-вторых, отсутствуют подходы к построению двуязычных семантических пространств для научных текстов, которые позволили бы реализовать кросс-языковой поиск.

Эти нерешенные проблемы — англоязычность существующих решений, отсутствие разработанных двуязычных моделей — формируют научную задачу настоящей диссертационной работы. Ее целью является разработка и исследование методов построения эффективных двуязычных семантических векторных представлений для научных документов.

## Глава 2. Разработка и обучение двуязычных моделей векторизации научных текстов SciRus

В настоящей главе описывается процесс разработки семейства легковесных двуязычных моделей SciRus, предназначенных для построения семантических векторных представлений научных текстов. Описывается общая постановка задачи, излагается и обосновывается выбранная архитектура моделей. Детально рассматривается двухэтапная методология обучения, включающая предобучение на большом корпусе неразмеченных научных статей и последующее контрастивное дообучение для формирования семантически и кросс-язычного векторного пространства. Приводятся сведения об использованных наборах данных и параметрах обучения.

### 2.1 Постановка задачи и существующие ограничения

Задачей, решаемой в данной работе, является построение семантических векторных представлений для коллекции научных документов. Формально, дана коллекция документов  $\mathcal{D} = \{x_i\}_{i=1}^N$ , где каждый документ  $x_i$  представляет собой последовательность токенов. Необходимо найти параметризованное отображение  $f(\cdot, \alpha)$ , которое сопоставляет каждому документу  $x_i$  вектор  $\mathbf{v}_i$  в пространстве  $\mathbb{R}^d$ :

$$\mathbf{v}_i = f(x_i, \alpha) \in \mathbb{R}^d.$$

Ключевое требование к этому отображению заключается в том, чтобы геометрическая близость векторов  $\mathbf{v}_i$  и  $\mathbf{v}_j$  в пространстве  $\mathbb{R}^d$  соответствовала семантической близости исходных документов  $x_i$  и  $x_j$ .

Современная парадигма решения этой задачи, как следует из обзора литературы (Глава 1), опирается на архитектуру трансформер-кодировщика и предполагает двухэтапный процесс обучения, в ходе которого параметры  $\alpha$  оптимизируются с помощью градиентного спуска. На первом этапе модель проходит предобучение без учителя на больших неразмеченных текстовых корпусах. Цель этого этапа — выучивание моделью общих языковых закономерностей, синтаксиса и семантики. В качестве критерия используется, как правило, задача

маскированного языкового моделирования (MLM):

$$\sum_{i=1}^N \mathcal{L}_{\text{MLM},i}(\alpha) \rightarrow \min_{\alpha}.$$

Однако, как было показано в разделе 1.5, векторные представления, полученные непосредственно после этапа предобучения, показывают низкое качество на задачах семантического поиска. Для формирования векторного пространства требуется второй этап — контрастивное дообучение. На этом этапе модель обучается на парах или тройках текстов с известными семантическими отношениями с целью сблизить векторы семантически схожих документов и отдалить векторы различных:

$$\sum_{i=1}^N \mathcal{L}_{\text{Contr},i}(\alpha) \rightarrow \min_{\alpha}.$$

Основная ценность полученной модели заключается в возможности последующего использования обученного кодировщика  $f(\cdot, \alpha)$  в качестве универсальной модели. Параметры кодировщика  $\alpha$  фиксируются, и для решения конкретной прикладной задачи (например, классификации или регрессии) на новом, как правило, небольшом наборе данных  $\mathcal{D}' = \{x'_i\}_{i=1}^M$ , где  $M \ll N$ , обучается лишь легковесная модель  $g'(\cdot, \beta')$ :

$$\sum_{i=1}^M \mathcal{L}'_i(g'(f(x'_i, \alpha), \beta')) \rightarrow \min_{\beta'}, \quad (2.1)$$

при этом размерность вектора параметров новой модели значительно меньше исходной:  $\dim(\beta') \ll \dim(\alpha)$ . Такой подход обеспечивает высокую эффективность переноса знаний и минимизирует вычислительные затраты при адаптации к новым задачам.

Несмотря на значительные успехи в этой области, анализ существующих решений (разделы 1.6, 1.7) выявил два ключевых ограничения. Первое — доменная и языковая ограниченность. Подавляющее большинство передовых моделей (SPECTER [41], SciNCL [47]) разработано и ориентировано исключительно на англоязычный научный корпус. Это создает существенный дефицит эффективных инструментов для анализа и поиска в массивах русскоязычных научных публикаций. Второе ограничение — отсутствие эффективных кросс-языковых моделей для научной области. Не существует моделей, способных строить единое семантическое пространство для русских и английских научных текстов, что является

необходимым условием для реализации кросс-языкового поиска и сопоставления исследований, опубликованных на разных языках.

Для преодоления указанных ограничений в рамках данной работы были разработаны модели SciRus. Основными целями при их создании являлись:

- Вычислительная эффективность и легковесность. Создание моделей с малым числом параметров, допускающих обучение и применение при ограниченных вычислительных ресурсах.
- Двуязычность. Обеспечение высокого качества векторных представлений как для русского, так и для английского языков, и формирование единого векторного пространства для эффективного кросс-языкового поиска.
- Высокое качество представлений при малом числе параметров. Разработанные модели должны демонстрировать более высокие показатели качества на целевых задачах по сравнению с аналогами сопоставимого размера. Вместе с тем, их качество должно быть конкурентоспособным на фоне значительно более крупных и ресурсоемких моделей.

Полный спектр целевых задач, используемых для всесторонней оценки качества разработанных моделей, будет подробно представлен в последующих главах, посвященных бенчмаркам RuSciBench (Глава 3) и RuSciFact (Глава 4).

Далее в главе подробно описывается процесс разработки, обучения и оценки моделей SciRus, направленный на достижение поставленных целей.

## 2.2 Наборы данных для обучения

Для обучения моделей SciRus были использованы два крупных мультиязычных корпуса научных текстов: Semantic Scholar Open Research Corpus (S2ORC) и данные российской научной электронной библиотеки eLibrary.ru.

**Semantic Scholar Open Research Corpus (S2ORC)** [53] представляет собой обширный гетерогенный граф знаний, агрегирующий информацию о научных публикациях, авторах и цитированиях из различных источников, включая Crossref, PubMed, Unpaywall и др. Исходно датасет содержит метаданные более чем 200 миллионов публикаций. Для обучения моделей SciRus из S2ORC была сформирована выборка, содержащая заголовки и аннотации научных статей.

Общий объем этой выборки составил около 30,5 миллионов пар "заголовок-аннотация".

В дополнение к текстовым метаданным, ключевым ресурсом для обучения является граф цитирований, предоставляемый S2ORC. Полный граф является чрезвычайно разреженным и содержит более 2.5 миллиардов ребер. Ввиду его масштаба, для обучения была использована подвыборка. Для ее формирования была произведена случайная выборка вершин (статей), после чего в итоговый граф были включены только те ребра, которые соединяют вершины из этой выборки. Полученный таким образом подграф содержит 51 970 696 ребер (цитирований). Этот сигнал о цитировании, как было показано в работах [41; 47], является семантически богатым источником для формирования положительных пар в задачах контрастивного обучения.

Важной характеристикой выборки из S2ORC является ее мультиязычность. Хотя подавляющее большинство текстов представлено на английском языке (приблизительно 83.3%), датасет также включает значительное количество публикаций на других языках, таких как китайский (2.8%), французский (2.6%), испанский (2.4%), немецкий (1.1%) и другие. Русский язык также присутствует, составляя около 0.4% от выборки. Наличие текстов на разных языках, а также пар, где язык заголовка и аннотации различается, создает предпосылки для обучения многоязычных и кросс-языковых способностей моделей.

Статистический анализ длин текстов в англоязычной части выборки показывает, что медианная длина заголовка составляет 81 символ (11 слов), а 95-й перцентиль - 154 символа (21 слово). Для аннотаций медианная длина равна 972 символам (144 слова), а 95-й перцентиль - 2388 символам (354 слова). Эти данные важны для определения максимальной длины входной последовательности моделей.

Тематическое распределение статей в выборке S2ORC охватывает широкий спектр научных областей, включая медицину (14.5%), биологию (9.3%), физику (5.3%), инженерные науки (4.7%), компьютерные науки (4.4%), химию (4.2

**Данные научной электронной библиотеки eLibrary.ru.** Для усиления способностей моделей работать с русскоязычным научным контентом и улучшения кросс-языковых возможностей между русским и английским языками, в обучающий корпус были добавлены данные из крупнейшей российской информационно-аналитической системы eLibrary.ru. Из этого источника было извлечено около 17,7 миллионов пар "заголовок-аннотация".

Особенностью данных из eLibrary.ru является их сбалансированность по русскому и английскому языкам: примерно 8.6 миллионов документов представлено на русском языке и около 8.8 миллионов - на английском. Существенная часть русскоязычных статей (около 5.2 миллионов, согласно оценкам в [9]) имеет также англоязычные версии заголовка и аннотации, что фактически формирует параллельный корпус и является ценным ресурсом для обучения кросс-языковых моделей. Другие языки также присутствуют, но в значительно меньшем объеме (например, украинский - 0.75%, китайский - 0.56%).

Анализ длин текстов показывает, что русскоязычные заголовки имеют медианную длину 80 символов (9 слов), а англоязычные - 91 символ (12 слов). Русскоязычные аннотации в медиане содержат 441 символ (50 слов), англоязычные - 946 символов (138 слов).

Аналогично S2ORC, данные из eLibrary.ru также включают информацию о цитированиях. Сформированный на основе этих данных граф цитирований содержит 39,988,291 ребро. Этот граф, отражающий связи преимущественно в русскоязычном и смешанном научном пространстве, является вторым важнейшим источником структурных данных для формирования обучающих примеров.

Тематический охват статей из eLibrary.ru также широк, включая физические науки (12.1%), клиническую медицину (10.0%), экономику и бизнес (9.7%), химические науки (8.6%), биологические науки (8.5%) и другие области.

Итоговый обучающий корпус был сформирован путем объединения выборок из S2ORC и eLibrary.ru. Суммарный объем составил около 48.2 миллионов пар "заголовок-аннотация", что соответствует примерно 15 миллиардам токенов. Этот объединенный мультиязычный корпус, сочетающий широкий международный охват S2ORC и значительный объем русскоязычных и русско-английских параллельных текстов из eLibrary.ru, послужил основой для двухэтапного процесса обучения моделей SciRus.

### 2.3 Архитектура моделей SciRus

В качестве базовой архитектуры для моделей SciRus была выбрана модель типа RoBERTa [30], являющаяся усовершенствованной версией архитектуры BERT [34]. RoBERTa использует только энкодерную часть трансформера [6]. Для

обеспечения вычислительной легковесности были выбраны конфигурации с относительно небольшим числом параметров.

Конфигурация моделей:

- **SciRus-tiny**: размер векторного представления - 312, общее количество параметров - приблизительно 23 миллиона.
- **SciRus-small**: размер векторного представления - 768, общее количество параметров - приблизительно 61 миллион.

Также модели состоят из 3 слоев, имеют 12 голов внимания. Обе модели могут обрабатывать входные последовательности длиной до 1024 токена. Для токенизации текста используется алгоритм Byte-Pair Encoding (BPE) [27] на уровне байтов (byte-level BPE). Размер словаря для обеих моделей составляет 50265 токенов.

Анализ распределения параметров в моделях SciRus выявляет, что существенная их доля сконцентрирована в слоях векторных представлений токенов (эмбеддингов). Так, для модели SciRus-tiny на слои эмбеддингов приходится около 69.5% всех параметров (16.0 млн из 23.0 млн), а для SciRus-small это значение составляет примерно 64.3% (39.4 млн из 61.2 млн). Данная особенность характерна и для других компактных моделей: например, в ‘cointegrated/rubert-tiny’ [54] доля параметров эмбеддингов достигает 79.6% (9.4 млн из 11.8 млн), а в ‘cointegrated/rubert-tiny2’ [11] — даже 91.8% (26.8 млн из 29.2 млн). В то же время, у более крупных моделей, таких как ‘allenai/specter’ [41], это соотношение иное: на слои эмбеддингов приходится лишь около 22.1% параметров (24.3 млн из 109.9 млн).

Уменьшение доли параметров, отводимых на эмбеддинги, в компактных моделях сопряжено со значительными трудностями. Основной способ сокращения размера слоев эмбеддингов заключается в уменьшении размера словаря, поскольку число параметров слоя эмбеддингов напрямую зависит от произведения размера словаря на размерность вектора эмбеддинга ( $V \times H$ , где  $V$  — размер словаря,  $H$  — размерность эмбеддинга). Однако существенное сокращение размера словаря негативно сказывается на качестве токенизации. Слишком маленький словарь приводит к тому, что многие слова, особенно в языках с богатой морфологией, таких как русский, будут разбиваться на большое количество более мелких субсловных единиц или даже отдельных символов. Это, в свою очередь, ведет к увеличению средней длины токенизированной последовательности для одного и того же текста, что не только повышает вычислительную нагрузку, но и может затруднить модели улавливание семантических связей из-за чрезмерной грану-

лярности представления. Таким образом, для обеспечения адекватного качества токенизации необходимо поддерживать достаточно большой размер словаря, даже если это приводит к увеличению относительной доли параметров, занимаемых слоями эмбеддингов в малопараметрических моделях.

Выбор таких конфигураций позволил создать модели, которые значительно меньше по сравнению со стандартными базовыми моделями (например, BERT-base имеет 110 млн параметров, RoBERTa-base - 125 млн), что напрямую приводит к меньшему потреблению памяти и более высокой скорости применения модели. SciRus-tiny представляет собой наиболее легковесный вариант, в то время как SciRus-small предлагает компромисс между эффективностью и потенциально более высоким качеством представлений за счет увеличенного числа параметров. Увеличенная до 1024 токенов максимальная длина контекста (по сравнению с типичными 512 токенами для многих моделей BERT-типа) позволяет обрабатывать более длинные фрагменты текста, что может быть важно для аннотаций или других научных текстов.

## 2.4 Методология обучения

Процесс обучения моделей SciRus состоял из двух последовательных этапов: предобучение с использованием задачи маскированного языкового моделирования (MLM) и последующее контрастивное дообучение.

### 2.4.1 Предобучение с использованием Masked Language Modeling (MLM)

На первом этапе модели SciRus проходили предобучение с нуля, инициализируясь случайными весами. В качестве обучающих данных на этом этапе использовался исключительно объединенный текстовый корпус, состоящий из заголовков и аннотаций из наборов данных S2ORC и eLibrary.ru. Структурная информация из графов цитирований на данном этапе не применялась.

Обучение проводилось с использованием маскированного языкового моделирования (MLM), унаследованной от архитектуры RoBERTa, с применением

динамического маскирования. Формальное описание данного метода и параметры маскирования были подробно изложены в разделе 1.4. Оптимизация параметров моделей осуществлялась путем минимизации функции потерь перекрестной энтропии, формальное определение которой было также дано в обзоре литературы (раздел 1.4).

Процесс предобучения продолжался в течение двух эпох. Для контроля сходимости и предотвращения переобучения была сформирована валидационная подвыборка размером 1% от общего объема данных. График сходимости функции потерь (Рисунок 2.1) демонстрирует синхронное снижение ошибки как на обучающей, так и на валидационной выборках, с выходом на плато к концу второй эпохи. Анализ промежуточных результатов на бенчмарках SciDocs и RuSciBench (Рисунки 2.2 и 2.3) также подтвердил, что дальнейшее обучение не приводило к значимому улучшению качества представлений.




Рисунок 2.1 — Значение функции ошибки моделей SciRus

После завершения этапа MLM-предобучения модели приобретают способность генерировать контекстуализированные векторные представления для отдельных токенов, а не для текстов как целостных единиц. Эти представления, полученные на уровне токенов, еще не оптимизированы для задач семантического поиска или сравнения текстов на уровне документа. Для этой цели предназначен второй этап обучения.




Рисунок 2.2 — Прогресс обучения моделей SciRus на англоязычном бенчмарке SciDocs.




Рисунок 2.3 — Прогресс обучения моделей SciRus на русскоязычном бенчмарке RuSciBench.

## 2.4.2 Контрастивное дообучение

На втором этапе модели, предобученные с помощью MLM, проходили дообучение с использованием контрастивного подхода. Цель этого этапа — преобразовать векторные представления, полученные на уровне токенов, в семантически согласованные векторы на уровне документов, пригодные для задач поиска и сравнения. Для агрегации векторов токенов в единый вектор документа применялся метод усреднения (Mean Pooling), как и в ряде других успешных моделей [8; 37].

В качестве основного метода обучения использовалась функция потерь InfoNCE, формальное описание которой приведено в разделе 1.5 (см. формулу 1.3). В качестве меры близости  $s(\cdot, \cdot)$  применялась косинусная близость, а температурный коэффициент  $\tau$  был установлен равным 0.01. Во всех случаях отрицательные примеры для каждой опорной статьи формировались из других примеров в той же мини-выборке (стратегия "in-batch negatives").

В рамках исследования были реализованы и обучены две версии моделей, различающиеся наборами данных и, соответственно, типами семантических сигналов, использованных для контрастивного обучения.

**Обучение на парах «заголовок–аннотация».** Первая версия моделей обучалась исключительно на парах, сформированных из текстовых метаданных. В этом подходе для формирования  $i$ -й положительной пары  $(x_{a,i}, x_{p,i})$  в качестве опорного примера (anchor)  $x_{a,i}$  использовался заголовок научной статьи, а в качестве положительного примера (positive)  $x_{p,i}$  — аннотация той же статьи. Этот метод основан на предположении о высокой семантической близости между заголовком и аннотацией одного документа.

Ключевой особенностью этого подхода является обучение кросс-языковых представлений. Для статей из набора данных eLibrary.ru, имеющих аннотации на русском и английском языках, пары формировались случайным образом. Например, в качестве опорного примера мог быть выбран заголовок на русском языке, а в качестве положительного — аннотация на английском. Такая стратегия заставляет модель выравнивать векторные пространства для разных языков, обучаясь сопоставлять семантически эквивалентные тексты независимо от языка их написания.

**Обучение с использованием комбинированных данных.** Для обучения второй версии моделей был сформирован объединенный набор данных, представляющий собой конкатенацию двух типов положительных пар: (1) пар «заголовок–аннотация», описанных в предыдущем пункте, и (2) пар, сформированных на основе графов цитирований S2ORC и eLibrary.ru. При формировании пар на основе цитирований в качестве опорного примера  $x_{a,i}$  использовалась конкатенация заголовка и аннотации цитирующей статьи, а в качестве положительного примера  $x_{p,i}$  — конкатенация заголовка и аннотации цитируемой статьи. Кросс-языковая стратегия сэмплирования применялась для всего объединенного набора данных: опорный и положительный примеры могли быть представлены на разных языках, что дополнительно усиливало выравнивание семантических пространств.

В результате были получены две линейки моделей. Модели, обученные исключительно на парах «заголовок–аннотация», в дальнейшем будут называться SciRus-tiny и SciRus-small. Модели, при обучении которых дополнительно использовались данные о цитированиях, получат суффикс -cite: SciRus-tiny-cite и SciRus-small-cite.

Динамика улучшения качества на бенчмарках SciDocs и RuSciBench в ходе контрастивного дообучения представлена на Рисунках 2.4 и 2.5 соответственно. Обучение также проводилось в течение 2 эпох. Этот этап позволил моделям SciRus достичь высоких результатов, в том числе на задачах кросс-языкового поиска, что подтверждает эффективность выбранных стратегий обучения.

## 2.5 Оценка качества моделей SciRus

Для всесторонней оценки качества разработанных моделей SciRus был проведен их сравнительный анализ с другими известными моделями. Отбор моделей для сравнения производился по двум ключевым принципам. Во-первых, в состав сопоставляемых решений были включены ведущие общечелевые англоязычные и многоязычные модели, занимающие лидирующие позиции в авторитетном международном лидерборде MTEB (Massive Text Embedding Benchmark) [52]. Такой выбор позволяет сопоставить модели SciRus с наиболее сильными современными решениями, не имеющими узкой доменной специализации. Во-вторых,




Рисунок 2.4 — Прогресс дообучения моделей SciRus на англоязычном бенчмарке SciDocs.




Рисунок 2.5 — Прогресс дообучения моделей SciRus на русскоязычном бенчмарке RuSciBench.

для корректной оценки в рамках целевой области, в сравнение были добавлены специализированные модели, разработанные для векторизации именно научных текстов, такие как SPECTER [41] и SciNCL [47]. Такой двухкомпонентный подход к формированию выборки для сравнения обеспечивает возможность объективно оценить как конкурентоспособность моделей SciRus на фоне универсальных лидеров, так и их преимущества в решении задач научной области. Полный перечень использованных моделей, упорядоченный по дате публикации, представлен в таблице 1.

