

Роль библиотек в эпоху искусственного интеллекта: аналитический взгляд на новые ИИ-технологии и их применение

И.Л. Трофимов^{1,2}✉, Е.М. Кустова¹, С.М. Бараш¹, А.В. Буряк¹, В.Н. Филатова¹,

¹Федеральный исследовательский центр «Иркутский институт химии им. А.Е. Фаворского» Сибирского отделения Российской академии наук, г. Иркутск, Российская Федерация

²Государственная публичная научно-техническая библиотека Сибирского отделения Российской академии наук, г. Новосибирск, Российская Федерация

✉t_john88@mail.ru

Резюме

В статье рассматривается трансформация роли современных библиотек в условиях «цифровой неопределенности» и стремительного развития технологий искусственного интеллекта. Авторы выполнили ретроспективный обзор эволюции нейросетевых архитектур – от первых вероятностных моделей перцептрона Фрэнка Розенблatta и рекуррентных сетей, решивших проблему долгосрочной памяти, до современных трансформеров и больших языковых моделей, обосновав неизбежность текущего технологического перехода. В работе систематизированы передовые инструменты генеративного искусственного интеллекта, включая диффузионные модели визуализации (Stable Diffusion), технологии распознавания речи и понимания структуры документов с детальной оценкой перспектив их внедрения в процессы сохранения научного наследия. Особый акцент сделан на риски «информационного шума», галлюцинации нейронных сетей и размытие понятия авторства, что актуализирует новую роль библиотеки как гаранта верифицированного знания в соответствии с принципами Международной федерации библиотечных ассоциаций. Практическая значимость исследования заключается в техническом описании опыта Центральной научной библиотеки Федерального исследовательского центра Иркутского института химии им. А.Е. Фаворского Сибирского отделения Российской академии наук по разработке локальной интеллектуальной поисковой системы для эффективного поиска и анализа содержания научной литературы. Представлена архитектура на основе методологии Retrieval Augmented Generation и локальных языковых моделей, которая обеспечивает семантический поиск по оцифрованным профильным (в том числе химическим) фондам, суворенитет данных и верифицируемость ответов со ссылками на первоисточники.

Ключевые слова

искусственный интеллект, цифровая неопределенность, информационный шум, генеративные нейронные сети, интеллектуальная поисковая система, Retrieval Augmented Generation, семантический поиск, верификация, научное наследие, большие языковые модели

Для цитирования

Роль библиотек в эпоху искусственного интеллекта: аналитический взгляд на новые ИИ-технологии и их применение / И.Л. Трофимов, Е.М. Кустова, С.М. Бараш, А.В. Буряк, В.Н. Филатова // Современные технологии. Системный анализ. Моделирование. 2025. № 3 (87). С. 94–104. DOI 10.26731/1813-9108.2025.3(87).94-104.

Информация о статье

поступила в редакцию: 02.09.2025 г.; поступила после рецензирования: 10.09.2025 г.; принята к публикации: 12.09.2025 г.

Благодарность

Работа выполнена в рамках инициативной научно-исследовательской работы по теме «Использование и развитие методов и алгоритмов искусственного интеллекта для поиска и анализа научной литературы по химии».

The role of libraries in the age of artificial intelligence: an analytical look at emerging AI technologies and their applications

И.Л. Трофимов^{1,2}✉, Е.М. Кустова¹, С.М. Бараш¹, А.В. Буряк¹, В.Н. Филатова¹,

¹Federal Research Center «Irkutsk Institute of Chemistry named after A.E. Favorskii», the Siberian Branch of the Russian Academy of Sciences, Irkutsk, the Russian Federation,

²State Public Scientific and Technical Library, the Siberian Branch of the Russian Academy of Sciences, Novosibirsk, the Russian Federation

✉t_john88@mail.ru

Abstract

This comprehensive study presents a fundamental analysis of the transformation of the functional role of modern scientific libraries in the context of global «digital uncertainty» and the exponential development of generative artificial intelligence technologies. The

authors conduct a deep retrospective review of the evolution of neural network architectures – from Frank Rosenblatt's first probabilistic perceptron models and recurrent networks that solved the problem of long-term memory, to modern Transformers and Large Language Models, justifying the inevitability of the current technological transition. The study systematizes advanced generative AI tools, including diffusion visualization models (Stable Diffusion), speech recognition technologies, and document structure understanding, with a detailed assessment of the prospects for their implementation in cultural heritage preservation processes. Special emphasis is placed on the risks of «information noise», neural network hallucinations, and the blurring of the concept of authorship, which updates the library's new mission as a guarantor of verified knowledge in accordance with the International Federation of Library Associations principles. The practical significance of the research lies in the detailed technical description of the experience of the Central Scientific Library of the Irkutsk Institute of Chemistry named after A.E. Favorskii of the Siberian Branch of the Russian Academy of Sciences in developing an autonomous intelligent search system. The architecture of the solution based on the Retrieval Augmented Generation methodology, local large language models, and efficient fine-tuning methods is presented, ensuring deep semantic search across chemical collections while maintaining full data sovereignty and answer verifiability.

Keywords

artificial intelligence, digital uncertainty, information noise, generative neural networks, intelligent search engine, Retrieval Augmented Generation, semantic search, verification, scientific heritage, large language models

For citation

Trofimov I.L., Kustova E.M., Barash S.M., Buryak A.V., Filatova V.N. Rol' bibliotek v epokhu iskusstvennogo intellekta: analiticheskii vzglyad na novye II-tehnologii i ikh primenie [The role of libraries in the age of artificial intelligence: an analytical look at emerging AI technologies and their applications]. *Sovremennye tekhnologii. Sistemnyi analiz. Modelirovanie* [Modern Technologies. System Analysis. Modeling]. 2025. № 3(87). Pp. 94–104. DOI: 10.26731/1813-9108.2025.3(87).94-104.

Article Info

Received: September 2, 2025; Revised: September 10, 2025; Accepted: September 12, 2025.

