



© Видавець Інститут кібернетики імені В.М. Глушкова НАН України, 19.06.2026

Це – препринт відкритого доступу за ліцензією CC BY-NC-ND 4.0

<https://creativecommons.org/licenses/by-nc-nd/4.0/legalcode.uk>

Автор підтверджує, що даний препринт відповідає всім вимогам Договору приєднання

https://arxiv.nas.gov.ua/public/accesion_agreement.html

Основи побудови гібридної онтолого-керованої системи опрацювання наукових публікацій

Петренко Микола¹ [ORCID 000-0000-0000-6440-0706]

¹ Інститут кібернетики імені В.М. Глушкова НАН України, проспект Академіка Глушкова, 40, Київ, 03187, Україна

petrng@ukr.net

Анотація. Розглянуто проблему побудови гібридної системи онтолого-керованого опрацювання наукових публікацій, у якій поєднуються структуроване сховище даних, локальні OWL-подання окремих статей, канонічний корпусний граф знань і природномовний інтерфейс як інтелектуальний компонент доступу до інформаційних ресурсів системи. Основна науково-технічна проблема полягає в тому, що більшість систем опрацювання наукових публікацій забезпечує або бібліографічний пошук, або повнотекстовий доступ, але не підтримує цілісного переходу від природномовного тексту статті до формально верифікованого знання, придатного для логічного виведення, пояснення результатів і міждокументної інтеграції. Унаслідок цього зміст наукової публікації часто залишається представленим на рівні неструктурованого тексту, а не у формі контрольованих семантичних об'єктів, пов'язаних із онтологією предметної галузі.

Природномовний інтерфейс забезпечує приймання, інтерпретацію та формальне перетворення запитів користувача, сформульованих природною мовою, у запити до відповідних інформаційних ресурсів і сервісів системи. Запропоновано підхід, за яким базовою одиницею інтеграції між текстом наукової статті, її формалізованим онтологічним описом і глобальним семантичним поданням виступає елементарний сенс. На відміну від традиційного трактування у вигляді ізольованої RDF-трійки, елементарний сенс інтерпретується як спеціалізований інформаційний об'єкт, що пов'язує просте речення, компоненти суб'єкта, предиката й об'єкта, метадані походження, рішення щодо відображення, ступінь упевненості та статус валідації.

Обґрунтовано багаторівневу архітектуру системи, яка охоплює рівень первинних джерел, документний рівень локального подання статті, рівень елементарних сенсів, рівень канонічного корпусного графа знань і рівень походження та контролю якості. Показано доцільність використання іменованих графів для збереження локального контексту окремих публікацій, сховища трійок – для семантичного зберігання, логічного виведення та SPARQL-доступу, а структурованого сховища даних – для керування життєвим циклом артефактів, версіонуванням, процесом опрацювання та журналами оброблення. Практична цінність запропонованого підходу полягає у формуванні цілісної моделі інтеграції текстового опрацювання, онтологічного подання, формальної валідації та природномовного доступу до знань у гібридному інформаційному середовищі.

Ключові слова: інженерія знань, семантичні веб-технології, онтологія, база знань, граф знань, елементарний сенс, природномовний інтерфейс, наукові публікації

1. Вступ

У роботі представлено багаторівневу архітектуру гібридної системи онтолого-керованого опрацювання наукових публікацій, яка охоплює рівень первинних джерел, документний рівень локального подання статті, рівень елементарних сенсів, рівень канонічного корпусного графа знань і рівень походження та контролю якості. Показано доцільність використання іменованих графів для збереження локального контексту окремих публікацій, сховища трійок – для семантичного зберігання, логічного виведення та SPARQL-доступу [1–5], а структурованого сховища даних – для керування життєвим циклом артефактів, версіонуванням, процесом опрацювання та журналами оброблення. Запропоновано мінімальну OWL-модель класів і властивостей для зв'язування сутностей типу *Стаття*, *Розділ*, *Складне речення*, *Просте речення*, *Елементарний сенс*, *Рішення щодо відображення*, *Звіт валідації* і *канонічних галузевих об'єктів*.

Матеріал статті ґрунтується на попередніх дослідженнях авторів, викладених, зокрема, у працях [6–11]. Зокрема, в [10] розглянуто онтолого-кероване опрацювання трансдисциплінарних предметних знань, що є методологічною основою для побудови корпусних графів знань і міждокументної інтеграції наукової інформації. В [11] запропоновано онтолого-орієнтований комплекс семантичного опрацювання наукових даних, що безпосередньо пов'язаний із завданнями формального подання, пошуку та інтерпретації змісту наукових публікацій.

Особливу увагу приділено правилам інтеграції Excel-розмітки простих речень із локальними OWL-графами статей та канонічним графом знань. Показано, що така інтеграція має здійснюватися поетапно: від формування елементарних сенсів і локального зіставлення URI – до SHACL-валідації (Shapes Constraint Language), онтологічного узгодження, логічного виведення та матеріалізації лише перевірених фактів у корпусному графі знань. Обґрунтовано необхідність розмежування локальних і канонічних сутностей, а також вираженого застосування відношень тотожності й семантичної близькості під час міжстаттєвої нормалізації наукових понять.

Запропоновано підхід до класифікації природномовних запитів до такої системи за типами виконавчих механізмів. Показано, що частина запитів безпосередньо транслюється у SPARQL-запити до графа знань, частина – у SQL-запити до структурованого сховища даних, а перевірка структурних і семантичних обмежень виконується засобами SHACL. Це дає підстави розглядати природномовний інтерфейс як інтеграційний інтелектуальний компонент системи, що забезпечує маршрутизацію намірів користувача між бібліографічним, документним, семантичним, аналітичним і операційним рівнями системи.

Запропонований підхід створює передумови для побудови систем пояснення щодо доступу до змісту наукових публікацій, у яких результати пошуку й аналітики можуть бути пов'язані з конкретними реченнями статті, елементарними сенсами, правилами

відображення, джерелами походження й ланцюгами логічного виведення. Практична цінність підходу полягає у формуванні цілісної моделі інтеграції текстового опрацювання, онтологічного подання, формальної валідації та природномовного доступу до знань у гібридному інформаційному середовищі.

Запропонований підхід відрізняється від традиційних бібліографічних і повнотекстових систем тим, що поєднує рівень елементарних сенсів, локальні OWL-подання окремих статей, канонічний корпусний граф знань, механізми SHACL-валідації, моделі походження даних PROV (provenance – походження даних) та природномовний інтерфейс доступу до інформаційних ресурсів.

Мета і завдання дослідження

Метою роботи є розроблення моделі, архітектури та методичних засад гібридної системи онтолого-керованого опрацювання наукових публікацій, яка забезпечує інтеграцію текстового подання статей, локальних OWL-графів, рівня елементарних сенсів, канонічного корпусного графа знань і природномовного доступу до інформаційних ресурсів системи.

Завданнями дослідження є:

1. Формалізувати роль елементарного сенсу як одиниці міжрівневого зв'язування;
2. Визначити архітектурні рівні системи;
3. Описати механізм інтеграції Excel-розмітки з OWL-поданням;
4. Обґрунтувати використання SHACL, PROV і SPARQL;
5. Класифікувати природномовні запити за типами виконавчих механізмів;
6. Визначити умови обґрунтованості й контролю якості результатів.

2. Пов'язані роботи

У сучасних дослідженнях, присвячених онтолого-керованому опрацюванню наукової інформації, доцільно виокремити два взаємодоповнювальні сегменти – український і англomовний.

