ТЕОРЕТИКО-ПРАКТИЧНІ ЗАСАДИ ВІЙСЬКОВОГО УПРАВЛІННЯ, ІНФОРМАЦІЙНОЇ ТА КІБЕРБЕЗПЕКИ

Стаття та будь-який пов'язаний з нею опублікований матеріал поширюється за ліцензією Creative Commons Attribution License (CC BY 4.0).
The article and any related published material are licensed under the Creative Commons Attribution License (CC BY 4.0).

УДК: 004.89 : 004.738.5 : 681.3
DOI: https://doi.org/10.17721/2519-481X/2026/91-03

Юрій КАТКОВ, доктор технічних наук, доцент
ORCID: 0009-0007-1194-4014
e-mail: katkov@duikt.ua
Державний університет інформаційно-комунікаційних технологій,
Київ, Україна

Володимир ВАСИЛЕНКО, кандидат технічних наук, доцент
ORCID: 0000-0001-8465-6178
e-mail: vasilenko@duikt.ua
Державний університет інформаційно-комунікаційних технологій,
Київ, Україна

Юлія БЕРЕЗОВСЬКА, доктор філософії (телекомунікації та радіотехніка)
ORCID: 0000-0002-9973-0497
e-mail: y.berezovska@duikt.edu.ua
Державний університет інформаційно-комунікаційних технологій,
Київ, Україна

Валерій САВЕНОК, магістр
ORCID: 0009-0001-3567-0448
e-mail: mag3433782@stud.duikt.edu.ua
Державний університет інформаційно-комунікаційних технологій,
Київ, Україна

КОНЦЕПТУАЛЬНА МОДЕЛЬ ЗАСТОСУВАННЯ ІНСТРУМЕНТІВ РОЗГОРНУТОГО ШТУЧНОГО ІНТЕЛЕКТУ У ПОШУКОВІЙ ОПТИМІЗАЦІЇ

Вступ. *У статті досліджено перспективи застосування розгорнутого штучного інтелекту (AGI) для автоматизації SEO-аналізу та генерації контенту. Актуальність дослідження зумовлена необхідністю підвищення ефективності пошукової оптимізації в умовах динамічної зміни алгоритмів пошукових систем, зростання обсягів цифрового контенту та необхідності врахування поведінки користувачів. Запропонована концептуальна модель SEO/AGI-аналізу передбачає інтеграцію методів обробки природної мови (NLP), машинного навчання (ML) та великих мовних моделей (LLM) в єдину адаптивну систему. Саме тому метою статті стало створення концептуальної моделі SEO/AGI-аналізу, яка формалізує оцінювання семантичної релевантності контенту, його ранжування, генерацію та оптимізацію відповідно до пошукового наміру користувача.*

Методи. *Для побудови концептуальної моделі SEO/AGI-аналізу використано методи математичного моделювання, формалізації та оптимізації. SEO/AGI-аналіз розглянуто як задачу максимізації показника клікабельності (CTR) результатів пошуку. У моделі застосовано векторизацію тексту та оцінювання семантичної релевантності за допомогою NLP, формування простору ознак і машинної функції ранжування на основі ML, а також умовну генерацію та оцінювання якості контенту за допомогою LLM. Для забезпечення адаптивності моделі передбачено механізм зворотного зв'язку (feedback loop), який дає змогу коригувати параметри системи на основі поведінкових факторів користувачів.*

Результати. *У результаті дослідження розроблено концептуальну модель SEO/AGI-аналізу, яка об'єднує NLP, ML та LLM у єдиний послідовний процес оптимізації. Модель охоплює векторизацію тексту, визначення семантичної релевантності, формування простору ознак, машинне ранжування, генерацію та оцінювання якості контенту. Як критерії оцінювання інтеграції AGI-компонентів визначено cosine similarity embeddings, embeddings та SEO-score, причому SEO-score розглядається як показник, що безпосередньо характеризує вплив AGI-компонентів на пошукову видимість. Запропонований механізм адаптивного навчання забезпечує ітеративне коригування параметрів моделі відповідно до результатів взаємодії користувачів із пошуковими результатами.*

Висновки. *Запропонована концептуальна модель SEO/AGI-аналізу формалізує інтеграцію NLP, ML та LLM у єдину адаптивну систему та забезпечує теоретичне обґрунтування AI-орієнтованої пошукової оптимізації. Модель поєднує оцінювання семантичної релевантності, ранжування, генерацію та оцінювання якості контенту, а також використання зворотного зв'язку на основі поведінкових факторів. Отриманий підхід створює основу для переходу від класичного ранжування до user-centric SEO та може бути використаний під час подальшої розробки самонавчальних і адаптивних SEO-систем. Перспективним напрямом подальших досліджень визначено перевірку запропонованої моделі шляхом симуляції в Python із використанням відповідних математичних бібліотек.*

Ключові слова: *SEO, AGI, штучний інтелект, машинне навчання, великі мовні моделі, обробка природної мови, семантична релевантність, ранжування, CTR, SEO-аналіз.*

© Катков Юрій, Василенко Володимир, Березовська Юлія, Савенок Валерій, 2026

ISSN 2524-0056 (Print)

Вступ

Передумови. Пошукова оптимізація (SEO, Search Engine Optimization) являє собою комплекс заходів, спрямованих на підвищення якості та кількості органічного трафіку веб-ресурсу з пошукових систем. Основними напрямами SEO є підвищення видимості веб-ресурсу, забезпечення відповідності контенту пошуковим запитам користувачів, покращення користувацького досвіду (UX), а також підвищення авторитетності веб-ресурсу. SEO-аналіз передбачає комплексне оцінювання технічних характеристик веб-сайту, якості та релевантності контенту, ключових слів, зворотних посилань і поведінкових факторів користувачів.

Актуальність розвитку методів SEO-аналізу зумовлена зміною характеру пошуку інформації та широким використанням засобів штучного інтелекту. Користувачі дедалі частіше отримують безпосередньо у пошуковій системі сформовані відповіді на свої запити, що може зменшувати кількість переходів на веб-сайти. За цих умов традиційного аналізу ключових слів і технічних характеристик недостатньо для комплексного оцінювання відповідності контенту пошуковим намірам користувачів. Під час впровадження AGI у пошукову оптимізацію основою виступають великі мовні моделі (LLMs – Large Language Models), методи машинного навчання (ML – Machine Learning) та обробка природної мови (NLP – Natural Language Processing) (Russell & Norvig, 2021; Goodfellow et al., 2016; Manning et al., 2008; Vaswani et al., 2017; Brown et al., 2025; Forsyth, 2019). Особливого значення застосування таких технологій набуває для інформаційних ресурсів критичної інфраструктури, для яких важливими є доступність, актуальність, релевантність та своєчасне представлення інформації користувачам. У цьому контексті автоматизований SEO/AGI-аналіз може розглядатися як інструмент підвищення інформаційної доступності та ефективності представлення веб-контенту критичної інфраструктури у пошуковому середовищі. Тому виникає потреба у створенні концептуальної моделі SEO/AGI-аналізу для проведення подальших досліджень.