Acknowledgement

The work was carried out as part of an initiative research project on the topic «The use and development of artificial intelligence methods and algorithms for the search and analysis of scientific literature on chemistry».

Введение

Современный этап развития информационного общества характеризуется экспоненциальным ростом объемов данных и, как следствие, снижением их достоверности. Наряду с целенаправленной деятельностью по формированию цензурных ограничений и дезинформации (создаваемой по различным причинам) мы наблюдаем лавинообразный рост объемов данных, сгенерированных искусственными нейронными сетями, способными создавать текст и практически неотличимые от человеческих изображения и видео. Мы вступили в эпоху «цифровой неопределенности», где границы между верифицированным научным знанием и контентом, сгенерированным автоматическими алгоритмами, становятся все более размытыми. В этом контексте библиотеки перестают быть пассивным хранилищем физических носителей информации. Они трансформируются в активный субъект цифровой среды, выполняющий функцию «якоря» достоверности – опоры проверенной информации в нарастающем потоке информационного шума.

Фундаментальная проблема, стоящая перед библиотеками, выходит за рамки простой автоматизации каталогов. Речь идет об обеспе-

чении сохранности и доступности научного наследия выдающихся ученых с использованием новых технологий искусственного интеллекта (ИИ) с учетом возможностей, ограничений и рисков их применения в библиотечной сфере.

Целью данной работы является анализ возможностей, ограничений и рисков практического применения генеративного ИИ в библиотеках, а также описание проекта создания интеллектуальной поисковой системы в Центральной научной библиотеке (ЦНБ) Федерального исследовательского центра Иркутского института химии им. А.Е. Фаворского (ИрИХ) СО РАН.

Для достижения поставленной цели в работе решаются следующие задачи:

- рассмотреть развитие ИИ-технологий от узкоспециализированных систем к мульти-модальным моделям;
- систематизировать основные классы ИИ-инструментов, применимых в библиотечной сфере;
- обосновать новую роль библиотеки как «опоры проверенной достоверной информации»;
- разработать архитектуру интеллектуальной поисковой системы и нейросетевой модели на основе Retrieval Augmented Generation

(RAG), обеспечивающей суверенитет данных и высокую релевантность поиска для сохранения научного наследия.

Структура работы включает обзор эволюции развития нейросетей, классификацию генеративных технологий (визуализация, машинное зрение, звук, код, текст), анализ проблемы достоверности информации и описание практического применения ИИ в научно-технической библиотеке.

Эволюция нейросетей

Понимание потенциала ИИ невозможно без анализа его истории и технологической эволюции. Путь от простейших математических абстракций до систем, способных проходить тест Тьюринга, занял более полувека и выдержал несколько смен парадигм.

Ранние нейронные сети (1940–1980 гг.). Эпоха ИИ началась с попыток математически формализовать работу биологического нейрона. Ключевой вехой стала работа Ф. Розенблатта, который в 1958 г. представил концепцию перцептрана – вероятностной модели для хранения и организации информации в мозге [1]. Перцепtron – простейшая однослойная сеть, способная обучаться бинарной классификации (вывод «да/нет») путем коррекции весовых коэффициентов. Но эти модели оказались непригодны для сложной работы с текстом и контекстом.

Рекуррентные сети (1980–1990 гг.). Для обработки естественного языка (NLP), который по своей сути является временнóй последовательностью, требовалась архитектура, обладающая «памятью». Это привело к появлению рекуррентных нейронных сетей (RNN), где выход нейрона подавался обратно на его вход. Однако классические RNN страдали от проблемы «затухающего градиента»: при обучении на длинных текстах сеть «забывала» начало предложения к моменту его полного прочтения [2]. Решением стала архитектура Long Short-Term Memory (LSTM), предложенная З. Хохрайтером и Ю. Шмидхубером в 1997 г. [3]. LSTM внедрила механизм «вентиляй» (gates) – входного, выходного и вентиля забывания, которые позволяли сети целенаправленно сохранять важную информацию на длительные промежутки времени и сбрасывать ненужную. Это стало фундаментом для машинного перевода и распознавания речи на следующие два десятилетия.

Трансформеры (2017). Настоящий прорыв произошел с появлением доступных вычислительных мощностей GPU и больших данных. В 2015 г. Я. Лекун, Й. Бенджио и Дж. Хинтон опубликовали в журнале «Nature» манифест «Deep Learning», закрепивший доминирование глубоких многослойных архитектур [4]. Однако революцией в обработке текстов стала статья 2017 г. «Attention Is All You Need» (А. Весвани и др.) [5], представившая архитектуру Трансформера (Transformer). Трансформеры отказались от рекуррентности в пользу механизма «внимания» (Self-Attention) [6]. Это позволило обрабатывать все слова в предложении параллельно, а не последовательно, а также учитывать глобальный контекст (модель понимает связь между словами, даже если они находятся в разных концах текста).

Большие языковые модели (2020). Масштабирование трансформеров (увеличение количества параметров и слоев) привело к появлению Больших языковых моделей (LLM), таких как GPT-3, LLaMA. Как отмечает М.М. Тихомиров, увеличение количества параметров (до сотен миллиардов) привело к появлению эмерджентных свойств: *Few-shot learning* (обучение на малых примерах) и *In-context learning* (обучение в контексте) [7]. Однако такие модели были склонны к «галлюцинациям» – генерации правдоподобного, но ложного текста. Это происходило из-за того, что модель оптимизирована на вероятностное продолжение текста, а не на проверку фактов. Для библиотек это создает существенный риск: система может выдумать несуществующую книгу, источник или приписать ученому открытие, которого он не совершил.