Український сегмент представлений працями, у яких семантичні технології, онтологічне моделювання та засоби Semantic Web розглядаються як інструменти підтримки професійної діяльності, структурованого подання знань і побудови інтелектуальних інформаційних систем [12–16]. У цих роботах увагу зосереджено на використанні онтологій для формалізації предметної області, підвищення прозорості подання знань, семантичної інтеграції ресурсів і підтримки тематичного пошуку. Водночас у більшості таких досліджень основну увагу зосереджено або на прикладному використанні семантичних технологій у конкретних доменах, або на загальних питаннях онтологічного представлення знань, тоді як проблема побудови цілісної гібридної системи, що поєднує структуроване сховище даних, локальні OWL-подання статей, канонічний корпусний граф знань, механізми валідації та природномовний інтерфейс, наразі висвітлена обмежено [12–16].

Англomовний сегмент досліджень є значно ширшим і охоплює кілька взаємопов'язаних напрямів. Перший із них пов'язаний з навчанням онтологій (*ontology learning*) із текстів,

у межах якого розроблено підходи до напіваавтоматичної побудови онтологій на основі статистичних, лінгвістичних і знаннє-орієнтованих процедур [17–19]. Другий напрям становлять роботи з онтолого-керованого видобування інформації (*ontology-driven information extraction*), у яких показано, що поєднання онтологічних моделей із дискурсивним і семантичним аналізом тексту підвищує якість видобування фактів і встановлення змістових відношень [20, 21]. Третій напрям охоплює роботи, присвячені графам знань, де розглядаються формальні моделі подання, інтеграції, логічного виведення та використання графових структур у наукових і прикладних системах [1, 2]. Четвертий напрям представлений працями із запитаннями-відповідями над пов'язаними даними (*question answering over Linked Data*) та перетворення природномовних запитів у SPARQL-запити, у яких досліджуються інтерактивні засоби побудови SPARQL-запитів, системи запитування до баз знань природною мовою над RDF-даними, а також нейромережеві та гібридні підходи до перетворення природномовних запитів у формальні запити до графів знань [22–26]. Окрему роль у цьому контексті відіграють стандартизовані набори даних для оцінювання систем *question answering*, зокрема LC-QuAD і LC-QuAD 2.0, які забезпечують порівняльний аналіз рішень для доступу до знань природною мовою [27, 28].

Таким чином, аналіз пов'язаних досліджень показує, що в українському сегменті переважають праці, орієнтовані на прикладне використання семантичних технологій і онтологій у конкретних інформаційних системах, тоді як в англomовному сегменті сформовано розвинену методологічну й інструментальну базу для *ontology learning*, *ontology driven information extraction*, графів знань (*knowledge graphs*) і природномовного доступу до структурованих знань. У цьому контексті запропонований у статті підхід орієнтований на інтеграцію кількох дослідницьких ліній – онтологічного подання наукових текстів, рівня елементарних сенсів, канонічного корпусного графа знань, процедур SHACL-валідації та природномовної маршрутизації запитів між різними функціональними рівнями гібридної системи.

Для уточнення місця запропонованого підходу серед наявних засобів опрацювання наукових публікацій доцільно порівняти традиційні бібліографічні системи, повнотекстові пошукові системи та гібридну систему онтолого-керованого опрацювання наукової інформації. Таке порівняння дає змогу показати, що відмінність запропонованої системи полягає не лише у використанні онтологій або графів знань, а у формуванні цілісного переходу від текстового фрагмента наукової статті до формально верифікованого, пояснюваного та придатного для логічного виведення знання (табл. 1).

Як видно з табл. 1, традиційні бібліографічні та повнотекстові системи забезпечують доступ переважно до метаданих або текстових фрагментів, але не підтримують повноцінного переходу до формально представленого знання. Запропонована гібридна система відрізняється тим, що поєднує документне подання, рівень елементарних сенсів, локальні OWL-графи, канонічний граф знань, механізми валідації та природномовний інтерфейс. Це створює підстави для семантичного пошуку, логічного виведення, пояснення результатів і міждокументної інтеграції знань.

ТАБЛИЦЯ 1. Порівняння підходів до опрацювання наукових публікацій

Критерій	Традиційна бібліографічна система	Повнотекстова пошукова система	Запропонована гібридна система
Основний об'єкт пошуку	Метадані	Текстові фрагменти	Елементарні сенси та канонічні знання
Семантична інтерпретація	Обмежена	Часткова	Онтолого-керована
Підтримка логічного виведення	Немає	Немає	Є
Обґрунтованість результатів	Низька	Обмежена	Через речення, сенс, правило, джерело
Контроль якості	Ручний або відсутній	Обмежений	SHACL + PROV + валідація
Природномовний доступ	Пошуковий	Пошуковий	Маршрутизація до SQL/SPARQL/API

3. Модель подання та архітектура гібридної системи

Гібридну систему онтолого-керованого опрацювання наукових публікацій доцільно подати у вигляді 9-компонентного кортежу:

$$S = \langle D, O^L, O^C, E, M, V, P, Q, R \rangle$$

де D – множина наукових документів; O^L – множина локальних OWL-подань окремих статей; O^C – канонічна корпусна онтологія або граф знань; E – множина елементарних сенсів; M – множина правил відображення локальних сутностей у канонічні; V – механізми SHACL-валідації; P – модель фіксації походження, історії формування та трансформації інформаційних об'єктів системи, побудована відповідно до стандарту PROV/PROV-O; Q – множина природномовних запитів користувача; R – множина виконавчих SPARQL механізмів, SQL, зовнішні сервіси та адміністративні процедури.

Функціонально-рівнева організація гібридної системи онтолого-керованого опрацювання наукових публікацій подана на рис. 1.

Для побудови природномовного інтерфейсу до гібридної системи онтолого-керованого опрацювання наукових публікацій доцільно розглядати множину користувацьких запитів не як однорідний набір звернень до єдиного інформаційного ресурсу, а як структурований комплекс запитів, адресованих до різних рівнів подання даних і знань. Такий підхід зумовлений тим, що в межах єдиної системи співіснують щонайменше кілька функціонально відмінних рівнів: рівень структурованого сховища даних, бібліографічних метаданих, документний рівень локального подання статей, семантичний рівень елементарних сенсів і канонічних онтологічних сутностей, аналітичний рівень агрегованих і бібліометричних показників, а також операційно-сервісний рівень, пов'язаний з історією взаємодії, адмініструванням і зовнішніми процедурами оброблення. У зв'язку з цим природномовні запити доцільно розподіляти за п'ятьма функціональними рівнями, кожен з яких характеризується власним типом

даних, набором типових сценаріїв, формальним механізмом виконання та роллю в загальній архітектурі системи.




Рис. 1 Архітектура гібридної системи онтолого-керованого опрацювання наукових публікацій

Перший рівень утворюють *запити до бібліографічних даних та метаданих*, орієнтовані на пошук і відбір публікацій за формальними характеристиками. До цього рівня належать звернення користувача, в яких фігурують такі атрибути, як назва публікації, автор, рік видання, журнал, категорія, ключові слова, DOI, тип публікації, статус відкритого доступу та інші бібліографічні параметри. Запити цього типу є найбільш традиційними для інформаційно-пошукових систем і в загальному випадку не потребують складної онтологічної інтерпретації, якщо не йдеться про нормалізацію варіантів імен авторів, назв видань або тематичних рубрик. Основним джерелом даних тут виступають структуроване сховище даних бібліографічних записів і, за наявності відповідного формалізованого подання, бібліографічна онтологія. З погляду формального виконання такі запити найчастіше транслюються у SQL або в еквівалентні SPARQL-запити до графа метаданих. Саме цей рівень формує базовий рівень доступу до фонду наукових публікацій і забезпечує класичні сценарії фільтрації, сортування та тематичного відбору.

