

УДК 004.891:004.912:61

DOI <https://doi.org/10.32782/IT/2026-1-3>**Богдан БОБКО**

аспірант кафедри системного аналізу та інформаційних технологій, Вінницький національний технічний університет, Хмельницьке шосе, 95, м. Вінниця, Україна, 21021

ORCID: 0009-0004-1845-4841

Сергій ЖУКОВ

кандидат технічних наук, доцент, доцент кафедри системного аналізу та інформаційних технологій, Вінницький національний технічний університет, Хмельницьке шосе, 95, м. Вінниця, Україна, 21021

ORCID: 0009-0002-3443-6139

Scopus Author ID: 57191729653

Бібліографічний опис статті: Бобко, Б., Жуков, С. (2026). Системний аналіз ефективності інтелектуальних методів для ідентифікації клінічних закономірностей у неструктурованих медичних текстах. *Information Technology: Computer Science, Software Engineering and Cyber Security*, doi: <https://doi.org/10.32782/IT/2026-1-3>

СИСТЕМНИЙ АНАЛІЗ ЕФЕКТИВНОСТІ ІНТЕЛЕКТУАЛЬНИХ МЕТОДІВ ДЛЯ ІДЕНТИФІКАЦІЇ КЛІНІЧНИХ ЗАКОНОМІРНОСТЕЙ У НЕСТРУКТУРОВАНІХ МЕДИЧНИХ ТЕКСТАХ

Мета статті. Системний аналіз ефективності сучасних інтелектуальних методів обробки природної мови та машинного навчання для автоматизованої ідентифікації клінічних закономірностей і типових симптомокомплексів у неструктурованих медичних текстах. Робота спрямована на узагальнення та порівняльну оцінку підходів до виявлення частотних і контекстуальних патернів у клінічних записах, а також на визначення перспектив застосування класичних алгоритмів, глибокого навчання, гібридних моделей та AutoML-платформ у задачах багатокласової та багатоміткової класифікації симптомів і діагнозів. Особливу увагу приділено ролі контекстуальних характеристик у підвищенні достовірності автоматизованого аналізу клінічних текстів.

Методологія. Дослідження виконано у формі систематичного огляду з використанням рекомендацій PRISMA. Пошук наукових публікацій здійснювався в базах даних PubMed, EMBASE та Scopus без обмежень за роком публікації, з урахуванням україномовних і англійських джерел. Загальний масив становив 1993 унікальні записи після усунення дублікатів, з яких 38 статей було включено до фінального аналізу за визначеними критеріями. Проведено структурований відбір та ручне вилучення даних щодо типів клінічних корпусів, методів NLP, алгоритмів контекстного аналізу, моделей машинного навчання та метрик оцінювання. Додатково виконано кількісний аналіз частоти симптомів і симптомокомплексів, а також аналіз контекстуальних патернів із використанням лексичних правил і трансформаторних моделей.

Наукова новизна. Наукова новизна роботи полягає у комплексному поєднанні частотного та контекстуального підходів до аналізу клінічних текстів із фокусом саме на симптомокомплекси, а не окремі симптоми. Уперше в межах одного дослідження здійснено порівняльний аналіз ефективності правил, класичних методів машинного навчання, глибоких нейронних мереж, гібридних підходів та AutoML-рішень для задач ідентифікації клінічних закономірностей. Показано критичну роль алгоритмів контекстного аналізу, зокрема CoNText, у підвищенні точності автоматизованої інтерпретації клінічних станів та обґрунтовано доцільність використання F1-оцінки й AUC як базових інтегральних метрик для оцінювання багатокласових і багатоміткових моделей.

Висновки. Результати системного аналізу свідчать, що найвищу ефективність у задачах ідентифікації клінічних закономірностей демонструють підходи, які поєднують статистичні ознаки з контекстно-чутливими моделями машинного навчання. Урахування заперечення, гіпотетичності та часових характеристик істотно зменшує кількість хибних спрацювань і підвищує інформативність автоматизованого аналізу клінічних текстів. Використання AutoML і трансформаторних моделей розширює можливості масштабування таких рішень у реальних умовах, однак потребує уваги до інтерпретованості та переносимості моделей. Отримані результати можуть бути використані для побудови систем підтримки клінічних рішень, моніторингу захворюваності та подальших досліджень у сфері інтелектуального аналізу медичних даних.

Ключові слова: клінічні тексти, симптомокомплекси, автоматизований аналіз, обробка природної мови (NLP), контекстуальні патерни, машинне навчання, інформаційні технології в медицині.

Bohdan BOBKO

Postgraduate Student at the Department of System Analysis and Information Technologies, Vinnytsia National Technical University, 95, Khmelnytsky highway, Vinnytsya, Ukraine, 21021, bobko.bogdan@gmail.com
ORCID: 0009-0004-1845-4841

Serghii ZHUKOV

Candidate of Technical Sciences, Associate Professor, Associate Professor at the Department of System Analysis and Information Technologies, Vinnytsia National Technical University, 95, Khmelnytsky highway, Vinnytsya, Ukraine, 21021, sazhukov@gmail.com
ORCID: 0009-0002-3443-6139
Scopus Author ID: 57191729653

To cite this article: Bobko, B., Zhukov, S. (2026). Systemnyi analiz efektyvnosti intelektualnykh metodiv dlia identyfikatsii klinichnykh zakonomirnostei u nestrukturovanykh medychnykh tekstakh [System analysis of the effectiveness of intelligent methods for identifying clinical patterns in unstructured medical texts]. *Information Technology: Computer Science, Software Engineering and Cyber Security*, doi: <https://doi.org/10.32782/IT/2026-1-3>

SYSTEM ANALYSIS OF THE EFFECTIVENESS OF INTELLIGENT METHODS FOR IDENTIFYING CLINICAL PATTERNS IN UNSTRUCTURED MEDICAL TEXTS

Purpose of the article. A systematic analysis of the effectiveness of modern intelligent methods based on natural language processing (NLP) and machine learning for the automated identification of clinical patterns and typical symptom complexes in unstructured medical texts. The study aims to summarise and comparatively evaluate existing approaches to detecting frequency-based and context-sensitive patterns in clinical narratives, as well as to assess the applicability of classical machine learning algorithms, deep learning models, hybrid approaches, and AutoML platforms for binary, multiclass, and multilabel classification of symptoms and diagnoses. Special attention is given to the role of contextual characteristics in improving the reliability of automated clinical text interpretation.

Methodology. The research was conducted as a systematic review following PRISMA guidelines. Scientific publications were retrieved from the PubMed, EMBASE, and Scopus databases without restrictions on publication year, covering both English- and Ukrainian-language sources. After duplicate removal, a total of 1,993 records were screened, of which 38 studies met all inclusion criteria and were selected for full analysis. A structured data extraction process was applied to identify types of clinical text corpora, NLP techniques, contextual analysis algorithms, machine learning models, and evaluation metrics used in each study. In addition, a quantitative analysis of symptom and symptom-complex frequencies was performed, along with an examination of contextual patterns using rule-based methods and transformer-based models.