Мультимодальные модели с рассуждением (настоящее время). Современный этап (2022–2025 гг.) характеризуется переходом к моделям, способным к «рассуждению» (Reasoning). Метод Chain-of-Thought (цепочка мыслей) (Дж. Вэй и др.) [8] позволяет моделям не просто предсказывать следующее слово, а выстраивать пошаговую логическую цепочку решения задачи. Это критически важно для анализа научной литературы, где выводы требуют дедукции, а не простого поиска совпадений. Такие модели (например, уровня GPT-4 или Claude) способны к кросс-доменному анализу, связывая текст, изображения и формулы в единое смысловое поле (мультимодальность), од-

нако они требуют решения серьезных этических и технических вызовов, связанных с ответственностью и безопасностью генерируемых данных.

Инструментарий искусственного интеллекта для современной библиотеки

Генеративные технологии визуализации. Диффузионные модели (Stable Diffusion, Midjourney и др.) позволяют библиотекам визуализировать архивные и другие данные. Фундаментальной работой здесь является исследование Р. Ромбаха и др. (2022) «High-Resolution Image Synthesis with Latent Diffusion Models» [9], которое легло в основу *Stable Diffusion*. Авторы предложили проводить процесс диффузии (восстановления изображения из шума) не в пиксельном пространстве, а в сжатом латентном пространстве, что радикально снизило требования к вычислительным ресурсам.

Для библиотек особенно важна точность реконструкции изображений, архивных фото и др. Для этого применяется *технология*

ControlNet (Л. Жанг и др.) (2023) [10]. *ControlNet* решает проблему хаотичности генерации, «замораживая» веса основной модели и добавляя обучаемую копию слоев для управления структурой. Это позволяет интегрировать пространственные управляющие элементы:

1. MLSD (Mobile Line Segment Detection).

Идеален для распознавания линий и архитектурных форм. В библиотеке может применяться для создания моделей библиотечных пространств («библиотеки будущего») и т.д.

2. Depth, Canny и др.

Используются для точного сохранения композиции при обработке изображений. Также их можно применять для «маскирования» частей изображения, например, когда нужно передать строго определенную форму, не трогая все остальное.

Не менее важна *технология LoRA (Low-Rank Adaptation)* (Э.Дж. Хью и др.) (2021) [11]. Она позволяет адаптировать (дообучать) огромные модели под специфические задачи, используя «дополнительные» слои. Изменение «весов» LoRA влияет на силу ее воздействия на



Рис. 1. Реставрация архивных фотографий ученого при оформлении выставок
Fig. 1. Restoration of archival photo of the scientist for exhibition design

основную модель. Пример использования LoRA на стиле газетных вырезок («newspaper collage style») позволяет генерировать изображения, стилизованные под прессу прошлых веков, что актуально для оформления выставок или цифровых проектов библиотеки.

Практическое применение в библиотеках:

1. Восстановление фото. Использование инструментов типа Remini (app.remini.ai) для улучшения качества старых снимков ученых или событий (рис. 1).

2. 3D-визуализация. Применение инструментов на подобии TripoSG или Krea.ai для создания трехмерных моделей на основе отсканированных изображений из книг и статей.

3. Генерация иллюстраций. Создание схем, фонов и визуальных материалов для выставок или презентаций.

Генерация видеоконтента. Переход от статических изображений к динамическим последовательностям (видео) в современных моделях сопровождается решением проблемы темпоральной согласованности (консистентности) кадров. Современные модели (Sora, Runway, PiKa, Luma, Kling, Veo, Wan) способны не только генерировать качественное видео, но и синхронизировать движение губ с речью (lipsync).

В контексте библиотеки это позволяет:

- создавать «ожившие» портреты исторических деятелей и ученых, например для образовательных целей;
- формировать виртуальные туры по архивам и фондам;
- визуализировать сложные исследовательские процессы, описанные в научной литературе.

Машинное зрение. Модели компьютерного зрения (CV) или визуальные модели (ViT, Florence, YOLO) интегрируют текст и изображение. Это открывает путь к автоматической каталогизации книг по отсканированным карточкам или фото обложек, OCR (распознавание текста) для рукописных архивных документов, а в перспективе – для распознавания химических структурных формул и схем реакций непосредственно со страниц старых изданий.

Генерация звука и речи. Современные системы «текст-в-речь» (Text-to-Speech, TTS) (ElevenLabs, Whisper, AudioLM) достигли уровня синтеза естественной речи с сохранением интонаций. Для работы с аудиоархивами (лекции, устные повествования) стандартом

стала модель Whisper от OpenAI (А. Рэдфорд и др.) (2022) [12]. Однако, несмотря на существующие сложности с синтезом речи на русском языке, для некоторых моделей прогресс очевиден. Это открывает путь к автоматическому созданию аудиокниг и аудиогидов по документам из фондов библиотеки, делая фонды доступными, например для слабовидящих.

Генерация кода и программные агенты.

Инструменты вроде MS Copilot, Claude Code, Gemini, DeepSeek Coder позволяют сотрудникам библиотеки, даже не обладая глубокими навыками программирования, создавать программные сервисы для решения широкого круга задач: от скриптов автоматизации до веб-интерфейсов поисковых систем.

Языковые модели – генерация текста.

Ключевой ИИ-технологией для научных библиотек является создание интеллектуальных систем, понимающих смысл текста, а не просто наличие ключевых слов. Для этого используются технологии векторных представлений и трансформеров. Как указывалось ранее, трансформеры полагаются на механизм внимания, чтобы понимать контекст, они оценивают, насколько важны отдельные слова в последовательности по отношению друг к другу.

Для поиска используются векторные представления (эмбеддинги) – многомерные списки чисел, описывающие параметры модели. Векторное представление запроса сравнивается с векторами в базе данных (БД) для нахождения ближайших соседей (ближайших по смыслу понятий). Этот принцип позволяет находить документы, близкие по смыслу, даже если в них не используются идентичные слова. Обычно для этого применяется косинусное сходство или евклидово расстояние (1):

$$d_{pq} = \sqrt{(p_1 - q_1)^2 + \dots + (p_n - q_n)^2}, \quad (1)$$

где d_{pq} – евклидово расстояние между двумя векторами (понятиями); p_i ($i \in 1 \dots n$) – вектор первого условного понятия (слова, токена) среди множества i -понятий; q_i – вектор второго условного понятия (слова, токена).