Таблица 1 — Список моделей для сравнения

Модель	Количество параметров	Дата публикации	Ссылка
SPECTER	110 млн	01-2021	<a href="#">allenai/specter</a>
SciNCL	110 млн	02-2022	<a href="#">malteos/scincl</a>
sn-xlm-roberta-base-snli-mnli-anli-xnli	278 млн	03-2022	<a href="#">symanto/sn-xlm-roberta-base-snli-mnli-anli-xnli</a>
paraphrase-multilingual-mpnet-base-v2	278 млн	03-2022	<a href="#">sentence-transformers/paraphrase-multilingual-mpnet-base-v2</a>
LaBSE-en-ru	129 млн	03-2022	<a href="#">cointegrated/LaBSE-en-ru</a>
multilingual-e5-base	278 млн	05-2023	<a href="#">intfloat/multilingual-e5-base</a>
multilingual-e5-large	560 млн	06-2023	<a href="#">intfloat/multilingual-e5-large</a>
multilingual-e5-small	118 млн	06-2023	<a href="#">intfloat/multilingual-e5-small</a>
SFR-Embedding-Mistral	7 млрд	01-2024	<a href="#">Salesforce/SFR-Embedding-Mistral</a>
GritLM-7B	7.24 млрд	02-2024	<a href="#">GritLM/GritLM-7B</a>
multilingual-e5-large-instruct	560 млн	02-2024	<a href="#">intfloat/multilingual-e5-large-instruct</a>

## Продолжение таблицы 1

Модель	Количество параметров	Дата публикации	Ссылка
GIST-large-Embedding-v0	335 млн	02-2024	<a href="#">avsolatorio/GIST-large-Embedding-v0</a>
Linq-Embed-Mistral	7 млрд	05-2024	<a href="#">Linq-AI-Research/Linq-Embed-Mistral</a>
<b>SciRus-small-cite</b>	61 млн	05-2024	<a href="#">mlsa-iai-msu-lab/sci-rus-small-cite</a>
<b>SciRus-tiny-cite</b>	23 млн	05-2024	<a href="#">mlsa-iai-msu-lab/sci-rus-tiny3-cite</a>
<b>SciRus-small</b>	61 млн	05-2024	<a href="#">mlsa-iai-msu-lab/sci-rus-small</a>
<b>SciRus-tiny</b>	23 млн	05-2024	<a href="#">mlsa-iai-msu-lab/sci-rus-tiny</a>

Для оценки и сопоставления с существующими решениями было проведено сравнительное тестирование разработанных моделей на общепринятом англоязычном бенчмарке SciDocs [41]. На момент проведения исследования устоявшиеся и публично доступные наборы данных для оценки качества семантических представлений в русскоязычной научной области отсутствовали. Именно для устранения этого пробела в рамках настоящей диссертационной работы были разработаны специализированные бенчмарки RuSciBench и RuSciFact. Детальное описание этих наборов данных, а также исчерпывающие результаты сравнительного тестирования всех моделей на них, будут представлены в последующих главах 3 и 4 соответственно. Результаты на англоязычном бенчмарке SciDocs приведены в таблице 2.

Анализ результатов, представленных в таблице 2, позволяет сделать следующие выводы. На англоязычном наборе данных SciDocs наилучшие средние показатели качества демонстрируют модели GIST-large-Embedding-v0, paraphrase-multilingual-mrnet-base-v2 и SciNCL.

Вместе с тем, разработанные модели семейства SciRus, обученные с использованием данных о цитированиях, показывают высокий и конкурентоспособный уровень. Так, модель SciRus-small-cite со средним значением 90.02 достигает качества, сопоставимого с результатами специализированной модели SciNCL,

Model	MAG	MeSH	Cite		CoView		CoCite		CoRead		Среднее
			map	nDCG	map	nDCG	map	nDCG	map	nDCG	
SciRus-tiny	82.01	85.98	84.17	93.03	81.37	90.46	83.31	92.59	81.45	90.88	86.53
SciRus-small	81.88	88.28	83.66	92.90	81.29	90.53	84.07	92.96	82.13	91.15	86.89
SciRus-tiny-cite	82.01	89.48	90.30	95.83	84.19	91.76	88.85	95.18	85.21	92.64	89.55
SciRus-small-cite	83.13	90.25	89.80	95.50	84.64	91.99	89.91	95.65	86.15	93.20	90.02
sn-xlm-roberta-base-snli-mnli-anli-xnli	75.05	72.97	68.41	84.33	70.06	84.22	67.71	83.60	68.94	83.66	75.89
LaBSE-en-ru	78.87	73.46	70.77	85.89	74.61	87.03	74.85	88.07	73.24	86.47	79.33
multilingual-e5-small	82.14	88.06	81.23	91.71	81.26	90.37	83.38	92.73	80.78	90.60	86.23
multilingual-e5-base	82.11	88.86	82.79	92.43	81.37	90.38	84.67	93.29	82.05	91.27	86.92
multilingual-e5-large	83.40	89.97	83.35	92.74	81.76	90.50	85.74	93.86	82.48	91.46	87.53
Ling-Embed-Mistral	79.63	88.43	86.94	94.42	84.08	91.87	88.12	94.97	85.97	93.27	88.77
SFR-Embedding-Mistral	79.05	87.70	86.67	94.35	84.92	92.26	88.44	95.07	86.64	93.60	88.87
SPECTER	79.40	87.70	92.00	96.60	83.40	91.40	88.00	94.70	85.10	92.70	89.10
multilingual-e5-large-instruct	83.49	89.67	86.87	94.49	84.20	91.88	88.17	94.94	85.22	92.88	89.18
GritLM-7B	84.63	90.38	88.19	95.04	84.12	91.72	88.92	95.22	85.68	93.12	89.70
SciNCL	81.11	89.00	93.55	97.35	85.28	92.23	91.66	96.44	87.69	94.00	90.84
paraphrase-multilingual-mpnet-base-v2	82.61	89.52	92.97	97.04	85.67	92.44	92.37	96.79	87.18	93.74	91.03
GIST-large-Embedding-v0	82.81	90.79	93.30	97.27	85.72	92.50	91.95	96.63	87.61	93.99	<b>91.26</b>

Таблица 2 — Сравнение моделей на бенчмарке SciDocs

уступая ей менее одного процентного пункта, но при этом имея почти вдвое меньшее число параметров (61 млн против 110 млн). Более того, данная модель превосходит не только SPECTER, но и значительно более крупные модели общего назначения, такие как multilingual-e5-large-instruct и GritLM-7B. Наиболее легковесный вариант, SciRus-tiny-cite (23 млн параметров), также демонстрирует высокий результат.

Следует отметить, что распределение лидеров по отдельным задачам неоднородно. В задачах тематической классификации (MAG, MeSH) преимущество остается за крупными англоязычными кодировщиками, такими как GritLM и GIST-large-Embedding-v0. В задачах, основанных на анализе структуры цитирований, наилучшие результаты показывают SciNCL (прямое цитирование, Cite) и paraphrase-multilingual-mpnet-base-v2 (совместная цитируемость, Co-cite). Наконец, в задачах, связанных с пользовательской активностью, лидируют GIST (совместные просмотры, Co-view) и SciNCL (совместные прочтения, Co-read).

Таким образом, полученные результаты подтверждают, что разработанные легковесные модели SciRus, обученные с использованием информации о цитированиях, не только сокращают разрыв в качестве с передовыми и значительно более ресурсоемкими англоязычными аналогами, но и превосходят многие из них. Это утверждение справедливо в том числе и при сравнении со специализированными научными моделями.

Следует особо подчеркнуть, что ведущие модели для научной области, SPECTER и SciNCL, ограничены поддержкой исключительно английского языка. На их фоне модели SciRus не только демонстрируют сопоставимое, а в ряде случаев и более высокое качество при меньшем числе параметров, но и являются полностью двуязычными, что является их принципиальным преимуществом. Это подтверждает высокую эффективность выбранной стратегии обучения для формирования компактных, но при этом высококачественных и кросс-языковых семантических представлений научных текстов.

## 2.6 Оценка производительности

В дополнение к качественным характеристикам, одной из ключевых целей при разработке моделей SciRus являлось обеспечение их высокой вычислительной эффективности и легковесности. Для экспериментального подтверждения достижения этой цели были проведены замеры скорости векторизации текстов на центральном процессоре (CPU). Для применения моделей и проведения тестов использовался фреймворк Text Embeddings Inference [55]. Данное решение было выбрано, поскольку оно предназначено для промышленного применения моделей векторизации. Тестирование всех моделей проводилось в одинаковых условиях на CPU Intel(R) Xeon(R) CPU @ 2.20GHz с использованием 2 ядер. В качестве инструмента для нагружочного тестирования использовалась библиотека k6 [56], представляющая собой современное средство для оценки производительности систем. В ходе эксперимента каждая сравниваемая модель обрабатывала запросы в течение 60 секунд. В качестве входных данных для моделей использовались случайно выбранные тексты, представляющие собой конкатенацию заголовка и аннотации научной статьи из набора данных, сформированного на основе публикаций научной электронной библиотеки eLibrary.ru. Полученные данные о времени инференса на CPU для различных моделей, сведены в таблицу 3.

Результаты, приведенные в таблице 3, демонстрируют существенное превосходство моделей семейства SciRus по скорости инференса на CPU. Модель SciRus-tiny показывает наилучшее среднее время отклика. Модель SciRus-small, имея большее число параметров, также демонстрирует высокую производитель-

Таблица 3 — Сравнение среднего времени инференса различных моделей на CPU.

Модель	Количество параметров (млн.)	Среднее время инференса (с)	Время инференса p95 (с)
SciRus-tiny	23	0.23	0.49
SciRus-small	61	0.44	0.95
paraphrase-multilingual-mpnet-base-v2	278	1.61	3.26
multilingual-e5-large-instruct	560	5.19	9.27
SciNCL	110	6.77	14.71
SPECTER	110	9.14	16.13

ность, оказываясь примерно в 3.7 раза быстрее ближайшей по этому показателю модели paraphrase-multilingual-mpnet-base-v2.

## 2.7 Практическая апробация и внедрение модели SciRus-tiny

Одним из ключевых результатов диссертационной работы является не только разработка и оценка моделей, но и подтверждение их практической значимости путем внедрения в реальные информационно-поисковые системы. Для этой цели, в сотрудничестве с крупнейшей российской научной электронной библиотекой eLibrary.ru, был разработан и внедрен новый функционал семантического поиска, получивший название «нейропоиск». В качестве основы для данного функционала была выбрана легковесная модель SciRus-tiny, поскольку она продемонстрировала оптимальное сочетание высокого качества векторных представлений и вычислительной эффективности, что является критически важным для применения в высоконагруженных промышленных системах.

Процесс работы системы «нейропоиск» можно формально разделить на два основных этапа: предварительное индексирование и обработка поискового запроса в режиме реального времени. На первом этапе была проведена векторизация всего корпуса аннотаций, доступных на портале eLibrary.ru. Для каждой аннотации  $x_i$  из коллекции  $D_{EL}$  было получено её семантическое векторное представление  $v_i$  с помощью разработанной модели:

$$v_i = f(x_i, \alpha_{tiny})$$

где  $f$  — функция модели-кодировщика, а  $\alpha_{\text{tiny}}$  — параметры обученной модели SciRus-tiny. Полученный массив векторов  $\{v_i\}$  был помещен в специализированную векторную базу данных, обеспечивающую возможность быстрого поиска ближайших соседей. На втором этапе, при обращении пользователя к системе, его текстовый запрос  $x_q$  (аннотация, фрагмент или полный текст документа) также преобразуется в векторное представление  $v_q = f(x_q, \alpha_{\text{tiny}})$ . Затем, после применения стандартных категориальных фильтров (год публикации, тип документа и др.), система производит поиск в векторной базе данных. Итоговый список публикаций ранжируется по убыванию значения косинусной меры близости между вектором запроса  $v_q$  и векторами документов  $v_i$  из отфильтрованной выборки. Интерфейс данного режима представлен на Рисунке 2.6.




Рисунок 2.6 — Интерфейс режима «нейропоиск» на портале eLibrary.ru, использующего модель SciRus-tiny.

Внедрение семантического поиска на основе модели SciRus-tiny открывает новые аналитические возможности для исследователей, существенно расширяя функционал традиционного поиска по ключевым словам. Основное применение данный инструмент находит при написании обзоров литературы, позволяя быстро находить релевантные публикации, даже если они не содержат точных терминов из запроса, но близки к нему по смыслу. Кроме того, «нейропоиск» является

эффективным инструментом для решения ряда смежных задач: подбора экспертов для рецензирования рукописей или оценки грантовых заявок путем поиска авторов наиболее близких по тематике работ; выявления ведущих научных организаций и коллективов, работающих в заданной предметной области; а также для предварительного анализа в рамках патентного поиска. Таким образом, данный инструмент трансформирует процесс взаимодействия с научными данными, смещающая акцент с лексического совпадения на семантическую близость, что способствует более глубокому и всестороннему анализу научной информации.

## **2.8 Основные выводы**

В настоящей главе был детально описан процесс разработки семейства легковесных двуязычных моделей SciRus, предназначенных для построения семантических векторных представлений научных текстов. Была обоснована выбранная архитектура на основе трансформера-кодировщика с уменьшенным числом параметров для обеспечения вычислительной эффективности и представлена двухэтапная методология обучения. На первом этапе, посредством задачи маскированного языкового моделирования на объединенном корпусе русско- и англоязычных статей, модели освоили общие языковые закономерности. На втором этапе, с помощью контрастивного дообучения, было сформировано единое семантическое пространство. Для этого использовались два типа обучающих сигналов: семантическая связь между заголовком и аннотацией, а также структурная информация из графов цитирований.

Проведенная предварительная оценка на англоязычном бенчмарке SciDocs продемонстрировала высокую конкурентоспособность разработанных моделей. В частности, было показано, что легковесные двуязычные модели SciRus достигают качества, сопоставимого и даже превосходящего качество значительно более крупных и исключительно англоязычных специализированных аналогов. Эксперименты по оценке производительности подтвердили их вычислительную эффективность, что было одной из ключевых целей разработки. Практическая значимость работы подтверждена успешным внедрением модели SciRus-tiny в промышленную эксплуатацию в составе информационно-поисковой системы научной электронной библиотеки eLIBRARY.RU. Таким образом, в настоящей

главе были созданы и верифицированы эффективные инструменты для семантического анализа научных текстов. Их всесторонняя и углубленная оценка на задачах русскоязычной и кросс-языковой научной области будет предметом рассмотрения в последующих главах, посвященных бенчмаркам RuSciBench и RuSciFact.

### Глава 3. Мультизадачный бенчмарк для оценки моделей векторного представления русско- и англоязычных научных текстов

Объективная оценка и направленное совершенствование моделей векторизации текста невозможны без стандартизованных инструментов — бенчмарков. Такие инструменты, включающие разнообразные наборы данных и задачи, позволяют проводить воспроизводимые эксперименты и получать сопоставимые результаты, что является фундаментом для развития технологий обработки естественного языка. В последние годы для русского языка был разработан ряд общеязыковых бенчмарков, таких как RuSentEval [10] и encodechka [11]. Однако, несмотря на их ценность, существует значительный пробел в области оценки моделей, работающих с научными текстами.

Научный дискурс имеет выраженную специфику: он характеризуется использованием узкоспециализированной терминологии, высокой информационной плотностью, сложной синтаксической структурой и формальным стилем изложения. Эти особенности приводят к тому, что качество работы модели, измеренное на общелитературных или новостных текстах, не является надежным показателем ее эффективности в научном домене. В то время как для английского языка существуют специализированные научные бенчмарки, например SciDocs [41], для русского языка до недавнего времени подобные инструменты практически отсутствовали. Единственным известным примером является бенчмарк RuMedBench [57], но его применимость ограничена исключительно медицинской областью, что оставляет без внимания множество других научных дисциплин.

Этот дефицит инструментов для оценки моделей на русскоязычном научном материале является серьезным препятствием для исследователей. Он затрудняет не только сравнительный анализ существующих и вновь создаваемых моделей, но и обоснованный выбор наиболее подходящего инструмента для решения конкретных прикладных задач, таких как семантический поиск, классификация научных статей.

Для устранения этого пробела был разработан RuSciBench — мультизадачный и двуязычный бенчмарк, целенаправленно созданный для всесторонней оценки качества векторных представлений научных текстов на русском языке. Он охватывает широкий спектр задач, и предоставляет исследователям стандартизированную и воспроизводимую методологию тестирования. В настоящей главе

будет подробно рассмотрена архитектура бенчмарка RuSciBench, описан состав входящих в него наборов данных и задач, представлена методология проведения оценки и приведены результаты, полученные для набора базовых моделей.

### 3.1 Источники данных и подготовка корпуса

В качестве основного источника данных для создания бенчмарка RuSciBench был выбран крупнейший российский ресурс научных публикаций – электронная библиотека eLibrary.ru<sup>1</sup>. Эта платформа содержит обширный архив статей, диссертаций, монографий и материалов конференций, преимущественно на русском языке, с аннотациями на английском. Выбор eLibrary.ru обусловлен её представительностью для русскоязычной научной среды, а также наличием структурированных метаданных, включая рубрикацию, информацию о цитированиях и типах публикаций, что позволяет формировать разнообразные задачи оценки.

Для обеспечения двуязычности корпуса и возможности включения задач кросс-языкового поиска были отобраны только те статьи, для которых доступны аннотации как на русском, так и на английском языке. Это гарантирует сопоставимость представлений текстов на разных языках и позволяет оценивать модели в условиях, приближенных к реальным сценариям многоязычного анализа научных документов.

В процессе анализа данных были выявлены наиболее частотные проблемы с качеством данных, для устранения которых был разработан многоэтапный процесс очистки, включающий удаление всех HTML-тегов и специальных символов с использованием регулярных выражений, дедупликацию, фильтрацию аннотаций по минимальной длине для обеспечения достаточной информативности (более 50 символов), а также автоматическое определение языка текста. Определение языка проводилось с помощью библиотеки Lingua [58], выбранной из-за её высокой точности на коротких текстах (средняя точность для русского языка составляет 97.57%, для английского - 98.7% на наборе данных, состоящем из предложений) и превосходству над альтернативами (такими как langdetect[59] или fastText[60]) в сценариях с смешанными языками и шумными данными. Эта процедура была

---

<sup>1</sup><https://www.elibrary.ru>

необходима, поскольку исходные метки языка в данных eLibrary.ru не всегда соответствовали реальности, что могло привести к искажениям в оценке моделей.

В результате применения процесса очистки было отфильтровано около 7,6% исходных записей. Финальный корпус содержит 182 264 статьи, каждая из которых включает заголовок и аннотацию на русском и английском языках, а также метаданные. Статистические характеристики корпуса приведены в таблице 5, где указано распределение длин текстов.

Таблица 5 — Распределение числа символов в заголовках и аннотациях

Язык	Тип	Среднее	25%	50%	75%
Русский	Заголовок	89	65	85	108
Английский	Заголовок	90	65	85	109
Русский	Аннотация	769	340	564	1044
Английский	Аннотация	807	347	586	1110

Подготовленный корпус обеспечивает высокое качество данных и позволяет проводить объективную оценку моделей векторных представлений в научной домене, учитывая специфику русскоязычных текстов.

### 3.2 Состав и методология оценки в бенчмарке RuSciBench

Бенчмарк RuSciBench, разработанный в соавторстве [15], представляет собой комплексный инструментарий, предназначенный для разносторонней оценки моделей семантического векторного представления научных текстов. Он включает задачи трех типов, отражающих ключевые сценарии использования векторных представлений в научной среде: классификация документов, регрессионный анализ и информационный поиск. Каждая из 9 уникальных задач представлена в двуязычном формате (на русском и английском языках), что в совокупности составляет 18 наборов данных. Такое разнообразие позволяет выявлять сильные и слабые стороны моделей, оценивая их способность кодировать как тематическую принадлежность, так и более тонкие семантические и структурные характеристики текста.

В рамках данной совместной работы вклад соискателя заключался в разработке и реализации задач, относящихся к каждому из этих трех типов. Со-

ответственно, в последующих разделах будет представлено детальное описание именно этих составных частей бенчмарка.

Для проведения всесторонней и объективной оценки на задачах бенчмарка RuSciBench был сформирован широкий и репрезентативный набор моделей-конкурентов. Чтобы составить полную картину качества современных решений, отбор моделей производился на основе их позиций в двух авторитетных лидербордах, входящих в состав Massive Text Embedding Benchmark (MTEB) [52]: основного англоязычного (MTEB leaderboard) и его русскоязычной версии.

Важным аспектом является поддержание бенчмарка в актуальном состоянии, поскольку ценность такого инструмента определяется не только первоначальной публикацией, но и его способностью отражать текущее состояние области. В связи с этим, первоначальный список моделей, оцененных на момент публикации бенчмарка, был существенно расширен. В него были добавлены новые передовые модели, появившиеся после публикации. Таким образом, итоговый набор для оценки включает в себя все модели, представленные в таблице 1 из предыдущей главы, а также ряд актуальных на текущий момент решений. Перечень использованных для оценки моделей в дополнение к таблице 1, упорядоченный по дате их публикации, представлен в таблице 6.

