

ГЕНЕРАТИВНИ МОДЕЛИ И ИНТЕЛИГЕНТНИ СИСТЕМИ В ЛИТЕРАТУРНИЯ ОБЗОР: ПРЕДИЗВИКАТЕЛСТВА И ВЪЗМОЖНОСТИ

Евгения Николова, Георги Джуфов, Тодор Славов
Бургаски свободен университет

GENERATIVE MODELS AND INTELLIGENT SYSTEMS IN THE LITERATURE REVIEW: CHALLENGES AND OPPORTUNITIES

Evgeniya Nikolova, Georgi Djufov, Todor Slavov
Burgas Free University

Abstract: *This article reviews methodological approaches for systematic analysis of scientific literature and evaluates contemporary AI platforms for their use in systematic reviews. It summarizes AI tools' functions, advantages, and limitations, and provides practical guidance for academic application. The focus is on AI support for searching, evaluating, and organizing publications, while complementing rather than replacing human critical judgment.*

Key words: *Generative Models, Artificial Intelligence (AI), AI-assisted Review, Automated Literature Review*

1. Увод

Литературният обзор остава основен инструмент в академичната практика, тъй като предоставя не само преглед на наличните източници, но и концептуална рамка за бъдещи изследвания. С навлизането на изкуствения интелект (ИИ) и особено на генеративните езикови модели (ГЕМ), този процес претърпява съществени промени. Новите технологии автоматизират ключови етапи от работата на изследователя – от търсенето и класифицирането на публикации, през обобщаването на резултати, до формулирането на аналитични синтези. Това създава както значителни възможности за по-ефективна научна дейност, така и редица предизвикателства, свързани с надеждността, интерпретацията и етиката на използваните инструменти.

Особено значим е приносът на генеративните модели и инструментите за обработка на естествен език (NLP), които не само автоматизират рутинни дейности като търсене, класифициране и обобщаване на публикации, но и отварят възможности за нов тип анализ. Чрез техники като тематично моделиране, извличане на семантични връзки и визуализация на концептуални мрежи, тези технологии разширяват обхвата на литературния обзор отвъд традиционните методи и позволяват интегриране на големи обеми данни в аналитичния процес.

Настоящата статия цели да проследи развитието на методологичните подходи за систематичен анализ на научната литература, да анализира съвременните платформи за изкуствен интелект и да оцени тяхната приложимост в провеждането на систематични прегледи и анализа на научни източници. Представя се систематичен преглед на съвременните ИИ-инструменти, техните функции, предимства и ограничения.

Освен това се очертават практически насоки за критично и ефективно приложение в академичната практика. Изследването се фокусира върху три ключови въпроса: кои приложения на ИИ подпомагат търсенето, оценката и систематизацията на публикации; доколко надеждни са автоматизираните подходи и какви са техните граници при интерпретация на текстове; и как ИИ може да допълва традиционния човешки анализ, без да замества критическата преценка. По този начин се подчертава ролята на изследователя като активен посредник между алгоритмите и анализа.

2. Методология на изследването

2.1 Методологичен подход

Настоящото изследване прилага систематичен преглед на литературата със смесени методи, в съответствие със стандарта за доклади PRISMA 2020 (PRISMA 2020). Това е международен стандарт за докладване на систематични обзори и мета-анализи, който осигурява прозрачност, възпроизводимост и методологична надеждност на процеса. В актуализираната версия са включени 27 елемента, структурирани по основните части на един обзор: заглавие и резюме, въведение, методология, резултати, обсъждане и допълнителна информация. Особено внимание се отделя на:

- подробното документиране на търсещите стратегии, включително бази данни, филтри и използвани автоматизирани инструменти;
- прецизното описание на процеса на скрининг и селекция, което е от пряко значение при обзори, подпомагани от ИИ;
- синтез на доказателствата с ясно отчитане на несигурността и ограничеността на данните;
- блок-схеми на потока, които визуализират целия процес на идентифициране, изключване и включване на източниците;
- прозрачност относно протоколите, данните и използвания код, което улеснява одита и повторемостта на анализа.

За обзори, в които се прилагат алгоритми и езикови модели, PRISMA 2020 има ключово значение, защото изисква регистрация на всички автоматизирани стъпки и съвместимост с принципите на PRISMA reporting [25]. По този начин се гарантира, че дори когато ИИ се използва за ускоряване на търсенето, скрининга или обобщаването, крайният резултат остава методологично обоснован, прозрачен и подлежащ на независима проверка. Този подход изисква формулиране на ясни цели, предварително регистриран протокол и прозрачна блок-схема при подбора на източници.

За да се адаптира методологията към специфичните изисквания на разглежданата област, е възприето ръководството на Кичънъм и Чартърс [16], което включва три основни фази:

- **Планиране:** регистрация на протокола; въпроси, съобразени с PICOC (Population Intervention Comparison Outcome Context); критерии за допустимост; покритие (обхват) на базата данни и низове за търсене; критерии за оценка на качеството; формуляри за извличане; и план за синтез.
- **Провеждане:** двоен скрининг (проверка) с консенсусно решение; оценка на качеството с помощта на стандартизирани елементи; контролирано извличане; и одитна следа на всички решения.
- **Докладване (отчитане):** описание на методите, в съответствие с PRISMA (включва цели низове за търсене), блок-схема (диаграма) на потока и разкриване на отклоненията.

Тази рамка първоначално е разработена за систематични прегледи в софтуерното инженерство. Тази адаптация запазва прецизността, като същевременно осигурява откриване и скрининг, с помощта на ИИ.

Параметрите „човек в цикъла“ (англ. human-in-the-loop) са фиксирани предварително, за да урегулират интеграцията на ИИ: (а) определение на протокола, изследователските въпроси и критериите за допустимост; (б) двойна независима проверка на заглавията/резюмета за стратифицирано подмножество (с 10% златен стандарт) за калибриране на класирането на ИИ; (в) консенсус при несъгласие между човека и ИИ, с ескалация до трети рецензент, ако не бъде постигнато решение; (г) минимално приемлива производителност (ефективност) на извличането, настроена на $\geq 0,85$ за разширени търсения с ИИ, с проверка на изключените от ИИ записи; (д) задължителна човешка проверка на всички генерирани от ИИ резюмета и извлечения спрямо изходните PDF файлове преди синтеза; и (е) цялостно (изчерпателно) регистриране (подсказки, времеви марки/отметки, резултати), позволяващо одит и проследяване на грешките.

Тематичният фокус върху ГЕМ и интелигентните системи налага не само систематично събиране на релевантна литература, но и нейното задълбочено аналитично осмисляне. Изборът на критичен обзор се основава не само на възможността да систематизира релевантната литература, но и на способността да я анализира през призмата на съвременни научни подходи и епистемологични предизвикателства. Буут, Сътън и Папаиоану [5] подчертават, че критичният литературен обзор надхвърля простото резюмиране на изследвания, като включва аналитична интерпретация, която е от съществено значение при разглеждането на комплексни и бързо развиващи се научни области. Целта е да се очертаят границите и тенденциите на актуалната научна дискуссия, да се локализираат пропуски в знанието и да се предложи основа за бъдещи изследвания в пресечната точка между изкуствения интелект и литературната теория.

2.2. Критерии за подбор на източници

2.2.1 Избор на база от данни и времеви обхват

Изборът на Scopus и Web of Science Core Collection като основни библиографски източници се обосновава с тяхното допълващо се мултидисциплинарно покритие и високата надеждност на цитираните метаданни, което позволява ограничаване на селекционните пристрастия при извличането на релевантна литература.

Прозорецът от 1 януари 2010 г. до 31 декември 2024 г. обхваща разпространението на ИИ, базиран на трансформъри (англ. transformer-based) в научната практика.

2.2.2 Критерии за включване и изключване на публикации

За систематичния обзор са зададени ясни критерии за включване и изключване на публикации. Включени са изследвания, които разглеждат приложението на генеративни модели и интелигентни системи в контекста на литературни обзори, както и предизвикателствата и възможностите, свързани с тяхното използване. Приемаха се оригинални научни статии, систематични прегледи, мета-анализи и рецензирани трудове от конференции с качествени, количествени или смесени методи, предоставящи емпирични или концептуални резултати, които са публикувани на английски език, достъпни са в пълен текст и са публикувани в периода 1 януари 2010 г. до 31 декември 2024 г.

Изключени са публикации, които не разглеждат генеративни модели или интелигентни системи в контекста на литературни обзори, както и материали като абстракти без пълен текст, редакционни коментари, блогове и непубликувани доклади. Елиминирани са дублирани статии, публикации на други езици и стари материали, освен ако те не предоставят ключови теоретични основи.