Другий рівень становлять **текстові запити до документів**, у яких об'єктом пошуку є не лише метадані статті, а її внутрішня текстова і композиційна структура. До цього рівня належать запити на пошук повного тексту статей, анотацій, назв розділів, фрагментів абзаців, окремих речень або простих речень, а також запити, пов'язані з виявленням входжень певного терміна чи виразу в межах конкретних частин документа. На відміну від першого рівня, тут уже недостатньо зберігати публікацію як неподільний бібліографічний запис; необхідно мати модель документів, у якій стаття представлена як структурований об'єкт із компонентами типу *Стаття*, *Розділ*, *Параграф*, *Речення*, *Просте речення* та відповідними текстовими властивостями. У цій частині природномовний інтерфейс взаємодіє або з графом статті, або з локальними OWL-поданнями наукових текстів, або з текстовими індексами, інтегрованими з структурованим сховищем даних. Формальне виконання таких запитів найчастіше ґрунтується на SPARQL-запитах до графа документів, інколи – у поєднанні з механізмами повнотекстового пошуку. Таким чином, документно-текстовий рівень забезпечує перехід від суто бібліографічного доступу до доступу до внутрішнього змісту статті як структурованого текстового об'єкта.

Третій рівень формують **семантико-онтологічні запити**, які є найбільш характерними саме для онтолого-керованої системи опрацювання наукових публікацій. У запитах цього типу користувача цікавить уже не просто наявність певного слова в назві чи тексті статті, а змістові відношення між канонічними сутностями предметної галузі: методами, задачами, моделями, наборами даних, метриками, науковими результатами, концептами або твердженнями, виділеними з тексту на рівні елементарних сенсів. Тут запит повинен інтерпретуватися через онтологічні класи, властивості, правила відображення й канонічні URI, а не лише через лексичні збіги. Основним джерелом даних у цьому випадку виступають локальні OWL-графи окремих статей, рівень елементарних сенсів і канонічний корпусний граф знань. Формальним механізмом виконання є SPARQL із використанням онтологічного зіставлення, а за потреби – також процедур логічного виведення. Саме цей рівень забезпечує перехід від пошуку документів до концептуального доступу до знань, що дозволяє системі відповідати на запити про предметний зміст наукових публікацій, зв'язки між поняттями, підтвердження тверджень кількома джерелами та виявлення семантичних відповідностей або суперечностей.

Четвертий рівень становлять **аналітико-бібліометричні запити**, у межах яких користувач звертається до системи не лише з метою пошуку окремих публікацій чи тверджень, а для отримання узагальнених характеристик масиву наукових даних. До цього рівня належать запити на підрахунок кількості публікацій, групування за роками, авторами, журналами чи категоріями, побудову рейтингів, аналіз частот ключових слів, оцінювання динаміки тематичних напрямів, визначення найбільш продуктивних авторів, дослідження мереж співавторства, а також бібліометричні сценарії, пов'язані з цитуванням і впливовістю. На відміну від попередніх рівнів, тут особливого значення набувають агреговані операції, часові зрізи, статистичні функції та іноді графові алгоритми. Джерелами даних є не лише метадані та граф знань, а й спеціалізовані таблиці статистичних показників, журнали

цитувань, зовнішні бібліометричні джерела або аналітичні підсистеми. Формальне виконання таких запитів може спиратися на SQL, SPARQL або на їх поєднання з подальшою обробкою результатів. Отже, аналітико-бібліометричний рівень забезпечує перетворення інформаційної системи з інструмента пошуку на засіб аналітичного дослідження наукового корпусу.

П'ятий рівень доцільно визначити як *операційно-сервісний та адміністративний*, оскільки він охоплює запити, що не зводяться безпосередньо ні до бібліографічного, ні до документно-текстового, ні до семантичного змісту самих публікацій. До цього рівня належать звернення, пов'язані з історією запитів користувача, журналами активності, аудитом змін, валідацією даних, імпортом та експортом, автоматизованим перекладом, зовнішньою синхронізацією, генерацією звітів, прогнозуванням. Особливість цього рівня полягає в тому, що він орієнтований не стільки на представлення наукового знання, скільки на керування життєвим циклом інформаційних артефактів, взаємодією користувачів із системою та сервісними процедурами її функціонування. Основними джерелами даних тут виступають таблиці користувачів, журнали подій, модулі технологічного процесу опрацювання, адміністративні реєстри та зовнішні API. Формально такі запити можуть реалізовуватися засобами SQL, сервісними викликами або спеціалізованими адміністративними сценаріями. При цьому дії, що модифікують, повинні виконуватися лише в межах контрольованого технологічного процесу опрацювання з підтвердженням, аудитом і розмежуванням прав доступу. Унаслідок цього п'ятий рівень відіграє роль інфраструктурного функціонального сегмента системи, який підтримує надійність, керованість і розширюваність усієї системи.

Таким чином, розподіл природномовних запитів за п'ятьма функціональними рівнями дозволяє не лише впорядкувати різноманітні сценарії взаємодії користувача з системою, а й задати чітку відповідність між типом запиту, рівнем подання даних, механізмом інтерпретації та способом виконання. Такий підхід є методологічно важливим для проєктування гібридних онтолого-керованих систем, оскільки забезпечує узгодження між мовним інтерфейсом, структурованим сховищем даних, моделями документів, графом знань і сервісною інфраструктурою. У практичному плані це означає, що природномовний інтерфейс може бути реалізований не як монолітний модуль універсального пошуку, а як інтелектуальний механізм класифікації наміру користувача і маршрутизації запиту до відповідного функціонального рівня системи. Саме така організація створює передумови для побудови пояснюваного, масштабованого й семантично керованого середовища доступу до наукових публікацій і знань, видобутих із них.

У табл. 2 узагальнено відповідність між функціональними рівнями природномовних запитів, типовими позиціями з переліку запитів, джерелами даних і механізмами їх виконання. Список природномовних запитів наведено у додатку.

ТАБЛИЦЯ 2. Розподіл природномовних запитів до системи наукових публікацій за п'ятьма функціональними рівнями

Рівень	Типові природномовні запити	Типові позиції з переліку	Основне джерело даних	Основний механізм виконання
1. Бібліографічні дані та метадані	Пошук публікацій за роком, автором, журналом, категорією, ключовими словами, DOI, типом публікації, доступом	A1.1–A1.13; A4.1–A4.5; A4.8; A6.1–A6.4; A8; A10; A11; A12	Структуроване сховище метаданих	бібліографічна онтологія SQL або SPARQL
2. Документно-текстовий	Пошук за анотаціями, розділами, абзацами, реченнями, повним текстом; витяг структурних фрагментів статті	A1.14–A1.17; A4.7; A9	Граф статей; локальні OWL-графи; текстові поля БД	SPARQL, за потреби гібридно з SQL/ повнотекстовий пошук
3. Семантико-онтологічний	Пошук змістових зв'язків між метаданими, задачами, доменами, сутностями та твердженнями; запити до елементарних сенсів	A4.10; A5.6; а також A1.7, A4.2, A4.7	у разі онтологічної інтерпретації	Елементарні сенси; канонічний граф знань; локальні OWL-подання статей SPARQL з онтологічним відображенням і логічним виведенням
4. Аналітико-бібліометричний	Підрахунок, групування, ранжування, частотний аналіз, рейтинги, цитування, співавторство, тенденції, мережевий аналіз	A2.1–A2.6; A4.6; A4.9; A5.1–A5.5; A5.7–A5.9; B3–B12	Метадані публікацій; статистичні атрибути; журнали цитувань; граф зв'язків авторів	SQL/SPARQL/ SPARQL+SQL, інколи з подальшою обробкою або зовнішнім аналітичним модулем
5. Операційно-сервісний та адміністративний	Історія запитів, аудит, валідація, імпорт/експорт, переклад, звіти, прогнозування, CRUD-операції, масові модифікації	A3.1–A3.3; A7.1–A7.4; A13–A18; B1–B2; B13–B20	Журнали подій; таблиці користувачів; стани процесу опрацювання; зовнішні API; сервісні модулі	SQL, сервісні виклики, контрольований процес опрацювання; для дій модифікування – лише контрольований адміністративний сценарій