Эволюция «мышления» моделей: от текстовых шаблонов к рассуждению. С 2023–2024 гг. мы наблюдаем переход к мультимодальным моделям с элементами рассуждения (GPT-4.5, Claude 3.5, Ernie-X1). Эти системы способны к кросс-доменному обучению. Они одновременно обрабатывают текст, изображения, видео и про-

граммный код, находя общие смыслы в разных модальностях. Технология рассуждения (Reasoning) позволяет модели не просто выдавать ответ, а выстраивать логическую цепочку:

– Chain-of-Thought (цепочка мыслей) – пошаговое рассуждение, имитирующее человеческую логику;

– Tree-of-Thought (дерево мыслей) – анализ нескольких возможных вариантов решения задачи перед формулированием ответа;

– верификация – способность к самопроверке и коррекции собственных выводов («что, если моя посылка неверна?»).

Такие модели способны к абстрактному мышлению и пониманию нюансов, что делает их идеальными помощниками для сложного информационного поиска в научных библиотеках. Они могут проанализировать изображение, график, схему, химическую формулу в книге или научной статье, сопоставить их с текстом и сделать вывод, недоступный простым текстовым анализаторам.

Проблема «информационного шума» и роль библиотек

Внедрение ИИ приносит не только новые возможности, но и системные риски, связанные с качеством информационной среды. Нарастание объема контента, сгенерированного алгоритмами ИИ, создает «информационный шум». Этот процесс имеет несколько опасных характеристик.

1. Галлюцинации и искажение фактов: нейросети, будучи вероятностными моделями, могут генерировать тексты, которые выглядят научно и убедительно, но содержат грубые фактические ошибки. В библиотечном контексте это особенно опасно, так как искажается научное знание.

2. Рекурсивное загрязнение данных. Одной из самых серьезных угроз является обучение новых моделей ИИ на данных, сгенерированных предыдущими версиями ИИ. Это приводит к эффекту деградации моделей. Если ИИ учится на «синтетике», теряется вариативность, накапливаются ошибки, исчезают редкие и уникальные знания. Возникает замкнутый круг производства информационного мусора.

3. Уязвимость к «фейкам». Возможность генерации поддельных документов, несуществующих цитат и даже целых лженаучных статей подрывает доверие к печатному делу.

В работах А.И. Земского эта проблема рассматривается через призму этики научных публикаций [13]. Он отмечает, что ChatGPT создает материалы, «юридически близкие к энциклопедическим статьям», но не имеющие автора, что размывает ответственность за их достоверность. А.И. Земсков указывает на риски нарушения издательской этики и на необходимость предупреждения пользователей о природе контента.

Массовое распространение ИИ-ассистентов несет в себе и образовательные риски. Чрезмерная надежда на ИИ-помощников может привести к «упрощению мышления» подрастающего поколения. Если студент получает готовый ответ от чат-бота, он теряет навык самостоятельного поиска, сопоставления источников и критического анализа. Возникает риск потери навыков самостоятельного исследования – фундаментального элемента научного познания.

«Цифровая неопределенность» – это состояние среды, в которой пользователь не может априори доверять ни тексту, ни изображению, ни видео на экране своего устройства.

В эпоху цифровой неопределенности библиотека обретает *новую роль*: она становится опорой проверенной достоверной информации. Согласно заявлению Международной федерации библиотечных ассоциаций (IFLA) о библиотеках и искусственном интеллекте (2020) [14], эта роль реализуется через несколько механизмов.

1. Хранение эталона. Физические фонды библиотек и их верифицированные цифровые копии становятся «золотым стандартом». В отличие от интернета, где текст может быть незаметно отредактирован, печатная книга в хранилище остается неизменной. Она служит точкой отсчета для проверки любой информации.

2. Экспертная верификация. Специалисты библиотек, имеющие доступ непосредственно к бумажным первоисточникам, выступают в роли квалифицированных экспертов-библиографов, способных отличить галлюцинацию нейросети от фактов.

3. Книга как инвестиция в истину. В мире информационного шума доступ к чистым, проверенным данным становится экономической ценностью. Фраза «кто владеет информацией – владеет миром» может быть дополнена: «кто владеет достоверной информацией...».

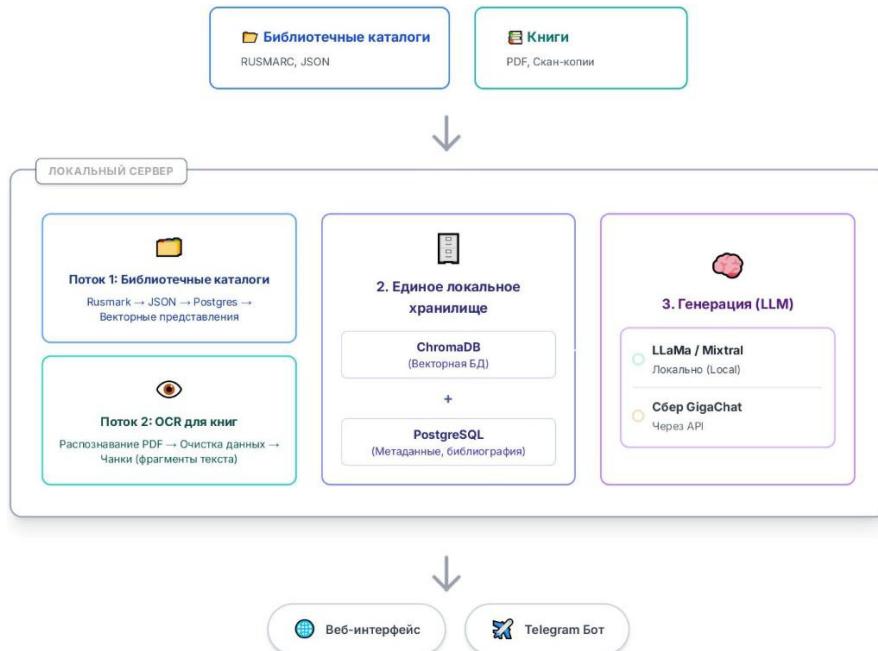


Рис. 2. Архитектура интеллектуальной поисковой системы
Fig. 2. Architecture of an intelligent search system

Я.Л. Шрайберг в своем докладе неоднократно подчеркивал, что библиотека должна стать активным участником цифрового рынка, но не как генератор шума, а как провайдер качественного знания [15]. В условиях, когда «поведенческие модели библиотек» меняются, именно функция гаранта качества становится конкурентным преимуществом.