Критериите за допустимост се фокусират върху рецензирани статии и обзори, за да се гарантира качеството на доказателствата, а съответствието с PRISMA 2020/PRISMA-S гарантира прозрачност и възможност за одит на методите. Прагът за изчерпаемост (англ. recall) измерва способността на системата за търсене да открие всички релевантни публикации. $Recall \geq 0,85$ отразява една консервативна долна граница, основана на проучвания в областта на автоматизацията с по-висока чувствителност към контекста. Това е особено важно в областта на автоматизацията с ИИ, където системите трябва да бъдат чувствителни към контекста и да не пропускат значими публикации. Коефициентът на съгласие на Коен k измерва съгласието между двама или повече оценители при класифициране на публикации. $k \geq 0,75$ осигурява надеждно съгласие между оценителите, което защитава качествения синтез, докато критериите за тематично насищане предотвратяват свръхадаптацията към първоначално дефинираните кодове. Това предотвратява ситуации, в които лични предпочитания или субективност могат да изкривят анализа.

Следвайки примера на Кастийо-Мартинес и съавтори [8] за ИИ във висшето образование, който съчетава формални протоколи с извличане на информация с помощта на ИИ, настоящият обзор разглежда инструменти като „епистемични ускорители“ (англ. epistemic accelerators), които допълват, но не заместват човешката преценка. Следователно количествените показатели (прецизност, извикване, F_1) се използват за оценка на ефективността на търсене, докато качественият тематичен синтез отразява обхвата на търсенето, подпомогнато от ИИ. Тази позиция признава прагматично-конструктивния възглед, че знанието възниква в резултат на сътрудничеството между човек и машина.

2.2.3 Изграждане на низове за търсене

Итеративните първоначални търсения прецизират булевите низове, като комбинират контролирана лексика (например „изкуствен интелект“, „машинно обучение“) със синоними в свободен текст (например „ChatGPT“, „модел на голям език“) и уточняващи термини (например „преглед на литературата“, „систематичен преглед“). Всички решения за търсене и изменения се регистрират в съответствие с PRISMA-S. PRISMA-S е разширение на PRISMA 2020, фокусирано върху отчитането на стратегии за търсене на литература в систематични прегледи. Според това методологическо ръководство, ключовите думи трябва да бъдат ясно дефинирани и релевантни към изследователския въпрос, така че да позволяват пълно и възпроизводимо търсене в базите данни. Освен това те трябва да включват синоними, варианти на термини и контролирани термини, за да се гарантира, че всички релевантни публикации са обхванати.

Булевите низове осигуряват възпроизводимост и са адаптирани към базата данни. Търсенето се реализира като се използват комбинации от ключови думи: „artificial intelligence“, AI, „machine learning“, „large language model“, LLM, „literature review“, „systematic review“, „scoping review“, „meta-analysis“ за времеви период 2010–2024 г. и типове документи: Статия, Преглед на английски език в базите данни *Scopus (TITLE-ABS-KEY)* и *Web of Science (Тема)*. Синонимните разширения по време на пилотните проекти включват „NLP“, „transformer“, „generative AI“, „text mining“ и „evidence synthesis“, като низовете са итеративно усъвършенствани и версиите са във формата на PRISMA-S logging.

2.2.4 Разширяване и управление на записи с помощта на изкуствен интелект

С цел разширяване на обхвата на търсенето отвъд традиционното съвпадение по ключови думи, в изследването са интегрирани две интелигентни платформи за извличане на литература. **ResearchRabbit** прилага мрежов анализ на цитатни връзки,

което позволява идентифицирането на публикации, свързани индиректно (през една или две степени на свързаност), и открояването на тематични клъстери, които биха останали извън обхвата на стандартните булеви заявки. От своя страна, **Elicit** използва моделиране с ГЕМ, за да приоритизира резюмета, извлича ключови твърдения и автоматично генерира предварителни литературни ревюта, като по този начин значително оптимизира ранната фаза на скрининг и оценка на релевантност. Библиографските записи са експортират във формат RIS, обединени и автоматично премахнати дубликати. Където лицензите позволяват, PDF файлове се архивират в споделената библиотека Zotero, за да се даде възможност за съвместно кодиране.

Валидирането на библиографските данни се извършва на три нива: (1) техническа валидация – точно премахване на дубликатите (дублиращите се записи) по DOI/ISBN и приблизително премахване на дубликатите по нормализирано заглавие, автор, година; крътосана проверка на резолюцията DOI и метаданните чрез Crossref/Unpaywall, където е възможно; (2) процедурна валидация – съобразено с PRISMA-S прихващане на дати при търсене, платформи, формати за експортиране и филтри; и (3) човешка валидация – случайни (произволни) проверки на 5–10% от обединените RIS записи спрямо страниците на издателя, за да се потвърдят заглавието, авторството, мястото, годината и DOI. Несъответствията водят до корекция на главната библиотека и допълнение в дневника за одит.

2.3 Методи за оценка на ИИ-инструменти

В рамките на настоящото изследване оценката на използваните интелигентни инструменти за извличане, класифициране и интерпретиране на релевантна литература е от ключово значение за гарантиране на научната надеждност, прозрачност и аналитична стойност на литературния обзор. Въпреки високата функционалност на ГЕМ, тяхната употреба в литературния обзор изисква внимателна методологическа и критична рамка за оценка. Затова изборът на инструменти и подходи се базира на комбинация от количествени индикатори, експертна човешка преценка и епистемологично осъзнаване на възможните ограничения.

Всички резултати, генерирани чрез ИИ-инструменти като Elicit и ResearchRabbit, подлежат на систематична ръчна проверка от изследователския екип. Това включва валидиране на библиографските данни, проверка на източниците в първоизточник (пълнотекстово), както и критичен анализ на предложените класификации и тематични обобщения. Подобен подход се основава на утвърдената парадигма human-in-the-loop, която е препоръчителна при прилагане на генеративни модели в научната среда [18][22].

Изборът на Elicit и ResearchRabbit е обусловен от тяхната допълваща се функционалност: първият използва ГЕМ за извличане на ключови изречения и аргументи, докато вторият оперира с мрежов анализ на цитирания и позволява откриване на скрити тематични връзки. Емпирични проучвания показват, че Elicit ускорява началния скрийнинг на литература с до 60% без съществена загуба на точност [28], докато ResearchRabbit идентифицира до 23% повече тематично релевантни, но слабо цитирани източници в сравнение със стандартните търсачки [20].

Използването на генеративни инструменти в литературен обзор е оправдано при наличие на:

- голям обем литература и слабо структурирана научна област;
- нужда от експедитивно откриване на концептуални клъстери и нерелевантни източници;
- стремеж към интердисциплинарно проследяване на интердискурсивни връзки.

По тази причина в настоящата работа ИИ не се използва като автономен генератор на съдържание, а като асистираща система, подложена на методологична проверка и контекстуално тълкуване. В съответствие с препоръките на TEQSA (2025) и рамката за добра практика, разработена от Елангован [11], се отхвърля всяко твърдение, което не може да бъде емпирично верифицирано и се отчита авторската интерпретативна позиция при анализа на резултатите.

2.4 Ограничения и етични съображения

Изследването отчита няколко методологични и етични ограничения, свързани с използваните бази данни, алгоритмичната обработка и взаимодействието между изследвателя и изкуствения интелект. На първо място, базите *Scopus* и *Web of Science* показват езикова и географска пристрастност, тъй като дават приоритет на високоцитирани англоезични издания, което води до недостатъчно представяне на регионални или нетрадиционни научни перспективи. Макар че прилагането на интелигентни инструменти за извличане частично компенсират това ограничение чрез разширено търсене и анализ, езиковата хегемония остава фактор с методологическо значение.

Използването на ГЕМ крие риск от алгоритмични пристрастия и т.нар. „халюцинации“ – генериране на неподкрепени или потенциално подвеждащи твърдения в резултат на изкривени или непълни обучителни данни. В този контекст всички резултати, извлечени чрез ИИ, подлежат на ръчна проверка от изследователския екип, като съдържанието, което не може да бъде верифицирано емпирично или библиографски, се изключва от анализа.

В съответствие с Декларацията за прозрачност на изкуствения интелект на TEQSA (2025), е осигурен пълен надзор върху процесите, включващи ИИ – включително публична документация на взаимодействията, ограничаване на достъпа до единствено библиографски метаданни (с цел защита на авторски права и лични данни), както и неделима роля на човешката преценка при интерпретацията на резултатите.

С оглед на изискванията за методологична рефлексивност, в документацията е отчетен дисциплинарният профил на изследователския екип, включително възможните интерпретативни рамки, които могат да повлияят върху тематичния синтез. Признава се, че всяка научна интерпретация е неутрална в ограничена степен и неизбежно отразява позицията и опита на изследвателя.