У межах SEO-аналізу виникає задача визначення відповідності контенту веб-сторінки пошуковим запитам користувачів та оцінювання факторів, які впливають на її видимість у пошуковій видачі. Використання інструментів штучного інтелекту створює можливість автоматизувати обробку та інтерпретацію контенту, визначати пошукові наміри користувачів, оцінювати семантичну релевантність, прогнозувати характеристики видимості веб-ресурсів і вдосконалювати їх ранжування. (Russell & Norvig, 2021; Goodfellow, Bengio, & Courville, 2016). Водночас для системного поєднання зазначених компонентів необхідна концептуальна модель SEO/AGI-аналізу, яка б формалізувала взаємозв'язок між контентом, пошуковими запитами, семантичною релевантністю, ранжуванням та оптимізацією контенту.

Метою дослідження є створення концептуальної моделі SEO/AGI-аналізу, яка відображає процес оцінювання та максимізації релевантності контенту відносно множини пошукових запитів, передбачає формування оцінки для ранжування веб-документів та забезпечує можливість генерації покращених варіантів контенту.

Завдання дослідження. Для досягнення поставленої мети визначено такі завдання дослідження:

– формалізувати SEO/AGI-аналіз як задачу оптимізації релевантності веб-контенту відносно множини пошукових запитів із використанням CTR як цільового показника;

– визначити основні об'єкти та змінні моделі, зокрема множину веб-документів, множину пошукових запитів, позицію документа у пошуковій видачі та функцію клікабельності;

– розробити підхід до семантичного аналізу контенту та пошукових запитів із використанням методів NLP і векторних представлень;

– визначити спосіб кількісного оцінювання семантичної релевантності документа пошуковому запиту на основі косинусної подібності векторних представлень;

– сформувати простір ознак для моделі ранжування з урахуванням семантичної релевантності, технічних SEO-факторів, характеристик користувацької взаємодії, авторитетності та актуальності контенту;

– визначити принцип використання ML-функції для формування оцінки та ранжування веб-документів;

– розробити концептуальний підхід до умовної генерації та оцінювання якості контенту за допомогою LLM з урахуванням семантичної релевантності, читабельності та пошукового наміру;

– інтегрувати NLP, ML та LLM-компоненти в єдину концептуальну SEO/AGI-модель із механізмом оптимізації та зворотного зв'язку (feedback loop);

– визначити показники та умови подальшої перевірки запропонованої концептуальної моделі на практичних даних. Таким чином, дослідження спрямоване на концептуальне поєднання NLP, ML та LLM у межах єдиної SEO/AGI-моделі, здатної забезпечити послідовний перехід від аналізу контенту та пошукового запиту до оцінювання релевантності, ранжування, генерації покращеного контенту та подальшої оптимізації моделі.

Таким чином, дослідження спрямоване на концептуальне поєднання NLP, ML та LLM у межах єдиної SEO/AGI-моделі, здатної забезпечити послідовний перехід від аналізу контенту та пошукового запиту до оцінювання релевантності, ранжування, генерації покращеного контенту та подальшої оптимізації моделі.

Методи

Для досягнення мети дослідження та розроблення концептуальної моделі SEO/AGI-аналізу застосовано комплекс взаємопов'язаних методів математичного моделювання, формалізації, обробки природної мови (NLP), машинного навчання (ML), генеративного моделювання на основі великих мовних моделей (LLM) та оптимізації. Застосування зазначених методів організовано як послідовний процес перетворення пошукового запиту та контенту веб-сторінки у числові характеристики, їх використання для ранжування, генерації покращеного контенту та подальшого коригування параметрів моделі за результатами користувацької взаємодії.

На першому етапі методом формалізації визначено об'єкти та змінні SEO/AGI-моделі. Нехай (D) — множина веб-документів, (Q) — множина пошукових запитів, (r(d,q)) — позиція документа (d) у результатах пошуку за запитом (q), а (CTR(r)) — функція клікабельності, що залежить від позиції документа. SEO/AGI-аналіз у

досліджені розглядається як задача оптимізації, у якій цільовою характеристикою є очікувана клікабельність результатів пошуку. При цьому CTR використовується як цільовий проксі-показник користувацької взаємодії, а не як безпосередній синонім загальної пошукової видимості.

На другому етапі застосовано методи NLP для семантичного аналізу контенту. Текст веб-сторінки та пошуковий запит перетворюються у векторні представлення за допомогою відповідних методів векторизації. У межах концептуальної моделі розглядаються статистичні методи (Bag of Words, TF-IDF), семантичні embeddings (Word2Vec, GloVe, FastText) та контекстні представлення (BERT, Sentence-BERT, LLM embeddings). Такий підхід дає змогу перейти від формального збігу ключових слів до оцінювання семантичної відповідності документа пошуковому запиту.

На третьому етапі для кількісного оцінювання семантичної релевантності застосовано метод косинусної подібності. Для кожної пари «документ-запит» формуються вектори (e_d) та (e_q), після чого семантична
релевантність визначається як (s(d,q)=\cos(e_d,e_q)). Отримане значення використовується як ознака подальшої моделі ранжування. При цьому cosine similarity розглядається саме як вимірювана ознака семантичної подібності, а її відповідність фактичній релевантності має перевірятися на розмічених парах «запит-документ».

На четвертому етапі методом формування простору ознак визначено сукупність характеристик, які можуть бути використані для ранжування веб-документів. До простору ознак включено семантичну релевантність контенту, технічні SEO-фактори, характеристики користувацької взаємодії, авторитетність веб-ресурсу та актуальність контенту. Поведінкові дані попередніх періодів розглядаються як агреговані лагові ознаки, тоді як кліки поточного показу використовуються як цільова змінна, а не як вхідна ознака. Така структура дає змогу уникнути використання інформації, яка стає доступною лише після здійснення поточного показу.

На п'ятому етапі застосовано метод машинного навчання для побудови функції ранжування. Вектор характеристик пари «документ-запит» подається на вхід ML-моделі, яка формує числову оцінку релевантності та визначає порядок документів у пошуковій видачі. У концептуальній моделі допускається використання лінійної або нелінійної функції ранжування. Таким чином, ML-компонент забезпечує інтеграцію семантичних, технічних та поведінкових характеристик у єдину оцінку, на основі якої формується ранг документа.