Наведений розподіл природномовних запитів за п'ятьма функціональними рівнями показує, що природномовний інтерфейс у гібридній системі повинен розглядатися не як універсальний пошуковий модуль, а як інтелектуальний механізм класифікації користувацького наміру та маршрутизації запиту [22–26] до відповідного інформаційного функціонального сегменту системи. Такий рівневий підхід забезпечує узгодження між бібліографічними

метаданими, документною структурою статей, онтологічно репрезентованими знаннями, аналітичними процедурами та сервісно-операційними функціями системи. В результаті створюється методологічна основа для побудови обґрунтованого, масштабованого та семантично керованого природномовного доступу до корпусу наукових публікацій і знань, видобутих з їхнього змісту.

4. Життєвий цикл опрацювання наукової публікації в гібридній системі

Життєвий цикл опрацювання наукової публікації в запропонованій системі включає такі етапи:

1. Імпорт бібліографічних метаданих і повного тексту статті.
2. Структуризацію документа на розділи, абзаци, речення і прості речення.
3. Формування первинної розмітки елементарних сенсів.
4. Створення локального OWL-графа статті.
5. Зіставлення локальних сутностей із канонічними URI.
6. SHACL-валідацію структурних і семантичних обмежень.
7. Фіксацію походження даних засобами PROV.
8. Логічне виведення та матеріалізацію перевірених фактів.
9. Включення перевірених тверджень до корпусного графа знань.
10. Забезпечення природномовного доступу до отриманих знань.

Припустимо, користувач формулює запит: “Які статті пов’язані з використанням машинного навчання у базах знань?”. На першому етапі природномовний інтерфейс визначає, що запит має семантико-онтологічний характер. Далі виконується зіставлення мовних виразів “машинне навчання” і “бази знань” із відповідними канонічними сутностями графа знань. Після цього формується SPARQL-запит до рівня елементарних сенсів і канонічного графа знань. Результат повертається не лише у вигляді списку статей, а й із посиланнями на конкретні прості речення, елементарні сенси, правила відображення і статус валідації відповідних тверджень.

4. Переваги та обмеження природномовного доступу

Запропонований природномовний інтерфейс до гібридної системи онтолого-керованого опрацювання наукових публікацій має істотні методологічні та функціональні переваги, зумовлені поєднанням структурованого сховища даних, онтологічно узгодженого графа знань, засобів лінгвістичної інтерпретації та механізмів формального перетворення природномовних запитів у виконувані запити до різних рівнів інформаційного середовища. На відміну від традиційних пошукових систем, орієнтованих переважно на лексичне зіставлення рядків або пошук за окремими бібліографічними полями, запропонований підхід забезпечує багаторівневу інтерпретацію запиту користувача. У межах такої інтерпретації один і той самий природномовний вираз може бути співвіднесений з бібліографічними метаданими, структурою документа, елементарними сенсами, канонічними сутностями галузевої онтології, журналами активності користувачів або сервісними процедурами оброблення даних.

Першою принциповою перевагою запропонованого підходу є його семантична керованість. Завдяки тому, що природномовний запит інтерпретується не безпосередньо на рівні текстових збігів, а через систему онтологічно визначених класів, властивостей і правил відображення, з'являється можливість переходу від поверхневого пошуку до змістовного опрацювання наукових публікацій. Це особливо важливо для роботи з науковими текстами, у яких одна й та сама концептуальна сутність може виражатися різними термінами, а одне й те саме слово – позначати різні поняття залежно від контексту. Використання локальних OWL-подань статей, канонічного корпусного графа знань і проміжного рівня елементарних сенсів створює підстави для контекстно чутливої нормалізації значень і, відповідно, для більш точного встановлення відповідності між запитом і знанням, що міститься в корпусі.

Другою суттєвою перевагою є інтегративний характер системи. Природномовний інтерфейс функціонує не як окремий модуль пошуку, а як рівень, що координує кілька типів інформаційних ресурсів. У межах одного інтерфейсу можуть бути об'єднані бібліографічні дані про публікації, структурні елементи текстів, онтологічно формалізовані знання, результати валідації, дані про версії, а також журнали взаємодії користувача із системою. Це означає, що користувачеві не потрібно окремо формувати SQL-запити до бази даних, SPARQL-запити до *triple store* або звернення до спеціалізованих сервісів; достатньо сформулювати змістовно зрозумілий природномовний запит, після чого система виконує його маршрутизацію до відповідного виконавчого функціонального сегменту системи. Така інтеграція суттєво розширює функціональну придатність інформаційної системи, перетворюючи її з бібліографічного сховища на інтелектуальне середовище опрацювання наукових знань.

Третьою перевагою є пояснюваність одержаних результатів. Оскільки в архітектурі системи елементарний сенс, канонічний факт і їхні походження не зливаються в одну нерозрізнену структуру, кожна відповідь може бути супроводжена посиланнями на джерельну статтю, конкретний фрагмент тексту, відповідний рядок розмітки, використане правило відображення та результат формальної перевірки. Поєднання стандарту подання походження даних PROV, обмежень цілісності, заданих мовою SHACL (SHACL-обмежень), і онтологічного виведення [3–5] робить можливим не лише отримання відповіді, а й реконструкцію шляху її формування. Для наукових і аналітичних застосувань це має принципове значення, оскільки дозволяє оцінювати надійність одержаних висновків, локалізувати джерела помилок і забезпечувати відтворюваність процедур опрацювання знань.

Четвертою перевагою є масштабованість концептуальної моделі. Запропонована архітектура дозволяє поступово нарощувати функціональні можливості системи без зміни її логічної цілісності. На початкових етапах реалізації природномовний інтерфейс може підтримувати запити бібліографічного пошуку, фільтрації, сортування та базової агрегації. Надалі, у міру наповнення графа знань і ускладнення онтологічної моделі, стає можливим перехід до змістовних запитів щодо методів, задач, корпусів, метрик, типів експериментів, а також підтверджень і суперечностей між твердженнями різних статей. Така еволюційність архітектури добре узгоджується з вимогами до сучасних дослідницьких платформ, які

розвиваються поступово і водночас мають зберігати сумісність між попередніми й новими рівнями подання знань.

Разом із тим запропонований підхід має і низку обмежень, які необхідно враховувати як на етапі проектування, так і під час практичної реалізації системи. Передусім, ефективність природномовного інтерфейсу істотно залежить від якості онтологічної моделі, ступеня структурованості корпусу статей та повноти процедур відображення між мовними виразами і формальними сутностями графа знань. Якщо галузева онтологія є неповною, неузгодженою або не охоплює достатньо репрезентативну термінологію предметної галузі, інтерпретація запитів може виявитися надто загальною, неоднозначною або хибною. Аналогічно, низька якість початкової Excel-розмітки означає наявність помилок у декомпозиції речень, визначенні компонентів $\langle S, P, O \rangle$, нормалізації термінів, фіксації джерела та зіставленні локальних сутностей із URI. Такі помилки можуть призводити до формування некоректних елементарних сенсів і накопичення похибок під час подальшої OWL-формалізації, SHACL-валідації, логічного виведення та включення фактів до канонічного графа знань.