Таблица 6 — Список моделей, оцененных на бенчмарке RuSciBench

Модель	Количество параметров	Дата публикации	Ссылка
rubert-tiny2	29 млн	03-2022	<a href="#">cointegrated/rubert-tiny2</a>
rubert-tiny	12 млн	03-2022	<a href="#">cointegrated/rubert-tiny</a>
SFR-Embedding-2_R	7.11 млрд	06-2024	<a href="#">Salesforce/SFR-Embedding-2_R</a>
gte-Qwen2-7B-instruct	7 млрд	06-2024	<a href="#">Alibaba-NLP/gte-Qwen2-7B-instruct</a>
gte-Qwen2-1.5B-instruct	1 млрд	06-2024	<a href="#">Alibaba-NLP/gte-Qwen2-1.5B-instruct</a>
USER-base	124 млн	06-2024	<a href="#">deepvk/USER-base</a>
rubert-tiny-turbo	29 млн	06-2024	<a href="#">sergeyzh/rubert-tiny-turbo</a>
USER-bge-m3	359 млн	07-2024	<a href="#">deepvk/USER-bge-m3</a>
NV-Embed-v2	7 млрд	08-2024	<a href="#">nvidia/NV-Embed-v2</a>

## Продолжение таблицы 6

Модель	Количество параметров	Дата публикации	Ссылка
jina-embeddings-v3	572 млн	09-2024	<a href="#">jinaai/jina-embeddings-v3</a>
Giga-Embeddings-instruct	2 млрд	12-2024	<a href="#">ai-sage/Giga-Embeddings-instruct</a>
FRIDA	823 млн	12-2024	<a href="#">ai-forever/FRIDA</a>
BERTA	128 млн	03-2025	<a href="#">sergeyzh/BERTA</a>
rubert-mini-frida	32 млн	03-2025	<a href="#">sergeyzh/rubert-mini-frida</a>

### 3.2.1 Задачи классификации документов

Задачи классификации направлены на оценку способности векторного представления агрегировать и сохранять информацию о принадлежности документа к определенному семантическому классу. Формально, пусть дана коллекция документов  $\mathcal{D} = \{x_i\}_{i=1}^N$  и конечное множество меток  $C = \{c_1, \dots, c_K\}$ , где  $K$  — число классов. Задача состоит в построении модели, способной сопоставить каждому документу  $x_i$  соответствующую метку  $y_i \in C$ .

Исходные данные для задач классификации характеризуются значительным дисбалансом классов. Чтобы обеспечить объективность оценки и избежать смещения в сторону мажоритарных классов, была применена процедура балансировки. И обучающая, и тестовая выборки были применены процедура балансировки путем сокращения выборки (*undersampling*) примеров из преобладающих классов. Итоговый корпус данных для каждой задачи был разделен на обучающую и тестовую части в соотношении 90% к 10%.

В рамках бенчмарка используется подход «векторы как признаки» (*embeddings as features*). Это означает, что параметры модели-кодировщика  $f(x, \alpha)$  заморожены, и для каждого документа  $x_i$  вычисляется его векторное представление  $\mathbf{v}_i = f(x_i, \alpha)$ . Затем на этих векторах обучается модель классификации - логистическая регрессия  $g(\mathbf{v}, \theta)$ .

Вероятность принадлежности документа  $x_i$  к классу  $c_k$  моделируется как:

$$p_{ik} = P(y_i = c_k | \mathbf{v}_i, \theta) = \frac{\exp(\mathbf{v}_i^T \theta_k)}{\sum_{j=1}^K \exp(\mathbf{v}_i^T \theta_j)},$$

где  $\theta_k$  — вектор весов для класса  $c_k$ , а  $\theta = \{\theta_1, \dots, \theta_K\}$  — полный набор параметров модели  $g(\mathbf{v}, \theta)$

Процесс обучения сводится к минимизации функции потерь только по параметрам классификатора  $\theta$ :

$$\mathcal{L}(\theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K [y_i = c_k] \log p_{ik} + \lambda \|\theta\|_2^2 \longrightarrow \min_{\theta}, \quad (3.1)$$

где  $p_{ik}$  — вероятность принадлежности документа  $x_i$  к классу  $c_k$ , предсказанная моделью  $g(\mathbf{v}_i, \theta)$ , а второй член соответствует L2-регуляризации с коэффициентом  $\lambda$ . Для решения данной задачи оптимизации в экспериментах использовалась реализация логистической регрессии из библиотеки scikit-learn [61] со следующими параметрами: решатель lbfgs, L2-регуляризация с параметром C=1.0 (обратным коэффициенту регуляризации  $\lambda$ ), мультиномиальная стратегия для многоклассовых задач и максимальное число итераций max\_iter=100.

Поскольку тестовые выборки для задач классификации являются сбалансированными, в качестве основной меры качества используется точность (Accuracy). Она вычисляется как доля правильно классифицированных объектов и формально определяется следующим образом:

$$\text{Accuracy} = \frac{1}{N_{\text{test}}} \sum_{i=1}^{N_{\text{test}}} [y_i = \hat{y}_i]$$

где  $N_{\text{test}}$  — число примеров в тестовой выборке,  $y_i$  — истинная метка,  $\hat{y}_i = \arg \max_k p_{ik}$  — предсказанная метка.

**Классификация по рубрикатору ГРНТИ**. Государственный рубрикатор научно-технической информации (ГРНТИ) является стандартной иерархической системой классификации, используемой в России для систематизации потока научной информации. Данная задача позволяет оценить, насколько хорошо векторное представление улавливает тематическую направленность научной работы в соответствии с принятой в российской научной среде таксономией.

Рубрикатор ГРНТИ имеет три уровня иерархии. Однако анализ данных из eLibrary.ru показал, что второй и третий уровни заполнены крайне редко (для

15.37% и 0.11% статей соответственно), что делает их использование для обучения и оценки моделей ненадежным. По этой причине в задаче используется только первый, самый общий уровень классификатора. Всего на первом уровне рубрикатора ГРНТИ представлено 90 классов, однако для формирования задачи были отобраны только те, доля которых в корпусе превышает 0.5%. Это привело к выбору 29 классов, исходное распределение которых представлено в таблице 7.

**Классификация по типу публикации**. Данная задача проверяет способность модели различать не тематическое содержание, а структурно-жанровые особенности научного документа. В качестве классов выступают типы публикаций, принятые в eLibrary.ru, такие как «научная статья», «материалы конференции», «обзорная статья», «краткое сообщение» и др. Умение различать эти типы важно для систем, которые могут по-разному обрабатывать, например, оригинальное исследование и обзор литературы. Исходное распределение типов публикаций в корпусе, представленное в таблице 8, является крайне несбалансированным. Для обеспечения робастности оценки, для итоговой задачи были отобраны четыре наиболее крупных и семантически различимых класса: «Научная статья», «Материалы конференции», «Обзорная статья» и «Краткое сообщение». Класс «Разное», не несущий смысловой нагрузки, был исключен.

Итоговые размеры сбалансированных выборок для каждой задачи классификации представлены в таблице 9.

Сводные результаты задач классификации приведены в таблицах 10 (русский язык) и 11 (английский язык). Сопоставление двух подзадач — принадлежности к теме (ГРНТИ) и жанрово-структурной классификации (тип публикации) — показывает различную чувствительность моделей к тематическим и стилевым признакам текста. Для подавляющего большинства моделей точность на ГРНТИ заметно выше, чем на типах публикаций; это указывает на то, что векторные представления лучше кодируют тематическое содержание, чем стиль и структуру документа. Доменно адаптированные модели на основе сигнала цитирования демонстрируют устойчивое преимущество над своими версиями без дообучения: прирост для **SciRus-tiny-cite** относительно **SciRus-tiny** составляет около 4.3 п.п. на русском (50.94 против 46.63) и 3.35 п.п. на английском (49.64 против 46.29), а для **SciRus-small-cite** относительно **SciRus-small** — 2.92 п.п. на русском (51.36 против 48.44) и 1.78 п.п. на английском (49.73 против 47.95). Наименьший разрыв между русской и английской версиями наблюдается у моделей, ориентированных

Таблица 7 — Процентная доля тем на первом уровне в рубрикаторе ГРНТИ.

<b>ГРНТИ</b>	<b>Процент</b>
Полиграфия. Репрография. Фотооборудование	13.84
Медицина и здравоохранение	10.61
Образование. Педагогика	8.46
Государство и право. Юридические науки	7.68
Механика	5.19
Лингвистика	4.31
Сельское и лесное хозяйство	3.89
Биология	2.85
Клиническая медицина	2.8
Информатика	2.25
Машиностроение	2.12
Психология	2.07
Физика	1.73
Литературоведение	1.68
Строительство. Архитектура	1.6
Математика	1.55
Химия	1.52
Политика и политические науки	1.47
Автоматизация. Вычислительная техника	1.37
Физическое воспитание и спорт	1.31
Геология	1.11
Высшее профессиональное образование. Педагогика высшей школы	0.75
Искусствоведение	0.72
Транспорт	0.7
Горное дело	0.69
Энергетика	0.68
Растениеводство	0.62
Пищевая промышленность	0.61
Культурология	0.6

на многоязычное применение, тогда как выраженная асимметрия качества (резкое падение на русском при сопоставимых значениях на английском) свидетельствует

Таблица 8 — Процентная доля типов публикаций

Тип публикации	Процент
Научная статья	93.98
Материалы конференции	2.15
Обзорная статья	1.98
Разное	0.67
Краткое сообщение	0.62
Рецензия	0.22
Персоналия	0.19

Таблица 9 — Размеры выборок для задач классификации

Название задачи	Язык	Выборка	Количество строк
ГРНТИ	русский	обучающая	28399
		тестовая	2764
	английский	обучающая	24338
		тестовая	2517
Тип публикации	русский	обучающая	4150
		тестовая	462
	английский	обучающая	4150
		тестовая	462

о англоцентричном характере предобучения и недостаточном охвате русскоязычной научной лексики и стиля.

Таблица 10 — Результаты для задач классификации на русском языке

Модель	ГРНТИ	Тип публикации	Среднее
gte-Qwen2-7B-instruct	0.6767	0.3823	0.5295
GritLM-7B	0.6521	0.4063	0.5292
Giga-Embeddings-instruct	0.6638	0.3831	0.5235
Linq-Embed-Mistral	0.6406	0.397	0.5188
<b>SciRus-small-cite</b>	<b>0.6641</b>	<b>0.363</b>	<b>0.5136</b>
FRIDA	0.6611	0.3639	0.5125

Продолжение таблицы 10

Модель	ГРНТИ	Тип публикации	Среднее
SFR-Embedding-Mistral	0.6625	0.3621	0.5123
SFR-Embedding-2_R	0.6611	0.3604	0.5107
<b>SciRus-tiny-cite</b>	0.655	0.3639	0.5094
gte-Qwen2-1.5B-instruct	0.6511	0.3565	0.5038
BERTA	0.6486	0.3539	0.5012
NV-Embed-v2	0.589	0.4017	0.4953
multilingual-e5-large-instruct	0.622	0.368	0.495
<b>SciRus-small</b>	0.6037	0.3652	0.4844
jina-embeddings-v3	0.598	0.3604	0.4792
rubert-mini-frida	0.6066	0.3411	0.4739
<b>SciRus-tiny</b>	0.5804	0.3522	0.4663
USER-bge-m3	0.5766	0.3489	0.4627
USER-base	0.5594	0.3567	0.458
multilingual-e5-large	0.5544	0.3615	0.458
multilingual-e5-base	0.5413	0.3645	0.4529
rubert-tiny-turbo	0.533	0.3615	0.4472
multilingual-e5-small	0.5318	0.3615	0.4466
LaBSE-en-ru	0.528	0.3634	0.4457
paraphrase-multilingual-mpnet-base-v2	0.5549	0.3281	0.4415
rubert-tiny2	0.4636	0.3565	0.41
sn-xlm-roberta-base-snli-mnli-anli-xnli	0.4441	0.3108	0.3775
rubert-tiny	0.36	0.3221	0.341
GIST-large-Embedding-v0	0.2256	0.2814	0.2535

Таблица 11 — Результаты для задач классификации на английском языке

Модель	ГРНТИ	Тип публикации	Среднее
GritLM-7B	0.6558	0.4297	0.5427
gte-Qwen2-7B-instruct	0.6888	0.3894	0.5391
NV-Embed-v2	0.6526	0.4119	0.5323

Продолжение таблицы 11

Модель	ГРНТИ	Тип публикации	Среднее
Linq-Embed-Mistral	0.6471	0.4004	0.5238
SFR-Embedding-Mistral	0.6535	0.381	0.5172
gte-Qwen2-1.5B-instruct	0.6535	0.3712	0.5124
SFR-Embedding-2_R	0.6386	0.3654	0.502
<b>SciRus-small-cite</b>	0.6334	0.3613	0.4973
<b>SciRus-tiny-cite</b>	0.64	0.3528	0.4964
GIST-large-Embedding-v0	0.6302	0.3485	0.4894
multilingual-e5-large-instruct	0.5999	0.3686	0.4842
<b>SciRus-small</b>	0.5946	0.3645	0.4795
FRIDA	0.6117	0.3461	0.4789
BERTA	0.5957	0.3489	0.4723
jina-embeddings-v3	0.5961	0.3444	0.4703
<b>SciRus-tiny</b>	0.5808	0.345	0.4629
Giga-Embeddings-instruct	0.546	0.3723	0.4592
USER-bge-m3	0.5596	0.3558	0.4577
multilingual-e5-base	0.5381	0.3604	0.4492
multilingual-e5-large	0.5428	0.3539	0.4483
rubert-mini-frida	0.5645	0.3297	0.4471
paraphrase-multilingual-mpnet-base-v2	0.5493	0.329	0.4392
multilingual-e5-small	0.5296	0.3457	0.4377
LaBSE-en-ru	0.5124	0.355	0.4337
USER-base	0.4407	0.342	0.3913
rubert-tiny-turbo	0.4137	0.3671	0.3904
sn-xlm-roberta-base-snli-mnli-anli-xnli	0.4461	0.3214	0.3838
rubert-tiny	0.4083	0.3398	0.374
rubert-tiny2	0.3886	0.3433	0.3659

### 3.2.2 Задачи регрессии

Задачи регрессии в RuSciBench направлены на оценку способности векторных представлений кодировать информацию, позволяющую предсказывать количественные характеристики научных текстов. Оценка проводится аналогично задачам классификации: модель векторизации  $f(x, \alpha)$  используется в предобученном виде для генерации векторных представлений  $\mathbf{v}_i$  для каждого документа  $x_i$ . Затем на этих векторах обучается легковесная регрессионная модель  $g(\mathbf{v}, \theta)$ . В качестве модели  $g(\mathbf{v}_i, \theta)$  используется линейная регрессия:

$$g(\mathbf{v}_i, \theta) = \mathbf{v}_i^T \mathbf{w} + b,$$

где  $\theta = \{\mathbf{w}, b\}$  — обучаемые параметры: вектор весов  $\mathbf{w}$  и свободный член  $b$ .

Процесс ее обучения заключается в минимизации среднеквадратичной ошибки по параметрам  $\theta$ :

$$\mathcal{L}(\theta) = \frac{1}{N} \sum_{i=1}^N (y_i - g(\mathbf{v}_i, \theta))^2 \longrightarrow \min_{\theta}, \quad (3.2)$$

где  $y_i$  — истинное количественное значение для документа  $x_i$ , а  $g(\mathbf{v}_i, \theta)$  — предсказанное моделью значение. В экспериментах используется реализация из библиотеки ‘scikit-learn’ (`sklearn.linear_model.LinearRegression` [61]) со стандартными параметрами.

Исходный набор данных для каждой задачи регрессии разделяется на обучающую и тестовую выборки в пропорции 90% к 10% соответственно. Поскольку целевая переменная является количественной, для обеспечения схожести ее распределений в обучающей и тестовой выборках была применена процедура стратификации по бинам: диапазон значений целевой переменной был разбит на дискретные интервалы, и разделение производилось со стратификацией по этим созданным категориям.

Для оценки качества решения регрессионной задачи используется коэффициент ранговой корреляции Кендалла (вариант  $\tau_b$ ). Его выбор обусловлен несколькими причинами. Во-первых, в отличие от коэффициентов, измеряющих линейную связь (например, корреляции Пирсона), он оценивает степень монотонной взаимосвязи между рангами истинных и предсказанных значений. Это делает его устойчивым к выбросам и нелинейным зависимостям, что крайне

важно при работе с такими зашумленными данными, как число цитирований. Во-вторых, важным свойством данной меры качества, обусловившим ее выбор, является наличие универсальной шкалы (после отсечения отрицательных значений), где большее значение всегда соответствует лучшему качеству. Это свойство аналогично мерам, используемым в задачах классификации (Accuracy) и ранжирования (nDCG), что делает возможным корректное усреднение мер качества по разнородным задачам для получения единой обобщенной оценки модели в рамках бенчмарка.

Коэффициент вычисляется по формуле:

$$\tau_b = \frac{P - Q}{\sqrt{(P + Q + T_{\hat{y}})(P + Q + T_y)}}, \quad (3.3)$$

где

$P = \sum_{i < j} [(y_i - y_j)(\hat{y}_i - \hat{y}_j) > 0]$  — число согласованных пар, для которых ранги истинных и предсказанных значений совпадают.

$Q = \sum_{i < j} [(y_i - y_j)(\hat{y}_i - \hat{y}_j) < 0]$  — число несогласованных пар.

$T_y = \sum_{i < j} [y_i = y_j, \hat{y}_i \neq \hat{y}_j]$  — число пар с совпадающими истинными значениями, но разными предсказанными.

$T_{\hat{y}} = \sum_{i < j} [\hat{y}_i = \hat{y}_j, y_i \neq y_j]$  — число пар с совпадающими предсказанными значениями, но разными истинными.

Коэффициент Кендалла имеет масштаб от -1 до 1. Значения меньше нуля указывают на обратную корреляцию, что является маловероятным исходом для адекватно обученной модели. В случае получения отрицательного значения, итоговая мера качества принимается равной нулю, так как обратная корреляция свидетельствует о неспособности модели извлечь полезный сигнал.

$$\tau_{final} = \max(0, \tau_b)$$

**Предсказание числа цитирований** Задача заключается в прогнозировании количества цитирований статьи другими научными работами. Это позволяет оценить, насколько хорошо векторное представление документа отражает его научную значимость и влиятельность. Следует отметить, что количество цитирований зависит от множества внешних факторов: не только от содержания аннотации и текста публикации, но и от авторитета автора, престижа журнала, текущих тенденций в научной области и случайных факторов. Поэтому не

следует ожидать, что модели, основанные исключительно на текстовых данных, достигнут высоких значений меры качества в этой задаче. Тем не менее, эксперименты, представленные далее в работе, показывают, что качество предсказаний значительно превосходит случайный уровень, что указывает на наличие в тексте полезного сигнала. Практика включения подобной задачи в оценочные наборы подтверждается наличием аналогичной задачи в авторитетном англоязычном бенчмарке SciDocs [41].

Размеры обучающих и тестовых выборок для задачи регрессии представлены в таблице 12.

Таблица 12 — Размеры выборок для задачи предсказания числа цитирований

Язык	Выборка	Количество строк
русский	обучающая	164037
	тестовая	18227
английский	обучающая	164037
	тестовая	18227

Таблица 13 — Результаты для задач регрессии

Модель	Количество цитат (ру.)	Количество цитат (англ.)
<b>SciRus-small-cite</b>	0.0838	0.0908
<b>SciRus-small</b>	0.0584	0.0756
rubert-mini-frida	0.0691	0.0625
multilingual-e5-small	0.0651	0.0605
rubert-tiny-turbo	0.0657	0.0535
multilingual-e5-large-instruct	0.0596	0.054
<b>SciRus-tiny-cite</b>	0.0592	0.0499
BERTA	0.0544	0.0516
multilingual-e5-large	0.0513	0.0546
multilingual-e5-base	0.043	0.053
rubert-tiny	0.0421	0.0521
jina-embeddings-v3	0.052	0.0421
NV-Embed-v2	0.0438	0.048

Продолжение таблицы 13

Модель	Количество цитат (ру.)	Количество цитат (англ.)
Linq-Embed-Mistral	0.0364	0.0486
USER-base	0.0463	0.0384
rubert-tiny2	0.0379	0.045
<b>SciRus-tiny</b>	0.0312	0.0515
gte-Qwen2-7B-instruct	0.0405	0.0419
paraphrase-multilingual-mpnet-base-v2	0.0412	0.0401
USER-bge-m3	0.0385	0.0419
sn-xlm-roberta-base-snli-mnli-anli-xnli	0.0336	0.0444
LaBSE-en-ru	0.0349	0.039
SFR-Embedding-Mistral	0.0347	0.034
SFR-Embedding-2_R	0.0318	0.0339
GritLM-7B	0.0148	0.0463
gte-Qwen2-1.5B-instruct	0.0157	0.0331
FRIDA	0.0249	0.0226
GIST-large-Embedding-v0	0.011	0.0255
Giga-Embeddings-instruct	0.009	0.0

Итоги задач регрессии суммированы в таблице 13, где для каждой модели представлены значения меры качества для русской и английской версий задачи. Лидирующее качество показывает **SciRus-small-cite**, превосходя собственную версию без сигнала цитирования: на русском прирост составляет 2.54 п.п. (0.0838 против 0.0584), на английском — 1.52 п.п. (0.0908 против 0.0756). Отмечается языковая асимметрия: для ряда крупных универсальных моделей значения на английском стабильно выше, чем на русском, тогда как доменно адаптированные русско-английские модели удерживают паритет или превосходят на русском, что указывает на важность доменной адаптации для улавливания слабого сигнала, связанного с числом цитирований. Для **SciRus-tiny** добавление сигнала цитирова-

ния дает значительный выигрыш на русском (рост с 0.0312 до 0.0592) при почти нейтральном эффекте на английском (0.0515 против 0.0499).