На шостому етапі використано метод умовної генерації контенту за допомогою LLM. Генерація здійснюється з урахуванням пошукового запиту, контексту, структури контенту, SEO-вимог, стилістичних та інших заданих обмежень. Метод передбачає формування декількох можливих варіантів контенту, після чого кожний варіант оцінюється за функцією якості. Функція якості враховує семантичну релевантність, читабельність та
відповідність пошуковому наміру користувача. Оптимальним вважається варіант, який отримує максимальне значення інтегральної оцінки якості.

На сьомому етапі застосовано метод оптимізації для інтеграції результатів NLP, ML та LLM у єдину SEO/AGI-модель. Цільова функція сформована як максимізація очікуваного CTR для множини пошукових запитів. Параметрами оптимізації є ваги ознак у функції ранжування, параметри генерації контенту та інші параметри, що визначають поведінку моделі. Така постановка дає змогу формально представити процес пошуку параметрів, за яких веб-документи отримують позиції, що забезпечують вищу ймовірність користувацького переходу.

На восьмому етапі застосовано метод адаптивного навчання на основі feedback loop. Результати взаємодії користувачів із пошуковими результатами використовуються для подальшого коригування параметрів SEO/AGI-моделі. Параметри моделі на кожній наступній ітерації уточнюються на основі спостережуваних результатів попередньої ітерації. Таким чином, формується замкнений цикл «аналіз контенту → оцінювання релевантності → ранжування → генерація/оптимізація контенту → спостереження за результатами → коригування параметрів».

Застосування зазначених методів дало змогу сформувати концептуальну послідовність SEO/AGI-аналізу: *NLP → семантичне представлення → оцінювання релевантності → формування простору ознак → ML-ранжування → LLM-генерація та оцінювання контенту → оптимізація → feedback loop*. Запропонована методологія використовується саме для побудови та
математичної формалізації концептуальної моделі. Практична перевірка її ефективності на реальних даних не є предметом цього етапу дослідження та потребує окремого експериментального дослідження.

Аналіз останніх наукових досліджень і публікацій

За останні роки тема SEO/AGI-аналізу набрала обертів. Штучний інтелект розвивався від класичних логічних агентів до моделей на основі нейронних мереж (Russell & Norvig, 2021; Goodfellow, Bengio, & Courville, 2016). Семантичний пошук та інформаційний пошук базуються на складних NLP-представленнях (Manning, Raghavan, & Schütze, 2008), тоді як архітектури, приміром Transformer, змінили підхід до генерації тексту й
розвитку LLM (Vaswani et al., 2017). GPT-моделі демонструють здатність до узагальнення знань без явного
навчання для кожної окремої задачі (Brown et al., 2020). Ранжування результатів пошуку активно використовує ML-методи, зокрема RankBrain (Google, n.d.), а практичне впровадження ML у прикладних задачах описано у відповідній прикладній літературі (Forsyth, 2019).

Результати

Запропонована концептуальна модель застосування інструментів розгорнутого штучного інтелекту у пошуковій оптимізації для критичної інфраструктури представлена на рис. 1. Модель на Рис. 1 відображає взаємозв'язок між джерелами інформації критичної інфраструктури,
інструментами NLP, ML та LLM і послідовними етапами SEO/AGI-аналізу – від аналізу пошукових запитів і контенту до оцінювання релевантності, ранжування, генерації та оптимізації контенту із використанням зворотного зв'язку.

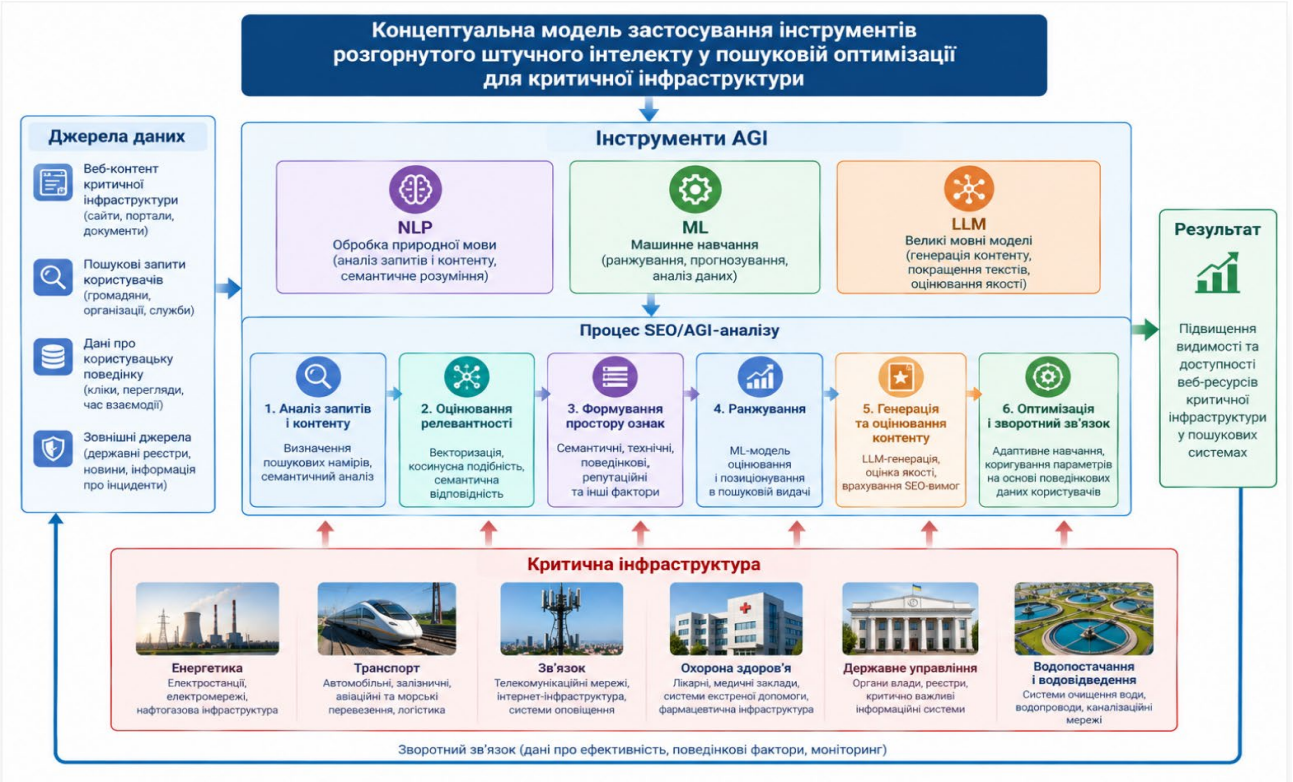

Рис. 1. Концептуальна модель AGI для критичної інфраструктури (зроблено LLM)

Для вирішення поставленого завдання створення концептуальної моделі SEO/AGI-аналізу зроблено загальну постановку задачі, як задачі оптимізації. У цій роботі цільовою метрикою є CTR (Click-Through Rate) - частка кліків серед показів для заданої множини запитів і умов показу. CTR використовується як один із проксі-показників взаємодії, але не ототожнюється із загальною пошуковою видимістю. Видимість ресурсу у пошуковій системі визначається клікабельністю CTR. На практиці це відносний показник ефективності пошукового результату, що характеризує ймовірність переходу користувача за умови відображення документа у SERP:

$$CTR = \frac{N_{cliks}}{N_{impressions}}, \quad (1)$$

де N_{cliks} - кількість кліків по результату;

$N_{impressions}$ - кількість показів результату.