Проект интеллектуальной поисковой системы и его архитектура

Для решения описанных проблем в ЦНБ ИрИХ СО РАН инициирована научно-исследовательская работа по созданию интеллектуальной поисковой системы для эффективного поиска и анализа содержания научной литературы.

В основе проекта лежит принципиальный отказ от использования зарубежных облачных сервисов (таких как OpenAI, Google и др.) для обработки внутренних данных. Проект реализует автономную систему интеллектуального поиска, где данные обрабатываются на серверах организации. Архитектура проекта (рис. 2) построена на методологии RAG, впервые систематизированной П. Льюисом и др. (2020) [16].

RAG решает проблему галлюцинаций, разделяя знания на два компонента:

– параметрическая память – знания, заложенные в веса модели при обучении (умение

строить фразы, понимать язык);

– непараметрическая память – внешний индекс верифицированных документов (фонды библиотеки).

При генерации ответа модель не «выдумывает» факты из своей памяти, а использует найденные в индексе фрагменты как контекст.

Технический процесс

1. *Обработка данных (два потока Extract-Transfer-Load – ETL)*. Система реализует два параллельных конвейера подготовки данных.

1.1. Библиографический поиск (каталоги): загруженные библиографические записи, экспортированные из Ирбис64 (формат RUSMARC) конвертируются в структурированный JSON-формат. Эти метаданные индексируются и сохраняются в реляционной базе (PostgreSQL) для реализации точного (строго) поиска по библиографическим полям (индексы ББК, УДК, автор, заглавие и т.д.), и параллельно «векторизуются» для реализации смыслового поиска по аннотациям и заголовкам.

1.2. Анализ полнотекстовых коллекций документов: электронные копии книг, статей, журналов (в формате PDF) проходят через модуль OCR (оптическое распознавание символов). Система извлекает полный текст, очищает его от «артефактов» сканирования и разбивает на смысловые фрагменты (чанки) для глубокого

анализа. В перспективе будут разработаны расширенные функции модуля OCR для распознавания химических формул и реакций.

2. Векторизация и хранение. Фрагменты текста преобразуются в цифровые векторы (Embeddings) с помощью энкодеров (например, e5-multilingual). Эти векторы сохраняются в локальной векторной БД (ChromaDB), что позволяет искать информацию не по ключевым словам, а по смыслу.

Для адаптации модели к специфическому языку химии используется *технология LoRA (Low-Rank Adaptation)*. Это универсальный математический метод, который, как было показано ранее, в контексте визуализации позволяет эффективно настраивать нейросеть без полного переобучения. В данном случае технология применяется не к диффузионным слоям, а к слоям внимания (Attention) текстового трансформера. Вместо изменения миллиардов параметров большой языковой модели, мы обучаем лишь небольшие матрицы адаптации (A и B), внедряемые в архитектуру: $W' = W + \Delta W = W + BA$. Это позволяет модели понимать специфическую терминологию (например, «реакция Фаворского»), сохраняя при этом общие речевые навыки, заложенные в базовой модели.

3. Семантический поиск (+RAG). Когда пользователь задает вопрос, система находит в векторной БД наиболее релевантные записи либо (если пользователь выбирает строгий поиск по библиографическим полям) ищет определенные записи в реляционной базе (PostgreSQL).

4. Генерация ответа. Найденный контекст передается в большую языковую модель (LLM). На данном этапе также используется гибридный подход:

- приоритет отдается локальным Open-Source моделям, таким как LLaMa (модель представлена Х. Тоувроном и др. в 2023 г. и является мощной открытой моделью, допускающей коммерческое использование и локальный запуск на сервере организации) [17];

- альтернатива – API российских сервисов (Сбер GigaChat), куда отправляются только обезличенные фрагменты текста.

5. Вывод ответа пользователю. Сгенерированный ответ выводится пользователю либо в веб-интерфейсе на сайте библиотеки, либо в телеграмм-боте библиотеки.

Такой подход гарантирует, что научные данные не передаются третьим лицам (и зару-

бежным сервисам), а ответы системы всегда обоснованы реальными верифицированными источниками.

Предложенная архитектура обеспечивает:

- отсутствие галлюцинаций (модель не выдумывает факты, а «достает» их из достоверных источников);
- безопасность (научные данные никуда не передаются и не зависят от интернета);
- надежность (система может предоставить ссылку на конкретную страницу источника).

Пример работы системы. В фондах ЦНБ хранятся уникальные труды сибирских ученых. Однако доступ к их содержанию (особенно это касается старых монографий 1950-х гг.) затруднен. Традиционные каталоги (например, в Ирбис64) не позволяют сделать запрос на естественном языке. Например, на вопрос «Каковы условия реакции синтеза виниловых эфиров?» система выдаст ответ, сформированный из монографии А.Е. Фаворского с обозначением страницы и условий реакции, а также с указанием первоисточника и его библиографических данных.

Правовые и социокультурные аспекты

Одной из главных гуманитарных задач проекта является обеспечение сохранности и популяризации научного наследия, которое зачастую существует только в бумажном виде или в виде сканов. Интеллектуальная обработка позволяет «оживить» труды ученых, сделав их доступными для современного читателя в формате естественного диалога. Это соответствует переходу библиотек на цифровую трансформацию, который отмечают в своих работах Я.Л. Шрайберг и Ю.В. Волкова, указывая на необходимость интеграции библиотек в цифровую экосистему науки.