Окремим обмеженням є багатозначність природної мови. Навіть за наявності розвинутої онтологічної моделі далеко не всі природномовні запити можуть бути однозначно зіставлені з єдиним формальним представленням [22–26]. Особливо це стосується запитів із неповною специфікацією умов, прихованими пресупозиціями, еліптичними конструкціями або змішаними критеріями пошуку й аналітики. У таких випадках система повинна або формувати кілька гіпотез інтерпретації, або застосовувати механізми уточнення наміру користувача. Отже, повноцінний природномовний інтерфейс не може спиратися лише на статичні правила зіставлення; він потребує поєднання онтологічного підходу з компонентами керування неоднозначністю, контекстного аналізу та, можливо, спеціалізованих мовних моделей.

Ще одним обмеженням є неоднорідність виконавчих механізмів. Як показано в попередньому аналізі типів запитів, не всі природномовні запити можуть бути зведені до єдиного формального механізму. Частина з них компілюється у SPARQL-запити до графа знань, частина – у SQL-запити до структурованого сховища даних, частина вимагає доступу до зовнішніх сервісів [22–26], а частина повинна виконуватися лише в межах контрольованого адміністративного процесу опрацювання. Це означає, що природномовний інтерфейс у такій системі повинен виконувати не лише функцію лінгвістичного аналізатора, а й функцію диспетчера, який класифікує намір користувача, визначає тип операції, обирає допустимий маршрут виконання і контролює коректність переходу між інформаційними рівнями. Саме така функціональна сегментація системи робить систему потужною, але водночас підвищує складність її реалізації та супроводу. Така багаторівнева маршрутизація прямо впливає з попередньо запропонованої класифікації природномовних запитів.

Істотним практичним обмеженням є також необхідність контролю небезпечних запитів або запитів, що модифікують вихідну інформацію. Запити на зміну, видалення, масове злиття, автоматичний переклад або зовнішню синхронізацію даних не повинні виконуватися безпосередньо на підставі одного лише природномовного формулювання. Для таких запитів

потрібен окремий режим підтвердження, аудит змін, фіксація прав доступу та можливість “відкату”. Інакше природномовний інтерфейс може перетворитися із засобу інтелектуального доступу до знань на джерело ризику для цілісності інформаційної системи. Отже, у межах гібридної архітектури слід принципово розмежовувати інформаційні запити, аналітичні запити і керуючі операції.

5. Перспективи розвитку гібридної системи онтолого-керованого опрацювання наукових публікацій

Перспективи розвитку запропонованого підходу пов’язані насамперед із *поглибленням семантичного рівня інтерпретації*. Одним із найперспективніших напрямів є перехід від оброблення окремих бінарних тверджень до підтримки складних n -арних наукових фактів, подій і ситуацій [1, 2]. Це дозволить коректно репрезентувати результати експериментів, зв’язки між методами, наборами даних, задачами й метриками, а також будувати запити, орієнтовані на виявлення закономірностей у науковому корпусі. Розвиток у цьому напрямі фактично означатиме перехід від системи пошуку за статтями до системи концептуального аналізу експериментального знання.

Іншим перспективним напрямом є *інтеграція компонентів інтелектуальної нормалізації та розв’язання неоднозначності*. Йдеться про автоматичне або напівавтоматичне зіставлення термінів, що мають різні поверхневі форми, з канонічними сутностями предметної галузі, а також про виявлення випадків, у яких одна й та сама текстова форма відповідає різним концептам. Для корпусу наукових публікацій це особливо актуально, оскільки термінологія є варіативною, а відмінності між суміжними поняттями нерідко мають методологічний характер. Поєднання онтологічних обмежень, статистичних критеріїв і мовних моделей може істотно підвищити якість такого зіставлення.

Перспективним є *розвиток обґрунтованих сценаріїв NLP→SPARQL/SQL* [22–26]. У завершені варіанті система повинна не просто повертати результат запиту, а надавати користувачеві формалізовану реконструкцію того, як саме природномовний вираз було перетворено на послідовність підзапитів, фільтрів, умов, онтологічних зіставлень і процедур виведення. Для наукового середовища це є особливо цінним, оскільки робить інтерфейс не лише інструментом доступу до знань, а й інструментом прозорої наукової аргументації.

Окремо слід відзначити перспективу розвитку сервісної підсистеми, що виходить за межі традиційного пошуку. До таких сервісів можуть належати автоматизований переклад анотацій, побудова аналітичних звітів, виявлення тенденцій у динаміці публікацій, інтеграція із зовнішніми бібліометричними джерелами та підтримка прогнозних сценаріїв. Однак такі можливості мають розглядатися не як заміна базового онтологічного ядра, а як надбудова над ним. Саме наявність структурованого графа знань, узгодженого з рівнем документів та бібліографічним рівнем, створює умови для коректного включення таких сервісів у єдину архітектуру.

Отже, подальший розвиток гібридної системи онтолого-керованого опрацювання наукових публікацій доцільно пов’язувати з поглибленням семантичного рівня подання знань, підтримкою складних n -арних наукових фактів, удосконаленням процедур нормалізації та

розв'язання неоднозначності, розвитком пояснюваних сценаріїв *NLP*→*SPARQL/SQL* і розширенням сервісної підсистеми. Такі напрями розвитку забезпечують перехід від системи пошуку наукових публікацій до інтегрованого середовища семантичного аналізу, валідації та пояснюваного доступу до знань.

6. Оцінювання якості гібридної системи онтолого-керованого опрацювання наукових публікацій

Оцінювання якості гібридної системи онтолого-керованого опрацювання наукових публікацій доцільно здійснювати з урахуванням її багаторівневої архітектури, у якій поєднуються структуроване сховище даних, локальні OWL-подання статей, рівень елементарних сенсів, канонічний корпусний граф знань, механізми SHACL-валідації, модель походження даних на основі PROV і природномовний інтерфейс доступу до інформаційних ресурсів. Тому якість такої системи не може бути зведена лише до точності пошуку або швидкодії виконання запитів, вона має оцінюватися за сукупністю семантичних, функціональних, технологічних і пояснювальних критеріїв.

- *Семантичні критерії* – точність виділення елементарних сенсів, коректність зіставлення локальних сутностей із канонічними URI, повнота онтологічного подання, узгодженість графа знань.
- *Функціональні критерії* – здатність системи виконувати бібліографічні, документно-текстові, семантико-онтологічні, аналітико-бібліометричні та операційно-сервісні запити.
- *Критерії валідації та контролю якості* – частка тверджень, що пройшли SHACL-перевірку, кількість виявлених порушень обмежень, коректність матеріалізації фактів у канонічному графі знань.
- *Критерії обґрунтованості* – можливість пов'язати відповідь системи з конкретною статтею, простим реченням, елементарним сенсом, правилом відображення, результатом валідації та джерелом походження.
- *Технологічні критерії* – час виконання *SQL/SPARQL*-запитів, масштабованість RDF-сховища, підтримка версіонування, журналювання операцій і стабільність роботи при збільшенні корпусу публікацій.