Для формалізації завдання SEO/AGI-оптимізації впроваджуємо наступні умови, нехай:

$D = \{d_1, d_2, \dots, d_n\}$ - множина веб-документів, контент (текст веб-сторінки);

– $Q = \{q_1, q_2, \dots, q_m\}$ - множина пошукових запитів;

– $R_i = (d_i, q_i)$ - позиція документа d_i у результатах пошуку за запитом q_i;

– $CTR(R)$ - функція клікабельності залежно від позиції.

Для формалізації задачі максимізації цільової функції SEO/AGI видимості ресурсу у пошуковій системі запропоновано математичні описання у вигляді редукованих моделей першого наближення. Редукована модель першого наближення - це математичне представлення складної системи, отримане шляхом зменшення розмірності та лінеаризації, яке зберігає головні закономірності процесу з допустимою точністю. Тобто, якщо повна модель – складна, нелінійна, багатовимірна, то редукована модель - проста, інтерпретована та обчислювально ефективна, а перше наближення означає, що враховано лише лінійний вплив факторів. Це забезпечує концептуальну чіткість, узагальненість та дає змогу уникнути надмірної математичної складності при збереженні коректного відображення динаміки навчального процесу. Нехай Q - вибірка запитів із заданим розподілом $P(q)$, а $CTR(q;\theta)$ оцінюється на незалежних показах у фіксованому часовому вікні. Отже, цільова функція SEO/AGI має вигляд:

$$\max_{\Omega} \mathbb{E}_{q \in Q}[CTR_{\Omega}(d, q))], \quad (2)$$

де $\max_{\Omega}(.)$ – оператор максимізації за параметрами моделі Ω, які визначають налаштування алгоритмів NLP, ML та LLM (ваги ознак, параметри ранжування, генерації контенту тощо);

$q \in Q$ – пошуковий запит q, що випадково вибирається з множини всіх можливих запитів Q відповідно до їх емпіричного розподілу;

$\mathbb{E}_{q \in Q}[.]$ – математичне сподівання, яке означає усереднення показника CTR по всій сукупності пошукових запитів, у разі об'єднання показів слід окремо визначити, чи застосовується зважування за кількістю impressions.

$CTR(R_{\Omega}(d, q))$ - значення показника клікабельності, що є функцією позиції документа в SERP; зазвичай CTR монотонно зменшується зі зростанням номера позиції;

$R_{\Omega}(d, q)$ - позиція (ранг) документа d у результатах пошуку за запитом q, яка залежить від параметрів моделі Ω.

Даний вираз описує задачу оптимізації SEO/AGI-моделі, метою якої є максимізація середнього показника

клікабельності результатів пошуку. Тобто оптимізувати параметри SEO/AGI-моделі таким чином, щоб у середньому по всіх пошукових запитах документи займали такі позиції в пошуковій видачі, які максимізують ймовірність кліку користувача.

Розглянемо сутність змінних у виразі (2) оператору $\max_{\Omega}(.)$. Він враховує інтеграцію великих мовних моделей (LLMs), методів машинного навчання (ML) та обробки природної мови (NLP) як єдину оптимізаційну систему, спрямовану на максимізацію релевантності, видимості та користувацької взаємодії в пошукових системах. Математична роль цих компонентів наступна:

NLP - семантичне відображення текстів, забезпечує векторизацію тексту та семантичну релевантність.

Векторизація тексту є процесом перетворення текстової інформації (слів, речень, документів) у числове (векторне) представлення, придатне для математичної обробки та використання в алгоритмах машинного навчання, NLP і SEO-моделях. Вона дозволяє обчислювати подібність текстів, визначати семантичну релевантність, застосовувати ML-моделі, формалізувати текст у математичних SEO-моделях. Методи векторизації доцільно класифікувати на статистичні, семантичні та контекстні. Статистичні методи, зокрема Bag of Words та TF-IDF, не враховують контекст і значення слів. Семантичні методи (word embeddings) векторизації, представлені моделями Word2Vec, GloVe та FastText, забезпечують формування векторних представлень слів з урахуванням їхньої семантичної близькості та взаємозв'язків у текстовому просторі. Сучасні контекстні методи, зокрема BERT, Sentence-BERT та LLM embeddings, формують більш інформативні векторні представлення завдяки врахуванню контексту вживання слів, синтаксичних і граматичних особливостей, а також семантичного змісту та комунікативного наміру тексту. Математичний запис векторизації тексту:

Нехай кожен документ d і запит q розглядаються у вигляді семантичних векторів:

$$v_d = f_{NLP}(d) \text{ та } v_q = f_{NLP}(q), \quad (3)$$

де $f_{NLP}(.)$ – функція кодування (TF-IDF, Word2Vec, FastText, BERT embeddings).

Семантична релевантність є мірою того, наскільки зміст документа відповідає змісту пошукового запиту, а не лише формальному збігу ключових слів. Математичний запис:

Нехай: v_d - векторне подання документа; v_q - векторне подання запиту. Тоді семантична релевантність визначається як:

$$R_{rel}(d,q) = \cos(v_d, v_q), \quad (4)$$

де $\cos(v_d, v_q)$ – косинусна міра подібності.

Семантичну подібність визначимо як $s(d,q) = \cos(e_d, e_q)$ для ненульових векторів однакової розмірності. Значення s є ознакою моделі, а не безпосереднім доказом релевантності, її валідність перевіряється на розмічених парах "запит-документ".

Векторизація тексту у SEO дозволяє правильно обробляти синоніми, перефразування, зменшує переспам ключовими словами, є базовим показником для ML-моделей ранжування, лежить в основі modern SEO та AI Search.

ML – машинне навчання для навчання функції ранжування. Забезпечує визначення простору ознак та ML-функцію ранжування.