### 3.2.3 Задачи информационного поиска

Задачи информационного поиска в рамках RuSciBench предназначены для оценки способности моделей эффективно извлекать релевантные научные документы из большого корпуса на основе текстового запроса. Постановка задачи следует стандартной парадигме информационного поиска и включает три ключевых компонента: коллекцию запросов  $\mathcal{Q} = \{q_j\}_{j=1}^M$ , обширный корпус документов  $\mathcal{D} = \{d_i\}_{i=1}^N$ , среди которых ведется поиск, и эталонные данные о релевантности, которые определяют, какие документы из корпуса являются релевантными для каждого запроса. Структура этих компонентов соответствует общепринятым форматам в таких авторитетных бенчмарках, как BEIR [62] и МТЕВ [52].

Процедура оценки начинается с этапа векторизации, на котором с использованием оцениваемой модели  $f(x, \alpha)$  генерируются векторные представления для всех запросов из  $\mathcal{Q}$  и всех документов из  $\mathcal{D}$ . Для каждого вектора запроса  $\mathbf{v}_q$  вычисляется мера сходства с каждым вектором документа  $\mathbf{v}_d$  в корпусе. В качестве основной меры используется косинусная близость:

$$\text{similarity}(\mathbf{v}_q, \mathbf{v}_d) = \frac{\mathbf{v}_q \cdot \mathbf{v}_d}{\|\mathbf{v}_q\| \cdot \|\mathbf{v}_d\|} = \frac{\sum_{k=1}^n v_{q,k} v_{d,k}}{\sqrt{\sum_{k=1}^n v_{q,k}^2} \sqrt{\sum_{k=1}^n v_{d,k}^2}},$$

где  $n$  — размерность векторного пространства, а  $v_{q,k}$  и  $v_{d,k}$  — компоненты векторов запроса и документа соответственно. Некоторые модели могут быть оптимизированы для использования скалярного произведения  $(\mathbf{v}_q \cdot \mathbf{v}_d)$ , и в таких случаях применяется мера, рекомендованная разработчиками модели. На основе вычисленных мер сходства документы корпуса ранжируются для каждого запроса.

Для оценки качества ранжирования используется нормализованный дисконтированный совокупный выигрыш (Normalized Discounted Cumulative Gain, NDCG) на первых 10 позициях, обозначаемый как NDCG@10. NDCG@k определяется как отношение дисконтированного совокупного выигрыша (DCG) к его

идеальному значению (IDCG):

$$\text{NDCG}@k = \frac{\text{DCG}@k}{\text{IDCG}@k}. \quad (3.4)$$

Дисконтированный совокупный выигрыш DCG@k рассчитывается как сумма релевантностей документов, взвешенных с учетом их позиций:

$$\text{DCG}@k = \sum_{i=1}^k \frac{2^{rel_i} - 1}{\log_2(i + 1)},$$

где  $rel_i$  — это оценка релевантности документа на  $i$ -й позиции. В задаче поиска цитирований релевантность бинарная:  $rel_i = 1$ , если документ на позиции  $i$  является релевантным (цитированным), и  $rel_i = 0$  в противном случае. С учетом этого, формула DCG@k упрощается до:

$$\text{DCG}@k = \sum_{i=1}^k \frac{[rel_i = 1]}{\log_2(i + 1)}.$$

Идеальный дисконтированный совокупный выигрыш IDCG@k представляет собой максимально возможное значение DCG@k, которое достигается при идеальном ранжировании, когда все релевантные документы находятся в начале списка. Он рассчитывается как:

$$\text{IDCG}@k = \sum_{i=1}^{\min(k, |\mathcal{R}_q|)} \frac{1}{\log_2(i + 1)},$$

где  $|\mathcal{R}_q|$  — общее число релевантных документов для запроса  $q$ .

**Предсказание прямых цитирований** В рамках RuSciBench представлена задача предсказания прямых цитирований. В терминах информационного поиска, для заданной статьи-запроса, представленной конкатенацией ее заголовка и аннотации, необходимо найти среди всех статей корпуса те, которые она цитирует. Релевантность в данном случае является бинарной: документ считается релевантным, если он процитирован статьей-запросом, и нерелевантным в противном случае.

Статистика по наборам данных для задачи поиска цитирований представлена в таблице 14.

Таблица 14 — Размеры выборок для задачи поиска цитирований

Язык	Тип данных	Количество
русский	Запросы	3000
	Документы	90000
	Релевантные пары	15000
английский	Запросы	3000
	Документы	90000
	Релевантные пары	15000

Таблица 15 — Результаты для задач поиска

Модель	Цитирование (ру.)	Цитирование (англ.)
SFR-Embedding-2_R	0.4065	0.4119
GritLM-7B	0.3987	0.4119
SFR-Embedding-Mistral	0.3846	0.3782
Linq-Embed-Mistral	0.3764	0.3814
gte-Qwen2-1.5B-instruct	0.372	0.3713
gte-Qwen2-7B-instruct	0.379	0.3554
jina-embeddings-v3	0.3694	0.3582
<b>SciRus-small-cite</b>	0.3598	0.3351
<b>SciRus-tiny-cite</b>	0.3508	0.3353
Giga-Embeddings-instruct	0.3693	0.3147
multilingual-e5-large-instruct	0.3467	0.3366
multilingual-e5-large	0.3459	0.3348
USER-bge-m3	0.3517	0.3228
BERTA	0.3465	0.3165
<b>SciRus-small</b>	0.3328	0.328
NV-Embed-v2	0.307	0.3433
<b>SciRus-tiny</b>	0.3231	0.3205
rubert-mini-frida	0.3201	0.2818
multilingual-e5-base	0.3039	0.2977
FRIDA	0.3016	0.2752
multilingual-e5-small	0.2892	0.2584
GIST-large-Embedding-v0	0.103	0.3894

## Продолжение таблицы 15

Модель	Цитирование (ру.)	Цитирование (англ.)
USER-base	0.2861	0.1589
paraphrase-multilingual-mpnet-base-v2	0.186	0.2507
rubert-tiny-turbo	0.2301	0.1318
LaBSE-en-ru	0.1948	0.166
sn-xlm-roberta-base-snli-mnli-anli-xnli	0.1183	0.1358
rubert-tiny2	0.1218	0.1033
rubert-tiny	0.0601	0.0732

Сопоставление результатов задач поиска представлено в таблице 15. Доменно адаптированные модели с использованием данных о цитировании демонстрируют устойчивый выигрыш относительно версий без такого дообучения: для **SciRus-small** прирост на русском составляет около 2.7 п.п. (33.28 → 35.98), для **SciRus-tiny** — порядка 2.8 п.п. (32.31 → 35.08), при этом на английском выигрыш менее выражен. Наблюдается также выраженная языковая асимметрия для отдельных моделей общего назначения: некоторые из них показывают высокие значения меры качества на английском при заметном падении на русском, тогда как модели с русской доменной адаптацией сохраняют более стабильный профиль качества. Разница между верхней группой крупных универсальных моделей и компактными доменно адаптированными моделями сокращается именно на русской версии задачи.

### 3.2.4 Задачи кросс-языкового поиска

Задачи кросс-языкового поиска предназначены для оценки способности моделей сопоставлять семантически эквивалентные тексты на разных языках. Данного типа задача, известный как поиск параллельных текстов (Bitext Mining), является стандартным подходом для оценки качества двуязычных векторных представлений. Её цель — оценить, насколько хорошо модель способна форми-

ровать общее семантическое пространство, в котором векторы текстов-переводов близки друг к другу.

В рамках RuSciBench представлена задача поиска перевода аннотации с русского языка на английский. Для ее решения используются два параллельных корпуса: исходный корпус  $\mathcal{D}_{ru}$ , содержащий 10 000 аннотаций на русском языке, и целевой корпус  $\mathcal{D}_{en}$ , содержащий их точные переводы на английский язык. Для каждой аннотации-запроса  $q_j \in \mathcal{D}_{ru}$  существует ровно один верный перевод  $d_{j,\text{true}} \in \mathcal{D}_{en}$ .

Процедура оценки включает следующие шаги. Сначала с помощью оцениваемой модели  $f(x, \alpha)$  генерируются векторные представления для всех текстов в исходном корпусе  $\{\mathbf{v}_{q,j}\}$  и в целевом корпусе  $\{\mathbf{v}_{d,i}\}$ . Затем для каждого вектора запроса  $\mathbf{v}_{q,j}$  в целевом корпусе находится вектор документа с наибольшим значением косинусной близости. Предсказанным переводом  $\hat{d}_j$  считается документ, соответствующий этому вектору (ближайший сосед):

$$\hat{d}_j = \arg \max_{d_i \in \mathcal{D}_{en}} \text{similarity}(\mathbf{v}_{q,j}, \mathbf{v}_{d,i}).$$

Качество модели оценивается путем сравнения предсказанного перевода  $\hat{d}_j$  с эталонным  $d_{j,\text{true}}$  для каждого запроса из  $\mathcal{D}_{ru}$ .

В качестве меры качества используется точность (Accuracy), которая вычисляется как доля правильно идентифицированных переводов. Формально, она определяется следующим образом:

$$\text{Accuracy} = \frac{1}{|\mathcal{D}_{ru}|} \sum_{q_j \in \mathcal{D}_{ru}} [\hat{d}_j = d_{j,\text{true}}]$$

где  $|\mathcal{D}_{ru}|$  — общее число запросов,  $\hat{d}_j$  — предсказанный перевод для запроса  $q_j$ ,  $d_{j,\text{true}}$  — истинный перевод. Эта задача является важным тестом способности модели улавливать семантическую эквивалентность текстов вне зависимости от языка, что критично для построения эффективных многоязычных систем в научной сфере.

Таблица 16 — Результаты для задачи поиска перевода

Модель	русский-английский
SFR-Embedding-2_R	0.9992
GritLM-7B	0.9989

## Продолжение таблицы 16

Модель	русский-английский
SFR-Embedding-Mistral	0.9987
gte-Qwen2-1.5B-instruct	0.9984
Linq-Embed-Mistral	0.9981
jina-embeddings-v3	0.9979
multilingual-e5-large-instruct	0.9979
multilingual-e5-large	0.9971
USER-bge-m3	0.9964
BERTA	0.9951
Giga-Embeddings-instruct	0.9947
gte-Qwen2-7B-instruct	0.9932
multilingual-e5-base	0.9914
NV-Embed-v2	0.9907
LaBSE-en-ru	0.9887
FRIDA	0.9873
<b>SciRus-small</b>	0.9866
<b>SciRus-tiny</b>	0.9852
rubert-mini-frida	0.9805
multilingual-e5-small	0.9748
<b>SciRus-small-cite</b>	0.96
<b>SciRus-tiny-cite</b>	0.953
paraphrase-multilingual-mpnet-base-v2	0.9321
rubert-tiny-turbo	0.8644
USER-base	0.8509
sn-xlm-roberta-base-snli-mnli-anli-xnli	0.7041
rubert-tiny2	0.675
rubert-tiny	0.436
<b>GIST-large-Embedding-v0</b>	0.0456

Результаты для задачи кросс-языкового поиска перевода приведены в таблице 16. Верхняя группа моделей демонстрирует насыщение меры качества вплотную к 100%, что указывает на низкую сложность идентификации точных переводов аннотаций при использовании современных кодировщиков и на

то, что задача ближе к проверке корректности выравнивания базового семантического пространства, чем к тонкой дифференциации качества представлений. Различия между моделями общего назначения и доменно адаптированными кодировщиками здесь существенно меньше, чем в задачах поиска и регрессии, что дополнительно подтверждает близость задачи насыщению качества на рассматриваемом корпусе.

### 3.3 Оценка моделей на RuSciBench

Итоговая таблица 17 представляет собой сводный рейтинг моделей, оцененных на бенчмарке RuSciBench. Для агрегирования результатов используется метод Борда, заимствованный из теории социального выбора и хорошо зарекомендовавший себя как робастный способ сравнения систем обработки естественного языка [63]. Суть метода заключается в том, что каждая задача бенчмарка рассматривается как «голосующий», который ранжирует все модели в соответствии с их производительностью. Модель получает баллы в зависимости от занятого места: чем выше ранг, тем больше баллов. Итоговый балл модели  $B_i$  формируется как сумма баллов, полученных по всем задачам. Формально, он вычисляется следующим образом:

$$B_i = \sum_{j=1}^m (n - r_{ij}), \quad (3.5)$$

где  $m$  — общее число задач,  $n$  — количество сравниваемых моделей, а  $r_{ij}$  — ранг  $i$ -й модели в  $j$ -й задаче (где ранг 1 является наилучшим). Итоговый рейтинг моделей строится на основе убывания их суммарных баллов  $B_i$ . Важно отметить, что итоговый ранг по методу Борда, а также представленные в таблице средние значения мер качества, вычислены по всему набору из 18 задач бенчмарка.

Таблица 17 — Сводный рейтинг моделей на RuSciBench

Модель	Ранг по методу Борда	Среднее по русскоязычным задачам	Среднее по англоязычным задачам
GritLM-7B	1	0.3873	0.4176
Linq-Embed-Mistral	2	0.3795	0.4001
SFR-Embedding-Mistral	3	0.3811	0.3946
SFR-Embedding-2_R	4	0.3878	0.3983
gte-Qwen2-7B-instruct	5	0.3851	0.4
<b>SciRus-small-cite</b>	6	0.3938	0.3903
multilingual-e5-large-instruct	7	0.3693	0.3702
<b>SciRus-tiny-cite</b>	8	0.3861	0.3837
NV-Embed-v2	9	0.3554	0.3978
gte-Qwen2-1.5B-instruct	10	0.3655	0.3868
BERTA	11	0.3771	0.3641
<b>SciRus-small</b>	12	0.3583	0.3699
jina-embeddings-v3	13	0.3621	0.3609
Giga-Embeddings-instruct	14	0.3608	0.3144
multilingual-e5-large	15	0.3497	0.3515
rubert-mini-frida	16	0.3675	0.347
<b>SciRus-tiny</b>	17	0.3542	0.3667
FRIDA	18	0.3566	0.339
multilingual-e5-base	19	0.3422	0.3475
USER-bge-m3	20	0.3502	0.3468
multilingual-e5-small	21	0.3437	0.3377
rubert-tiny-turbo	22	0.3333	0.2885
LaBSE-en-ru	23	0.3083	0.306
USER-base	24	0.3404	0.2858
rubert-tiny2	25	0.2881	0.2703
GIST-large-Embedding-v0	26	0.194	0.3762

Продолжение таблицы 17

Модель	Ранг по методу Борда	Среднее по русскоязычным задачам	Среднее по англоязычным задачам
rubert-tiny	27	0.245	0.2745
paraphrase-multilingual-mppnet-base-v2	28	0.3045	0.321
sn-xlm-roberta-base-snli-mnli-anli-xnli	29	0.2543	0.2698

После представления общего рейтинга моделей, целесообразно проанализировать факторы, влияющие на их производительность. Одним из ключевых факторов является размер модели, или количество ее параметров. На рисунке 3.1 визуализирована зависимость среднего результата модели на всех задачах бенчмарка RuSciBench от ее размера.




Рисунок 3.1 — Зависимость среднего результата на всех задачах от размера модели.

На рисунке 3.1 представлена зависимость усредненного по всем задачам RuSciBench показателя качества модели от ее размера, измеряемого количе-

ством параметров. Ось абсцисс, представляющая размер модели, использует логарифмическую шкалу для охвата широкого диапазона значений — от десятков миллионов до нескольких миллиардов параметров. Ось ординат отражает среднее значение меры качества по всем русскоязычным и англоязычным задачам бенчмарка.

Анализ графика позволяет выявить общую тенденцию к увеличению производительности моделей с ростом их размера. Большинство моделей общего назначения (обозначены синими точками) демонстрируют положительную корреляцию между количеством параметров и средним результатом. Эта тенденция аппроксимирована пунктирной линией регрессии, которая показывает монотонный рост среднего качества с увеличением масштаба модели. Наиболее крупные модели общего назначения, такие как GritLM-7B (7.24 млрд параметров), располагаются в верхней правой части графика, достигая одних из самых высоких средних показателей качества среди всех оцененных моделей.

Однако график также выявляет существенные отклонения от этой общей тенденции. Наблюдается значительная дисперсия в производительности моделей со схожим числом параметров, особенно в диапазоне от  $10^8$  до  $10^9$  параметров. Это указывает на влияние других факторов, помимо размера, таких как архитектурные особенности, качество и специфика обучающих данных, а также методы оптимизации и дообучения. Таким образом, результаты подтверждают общую гипотезу о положительном влиянии масштабирования моделей, однако подчеркивают важность доменной адаптации и других характеристик для достижения оптимального качества в задачах обработки русскоязычных научных текстов.

### 3.3.1 Оценка степени языковой специализации моделей

Бенчмарк RuSciBench обладает ключевой особенностью: его структура является полностью парной. Это означает, что каждая задача и каждый текстовый пример в наборе данных на русском языке имеют точный семантический аналог на английском. В таких условиях многоязычная модель, обладающая высокой степенью языковой универсальности, теоретически должна демонстрировать эквивалентное качество на обеих языковых версиях задач. Любое систематическое отклонение от этого паритета свидетельствует о наличии языковой специализа-

ции — лучшей адаптации модели к особенностям одного из языков, что приводит к асимметрии в производительности.

Для количественной оценки этого явления в таблице 18 представлен детальный анализ, позволяющий сопоставить производительность каждой модели на русском и английском языках. Вместо единого общего ранга, здесь вычисляются два независимых рейтинга: «Ранг Борда (рус.)» и «Ранг Борда (англ.)». Каждый из них строится на основе результатов модели исключительно на русскоязычном или англоязычном подмножестве задач соответственно. Такое разделение позволяет выявить, как меняется относительная позиция модели в рейтинге в зависимости от языка.

Ключевым показателем является столбец «Прирост на рус. по отношению к англ. (%)», который напрямую измеряет разницу в средней производительности. Он вычисляется как процентное изменение средней меры качества модели по всем задачам при переходе от английского языка к русскому. Этот показатель напрямую количественно определяет степень и направление языковой специализации модели.

Интерпретация значений в этом столбце является следующей:

- **Положительное значение** указывает на то, что модель демонстрирует более высокую эффективность на задачах на русском языке, что свидетельствует о ее специализации на русскоязычном научном контенте.
- **Отрицательное значение** говорит о специализации модели на английском языке, поскольку на нем достигаются более высокие результаты.
- **Значение, близкое к нулю**, характеризует модель с низкой степенью языковой специализации, то есть с хорошим балансом и высокой кроссязыковой стабильностью.
- **Абсолютная величина значения** отражает степень этой специализации. Большие по модулю значения указывают на значительный перекос в производительности, что может быть критичным при выборе модели для конкретных задач.

В таблице модели упорядочены в соответствии с их общим рейтингом, представленным в таблице 10, что позволяет сопоставить их общую производительность со степенью языковой специализации.