Внедрение подобных ИИ-систем требует учета правового поля. Я.Л. Шрайберг в работе «Авторское право в отношении произведений, созданных с помощью инструментов генеративного искусственного интеллекта» (2025) [15] поднимает следующие вопросы:

- генеративный ИИ создает парадокс: произведение есть, а автора (человека) нет;
- традиционное право охраняет только результаты человеческого творчества;
- кому принадлежат права на сгенерированный текст или изображение?

А.И. Земсков развивает тему этики, фокусируясь на проблеме «открытого доступа» и ка-

честве научного контента [13]. Он предупреждает, что если библиотеки начнут массово внедрять ИИ, они рискуют размыть понятие авторства. Материалы, созданные ChatGPT, могут быть высокого качества, но они лишены субъектности.

В предлагаемом в настоящей работе проекте указанные проблемы решаются применением и использованием ИИ не как «автора», а как «интеллектуального интерфейса» к трудам реальных ученых, права на которые защищены.

При исследовании феномена «цифрового чтения» и книжной культуры [18] отмечается, что мы имеем дело с новым типом читателя. Медиасреда формирует «клиповое мышление», привычку к быстрому потреблению контента. В этой среде ИИ-инструменты (саммаризация, ответы на вопросы) могут сыграть двоякую роль: с одной стороны, они потакают лени, позволяя не читать книгу целиком, с другой – в условиях информационной перегрузки они служат навигаторами.

И.В. Лизунова подчеркивает важность «медиалогического подхода»: книга трансформируется, но не умирает. Она становится частью мультимедийного пространства. Библиотека должна использовать ИИ, чтобы вернуть читателя к глубокому чтению, используя технологии как «тизеры», пробуждающие интерес к полному тексту.

Представленный проект интеллектуальной поисковой системы учитывает этот аспект, предлагая пользователю (особенно молодежи) привычный формат взаимодействия (чат-бот), который служит «точкой входа» к глубокому чтению полных текстов.

Заключение

Синтезируя технологические возможности и этические риски, мы формулируем ключевой принцип работы библиотеки с ИИ, который можно назвать «Правилом библиотекаря»: ИИ нужно применять как инструмент усиления, а не замены интеллектуальной деятельности, при этом любой контент, сгенерированный ИИ, должен иметь маркировку и сопровождаться ссылками на верифицированные первоисточники. Это правило защищает общество от информационного шума. Библиотека остается последним рубежом обороны истины, используя мощь нейросетей для поиска, но оставляя за человеком право на окончательное суждение и ответственность.

В ходе проведенного исследования были

успешно реализованы все поставленные цели и задачи, направленные на трансформацию библиотеки в активный центр верифицированного знания в эпоху ИИ. Основные результаты работы заключаются в следующем:

1. Теоретическое обоснование и систематизация. Проведен комплексный аналитический обзор эволюции нейросетевых архитектур и инструментов генеративного ИИ. Это позволило обосновать переход от классических систем поиска к мультимодальным моделям и подтвердить необходимость внедрения «Правила библиотекаря», где ИИ выступает инструментом усиления, а не замены человеческой деятельности.

2. Разработка архитектуры. Спроектирована и теоретически обоснована оригинальная архитектура Dual-Stream Retrieval (двуихпоточный поиск), обеспечивающая параллельную обработку текстово-библиографической информации и структурных данных, что позволяет эффективно интегрировать традиционные библиотечные каталоги с современными нейросетевыми методами анализа.

3. Создание инфраструктурного фундамента. Для обеспечения суверенитета данных и автономности системы был развернут локальный аппаратно-программный комплекс на базе графического процессора NVIDIA RTX 3090Ti. Это позволило отказаться от использования зарубежных облачных сервисов, гарантируя безопасность и конфиденциальность научных фондов.

4. Реализация конвейера обработки данных. Разработана методология ETL-конвейера (извлечение, преобразование, загрузка), включающая процедуры очистки текстов и сегментации страниц с использованием моделей компьютерного зрения. Сформирован и размечен пилотный корпус оцифрованных документов, прошедших первичную OCR-обработку.

5. Экспериментальная проверка. Проведено тестирование базовых открытых языковых моделей (LLaMA-3, Mistral) в режиме Zero-shot evaluation в связке с технологией RAG. Результаты подтвердили возможность точного извлечения фактографической информации из текстов при наличии верифицированного контекста из фондов библиотеки, что минимизирует риск «галлюцинаций» нейросети.

Библиотека будущего – это не фантастический «Skynet», приводящий к катастрофе, а скорее «машина времени», позволяющая вести диалог с великими умами прошлого.

Создание интеллектуальной системы в ЦНБ ИрИХ СО РАН для эффективного поиска и анализа содержания научной литературы – это шаг к тому, чтобы библиотека стала активным интеллектуальным центром. Объединяя классические формы хранения знаний и современные технологии RAG, мы создаем барьер для информационного шума и обеспечиваем суворенитет и доступность отечественного научного знания.

Представленная в работе архитектура нейросетевой модели является фундаментом

для следующего этапа исследований. В дальнейшем планируется ее «дообучение» на специализированном корпусе данных по химии (Scientific Knowledge Injection). Это позволит перейти от общего семантического поиска к мультимодальному анализу химических структур и синтезу ответов с учетом сложной предметной терминологии, что полностью соответствует задачам сохранения научного наследия в области естественных наук.