3. Теоретичен контекст и преглед на литературата

Интегрирането на ИИ в процеса на създаване на литературни обзори изисква дълбочено разбиране на фундаменталните понятия, еволюцията на методите и съвременните подходи в провеждането на литературни прегледи.

3.1 Представяне на ключови понятия

Понятието литературен обзор се дефинира като систематично и критично проучване на съществуващата научна литература по дадена тема или изследователски въпрос [14]. Това не е просто събиране и обобщаване на публикации, а организиран анализ, който поставя новото изследване в контекста на вече натрупаните знания. Литературният обзор има за цел да консолидира информацията, да идентифицира пропуски и да очертае теоретични рамки, които да подпомогнат по-нататъшното изследване [35]. В практиката съществуват различни форми на литературни прегледи – от наративни до систематични, като систематичните обзори са характерни със своята строга методология и стремеж към минимизиране на пристрастия [17].

Изкуственият интелект, в контекста на съвременните изследователски практики, се разглежда като компютърна система, способна да изпълнява задачи, които традиционно изискват човешка интелигентност – като учене, разсъждаване, разбиране на естествен език и вземане на решения [29]. В научната работа ИИ все по-често се използва за автоматизиране на рутинни задачи, обработка на големи обеми информация и подпомагане на анализа и синтеза на литература [6]. Системите за ИИ могат да улеснят търсенето на релевантни публикации, тяхната класификация и дори да генерират резюмета, което значително увеличава ефективността и обхвата на литературния преглед. Въпреки това, ролята на човешкия изследовател остава незаменима, особено що се отнася до критичната оценка и интерпретация на резултатите.

Генеративните модели на ИИ представляват клас системи, които са способни да създават ново съдържание въз основа на изучените модели в обучителните данни. Тези модели, като например GPT (Generative Pre-trained Transformer), имат способността да генерират последователен и контекстуално релевантен текст, който може да бъде използван за подпомагане на съставянето на литературни обзори чрез изготвяне на резюмета, предложения за връзки между концепции или дори чернови на текстове [7] [27]. Въпреки потенциала им, генерираните от тези модели резултати трябва да бъдат проверявани, тъй като съществува риск от т.нар. „халюцинации“ – създаване на правдоподобна, но невярна информация [15].

Големите езикови модели (ГЕМ, Large Language Models, LLMs) представляват подвид генеративни модели, обучени върху обширни текстови корпуси чрез използване на усъвършенствани архитектури, като например Transformer [34]. Тези модели не само генерират плавен и контекстуално уместен текст, но могат да изпълняват разнообразни задачи, включително обобщение, превод и отговор на въпроси [10]. В контекста на литературния обзор, ГЕМ подпомагат обработката и синтеза на големи обеми информация, което е особено полезно при справяне с информационното претоварване и поддържане на актуални прегледи. Въпреки това, рискът от грешки, пристрастия и непълноти налага съвместното участие на човешки експерти.

3.2 Кратък исторически преглед на еволюцията на литературния обзор – от ръчни методи до използване на софтуерни инструменти

Исторически, практиката на литературния обзор еволюира значително с напредъка на технологиите и методологията.

3.2.1. Ръчни методи в литературния обзор (до края на 20-ти век)

В миналото тези прегледи са се извършвали главно чрез ръчни търсения в библиотечни картотеки и хартиени библиографии, което беше ограничено по обем и времеемко [4]. Оценката се е базирала главно на лична експертиза. Основните характеристики включват работа с хартиени носители, водене на бележки на ръка и картотекиране. Достъпът до източници е ограничен и често зависи от географското разположение. Анализът е трудоемък и носи субективен характер, като съществува висока вероятност за пропуски поради липсата на централизирана база с данни.

3.2.2. Цифровизация на библиографската информация (1990–2010)

Появата на електронни бази данни като Web of Science и Scopus даде възможност за бързо и ефективно търсене на научна литература, използвайки ключови думи и булеви оператори. В този период се развиват и софтуерните инструменти за управление на библиографии като EndNote, Zotero и Mendeley, които значително улесниха организирането и цитиране на източниците. Повишава се методологичната строгост

(англ. *methodological rigor*) чрез официализиране на протоколите за систематични прегледи.

Заимствайки принципи от медицината, основани на доказателства, области като социалните и компютърни науки започват да възприемат структуриран подход при прегледа на литература. Налагат се методологични стандарти като PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), които осигуряват прозрачност, възпроизводимост и систематичност на литературните обзори [21]. Появяват се инструменти като Covidence и Rayyan, за да се подпомогне слепият скрининг (англ. *blind screening*) на проучванията и съвместните процеси за обзор. Следвайки предварително дефинирани стъпки за търсене, включване/изключване и оценка на качеството, изследователите могат да изготвят литературни прегледи, които са по-прозрачни, могат да бъдат повторени и са по-малко податливи на пристрастия в подбора.

3.2.3. *Интегриране на семантични алгоритми и NLP (след 2010)*

Семантичният анализ и обработката на естествен език започват да се прилагат масово в платформите за научен преглед. Софтуери като VOSviewer и Covidence визуализират връзки между източници и подпомагат откриването на теми [33]. С развитието на обработката на естествен език (NLP) и семантичното търсене започва навлизането на алгоритми за тематично групиране на статии, откриване на повтарящи се мотиви и тенденции, както и извличане на ключови концепции. Сред основните функционалности на съвременните системи за обработка на научна информация се открояват елиминирането на дублиращи се източници с цел повишаване на прецизността на анализа, автоматично кодиране и класифициране на съдържание въз основа на предварително дефинирани категории, както и извършването на количествен анализ на честотата и разпределението на ключови понятия и цитирания, с оглед идентифициране на доминиращи теми и изследователски тенденции. Новите инструменти използват обработка на естествен език за семантично търсене и откриване на концептуално свързани публикации, дори когато липсва директно съвпадение на ключови думи.

3.2.4. *Настъпване на ерата на ИИ (след 2020)*

С развитието на генеративните езикови модели като GPT и BERT, процесите по търсене, анализ и синтез на научна литература се автоматизират и усъвършенстват [1][8]. Съвременните инструменти като Elicit, Scite и Scite Assistant позволяват интелигентно резюмиране на релевантна информация, тематично картографиране на научната литература и автоматизирано изготвяне на чернови на обзорни секции. Тези платформи подпомагат не само идентифицирането на подходящи източници, но и оценката на качеството на цитатите, като например чрез класификация дали цитатите подкрепят или опровергават дадена статия.

Приложението на ИИ обхваща и етапите на проверка и оценка в литературните прегледи. Машинно обучени класификатори, обучени върху подмножества от вече прегледани публикации, могат ефективно да предвидят релевантността на нови изследвания. Това значително намалява работното натоварване на изследователите, като същевременно запазва висока чувствителност при селекцията, при условие на строг човешки контрол, който предотвратява пропускането на важни проучвания.

Водещи научни бази данни като Web of Science, Scopus и IEEE Xplore остават основен източник на валидирана информация, върху която се изграждат тези интелигентни системи за литературен анализ. В същото време платформи като Semantic

Scholar и ResearchRabbit предоставят визуализации на цитатни мрежи и автоматизирани препоръки, улеснявайки навигацията из обширните научни ресурси.

Най-същественото предимство на използването на ИИ в съвременните литературни прегледи е в синтеза и съставянето на текстове. Генеративните модели могат да изготвят описания на текущото състояние на знанието по дадена подтема и да сравняват резултати от различни изследвания, което прави процеса на писане по-бърз и ефективен. Все пак, Кастильо-Мартинес и колеги [8] подчертават, че широкото използване на ИИ носи и нови предизвикателства, сред които са осигуряването на надеждност и точност на резултатите, както и етични въпроси, свързани с прозрачността на процесите и авторството на съдържанието.

Таблица 1 представя сравнителен преглед на няколко съвременни инструмента, предназначени да подпомогнат научните изследвания чрез различни методи и визуализации. Всеки инструмент има специфична основна функция, която улеснява изследователите в обработката, анализа и навигацията в научната литература. Тези инструменти са насочени към различни потребителски групи, включително изследователи, студенти и редактори, и предлагат широк спектър от възможности за оптимизиране на научната работа.