Простір ознак - це математичний простір, у якому кожен об'єкт (документ, запит, користувач, сторінка) подається у вигляді вектора числових характеристик (ознак), що описують його властивості. Він показує, що кожен об'єкт є точкою в багатовимірному просторі. Чим ближчі дві точки, тим більш подібні відповідні об'єкти за своїми властивостями. Математичний запис:

Нехай для кожної пари контент-пошуковий запит формується вектор ознак $x_{d,q}$:

$$x_{d,q} = \begin{bmatrix} R_{rel}(d,q) \\ S_{tech}(d) \\ U_{UX}(d) \\ A_{auth}(d) \\ F_{fresh}(d) \end{bmatrix}, \quad (5)$$

де $R_{rel}(d,q)$ – ступінь релевантності (відповідності) інформації сучасному стану теми та поточним потребам користувачів;

$S_{tech}(d)$ – технічні фактори (SEO-Core Web Vitals, індексація);

$U_{UX}(d)$ – показник взаємодії UX-користувачів із веб-документом, що використовуються для оцінювання якості та релевантності результатів пошуку;

$A_{auth}(d)$ – показник довіри (авторитетності) веб-ресурсу, відображає наскільки документ або сайт сприймається пошуковою системою як надійне й авторитетне джерело інформації;

$F_{fresh}(d)$ – актуальність контенту, характеристика ступеня часової та контекстної відповідності інформації запитам користувачів у момент звернення до пошукової системи.

ML-функція ранжування - це математична функція, навчена методами машинного навчання, яка на основі вектора ознак визначає оцінку релевантності або порядок (ранг) документів у результатах пошуку. Відрізняють лінійну та нелінійну модель. Забезпечує у SEO-моделі об'єднання семантичних, технічних та поведінкових ознак, адаптацію до користувачів, а також є центральним елементом SEO /AGI системи.

Математичний запис: Нехай $x_{d,q} \in W^n$ – вектор ознак пари «документ-запит». Тоді лінійна ML-функція ранжування має вигляд:

$$S_{Rel}(d,q) = F_{ML}(x_{d,q}, \Omega_{ML}), \quad (6)$$

де $S_{Rel}(d,q)$ – числова оцінка релевантності;

$F_{ML}(.)$ – модель машинного навчання;

Ω_{ML} – її параметри.

Документи впорядковуються за спаданням $S_{Rel}(d,q)$.

LLM – великі мовні моделі для генерації та оптимізації контенту. В SEO/AGI використовується умовна генеративна модель LLM та функція оцінки якості контенту.

Умовна генеративна модель LLM означає, що велика мовна модель генерує текст не довільно, а за заданою умовою (контекстом), яка визначає зміст, стиль і ціль генерації. У SEO-моделі LLM автоматизує створення та оновлення контенту, оптимізує тексти під семантичну релевантність, формує ознаки для ML-функції ранжування.

Математичний запис: Нехай $d = (w_1, w_2, \dots, w_n)$ - згенерований текст; C – додаткові обмеження (SEO-вимоги; структура контенту; пошукова ціль; тональність і стиль); q - цільовий запит. Тоді LLM моделює $P_W(d|\mathrm{q}, \mathrm{C})$ - умовний імовірнісний розподіл тексту d як послідовності токенів $\mathrm{w}_1, \mathrm{w}_2, \dots, \mathrm{w}_\mathrm{T}$ за допомогою великої мовної моделі (LLM):

$$P_W(d|\mathrm{q}, \mathrm{C}) = \prod_{t=1}^{T} P_W\{\, w_t|w_{<t}, \mathrm{q}, \mathrm{C}\}\ , \qquad (7)$$

де $d = (w_1, w_2, \dots, w_\mathrm{T})$ - текстовий документ або згенерований контент як послідовність T токенів (слів, підслів або символів);

q – пошуковий запит користувача, який задає основний намір генерації;

C – контекст або умови генерації (структура і стиль тексту, SEO-вимоги, тематичні обмеження, інші зовнішні фактори, що впливають на зміст);

$w_{<t} = (\mathrm{w}_1, \mathrm{w}_2, \dots, \mathrm{w}_{t-1})$ – всі токени, згенеровані до поточного моменту t;

$P_W\{\, w_t|w_{<t}, q, C\}$ – умовна ймовірність наступного токена w_t за параметрами моделі W, знаючи попередні токени та контекст;

$\prod_{t=1}^{T} P_W\{\, w_t|w_{<t}, \mathrm{q}, \mathrm{C}\}$ - множення ймовірностей токенів, що відповідає правилу ланцюга (chain rule) для послідовності.

Отже, формула (7) описує умовний розподіл послідовності токенів документа, який генерується великою мовною моделлю на основі пошукового запиту та контексту, застосовуючи правило ланцюга для прогнозування кожного слова.

Функція оцінки якості контенту є математичною функцією, яка формалізує рівень корисності, релевантності та читабельності згенерованого або існуючого тексту. Вона використовується для вибору оптимального контенту у SEO, ML або LLM-моделях. З її допомогою оцінюється наскільки документ «гарний» з точки зору користувача та пошукової системи, дозволяє порівнювати різні варіанти контенту та обирати оптимальний, застосовується як критерій для генеративних моделей та ML-моделей ранжування.

Математичне представлення: Нехай $Q(d)$ - функція оцінки якості контенту, яка кожному документу d ставить у відповідність числове значення, що характеризує його ефективність, релевантність та корисність для користувача:

$$Q(d) = \alpha R_{rel}(d, q) + \beta R_{read}(d) + \gamma I_{int}(d), \qquad (8)$$

де $R_{rel}(d, q)$ – семантична релевантність документа запиту q;

$R_{read}(d)$ – читабельність;

$I_{int}(d)$ – відповідність пошуковому наміру користувача;

α, β, γ – вагові коефіцієнти важливості кожного компонента.

Практичне значення $Q(d)$ функції у тому, що вона оцінює, наскільки документ «гарний» з точки зору користувача та пошукової системи, дозволяє порівнювати різні варіанти контенту та обирати оптимальний, застосовується як критерій для генеративних моделей та ML-моделей ранжування.

Процедура SEO оптимізації наступна в LLM:

- LLM генерує кілька варіантів тексту d_1, d_2, …, d_i, …;
- для кожного варіантів тексту виконується обчислення $Q(d_i)$;
- вибирається документ d_{opt} із максимальним значенням $Q(d_i)$ функції якості:

$$d_{opt} = \arg\max_{i \in N} Q(d_i). \qquad (9)$$

Отже, функція оцінки якості контенту $Q(d)$ ставить кожному документу d у відповідність числове значення, що характеризує його ефективність, релевантність та корисність для користувача.