Таблица 18 — Оценка степени языковой специализации моделей

Модель	Количество параметров	Ранг Борда (англ.)	Ранг Борда (рус.)	Прирост на рус. по отношению к англ. (%)
GritLM-7B	7.24 млрд	1	3	-7.26
Linq-Embed-Mistral	7.0 млрд	2	7	-5.15
SFR-Embedding-Mistral	7.0 млрд	5	5	-3.42
SFR-Embedding-2_R	7.11 млрд	6	6	-2.65
gte-Qwen2-7B-instruct	7.0 млрд	4	4	-3.74
<b>SciRus-small-cite</b>	61 млн	7	1	0.89
multilingual-e5-large-instruct	560 млн	11	8	-0.23
<b>SciRus-tiny-cite</b>	23 млн	10	2	0.61
NV-Embed-v2	7.0 млрд	3	14	-10.65
gte-Qwen2-1.5B-instruct	1.0 млрд	9	17	-5.5
BERTA	128 млн	12	9	3.58
<b>SciRus-small</b>	61 млн	11	13	-3.12
jina-embeddings-v3	572 млн	16	13	0.32
rubert-mini-frida	32 млн	15	12	5.92
<b>SciRus-tiny</b>	23 млн	13	19	-3.42
multilingual-e5-large	560 млн	14	18	-0.51
Giga-Embeddings-instruct	2.0 млрд	22	10	14.73
multilingual-e5-base	278 млн	16	19	-1.54
FRIDA	823 млн	21	15	5.19
USER-bge-m3	359 млн	20	22	1.0
multilingual-e5-small	118 млн	18	19	1.76
rubert-tiny-turbo	29 млн	18	16	15.56
LaBSE-en-ru	129 млн	24	24	0.76
USER-base	124 млн	28	21	19.1
rubert-tiny2	29 млн	26	23	6.55
rubert-tiny	12 млн	23	26	-10.75

## Продолжение таблицы 18

Модель	Количество параметров	Ранг Борда (англ.)	Ранг Борда (рус.)	Прирост на рус. по отношению к англ. (%)
paraphrase-multilingual-mmpnet-base-v2	278 млн	27	25	-5.15
GIST-large-Embedding-v0	335 млн	13	29	-48.43
sn-xlm-roberta-base-snli-mnli-anli-xnli	278 млн	29	28	-5.77

Анализ результатов выявляет глубокую неоднородность в языковой специализации моделей и ставит под сомнение идею об их универсальной многоязычной применимости. Наблюдается четкая тенденция: модели, занимающие верхние строчки в общем рейтинге (например, GritLM-7B, NV-Embed-v2), достигают этого положения преимущественно за счет своей исключительной производительности на английском языке, при этом демонстрируя существенную деградацию качества на русскоязычных задачах (падение до -7.26% и -10.65% соответственно). Это указывает на то, что их предобучение было в значительной степени англоцентричным, и их способность к обобщению на русскую научную лексику и синтаксис остается неполной. В противовес этому, специально разработанные модели семейства SciRus, несмотря на меньшее число параметров, занимают первые два места в рейтинге именно для русского языка, демонстрируя при этом почти идеальный языковой баланс (прирост +0.89% и +0.61%). Этот факт подчеркивает критическое преимущество целенаправленной доменной и языковой адаптации над чистым масштабированием модели. Данные также выявляют крайние случаи специализации, такие как модель GIST-large-Embedding-v0, чья производительность на русском языке катастрофически падает (-48.43%), что делает ее практически моноязычной для данного домена, и, с другой стороны, модели, подобные multilingual-e5-large-instruct, которые показывают образцовый паритет (-0.23%). Следовательно, выбор оптимальной модели для работы с русскоязычными научными текстами не может основываться только на общем рейтинге производительности; необходимо учитывать степень ее языковой специализации, поскольку компактная, но правильно адаптированная модель может

оказаться значительно эффективнее более крупной, но лингвистически несбалансированной.

### 3.4 Интеграция в международный бенчмарк МТЕВ

Для обеспечения воспроизводимости и сопоставимости результатов, полученных на бенчмарке RuSciBench, с результатами других исследователей, была проведена его интеграция в ведущий международный бенчмарк Massive Multilingual Text Embedding Benchmark (МТЕВ) [17]. МТЕВ представляет собой общепринятый стандарт и открытую программную библиотеку для оценки качества моделей векторного представления текстов. Он агрегирует большое количество разнородных задач на множестве языков, что позволяет унифицировать процедуру тестирования и проводить комплексное сравнение моделей. Включение RuSciBench в МТЕВ позволяет не только валидировать разработанный инструментарий силами международного научного сообщества, но и включить русскоязычный научный домен в глобальный контекст оценки нейросетевых моделей.

Интеграция RuSciBench в экосистему МТЕВ предоставляет ряд ключевых преимуществ. Во-первых, она существенно упрощает процесс оценки для сторонних исследователей, которым достаточно использовать стандартный программный интерфейс МТЕВ, чтобы протестировать свои модели на всём наборе задач RuSciBench. Во-вторых, это позволяет проводить прямое и объективное сопоставление как специализированных моделей, ориентированных на научный домен, так и мощных многоязычных моделей общего назначения, на единой и стандартизированной платформе. Бенчмарк RuSciBench, включающий 18 задач, составляет существенную долю от общего числа задач в ММТЕВ, насчитывавшего на момент интеграции 73 задачи, что подчёркивает значимость данного вклада в развитие инструментов оценки.

Практическая реализация оценки с использованием данной интеграции демонстрирует её простоту и доступность. Процесс запуска полного цикла тестирования произвольной модели, доступной на платформе Hugging Face, на всех задачах бенчмарка RuSciBench может быть выполнен с помощью следующего короткого программного кода 3.1.

### Листинг 3.1 Пример использования бенчмарка RuSciBench в MTEB

```
import mteb

model_name = "mlsa-iai-msu-lab/sci-rus-tiny"
benchmark = mteb.get_benchmark("RuSciBench")
model = mteb.get_model(model_name)
evaluation = mteb.MTEB(tasks=benchmark.tasks)
results = evaluation.run(
    model,
    output_folder=f"results/{model_name.replace('/', '__')}"))
)
```

Данный фрагмент кода автоматически загружает указанную модель, получает полный набор задач из бенчмарка RuSciBench, выполняет оценку по всем предопределенным мерам качества и сохраняет результаты в структурированном виде. Такая автоматизация и стандартизация являются необходимым условием для построения воспроизводимой и прозрачной системы оценки качества моделей, что, в свою очередь, способствует ускорению научного прогресса в данной области.

### 3.5 Основные выводы

Разработка и апробация бенчмарка RuSciBench позволили создать стандартизованный инструмент для оценки качества моделей векторного представления текстов в специфическом домене русскоязычной научной литературы. Отвечая на потребность в специализированных ресурсах для неанглоязычных научных данных, RuSciBench предоставляет набор из 18 задач, охватывающих классификацию, регрессию и информационный поиск, а также кросс-языковые возможности. Структура бенчмарка, основанная на реальных метаданных научных публикаций из eLibrary.ru, и его двуязычный характер (русский и английский) обеспечивают реалистичность оценочных сценариев и возможность глубокого анализа многоязычных моделей.

Проведенная оценка широкого спектра моделей, от компактных до многомилиардных архитектур, выявила картину их производительности. Подтверждена общая тенденция к улучшению качества с ростом размера модели, однако результаты также подчеркнули исключительную важность доменной специализации: модели, дообученные на научном корпусе (*sci-rus-\**), продемонстрировали выдающуюся эффективность даже при малом числе параметров, конкурируя с крупнейшими моделями общего назначения.

Итоговый рейтинг, построенный с использованием робастного метода агрегации рангов Борда, представляет собой ценный ориентир для выбора оптимальной модели в зависимости от конкретных требований к производительности и ресурсам. Таким образом, RuSciBench не только заполняет существующий пробел в инструментах оценки для русскоязычного научного домена, но и предоставляет детализированные данные для дальнейших исследований в области разработки и адаптации моделей векторизации текстов, стимулируя создание более эффективных и универсальных решений для работы с научной информацией.

## Глава 4. Бенчмарк для оценки качества верификации научных фактов на русском языке

В предыдущих главах проводилась оценка моделей на задачах, использующих существующие метаданные научных публикаций, такие как рубрикация или число цитирований. Однако такие данные отражают лишь общие характеристики документа и не позволяют оценить способность моделей к глубокому семантическому анализу и логическому выводу на уровне его содержания. Стремительный рост объема научной информации, особенно в периоды глобальных вызовов, таких как пандемии, остро ставит задачу автоматизированной оценки истинности конкретных научных утверждений [51]. Эта задача, известная как верификация научных фактов, требует от моделей не просто тематической классификации, а способности находить релевантные доказательства в тексте и рассуждать о сложных взаимосвязях, что представляет собой значительный вызов для современных систем обработки естественного языка.

Для русскоязычного научного домена инструменты, позволяющие проводить такую детальную оценку, до сих пор отсутствовали. Данная глава посвящена восполнению этого пробела путем разработки нового инструментария для оценки качества моделей — бенчмарка RuSciFact. В главе детально описывается методология его полуавтоматического формирования, основанная на генерации утверждений с помощью больших языковых моделей и их последующей экспертной валидации. На основе созданного бенчмарка проводится комплексное экспериментальное исследование, в рамках которого оценивается и сравнивается производительность современных моделей векторизации, включая разработанные в диссертации модели семейства SciRus.

### 4.1 Постановка задачи верификации научных фактов

Задача верификации научных фактов состоит в поиске релевантного для утверждения документа и определения на его основе, подтверждается ли или опровергается данное утверждение информацией, содержащейся в документе. Формально, дано:

- Утверждение  $c$  — атомарный, проверяемый научный факт.
- Корпус документов  $D = \{e_i\}_{i=1}^{N_D}$  — множество аннотаций научных статей.
- Множество меток  $L = \{\text{ПОДТВЕРЖДАЕТ}, \text{ОПРОВЕРГАЕТ}\}$ , отражающих отношение между утверждением и аннотацией.

Итоговая цель состоит в построении модели  $M$ , которая для заданного утверждения  $c$  и корпуса  $D$  находит релевантный документ  $e^* \in D$  и определяет его отношение  $l^* \in L$  к утверждению:

$$(e^*, l^*) = M(c, D).$$

Для решения данной задачи с помощью моделей семантического векторного представления текста, ее целесообразно декомпозировать на два последовательных этапа: информационный поиск и классификация.

**Этап 1: Информационный поиск релевантной аннотации.** На первом этапе для заданного утверждения  $c$ , выступающего в роли запроса, необходимо найти наиболее релевантную аннотацию  $e^*$  в корпусе  $D$ . Эта задача решается путем отображения всех текстов в единое векторное пространство с помощью модели-кодировщика  $f(x, \alpha)$  и последующего ранжирования аннотаций по мере близости к вектору утверждения.

$$e^* = \underset{e_i \in D}{\operatorname{argmax}} s(f(c, \alpha), f(e_i, \alpha)), \quad (4.1)$$

где  $f(x, \alpha)$  — параметризованная модель семантического векторного представления текста с параметрами  $\alpha$ , а  $s(\cdot, \cdot)$  — функция близости векторов, как правило, косинусная.

Качество решения этой задачи оценивается с помощью меры Mean Reciprocal Rank (MRR@k), которая вычисляется как среднее обратных рангов первой релевантной аннотации:

$$\text{MRR}@k = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \frac{1}{\text{rank}_i},$$

где  $Q$  — множество запросов (утверждений), а  $\text{rank}_i$  — ранг первого правильного документа для  $i$ -го запроса (если ранг  $> k$ , то слагаемое считается равным нулю).

**Этап 2: Классификация пары «утверждение–аннотация».** На втором этапе для найденной или предоставленной пары  $(c, e)$  решается задача бинарной классификации. Для этой подзадачи в работе рассматриваются два подхода. Основной

подход, основанный на векторных моделях, предполагает обучение легковесного классификатора  $g(\cdot, \theta)$  поверх замороженных представлений  $f(c, \alpha)$  и  $f(e, \alpha)$ . Процесс обучения сводится к минимизации функции потерь, в качестве которой используется бинарная перекрестная энтропия:

$$\mathcal{L}(\theta) = -\frac{1}{N} \sum_{i=1}^N [y_i \log p_i + (1 - y_i) \log(1 - p_i)] \rightarrow \min_{\theta}, \quad (4.2)$$

где  $N$  — число пар в обучающей выборке,  $y_i \in \{0, 1\}$  — истинная метка для  $i$ -й пары (1 для ПОДТВЕРЖДАЕТ и 0 для ОПРОВЕРГАЕТ), а  $p_i$  — вероятность принадлежности к классу ПОДТВЕРЖДАЕТ, предсказанная моделью  $g$ .

Анализ существующих наборов данных показывает отсутствие инструментов для оценки моделей в рамках такой постановки для русскоязычных научных текстов. Это определяет научную задачу данной главы — разработку и апробацию такого инструментария.

## 4.2 Методология формирования набора данных RuSciFact

В качестве исходного материала для формирования набора данных был использован корпус аннотаций из бенчмарка RuSciBench [15], детально описанного в Главе 3. Данный выбор обусловлен тем, что RuSciBench содержит обширный и репрезентативный срез русскоязычных научных публикаций из различных дисциплин, а сами тексты уже прошли этап предварительной очистки. Это позволило сфокусироваться непосредственно на основной задаче — генерации и верификации научных фактов, опираясь на подготовленную и верифицированную текстовую базу.

Ключевым методологическим решением стало использование большой языковой модели для автоматической генерации научных утверждений. Эффективность такого подхода для ускорения и масштабирования процесса создания наборов данных продемонстрирована в ряде недавних исследований [64; 65]. Выбор конкретной генеративной модели, однако, является нетривиальной задачей, требующей объективных критериев оценки. Обоснование выбора модели было сделано на основе результатов комплексного русскоязычного бенчмарка MERA (Multitask Evaluation of Russian-language Abilities) [66]. Данный бенчмарк

представляет собой многозадачный оценочный набор, предназначенный для всестороннего анализа способностей языковых моделей в обработке русского языка. Он включает в себя широкий спектр задач, таких как ответы на вопросы, классификация текстов, семантическая близость, суммаризация и логический вывод. Задача генерации научного утверждения на основе аннотации требует от модели комплекса способностей: глубокого понимания текста, способности к логическому умозаключению и навыков синтеза нового текста. Поскольку бенчмарк MERA оценивает именно эти фундаментальные способности, высокий совокупный результат модели на нем является надежным индикатором ее пригодности для решения данной, более узкой и специфической, задачи.

Таблица 19 — Результаты оценки языковых моделей на бенчмарке MERA (агрегированная мера качества). Данные приведены по состоянию на 2 ноября 2024 года [66].

Модель	Открытые веса	Результат
Human Benchmark	-	0.852
GPT-4o	нет	0.642
<b>Meta-Llama-3.1-405B-Instruct</b>	<b>да</b>	<b>0.590</b>
GigaChat Max	нет	0.588
Mistral-Large-Instruct-2407	да	0.574
GPT-4o-mini	нет	0.570
Qwen2-72B-Instruct	да	0.570
Meta-Llama-3.1-70B-Instruct	да	0.554

Результаты, представленные в Таблице 19, показывают, что на момент проведения работы модель **Meta-Llama-3.1-405B-Instruct**<sup>1</sup> демонстрировала наилучшие результаты среди всех моделей с открытыми весами, что является ключевым фактором для обеспечения воспроизводимости данного исследования. Исходя из этого, именно данная модель была выбрана в качестве основного инструмента для генерации утверждений в рамках конвейера RuSciFact.

Для применения модели использовался вычислительный кластер, состоящий из восьми графических ускорителей NVIDIA A100 с объемом видеопамяти 80 ГБ каждый. Развертывание и эффективное исполнение запросов к модели обеспечивалось с помощью специализированной библиотеки vLLM [67]. Полная

<sup>1</sup><https://huggingface.co/meta-llama/Llama-3.1-405B-FP8>

версия модели, использующая 16-битное представление весов, требует для размещения в памяти около 810 ГБ ( $405 \times 10^9$  параметров  $\times$  2 байта/параметр), что превышает суммарный объем памяти доступного кластера (640 ГБ). В связи с этим, для проведения экспериментов была задействована версия модели, квантованная до 8 бит. Такое преобразование позволяет сократить требования к памяти вдвое, до приблизительно 405 ГБ, делая возможным ее размещение на используемом оборудовании без существенной потери качества генерации[68].

Для того чтобы генерируемые данные были релевантны поставленной задаче и позволяли проводить содержательную оценку моделей, был сформулирован ряд требований, которые легли в основу инструкций (промптов) для LLM. Каждая итоговая пара «утверждение–аннотация» ( $c, e$ ) должна была удовлетворять следующему своду правил.

Сначала определялись требования к аннотации-источнику  $e$ . **Информативность** являлась необходимым условием, то есть текст должен был содержать достаточный объем фактической информации для формулирования проверяемого научного вывода. Аннотации, описывающие исключительно структуру работы или общие рассуждения без конкретных результатов, отбраковывались. Примером такой неинформативной аннотации, не содержащей конкретных выводов, может служить следующий текст:

*Статья посвящена традиционному объекту социально-экономической географии – районному центру. В статье описан новый подход к оценке центральных функций районных центров Ивановской области. Основу данной методики составила информация о некоторых государственных учреждениях, размещенных в райцентре. В результате анализа системы иерархии государственных учреждений были выделены несколько типов райцентров.*

Далее, для информативных аннотаций, были сформулированы жесткие требования к генерируемому утверждению  $c$ :

- **Логическая выводимость:** Утверждение должно являться строгим логическим следствием текста аннотации. Это центральное требование, гарантирующее, что отношение между  $c$  и  $e$  является именно логическим, а не ассоциативным или тематическим.
- **Обоснованность:** Утверждение не должно содержать никакой информации, отсутствующей в аннотации. Каждая его часть должна быть

полностью основана на исходном тексте, исключая любые внешние знания, интерпретации или допущения.

- **Неявность:** Утверждение не должно быть результатом прямого копирования фрагмента текста. Оно должно представлять собой результат умозаключения, обобщения или переформулирования, т.е. следовать из аннотации, но не быть в ней эксплицитно указанным в той же форме. Это требование направлено на то, чтобы модели-оценщики демонстрировали способность к пониманию, а не просто к поиску подстроки.
- **Конкретность и атомарность:** Утверждение должно быть сформулировано точно, выражать одну законченную мысль и не содержать неопределенных выражений (например, «с определенными свойствами», «в некоторых состояниях») или модальных конструкций.
- **Автономность:** Утверждение должно быть полностью самодостаточным и не содержать прямых ссылок на исходный текст (например, «в данной работе», «предложенный метод», «авторы показали»). Это обеспечивает возможность его оценки в отрыве от контекста аннотации.

Соблюдение этого свода правил при генерации и последующей фильтрации данных позволило создать набор пар  $(c, e)$ , проверка которых требует от моделей не простого лексического сопоставления, а развитой способности к семантическому анализу и логическому выводу. На основе этих формализованных требований был разработан многоэтапный конвейер генерации и фильтрации данных.

### 4.3 Конвейер генерации и фильтрации данных

Для формирования набора данных RuSciFact был разработан и применен многоэтапный конвейер, который схематично представлен на Рисунке 4.1. Процесс был разделен на две независимые ветви: создание подтверждающих («положительных») и противоречащих («отрицательных») утверждений. Такой подход позволил тонко настроить инструкции и критерии фильтрации для каждого типа данных, учитывая их специфику.




Рисунок 4.1 — Обзор конвейера генерации и валидации данных для RuSciFact.

#### 4.3.1 Генерация подтверждающих утверждений

Создание качественных подтверждающих утверждений потребовало последовательного применения нескольких этапов фильтрации, каждый из которых был направлен на повышение валидности и сложности итогового набора данных.

**Этап 1: Отбор информативных аннотаций и первичная генерация.** Начальный этап был посвящен решению фундаментальной проблемы: значительная доля аннотаций в научных корпусах, включая RuSciBench, носит описательный, а не фактологический характер. Они могут описывать цели, методы или структуру исследования, не содержа при этом конкретных, проверяемых выводов. Использование таких текстов в качестве источника привело бы к генерации либо нерелевантных, либо ложных утверждений.

Для решения этой проблемы была применена стратегия предварительной фильтрации с помощью самой языковой модели. Был разработан специальный промпт, который инструктировал модель Meta-Llama-3.1-405B-Instruct выполнить одну из двух задач: либо сгенерировать научное утверждение, строго следующее из текста, либо, если это невозможно, вернуть специальный маркер «Аннотация не содержит факт». Такая постановка задачи позволила эффективно отсеять неинформативные аннотации на ранней стадии, что существенно повысило качество и релевантность первичного набора сгенерированных утверждений. По оценке модели, лишь около 42% исходных аннотаций содержали достаточный объем информации для формулирования факта. Полный текст инструкции приведён в Приложении А.1.

**Этап 2: Фильтрация по лексическому сходству.** Следующей задачей было исключение утверждений, которые, хотя и являлись формально корректными, по сути представляли собой прямое или незначительно измененное цитирование фрагментов исходной аннотации. Наличие таких примеров в наборе данных сместило бы фокус оценки с семантического понимания на поверхностное сопоставление строк.