Scientific novelty. The scientific novelty of this work lies in its comprehensive integration of frequency-based and context-aware analytical approaches with a specific focus on symptom complexes rather than isolated symptoms. For the first time, a comparative assessment of rule-based methods, classical machine learning algorithms, deep neural networks, hybrid models, and AutoML solutions is presented within a unified framework tailored to the identification of clinical patterns in unstructured texts. The study substantiates the critical importance of contextual analysis algorithms, particularly ConText, for improving the accuracy of automated symptom interpretation and justifies the use of F1-score and AUC as the most informative evaluation metrics for multiclass and multilabel clinical classification tasks.

Conclusions. The results of the systematic analysis demonstrate that approaches combining statistical feature extraction with context-sensitive machine learning models achieve the highest effectiveness in identifying clinical patterns in unstructured medical texts. Incorporating contextual attributes such as negation, temporality, and hypothetical status significantly reduces false detections and enhances the clinical validity of automated analyses. The adoption of AutoML platforms and transformer-based architectures increases scalability and practical applicability, although challenges related to model interpretability and cross-domain generalisation remain. The findings support the use of intelligent NLP-based systems for clinical decision support, disease surveillance, and large-scale analysis of medical narratives, and provide a methodological foundation for further research in intelligent medical data analysis.

Key words: clinical texts, symptom complexes, automated analysis, natural language processing (NLP), contextual patterns, machine learning, information technologies in medicine.

Вступ. Ця стаття концептуально продовжує результати аналітичного огляду методів виявлення аномалій у медичній статистиці (Бобко, 2025, с. 402-413). Якщо попереднє дослідження було зосереджене на теоретичних засадах і алгоритмічних підходах до ідентифікації нетипових даних, то поточна стаття розширює ці положення на домен клінічних текстів. У межах такого розширення увага приділяється автоматизованому виявленню типових симптомкомплексів, що також ґрунтується на аналізі аномальних та контекстно зумовлених патернів. У цій роботі формується наступний етап розвитку дослідження, поглиблюючи його методологічні та прикладні аспекти.

Методи обробки природної мови (NLP) є основою сучасної медичної інформатики, оскільки вони дозволяють автоматично витягувати відповідні змінні з клінічних записів у вигляді вільного тексту. Отримана таким чином інформація використовується для прийняття клінічних рішень, контролю якості медичної допомоги та систем біоспостереження (Haritima, 2024; Dreisbach, 2019; Chen, 2021; Venkataraman, 2020; Huang, 2019; Kambala, 2024; Mustafa, 2021). Більшість існуючих робіт зосереджені на виявленні окремих клінічних станів у тексті, що є важливим першим кроком до інтеграції неструктурованих медичних даних у комп'ютерні системи.

Однак виявлення згадки про клінічний стан не завжди достатньо для вирішення численних практичних проблем медичної інформатики. Для точної ідентифікації клінічного стану пацієнта важливо враховувати контекст, у якому згадується певний стан. Зокрема, необхідно розуміти, чи є підтверджений або заперечений стан гострим чи хронічним, і чи є згадка гіпотетичною, чи стосується минулого. Ці ознаки були названі контекстуальними ознаками, оскільки вони зазвичай не виражаються безпосередньо в лексичному представленні клінічного терміна, а містяться в навколишньому текстовому контексті (Mustafa, 2021, с. 24).

Для автоматизації вилучення таких контекстних ознак було розроблено алгоритм ConText, орієнтований на завдання біоспостереження. Алгоритм обробляє текст звітів відділення невідкладної допомоги та визначає три ключові контекстуальні параметри: заперечення, гіпотетичний статус та історичне посилання. Продуктивність алгоритму було перевірено шляхом порівняння його результатів з анотаціями медичних експертів. Отримані результати продемонстрували, що правильність автоматизованого аналізу клінічного тексту значно покращується при врахуванні контексту, і що це є критично

важливим для подальшої інтеграції медичних даних в інформаційні системи. В сучасній медицині інформація про пацієнтів в значній мірі базується на записах клінічних текстів, які включають історії хвороб, виписки та медичні нотатки (Sreenivasgoud, 2023). Ці дані охоплюють опис симптомів, діагнозів і лікувальних процедур, проте досить часто залишаються в неструктурованому вигляді, що робить їх системне використання для досліджень, клінічного моніторингу та прийняття рішень проблематичним.

Методи, якими можна дослідити медичні тексти, наприклад, ручне кодування чи експертні оцінки, є ресурсозатратними, схильними до суб'єктивності і не дають можливість швидко ідентифікувати типовий симптомкомплекс у великих обсягах даних. В той же час, сучасні підходи до автоматичного аналізу текстів, зокрема за допомогою методів машинного навчання та обробки природної мови, відкривають можливість максимально ефективно знаходити патерни та частотні закономірності в клінічних записах (Sreenivasgoud, 2023).

Існує кількість досліджень, присвячених питанню автоматизованого аналізу клінічних даних, але все одно залишається багато проблем, зокрема: відсутність стандартів для визначення симптомкомплексів, недостатнє врахування контекстуальних зв'язків між симптомами, а також обмежена перевірка результатів на великій кількості реальних клінічних текстів. Це зумовлює потребу у розробці методів, що дозволяють не тільки системно ідентифікувати типові симптомкомплекси, а й аналізувати їхню частоту і контекстуальні патерни для подальшого використання у клінічній практиці та академічних дослідженнях (Mowery, 2015, с. 183–193).

У сучасних дослідженнях автоматизованого аналізу клінічних текстів велика увага приділяється включенню контекстуальних ознак медичних записів. Під час автоматичного індексування клінічних станів дуже важливо з'ясувати, чи є певний стан заперечуваним, гіпотетичним, історичним, чи стосується іншої особи, а не самого пацієнта. Для вирішення цієї проблеми було створено алгоритм ConText, який розширює відомий алгоритм NegEx. ConText використовує набір тригерних, псевдотригерних та кінцевих термінів для автоматичного визначення трьох основних контекстуальних ознак (Allam, 2025, с. 130).

Незважаючи на свою відносну простоту, алгоритм продемонстрував високу продуктивність у виявленні заперечуваних та гіпотетичних тверджень у клінічних текстах. Крім того,

алгоритм дав задовільні результати при визначенні того, чи належав стан іншій особі та чи мав він історичний характер. Використання таких алгоритмів дозволяє значно підвищити точність автоматизованої ідентифікації симптомів, оскільки врахування контексту є ключем до правильної інтерпретації клінічних даних.