Інтегрована модель $R_\Omega(d, q)$, що визначає позицію (ранг) документа d у результатах пошуку за запитом q, яка залежить від параметрів моделі Ω. На основі наведених компонентів запропоновано концептуальну модель AI-орієнтованого SEO-аналізу (SEO/AI). Скорочення в усьому тексті SEO/AI або SEO/LLM:

$$R_\Omega(d, q) = \mathbb{R}\{R_{rel}\,(d, q), S_{Rel}\,(d, q), P_W(d|\mathrm{q}, \mathrm{C}), d_{opt}\}, \qquad (10)$$

де $R_{rel}(d, q)$ – семантична релевантність документа запиту q з формули (4);

$S_{Rel}\,(d, q)$ – числова оцінка релевантності з формули (6);

$P_W(d|\mathrm{q}, \mathrm{C})$ – умовний ймовірнісний розподіл тексту d як послідовності токенів $\mathrm{w}_1, \mathrm{w}_2, \dots, \mathrm{w}_\mathrm{T}$ за допомогою LLM з формули (7);

d_{opt} – документ із максимальним значенням $Q(d_i)$ функції якості з формули (9);

Отже, концептуальна SEO/AGI модель описує процес інтеграції AGI-компонентів наступним чином: модель SEO/AGI комбінує AI-компоненти у ланцюг: NLP → LLMs → ML. Це створює ітеративний процес оптимізації за рахунок адаптивного навчання (feedback loop).

Адаптивне навчання (feedback loop) є механізмом безперервного самоналаштування моделі, за якого система оновлює свої параметри на основі зворотного зв'язку від користувачів або середовища. Тобто, під час SEO/AGI-аналізу проводиться прогноз або пропонується оптимальне рішення, спостерігається реакція користувачів для подальшого аналізу, визначається чи коригується поведінка. Це означає, що з кожною ітерацією система аналізує результати попередньої ітерації, виявляє відхилення та коригує параметри оптимізації відповідно до отриманого зворотного зв'язку. У результаті модель SEO/AGI забезпечує динамічну адаптацію до змін алгоритмів пошукових систем і поведінки користувачів, зменшує потребу в ручному налаштуванні та інтегрує методи машинного навчання (ML) і великих мовних моделей (LLM) у єдину самонавчальну систему. Запропонована схема передбачає оновлення параметрів за спостережуваними метриками користувачів; здатність адаптуватися до змін пошукових алгоритмів потребує окремої експериментальної перевірки.

Таким чином, кожна наступна ітерація використовує результати попередньої для уточнення параметрів моделі та підвищення якості отримуваного результату.

Математичне представлення: Нехай SEO/AGI-модель навчається на основі поведінкових даних: $\theta_t\,(d, q)$ - параметри моделі на ітерації t, а задачу

оптимізації на ітерації t, розглянемо як задачу максимізації цільової функції SEO/AGI, що визначається клікабельністю CTR_t

$$\theta_{t+1}(d,q) = \theta_t(d,q) + \eta_t \nabla_{\theta_t} \mathbb{E}_{q\in Q}[CTR_t(R_\Omega(d,q))], \quad (11)$$

де $\theta_{t+1}(d,q)$ – оновлений вектор параметрів d,q моделі після урахування зворотного зв'язку на кроці навчання t;

t – індекс ітерації навчання, що відповідає певному періоду збору даних (сеанс, день, тиждень тощо);

$\theta_t(d,q)$ – поточний вектор параметрів d,q моделі на кроці навчання t (у SEO/AGI-моделі це можуть бути: ваги ознак у ML-функції ранжування, параметри генерації контенту (LLM-контрольні коефіцієнти), коефіцієнти важливості поведінкових факторів);

η_t – швидкість навчання (learning rate) на кроці навчання t, що визначає наскільки сильно змінюються параметри, компроміс між стабільністю та швидкістю адаптації;

$\mathbb{E}_{q\in Q}[.]$ – математичне сподівання показника клікабельності на ітерації t, що означає середній CTR по всіх запитах, документах і за певний період часу;

∇_{θ_t} - градієнт очікуваного CTR за параметрами θ, що показує у якому напрямку змінювати параметри, які параметри найбільше впливають на CTR, як підвищити клікабельність.

Параметри моделі коригуються у напрямку, який збільшує середню кількість кліків користувачів. Параметри оновлюються методом, що відповідає обраній цільовій функції. Якщо оптимізується диференційовний сурогат $L(\theta)$, застосовується $\theta_{t+1} = \theta_t - \eta_t \nabla\theta L(\theta_t)$, зв'язок L із CTR перевіряється окремо. Для недиференційовної цілі слід зазначити градієнтно-вільний або контекстно-бандитний метод і спосіб корекції експозиційного/позиційного зміщення. Формула (11) описує механізм адаптивного оновлення параметрів SEO/AGI-моделі на основі градієнта очікуваного показника клікабельності, що реалізує зворотний зв'язок між поведінкою користувачів і моделлю ранжування, спрямований на збільшення середнього показника клікабельності (CTR) на наступному кроці навчання.

Отже, адаптивне навчання є ітеративним процесом оновлення параметрів моделі на основі спостережуваних результатів її роботи з метою підвищення якості прийняття рішень у динамічному середовищі.

Оцінку процесу інтеграції AGI-компонентів можна зробити за допомогою наступних показників: Cosine similarity embeddings; Embeddings; SEO-score.

Cosine similarity embeddings - міра семантичної подібності між векторними представленнями текстів, яка показує, наскільки AGI коректно зберігає зміст.

Embeddings - числові векторні подання даних (тексту), що дозволяють AGI аналізувати сенс, контекст і зв'язки між об'єктами.

SEO-score (SEO-показник, SEO-оцінка) - інтегральний показник видимості та якості контенту для пошукових систем (релевантність, ключові слова, структура), що відображає ефект AGI на оптимізацію контенту. У цій роботі SEO-score не використовується як валідована метрика, оскільки його склад і спосіб вимірювання не визначено. Для подальшої перевірки потрібно задати формулу, джерела компонентів, шкалу, ваги та критерії зовнішньої валідності.

Для SEO-орієнтованої інтеграції AGI краще використовувати SEO-score, бо він напряму відображає вплив AGI-компонентів на пошукову видимість. Embeddings і cosine similarity доцільні як доповнення для внутрішньої оцінки семантичної якості, релевантності та узгодженості контенту.

