

УДК 004.85:004.518

DOI <https://doi.org/10.32689/maup.it.2025.1.6>**Артем ВАТУЛА**

аспірант, Приватний вищий навчальний заклад «Європейський університет»,

a.vatyla@e-u.edu.ua

ORCID: 0009-0001-5491-5308

## ОСНОВНІ МЕТОДИ МАШИННОГО НАВЧАННЯ В СИСТЕМАХ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ

**Анотація.** Мета роботи полягає у комплексному огляді та систематизації основних класів методів машинного навчання (МН), які використовуються у системах підтримки прийняття рішень (СППР). Дослідження включає детальний аналіз характерних особливостей, практичних прикладів застосування алгоритмів МН у різноманітних галузях (медицина, фінанси, логістика), а також критичне порівняння переваг і недоліків кожного методу з метою визначення оптимальних умов для їх інтеграції в СППР та підвищення ефективності прийняття рішень.

**Методологія дослідження** базується на комплексному аналізі наукових публікацій, присвячених використанню МН у СППР, застосуванні методів класифікації алгоритмів за типом навчання (кероване, некероване, напівкероване, навчання з підкріпленням, глибоке навчання). Для цього використано методи аналізу, синтезу, порівняльної характеристики можливостей алгоритмів, а також узагальнення результатів їх практичного застосування. У дослідженні додатково враховані фактори якості вхідних даних, на яких тренуються моделі, та потенційні етичні й технологічні обмеження інтеграції цих методів.

**Наукова новизна** проведеного дослідження полягає в тому, що вперше запропоновано цілісну та систематизовану оцінку використання різних категорій методів машинного навчання у СППР з поглибленим аналізом їх переваг, недоліків, сфер найбільш доцільного застосування, а також умов, що визначають ефективність їх інтеграції. Узагальнено та порівняно результати попередніх досліджень, на основі чого сформульовано комплексне бачення перспективних напрямків розвитку інтелектуальних СППР з урахуванням сучасних технологічних та етичних викликів.

**Висновки** дослідження підтверджують, що інтеграція методів машинного навчання суттєво підвищує якість та обґрунтованість управлінських рішень завдяки автоматизації процесу аналізу великих обсягів даних та адаптації рекомендацій на основі накопиченого досвіду. Встановлено, що вибір конкретного класу методів повинен здійснюватися відповідно до особливостей завдання, обсягу доступних розмічених даних, вимог до інтерпретованості моделі та допустимих ресурсних витрат. Подальші перспективи розвитку цієї наукової проблематики пов'язані із розробкою методологічних рекомендацій щодо оптимального вибору методів для різних типів СППР, підвищенням прозорості та інтерпретованості алгоритмів, а також створенням ефективних механізмів забезпечення їх етичності, надійності та безпечності використання у практичних задачах.

**Ключові слова:** машинне навчання, системи підтримки прийняття рішень, кероване навчання, некероване навчання, напівкероване навчання, навчання з підкріпленням, глибоке навчання.

## Artem VATULA. MAIN METHODS OF MACHINE LEARNING IN DECISION SUPPORT SYSTEMS

**Abstract.** The purpose of this paper is a comprehensive review and systematization of the main classes of machine learning (ML) methods utilized in decision support systems (DSS). The research includes a detailed analysis of distinctive features, practical examples of ML algorithms application in various fields (medicine, finance, logistics), and a critical comparison of the advantages and disadvantages of each method to identify optimal conditions for their integration into DSS and to enhance decision-making efficiency.

**The research methodology** is based on a comprehensive analysis of scientific publications devoted to the use of ML in DSS, employing classification methods of algorithms according to the type of learning (supervised, unsupervised, semi-supervised, reinforcement learning, deep learning). The study utilizes methods of analysis, synthesis, comparative evaluation of algorithm capabilities, and generalization of practical implementation results. Additionally, the research considers the quality of input data used for training models and addresses potential ethical and technological constraints related to the integration of these methods.