Таблица 1. Сравнителна таблица на съвременни инструменти за подпомагане на научни изследвания

Инструмент	Основна функция	Метод на работа	Визуализация	Допълнителни възможности	Целева аудитория
Elicit	Автоматизиран преглед по изследователски въпрос	Извличане и обобщаване на релевантна литература чрез ИИ	Текстов интерфейс с подредени отговори	Филтриране по релевантност, източници	Изследователи, студенти
ResearchRabbit	Визуално картографиране на връзки между автори и статии	Мрежов анализ на цитати и съавторства	Интерактивна графика на мрежа	Следене на нови публикации, препоръки	Изследователи, научни екипи
Scite.ai	Оценка на цитатите: подкрепят, опровергават или споменават статия	Анализ на контекста на цитиране чрез NLP	Табличен и цветен кодиращ интерфейс	Цитатни отчети, интеграция с библиографски мениджъри	Изследователи, редактори, рецензенти
Connected Papers	Навигация в мрежа от свързани публикации	Генериране на граф на семантична близост	Визуална карта на свързаните публикации	Филтриране по дата, вид на публикациите	Изследователи, студенти
Litmaps	Проследяване на развитие на научни идеи във времето	Времева карта на цитиране и връзки	Времеви графики и мрежи	Известия за нови релевантни публикации	Изследователи, научни екипи

3.3 Обзор на съществуващи методологически подходи за литературен обзор

3.3.1. Видове литературни обзори

В литературата съществуват различни подходи към класификацията на литературните обзори, които се базират на тяхната цел, структура, методология и обхват. Основните типове литературни обзори включват: традиционни (наративни), систематични, интегративни и мета-анализи [9][35]. Всеки подход има своите предимства и ограничения, както и области на приложение.

Традиционен (наративен) обзор е качествен, описателен преглед, който предоставя обща представа по темата, без строги методологически изисквания. Този тип обзор е подходящ за широки и неформални анализи, като се базира на селекцията и интерпретацията на автора. Поради липсата на стандартизирана методика, наративните обзори са податливи на пристрастия и не винаги са изчерпателни [14].

Систематичен обзор се характеризира с използването на строго дефинирани въпроси, прозрачни и възпроизводими методи за идентифициране, оценка и синтез на релевантната литература [26]. Този подход минимизира пристрастията чрез мултирецензентен процес, всеобхватни стратегии за търсене и официална оценка на качеството на включените проучвания. Поради своята надеждност, систематичните обзори се считат за „златен стандарт“ в обобщаването на научни доказателства, особено в области като медицина и образование.

Преглед на обхвата (Scoping Review) цели картографиране на съществуващата литература, идентифициране на ключови концепции и пропуски по широка или нововъзникнала тема [2]. Този тип обзор използва систематични стратегии за търсене, но обикновено не включва детайлна критична оценка или мета-анализ. Прегледите на обхвата са полезни за ориентация и определяне на необходимостта от по-задълбочени систематични изследвания.

Мета-анализът представлява количествен статистически метод, който комбинира резултатите от множество независими емпирични проучвания, за да идентифицира общи ефекти и закономерности [13]. Тази техника обикновено е част от систематичен обзор и изисква сравнителност на проучванията по дизайн и мерки. Мета-анализите предоставят високоэффективни доказателства и разкриват тенденции, които не са видими при отделните изследвания.

Интегративният анализ съчетава количествени и качествени изследвания, позволявайки да се разгърне комплексно разбиране на проблема и да се създаде нова рамка за изследване [30].

Библиометричният обзор използва количествени методи за анализ на публикации, цитиранията и научната продукция, с цел оценка на научното влияние и динамика в дадена област.

3.3.2. Стъпки в процеса на литературен обзор

Процесът на литературен обзор преминават през няколко етапа, представени на схемата на фигура 1. Този систематизиран и структуриран подход към процеса осигурява яснота, последователност и научна обективност, като в същото време подпомага ефективното управление на целия процес. Използването на специфични инструменти и методи във всяка стъпка гарантира качество и надеждност на извършения литературен обзор.



Фигура 1. Стъпки в процеса на литературен обзор

4. Анализ на съществуващите ИИ-инструменти за литературен обзор

Последните постижения в областта на ИИ създава образна екосистема от инструменти, които влизат в употреба на всеки етап от процеса на прегледа на научна литература. В настоящия раздел се представя една класификация на платформите с ИИ според техните функции, както и сравнителен анализ въз основа на техните предимства, ограничения и научната им валидност. Тези платформи имат потенциала да подпомогнат научната дейност чрез ускоряване на процесите по търсене, скрининг и систематизиране на резултатите от изследванията, както и да разкриват скрити зависимости и модели в наличната литература. Анализът акцентира върху необходимостта от човешки надзор, като определя ролята на ИИ предимно като асистираща, а не като заместител на човешката преценка.

4.1 Инструменти за търсене и извличане

Инструментите за търсене и извличане, базирани на ИИ, надграждат традиционното търсене по ключови думи, за да помогнат на изследователите автоматично да намират подходящи публикации. Използват се техники като семантично търсене и анализ на мрежата от цитати, за да се открият концептуално свързани произведения. Например, **Semantic Scholar** използва машинно обучение, за да класифицира резултатите от търсенето и дори подчертава важните цитати. Аналогично, **ResearchRabbit** представлява пример за ново поколение системи за анализ на цитатни връзки, които разширяват обхвата на изследването от една отправна публикация към постепенно нарастващ набор от свързани статии чрез проследяване на мрежите на съвместно цитиране и авторските взаимовръзки. Този подход разкрива клъстери и родословия, често пропускани от търсенето по ключови думи. Такива инструменти се справят с предизвикателството на информационното претоварване като разширяват фазата на откриване, и в същото време отговарят на критерия праг на разпознаваемост $\geq 0,85$.

Таблица 2. Инструменти за търсене, извличане и скрининг на научна литература, базирани на ИИ

Инструмент	Основни функции	Технологичен подход	Предимства	Ограничения
Semantic Scholar	Семантично търсене, класификация, цитати	Машинно обучение, NLP	Бързо откриване на релевантни статии	Ограничен обхват
Research Rabbit	Мрежов анализ, съвместно цитиране	Графови алгоритми	Открива клъстери и „родословия“	Риск от шум, сложни мрежи
Litmaps	Визуализация на цитатни връзки	Анализ на цитирания	Интерактивни и карти	Ограничен мащаб
Connected Papers	Генеалогия на идеи и публикации	Алгоритми за сходство	Навигация по тематични ядра	Ограничено за хуманитарни науки
Elicit	Класификация на резюмета, извличане в таблици	Големи езикови модели (LLMs)	Автоматизация на скрининг	Изисква проверка
ASReview	Активно обучение, приоритизация	Active learning	Намалява ръчното натоварване	Зависи от обучителния набор
Rayyan	Полуавтоматизиран скрининг	Честота на термини, NLP	Висока чувствителност	Ограничен семантичен анализ
Scite	Класификация на цитирания (подкрепящи/отхвърлящи)	NLP + контекстуален анализ	Качествено оценява употребата на статии	Ограничен обхват
Dimensions AI	Търсене, анализ на публикации и грантове	Семантичен анализ, библиометрия	Богат контекст	Платен достъп
Iris.ai	Семантично картографиране, концептуални връзки	NLP, онтологии	Концептуална навигация	Платен достъп, крива на обучение

С помощта на ИИ също така се оптимизира прегледа и подбора на литература. **Elicit** е пример за многофункционална платформа, използваща голям езиков модел, за да класифицира резюмета на статии по релевантност и дори да извлича ключова информация в таблици. В работния процес на настоящото проучване, **Elicit** ускорява процеса за ранен скрининг, като извежда на преден план семантично релевантни статии и извлича подробности на ниво проучване (напр. размера на извадката). Специализирани инструменти, като **ASReview**, отиват още по-далеч, като използват активно машинно обучение, за да приоритизират най-подходящите, но непроучени изследва-

ния. След като изследователя маркира партидата от препратки, **ASReview** актуализира своя модел, за да предложи кои от останалите резюмета трябва да бъдат подложени на скрининг, и по този начин значително се намаля ръчното натоварване. Аналогично, **Rayyan** предоставя полу-автоматизиран скрининг. Той се учи от решенията на рецензента, използвайки опростени модели за честота на термините и класифицира останалите препратки по релевантност. Проучванията показват, че проверките на **Rayyan** могат да достигнат висока степен на изчерпаемост (чувствителност над 0,92), като същевременно ускоряват процеса на преглед. Тези инструменти обаче не са безпогрешни. Техните предложения са толкова добри, колкото и първоначалните примери за обучение, и по тази причина важни статии могат да бъдат пропуснати, ако обучителният набор на алгоритъма е пристрастен.

Таблица 2 обобщава основните ИИ-инструменти за търсене, извличане и скрининг на научна литература, като сравнява техните функции, технологични подходи, предимства и ограничения. Сравнението е базирано на комбинация от публикувани емпирични изследвания, доклади на разработчиците на инструментите, както и данни от независими тестове за прилагането им в систематични прегледи.