Сьогодні аналіз неструктурованого клінічного тексту є одним із основних напрямків у медицині, оскільки він дозволяє ідентифікувати симптомокомплекси, моніторити стан пацієнтів та підтримувати клінічні рішення. Автоматизовані методи обробки природної мови (NLP) та текстового інтелектуального аналізу дозволяють отримувати з медичних нарративів цінні дані про симптоми, побічні ефекти та звіти пацієнтів, які рідко записуються в структурованих полях електронних медичних записів (Dreisbach, 2019; Mowery, 2015).

У своєму систематичному огляді Дрісбе К. та ін. (Dreisbach, 2019, с. 37–46) виділили основні тенденції розвитку досліджень NLP: поширення методів попередньої обробки, використання лексиконів та правил у поєднанні з машинним навчанням та відсутність стандартизованих підходів до оцінки результатів. Подібні висновки зробили Моєрі Д. та ін. (Mowery, 2015), які наголошують, що клінічне NLP поступово переходить від пошуку за ключовими словами до семантичного аналізу, але все ще чутливе до контексту та специфіки медичної сфери.

Серед поширених підходів все ще існують традиційні методи (словники, TF-IDF, класичні алгоритми машинного навчання), а також сучасні моделі глибокого навчання. Дослідження Хуана З., Осоріо К. та Сая Л. (Huang, 2019, с. 141–153) показало, що нейронні мережі забезпечують високу точність автоматичного кодування (МКХ-9) клінічних записів, але вимагають великої кількості анотованих даних. Ванкатараман Г. Р. та співавтори (Venkataraman, 2020) у своїй статті FasTag продемонстрували потенціал автоматичної класифікації медичних нарративів, підкреслюючи важливість балансування даних та вибору відповідних ознак.

Використання AutoML та адаптивних екосистем у працях Мустафа А., Рахімі Азгаді М. (Mustafa, 2021, с. 24); Харітіма Х. та колеги (Haritima, 2024, с. 45–54) сприяло автоматизації процесу побудови моделі, зокрема вибору архітектур та гіперпараметрів. Це відкриває шлях для ширшого впровадження в медичній практиці, хоча часто виникає проблема інтерпретації моделі та врахування клінічного контексту.

Срініवासгауд П. та колеги (Sreenivasgoud, 2023) та авторський колектив на чолі з

Сім Дж.-А. (Sim, 2024) досліджували використання NLP для аналізу результатів, про які повідомляють пацієнти, та розробки систем підтримки клінічних рішень. Автори наголошують, що інтеграція NLP у робочі процеси вимагає стандартизації форматів даних та створення зрозумілих інтерфейсів для клініцистів.

Чен І. Й. та співавтори (Chen, 2021, с. 123–144) наголошують, що розвиток машинного навчання в охороні здоров'я має йти пліч-о-пліч з етичними принципами – прозорістю, справедливістю та безпекою алгоритмів. Васундхара С. (Vasundhara, 2023, с. 495–497) та Камбала М. (Kambala, 2024, с. 34–47) додатково вказують на технічні бар'єри (низька якість текстових даних, відсутність уніфікованих анотацій) та організаційні обмеження такі, як брак ресурсів, кваліфікованого персоналу. Систематичні огляди вказують на різноманітність показників оцінки моделей (точність, повнота, F1-оцінка тощо), що ускладнює порівняння результатів різних робіт (Dreisbach, 2019; Allam, 2025). Крім того, різні стилі клінічної документації зменшують можливість передачі моделей між медичними закладами. Найновіші дослідження, які провів Алам Х. та колеги (Allam, 2025, с. 130); Камбала М. (Kambala, 2024, с. 34–47) демонструють широке використання трансформаторних моделей, алгоритмів самонавчання та гібридних підходів, що поєднують правила, статистику та нейронні мережі. Харітіма Х. та співавтори (Haritima, 2024, с. 45–54) запропонували ідею адаптивної екосистеми оптимізованих рішень для охорони здоров'я, де NLP є частиною інтегрованого програмного середовища.

Аналіз сучасних досліджень показує, що автоматизоване виявлення клінічних патернів потребує поєднання масштабованих обчислювальних технологій, семантичного аналізу тексту та контекстно-чутливих моделей. У роботі Долінського представлено ефективні рішення для обробки великих обсягів текстових даних із використанням Apache Spark для побудови NLP-систем у медицині (Долінський, 2018). Новіков продемонстрував можливості нейронних мереж у діагностуванні. Однак такий підхід обмежений вузькою вибіркою та відсутністю глибокої контекстної обробки клінічних записів (Новіков, 2021, с. 65). Публікація Різака Г. і співавторів стосується інтеграції штучного інтелекту в доказову медицину та важливості міждисциплінарної підготовки кадрів (Різак, 2023), тоді як роботи Чабана О. (Чабан, 2025, с. 297–301), Черниш К. та Білошицької О. стосуються систем підтримки прийняття, інтерпретованості та клінічної валідації лікарських рішень (Черниш,

Білошицька, 2022, 119–121). Найбільш релевантними для вирішення завдання виявлення симптомокомплексів є праці Чабана О. (Чабан, 2025, 297–301) та А. В. Лосенка і колег (Лосенко, 2024, с. 135–144).

Незважаючи на досягнення, література виявляє кілька суттєвих прогалин. Зокрема, недостатня кількість досліджень, що зосереджені саме на ідентифікації та класифікації симптомокомплексів, а не окремих симптомів; відсутність порівняльного аналізу ефективності методів (правила, класичне машинне навчання, глибокі мережі, AutoML) спеціально для завдання виявлення закономірностей симптомів; недостатнє врахування питання переносимості моделей між клінічними умовами та інтеграції етичних вимог у практику.

Тому актуальною проблемою є розробка методів автоматизованого аналізу частотних та контекстуальних закономірностей у клінічних текстах з акцентом на симптомокомплексі, що дозволить покращити якість клінічних даних та забезпечити ефективнішу підтримку рішень в охороні здоров'я.

Метою роботи є систематичний аналіз ефективності автоматизованих методів для виявлення типових симптомокомплексів у клінічних текстах за допомогою машинного навчання та аналізу частотно-контекстних патернів і показати можливість використання великих мовних моделей (LLM) для цих задач.

Методологія дослідження. Пошук і відбір матеріалів були проведені у березні 2025 року в базах даних PubMed, EMBASE і Scopus. Ініціативним завданням було ідентифікувати релевантні публікації, які б висвітлювали методи обробки природної мови (NLP), текстового майнінгу та визначення симптомів чи симптомокомплексів у клінічних текстах. У ході попереднього огляду було ухвалено рішення про поділ текстових корпусів залежно від їх джерела, зокрема, було вирішено розділити електронні медичні записи (EHR) і інші джерела клінічної інформації. Відповідно, були організовані два окремі огляди: один – для текстів EHR, інший – для корпусів клінічних звітів, електронних історій хвороби та іншої медичної документації.