**The scientific novelty** of this research lies in the first-time holistic and systematized assessment of various categories of ML methods within DSS, providing an in-depth analysis of their advantages, limitations, the most suitable areas of application, and the conditions determining their integration effectiveness. The paper generalizes and compares the outcomes of previous studies, forming a comprehensive vision of prospective directions for the development of intelligent DSS, taking into account contemporary technological and ethical challenges.

**The conclusions** of the research confirm that the integration of ML methods significantly enhances the quality and validity of managerial decisions by automating the analysis of large data volumes and adapting recommendations based on accumulated experience. It is established that selecting a specific class of methods should depend on the nature of the task, the volume of available labeled data, the requirements for model interpretability, and allowable resource expenditures. Further research perspectives involve developing methodological guidelines for the optimal selection of methods for various types of DSS, improving algorithm transparency and interpretability, and creating effective mechanisms to ensure their ethical use, reliability, and safety in practical applications.

**Key words:** machine learning, decision support systems, supervised learning, unsupervised learning, semi-supervised learning, reinforcement learning, deep learning.

**Постановка проблеми в загальному вигляді та її зв'язок із важливими науковими чи практичними завданнями.** Сучасний етап розвитку інформаційного суспільства характеризується стрімким зростанням обсягів даних, які необхідно опрацьовувати для ухвалення обґрунтованих управлінських рішень. У різних галузях – від медицини і фінансів до промисловості – успішність діяльності все більше залежить від спроможності ефективно аналізувати великі масиви інформації та виявляти приховані закономірності. Традиційні підходи до аналізу даних часто не витримують сучасних вимог щодо масштабів і складності інформації. Це зумовлює потребу в нових, автоматизованих інструментах підтримки прийняття рішень, здатних швидко і точно обробляти інформацію, перевищуючи людські можливості за обсягом і швидкістю аналізу. Системи підтримки прийняття рішень (СППР) визначаються як інтерактивні комп'ютерні системи для підтримки різних видів діяльності під час прийняття рішень стосовно слабоструктурованих і неструктурованих проблем [1, с. 20]. Інтегрування методів штучного інтелекту, зокрема машинного навчання, трансформують такі системи на інтелектуальні СППР, які здатні автоматично покращувати свої рекомендації на основі накопичених даних і знань. Таким чином, актуальність вивчення методів машинного навчання у контексті СППР обумовлена нагальною потребою підвищення ефективності, точності й обґрунтованості управлінських рішень у складних умовах невідомості та великих даних.

Машинне навчання (МН) – це напрямок штучного інтелекту, який фокусується на розробці алгоритмів, здатних навчатися на основі даних і приймати рішення або робити прогнози без явного програмування під кожен випадок. На сьогодні існує надзвичайно багато методів і алгоритмів МН. Вибір конкретного підходу для певної задачі є нетривіальним завданням: кожен метод має свої сильні сторони, припущення і обмеження. Отже, постає важливе практичне питання – коли і який метод машинного навчання доцільно застосувати, щоб отримати найкращий результат у системі підтримки рішень.