Отже, оцінювання якості запропонованої системи має бути комплексним і враховувати не лише результативність пошуку, а й коректність переходу від природномовного тексту до формалізованого знання, якість онтологічного зіставлення, надійність валідації, відтворюваність походження даних і пояснюваність отриманих результатів. Саме така багатокритеріальна оцінка відповідає гібридному характеру системи та дозволяє визначити її придатність для інтелектуального опрацювання корпусів наукових публікацій.

7. Висновки

У роботі запропоновано основи побудови гібридної системи онтолого-керованого опрацювання наукових публікацій, у якій поєднуються структуроване сховище даних, OWL-подання статей, канонічний граф знань і природномовний інтерфейс доступу до інформаційних ресурсів. На відміну від традиційних підходів, орієнтованих переважно на зберігання бібліографічних метаданих або на повнотекстовий пошук, запропонована модель

забезпечує багаторівневе подання наукового документа як джерела структурованого, семантично інтерпретованого та формально перевірюваного знання.

Ключовим результатом дослідження є обґрунтування ролі елементарного сенсу як базової одиниці міжрівневого зв'язування між природномовним фрагментом статті, її локальним OWL-поданням і глобальним корпусним графом знань. Показано, що елементарний сенс доцільно трактувати не як ізольовану RDF-трійку, а як спеціалізований інформаційний об'єкт, який містить компоненти суб'єкта, предиката й об'єкта, пов'язується з конкретним простим реченням, зберігає походження, параметри відображення, оцінку впевненості та статус валідації. Саме таке трактування забезпечує збереження контексту, підтримку пояснюваності, можливість інкрементального уточнення інтерпретації та коректний перехід від мовної форми до формалізованого знання.

Сформовано багаторівневу модель інтеграції, у якій розрізняються рівень джерел, рівень окремої статті, рівень елементарних сенсів, рівень канонічного графа знань, інтегрованого на основі множини статей та рівень походження, пояснення й контролю якості. Така архітектура дозволяє, з одного боку, зберігати локальний контекст кожної публікації у вигляді іменованого графа, а з іншого – виконувати нормалізацію між статтями, канонізацію сутностей, логічне виведення та глобальний семантичний пошук. Обґрунтовано доцільність використання іменованих графів для розмежування контекстів документів, сховища трійок – для зберігання онтологічних структур і результатів виведення, а структурованого сховища даних – для підтримки життєвого циклу артефактів, керування технологічним процесом опрацювання, версіями та журналами оброблення.

Запропоновано мінімальну OWL-модель класів і властивостей, достатню для зв'язування сутностей типу *Стаття*, *Розділ*, *Складне речення*, *Просте речення*, *Елементарний сенс*, *Рішення щодо відображення*, *Звіт валідації* і канонічних галузевих об'єктів та канонічних предметних класів. Показано, що така модель створює формальну основу для відображення рядків Excel-розмітки в ABox-структури, подальшої SHACL-валідації, логічного узгодження з TBox та матеріалізації лише тих фактів, які пройшли перевірку і можуть бути включені до глобального графа знань. Окремо обґрунтовано необхідність розмежування локальних і канонічних URI, а також виваженого використання відношень тотожності й близької відповідності при інтеграції між статтями наукових понять.

Важливим результатом є також класифікація природномовних запитів до такої системи за типами виконавчих механізмів. Показано, що частина запитів безпосередньо компілюється у SPARQL, частина – у SQL до структурованого сховища даних, частина потребує звернення до зовнішніх сервісів, а запити на зміну даних мають виконуватися лише в межах контрольованого адміністративного процесу опрацювання. Це дає підстави розглядати природномовний інтерфейс не як окремий модуль пошуку, а як інтелектуальний рівень маршрутизації, який класифікує наміри користувача, спрямовує запит до відповідного виконавчого механізму системи і забезпечує узгоджену взаємодію між семантичним, документним, аналітичним та операційним рівнями системи.

Показано, що поєднання онтологічного опису, SHACL-обмежень, PROV-моделей, інкрементального логічного виведення та механізмів природномовної інтерпретації створює підґрунтя для обґрунтованого доступу до змісту наукових публікацій. У такому середовищі користувач може формулювати запити не лише до метаданих статті, а й до її внутрішньої структури, елементарних сенсів, предметних тверджень, відповідностей між статтями, підтверджень і суперечностей. Отже, система переходить від рівня бібліографічного пошуку до рівня семантичного опрацювання знань, що особливо важливо для дослідницьких і аналітичних сценаріїв.

Разом із тим встановлено, що ефективність запропонованого підходу істотно залежить від повноти та узгодженості предметної онтології, якості первинної розмітки, ступеня структурованості статей і наявності засобів розв'язання неоднозначності природної мови. Тому подальший розвиток системи доцільно пов'язувати з удосконаленням процедур нормалізації термінів, автоматизованого та експертного зіставлення локальних і канонічних сутностей, підтримкою n -арних наукових фактів, а також із побудовою пояснюваного функціонального сегменту системи $NLP \rightarrow SPARQL/SQL$ для гібридних інформаційних середовищ.

Отже, запропонований підхід формує теоретичне і технологічне підґрунтя для створення гібридних онтолого-керованих систем нового покоління, призначених для інтеграції, накопичення, валідації та інтелектуального опрацювання знань, видобутих із корпусів наукових публікацій. Його практична цінність полягає у створенні цілісної моделі, що поєднує лінгвістичне видобування знань, формальне онтологічне подання, контроль якості, логічне виведення та природномовний доступ до результатів опрацювання.

Перелік посилань

- [1] Hogan A., Blomqvist E., Cochez M. et al. Knowledge Graphs. ACM Computing Surveys. 2021. Vol. 54, No. 4. Art. 71. [DOI: 10.1145/3447772](https://doi.org/10.1145/3447772).
- [2] Hogan A. Knowledge graphs: Research directions. In: Reasoning Web 2020. LNCS 12258. Springer, 2020. P. 223–253. [DOI: 10.1007/978-3-030-60067-9_8](https://doi.org/10.1007/978-3-030-60067-9_8).
- [3] W3C OWL Working Group. OWL 2 Web Ontology Language: Document Overview (Second Edition). W3C Recommendation. 11 December 2012. <https://www.w3.org/TR/owl-overview/>
- [4] Knublauch H., Kontokostas D. Shapes Constraint Language (SHACL). W3C Recommendation. 20 July 2017. <https://www.w3.org/TR/shacl/>
- [5] Lebo T., Sahoo S., McGuinness D. PROV-O: The PROV Ontology. W3C Recommendation. 30 April 2013. <https://www.w3.org/TR/prov-o/>
- [6] M. Petrenko, E. Cohn, O. Shchurov, K. Malakhov, "Ontology-Driven Computer Systems: Elementary Senses in Domain Knowledge Processing," South Afr. Comput. J. 35(2), 127–144 (2023). <https://doi.org/10.18489/sacj.v35i2.17445>
- [7] M. G. Petrenko, O. V. Palagin, M. O. Boyko, S. M. Matveyshyn, "Knowledge-Oriented Tool Complex for Developing Databases of Scientific Publications and Taking into Account Semantic Web Technology," Control Systems and Computers, 2022, Issue 3 (299), 11–28. <https://doi.org/10.15407/csc.2022.03.011>