Чтобы гарантировать, что задача требует именно логического вывода, а не поиска подстроки, был внедрен этап фильтрации на основе лексического сходства. Для каждой пары «утверждение–аннотация» вычислялась мера сходства с использованием функции `partial_ratio`, которая оценивает степень совпадения наилучшим образом выровненных подстрок. Утверждения, для которых значение этой меры превышало эмпирически подобранный порог 0.7, отбраковывались. Этот шаг позволил целенаправленно удалить «тривиальные» примеры, оставив те, что требуют от модели анализа связей между несколькими частями текста или умозаключения.

**Этап 3: Фильтрация по уровню сложности.** Предварительный ручной анализ показал, что даже после предыдущих этапов фильтрации некоторые сгенерированные утверждения могли быть общеизвестными фактами, для верификации которых не требуется научный контекст (например, «Россия является самой большой страной по территории»). Присутствие таких утверждений снизило бы сложность бенчмарка и его способность различать модели с разным уровнем «научных знаний».

Для повышения сложности и специфичности набора данных был добавлен этап классификации утверждений по уровню их нетривиальности. Языковая модель, выступая в роли эксперта, классифицировала каждое утверждение как «простое», «среднее» или «сложное» на основе промпта с четкими определениями и примерами для каждой категории. Для дальнейшей работы отбирались только утверждения средней и высокой сложности. Этот этап обеспечил фокусировку бенчмарка на проверке фактов, требующих анализа именно научного контекста, представленного в аннотации. Текст инструкции для этой классификации приведён в Приложении A.2.

### 4.3.2 Генерация противоречащих утверждений

Генерация осмысленных и нетривиальных противоречий является значительно более сложной задачей, чем подтверждение, поскольку требует не только понимания исходного текста, но и способности формулировать альтернативные, но при этом релевантные гипотезы.

В качестве исходного материала для этого этапа использовались исключительно те аннотации, для которых на предыдущем шаге удалось успешно сгенерировать подтверждающее утверждение. Такой подход был выбран из соображений эффективности и качества. Аннотации, из которых удалось извлечь подтверждаемый вывод, по определению являются информационно насыщенными и содержат четко сформулированную основную мысль. Это делает их хорошими кандидатами для формулирования осмысленного семантического противоречия, поскольку существует конкретный тезис, который можно опровергнуть. Использование этого отфильтрованного подмножества позволило сфокусировать генерацию на заведомо качественных источниках и повысить вероятность получения валидных отрицательных примеров.

**Этап 1: Формулирование семантического противоречия.** Простейший способ создать противоречие — добавить частицу «не» или иное прямое отрицание. Однако такие примеры проверяют лишь способность модели распознавать синтаксическое отрицание, а не глубокое семантическое противоречие.

Чтобы создать действительно сложные «отрицательные» примеры, был разработан промпт, который явно запрещал модели использовать прямое отрицание. Вместо этого модель должна была сгенерировать утверждение, которое по смыслу является антонимичным исходному выводу аннотации. Например, если в аннотации утверждается, что «метод А эффективнее метода Б», то требуемое противоречие не должно было звучать как «метод А не эффективнее метода Б». Этот подход позволил создать примеры, для распознавания которых требуется семантический, а не синтаксический анализ. Полная формулировка инструкции приведена в Приложении A.3.

**Этап 2: Фильтрация с использованием модели-оценщика.** Свободная генерация противоречий часто приводит к появлению утверждений, которые либо

уходят от темы исходной аннотации, либо не создают прямого логического конфликта. Ручная фильтрация таких артефактов была бы крайне трудоемкой.

Для автоматизированного контроля качества была применена парадигма «LLM как судья» (*LLM-as-a-judge*)<sup>[69]</sup>. Для каждой сгенерированной пары «утверждение–аннотация» модель просили оценить по 10-балльной шкале два параметра: релевантность утверждения теме аннотации и степень поддержки утверждения текстом (где 0 — полное противоречие, а 10 — полная поддержка). Формулировка задания для модели приведена в Приложении A.4.




Рисунок 4.2 — Распределение оценок релевантности (слева) и поддержки (справа), полученных от языковой модели при генерации противоречащих утверждений.

Распределения полученных оценок представлены на Рисунке 4.2. Как видно из гистограмм, модель часто генерировала либо высокорелевантные (оценка 8–10), либо совершенно нерелевантные (оценка 0) утверждения. Распределение оценок поддержки более равномерно, однако также имеет выраженные пики на крайних значениях, что указывает на способность модели генерировать как явные противоречия (оценка 0), так и ошибочные подтверждения.

Для дальнейшей обработки отбирались только те пары, где релевантность была не ниже 7, а степень поддержки — не выше 4. Эти пороговые значения были подобраны эмпирически на основе экспертной разметки контрольной подвыборки сгенерированных данных, что позволило откалибровать критерии автоматического отбора для максимального соответствия человеческой оценке. Использование количественных оценок позволило формализовать и автоматизировать процесс отбраковки некачественных примеров, обеспечив высокую валидность отрицательной части набора данных.

#### 4.4 Экспертная валидация и характеристики набора данных

Несмотря на многоэтапную автоматизированную фильтрацию, сгенерированные данные могут содержать артефакты, смысловые неточности или неоднозначности, которые языковая модель не способна выявить. Для обеспечения высокой объективности и валидности итогового бенчмарка был проведен заключительный этап ручной верификации всего сгенерированного корпуса.

К работе были привлечены два асессора-терминолога, обладающие опытом анализа научных текстов в различных предметных областях. Задача асессоров заключалась в независимой разметке каждой пары «утверждение–аннотация». Каждой паре  $(c, e)$  необходимо было присвоить одну из трех меток: подтверждает, опровергает или проблемный. Данная метка предназначалась для случаев, когда утверждение было сформулировано неоднозначно, содержало несуществующие термины, его истинность нельзя было установить на основе аннотации или оно имело другие дефекты, делающие его непригодным для оценки.

Ключевым принципом формирования итогового набора данных стало требование полного консенсуса между экспертами. Пары, получившие различные оценки от двух асессоров, из итоговой выборки исключались. Такой строгий подход позволил включить в бенчмарк только наиболее однозначные и качественные примеры, что критически важно для надежности оценки моделей. Примеры положительных и отрицательных утверждений доступны в Приложении А.5.

В результате описанной процедуры был сформирован итоговый набор данных RuSciFact, включающий 1128 пар «утверждение–аннотация». Детальный анализ его характеристик позволяет оценить его сложность и репрезентативность.

В Таблице 20 представлена статистика по длине текстов. Данные показывают существенную разницу в длине между короткими, атомарными утверждениями (медианная длина 14 слов) и развернутыми аннотациями (медиана 144 слова). Это отражает специфику задачи, где для проверки лаконичного факта требуется проанализировать значительно больший по объему контекст.

Распределение по классам, приведенное в Таблице 21, демонстрирует преобладание подтверждающих примеров над опровергающими. Наблюдается дисбаланс классов (примерно 2:1).

Тематический охват бенчмарка, представленный в Таблице 22, был определен на основе рубрикатора ГРНТИ исходных публикаций. Бенчмарк охватывает

Таблица 20 — Статистические характеристики длин текстов в наборе данных RuSciFact

Тип текста	Среднее	25% квантиль	50% квантиль	75% квантиль
Утверждение	15	12	14	18
Аннотация	165	86	144	234

Таблица 21 — Распределение классов в итоговом наборе данных RuSciFact

Метка	Количество
подтверждает	758
опровергает	369
Всего	1128

широкий спектр научных дисциплин, что позволяет оценивать модели на разнообразном материале. Отмечается значительное преобладание тематики «Медицина и здравоохранение» (30.85%), что отражает общие тенденции в объеме публикаций в исходном корпусе RuSciBench. Тем не менее, такие области, как физика, биология, химия и инженерные науки, также представлены в достаточном объеме, обеспечивая тематическое разнообразие набора данных.

#### 4.5 Экспериментальная оценка и анализ результатов

Созданный набор данных RuSciFact был использован для проведения комплексной оценки широкого спектра современных моделей семантического представления текстов. Эксперименты проводились в соответствии с двумя подзадачами, определенными в Разделе 4.1: информационный поиск и классификация. Цель исследования состояла в том, чтобы определить, насколько эффективно существующие векторные представления справляются с задачами тонкого семантического анализа научных текстов, требующими логического вывода, а также позиционировать разработанные в рамках диссертации модели семейства SciRus в контексте современных решений.

Таблица 22 — Тематическое распределение данных RuSciFact по областям науки (рубрикатор ГРНТИ, 1-й уровень, представлены категории с долей >1%)

Научная область (ГРНТИ)	Доля (%)
Медицина и здравоохранение	30.85
Физика	7.09
Биология	6.83
Химия	6.12
Сельское и лесное хозяйство	5.85
Машиностроение	3.99
Механика	3.46
Геология	3.28
Полиграфия. Репрография. Фотокинотехника	3.10
Математика	2.75
Народное образование. Педагогика	2.04
Строительство. Архитектура	1.95
Горное дело	1.68
Автоматика. Вычислительная техника	1.68
Языкоzнание	1.51
Психология	1.51
Государство и право. Юридические науки	1.33
Электроника. Радиотехника	1.24
Электротехника	1.15
Информатика	1.15
Металлургия	1.06
Остальные	8.43

#### 4.5.1 Оценка в задаче информационного поиска

Первая подзадача состояла в поиске единственno верной аннотации-источника для каждого утверждения из набора данных. В качестве основной меры качества использовалась метрика MRR@1 (Mean Reciprocal Rank at 1), которая показывает долю случаев, когда релевантная аннотация была ранжирована

на первое место. Высокое значение этой меры свидетельствует о способности модели точно сопоставлять семантически близкие, но лексически различные тексты.

Результаты эксперимента представлены в Таблице 23. Анализ полученных данных позволяет сделать ряд ключевых выводов.

- **Доминирование крупномасштабных моделей.** Верхние строчки рейтинга с большим отрывом занимают современные модели с миллиардами параметров, такие как GPTLM-7B, SFR-Embedding-2\_R и multilingual-e5-large-instruct. Их результаты, достигающие 0.93–0.95 по мере MRR@1, показывают, что для задачи точного поиска релевантного документа по сложному запросу-утверждению масштаб модели является определяющим фактором. Эти модели, обученные на огромных и разнообразных текстовых корпусах, формируют векторное пространство, достаточно богатое для улавливания тонких семантических связей.
- **Эффективность компактных моделей.** Примечательно, что некоторые значительно более компактные модели, в частности BERTA (128 млн) и rubert-mini-frida (32 млн), демонстрируют весьма высокие показатели (0.92 и 0.88 соответственно), опережая многие более крупные аналоги. Это говорит о том, что качественная архитектура и целевое обучение могут частично компенсировать меньший размер модели.
- **Позиционирование моделей SciRus.** Разработанные модели семейства SciRus показывают конкурентоспособные результаты в своем классе. С показателями MRR@1 в диапазоне 0.70–0.75, они существенно превосходят ряд общечелевых многоязычных моделей сопоставимого или даже большего размера (rubert-tiny-turbo, LaBSE-en-ru). Однако они заметно уступают лидирующим крупным моделям. Это указывает на то, что специализация на научных текстах дает преимущество над базовыми моделями, но для задачи точного поиска его оказывается недостаточно, чтобы конкурировать с моделями, превосходящими их по масштабу на порядки.
- **Непригодность устаревших подходов.** Ряд моделей, особенно более старых архитектур, показывают результаты, близкие к случайным (например, rubert-tiny с результатом 0.09). Это подчеркивает сложность задачи и высокие требования к структуре векторного пространства, которым удовлетворяют далеко не все подходы.

Таблица 23 — Результаты оценки моделей-кодировщиков в задаче информационного поиска на RuSciFact

Название модели	Количество параметров	MRR@1
GritLM-7B	7.24 млрд	0.95
SFR-Embedding-2_R	7.11 млрд	0.94
gte-Qwen2-1.5B-instruct	1 млрд	0.93
Linq-Embed-Mistral	7 млрд	0.93
SFR-Embedding-Mistral	7 млрд	0.93
multilingual-e5-large-instruct	560 млн	0.93
FRIDA	823 млн	0.92
BERTA	128 млн	0.92
jina-embeddings-v3	572 млн	0.92
gte-Qwen2-7B-instruct	7 млрд	0.88
multilingual-e5-base	278 млн	0.88
rubert-mini-frida	32 млн	0.88
multilingual-e5-large	560 млн	0.86
USER-bge-m3	359 млн	0.85
multilingual-e5-small	118 млн	0.80
<b>SciRus-small-cite</b>	61 млн	0.75
USER-base	124 млн	0.73
<b>SciRus-tiny-cite</b>	23 млн	0.70
<b>SciRus-small</b>	61 млн	0.70
<b>SciRus-tiny</b>	23 млн	0.71
rubert-tiny-turbo	29 млн	0.66
LaBSE-en-ru	129 млн	0.53
paraphrase-multilingual-mpnet-base-v2	278 млн	0.49
GIST-large-Embedding-v0	335 млн	0.24
rubert-tiny2	29 млн	0.22
sn-xlm-roberta-base-snli-mnli-anli-xnli	278 млн	0.17
rubert-tiny	12 млн	0.09

#### 4.5.2 Оценка в задаче классификации

Вторая подзадача заключалась в классификации предоставленной пары «утверждение–аннотация» на два класса: подтверждает или опровергает. В отличие от поиска, эта задача требует не только установления тематической близости, но и проведения логического вывода для определения характера взаимосвязи. В качестве меры качества использовалась F1-мера.

Результаты, представленные в Таблице 24, показывают иную картину.

- **Более высокая сложность задачи.** Лидирующие позиции вновь занимают крупные модели, однако максимальное значение F1-меры (0.87 у `gte-Qwen2-7B-instruct`) заметно ниже, чем значения MRR@1 в задаче поиска. Это прямо указывает на то, что задача классификации, требующая логического вывода, является существенно более сложной для современных векторных представлений, чем задача поиска по семантической близости.
- **Уплотнение результатов.** Ключевой особенностью является сильное уплотнение результатов в середине таблицы. Широкий спектр моделей с разным числом параметров и архитектурой (от 23 млн до 823 млн) показывает очень близкие F1-оценки в диапазоне 0.67–0.70. В эту группу попадают и модели семейства SciRus, и многоязычные модели, и общие модели для русского языка. Это явление можно интерпретировать как наличие «плато производительности»: многие современные кодировщики способны уловить общую тематическую связь между утверждением и аннотацией, но им не хватает разрешающей способности для надежного различия подтверждения и тонкого семантического противоречия.
- **Отсутствие явной корреляции с размером.** В отличие от задачи поиска, в задаче классификации преимущество крупных моделей не столь выражено. Например, `GritLM-7B` (7.24 млрд параметров), лидер задачи поиска, здесь показывает результат 0.73, уступая гораздо более компактным моделям. Это подтверждает, что для задач, требующих логического вывода, простое увеличение масштаба модели не всегда приводит к пропорциональному росту качества.

В целом, проведенный анализ показывает, что созданный бенчмарк RuSciFact является эффективным инструментом для дифференцированной

оценки языковых моделей. Он выявляет, что если задача поиска релевантного научного контекста для современных крупных моделей близка к решению, то задача логической верификации этого контекста остается открытым вызовом, указывая на необходимость разработки новых архитектур и методов обучения, нацеленных на улучшение способностей моделей к логическому выводу.

Таблица 24 — Результаты оценки моделей-эмбеддеров в задаче классификации на RuSciFact

Название модели	Количество параметров	F1
gte-Qwen2-7B-instruct	7 млрд	0.87
SFR-Embedding-2_R	7.11 млрд	0.82
Linq-Embed-Mistral	7 млрд	0.81
SFR-Embedding-Mistral	7 млрд	0.80
multilingual-e5-large-instruct	560 млн	0.77
gte-Qwen2-1.5B-instruct	1 млрд	0.74
GritLM-7B	7.24 млрд	0.73
USER-base	124 млн	0.70
BERTA	128 млн	0.68
USER-bge-m3	359 млн	0.68
rubert-tiny-turbo	29 млн	0.68
<b>SciRus-small-cite</b>	61 млн	0.68
<b>SciRus-small</b>	61 млн	0.68
multilingual-e5-large	560 млн	0.68
LaBSE-en-ru	129 млн	0.68
FRIDA	823 млн	0.67
rubert-tiny	12 млн	0.67
paraphrase-multilingual-mpnet-base-v2	278 млн	0.67
jina-embeddings-v3	572 млн	0.67
rubert-tiny2	29 млн	0.67
<b>SciRus-tiny-cite</b>	23 млн	0.67
multilingual-e5-base	278 млн	0.67
rubert-mini-frida	32 млн	0.67
<b>SciRus-tiny</b>	23 млн	0.67

Продолжение таблицы 24

Название модели	Количество параметров	F1
multilingual-e5-small	118 млн	0.66
sn-xlm-roberta-base-snli-mnli-anli-xnli	278 млн	0.63
GIST-large-Embedding-v0	335 млн	0.58

#### 4.5.3 Анализ сложности задачи в разрезе научных дисциплин

Для выявления научных дисциплин, представляющих наибольшую сложность для задачи классификации, был проведен анализ ошибок в разрезе предметных областей. Основная задача состояла в построении меры сложности, не зависящей от выбора конкретной архитектуры модели, что позволило бы ранжировать области по их внутренним, текстовым свойствам. Такой подход позволяет отделить специфику данных от артефактов, вносимых отдельными моделями. Для этого была предложена процедура, основанная на усреднении показателей качества по множеству разнородных моделей-кодировщиков и оценке статистической устойчивости полученных результатов с помощью метода бутстреп [70].

Методология анализа опирается на предсказания, полученные от  $M = 27$  независимых моделей-кодировщиков, описанных в 4.5. Пусть  $G$  — множество предметных областей, соответствующих рубрикам ГРНТИ первого уровня, а  $\mathcal{D}_g$  — подмножество пар «утверждение–аннотация», относящихся к области  $g \in G$ , и  $N_g = |\mathcal{D}_g|$  — его объем. Для каждой модели  $m \in \{1, \dots, M\}$  и каждой области  $g \in G$  доля ошибочных классификаций  $e_{m,g}$  определяется как:

$$e_{m,g} = \frac{1}{N_g} \sum_{i \in \mathcal{D}_g} [\hat{y}_{m,i} \neq y_i]$$

где  $y_i \in \{0, 1\}$  — истинная метка для  $i$ -й пары,  $\hat{y}_{m,i}$  — метка, предсказанная моделью  $m$ .

В качестве итоговой меры сложности предметной области  $g$  вводится индекс  $H(g)$ , вычисляемый как доля ошибок, усредненная по всему множеству

рассматриваемых моделей:

$$H(g) = \frac{1}{M} \sum_{m=1}^M e_{m,g}. \quad (4.3)$$

Величину  $H(g)$  можно интерпретировать как ожидаемую долю ошибок, усредненную по всем моделям, что позволяет использовать ее для ранжирования дисциплин по их объективной сложности.

Статистическая значимость полученных оценок  $H(g)$  и их устойчивость к выбору конкретного подмножества моделей оценивались путем построения 95%-го доверительного интервала с использованием непараметрического бутстрепа [70] по исходному множеству моделей. Процедура состояла в многократном ( $B = 200$ ) формировании бутстреп-выборок из  $M$  моделей с возвращением и пересчете индекса сложности  $H^{(b)}(g)$  для каждой  $b$ -й репликации. Границы доверительного интервала определялись как 2.5-й и 97.5-й процентили эмпирического распределения значений  $\{H^{(b)}(g)\}_{b=1}^B$ . В анализ включались только те области, для которых число примеров  $N_g \geqslant 35$ , что обеспечивало достаточную статистическую мощность для оценки.

Детальные результаты ранжирования предметных областей по индексу сложности  $H(g)$  сведены в Таблицу 25. Визуализация этих данных представлена на Рисунке 4.3, где для каждой дисциплины показан 95%-й доверительный интервал. Анализ полученных данных позволяет выделить несколько групп дисциплин.

Таблица 25 — Ранжирование научных областей по индексу сложности  $H(g)$

Научная область (ГРНТИ)	Индекс сложности $H(g)$	95% доверительный интервал
Информатика	0.4923	[0.4708; 0.5138]
Языкознание	0.4329	[0.3953; 0.4683]
Сельское и лесное хозяйство	0.3000	[0.2818; 0.3182]
Машиностроение	0.2978	[0.2773; 0.3147]
Геология	0.2832	[0.2454; 0.3297]
Энергетика	0.2800	[0.2440; 0.3160]
Математика	0.2748	[0.2439; 0.3085]
Электротехника	0.2523	[0.2154; 0.2985]

## Продолжение таблицы 25

Научная область (ГРНТИ)	Индекс сложности $H(g)$	95% доверительный интервал
Автоматика. Вычислительная техника	0.2505	[0.2020; 0.3012]
Биология	0.2270	[0.2104; 0.2473]
Медицина и здравоохранение	0.2136	[0.2024; 0.2261]
Металлургия	0.2133	[0.1900; 0.2468]
Электроника. Радиотехника	0.1857	[0.1543; 0.2143]
Физика	0.1850	[0.1630; 0.2125]
Горное дело	0.1747	[0.1453; 0.2106]
Химия	0.1588	[0.1403; 0.1774]
Химическая технология. Химическая промышленность	0.1480	[0.1160; 0.1721]
Народное образование. Педагогика	0.1374	[0.1147; 0.1583]
Механика	0.1231	[0.0984; 0.1539]
Строительство. Архитектура	0.1145	[0.0909; 0.1400]
Полиграфия. Репродукция. Фотокинотехника	0.1131	[0.0811; 0.1543]

Наивысшую сложность демонстрируют «Информатика» ( $H = 0.492$ ,  $N_g = 13$ , доверительный интервал [0.474; 0.517]) и «Языковедение» ( $H = 0.433$ ,  $N_g = 17$ , [0.398; 0.466]). Для этих областей вероятность ошибки классификации статистически значимо выше, чем для большинства других дисциплин, поскольку их доверительные интервалы не пересекаются с интервалами для областей из нижней части ранжирования. Это указывает на устойчивую внутреннюю сложность данных, не зависящую от выбора конкретной модели.