Основні напрямки застосування розгорнутого штучного інтелекту (AGI) є:

– гіпер-персоналізація: моделі вже вміють читати між рядків, аналізують попередні запити, поведінку, навіть настрій. У недалекому майбутньому AGI змінюватиме заголовки, картинки, структуру тексту прямо під конкретного відвідувача, залежно від часу доби, пристрою чи місця. Персоналізація контенту може бути окремим напрямом застосування; її вплив на конверсію в цій роботі не оцінювався;

– предиктивний аналіз: замість реагувати постфактум система передбачатиме тренди, знаходитиме ще не зайняті теми, моделюватиме наслідки оновлень і сама пропонуватиме стратегію перелінковки чи лінкбілдінгу;

– мультимодальний контент AGI створюватиме цілі пакети: статтю з інфографікою, коротким відео, озвученням для голосового пошуку, квізом чи калькулятором. Усе буде пов'язане за змістом і оптимізовано під різні канали;

– самонавчання: система сама проводитиме A/B-тести, реагуватиме на зміни алгоритмів у реальному часі, виправлятиме технічні огріхи й коригуватиме стратегію за довгостроковими метриками.

Дискусія і висновки

Результати проведеного дослідження дають підстави розглядати застосування розгорнутого штучного інтелекту (AGI) у пошуковій оптимізації як перспективний напрям розвитку сучасних SEO-систем. Запропонована концептуальна модель відрізняється від традиційного підходу до SEO тим, що розглядає оптимізацію не як сукупність окремих технічних заходів, а як інтегрований процес взаємодії NLP, ML та LLM. Такий підхід дає змогу поєднати семантичний аналіз контенту, оцінювання релевантності, формування ознак, ранжування, генерацію та оцінювання якості контенту в межах єдиної адаптивної системи.

Важливим результатом дослідження є формалізація SEO/AGI-аналізу як задачі оптимізації, цільовою характеристикою якої визначено клікабельність результатів пошуку (CTR). Така постановка дає змогу перейти від оцінювання окремих характеристик вебдокумента до комплексного розгляду його позиції та потенційної взаємодії з користувачем. При цьому CTR у запропонованій моделі виступає цільовим показником, тоді як семантична релевантність, технічні фактори, UX, авторитетність та актуальність контенту формують простір ознак, на основі якого здійснюється ранжування.

Окремого значення набуває інтеграція LLM у запропоновану модель. LLM розглядається не лише як засіб генерації тексту, а як компонент, здатний формувати та оптимізувати контент відповідно до пошукового запиту, пошукового наміру користувача, структури, стилю та інших заданих обмежень. Запровадження функції оцінювання якості контенту створює можливість порівнювати декілька варіантів згенерованого тексту за такими характеристиками, як семантична релевантність, читабельність та відповідність пошуковому наміру. Це

розширює традиційне розуміння автоматизованої генерації контенту та переводить її у площину керованої оптимізації.

Перспективність запропонованого підходу також пов'язана з використанням механізму адаптивного навчання (feedback loop). На відміну від статичної моделі, параметри SEO/AGI-системи можуть коригуватися на основі спостережуваної поведінки користувачів. У такому випадку результати попередньої ітерації використовуються для подальшого уточнення параметрів моделі, що створює можливість її адаптації до змін пошукового середовища та поведінкових факторів. Таким чином, запропонована модель орієнтується не лише на формальне ранжування вебдокументів, а й на поступове підвищення ефективності взаємодії користувача з пошуковою системою.

Водночас концептуальний характер запропонованої моделі визначає певні обмеження дослідження. Модель математично формалізована на рівні редукованих моделей першого наближення, що забезпечує її інтерпретованість і зменшує математичну складність, однак не дає змоги повною мірою відобразити всі нелінійні взаємозв'язки реального SEO-середовища. Крім того, запропонована модель потребує практичної перевірки шляхом комп'ютерного моделювання та оцінювання її роботи на реальних даних. Тому отримані результати слід розглядати передусім як теоретико-методологічну основу для подальшої експериментальної перевірки, а не як емпірично підтверджену модель прогнозування пошукового ранжування.

Перспективним напрямом подальших досліджень є експериментальне оцінювання взаємозв'язків між семантичною релевантністю, якістю контенту, ранжуванням та поведінковими показниками користувачів. Зокрема, cosine similarity на основі embeddings може використовуватися для кількісного оцінювання семантичної близькості контенту до пошукового запиту, тоді як інтегральний SEO-score може бути застосований для оцінювання сукупного впливу AGI-компонентів на пошукову видимість. Комплексне використання таких показників створює основу для кількісної перевірки ефективності запропонованої моделі та окремих її компонентів.

З практичної точки зору запропонована модель може бути реалізована та перевірена засобами програмного моделювання, зокрема із застосуванням Python та відповідних бібліотек для математичного, статистичного й семантичного аналізу. Така реалізація дасть змогу дослідити вплив окремих параметрів моделі на результати ранжування, оцінювання якості контенту та поведінкові показники. Зокрема, використання механізму зворотного зв'язку може забезпечити послідовне коригування параметрів системи залежно від отриманих результатів.

Отже, запропонована SEO/AGI-модель формує концептуальну основу для інтеграції семантичного аналізу, машинного ранжування, генерації та оцінювання
контенту й адаптивного навчання в єдиному процесі. Її основною особливістю є поєднання формальних характеристик контенту з поведінковим зворотним зв'язком, що відповідає концепції переходу від класичного ранжування до user-centric SEO. Модель реалізує підхід, за якого оптимізація орієнтована не лише на позицію вебдокумента у пошуковій видачі, а й на релевантність контенту пошуковому наміру та ефективність взаємодії користувача з результатом пошуку.

Таким чином, у результаті дослідження розроблено концептуальну модель SEO/AGI-аналізу, що інтегрує NLP, ML та LLM у єдину адаптивну систему. Модель формалізує процеси визначення семантичної релевантності, ранжування, генерації та оцінювання якості контенту, а також використання зворотного зв'язку на основі поведінкових факторів. Запропонований підхід забезпечує теоретичне обґрунтування переходу від традиційного SEO до AI-орієнтованої та user-centric моделі оптимізації. Подальші дослідження мають бути спрямовані на програмну реалізацію моделі, її тестування на реальних наборах даних, визначення статистично значущих взаємозв'язків між її компонентами та експериментальне підтвердження ефективності запропонованого підходу.

Внесок авторів: Березовська Юлія – концептуалізація, формальний аналіз, написання (оригінальна
чернетка); Катков Юрій – методологія, написання (перегляд і редагування); Савенок Валерій – валідація даних, написання початкового варіанта (чернетки) статті; Василенко Володимир – методологія, написання (перегляд і редагування).

Джерела фінансування. Це дослідження не отримало жодного гранту від фінансової установи в державному, комерційному або некомерційному секторах.

Конфлікт інтересів: Автори заявляють про відсутність конфлікту інтересів.