**Аналіз останніх досліджень і публікацій.** Протягом останніх років опубліковано значну кількість наукових робіт, присвячених застосуванню машинного навчання у системах підтримки прийняття рішень. В міру того, як МН стає все більш поширеним, етичні, соціальні та управлінські аспекти привертають все більшу увагу, визнаючи глибокий вплив цих технологій на суспільство. Таким чином, еволюція машинного навчання є результатом синергії між обчислювальним прогресом, теоретичними дослідженнями та розширенням горизонтів практичного застосування, що свідчить про настання ери, коли штучний інтелект не лише розширює людські можливості, але й змінює технологічний ландшафт [2]. Дослідники демонструють успішну інтеграцію методів МН у СППР різних галузей. Так, у медицині розроблено інтелектуальні клінічні СППР, що на основі алгоритмів машинного навчання допомагають лікарям ставити діагнози та визначати ризики захворювань. У фінансовому секторі прогностичні моделі, побудовані за допомогою МН, підвищують точність передбачення ринкових тенденцій і підтримують прийняття рішень щодо інвестицій чи управління ризиками. В сфері логістики та виробництва алгоритми МН оптимізують планування постачань, керування запасами і маршрути транспорту – тобто автоматизують складні рішення в реальному часі. Ці приклади підтверджують, що використання методів МН здатне суттєво підвищити ефективність і обґрунтованість рішень за рахунок глибшого аналізу даних, ніж це може зробити людина вручну. Разом з тим, більшість існуючих досліджень зосереджені на впровадженні окремих алгоритмів або вирішенні конкретних прикладних задач. Питання комплексного підходу залишається недостатньо висвітленим. Зокрема, дотепер не сформовано узагальнені рекомендації щодо вибору того чи іншого класу методів МН для певних умов задачі. Відсутній цілісний огляд, що порівнює різні типи навчання (кероване, некероване, напівкероване, з підкріпленням, глибоке) саме з точки зору їх ролі у системах підтримки рішень. Невирішеними частинами загальної проблеми є також питання інтерпретованості моделей МН у СППР (щоб користувач міг довіряти рекомендаціям) та забезпечення достатньої кількості якісних даних для навчання моделей. Ця стаття присвячена тим аспектам, що залишилися поза належною увагою: у ній здійснюється систематизований огляд основних категорій методів машинного навчання для СППР, порівнюються їхні можливості і обмеження, а також окреслюються підходи до вибору оптимального методу залежно від характеру задачі і даних.

**Метою даної статті** є узагальнення та систематизація основних методів машинного навчання, що застосовуються в системах підтримки прийняття рішень, і визначення їх ролі у підвищенні ефективності таких систем. Для досягнення цієї мети поставлено такі завдання: 1) класифікувати методи МН за категоріями навчання та описати сутність кожної категорії; 2) проаналізувати особливості та приклади застосування кожного класу методів у різних предметних областях; 3) порівняти їхні переваги і недоліки та надати рекомендації щодо вибору підходу для конкретних умов; 4) окреслити перспективи розвитку інтеграції МН у СППР.

Для досягнення поставленої мети було проведено аналітичне дослідження, результати якого викладено нижче у розрізі основних категорій методів машинного навчання. Методи дослідження полягали

у вивченні сучасної літератури з тематики МН та СППР, класифікації підходів МН за типом навчання, а також в аналізі конкретних прикладів використання цих методів. Під час аналізу особлива увага приділялася обґрунтуванню вибору методів, їх продуктивності в різних умовах і можливим обмеженням. Зокрема, розглядалися доступність і якість даних для навчання моделей, вимоги до обчислювальних ресурсів, питання інтерпретованості результатів, а також етичні аспекти (конфіденційність даних, допустимість автономного ухвалення рішень системою тощо).

**Виклад основного матеріалу.** В статті послідовно досліджено основні категорії методів МН – кероване, некероване, напівкероване навчання, навчання з підкріпленням та глибоке навчання – з описом їх сутності, ключових алгоритмів та ролі в системах підтримки рішень.

*Кероване навчання (supervised learning)* передбачає наявність навчальної вибірки даних, де для кожного прикладу задано правильний результат (цільове значення або клас). Іншими словами, алгоритм вчиться на прецедентах (історичних випадках) і будує узагальнену модель, яку потім можна застосувати для передбачення результатів на нових, раніше не бачених даних. Кероване навчання охоплює дві основні групи задач: класифікацію (присвоєння кожному об'єкту одного з наперед визначених класів) та регресію (прогнозування числового значення показника). Для реалізації таких задач розроблено багато алгоритмів МН. Основні з них включають:

- Лінійна та логістична регресія. Прості математико-статистичні моделі, що застосовуються для прогнозування кількісних показників або ймовірності належності до категорії. Наприклад, лінійна регресія може передбачати обсяг продажів на наступний період на основі витрат на рекламу, а логістична регресія – оцінювати ймовірність дефолту позичальника на підставі його фінансових показників. Регресія може використовуватись під час прогнозування обсягів продажів. В цьому випадку залежною величиною є обсяги продажів, а факторами, що на неї впливають, можуть бути попередні обсяги продажів, зміна курсу валют, активність конкурентів тощо. [5, с. 8].