Симптом у контексті даного дослідження розглядався як суб'єктивна ознака хвороби, що відображає стан здоров'я пацієнта або клінічний стан, який був описаний у тексті (наприклад, тривога, втома, порушення сну, нудота, біль, пригнічений настрій). Пошукова стратегія була побудована навколо використання ключових слів і їх комбінацій, створених із урахуванням словника Medical Subject Headings (MeSH) для

PubMed і відповідних дескрипторів для EMBASE і Scopus. Терміни включали слова, пов'язані з конкретними симптомами та їх контекстуальними характеристиками (заперечення, гіпотетичність, історичність), а також слова, що стосуються обробки природної мови та текстового аналізу (наприклад, natural language processing, text mining, symptom, negation, context).

Пошук не мав обмежень щодо року публікації, але був обмежений двома мовами – англійською та українською. В результаті було знайдено 954 записи в PubMed, 1283 записи в EMBASE і 467 у Scopus. Після виключення дублікатів (n = 711) аналізу підлягали 1993 записи.

Відбір публікацій був здійснений відповідно до рекомендацій PRISMA (набір критеріїв для систематичних оглядів і мета-аналізів). Включенням визначалися статті, в яких описувались, оцінювались або застосовувались NLP чи текстовий майнінг, алгоритми для автоматизованого виявлення симптомів чи симптомокомплексів у клінічних текстах. Було виключено оглядові статті, публікації без повного тексту, роботи, які не були написані англійською (крім української), і дослідження, у яких не застосовувались підходи NLP до аналізу симптомів.

Два незалежних рецензенти виконували скринінг назв і анотацій, після чого вони обговорювали результати для досягнення консенсусу щодо включення. Із 74 статей, відібраних для повнотекстового аналізу, 38 відповідали всім критеріям включення. Основні причини виключення були: дослідження текстів не клінічної природи (n = 15), відсутність методів NLP або контекстуального аналізу (n = 12), фокус на структурованих даних, а не на вільному тексті (n = 9).

Зі статей, що пройшли відбір, були вручну вилучені дані про:

- вид корпусу (EHR, клінічні звіти тощо),
- характеристики пацієнтів або джерела тексту,
- описані симптоми і симптомокомплексі,
- застосування методів NLP (частотний аналіз, тематичне моделювання, кластеризація, алгоритми заперечення/контексту),
- результати та показники ефективності алгоритмів.

Крім того, був проведений кількісний аналіз частоти згадування симптомів і симптомокомплексів у текстах, а також аналіз контекстуальних патернів із використанням лексичних індикаторів і класифікаційних моделей (зокрема моделі типу BERT). Для підвищення достовірності оцінювання здійснювався подвійний контроль вилучених даних.

Результати. Розроблені та адаптовані системи обробки природної мови (NLP) продемонстрували ефективність у кодуванні клінічної текстової інформації, що є ключовим кроком до автоматизованої ідентифікації типових симптомкомплексів. Зокрема, системи MedLEE, MPLUS та MedSyndicate успішно реалізують кодування таких контекстуальних ознак, як заперечення, невизначеність, часові зміни та тяжкість діагнозу. Аналіз літератури за останні десять років показує активний розвиток алгоритмів виявлення заперечення в клінічних звітах, що забезпечує підвищення точності автоматизованої індексації.

Алгоритм ConText, який розширює можливості базового алгоритму NegEx, є основним серед обговорюваних рішень. Відмінністю ConText є можливість інтеграції як окремого модуля в будь-яку систему, яка індексує клінічні стани з тексту. ConText ефективно ідентифікує контекстуальні характеристики, такі як заперечення, гіпотетичність або часові параметри стану, тим самим забезпечуючи більш точне виявлення та класифікацію симптомкомплексів у клінічних описах.

Крім того, велика увага була приділена використанню даних відділень невідкладної допомоги як джерела оперативної клінічної інформації для біологічного спостереження та ситуаційної обізнаності. Традиційні системи спостереження здебільшого спираються на скарги пацієнтів та коди МКХ-9, що обмежує повноту клінічної картини та забезпечує лише помірний рівень чутливості. Запропоновані методи NLP дозволяють автоматично витягувати відповідні клінічні стани зі звітів відділення невідкладної допомоги, що розширює можливості спостереження за синдромами в режимі реального часу (табл. 1).

Огляд різних підходів, призначених для клінічного аналізу тексту, наведено в Таблиці 1. ConText продемонстрував найвищу продуктивність для завдання визначення атрибутів контексту в клінічних описах перебування

у відділенні невідкладної допомоги. Загалом, найкраща продуктивність цього алгоритму була отримана для випадку заперечення, при цьому як повнота, так і точність досягли понад 97%. Це показує здатність ConText точно виявляти, чи клінічна ознака відсутня або заперечується в тексті.

Для ознаки «Часовий контекст: гіпотетичний (Temporality – hypothetical)» точність і повнота алгоритму становили 94,3% та 82,5% відповідно, що дозволило надійно виявити гіпотетичний стан. Водночас, для атрибута «Часова приналежність: історична» точність і повнота були нижчими (74,2% та 67,4 відповідно), що пояснюється меншою кількістю таких випадків у тестовому наборі та складністю визначення історичних станів у тексті.

Ознака «Пацієнт/інші особи (Experiencer)» мала дуже мало прикладів у тестових даних ($n = 8$), тому надійність оцінки була обмеженою. Хоча точність для цього атрибута досягла 100%, повнота була лише 50%, що вказує на необхідність розширення навчального корпусу для покращення виявлення таких рідкісних контекстів.

Ці результати демонструють, що ConText є ефективним інструментом для визначення ключових контекстних ознак, необхідних для правильної інтерпретації клінічних станів пацієнтів у текстах відділення невідкладної допомоги. Це підкреслює потенціал алгоритму для використання в автоматизованих системах спостереження та підтримки клінічних рішень.

Вибір методів вилучення ознак з клінічних текстів є вирішальним моментом у побудові ефективних систем автоматичного аналізу даних. Різні дослідницькі підходи поєднують статистичні моделі, методи розподіленого представлення слів та спеціалізовані медичні інструменти для підвищення точності класифікації та кодування клінічних записів. У таблиці 2 наведено порівняльний опис основних методів, що використовувалися в останніх дослідженнях.