Декларація про використання штучного інтелекту. При підготовці статті великі мовні моделі використовувалися виключно як інструмент підтримки для автоматизованого пошуку наукових джерел, попередньої тематичної класифікації лакун, а також для граматичного та стилістичного редагування тексту. Усі згенеровані класифікаційні блоки та бібліографічні посилання були критично перевірені, верифіковані через наукометричні бази CrossRef та Scopus і затверджені авторами, які несуть повну відповідальність за зміст роботи.

Список використаних джерел

Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). Language models are few-shot learners. *arXiv*. https://doi.org/10.48550/arXiv.2005.14165

Forsyth, D. (2019). *Applied machine learning*. Springer. https://doi.org/10.1007/978-3-030-18114-7

Google. (n.d.). *A guide to Google Search ranking systems*. Retrieved October 2, 2026, from https://developers.google.com/search/docs/appearance/ranking-systems-guide

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. https://www.deeplearningbook.org/

Manning, C. D., Raghavan, P., & Schütze, H. (2008). *Introduction to information retrieval*. Cambridge University Press. https://nlp.stanford.edu/IR-book/

Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson. https://aima.cs.berkeley.edu/

Supply Chain Dive. (2024). *UPS' Happy Returns taps into Geek+ sorting robotics*. https://www.supplychaindive.com/news/ups-happy-returns-uses-geek-plus-robotics/730957/

UPS. (n.d.). *Ecommerce returns management with Happy Returns*. Retrieved October 2, 2026, from https://www.ups.com/us/en/ups-happyreturns

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *arXiv*. https://doi.org/10.48550/arXiv.1706.03762

References

Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). Language models are few-shot learners. *arXiv*. https://doi.org/10.48550/arXiv.2005.14165

Forsyth, D. (2019). *Applied machine learning*. Springer. https://doi.org/10.1007/978-3-030-18114-7

Google. (n.d.). *A guide to Google Search ranking systems*. Retrieved October 2, 2026, from https://developers.google.com/search/docs/appearance/ranking-systems-guide

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. https://www.deeplearningbook.org/

Manning, C. D., Raghavan, P., & Schütze, H. (2008). *Introduction to information retrieval*. Cambridge University Press. https://nlp.stanford.edu/IR-book/

Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson. https://aima.cs.berkeley.edu/

Supply Chain Dive. (2024). *UPS' Happy Returns taps into Geek+ sorting robotics*. https://www.supplychaindive.com/news/ups-happy-returns-uses-geek-plus-robotics/730957/

UPS. (n.d.). *Ecommerce returns management with Happy Returns*. Retrieved October 2, 2026, from https://www.ups.com/us/en/ups-happyreturns

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *arXiv*. https://doi.org/10.48550/arXiv.1706.03762

Отримано редакцією журналу/Received:23.04.26
Прорецензовано / Revised: 15.05.26
Схвалено до друку / Accepted: 18.06.26
Опубліковано / Published: 30.06.26

Yurii KATKOV, DSc (Engin), Assoc. Prof.
ORCID ID: 0009-0007-1194-4014
e-mail: katkov@duikt.ua
State University of Information and Communication Technologies, Kyiv, Ukraine

Volodymyr VASYLENKO, PhD (Engin.), Assoc. Prof.
ORCID ID: 0000-0001-8465-6178
e-mail: vasilenko@duikt.ua
State University of Information and Communication Technologies, Kyiv, Ukraine

Yuliia BEREZOVSKA, PhD (Telecommunications and Radio Engineering)
ORCID ID: 0000-0002-9973-0497
e-mail: y.berezovska@duikt.edu.ua
State University of Information and Communication Technologies, Kyiv, Ukraine

Valeriy SAVENOK, Master's Student
ORCID ID: 0009-0001-3567-0448
e-mail: mag3433782@stud.duikt.edu.ua
State University of Information and Communication Technologies, Kyiv, Ukraine

CONCEPTUAL MODEL FOR THE APPLICATION OF ARTIFICIAL GENERAL INTELLIGENCE TOOLS IN SEARCH ENGINE OPTIMIZATION INTRODUCTION

Background. ***This article investigates the prospects of applying Artificial General Intelligence (AGI) to automate SEO analysis and content generation. The relevance of the study is determined by the need to improve the effectiveness of search engine optimization amid rapidly changing search engine algorithms, the growing volume of digital content, and the need to account for user behavior. The proposed conceptual model of SEO/AGI analysis involves the integration of Natural Language Processing (NLP), Machine Learning (ML), and Large Language Models (LLMs) into a unified adaptive system. Accordingly, the aim of the article is to develop a conceptual model of SEO/AGI analysis that formalizes the assessment of the semantic relevance of content, its ranking, generation, and optimization in accordance with user search intent.***

Methods. ***To develop the conceptual model of SEO/AGI analysis, methods of mathematical modeling, formalization, and optimization were employed. SEO/AGI analysis is considered as a problem of maximizing the Click-Through Rate (CTR) of search results. The model incorporates text vectorization and semantic relevance assessment using NLP, feature-space construction and a machine-learning-based ranking function, as well as conditional content generation and quality assessment using LLMs. To ensure the adaptability of the model, a feedback-loop mechanism is incorporated, enabling the system parameters to be adjusted based on user behavioral factors.***

Results. ***As a result of the study, a conceptual model of SEO/AGI analysis was developed that integrates NLP, ML, and LLM technologies into a unified sequential optimization process. The model encompasses text vectorization, semantic relevance assessment, feature-space construction, machine-based ranking, and content generation and quality assessment. The criteria for evaluating the integration of AGI components include cosine similarity, embeddings, and an SEO score, with the SEO score considered as an indicator directly characterizing the impact of AGI components on search visibility. The proposed adaptive learning mechanism enables iterative adjustment of the model parameters according to the results of user interactions with search results.***

Conclusions. ***The proposed conceptual model of SEO/AGI analysis formalizes the integration of NLP, ML, and LLM technologies into a unified adaptive system and provides a theoretical foundation for AI-oriented search engine optimization. The model combines semantic relevance assessment, ranking, content generation and quality evaluation, as well as the use of feedback based on user behavioral factors. The proposed approach provides a basis for transitioning from conventional ranking approaches toward user-centric SEO and may be applied in the further development of self-learning and adaptive SEO systems. A promising direction for future research is the validation of the proposed model through Python-based simulation using appropriate mathematical libraries.***

Keywords: ***SEO, AGI, artificial intelligence, machine learning, large language models, natural language processing, semantic relevance, ranking, CTR, SEO analysis.***

Автори заявляють про відсутність конфлікту інтересів. Спонсори не брали участі в розробленні дослідження; у зборі, аналізі чи інтерпретації даних; у написанні рукопису; в рішенні про публікацію результатів.
The authors declare no conflicts of interest. The funders had no role in the design of the study; in the collection, analyses or interpretation of data; in the writing of the manuscript; in the decision to publish the results.