- [8]] Palagin, O., Petrenko, M. and Boyko, M. (2026) “An ontology-driven method for processing scientific texts for the automatic interpretation of structurally complex natural language user queries”, International Scientific Technical Journal "Problems of Control and Informatics", 71(3), pp. 80–94. <https://doi.org/10.34229/1028-0979-2026-3-6>
- [9] Palagin O., Petrenko M., Malakhov K. Challenges and Role of Ontology Engineering in Creating the Knowledge Industry: A Research-Related Design Perspective. Cybernetics and Systems Analysis. 2024. Vol. 60, No. 4. P. 633–645. DOI: [10.1007/s10559-024-00702-6](https://doi.org/10.1007/s10559-024-00702-6)
- [10] Oleksandr Palagin et al. 2023. *Ontology-Driven Processing of Transdisciplinary Domain Knowledge*. Iowa State University Digital Press, P.189. <https://doi.org/10.31274/isudp.2023.140>.
- [11] Oleksandr Palagin, Mykola Petrenko, Mykola Boyko. Ontology-related Complex for Semantic Processing of Scientific Data. Proceedings of the 13th International Scientific and Practical Programming Conference UkrPROG 2022. Kyiv, Ukraine, October 11–12, 2022. URL: <https://ceur-ws.org/Vol-3501/s26.pdf>.
- [12] Rogushina J.V., Gladun A.Y., Anishchenko O.V., Pryima S.M. Semantic technologies as a tool of information support for professionalization of andragogues. Problems in Programming. 2024. No. 2–3. P. 441–448. DOI: [10.15407/pp2024.02-03.441](https://doi.org/10.15407/pp2024.02-03.441)
- [13] Rogushina J., Pryima S. Use of ontologies and semantic web to provide for the transparency of qualifications frameworks. Eastern-European Journal of Enterprise Technologies. 2017. DOI: [10.15587/1729-4061.2017.92815](https://doi.org/10.15587/1729-4061.2017.92815)
- [14] Гайко С. Онтолого-керовані засоби оброблення та подання великих масивів неструктурованих текстів. Сучасний стан наукових досліджень та технологій в промисловості. 2023. DOI: [10.30837/ITSSI.2023.24.027](https://doi.org/10.30837/ITSSI.2023.24.027)
- [15] Bibichkov I., Sokol V., Shevchenko O. Ontological approach to development of web-content generation method. Technology Audit and Production Reserves. 2019. DOI: [10.15587/2312-8372.2019.183201](https://doi.org/10.15587/2312-8372.2019.183201)
- [16] Kosenko S. The main statements of ontology theory and its implementation in the system of legal knowledge. Information Technology and Security. 2016. DOI: [10.20535/2411-1031.2016.4.2.109915](https://doi.org/10.20535/2411-1031.2016.4.2.109915)
- [17] Maedche A., Staab S. Ontology Learning for the Semantic Web. IEEE Intelligent Systems. 2001. Vol. 16, No. 2. P. 72–79. DOI: [10.1109/5254.920602](https://doi.org/10.1109/5254.920602)
- [18] Wong W.Y., Liu W., Bennamoun M. Ontology Learning from Text: A Look Back and into the Future. ACM Computing Surveys. 2012. Vol. 44, No. 4. Art. 20. DOI: [10.1145/2333112.2333115](https://doi.org/10.1145/2333112.2333115)
- [19] Wątróbski J. Ontology Learning Methods from Text – An Extensive Knowledge-Based Approach. Procedia Computer Science. 2020. Vol. 176. P. 3356–3368. DOI: [10.1016/j.procs.2020.09.061](https://doi.org/10.1016/j.procs.2020.09.061)
- [20] Cimiano P., Reyle U., Šarić J. Ontology-driven Discourse Analysis for Information Extraction. Data & Knowledge Engineering. 2005. Vol. 55, No. 1. P. 59–83. DOI: [10.1016/j.datak.2004.11.009](https://doi.org/10.1016/j.datak.2004.11.009)

- [21] Pertsas V., Constantopoulos P. Ontology-Driven Information Extraction from Research Publications. In: Digital Libraries for Open Knowledge (TPDL 2018). LNCS 11057. Springer, 2018. P. 241–253. [DOI: 10.1007/978-3-030-00066-0_21](https://doi.org/10.1007/978-3-030-00066-0_21).
- [22] Dimitrakis E., Sgontzos K., Tzitzikas Y. A Survey on Question Answering Systems over Linked Data and Documents. Journal of Intelligent Information Systems. 2020. Vol. 55, No. 2. P. 233–259. [DOI: 10.1007/s10844-019-00584-7](https://doi.org/10.1007/s10844-019-00584-7).
- [23] Ferré S. Sparklis: An expressive query builder for SPARQL endpoints with guidance in natural language. Semantic Web. 2017. Vol. 8, No. 3. P. 405–418. [DOI: 10.3233/SW-150208](https://doi.org/10.3233/SW-150208)
- [24] Diefenbach D., Giménez-García J., Both A., Singh K., Maret P. QAnswer KG: Designing a Portable Question Answering System over RDF Data. In: The Semantic Web – ESWC 2020. LNCS 12123. Springer, 2020. P. 429–445. [DOI: 10.1007/978-3-030-49461-2_25](https://doi.org/10.1007/978-3-030-49461-2_25)
- [25] Yin X., Gromann D., Rudolph S. Neural Machine Translating from Natural Language to SPARQL. Future Generation Computer Systems. 2021. Vol. 117. P. 510–519. [DOI: 10.1016/j.future.2020.12.013](https://doi.org/10.1016/j.future.2020.12.013)
- [26] Borroto M.A., Ricca F. SPARQL-QA-v2 system for Knowledge Base Question Answering. Expert Systems with Applications. 2023. Vol. 229. Art. 120383. [DOI: 10.1016/j.eswa.2023.120383](https://doi.org/10.1016/j.eswa.2023.120383)
- [27] Trivedi P., Maheshwari G., Dubey M., Lehmann J. LC-QuAD: A Corpus for Complex Question Answering over Knowledge Graphs. In: The Semantic Web – ISWC 2017. Springer, 2017. P. 210–218. [DOI: 10.1007/978-3-319-68204-4_22](https://doi.org/10.1007/978-3-319-68204-4_22)
- [28] Dubey M., Banerjee D., Abdelkawi A., Lehmann J. LC-QuAD 2.0: A Large Dataset for Complex Question Answering over Wikidata and DBpedia. In: The Semantic Web – ISWC 2019. LNCS 11779. Springer, 2019. P. 69–78. [DOI: 10.1007/978-3-030-30796-7_5](https://doi.org/10.1007/978-3-030-30796-7_5)

ДОДАТОК

Природномовні запити до бази даних наукових публікацій.

А – запити користувачів;

Б – запити аналітичного характеру (як працівники аналітичного відділу, так і користувачі).

A1. – Пошук публікації

1. "Знайти назви всіх публікацій за 2023 рік."
2. "Знайти назви всіх публікацій за 2023 рік у порядку зростання дати публікації."
3. Знайти назви всіх публікацій після 2023 року.
4. Знайти назви всіх одноосібних публікацій після 2023 року.
5. "Показати статті, опубліковані у журналі Control Systems and Computers."
6. "Які роботи написав Mykola Petrenko?"
7. "Знайти всі статті, де згадується Semantic Web."
8. "Які статті є у співавторстві Kyrylo Malakhov?"
9. "Показати всі статті, які не мають DOI."
10. "Які публікації опубліковані у журналах Springer?"

11. "Знайти всі роботи, опубліковані між 2020 і 2024 роками."
12. "Які статті містять слово *ontology* у назві?"
13. "Знайти всі статті з категорії Штучний інтелект."
14. "Знайти текст статей з категорії Штучний інтелект."
15. "Знайти назви розділів статей з категорії Штучний інтелект."
16. "Знайти тексти абзаців в розділах статей, в яких згадується Формальна комп'ютерна онтологія "

17. "Знайти анотації статей з категорії Штучний інтелект."