- Дерева рішень. Алгоритми ухвалення рішень у вигляді дерева, де вузли відповідають умовам на значення ознак, а гілки – варіантам дії залежно від виконання цих умов. Дерева рішень послідовно розбивають простір ознак на підмножини і у кінцевих листках генерують рішення (клас або числове значення). Цей підхід застосовується як для задач класифікації, так і для регресії, забезпечуючи інтерпретовану модель ухвалення рішень (кожна гілка дерева – це правило «якщо-то»). Дерева рішень належать до найпопулярніших і потужних інструментів, що дозволяють ефективно вирішувати задачі [11, с. 117].

- Метод опорних векторів (SVM). Потужний метод класифікації та регресії, ефективний на задачах середньої розмірності даних. SVM шукає таку гіперплощину у просторі ознак, яка максимально відділяє приклади різних класів з максимальним зазором. Метод застосовується, зокрема, для розпізнавання образів чи виявлення аномалій.

- Нейронні мережі. Моделі, натхнені біологічними нейронами, які складаються з багатьох взаємопов'язаних штучних нейронів. Нейронні мережі можуть апроксимувати складні нелінійні залежності, що робить їх дуже потужними для задач класифікації та прогнозування. Наприклад, у логістиці глибокі нейронні мережі успішно застосовуються для оптимізації маршрутів транспортування або оцінки ризику збоїв у постачанні, враховуючи одразу багато факторів.

- Ансамблеві методи. Підходи, що поєднують декілька базових моделей з метою підвищення точності. Класичний приклад – алгоритм Random Forest, який будує комітет із численних дерев рішень і усереднює їх результати, знижуючи ризик перенавчання. Інший популярний підхід – Boosting (наприклад, алгоритми Gradient Boosting, XGBoost), де велика модель створюється послідовно, підбираючи наступну «слабку» модель для найгірше прогнозованих прикладів попередника. Ансамблеві методи часто демонструють вищу якість прогнозів порівняно з окремими моделями за рахунок агрегування їхніх рішень.

Керовані методи машинного навчання є найпоширенішими в практиці побудови СППР, адже велика частина управлінських задач формулюється саме як задача прогнозування або класифікації на основі історичних даних. Наприклад, моделі класифікації у медичних СППР автоматично відносять пацієнтів до груп ризику захворювання або рекомендують ймовірний діагноз на підставі наявних симптомів та результатів аналізів. Моделі регресії широко впроваджені у фінансових СППР – вони прогнозують ціни активів, обсяги продажів чи інші економічні показники, що допомагає менеджерам приймати більш обґрунтовані рішення у плануванні та інвестуванні.

*Некероване навчання (unsupervised learning)* працює в умовах відсутності наперед відомих правильних відповідей. Алгоритм отримує лише вхідні дані без еталонного виходу і намагається самостійно виявити внутрішні структури або закономірності. Метою некерованих методів є знайти приховану впорядкованість у даних, зрозуміти, як об'єкти можуть бути організовані чи згруповані за схожими

ознаками. Ключові завдання, що вирішуються в межах цього підходу, включають кластеризацію, пошук асоціативних правил та зниження розмірності.

Кластеризація – це групування об'єктів в однорідні групи (кластери) на основі схожості їх характеристик. При цьому наперед невідомо, скільки груп і з якими властивостями вийде – алгоритм сам шукає природну сегментацію. Кластеризація дозволяє виявити у даних структури, що не були очевидними для аналітика. У контексті СППР результати кластеризації можуть підказати нові рішення. Наприклад, маркетинговий СППР може автоматично сегментувати клієнтів на групи за схожими поведінковими патернами, що допоможе менеджерам сформувати цільові пропозиції для кожного сегмента. Застосування кластерного аналізу в контексті закупівельних процесів дозволить здійснити сегментацію постачальників та інших даних про закупівлі [7, с. 65].