В противоположной части спектра сложности находятся дисциплины с наименьшей вероятностью ошибки. Наиболее «простыми» для классификации оказались «Государство и право» ( $H = 0.024$ ,  $N_g = 15$ ), «Психология» ( $H = 0.106$ ,  $N_g = 17$ ), «Строительство. Архитектура» ( $H = 0.115$ ,  $N_g = 22$ ) и «Механика» ( $H = 0.123$ ,  $N_g = 39$ ).




Рисунок 4.3 — График с 95%-ми доверительными интервалами для индекса сложности  $H(g)$  по классам первого уровня ГРНТИ. Оценка получена усреднением по множеству из 27 моделей.

Наиболее представленные в наборе данных дисциплины, такие как «Химия» ( $H = 0.159$ ,  $N_g = 69$ ), «Физика» ( $H = 0.185$ ,  $N_g = 80$ ) и «Медицина и здравоохранение» ( $H = 0.214$ ,  $N_g = 348$ ), занимают промежуточное положение. Благодаря большому объему данных, доверительные интервалы для них являются наиболее узкими, что делает оценки их сложности особенно надежными и указывает на стабильность работы моделей в этих областях.

Наблюдаемые различия в сложности можно объяснить спецификой научного дискурса в различных областях. Наибольшую трудность представляют дисциплины, для которых характерен высокий уровень абстракции, терминологическая вариативность и использование сложных синтаксических конструкций, где логическая связь между утверждением и текстом-источником выражена неявно. В то же время в текстах естественнонаучного и инженерного профиля, таких как физика, химия или механика, выводы часто формулируются более строго и однозначно, что упрощает задачу бинарной классификации.

Таким образом, предложенный подход позволил получить статистически обоснованное ранжирование предметных областей по сложности задачи верификации научных фактов. Полученные результаты позволяют целенаправленно подходить к разработке доменно-специфичных моделей, уделяя первоочередное внимание областям с наивысшим индексом сложности, таким как «Информатика» и «Языкознание», где существующие подходы демонстрируют недостаточную эффективность.

## 4.6 Основные выводы

В главе предложен новый бенчмарк RuSciFact для верификации научных фактов на русском языке. Задача формализована как декомпозиция на информационный поиск релевантной аннотации (4.1) и последующую бинарную классификацию пары «утверждение–аннотация» (4.2). Такая постановка позволяет раздельно оценивать способность моделей к семантическому сопоставлению и логическому выводу.

Основой бенчмарка стал набор данных из 1128 пар, созданный с помощью многоэтапного конвейера. Утверждения генерировались большой языковой моделью на основе строгих семантических и логических критериев: логическая

выводимость, неявность и обоснованность для подтверждающих примеров; семантическая антонимия без прямого отрицания для противоречащих. Качество данных обеспечивалось автоматизированной фильтрацией, включающей отсев тривиальных перефразирований по лексическому сходству и отбор сложных примеров, а также применением парадигмы «LLM как судья» для оценки релевантности и степени противоречия. Итоговая чистота корпуса была достигнута за счет ручной валидации с требованием полного консенсуса двух независимых ассессоров.

Экспериментальная оценка выявила принципиальное различие в сложности подзадач. В задаче поиска (MRR@1) современные крупномасштабные модели демонстрируют результаты, близкие к насыщению, что говорит о ее практической решенности. В то же время в задаче классификации (F1-мера) наблюдается «плато производительности»: широкий спектр моделей показывает близкие и заметно более низкие результаты, что указывает на логический вывод как на ключевое узкое место существующих векторных представлений.

Для анализа предметной сложности был введен индекс  $H(g)$  (4.3), усредняющий долю ошибок по множеству моделей и снабженный доверительными интервалами. Анализ показал, что наибольшую сложность представляют дисциплины с высоким уровнем абстракции («Информатика», «Языкознание»), тогда как области с более формализованным языком («Механика», «Строительство. Архитектура») оказались значительно проще для классификации.

Таким образом, RuSciFact является эффективным инструментом, разделяющим способности моделей к поиску и логическому анализу. Он задает эталон для разработки доменно-устойчивых кодировщиков и указывает на необходимость создания моделей, целенаправленно улучшающих способности к логическому выводу, особенно в предметных областях с доказанной высокой сложностью.

## Заключение

Основные результаты работы заключаются в следующем.

1. Разработана двухэтапная методология обучения компактных двуязычных моделей SciRus-tiny (23 млн параметров) и SciRus-small (61 млн параметров) для векторного представления научных текстов на русском и английском языках. Методология включает этап маскированного языкового моделирования (MLM) на большом мультиязычном корпусе научных текстов и последующее контрастивное дообучение на парах «заголовок-аннотация» и на парах «цитирующая статья — цитируемая статья». Эксперименты на бенчмарках RuSciBench и SciDocs показали, что предложенные модели, несмотря на значительно меньшее число параметров, демонстрируют качество, сопоставимое с гораздо более крупными моделями, и обладают высокой вычислительной эффективностью.
2. Разработан и апробирован мультизадачный русско-английский бенчмарк RuSciBench, предназначенный для оценки качества моделей векторного представления научных текстов. Бенчмарк суммарно включает 18 задач, 9 из которых были разработаны лично, а именно классификацию, регрессию, моно- и кросс-языковой поиск, и основан на данных российской научной электронной библиотеки eLibrary.ru. RuSciBench обеспечивает стандартизированную и воспроизводимую процедуру тестирования и интегрирован в международный лидерборд МТЕВ. Оценка широкого спектра моделей на данном бенчмарке позволила выявить как общие тенденции влияния размера моделей на их производительность, так и преимущества доменной специализации.
3. Предложена и экспериментально проверена полуавтоматическая методика формирования наборов данных для задачи верификации научных фактов на русском языке. Данная методика сочетает генерацию научных утверждений на основе аннотаций с использованием больших языковых моделей (LLM), многоэтапную фильтрацию и оценку сгенерированных утверждений самой моделью, а также последующую экспертную валидацию. На основе этой методики создан и опубликован RuSciFact — первый русскоязычный бенчмарк для оценки способности моделей

определять, подтверждается ли научное утверждение текстом аннотации или противоречит ему. Проведена оценка современных генеративных и эмбеддинг-моделей на данном бенчмарке.

Таким образом, в рамках данной работы были разработаны, исследованы и апробированы инструменты и модели, направленные на решение актуальных задач эффективной обработки, анализа и оценки качества представления научных текстов на русском и английском языках. Полученные результаты вносят вклад в развитие методов анализа научной информации, предоставляя научному сообществу открытые ресурсы для оценки и создания новых моделей, а также эффективные легковесные решения для практического применения в научно-информационных системах.

## Список литературы

1. *Thelwall, M.* Scopus 1900–2020: Growth in articles, abstracts, countries, fields, and journals [Текст] / М. Thelwall, P. Sud // Quantitative Science Studies. — 2022. — Апр. — Т. 3, № 1. — С. 37—50. — eprint: [https://direct.mit.edu/qss/article-pdf/3/1/37/2008360/qss\\_a\\_00177.pdf](https://direct.mit.edu/qss/article-pdf/3/1/37/2008360/qss_a_00177.pdf). — URL: [https://doi.org/10.1162/qss%5C\\_a%5C\\_00177](https://doi.org/10.1162/qss%5C_a%5C_00177).
2. Динамика роста числа публикаций [Текст]. — ООО Научная электронная библиотека, 2025. — URL: [https://www.elibrary.ru/stat\\_time\\_items.asp](https://www.elibrary.ru/stat_time_items.asp) (дата обр. 10.05.2025) ; Статистические данные по состоянию на 04.05.2025. Электронный ресурс eLIBRARY.RU.
3. *Бажанов, Д. И.* Параллельная обработка данных в научных исследованиях [Текст] / Д. И. Бажанов, А. А. Журавлев, К. К. Абгарян. — Москва : МАКС ПРЕСС, 2021. — С. 112. — Тираж 500(1-50) экз.
4. *Salton, G.* A vector space model for automatic indexing [Текст] / G. Salton, A. Wong, C.-S. Yang // Communications of the ACM. — 1975. — Т. 18, № 11. — С. 613—620.
5. *Robertson, S.* The probabilistic relevance framework: BM25 and beyond [Текст] / S. Robertson, H. Zaragoza // Foundations and Trends® in Information Retrieval. — 2009. — Т. 3, № 4. — С. 333—389.
6. Attention is all you need [Текст] / A. Vaswani [и др.] // Advances in neural information processing systems. — Curran Associates, Inc. 2017. — С. 5998—6008.
7. BioCPT: Contrastive Pre-trained Transformers with Large-scale PubMed Search Logs for Zero-shot Biomedical Information Retrieval [Текст] / Q. Jin [и др.] // Bioinformatics. — 2023. — Т. 39 11. — URL: <https://api.semanticscholar.org/CorpusID:259316759>.
8. Text Embeddings by Weakly-Supervised Contrastive Pre-training [Текст] / L. Wang [и др.] // arXiv preprint arXiv:2212.03533. — 2022.
9. SciRus: Tiny and Powerful Multilingual Encoder for Scientific Texts [Текст] / N. Gerasimenko [и др.] // Doklady Mathematics. — 2024. — Дек. — Т. 110, № 1. — С193—С202. — URL: <https://doi.org/10.1134/S1064562424602178>.

10. RuSentEval: Linguistic Source, Encoder Force! [Текст] / V. Mikhailov [и др.] // Proceedings of the 8th Workshop on Balto-Slavic Natural Language Processing. — Kyiv, Ukraine : Association for Computational Linguistics, 04.2021. — С. 43—65. — URL: <https://aclanthology.org/2021.bsnlp-1.6>.
11. Dale, D. Рейтинг русскоязычных энкодеров предложений [Текст] / D. Dale. — 06.2022. — URL: <https://habr.com/ru/articles/669674/> ; [Online; posted 12-June-2022].
12. Президент Российской Федерации. Национальная стратегия развития искусственного интеллекта на период до 2030 года (с изменениями 2024 г.) [Текст] / Президент Российской Федерации. — 2024. — Утверждена Указом Президента Российской Федерации от 10 октября 2019 г. № 490. Изменения внесены Указом Президента Российской Федерации от 15 февраля 2024 г. № 124 ”О внесении изменений в Указ Президента Российской Федерации от 10 октября 2019 г. N 490 ’О развитии искусственного интеллекта в Российской Федерации’ и в Национальную стратегию, утвержденную этим Указом”.
13. AIR-Bench: Benchmarking Large Audio-Language Models via Generative Comprehension [Текст] / Q. Yang [и др.] // Annual Meeting of the Association for Computational Linguistics. — 2024. — URL: <https://api.semanticscholar.org/CorpusID:267626820>.
14. Long Input Benchmark for Russian Analysis [Текст] / I. Churin [и др.] // ArXiv. — 2024. — T. abs/2408.02439. — URL: <https://api.semanticscholar.org/CorpusID:271710181>.
15. RuSciBench: Open Benchmark for Russian and English Scientific Document Representations [Текст] / A. Vatolin [и др.] // Doklady Mathematics. — 2024. — Дек. — Т. 110, № 1. — S251—S260. — URL: <https://doi.org/10.1134/S1064562424602191>.
16. ruSciFact: Open Benchmark for Verifying Scientific Facts in Russian [Текст] / A. Vatolin [и др.] // Computational Linguistics and Intellectual Technologies: Papers from the Annual International Conference ”Dialogue” (2025). — 2025. — Июнь. — Т. 23. — S435—S459. — URL: <https://doi.org/10.28995/2075-7182-2025-23-435-459>.

17. MMTEB: Massive Multilingual Text Embedding Benchmark [Текст] / K. Enevoldsen [и др.] // — 02.2025. — URL: <https://openreview.net/forum?id=zl3pfz4VCV>.
18. Vatolin, A. Structured Sentiment Analysis with Large Language Models: A Winning Solution for RuOpinionNE-2024 [Текст] / A. Vatolin // Computational Linguistics and Intellectual Technologies: Papers from the Annual International Conference "Dialogue" (2025). — 2025. — Июнь. — Т. 23. — S416—S434. — URL: <https://doi.org/10.28995/2075-7182-2025-23-416-434>.
19. Liu, Z. Representation Learning for Natural Language Processing [Текст] / Z. Liu, Y. Lin, M. Sun // Representation Learning for Natural Language Processing. — 2023. — URL: <https://api.semanticscholar.org/CorpusID:63458344>.
20. Firth, J. R. A synopsis of linguistic theory 1930-1955 [Текст] / J. R. Firth // Studies in Linguistic Analysis, Special volume of the Philological Society. — 1957. — C. 1—32.
21. Spärck Jones, K. A statistical interpretation of term specificity and its application in retrieval [Текст] / K. Spärck Jones // Journal of Documentation. — 1972. — Т. 28, № 1. — С. 11—21.
22. Indexing by latent semantic analysis [Текст] / S. Deerwester [и др.] // Journal of the American Society for Information Science. — 1990. — Т. 41, № 6. — С. 391—407.
23. A Neural Probabilistic Language Model [Текст] / Y. Bengio [и др.] // Journal of machine learning research. — 2003. — Т. 3. — С. 1137—1155.
24. Efficient estimation of word representations in vector space [Текст] / T. Mikolov [и др.] // arXiv preprint arXiv:1301.3781. — 2013.
25. Pennington, J. GloVe: Global Vectors for Word Representation [Текст] / J. Pennington, R. Socher, C. D. Manning // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). — Association for Computational Linguistics, 2014. — С. 1532—1543. — URL: <https://aclanthology.org/D14-1162>.
26. Deep contextualized word representations [Текст] / M. E. Peters [и др.] // arXiv preprint arXiv:1802.05365. — 2018.
27. Sennrich, R. Neural machine translation of rare words with subword units [Текст] / R. Sennrich, B. Haddow, A. Birch // arXiv preprint arXiv:1508.07909. — 2015.

28. Google’s Neural Machine Translation System: Bridging the Gap between Human and Machine Translation [Текст] / Y. Wu [и др.] // ArXiv. — 2016. — T. abs/1609.08144. — URL: <https://api.semanticscholar.org/CorpusID:3603249>.
29. Kudo, T. Subword Regularization: Improving Neural Network Translation Models with Multiple Subword Candidates [Текст] / T. Kudo // Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers) / под ред. I. Gurevych, Y. Miyao. — Melbourne, Australia : Association for Computational Linguistics, 07.2018. — С. 66—75. — URL: <https://aclanthology.org/P18-1007/>.
30. A Robustly Optimized BERT Pre-training Approach with Post-training [Текст] / L. Zhuang [и др.] // Proceedings of the 20th Chinese National Conference on Computational Linguistics / под ред. S. Li [и др.]. — Huhhot, China : Chinese Information Processing Society of China, 08.2021. — С. 1218—1227. — URL: <https://aclanthology.org/2021.ccl-1.108/>.
31. Language Models are Unsupervised Multitask Learners [Текст] / A. Radford [и др.] // . — 2019. — URL: <https://api.semanticscholar.org/CorpusID:160025533>.
32. Householder, A. S. A theory of steady-state activity in nerve-fiber networks: I. Definitions and preliminary lemmas [Текст] / A. S. Householder // The Bulletin of Mathematical Biophysics. — 1941. — Июнь. — Т. 3, № 2. — С. 63—69.
33. Ba, J. Layer Normalization [Текст] / J. Ba, J. R. Kiros, G. E. Hinton // ArXiv. — 2016. — T. abs/1607.06450. — URL: <https://api.semanticscholar.org/CorpusID:8236317>.
34. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding [Текст] / J. Devlin [и др.] // Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers) / под ред. J. Burstein, C. Doran, T. Solorio. — Minneapolis, Minnesota : Association for Computational Linguistics, 06.2019. — С. 4171—4186. — URL: <https://aclanthology.org/N19-1423/>.
35. Google’s Neural Machine Translation System: Bridging the Gap between Human and Machine Translation [Текст] / Y. Wu [и др.] // ArXiv. — 2016. — T. abs/1609.08144. — URL: <https://api.semanticscholar.org/CorpusID:3603249>.

36. SemEval-2017 Task 1: Semantic Textual Similarity Multilingual and Crosslingual Focused Evaluation [Текст] / D. Cer [и др.] // Proceedings of the 11th International Workshop on Semantic Evaluation (SemEval-2017) / под ред. S. Bethard [и др.]. — Vancouver, Canada : Association for Computational Linguistics, 08.2017. — C. 1—14. — URL: <https://aclanthology.org/S17-2001/>.
37. Reimers, N. Sentence-bert: Sentence embeddings using siamese bert-networks [Текст] / N. Reimers, I. Gurevych // arXiv preprint arXiv:1908.10084. — 2019.
38. Schroff, F. FaceNet: A unified embedding for face recognition and clustering [Текст] / F. Schroff, D. Kalenichenko, J. Philbin // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). — 2015. — C. 815—823. — URL: <https://api.semanticscholar.org/CorpusID:206592766>.
39. Oord, A. van den. Representation Learning with Contrastive Predictive Coding [Текст] / A. van den Oord, Y. Li, O. Vinyals // ArXiv. — 2018. — T. abs/1807.03748. — URL: <https://api.semanticscholar.org/CorpusID:49670925>.
40. Koponen, I. T. Usage of Terms "Science" and "Scientific Knowledge" in Nature of Science (NOS): Do Their Lexicons in Different Accounts Indicate Shared Conceptions? [Текст] / I. T. Koponen // Education Sciences. — 2020. — URL: <https://api.semanticscholar.org/CorpusID:225026010>.
41. SPECTER: Document-level Representation Learning using Citation-informed Transformers [Текст] / A. Cohan [и др.] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics / под ред. D. Jurafsky [и др.]. — Online : Association for Computational Linguistics, 07.2020. — C. 2270—2282. — URL: <https://aclanthology.org/2020.acl-main.207/>.
42. Pan, S. J. A Survey on Transfer Learning [Текст] / S. J. Pan, Q. Yang // IEEE Transactions on Knowledge and Data Engineering. — 2010. — Т. 22, № 10. — C. 1345—1359.
43. Beltagy, I. SciBERT: A Pretrained Language Model for Scientific Text [Текст] / I. Beltagy, K. Lo, A. Cohan // Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). — Association for Computational Linguistics, 2019. — C. 3613—3618.
44. SciRepEval: A Multi-Format Benchmark for Scientific Document Representations [Текст] / A. Singh [и др.] // ArXiv. — 2022. — T. abs/2211.13308.

45. Parameter-efficient transfer learning for NLP [Текст] / N. Houlsby [и др.] // International conference on machine learning. — PMLR. 2019. — C. 2790—2799.
46. *Pasternack, S.* The Scientific Enterprise: Public Knowledge. An Essay Concerning the Social Dimension of Science [Текст] / S. Pasternack // Science. — 1969. — Май. — Т. 164, № 3880. — С. 669—670. — URL: <https://www.science.org/doi/10.1126/science.164.3880.669>.
47. Neighborhood Contrastive Learning for Scientific Document Representations with Citation Embeddings [Текст] / M. Ostendorff [и др.] // Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing / под ред. Y. Goldberg, Z. Kozareva, Y. Zhang. — Abu Dhabi, United Arab Emirates : Association for Computational Linguistics, 12.2022. — URL: <https://aclanthology.org/2022.emnlp-main.802/>.
48. PyTorch-BigGraph: A Large-scale Graph Embedding System [Текст] / A. Lerer [и др.] // Proceedings of the 2nd SysML Conference. — Palo Alto, CA, USA, 2019.
49. *Lipscomb, C. E.* Medical subject headings (MeSH) [Текст] / C. E. Lipscomb // Bulletin of the Medical Library Association. — 2000. — Т. 88, № 3. — С. 265.
50. An overview of microsoft academic service (mas) and applications [Текст] / A. Sinha [и др.] // Proceedings of the 24th international conference on world wide web. — 2015. — С. 243—246.
51. Fact or Fiction: Verifying Scientific Claims [Текст] / D. Wadden [и др.] // Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). — Online : Association for Computational Linguistics, 11.2020. — С. 7534—7550. — URL: <https://aclanthology.org/2020.emnlp-main.609>.
52. MTEB: Massive Text Embedding Benchmark [Текст] / N. Muennighoff [и др.] // arXiv preprint arXiv:2210.07316. — 2022. — URL: <https://arxiv.org/abs/2210.07316>.
53. S2ORC: The Semantic Scholar Open Research Corpus [Текст] / K. Lo [и др.] // Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics / под ред. D. Jurafsky [и др.]. — Association for Computational Linguistics, 07.2020. — С. 4969—4983. — URL: <https://aclanthology.org/2020.acl-main.447>.