Таблиця 1

Показники ефективності алгоритму ConText у тестовому наборі з 90 звітів відділень невідкладної допомоги

Контекстуальна ознака	Істинно позитивні	Істинно негативні	Хибно позитивні	Хибно негативні	Чутливість, % (95% CI)	Точність, % (95% CI)
Заперечення (Negation)	750	824	23	23	97.0 (96–98)	97.0 (96–98)
Часовий контекст: історичний (Temporality – historical)	66	1499	23	32	67.4 (58–76)	74.2 (64–82)
Часовий контекст: гіпотетичний (Temporality – hypothetical)	33	1578	2	7	82.5 (68–91)	94.3 (81–98)
Пацієнт/інші особи (Experiencer)	4	1612	0	4	50.0 (22–78)	100 (51–100)

Таблиця 2 показує застосування різних методів вилучення ознак у аналізі клінічних текстів. Традиційні методи – такі як TF-IDF і BOW – все ще широко визнані в машинному навчанні та класифікації текстів, тоді як методи векторів слів (Word2Vec, GloVe) в основному застосовуються для моделювання семантичних відносин між словами в глибокому навчанні. Спеціалізовані медичні аналітичні інструменти (cTAKES, MetaMap) використовуються для автоматизованого вилучення клінічних термінів, кодування ICD та семантичного аналізу. У підрахунку використання методів cTAKES найчастіше використовується для аналітики медичних текстів (10 досліджень), тоді як MetaMap використовувався рідше (2 дослідження). Традиційні техніки, такі як TF-IDF і BOW, все ще корисні для базової класифікації, але векторні представлення та сучасні підходи NLP дозволяють покращити точність і краще розуміння контексту клінічних даних.

Розробка моделей машинного навчання (ML) для аналізу клінічного тексту проходить етапи вилучення та відбору ознак, після чого розробляється та оптимізується алгоритм ML проекту відповідно до заданих метрик оцінки.

Клінічні записи зазвичай класифікуються для виявлення певного захворювання, симптому або поведінки пацієнта. Як і в інших областях ML, завдання класифікації можна розділити на три типи: бінарна, багатокласова та багатоміткова багатокласова класифікація. Бінарна класифікація використовується для підтвердження наявності або відсутності певного стану або поведінки, наприклад, наявності діабету або куріння. У такій класифікації цільова змінна може приймати лише два значення: 0 або 1.

Багатокласова класифікація дозволяє алгоритму ML передбачати один з трьох або більше класів, наприклад, різні захворювання за кодами МКХ-9 або групами крові (O, A, B, AB).

Багатоміткова багатокласова класифікація передбачає кілька цільових класів для одного запису, де кількість цільових значень може відрізнятися від пацієнта до пацієнта. Наприклад, одному пацієнту може бути призначено кілька ліків одночасно, тоді як іншому – інший набір. Для обробки таких даних використовуються підходи до перетворення багатомічених цілей на багатокласові або бінарні цілі (Chen, Pierson, Rose, Joshi, Ferryman, Ghassemi, 2021; Sreenivasgoud, Sharma, Kumar, Nijhawan,

Таблиця 2

Методи вилучення ознак для клінічних записів

Дослідження	TF-Ізраїльські Сили Оборони	LUK	Word2Vec	Glove	cTAKES	Metamap
ML та NLP для класифікації клінічних записів	✓	✓	✓	×	✓	×
Оцінка глибокого навчання для ICD	✓	✓	✓	×	×	×
Класифікація клінічного тексту	✓	×	×	×	×	×
Анотація клінічного тексту	✓	×	×	×	×	×
Ідентифікація вживання алкоголю	✓	×	×	×	×	×
Автоматизоване кодування ICD	✓	×	×	×	×	×
Індексація біомедичної літератури	✓	×	×	×	×	×
Багатолейблова класифікація	×	✓	✓	×	×	×
Автоматичне виявлення психічного стану	×	✓	✓	×	×	×
ML та NLP для клінічного кодування	×	✓	✓	×	×	×
Підхід машинного навчання до кодування	×	✓	✓	×	×	×
Вибір ознак з BOW	×	✓	✓	×	×	×
Вилучення медикаментів	×	×	✓	×	×	×
Кодування ICD з використанням глибокого навчання	×	×	✓	×	×	×
Моделі машинного навчання для клінічного кодування та класифікації медичних записів	×	×	✓	✓	×	×
Навчання вбудов з медичних записів	×	×	×	✓	×	×
Штучний інтелект для класифікації діагнозів	×	×	×	✓	×	×
ML та NLP для класифікації клінічних записів	×	×	×	✓	×	×

Al-Jawahry, Udhayakumar, 2023). Оцінка моделі виконується за стандартними показниками: повнота, точність, F1-оцінка, специфічність, коефіцієнт помилок та точність, а також площа під ROC-кривою (AUC) часто використовується для багатокласових та багатомічених завдань (Mustafa, Rahimi Azghadi, 2021, 24). Автори у своєму дослідженні використовували бінарну класифікацію для прогнозування депресії з клінічних записів на основі набору даних MIMIC, який включав 1610 записів (460 випадків депресії). Дані були розділені на 70% для навчання, 10% для валідації та 20% для тестування. Найкращі результати були досягнуті за допомогою CNN: точність – 91%, повнота – 76%, F1 – 83% (табл. 3).

Хоча бінарна класифікація демонструє високу точність для окремих захворювань або поведінкових рис, її чутливість (повнота) може бути нижчою, що вказує на можливість пропуску деяких позитивних випадків. Багатокласова класифікація підходить для класів, які є взаємовиключними, як-от коди ICD, але F1-оцінка відрізняється залежно від розподілу класів. Багатокласова класифікація з багатьма мітками полегшує одночасну класифікацію кількох станів пацієнта, хоча F1-оцінка значною мірою залежить як від складності кодування, так і від обраних алгоритмів. Для складних багатокласових і багатоміткових завдань метрики F1 та AUC є найбільш репрезентативними для оцінки якості моделі, оскільки вони враховують як точність, так і чутливість.

Прикладом багатокласової класифікації є робота з визначення статусу куріння пацієнтів за допомогою гібридного підходу (сTAKES + ML та правила). Модель класифікувала пацієнтів за категоріями: «можливий курець», «колишній

курець», «некурець» та «невідомо». В результаті, мікросередня точність досягла 0,967 для F1, прецизійності та повноти, що демонструє ефективність багатокласового підходу. У багатоміткових багатокласових завданнях для клінічного кодування використовувалися такі підходи: ланцюг класифікатора, ансамбль ланцюгів класифікатора, MLKNN та нейронні мережі (Chen, Pierson, Rose, Joshi, Ferryman, Ghassemi, 2021; Sreenivasgoud, Sharma, Kumar, Nijhawan, Al-Jawahry, Udhayakumar, 2023). Наприклад, метод ECC-LR дав найкращий F1 для більшості груп кодів ICD (від 41% до 93,3% залежно від групи). Деякі автори використовували LR, NN, RNN, LSTM та GRU для прогнозування кодів ICD-9 у наборі даних MIMIC; найкращий F1 для топ-10 кодів був у GRU – 42,03%, а для топ-100 кодів у RNN – 24,39%. Для платформ AutoML, таких як Auto-Sklearn, Auto-WEKA, Auto-Keras, JADBIO та AutoPrognosis, основними показниками оцінки залишаються коефіцієнт помилок, точність та площа під кривою (AUC), особливо для завдань з кількома класами та кількома мітками (Mustafa, Rahimi Azghadi, 2021; Vasundhara, 2023). F1 залишається ключовим показником завдяки своїй здатності поєднувати точність та повноту і забезпечувати більш повну оцінку продуктивності моделі (див. табл. 3).