Список литературы

1. Rosenblatt F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain // Psychological Review. 1958. Vol. 65. Iss. 6. P. 386–408.
2. Николенко С., Кадурин А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. СПб. : Питер, 2018. 480 с.
3. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation. 1997. Vol. 9. Iss. 8. P. 1735–1780.
4. LeCun Y., Bengio Y., Hinton G. Deep Learning // Nature. 2015. Vol. 521. Iss. 7553. P. 436–444. DOI 10.1038/nature14539.
5. Attention Is All You Need / A. Vaswani, N. Shazeer, N. Parmar et al. // 31st Conference on Neural Information Processing Systems (NIPS 2017). Long Beach, 2017. DOI 10.48550/ARXIV.1706.03762.
6. Transformer – новая архитектура нейросетей для работы с последовательностями // Habr : сайт. URL : <https://habr.com/ru/articles/341240/> (дата обращения: 05.08.2025).
7. Тихомиров М.М. Большие языковые модели // ИСП РАН : сайт. URL : <https://tpc.ispras.ru/wp-content/uploads/2023/12/lecture14-2023.pdf> (дата обращения: 05.08.2025).
8. Chain of Thought Prompting Elicits Reasoning in Large Language Models / J. Wei, X. Wang, D. Schuurmans et al. // 36th Conference on Neural Information Processing Systems (NeurIPS 2022). Long Beach, 2022. DOI arxiv.org/pdf/2201.11903v1.
9. High-Resolution Image Synthesis with Latent Diffusion Models / R. Rombach, A. Blattmann, D. Lorenz et al. // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, 2022. P. 10674–10685. DOI 10.1109/CVPR52688.2022.01042.
10. Zhang L., Rao A., Agrawala M. Adding Conditional Control to Text-to-Image Diffusion Models // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Paris, 2023. P. 3836–3847. DOI 10.1109/ICCV51070.2023.00355.
11. LoRA: Low-Rank Adaptation of Large Language Models / E.J. Hu, Y. Shen, P. Wallis et al. // International Conference on Learning Representations (ICLR). 2022. DOI arxiv.org/abs/2106.09685.
12. Robust Speech Recognition via Large-Scale Weak Supervision / A. Radford, J.W. Kim, T. Xu et al. // Proceedings of the 40th International Conference on Machine Learning (ICML). Honolulu, 2023. URL : <https://cdn.openai.com/papers/whisper.pdf> (дата обращения: 04.08.2025).
13. Земсков А.И., Телицына А.Ю. Демонстрация возможностей чата GPT в библиотечной деятельности // Научные и технические библиотеки. 2024. № 4. С. 131–145.
14. IFLA Statement on Libraries and Artificial Intelligence // IFLA : сайт. URL : <https://repository.ifla.org/items/8c05d706-498b-42c2-a93a-3d47f69f7646> (дата обращения: 05.08.2025).
15. Шрайберг Я.Л., Волкова К.Ю. Вопросы авторского права в отношении произведений, созданных при помощи генеративного искусственного интеллекта // Научные и технические библиотеки. 2025. № 2. С. 115–130.
16. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks / P. Lewis, E. Perez, A. Piktus et al. // 34th Conference on neural information processing systems NeurIPS. 2020. URL : <https://arxiv.org/pdf/2005.11401v1> (дата обращения: 05.08.2025).
17. Llama 2: Open Foundation and Fine-Tuned Chat Models / H. Touvron, L. Martin, K. Stone et al. DOI 10.48550/arXiv.2307.09288.
18. Йылмаз Б. Культура чтения в цифровом мире // Книга. Чтение. Медиасреда. 2024. Т. 2. № 1. С. 17–26.

References

1. Rosenblatt F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain // Psychological Review, 1958, Vol. 65, iss. 6, pp. 386–408.
2. Nikolenko S., Kadurin A., Arhangel'skaya E. Glubokoe obuchenie. Pogruzhenie v mir neironnykh setei [Deep learning. Diving into the world of neural networks]. Saint Petersburg: Piter Publ., 2018, 480 p.
3. Hochreiter S., Schmidhuber J. Long Short-Term Memory // Neural Computation, 1997, Vol. 9, iss. 8, pp. 1735–1780.
4. LeCun Y., Bengio Y., Hinton G. Deep Learning // Nature, 2015, Vol. 521, pp. 436–444. DOI: 10.1038/nature14539.
5. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser L., Polosukhin I. Attention Is All You Need // // 31st Conference on Neural Information Processing Systems (NIPS 2017). Long Beach, 2017. DOI 10.48550/ARXIV.1706.03762.
6. Transformer – novaya arkhitektura neirosetei dlya raboty s posledovatelnostyami (Elektronnyi resurs) [Transformer – a new architecture of neural networks for working with sequences (Electronic resource)]. Available at: <https://habr.com/ru/articles/341240/> (Accessed August 5, 2025).