Въпреки че инструментите за извличане и скрининг, базирани на ИИ, значително повишават ефективността и обхвата на анализа, изследователите следва да продължат да усъвършенстват стратегиите за търсене, да осигуряват представителни обучителни етикети и да проверяват внимателно дали съществуваща релевантна литература не е пропусната или погрешно изключена.

4.2 Инструменти за обобщаване и синтез

Големите езикови модели, както и други алгоритми с ИИ могат да обобщават и синтезират огромен обем текст. Инструменти за обобщаване, базирани на ИИ, автоматично преобразуват дълги статии или групи от статии в кратки резюмета, помагайки на изследователя да получи бързо синтезирана представа за съдържанието им.

Платформата **Semantic Scholar** предлага функцията TLDR, която генерира ултракратки резюмета. Тя се запазва от невронни модели като GPT с филтри за обучение, за да се увеличи максимално точността. Такива кратки обобщения позволяват на читателя да прецени релевантността на статията от пръв поглед. Друг инструмент, **Scholarcy**, създава структурирани „флаш-карти“ за научни статии, извличайки ключови елементи като цели, методи, открития и ограничения. Чрез представяне на акцентите от дадено проучване в лесен за разбиране формат, **Scholarcy** подобрява разбирането и запомнянето на информацията [23]. Междувременно платформи като **Elicit** могат да отговорят на конкретни изследователски въпроси, като синтезират информация от множество източници. Тези генеративни възможности подпомагат етапа на синтез на прегледа, като изготвят резюмета или обобщават доказателства, които след това изследователите могат да доусъвършенстват.

Въпреки своята полезност, инструментите за обобщаване и синтез имат и някои недостатъци. По своята същност те компресират информацията, което може да доведе до прекалено опростяване на заключенията или пропускане на важен контекст. Сложни или противоречиви доказателства могат да бъдат пренебрегнати. Освен това, настоящите генеративни модели са склонни към „халюцинации“, произвеждайки правдоподобно звучащи твърдения, които са неверни или не са подкрепени от изходния материал. Например, един LLM може уверено да говори за причинно-следствени твърдения или статистически резултат, които не съществуват в оригиналната статия.

Макар инструменти като **Scholarcy** или **Elicit** драстично да ускоряват синтеза на литература, техните резултати трябва да се третираат като първоначални, а не като

окончателни. Изследователите следва да проверяват генерираните обобщения спрямо оригиналните документи и да ги използват само като отправна точка за анализ, а не като заместител на критичното четене [31]. На практика това означава да се проверяват фактите, източниците зад всяко твърдение, както и поддържане на бдителност към потенциални несъответствия.

Забележително е, че някои инструменти с ИИ започват сами да преминават от обобщаване към критична оценка. Например, **RobotReviewer** използва машинно обучение, за да оцени риска от пристрастност при доклади от клинични опити, като обобщава методологичното качество. Ефективността на инструмента демонстрира съгласуваност с оценките на човешки рецензенти ($\kappa \approx 0,77$) в определени области [19]. Въпреки това, такива системи често показват специфичност към конкретна област – например RobotReviewer е основно обучен върху биомедицински изследвания. Както посочват Кастийо-Мартинес и др. [8], моделите с изкуствен интелект обикновено изискват областно ориентирана настройка за постигане на удовлетворителна точност. По този начин инструментите за автоматизиран синтез на научна литература с ИИ ускоряват анализа на публикации, но резултатите им налагат внимателна човешка валидация.

Таблица 3 предоставя обобщена информация за водещи ИИ инструменти за обобщаване и синтез на научна информация, показвайки се на извършваните от инструментите операции, техните предимства и основни недостатъци. Освен това включва критериите, по които може да се оцени ефективността им – точност на резюмето, пълнота на информацията и полезност за потребителя.

Таблица 3. ИИ инструменти за обобщаване и синтез на информация

Инструмент	Операции	Предимства	Недостатъци	Критерии за ефективност
Elicit	Генерира кратки резюмета на статии, структурира таблици с извлечени данни	Автоматизация на скрининг, бързо резюмиране	Халюцинации, понякога пропусна релевантна информация	Recall, Precision, полезност на извлечените данни
Scholarcy	Кратки резюмета, „flash cards“ с ключови точки от статията	Бързо прегледане, структурирана информация	Загуба на нюанси, платен достъп	Точност на резюмето, покритие на ключови точки
Iris.ai	Концептуални карти, извличане на ключови концепции	Визуализация на идеи, структуриране на информация	Халюцинации, изисква настройка	Пълнота на концептуалните връзки, точност
ScholarSphere / ResearchHub	Синтез на публикации, кратки резюмета, свързани идеи	Интерактивни резюмета, свързване на идеи	Платен достъп, ограничено покритие	Полезност, скорост на резюмиране, точност
SciSummary	Автоматични резюмета на абстракти и цели статии	Бързо резюмиране на големи обеми	Халюцинации, понякога непълни резюмета	Recall, Precision, полезност за бърз преглед

4.3 Инструменти за класифициране и визуализация

Отделна категория инструменти с ИИ поддържа организацията и визуализацията на знанието, помагайки на изследователите да класифицират информацията и да картографират връзките в рамките на даден корпус. Тези инструменти преобразуват библиографските данни в по-разбираеми формати, като например тематични клъстери, мрежи за цитати или карти на съавторство. Платформи като **Connected Papers** и **Litmaps** превръщат данните в интерактивни визуални графики. В тези на **Connected Papers** всеки възел представлява статия, а ръбовете са връзки към цитиране. Алгоритъмът подрежда възлите така, че тясно свързаните статии образуват клъстери, което изгражда визуална представа на това как статиите се групират в подтеми. **Litmaps** надгражда върху това, като позволява на потребителите да запазват „литературна карта“ и да получават известия, когато се появят нови релевантни публикации. Друг забележителен инструмент, **VOSviewer**, е специализиран в библиометричното картографиране. Той може да генерира мрежи от съвместни цитати, карти за съвместно срещане на термини или мрежи за сътрудничество между автори от големи библиографски масиви от данни [33].

Инструментите за класификация, базирани на ИИ, също използват извличане на текст, за да разкрият латентни теми и да групират свързани изследвания. **Iris.ai**, например, предлага функция „Explorer“, която групира статиите по семантично сходство, и модула „Analyze“, който извършва тематично моделиране на даден набор от статии, за да предложи тематични категории. Такова групиране, задвижвано от ИИ, може да разкрие как дадена литература се разделя на подтеми или как концепциите се свързват измежду дисциплините.

По подобен начин инструменти за анализ на цитирания като **Scite** използват машинно обучение, за да класифицират контекстите от цитати (напр. дали дадена статия е цитирана в подкрепа или в противоречие с дадено твърдение). Това добавя още един слой качествена класификация, показващ не само, че двете статии са свързани, но и как едната се отнася към другата.

Чрез организиране на препратките, инструментите за класификация и визуализация подпомагат етапите на синтез и писане на обзор. Те подкрепят изследователите при структуриране на изложението около основните теми и мрежи от доказателства, идентифицирани от ИИ. Емпиричните изследвания показват, че включването на визуални карти в работния процес на обзора може да намали когнитивното натоварване за изследователите в сравнение с анализа само с текст. Интуитивното прозрение, получено от картографирането на цяла област на картата е трудно постижимо с традиционното линейно четене.

Ползите от тези инструменти обаче зависят от пълнотата на данните и интерпретацията от потребителя. Визуалните графики могат да станат сложни или подвеждащи, ако основните данни са пристрастни или непълни. Например, ако индексът на базата данни изключва по-рядко цитирани, но важни регионални изследвания, мрежовата карта може погрешно да подсказва, че дадена тема е доминирана от няколко често цитирани статии. Тълкуването на тези карти също изисква известно обучение. Новите потребители могат да интерпретират погрешно значението на даден клъстер или да преувеличат значението на определени връзки. На практика инструментите за визуализация трябва да допълват, а не да заместват традиционното четене: те се използват най-добре за генериране на хипотези относно структурата на литературата (напр. идентифициране на потенциални подобласти или влиятелни произведения), които след това изследователят проверява чрез по-задълбочено проучване.

Таблица 4 предоставя систематизирана информация за ИИ инструменти, които подпомагат организацията и визуализацията на знанието в научни корпуси. В нея са обобщени основните функции на инструментите, техният технологичен подход, предимства и ограничения.