Таким чином, результати попередніх досліджень ілюструють, що успіх автоматичного виявлення комплексу симптомів у клінічних текстах значною мірою залежить від типу класифікації та вибору показників оцінки. Бінарна класифікація підходить для окремих захворювань, багатокласова – для кількох взаємовиключних класів, а багатоміткова багатокласова – для складних сценаріїв, де пацієнт може мати кілька одночасних станів або кодів діагнозів.

Таблиця 3

Результати класифікації клінічних текстів різними методами машинного навчання

Тип класифікації	Алгоритм/ Модель	Кількість класів	Метрики оцінювання	Результати
Бінарна	CNN	2 (депресія/ без депресії)	Precision/Recall/F1	91%/76%/83%
Бінарна	SVM + сTAKES	2 (курець/ не курець)	Micro-average Accuracy/ F1	96,7%/0,967
Багатокласова	SVM	18 ICD-кодів (ендокринні та метаболічні)	Recall/Precision/F1	74,68%/97,3%/84,5%
Багатокласова	RF/CNN	10-20 класів	F1/AUC	65–88%/0,79–0,91
Багатозначна багатокласова	ECC-LR	18 ICD-груп	F1	41–93,3%
Багатозначна багатокласова	GRU	Топ-10 ICD-9 кодів	F1	42,03%
Багатозначна багатокласова	RNN	Топ-100 ICD-9 кодів	F1	24,39%

Обговорення. Результати дослідження підтверджують, що автоматизовані підходи до класифікації клінічних текстів є потужними інструментами для виявлення типових симптомомкомплексів у медичних записах. Були проаналізовані різні типи класифікації – бінарна, багатокласова та багатоміткова багатокласова – і було виявлено, що кожен з них має свої переваги та недоліки залежно від конкретного завдання та структури даних. Бінарна класифікація, яка дозволяє визначити наявність захворювання або поведінкової характеристики, продемонструвала високу точність та F1-метрику, що відповідає результатам попередніх досліджень (Huang, 2019; Mustafa, 2021). Однак її обмеження полягає в тому, що її не можна використовувати для одночасного виявлення кількох патологічних станів, що може бути надзвичайно важливим для комплексної оцінки пацієнта. Багатокласова класифікація продемонструвала здатність моделювати взаємовиключні класи, наприклад, коди МКХ захворювань, і дозволяє точніше прогнозувати певний діагноз серед кількох варіантів (Sreenivasgoud, 2023). Однак точність моделей у таких завданнях сильно залежить від балансу класів та кількості доступних даних для рідкісних діагнозів. Це узгоджується з результатами попереднього дослідження, де F1 коливався від 41% до 93% залежно від груп МКХ та обраної моделі (Haritima, 2024; Sreenivasgoud, 2023). Багатоміткова багатокласова класифікація виявилася особливо ефективною для одночасного прогнозування кількох діагнозів або препаратів, що узгоджується з реальними клінічними сценаріями, де пацієнт може мати супутні захворювання (Kambala, 2024; Sreenivasgoud, 2023). Використання таких підходів, як ансамбль класифікаторних ланцюгів (ECC-LR) або рекурентні нейронні мережі (RNN, GRU), може підвищити точність та зменшити ризик пропуску важливих діагнозів. Метрики оцінки для моделей, а саме F1 та AUC, виявилися найбільш репрезентативними для всіх типів класифікації, оскільки вони одночасно враховують точність та повноту моделі (Haritima, 2024; Dreisbach, 2019; Mustafa, 2021). Це особливо важливо для медичних застосувань, де пропуск позитивного випадку або неправильне визначення діагнозу може мати серйозні наслідки для пацієнта. Водночас показники точності та рівня помилок можуть бути недостатньо інформативними для багатокласових та багатоміткових завдань, особливо коли дані незбалансовані. Варто також зазначити, що інтеграція методів автоматичного машинного навчання (AutoML)

для обробки клінічних текстів дає додаткову перевагу: вона дозволяє швидко тестувати різні моделі, оптимізувати гіперпараметри та вибирати найефективніший алгоритм для конкретного завдання (Mustafa, 2021; Vasundhara, 2023). Це особливо актуально для багатоміткової багатокласової класифікації, де традиційне ручне налаштування моделі є надмірно трудомістким та тривалим. Таким чином, результати дослідження свідчать про потенціал автоматизованих методів для ефективного виявлення симптомомкомплексів у клінічних текстах. Гібридні та нейромережеві моделі, які дозволяють інтегрувати як аналіз частоти термінів, так і контекстні шаблони, тим самим забезпечуючи більш точну та повну класифікацію медичних записів, є найефективнішими. Подальші дослідження повинні не лише розширити базу даних клінічних текстів для кращої узагальнюваності моделей, але й дослідити комбіновані підходи, що інтегрують AutoML, нейромережеві моделі та методи обробки природної мови (NLP) для підвищення точності ідентифікації коморбідних симптомів та рідкісних патологій.

Висновки. Результати цього систематичного огляду довели ефективно та перспективно рішення для сприяння клінічному прийняттю рішень шляхом автоматизації ідентифікації характерних симптомомкомплексів у клінічних текстах. Основні результати дослідження були позитивними для простих завдань, таких як діагностика, що вказує на наявність або відсутність конкретного захворювання, наприклад, бінарна класифікація. Багатокласова та багатозначна класифікація може мати справу з більш складними випадками, такими як коморбідні розлади та багатодіагностичні прогнози або призначення ліків одночасно. Найбільш корисними та репрезентативними метриками для оцінки ефективності моделі є F1 та AUC, оскільки вони спільно враховують чутливість та точність моделі. Для багатокласової та багатозначної роботи метрики точності та помилок пропонують набагато менше розуміння. Платформи AutoML значно полегшують вибір та налаштування моделей; кілька алгоритмів та гіперпараметрів можуть бути протестовані в одному конвеєрі, що призводить до швидших рішень, що важливо для багатозначної багатокласової класифікації. Моделі машинного навчання можуть бути більш точно та ретельно використані для класифікації клінічних текстів при поєднанні частотного аналізу з аналізом термінів та контекстуального патернування. Для покращення узагальнення моделей рекомендується розширити бази даних клінічних текстів, поєднати

їх з NLP та нейронними мережами та додати AutoML до методів обробки медичних даних. Таким чином, автоматичні підходи до класифікації клінічних текстів мають великий потенціал для клінічного використання, такого як рання ідентифікація симптомомкомплексів клінічними рішеннями та оптимізація управління

пацієнтами. Такі системи підвищують точність діагностичних моделей та полегшать надання медичної допомоги. Перспективним напрямом подальших робіт є поширення підходу на інші категорії медичних текстів та дослідження можливостей поєднання LLM-орієнтованої інженерії ознак з гібридними моделями прогнозування.