A2. – Аналіз публікацій

1. "Які ключові слова найчастіше зустрічаються в статтях?"
2. "Показати список авторів, які мають найбільше публікацій."
3. "Які статті мають найбільше співавторів?"
4. "Знайти статті, які мають більше 3 авторів."
5. "Які журнали найчастіше цитуються?"
6. "Які роботи мають найбільшу кількість переглядів?"

A3. – Історія запитів користувача

1. "Показати всі мої запити за останній місяць."
2. "Знайти останні 5 запитів, які я виконав."
3. "Які статті я переглядав останнього разу?"

A4. – Пошук публікацій за різними критеріями

1. "Знайти всі публікації, опубліковані у 2023 році в журналі Control Systems and Computers."
2. "Показати всі статті, що містять слово *ontology* у назві або ключових словах."
3. "Знайти всі роботи, де серед авторів є Aidan Hogan, і вони були опубліковані після 2020 року."
4. "Які статті написані спільно Palagin O. та Petrenko M.?"
5. "Знайти всі публікації, які мають більше 5 авторів і були опубліковані на конференціях."
6. "Показати всі статті, які цитують Knowledge Graphs."
7. "Знайти всі публікації, де в анотації згадується Semantic Search."
8. "Які статті опубліковані у невідкритому доступі?"
9. "Показати всі статті, що мають більше 10 цитувань у Google Scholar."
10. "Які роботи пов'язані з використанням Machine Learning у базах знань?"

A5. – Аналіз публікацій та авторів

1. "Скільки статей було опубліковано в журналі South African Computer Journal за останні 5 років?"
2. "Показати топ-5 авторів за кількістю публікацій у категорії Artificial Intelligence."
3. "Які журнали найчастіше публікують роботи з Semantic Web?"
4. "Які конференції найчастіше приймають статті про Natural Language Processing?"

5. "Скласти рейтинг авторів за кількістю публікацій у період з 2015 по 2024 рік."
6. "Які ключові слова найчастіше зустрічаються у статтях про *ontology engineering*?"
1. "Які роботи були написані спільно між авторами з різних установ?"
2. "Скільки унікальних авторів є у базі даних?"
3. "Які автори публікуються в декількох наукових журналах одночасно?"

A6. – Структурований пошук за категоріями

1. "Показати всі статті, що входять до категорій Штучний інтелект і Онтології."
2. "Знайти статті, які мають більше однієї категорії."
3. "Які роботи належать одночасно до категорій Knowledge Graphs та Data Integration?"
1. "Знайти всі статті, що входять до категорії Баз даних та були опубліковані після 2021 року."

A7. – Аналіз запитів користувачів

1. "Показати всі мої запити за останній рік."
2. "Які статті я найчастіше шукав?"
3. "Знайти всі запити, що містять слово *ontology*."
4. "Скільки запитів зроблено у базі даних за останній місяць?"

Розширені пошукові запити за публікаціями

A8. – Комбінований пошук за декількома полями:

5. "Знайти всі публікації, опубліковані між 2018 та 2024 роками, в яких у заголовку згадується 'Deep Learning', а ключові слова містять '*neural networks*'."

A9. – Пошук за повним текстом анотації:

6. "Знайти всі роботи, у яких в анотації фраза '*big data analytics*' згадується більше одного разу."

A10. – Пошук за комбінованими умовами авторів і журналу:

7. "Які статті, написані спільно з автором Aidan Hogan і іншими авторами, опубліковані у журналах з відкритим доступом?"

A11. – Фільтрація за типом публікації:

8. "Показати тільки оглядові статті (review articles) та мета-аналізи у категорії 'Artificial Intelligence'."

Розширений пошук за категоріями, темами та метаданими

A12. – Комбінований пошук за категоріями:

9. "Знайти всі статті, що належать одночасно до категорій 'Штучний інтелект', 'Баз даних' та 'Machine Learning', і які опубліковані в 2023 році."
10. Знайти назви статей із співавтором «Кургаєв».

A13. – Пошук за зацікавленістю спільнот:

11. "Знайти публікації, які отримали відгуки або були відзначені як важливі користувачами в системі коментарів/оцінок."

A14. – Масове видалення:

12. "Видалити всі дублікати записів, що містять однаковий DOI, або об'єднати їх з урахуванням додаткової інформації."

A15. – Автоматизація перекладів:

13. "Запустити процес автоматичного перекладу анотацій публікацій з української на англійську для всіх робіт, опублікованих після 2021 року."

A16. – Валідація даних:

14. "Знайти та позначити записи публікацій, де відсутні обов'язкові поля (назва, автори, рік) або де значення не відповідають очікуваному формату (наприклад, некоректний DOI або рік)."

A17. – Імпорт/Експорт даних:

15. "Створити запит для експорту всіх публікацій з категорією 'Artificial Intelligence' у форматі CSV для подальшого аналізу в інших інструментах."

A18. – Аудит змін:

16. "Вивести історію змін для конкретної публікації, включаючи дату оновлення, хто додав зміни, та які поля були змінені."

B1. – Управління базою даних

1. "Додати нову статтю "AI in Science автора Kyrylo Malakhov."
2. "Оновити DOI статті Knowledge Graphs."
3. "Видалити всі статті за 2010 рік."
4. "Видалити всі роботи, які не мають DOI."
5. "Додати нове ключове слово Machine Learning до статті Developing an ontology-based system."

B2. – Управління базою даних (CRUD-операції, (англ. create read update delete))

1. "Додати нову статтю Neural Networks for Ontology Alignment від авторів Kyrylo Malakhov та Ellen Cohn у журнал Artificial Intelligence Review, 2024 рік."
2. "Оновити DOI статті Developing an ontology-based system for semantic processing of scientific digital libraries."
3. "Додати до статті Knowledge-Oriented Tool Complex нове ключове слово data science."
4. "Змінити назву статті Challenges and Role of Ontology Engineering на Ontology Engineering in the Knowledge Industry."
5. "Видалити всі статті, що були опубліковані до 2000 року."
6. "Видалити всі записи, які не мають DOI або ISSN."
7. "Додати нового автора John Smith з ORCID 0000-0002-XXXX-YYYY до бази даних."
8. "Оновити інформацію про автора Petrenko M.G., додавши нову афіліацію Kyiv Polytechnic Institute."
9. "Додати нову категорію Deep Learning у список категорій."
10. "Перекласти всі анотації статей з української на англійську мову."

Розширені аналітичні запити та статистика

Б3. – Аналіз тенденцій:

11. "Показати, як змінювалася кількість публікацій з тематики 'Knowledge Graphs' по роках за останні 10 років."

Б4. – Аналіз цитування:

12. "Які статті, що публікувалися до 2015 року, мають найбільший приріст цитувань за останні 5 років?"

Б5. – Аналіз впливовості авторів:

13. "Скласти рейтинг авторів за середнім числом цитувань на статтю, включаючи тільки публікації з 2020 року."

Б6. – Географічна аналітика:

14. "Які публікації мають співавторів з різних країн? Побудувати список за країнами авторів."

Б7. – Аналіз ключових слів:

15. "Визначити, які ключові слова з'являються у статтях про 'Semantic Web' найбільш часто, і побудувати хмару слів за останні 5 років."

Б8. – Аналіз тематики конференцій:

16. "Порівняти кількість публікацій за темою 'Data Mining' серед журналів і конференцій за останнє десятиліття."

Розширені запити для аналізу взаємозв'язків між публікаціями та авторами.

Б9. – Мережевий аналіз.