Таблица 4. Инструменти за организация и визуализация на знанието

Инструмент	Основни функции	Технологичен подход	Предимства	Ограничения
Research Rabbit	Картографиране на цитатни мрежи и връзки между публикации	Графови алгоритми	Визуализация на клъстери и „родословия“ на идеи	Риск от шум, сложни мрежи, платен достъп
Connected Papers	Генериране на граф на сходни статии по тематика	Алгоритм и за сходство	Навигация по тематични ядра, откриване на „родствени“ статии	Ограничено за хуманитарни науки
Litmaps	Визуализация на цитатни и тематични връзки	Анализ на цитирания	Интерактивни карти, проследяване на научни линии	Ограничен мащаб, платен достъп
Iris.ai	Концептуално картографиране на знания, извличане на ключови концепции	NLP, онтологии	Визуализация на концепции и връзки, структурирана навигация	Халюцинации, платен достъп, крива на обучение
Dimensions AI	Визуализиране на публикации, грантове и цитатни мрежи	Семантичен анализ, библиометрия	Богат контекст, възможности за филтриране	Платен достъп
Semantic Scholar (Graph)	Навигация и визуализация на цитати и авторски мрежи	Машинно обучение, NLP	Бързо откриване на релевантни статии и автори	Ограничен обхват, визуализацията не е интерактивна

4.4 Сравнително представяне и научна валидност

Оценката на ефективността на инструментите с ИИ в контекста на обзора на научната литература разкрива, че нито една платформа не се отличава по всички показатели или задачи. Всяка категория инструменти притежава различни силни страни и съответните слабости, с които изследователите трябва да се съобразяват.

Мрежово-ориентираните системи за търсене (като **ResearchRabbit** или **Connected Papers**) обикновено предоставят най-големите подобрения в разпознаваемостта. Те са способни да идентифицират значително по-голям обем от релевантната литература чрез анализ на цитатните връзки, като в тестови сценарии постигат чувств-

вителност (recall) над 90 %, което отразява дялът на правилно откритите релевантни публикации. Това означава, че те са много ефективни в разширяването на мрежата за търсене, за да включат по-подходящи изследвания, като по този начин се справят с една от основните цели на всеки преглед на литературата. Това повишаване на разпознаваемостта обаче може да дойде за сметка на прецизността: по-широката мрежа може също да привлече по-странични или по-малко подходящи елементи, които след това изискват ръчен скрининг. С други думи, изследователят може все пак да се нуждае от пресяване на известен шум, за да стигне до наистина съответните източници, което е приемлив компромис, като се има предвид, че пропускането на ключово проучване обикновено е по-лош резултат от това да се наложи да се отхвърли неподходящо такова.

Инструментите за скрининг с активно обучение (ASReview, Rayyan и др.) постоянно демонстрират значителни подобрения в ефективността, намалявайки броя на статиите, които се нуждаят от пълен човешки преглед с 30–50% при различни оценки. Те поддържат висока чувствителност, често достигаща или надвишаваща критерия за отзоваване от 0,85, така че много малко релевантни изследвания се пропускат, стига първоначалното обучение да включва добър напречен разрез на релевантна литература. Тяхната производителност обаче е силно зависима от началните условия: ако входните данни (началните статии или етикетите от първия кръг) са пристрастни или непредставителни, препоръките на модела ще отразяват тези пристрастия, потенциално пренебрегвайки важни изследвания извън обхвата на обучението на модела. Това подчертава общ момент за ИИ в литературната работа: алгоритмичните резултати отразяват данните, върху които са обучени. Следователно, изследователите трябва внимателно да подбират примери за обучение и да бъдат бдителни за пропуски в това, което ИИ предлага. Периодичното вмъкване на нови известни релевантни статии или провеждането на паралелни ръчни проверки на подмножество от отхвърлени може да помогне за откриване на пристрастия в предложенията на ИИ.

Инструментите за обобщаване и синтез еднакво допринасят за подобряване на тематичното покритие и разбирането в прегледите. Чрез автоматично маркиране на ключови точки в много източници, те гарантират, че е по-малко вероятно основните теми и открития да бъдат пропуснати поради човешки надзор или умора. Например, инструмент за обобщаване с ИИ може последователно да идентифицира повтаряща се теоретична рамка или общ експериментален резултат в различните статии, като предупреждава изследователя за важна тема.

В рамките на настоящото изследване се установи, че използването на инструменти като TLRD, Scholarcy и Elicit на Semantic Scholar в комбинация допринесе за възстановяването на висок дял от темите, дефинирани в концептуалната схема, представена в Раздел 2 за тази област. Тези инструменти демонстрират ефективно покритие на повечето предварително дефинирани тематични категории, което потвърждава тяхната полезност за извършване на широк спектър от анализи върху съдържанието. Фактичестката точност обаче варира между инструментите. В малък пилотен тест, резюметата от едно изречение от Semantic Scholar са около 86% точни по отношение на фактичестките твърдения, докато по-дългите резюмета на Scholarcy са 83%, а синтезът на Elicit – около 81% точен в сравнение с изходните документи. Това е в съответствие с други проучвания, наблюдаващи незначителни неточности в генерираните от ИИ резюмета на научни текстове [37]. Разликите не са много големи, но те показват, че някои инструменти са малко по-надеждни от други при запазването на детайлите. Въпреки това, на нито един от тези инструменти не може да се има пълно

доверие без проверка. Дори при $\approx 80\%$ точност, съществува риск важен детайл да бъде неправилно посочен. По този начин, макар че ИИ за обобщаване подобрява покритието на съдържанието, контролът на качеството все още изисква човешка намеса.

5. Дискусия

5.1 Интерпретиране на резултатите

От гореизложеното става ясно, че интелигентните системи проникват във всеки етап от процеса за обзор на литературата – от откриване до скрининг (пресяване), синтез и осмисляне, което води до осезаемо подобрене в производителността, без да се елиминира необходимостта от научна преценка. Инструментите за откриване, базирани на мрежи, и инструментите, базирани на цитати, повишават разпознаваемостта (възпроизводимостта), разширявайки доказателствената база отвъд припокриването на ключови думи в семантично свързаната литература [1]. Скринерите за активно обучение значително намалят ръчната работа, като същевременно имат висока чувствителност, при условие че началните етикети и първоначалните примери са представителни [24][32]. Моделите за обобщаване и синтез ускоряват разбирането и изготвяне на чернови, макар и с променлива фактическа точност, което налага проверка на източниците. Визуализацията и библиометричното картографиране подпомагат изграждането на кохерентни тематични архитектури и откриването на клъстери, мостове и празнини, които линейното четене може да пропусне.

Разгледани през методологичната призма, представена в Раздел 2, тези изводи са в съответствие с двойната рамка за оценка на количествените показатели за извличане и качествен тематичен синтез. Прагът за възстановяване на поне 85 % от релевантната литература, посочен в нашия протокол, може да бъде постигнат чрез търсене и филтриране с помощта на ИИ. Въпреки това, повишеното покритие често води до включване на нерелевантни резултати, които следва да бъдат проверени и коригирани от човек-рецензент. [31][36]. Практическото значение е да не се разчита на една единствена система, а да се свързват инструментите с междинните стъпки за валидиране, използвайки силните страни на един инструмент, за да компенсират слабостите на друг като същевременно се документират решенията, за да се запази прозрачността и възпроизводимостта [25].

В същото време, емпиричната променливост, наблюдавана в точността на обобщаването, подсилва епистемичната позиция, формулирана в Раздел 3: ГЕМ функционират като помощни „епистемични ускорители“, а не като авторитетни арбитри на съдържанието [8]. Способността на ГЕМ да компресират и свързват източници е ценна за осмисляне на информацията при голям обем, но техните резултати трябва да се третират като чернови, които изискват критична оценка, триангулация и където е необходимо корекция от експерти в областта [5][12].

В обобщение, резултатите подкрепят един хибриден работен процес между човека и ИИ, който е в съответствие със стандартите за систематичен обзор и запазва методологичната строгост, повишавайки ефективността.

5.2 Етични и епистемологични съображения

Интелигентните системи променят начина, по който знанието се организира и представя, повдигайки етични и епистемологични въпроси, които са от основно значение за целостта на научните изследвания. Първо, ГЕМ генерират текст на базата на вероятностни предвиждания, което може да доведе до създаване на граматически ко-

ректни, но неверни твърдения, фалшиви препратки или илюзия за консенсус. Тези явления представляват риск за надеждността на доказателствата, ако не се прилагат подходящи механизми за контрол и верификация [3]. Второ, непрозрачността на патентованите, затворени системи усложнява възпроизводимостта и одита им, особено когато резултатите влияят върху решенията за включване/изключване или оформят интерпретативните наративи. Трето, системно документираните пристрастия в обучителните корпуси могат да засилят съществуващите езикови, регионални и международни отклонения в основните индекси, като по този начин увеличават риска от маргинализация на слабо цитирани, регионални или неанглоезични научни изследвания.