ЛІТЕРАТУРА:

1. Бобко Б., Жуков С. Методи машинного навчання для виявлення аномалій у медичній статистиці України: аналітичний огляд. *Таврійський науковий вісник*. Серія: Технічні науки, 2025. 1(4), С. 402–413. <https://doi.org/10.32782/tnv-tech.2025.4.1.38>.
2. Haritima H., Benazer S. S., Kanth T. V. R., Dhineshkumar, K. An adaptive learning-driven software ecosystem for optimized healthcare solutions with artificial intelligence. *International journal of BIM and engineering science*. 2024. Vol. 09, № 2. P. 45–54. <https://doi.org/10.54216/ijbes.090206>.
3. Dreisbach C., Koleck T. A., Bourne P. E., Bakken S. A systematic review of natural language processing and text mining of symptoms from electronic patient-authored text data. *International journal of medical informatics*. 2019. Vol. 125. P. 37–46. <https://doi.org/10.1016/j.ijmedinf.2019.02.008>.
4. Chen I. Y., Pierson E., Rose S., Joshi, S., Ferryman K., Ghassemi M. Ethical machine learning in healthcare *Annual review of biomedical data science*. 2021. Vol. 4, № 1. P. 123–144. <https://doi.org/10.1146/annurev-biodatasci-092820-114757>.
5. Venkataraman G. R., Pineda A. L., Bear Don't Walk IV O. J., Zehnder A. M., Ayyar S., Page R. L., Bustamante C. D., Rivas M. A. FasTag: automatic text classification of unstructured medical narratives. *Plos one*. 2020. Vol. 15, № 6. P. e0234647. <https://doi.org/10.1371/journal.pone.0234647>.
6. Huang J., Osorio C., Sy L. W. An empirical evaluation of deep learning for ICD-9 code assignment using MIMIC-III clinical notes. *Computer methods and programs in biomedicine*. 2019. Vol. 177. P. 141–153. <https://doi.org/10.1016/j.cmpb.2019.05.024>
7. Kambala M. AI-Powered healthcare: transforming patient outcomes with machine learning. *Journal of medical science and clinical research*. 2024. Vol. 12, № 08. P. 34–47. <https://doi.org/10.18535/jmscr/v12i08.07>.
8. Mustafa A., Rahimi Azghadi M. Automated machine learning for healthcare and clinical notes analysis. *Computers*. 2021. Vol. 10, № 2. P. 24. <https://doi.org/10.3390/computers10020024>.
9. Sreenivasgoud P., Sharma M. K., Kumar B. S., Nijhawan G., Al-Jawahry H. M., Udhayakumar R. Natural language processing in electronic health record mining for clinical decision support. *2023 international conference on artificial intelligence for innovations in healthcare industries (ICAIIHI)*, Raipur, India, 29–30 December 2023. 2023. <https://doi.org/10.1109/icaaihi57871.2023.10489801>.
10. Mowery D., South B. R., Kvist M., Dalianis H., Velupillai S. Recent advances in clinical natural language processing in support of semantic analysis. *Yearbook of medical informatics*. 2015. Vol. 24, № 01. P. 183–193. <https://doi.org/10.15265/iy-2015-009>.
11. Allam H., Makubvure L., Gyamfi B., Graham K. N., Akinwolere K. Text classification: how machine learning is revolutionizing text categorization. *Information*. 2025. Vol. 16, № 2. P. 130. <https://doi.org/10.3390/info16020130>.
12. Sim J.-A., Huang X., Horan M. R., Baker J. N., Huang I.-C. Using natural language processing to analyze unstructured patient-reported outcomes data derived from Electronic Health Records for cancer populations: a systematic review. *Expert review of pharmacoeconomics & outcomes research*. 2024. <https://doi.org/10.1080/14737167.2024.2322664>.
13. Vasundhara S. Challenges of machine learning in healthcare industry. *International journal of science and research (IJSR)*. 2023. Vol. 12, № 7. P. 495–497. <https://doi.org/10.21275/sr23706105157>.
14. Долінський Т. Інформаційна система семантичного аналізу текстових даних з використанням засобів SPARK : автореф. Thesis Abstract. 2018. URL: <http://elartu.tntu.edu.ua/handle/lib/23565>.
15. Новіков О. Комп'ютерні засоби діагностування захворювань на основі нейронної мережі : bachelor's thesis. 2021. 65 с. URL: <https://ela.kpi.ua/handle/123456789/43287>.
16. Різак Г., Кампі Ю., Якименко В. Перспективи розвитку доказової медицини в умовах наявності штучного інтелекту й сучасних технологій: роль закладів вищої медичної освіти в Україні. *Перспективи та інновації науки*. 2023. № 12(30). [https://doi.org/10.52058/2786-4952-2023-12\(30\)-1033-1043](https://doi.org/10.52058/2786-4952-2023-12(30)-1033-1043).
17. Чабан О. Метод поєднання контекстних векторних представлень слів із векторним поданням медичного домену. *Вимірювальна та обчислювальна техніка в технологічних процесах*. 2025. № 2. С. 297–301. <https://doi.org/10.31891/2219-9365-2025-82-42>.

18. Черниш К., Білошицька О. Системи підтримки прийняття лікарських рішень. *Grail of Science*. 2022. № 21. С. 119–121. <https://doi.org/10.36074/grail-of-science.28.10.2022.021>.

19. Лосенко А., Крижановський Є., Штельмах І., Варчук І. Технологія LLM-видобування ознак тестування пацієнтів з текстових звітів для удосконалення прогнозування кількості хворих на коронавірус. *Вісник ВПІ*, 2024. вип. 6, С. 135–144, <https://doi.org/10.31649/1997-9266-2024-177-6-135-144>

REFERENCES:

1. Bobko, B., Zhukov, S. (2025) Metody mashynnoho navchannia dlia vyivlennia anomalii u medychnii statystytsi Ukrainy: analitychnyi ohliad [Machine learning methods for anomaly detection in Ukrainian medical statistics: an analytical overview]. *Taurida Scientific Herald. Series: Technical Sciences*, 1(4), 402–413. <https://doi.org/10.32782/tnv-tech.2025.4.1.38>.