7. Tikhomirov M.M. Bol'shie yazykovye modeli (Elektronnyi resurs) [Large language models (Electronic resource)]. Available at: <https://tpc.ispras.ru/wp-content/uploads/2023/12/lecture14-2023.pdf> (Accessed August 5, 2025).
8. Wei J., Wang X., Schuurmans D., Bosma M., Ichter B., Xia F., Chi E.H., Le Q.V., Zhou D. Chain of Thought Prompting Elicits Reasoning in Large Language Model // 36th Conference on Neural Information Processing Systems (NeurIPS 2022). Long Beach, 2022. DOI arxiv.org/pdf/2201.11903v1.pdf.
9. Rombach R., Blattmann A., Lorenz D., Esser P., Ommer B. High-Resolution Image Synthesis with Latent Diffusion Models // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, 2022, pp. 10674–10685. DOI [10.1109/CVPR52688.2022.01042](https://doi.org/10.1109/CVPR52688.2022.01042).
10. Zhang L., Rao A., Agrawala M. Adding Conditional Control to Text-to-Image Diffusion Models // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Paris, 2023, pp. 3836–3847. DOI [10.1109/ICCV51070.2023.000355](https://doi.org/10.1109/ICCV51070.2023.000355).
11. Hu E.J., Shen Y., Wallis Ph., Allen-Zhu Z., Li Yu., Wang Sh., Wang L., Chen W. LoRA: Low-Rank Adaptation of Large Language Models // International Conference on Learning Representations (ICLR). 2022. DOI arxiv.org/abs/2106.09685.
12. Radford A., Kim J.W., Xu T., Brockman G., McLeavey Ch., Sutskever I. Robust Speech Recognition via Large-Scale Weak Supervision // Proceedings of the 40th International Conference on Machine Learning (ICML). Honolulu, 2023. Available at: <https://cdn.openai.com/papers/whisper.pdf> (August 4, 2025).
13. Zemskov A.I., Telitsyna A.Yu. Demonstratsiya vozmozhnosti chata GPT v bibliotekhnoi deyatel'nosti [Demonstration of GPT chat capabilities in library activities]. *Nauchnye i tekhnicheskie biblioteki* [Scientific and Technical Libraries], 2024, no 4, pp. 131–145.
14. IFLA Statement on Libraries and Artificial Intelligence. Available at: <https://repository.ifla.org/items/8c05d706-498b-42c2-a93a-3d47f69f7646> (Accessed August 5, 2025).
15. Shraiberg Ya.L., Volkova K.Yu. Voprosy avtorskogo prava v otnoshenii proizvedenii, sozdannykh pri pomoshchi generativnogo iskusstvennogo intellekta [Copyright issues in relation to works created with the help of generative artificial intelligence]. *Nauchnye i tekhnicheskie biblioteki* [Scientific and Technical Libraries], 2025, no 2, pp. 115–130.
16. Lewis P., Perez E., Piktus A., Petroni F., Karpukhin V., Goyal N., Kuttler H., Lewis M., Yih W.-t., Rocktaschel T., Riedel S., Kiela D. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks // // 34th Conference on neural information processing systems NeurIPS. 2020. Available at: <https://arxiv.org/pdf/2005.11401v1.pdf> (Accessed August 5, 2025).
17. Touvron H., Martin L., Stone K., Albert P., Almahairi A., Babaei Y., Bashlykov N., Batra S., Bhargava P., Bhosale S., Bikel D., Blecher L., Canton Ferrer C., Chen M., Cucurull G., Esiobu D., Fernandes J., Fu J., Fu W., Fuller B., Gao C., Goswami V., Goyal N., Hartshorn A., Hosseini S., Hou R., Inan H., Kardas M., Kerkez V., Khabsa M., Kloumann I., Korenev A., Koura P.S., Lachaux M.-A., Lavril T., Lee J., Liskovich D., Lu Y., Mao Y., Martinet X., Mikhaylov T., Mishra P., Molybog I., Nie Y., Poultan A., Reizenstein J., Rungra R., Saladi K., Schelten A., Silva R., Smith E.M., Subramanian R., Tan X.E., Tang B., Taylor R., Williams A., Xiang J., Xu K.P., Yan Z., Zarov I., Zhang Y., Fan A., Kambadur M., Narang S., Rodriguez A., Stojnic R., Edunov S., Scialom T. Llama 2: Open Foundation and Fine-Tuned Chat Models. DOI [10.48550/arXiv.2307.09288](https://arxiv.org/abs/2307.09288).
18. Yilmaz B. Kul'tura chteniya v tsifrovom mire [Reading Culture in the Digital World]. *Kniga. Chtenie. Mediasreda* [Book. Reading. Media], 2024, Vol. 2, no 1, pp. 17–26.

Информация об авторах

Трофимов Иван Леонидович, младший научный сотрудник, заведующий Центральной научной библиотеки, Федеральный исследовательский центр «Иркутский институт химии им. А.Е. Фаворского» СО РАН, г. Иркутск; e-mail: t_john88@mail.ru.

Кустова Елена Михайловна, младший научный сотрудник, старший библиограф Центральной научной библиотеки, Федеральный исследовательский центр «Иркутский институт химии им. А.Е. Фаворского» СО РАН, г. Иркутск; e-mail: kustovahelen@mail.ru.

Бараш Светлана Михайловна, младший научный сотрудник, старший библиограф Центральной научной библиотеки, Федеральный исследовательский центр «Иркутский институт химии им. А.Е. Фаворского» СО РАН, г. Иркутск; e-mail: svbarash@crust.irk.ru.

Буряк Алена Владимировна, младший научный сотрудник, инженер Центральной научной библиотеки, Федеральный исследовательский центр «Иркутский институт химии им. А.Е. Фаворского» СО РАН, г. Иркутск; e-mail: snejinka-88@inbox.ru.

Филатова Вера Николаевна, младший научный сотрудник, программист Центральной научной библиотеки, Федеральный исследовательский центр «Иркутский институт химии им. А.Е. Фаворского» СО РАН, г. Иркутск; e-mail: verafil@yandex.ru.

Information about the authors

Ivan L. Trofimov, Junior Researcher, Head of the Central Scientific Library, Federal Research Center «Irkutsk Institute of Chemistry named after A.E. Favorskii» of the SB RAS, Irkutsk; e-mail: t_john88@mail.ru.

Elena M. Kustova, Junior Researcher, Senior Bibliographer of the Central Scientific Library, Federal Research Center «Irkutsk Institute of Chemistry named after A.E. Favorskii» of the SB RAS, Irkutsk; e-mail: kustovahelen@mail.ru.

Svetlana M. Barash, Junior Researcher, Senior Bibliographer of the Central Scientific Library, Federal Research Center «Irkutsk Institute of Chemistry named after A.E. Favorskii» of the SB RAS, Irkutsk; e-mail: svbarash@crust.irk.ru.

Alena V. Buryak, Junior Researcher, Engineer of the Central Scientific Library, Federal Research Center «Irkutsk Institute of Chemistry named after A.E. Favorskii» of the SB RAS, Irkutsk; e-mail: snejinka-88@inbox.ru.

Vera N. Filatova, Junior Researcher, Programmer of the Central Scientific Library, Federal Research Center «Irkutsk Institute of Chemistry named after A.E. Favorskii» of the SB RAS, Irkutsk; e-mail: verafil@yandex.ru.