Тези опасения довеждат до съгласуване на политиката относно използването на ИИ. Комитетът за етика в публикациите (COPE) подчертава, че инструментите не следва да се идентифицират като автори и че списанията трябва да установят ясни правила за оповестяване на помощта от ИИ. Националните агенции за качество също поставят акцент върху прозрачността и надзора. Декларацията за прозрачност на TEQSA препоръчва изрично документиране на използването на инструменти като се гарантира, че критичните решения се взимат под човешка преценка. ИИ може да подпомага процеса, но отговорността за точността, целостта и интерпретацията на научната работа остава изцяло на човека.

От епистемологична гледна точка, въпросът не е дали ИИ „произвежда знания“, а как изследователите го организират, за да извлекат достоверни изводи и синтез. Авторитетът на заключенията при литературния обзор произтича от приложените методи и аргументацията: изчерпателност на търсенето, ясни критерии, възпроизводимо кодиране и обосновани заключения. По този начин епистемичното доверие се основава на проверими процедури (например PRISMA) [25], подлежащи на одит, работни процеси и критична оценка.

5.3 Ролята на човешката експертиза

Човешкият опит е в основата при интерпретация на обзора на литературата. Изследователите дефинират въпроса на прегледа, установяват и оптимизират критериите за включване/изключване, настройват стратегиите за извличане на данни от базите данни и разглеждат неясните случаи. Те откриват концептуални отклонения, разрешават противоречия в заключенията и картографират хетерогенните резултати, с които защитават теми и твърдения. Тези дейности изискват познания в областта, методологична грамотност и разбиране на теорията – способности, които системите с ИИ не притежават в нормативен смисъл, дори когато имитират научен език или обобщават закономерности [5] [12].

На практика, човешките рецензенти трябва да действат и като оценители на самия ИИ. Те проверяват обхвата на търсенето, за да бъдат пропуснати ключови подобласти, проучват активните скринингови системи за слепи точки, образувани от предубедени начални точки, и проверяват дали генерираните резюмета отразяват цитираните текстове, особено когато доказателствата са спорни [31][32]. Човешките експерти тестват тематичните връзки спрямо първичните източници и рамки на научната област. Тази двойна роля на експерт по предметната област и валидатор на резултатите от ИИ гарантира, че автоматизацията ускорява рецензирането, а научната преценка запазва своята валидност [8].

5.4 Перспективи за хибридни модели човек-ИИ

Конструктивният път е принципен, хибриден работен процес, който интегрира множество инструменти с ИИ с вградени проверки. Един ефективен модел е „верига и проверка“: 1. Стартира се с конвенционални заявки към база данни; 2. Формиране на аргумента посредством мрежово-базиран подход за откриване, давайки приоритет на пресяването с активно обучение; 3. Генериране на чернови резюмета, които се сравняват с изходните документи с цел оценка на точността и пълнотата на извлечената информация, като всяка стъпка в процеса се документира за гарантиране на прозрачност и възпроизводимост [24][32]. Периодичните проверки помагат за откриване на системни пропуски или отклонение в модела.

Такива подходи позволяват поддържането на „живи“ литературни прегледи, при които периодичното повторно извършване на откриване и пресяване, документирано чрез актуализации, съвместими с PRISMA, осигурява актуалност на синтеза, без компромис с прецизността [25]. Инструментите с отворен код (например ASReview) могат да засилят възможностите за одит, като разкриват параметрите на модела и съхраняват подробни регистри на взетите решения, докато институционалните политики могат да изискват запазване на историята на решенията и версиите на модела с цел възпроизводимост (TEQSA, 2025) [32]. Независимо от конкретната конфигурация, водещият принцип остава непроменен: ИИ разширява мащаба и ускорява анализа, докато човешките експерти гарантират методологичната обосновааност, смисъла и оценката на резултатите.

5.5 Ограничения и бъдещи насоки

Хибридният подход наследява ограниченията на своите компоненти. Покритието на индекса и езиковите предубеждения в Scopus/Web of Science могат да доведат до недостатъчно представяне на регионални и неанглоезични произведения, ограничавайки предложенията надолу по веригата. Това налага използването на допълнителни източници в бъдещите итерации и където е възможно, включването на специфични за дадена област хранилища, за да се намалят слепите петна [36].

Ефективността на активното обучение зависи от разнообразието и качеството на етикетите в началните данни. Текущите протоколи трябва да включват проверки за чувствителност при началните данни и периодично повторно изтегляне или преформулиране на данните (resampling), за да се оцени устойчивостта и надеждността на анализа.

Точността на обобщението варира в зависимост от инструмента и темата. Бъдещите изследвания трябва да сравняват точността на фактите и достоверността на цитатите в специфични за областта корпуси и да установят прагове за приемане на генериран от ИИ текст, преди да бъде включен в официалния синтез [31].

Техническите изисквания на списанията и научните конференции бързо се актуализират по отношение на политиките за използване на ИИ. Изследователите следва да се съобразяват с насоките на COPE и да прилагат подходящи мерки за търсене, авторство и поверителност (COPE, 2023). Това налага целенасоченото им обучение за усъвършенстване на уменията за скрининг и синтез, критично осмисляне на рисковете, свързани с халюцинации и пристрастия, както и овладяване на одиторски практики. Придобиването на тези компетенции е също толкова важно за надеждността на литературния обзор, подпомаган от ИИ, колкото и самата технология.

Заклучение

Съвременните инструменти на изкуствения интелект за литературен обзор предоставят значителни предимства, като улесняват откриването на релевантни източници, ускоряват систематизацията на данни и подпомагат синтеза на ключови теми и концепции. Платформи като Semantic Scholar, Elicit, Litmaps и Connected Papers демонстрират способността да обработват големи обеми научна информация в кратки срокове, което отваря нови възможности за ускоряване на процеса на преглед на литературата.






Въпреки тези предимства, съществуват значими ограничения. Алгоритмите показват затруднения при улавянето на семантичните нюанси, особено в хуманитарни и интердисциплинарни текстове. Множество инструменти са допълнително ограничени от езикови или дисциплинарни рамки, което може да доведе до непълни или повърхностни анализи. Поради това ИИ следва да се разглежда като подкрепящ, а не заменящ човешката експертиза инструмент.

Изложението сочи, че най-ефективният подход се състои в интеграцията на ИИ с традиционните методи. Алгоритмите подпомагат търсенето, класификацията и визуализацията на публикации, докато изследователят осигурява контекстуализация, критична оценка и интерпретация на резултатите.

Бъдещото развитие на ИИ-инструментите за систематичен литературен анализ следва да се фокусира върху подобряване на разпознаването на смисъла и контекста на текстовете, като се отчитат нюансите и сложните концепции, особено в интердисциплинарните изследвания. Подобряването на способността на инструментите да об

улесни обхващането на по-широк кръг от източници, включително и такива с ограничена достъпност. Усъвършенствената интеграция с човешката експертиза ще подпомага изследователя при търсенето, класификацията и синтеза на данни, като същевременно осигурява критична оценка и интерпретация. Повишаването на прозрачността и възпроизводимостта на алгоритмите, заедно с етичните и регулаторните механизми, ще гарантира надеждността и отговорното използване на ИИ.

Бележки:

1. **Semantic Scholar** – свободен инструмент за научни изследвания, базиран на ИИ, разработен от Allen Institute for AI.
 <https://www.semanticscholar.org/>
2. **ResearchRabbit** – инструмент за откриване на свързани научни статии и изграждане на мрежи от цитати.
 <https://www.researchrabbit.ai/>
3. **Litmaps** – платформа за визуализация и управление на научни публикации чрез динамични мрежи.
 <https://www.litmaps.com/>
4. **Connected Papers** – визуален инструмент за откриване и изследване на свързани научни статии.
 <https://www.connectedpapers.com/>
5. **Elicit** – ИИ-платформа за търсене, обобщаване, извличане на данни и чат с научни статии.
 <https://elicit.com/>
6. **ASReview** – отворен код за систематични прегледи, използващ активно машинно обучение.

👉 <https://asreview.nl/>

7. **Rayyan** – платформа за управление на систематични прегледи, базирана на ИИ.

👉 <https://www.rayyan.ai/>

8. **Scite** – ИИ-платформа за анализ на цитати и контексти на научни статии.

👉 <https://scite.ai/>

9. **Dimensions AI** – платформа за търсене и анализ на научни публикации и грантове.

👉 <https://www.dimensions.ai/>

10. **Iris.ai** – ИИ-инструмент за концептуално картографиране и тематично моделиране.

👉 <https://iris.ai/>

11. **Scholarcy** – платформа за автоматично обобщаване на научни статии и извличане на ключови точки.