2. Haritima, H., Benazer, S. S., Kanth, T. V. R., & Dhineshkumar, K. (2024). An adaptive learning-driven software ecosystem for optimized healthcare solutions with artificial intelligence. *International Journal of BIM and Engineering Science*, 09(2), 45–54. <https://doi.org/10.54216/ijbes.090206>.

3. Dreisbach, C., Koleck, T. A., Bourne, P. E., & Bakken, S. (2019). A systematic review of natural language processing and text mining of symptoms from electronic patient-authored text data. *International Journal of Medical Informatics*, 125, 37–46. <https://doi.org/10.1016/j.ijmedinf.2019.02.008>.

4. Chen, I. Y., Pierson, E., Rose, S., Joshi, S., Ferryman, K., & Ghassemi, M. (2021). Ethical machine learning in healthcare. *Annual Review of Biomedical Data Science*, 4(1), 123–144. <https://doi.org/10.1146/annurev-biodatasci-092820-114757>.

5. Venkataraman, G. R., Pineda, A. L., Bear Don't Walk IV, O. J., Zehnder, A. M., Ayyar, S., Page, R. L., Bustamante, C. D., & Rivas, M. A. (2020). FasTag: Automatic text classification of unstructured medical narratives. *Plos One*, 15(6), Стаття e0234647. <https://doi.org/10.1371/journal.pone.0234647>.

6. Huang, J., Osorio, C., & Sy, L. W. (2019). An empirical evaluation of deep learning for ICD-9 code assignment using MIMIC-III clinical notes. *Computer Methods and Programs in Biomedicine*, 177, 141–153. <https://doi.org/10.1016/j.cmpb.2019.05.024>.

7. Kambala, M. (2024). AI-Powered healthcare: Transforming patient outcomes with machine learning. *Journal of Medical Science and Clinical Research*, 12(08), 34–47. <https://doi.org/10.18535/jmscr/v12i08.07>.

8. Mustafa, A., & Rahimi Azghadi, M. (2021). Automated machine learning for healthcare and clinical notes analysis. *Computers*, 10(2), 24. <https://doi.org/10.3390/computers10020024>.

9. Sreenivasgoud, P., Sharma, M. K., Kumar, B. S., Nijhawan, G., Al-Jawahry, H. M., & Udhayakumar, R. (2023). Natural language processing in electronic health record mining for clinical decision support. *2023 international conference on artificial intelligence for innovations in healthcare industries (ICAIIHI)*. IEEE. <https://doi.org/10.1109/icaihi57871.2023.10489801>.

10. Mowery, D., South, B. R., Kvist, M., Dalianis, H., & Velupillai, S. (2015). Recent advances in clinical natural language processing in support of semantic analysis. *Yearbook of Medical Informatics*, 24(01), 183–193. <https://doi.org/10.15265/iy-2015-009>.

11. Allam, H., Makubvure, L., Gyamfi, B., Graham, K. N., & Akinwolere, K. (2025). Text classification: How machine learning is revolutionizing text categorization. *Information*, 16(2), 130. <https://doi.org/10.3390/info16020130>.

12. Sim, J.-A., Huang, X., Horan, M. R., Baker, J. N., & Huang, I.-C. (2024). Using natural language processing to analyze unstructured patient-reported outcomes data derived from Electronic Health Records for cancer populations: A systematic review. *Expert Review of Pharmacoeconomics & Outcomes Research*. <https://doi.org/10.1080/14737167.2024.2322664>.

13. Vasundhara, S. (2023). Challenges of machine learning in healthcare industry. *International Journal of Science and Research (IJSR)*, 12(7), 495–497. <https://doi.org/10.21275/sr23706105157>.

14. Dolinsky, T. (2018). Informatsiina systema semantynnoho analizu tekstovykh danykh z vykorystanniam zasobiv SPARK [Information system for semantic analysis of text data using SPARK tools] [Author ref. Thesis Abstract, Ivan Pulyuy Ternopil National Technical University]. *ELARTU – Institutional repository of Ivan Pulyuy TNTU*. <http://elartu.tntu.edu.ua/handle/lib/23565>.

15. Novikov, O. (2021). Kompiuterni zasoby diahnostuvannia zakhvoriuvan na osnovi neuronnoi merezhi [Computer tools for diagnosing diseases based on a neural network] [Bachelor's thesis, Igor Sikorsky Kyiv Polytechnic Institute]. *ELAKPI – Electronic archive of scientific and educational materials of Igor Sikorsky Kyiv Polytechnic Institute*. <https://ela.kpi.ua/handle/123456789/43287>.


16. Rizak, G., Kampi, Y., & Yakymenko, V. (2023). Perspektyvy rozvytku dokazovoi medytsyny v umovakh naiavnosti shtuchnoho intelektu y suchasnykh tekhnolohii: rol zakladiv vyshchoi medychnoi osvity v Ukraini

[Prospects for the development of evidence-based medicine in the conditions of artificial intelligence and modern technologies: The role of higher medical education institutions in Ukraine]. *Perspectives and innovations of science*, (12(30)). [https://doi.org/10.52058/2786-4952-2023-12\(30\)-1033-1043](https://doi.org/10.52058/2786-4952-2023-12(30)-1033-1043).

17. Chaban, O. (2025). Metod poiednannia kontekstnykh vektornykh predstavlen sliv iz vektornym podanniam medychnoho domenu [Method of combining contextual vector representations of words with vector representations of the medical domain]. *Measuring and computing devices in technological processes*, (2), 297–301. <https://doi.org/10.31891/2219-9365-2025-82-42>.

18. Chernysh, K., Biloshitska, O. (2022). Systemy pidtrymky pryiniattia likarskykh rishen [Medical decision support systems]. *Grail of Science*, (21), 119–121. <https://doi.org/10.36074/grail-of-science.28.10.2022.021>.

19. Losenko, A., Kryzhanovskyi, Y., Shtelmakh, I., Varchuk, I. (2024). Tekhnolohiia LLM-vydobuvannia oznak testuvannia patsientiv z tekstovykh zvitiv dlia udoskonalennia prohnozuvannia kilkosti khvorykh na koronavirus [LLM-based Feature Extraction Technology for Patient Testing from Textual Reports to Enhance Covid-19 Case Forecasting]. *Visnyk of Vinnytsia Politechnical Institute*, 177(6), 135–144. <https://doi.org/10.31649/1997-9266-2024-177-6-135-144>.



Стаття поширюється на умовах ліцензії відкритого доступу (CC BY 4.0)

Дата першого надходження статті до видання: 03.02.2026

Дата прийняття статті до друку після рецензування: 10.03.2026

Дата публікації (оприлюднення) статті: 20.05.2026