54. *Dale, D.* Маленький и быстрый BERT для русского языка [Текст] / D. Dale. — 06.2021. — URL: <https://habr.com/ru/post/562064/> ; [Online; posted 10-June-2021].
55. *Hugging Face.* Text Embeddings Inference [Текст] / Hugging Face. — 2023. — URL: <https://github.com/huggingface/text-embeddings-inference> ; Accessed: 2025-05-14. <https://github.com/huggingface/text-embeddings-inference>.
56. *Grafana Labs.* k6 [Текст] / Grafana Labs. — 2017. — URL: <https://k6.io> ; A modern load testing tool for developers and testers. <https://k6.io>.
57. RuMedBench: A Russian Medical Language Understanding Benchmark [Текст] / P. Blinov [и др.] // Conference on Artificial Intelligence in Medicine in Europe. — 2022. — URL: <https://api.semanticscholar.org/CorpusID:246016223>.
58. *Stahl, P. M.* Lingua-py: The most accurate natural language detection library for Python [Текст] / P. M. Stahl. — 2024. — URL: <https://github.com/pemistahl/lingua-py> ; Suitable for short text and mixed-language text detection. <https://github.com/pemistahl/lingua-py>.
59. *Lopez, F.* langdetect: Language detection library for Python [Текст] / F. Lopez. — 2021. — Дата обращения: 07.08.2025. <https://github.com/fedelopez77/langdetect>.
60. Learning Word Vectors for 157 Languages [Текст] / E. Grave [и др.] // Proceedings of the International Conference on Language Resources and Evaluation (LREC 2018). — 2018.
61. Scikit-learn: Machine Learning in Python [Текст] / F. Pedregosa [и др.] // Journal of Machine Learning Research. — 2011. — Т. 12. — С. 2825—2830.
62. BEIR: A Heterogeneous Benchmark for Zero-shot Evaluation of Information Retrieval Models [Текст] / N. Thakur [и др.] // Thirty-fifth Conference on Neural Information Processing Systems Datasets and Benchmarks Track (Round 2). — 2021. — URL: <https://openreview.net/forum?id=wCu6T5xFjeJ>.
63. What are the best systems? new perspectives on NLP benchmarking [Текст] / P. Colombo [и др.] // Proceedings of the 36th International Conference on Neural Information Processing Systems. — New Orleans, LA, USA : Curran Associates Inc., 2022. — (NIPS '22).

64. *Gilardi, F.* ChatGPT outperforms crowd workers for text-annotation tasks [Текст] / F. Gilardi, M. Alizadeh, M. Kubli // Proceedings of the National Academy of Sciences of the United States of America. — 2023. — Т. 120. — URL: <https://api.semanticscholar.org/CorpusID:257766307>.
65. LLMs in the Loop: Leveraging Large Language Model Annotations for Active Learning in Low-Resource Languages [Текст] / N. Kholodna [и др.] // ArXiv. — 2024. — Т. abs/2404.02261. — URL: <https://api.semanticscholar.org/CorpusID:268876095>.
66. MERA: A Comprehensive LLM Evaluation in Russian [Текст] / A. Fenogenova [и др.] // Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers) / под ред. L.-W. Ku, A. Martins, V. Srikumar. — Bangkok, Thailand : Association for Computational Linguistics, 08.2024. — С. 9920—9948. — URL: <https://aclanthology.org/2024.acl-long.534>.
67. Efficient Memory Management for Large Language Model Serving with PagedAttention [Текст] / W. Kwon [и др.] // Proceedings of the ACM SIGOPS 29th Symposium on Operating Systems Principles. — 2023.
68. LLM.int8(): 8-bit Matrix Multiplication for Transformers at Scale [Текст] / T. Dettmers [и др.] // Advances in Neural Information Processing Systems. — 2022. — URL: <https://arxiv.org/abs/2208.07339>.
69. Judging LLM-as-a-Judge with MT-Bench and Chatbot Arena [Текст] / L. Zheng [и др.]. — 2023. — arXiv: [2306.05685 \[cs.CL\]](https://arxiv.org/abs/2306.05685).
70. *Efron, B.* Bootstrap Methods: Another Look at the Jackknife [Текст] / B. Efron // Annals of Statistics. — 1979. — Т. 7. — С. 1—26. — URL: <https://api.semanticscholar.org/CorpusID:227312712>.

## Приложение А

### Промпты для формирования выборки в бенчмарке RuSciFact и примеры данных

#### A.1 Промпты для генерации подтверждающего утверждения в бенчмарке RuSciFact

Этот промпт генерирует один строгий факт, который следует из аннотации, без прямого цитирования. Плейсхолдер {text} заменяется текстом аннотации.

Вы ученый, который хорошо разбирается во всех областях науки. Ваша задача - записать один факт, который следует из аннотации к статье. Вы не можете скопировать текст из аннотации, вам нужно написать факт, который следует из аннотации, но прямо в ней не указан. Примечание: Убедитесь, что извлеченный факт точно выведен из содержания аннотации, без добавления какой-либо дополнительной информации или интерпретации. При написании факта избегай ссылок на аннотацию (в приведенном текст, в данной работе, предложенный метод). Также при написании факта избегай неопределенности, например "с определенным свойствами", "в некоторых состояниях", "определенной длины". Если по аннотации невозможно написать точный факт, то напиши "Аннотация не содержит факт"

Ниже приведены 2 примера фактов и аннотаций, на основе которых они были написаны.

Аннотация к статье: Ожидается, что снижение уровня гомоцистеина в сыворотке крови с помощью фолиевой кислоты снизит смертность от ишемической болезни сердца. Известно, что максимальное снижение уровня гомоцистеина достигается при приеме фолиевой кислоты в дозе 1 мг/сут, но эффект более низких доз (имеющих отношение к обогащению пищевых продуктов) неясен. МЕТОДЫ Мы рандомизировали 151 пациента с ишемической болезнью сердца на 1 из 5 доз фолиевой кислоты (0,2, 0,4, 0,6, 0,8

и 1,0 мг/сут) или плацебо. Первоначально, через 3 месяца приема добавок и через 3 месяца после прекращения приема фолиевой кислоты, были взяты образцы крови натощак для анализа на содержание гомоцистеина и фолиевой кислоты в сыворотке крови. РЕЗУЛЬТАТЫ: Средний уровень гомоцистеина в сыворотке крови снижался при увеличении дозы фолиевой кислоты до максимума при приеме 0,8 мг фолиевой кислоты в день, когда снижение уровня гомоцистеина (с поправкой на плацебо) составляло 2,7 мкмоль/л (23%), что аналогично известному эффекту приема фолиевой кислоты в дозах 1 мг/сут и выше. Чем выше был исходный уровень гомоцистеина в сыворотке крови человека, тем сильнее была реакция на фолиевую кислоту, но статистически значимое снижение наблюдалось независимо от исходного уровня. Уровень фолиевой кислоты в сыворотке крови повышался примерно линейно (5,5 нмоль/л на каждые 0,1 мг фолиевой кислоты). Индивидуальные колебания уровня гомоцистеина в сыворотке крови, измеренные в группе плацебо, были значительными по сравнению с эффектом приема фолиевой кислоты, что указывает на то, что мониторинг снижения уровня гомоцистеина у конкретного человека нецелесообразен.

**ВЫВОДЫ** Для достижения максимального снижения уровня гомоцистеина в сыворотке крови во всем диапазоне уровней гомоцистеина в популяции, по-видимому, необходима доза фолиевой кислоты в размере 0,8 мг/сут. Нынешние уровни обогащения пищевых продуктов в США позволяют достичь лишь небольшой доли достижимого снижения уровня гомоцистеина.

Факт из статьи: Дефицит витамина В9 снижает уровень гомоцистеина в крови.

**Аннотация к статье:** Для реакции выделения кислорода (OER) были разработаны известные на Земле катализаторы первого ряда (3d) на основе переходных металлов; однако они работают при потенциалах, значительно превышающих термодинамические требования. Теория функционала плотности предполагает, что не трехмерные металлы с высокой валентностью, такие как вольфрам, могут модулировать трехмерные оксиды металлов, обеспечивая почти оптимальную энергию адсорбции для предлагаемых

промежуточных продуктов. Мы разработали метод синтеза при комнатной температуре для получения гелеобразных оксигидроксидных материалов с атомарно однородным распределением металлов. Эти гелеобразные оксигидроксиды FeCoW обладают самым низким перенапряжением (191 милливольт), зарегистрированным при 10 миллиамперах на квадратный сантиметр в щелочном электролите. Катализатор не проявляет признаков разложения после более чем 500 часов работы. Рентгеновское поглощение и компьютерные исследования показывают синергетическое взаимодействие между вольфрамом, железом и кобальтом в создании благоприятной локальной координационной среды и электронной структуры, которые повышают энергетику предложения.

Факт из статьи: Усовершенствованные катализаторы OER демонстрируют стабильную активность в течение нескольких сотен часов.

Если в аннотации не содержится фактов, например: В статье рассмотрено становление британо-японских отношений в период биполярности, отражена история формирования двусторонних отношений, а также сотрудничество в экономической, политической, научно-технической и социально-культурной сферах в указанный период. Главный акцент был сделан на рассмотрении зарождения отношений между Великобританией и Японией и анализа динамики их развития. то напиши "Аннотация не содержит факт".

Теперь ваша задача - записать этот факт в следующую аннотацию, точно следуя инструкциям

{text}

Не пиши никаких вводных слов (например "из аннотации следует, что"), только факт. Напишите свой факт из этой аннотации:

## A.2 Промпт для классификации сложности факта

Этот промпт определяет уровень сложности уже сформулированного факта. На вход подставляется сам факт вместо {text}; на выходе требуется одно слово: простой, средний, сложный или неопределенный.

### **Инструкция по классификации фактов по научным статьям**

Вы являетесь учёным, обладающим глубокими знаниями во всех областях науки. Ваша задача - определить сложность факта, изложенного в аннотации к научной статье. Факты могут быть классифицированы по трём уровням сложности: простой, средний и сложный. В отдельных случаях факт может быть неопределенным.

#### **Категории фактов:**

##### **1. Простой факт:**

Факт очевиден большинству образованных людей и не требует дополнительных исследований или чтений для его подтверждения или опровержения. Такие факты известны из общих знаний.

Примеры простых фактов:

- Экономическая эффективность потребления может варьироваться в зависимости от личностных свойств потребителей.
- В России существует закон, регулирующий проведение медицинских научных исследований с участием человека и/или лабораторных животных.
- Нитраты могут вызывать токсические эффекты у животных.
- Российские вузы сокращают количество бюджетных мест.
- В Республике Алтай представлены многочисленные виды туризма и отдыха.
- У студентов вузов ценность внутреннего успеха выше, чем внешнего.
- Изменение жесткости элементов конструкций здания может быть вызвано разными факторами.
- Преступления, связанные с фальшивомонетничеством, совершались на территории Российской Федерации и Белгородской области.

## **2. Средний факт:**

Факт достаточно сложен, большинству людей понадобится читать специализированные статьи или проводить запросы в интернете, чтобы понять, подтвердить или опровергнуть этот факт.

Примеры средних фактов:

- Поражение молочной железы эхинококком может быть излечено хирургическим путем.
- Татарстан стал более засушливым регионом за последние десятилетия.

## **3. Сложный факт:**

Факт требует специфических знаний или экспертизы в данной научной области для его понимания.

Примеры сложных фактов:

- Прокатка СВС-продуктов в валках прокатного стана перед измельчением в шаровой мельнице увеличивает эффективность измельчения.
- У больных диабетическим макулярным отеком наблюдается повышенный уровень брадикинина в крови.
- Стентирование коронарных артерий не вызывает значимых изменений показателей глобальной и сегментарной продольной систолической деформации миокарда левого желудочка в первые 3 сут после процедуры.

## **4. Неопределённый факт:**

Факт недостаточно ясен, неполон или содержит ссылки, требующие дополнительных разработок или исследований.

Примеры неопределённых фактов:

- Российские компании могут использовать разработанную шкалу для определения уровня развития ориентации на бренд.
- Предыдущие модели теплоусвоения вермикулита были неточными.

### **Ваша задача:**

Внимательно изучите предоставленный факт и напишите одно из следующих определений сложности факта: "простой" "средний" "сложный" или "неопределенный". Напиши только одно слово, не объясняй причины такой классификации

Вот факт, для которого это нужно написать: {text}

### A.3 Промпт для генерации опровергающего факта

Этот промпт формирует релевантное аннотации утверждение, которое не вытекает из текста и не подтверждается им. Нельзя использовать явное отрицание, требуется конкретный, проверяемый факт. На вход подается аннотация вместо {text}.

Вы ученый, который хорошо разбирается во всех областях науки. Ваша задача - написать один факт, который был бы релевантен аннотации, но не следует из нее. Не используй отрицание, вместо этого напишите факт, который не подтверждается аннотацией, но релевантен ей! Вы не можете скопировать текст из аннотации, вам нужно написать факт, который не следует из аннотации. Примечание: Убедитесь, что извлеченный факт точно выведен из содержания аннотации, без добавления какой-либо дополнительной информации или интерпретации. При написании факта избегай ссылок на аннотацию (в приведенном текст, в данной работе, предложенный метод). Также при написании факта избегай неопределенности, например "с определенным свойствами" в некоторых состояниях "определенной длины". Если по аннотации невозможно написать точный факт, то напиши "Аннотация не содержит факт".

Ниже приведены 2 примера фактов и аннотаций, на основе которых они были написаны.

#### Пример 1

##### **Аннотация к статье:**

Статья посвящена актуальным проблемам установления уголовного запрета в сфере профессиональной медицинской деятельности. Проанализированы предложения Следственного комитета РФ о внесении изменений в действующий Уголовный Кодекс РФ, на основании социологического опроса и изучения уголовных дел, сделаны выводы о необходимости реформы

уголовного закона. Основным является вывод о невозможности решения актуальных проблем в российском здравоохранении исключительно уголовно-правовыми средствами.

**Факт из статьи:** Актуальные проблемы в российском здравоохранении могут быть решены исключительно уголовно-правовыми средствами

### Пример 2

#### **Аннотация к статье:**

Рассмотрены вопросы создания системы охраны территорий и объектов стратегического назначения. Предложены структура и способ построения такой системы, использующие методы теории решеток. Для обработки и анализа информации с датчиков физических величин и последующего принятия решений применяются решетки, построенные с помощью оператора замыкания.

**Факт из статьи:** Решетки могут быть построены без использования оператора замыкания

### Пример аннотации без фактов

Если в аннотации не содержится фактов, например:

В статье рассмотрено становление британо-японских отношений в период bipolarности, отражена история формирования двусторонних отношений, а также сотрудничество в экономической, политической, научно-технической и социально-культурной сферах в указанный период. Главный акцент был сделан на рассмотрении зарождения отношений между Великобританией и Японией и анализа динамики их развития.

то напиши "Аннотация не содержит факт".

### Пример неподходящего факта

**Аннотация к статье:** В статье обсуждаются вопросы взаимосвязи токсичности сточных вод и их химического состава. Для ряда гидрохимических показателей установлена достоверная связь между показателем токсичности, определявшимся с использованием методики, где в качестве тест-организма выступает *P. Caudatum*.

**Факт из статьи:** Для ряда гидрохимических показателей не существует достоверной связи между показателем токсичности,

определявшимся с использованием методики, где в качестве тест-организма выступает *P. Caudatum*.

Факт не подходит, потому что можно удалить "не" и факт будет верным.

Не добавяй ничего к ответу, напиши только факт. Не пиши свои рассуждения, только факт! Теперь ваша задача - записать этот факт в следующую аннотацию, точно следуя инструкциям:

**Аннотация к статье:** {text}

**Факт из статьи:**

#### A.4 Промпт для оценки релевантности и степени подтверждения

Этот промпт оценивает по шкале от 0 до 10 два аспекта: релевантность факта аннотации и степень подтверждения факта текстом. На вход подставляется текст, содержащий аннотацию и соответствующий факт, через {text}; на выход требуется JSON с полями `relevance` и `support`.

##### Описание Задачи

Вы ученый, который хорошо разбирается во всех областях науки.

##### Задача

Задача - оценить релевантность факта аннотации и насколько аннотация подтверждает факт.

##### Формат Вывода

На выходе нужно написать JSON.

**Пример ответа:**

```
{
    "relevance": "Релевантность факта аннотации",
    "support": "Насколько аннотация подтверждает факт"
}
```

**Описание Полей**

Поля `relevance` и `support` могут принимать значения от 0 до 10, где 0 — не релевантно (не подтверждает факт), 10 — максимально релевантно (подтверждает факт).

**Входные Данные**

Текст для анализа:

{text}

**A.5 Примеры положительных и отрицательных утверждений из ruSciFact**

В этом разделе приведён один положительный и один отрицательный пример из датасета ruSciFact.

**Пример 1**

**Утверждение:** Пациенты с ишемической болезнью сердца, перенесшие чрескожные коронарные вмешательства, демонстрируют улучшение толерантности к физической нагрузке при использовании компьютеризированных систем поддержки врачебных решений.

**Анноатция:** Цель. Изучить эффективность амбулаторных реабилитационно-профилактических программ у пациентов после чрескожных коронарных вмешательств (ЧКВ) с использованием компьютеризированной системы под-

держки врачебных решений (СПКР), предназначенной для выбора режима контролируемых физических тренировок (КФТ) и предоставления полноценных рекомендаций по физической активности (ФА). Материал и методы. Исследование выполняли в течение 12 мес. с включением 194 пациентов (124 мужчины и 70 женщин, средний возраст 53,5) со стабильной формой ишемической болезни сердца (ИБС), перенесших ЧКВ (коронарную ангиопластику, коронарное стентирование). При выборе режима КФТ использовалась компьютеризированная СПКР. Традиционные врачебные решения анализировали по специально разработанной анкете. Результаты. Пациенты группы КФТ, продемонстрировали достоверное увеличение толерантности к физической нагрузке (ТФН) и средней продолжительности ФН, положительную динамику качества жизни (КЖ), высокий уровень приверженности лекарственной терапии на протяжении всего периода реабилитации. При формировании врачебных решений использовали, в среднем, 3 клинических признака. Наиболее типичные врачебные ошибки носили методологический характер. Заключение. Интегрирование реабилитационных программ с использованием СПВР в амбулаторных условиях у пациентов, перенесших ЧКВ, обеспечивает высокую эффективность реабилитационно-профилактических мероприятий и безопасность ФТ.

**Метка класса:** подтверждает

### **Пример 2**

**Утверждение:** Порода карпа не влияет на содержание сухого вещества, жира, протеина у сеголетков карпа

**Аннотация:** В статье приведены результаты сравнения биохимического состава тела сеголетков и годовиков некоторых коллекционных пород карпа, разводимых в спу «Изобелино»: немецкого, сарбоянского, отводок изобелинского карпа (столин XVIII, три прим, смесь чешуйчатая), выращенных одновременно, в одинаковых условиях и зимовавших совместно в одном пруду. Установлены породы, характеризующиеся повышенными уровнями содержания сухого вещества, жира, протеина у сеголетков карпа. В результате исследования биохимического состава тела сеголетков карпа разной породной принадлежности, выращенных в одинаковых условиях, проявляется тенденция к увеличению содержания сухого вещества, жира и протеина у коллекционных линий карпа белорусской селекции (изобелинский) по сравнению с породами зарубежной селекции (немецкий и сарбоянский), выращенными одновременно в одинаковых условиях. У годовиков коллекционных линий белорусской селекции отмечается тенденция к увеличе-

нию содержания сухого вещества, жира и протеина, снижению содержания влаги по сравнению с зимовавшими совместно коллекционными породами зарубежной селекции. В результате исследования изменения показателей, характеризующих биохимический состав тела, произошедших за зимний период, установлено, что отклонения биохимических показателей, особенно содержания сухого вещества и жира у пород зарубежной селекции значительно выше, чем у линий изобелинского карпа (белорусская селекция). Полученные данные свидетельствуют о большей приспособленности карпа коллекционных линий белорусской селекции к условиям зимовки в Беларуси, по сравнению с импортными породами (немецким и сарбоянским).

**Метка класса:** опровергает