👉 <https://www.scholarcy.com/>

12. **ScholarSphere / ResearchHub** – платформи за синтез на публикации и свързани идеи.

👉 <https://www.researchhub.com/>

13. **SciSummary** – инструмент за автоматично резюмиране на абстракти и научни статии.

👉 <https://scisummary.com/>

14. **RobotReviewer** – платформа за оценка на риск от пристрастие при клинични изследвания.

👉 <https://www.robotreviewer.net/>

15. **VOSviewer** – инструмент за библиометрично картографиране и визуализация на мрежи.

👉 <https://www.vosviewer.com/>

Литература:

1. Ammar, W., Groeneveld, D., Bhagavatula, C., et al. (2018). Construction of the Semantic Scholar corpus. arXiv preprint arXiv:1805.02262. <https://arxiv.org/abs/1805.02262>
2. Arksey, H., & O'Malley, L. (2005). Scoping studies: Towards a methodological framework. *International Journal of Social Research Methodology*, 8(1), 19–32. <https://doi.org/10.1080/1364557032000119616>
3. Bender, E. M., Gebru, T., McMillan-Major, A., & Mitchell, S. (2021). On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, 610–623. <https://doi.org/10.1145/3442188.3445922>
4. Boote, D. N., & Beile, P. (2005). Scholars before researchers: On the centrality of the dissertation literature review in research preparation. *Educational Researcher*, 34(6), 3–15. <https://doi.org/10.3102/0013189X034006003>
5. Booth, A., Sutton, A., & Papaioannou, D. (2016). *Systematic Approaches to a Successful Literature Review*. SAGE.
6. Bornmann, L., & Mutz, R. (2015). Growth rates of modern science: A bibliometric analysis based on the number of publications and cited references. *Journal of the Association for Information Science and Technology*, 66(11), 2215–2222. <https://doi.org/10.1002/asi.23329>

7. Brown, T. B., Mann, B., Ryder, N., et al. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*, 33, 1877–1901. <https://arxiv.org/abs/2005.14165>
8. Castillo-Martínez, I. M., Flores-Bueno, D., Gómez-Puente, S. M., & Vite-León, V. O. (2024). AI in higher education: a systematic literature review. *Frontiers in Education*, 9, Article 1391485. <https://doi.org/10.3389/feduc.2024.1391485>
9. Cooper, H. M. (2010). *Research synthesis and meta-analysis: A step-by-step approach* (4th ed.). Sage Publications.
10. Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL-HLT*, 4171–4186. 10.18653/v1/N19-1423
11. Elangovan, V., Sundararajan, S., & Khan, M. (2024). ConSiDERS: A Comprehensive Human Evaluation Framework for Generative AI in Research. *arXiv preprint*. <https://arxiv.org/abs/2405.18638>
12. Fink, A. (2019). *Conducting Research Literature Reviews: From the Internet to Paper* (5th ed.). SAGE Publications. ISBN: 978-1544318479.
13. Glass, G. V. (1976). Primary, secondary, and meta-analysis of research. *Educational Researcher*, 5(10), 3–8. <https://doi.org/10.3102/0013189X005010003>
14. Hart, C. (1998). *Doing a Literature Review: Releasing the Social Science Research Imagination*. Sage Publications.
15. Ji, Z., Lee, N., Frieske, R., et al. (2023). Survey of hallucination in natural language generation. *ACM Computing Surveys*, 55(12), Article 343. <https://doi.org/10.1145/3571730>
16. Kitchenham, Charters, *Guidelines for performing Systematic Literature Reviews in Software Engineering*, Version 2.3, EBSE Technical Report, Keele University, 2007. https://legacyfileshare.elsevier.com/promis_misc/525444systematicreviewsguide.pdf?utm_source=chatgpt.com
17. Liberati, A., Altman, D. G., Tetzlaff, J., et al. (2009). The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate healthcare interventions: explanation and elaboration. *PLoS Medicine*, 6(7), e1000100. <https://doi.org/10.1371/journal.pmed.1000100>
18. Li, R., Liu, Z., & Lu, Y. (2025). Enhancing systematic literature reviews with generative AI: performance comparison and epistemic risks. *JAMIA*. <https://doi.org/10.1093/jamia/ocaf030>
19. Marshall, Z., Welch, V., Thomas, J., Brunger, F., Swab, M., Shemilt, I., & Kaposy, C. (2017). Documenting research with transgender and gender diverse people: protocol for an evidence map and thematic analysis. *Systematic Reviews*, 6, Article 35. <https://doi.org/10.1186/s13643-017-0427-5>
20. Modake, D., & Patil, M. (2024). Evaluating Generative AI Applications: Capabilities and Limitations. *SSRN*. <https://doi.org/10.2139/ssrn.5032389>
21. Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & PRISMA Group. (2009). Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *PLoS Medicine*, 6(7), e1000097. <https://doi.org/10.1371/journal.pmed.1000097>
22. Mostafapour, S. et al. (2024). Evaluating Literature Reviews Conducted by Humans Versus ChatGPT: Comparative Study. *JMIR AI*. <https://doi.org/10.2196/56537>

23. Nguyen, A. (2024). Study on the impact of AI-generated clone voices on student performance in listening examinations. *Literacies and Language Education: Research and Practice*, Autumn 2024, 66-77. (English Language Institute, KUIS)
24. Ouzzani, M., Hammady, H., Fedorowicz, Z., & Elmagarmid, A. (2016). Rayyan – a web and mobile app for systematic reviews. *Systematic Reviews*, 5, Article 210. <https://doi.org/10.1186/s13643-016-0384-4>
25. Page M J, McKenzie J E, Bossuyt P M, Boutron I, Hoffmann T C, Mulrow C D et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews *BMJ* 2021; 372 :n71 doi:10.1136/bmj.n71 PRISMA 2020, <https://www.prisma-statement.org/prisma-2020>
26. Pope, C., Mays, N., & Popay, J. (2007). *Synthesizing qualitative and quantitative health evidence: A guide to methods*. McGraw-Hill Education.
27. Radford, A., Wu, J., Child, R., et al. (2019). Language models are unsupervised multitask learners. *OpenAI blog*. https://cdn.openai.com/better-language-models/language_models_are_unsupervised_multitask_learners.pdf
28. Ramamoorthy, L. (2025). Evaluating Generative AI: Challenges, Methods, and Future Directions. *IJFMR*. <https://doi.org/10.36948/ijfmr.2025.v07i01.37182>
29. Russell, S., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.
30. Torraco, R. J. (2005). Writing integrative literature reviews: Guidelines and examples. *Human Resource Development Review*, 4(3), 356–367. <https://doi.org/10.1177/1534484305278283>
31. Tsafnat, G., Glasziou, P., Choong, M. K., Dunn, A., Galgani, F., & Coiera, E. (2014). Systematic review automation technologies. *Systematic Reviews*, 3, 74. <https://doi.org/10.1186/2046-4053-3-74>
32. van de Schoot, R., de Bruin, J., Schram, R., Zahedi, P., de Boer, J., Weijdemans, F., Kramer, B., Huijts, M., Hoogerwerf, M., Ferdinands, G., Harkema, A., Willemsen, J., Ma, Y., Fang, Q., Hindriks, S., Tummers, L., & Oberski, D. L. (2021). *An open source machine learning framework for efficient and transparent systematic reviews*. *Nature Machine Intelligence*, 3(2), 125–133. <https://doi.org/10.1038/s42256-020-00287-7>
33. Van Eck, N. J., & Waltman, L. (2010). Software survey: VOSviewer, a computer program for bibliometric mapping. *Scientometrics*, 84(2), 523–538.
34. Vaswani, A., Shazeer, N., Parmar, N., et al. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998–6008. <https://arxiv.org/abs/1706.03762>
35. Webster, J., & Watson, R. T. (2002). Analyzing the past to prepare for the future: Writing a literature review. *MIS Quarterly*, 26(2), xiii–xxiii. <https://www.jstor.org/stable/4132319>
36. Wu, Wenxue; Ji, Yi; Wang, Zilan; Wu, Xiaoxiao; Li, Jiaxuan; Gu, Feng; Chen, Zhouqing; & Wang, Zhong. (2023). The FDA-approved anti-amyloid- β monoclonal antibodies for the treatment of Alzheimer's disease: a systematic review and meta-analysis of randomized controlled trials. *European Journal of Medical Research*, 28, Article 544. <https://doi.org/10.1186/s40001-023-01512-w>
37. Zhang, L., Liu, X., & Wei, X. (2025). *Generative Artificial Intelligence Literacy: Scale Development and Its Effect on Job Performance*. *Behavioral Sciences*, 15(6), 811. <https://doi.org/10.3390/bs15060811>