Асоціативні правила – тобто пошук закономірностей типу «якщо X, то Y» у великих масивах транзакційних даних. Класичний приклад – аналіз кошика покупця в роздрібній торгівлі: алгоритми асоціативного аналізу (наприклад, Apriori) можуть виявити правила на кшталт “якщо купується товар A, то з високою ймовірністю купується і товар B”. Такі знання, інтегровані у СППР, допомагають приймати рішення щодо оптимального розміщення товарів у магазині, формування наборів продуктів чи систем рекомендацій для покупців. В ширшому сенсі, асоціативні правила застосовуються скрізь, де потрібно виявити стійкі залежності між подіями або об'єктами – наприклад, для виявлення послідовностей дій клієнта на вебсайті, що передують здійсненню покупки.

Зниження розмірності. Методи перетворення високо-вимірних даних (коли об'єкт описується дуже великою кількістю ознак) до простішого, низьковимірного представлення із збереженням основної інформативності. Відомі підходи – це метод головних компонент (PCA), сингулярний розклад, а також нейромережеві автоенкодера (autoencoders). Зниження розмірності корисне як етап попередньої обробки: воно дозволяє усунути шум, виявити ключові фактори і навіть візуалізувати складні дані на графіках. У СППР такі методи часто застосовують перед побудовою моделей прогнозування – спрощена задача з меншим числом ознак може дати більш надійний і швидкий результат. Наприклад, якщо база даних містить десятки потенційно корельованих показників, PCA допоможе сконструювати кілька узагальнених факторів, на основі яких легше будувати прогнози.

Некероване навчання відіграє допоміжну, але важливу роль у системах підтримки рішень. Його результати самі по собі не дають прямої відповіді, яке рішення правильне, але надають цінну інформацію для аналітика. Виявлені сегменти, шаблони чи залежності збагачують інформаційну базу, на основі якої вже формулюються управлінські рішення або налаштовуються інші моделі (наприклад, методи керованого навчання). Скажімо, кластерний аналіз клієнтів банку може виявити приховану групу позичальників з високим кредитним ризиком, що спонукає менеджмент розробити спеціальну стратегію роботи з цією категорією клієнтів. Таким чином, некеровані методи МН виступають інструментом пошуку нового знання, яке підвищує обґрунтованість подальших дій системи підтримки рішень.

*Напівкероване навчання (semi-supervised learning)* є проміжним підходом між керованим і некерованим: воно використовує невелику кількість розмічених даних разом з великою кількістю нерозмічених. Така ситуація є типовою для реальних задач, коли зібрано дуже багато інформації, але тільки для відносно небагатьох прикладів відомі правильні відповіді (розмітка виконана експертами). Отримати великі обсяги якісно розмічених даних буває дорого, довго або навіть практично неможливо, тоді як необроблені дані накопичуються постійно. Напівкеровані алгоритми дають змогу використати масив нерозмічених даних для покращення навчання на розмічених, підвищуючи точність моделі без потреби в додаткових ручних розмітках. Типовий підхід у напівкерованому навчанні полягає у двох етапах. Спочатку на всіх доступних даних (в тому числі нерозмічених) алгоритм будує певну модель структури – наприклад, виконує кластеризацію або оцінює розподіл ознак. На другому етапі ця попередня «карта» даних використовується для підсилення керованого навчання на тих прикладах, де відповіді відомі. Простими словами, модель екстраполює знання від міток на розмічених даних до схожих нерозмічених прикладів. Один із методів – self-training (самонавчання): модель спочатку навчається на невеликій вибірці з мітками, потім прогнозує мітки для частини нерозмічених даних, обирає найбільш впевнені прогнози як псевдо-мітки і донавчається з ними. Інший підхід – графові алгоритми, що моделюють всі дані як вершини графа і поширюють мітки від помічених точок до сусідніх непомічених через ребра зв'язків (алгоритми розповсюдження міток). У будь-якому разі ідея одна: задіяти структуру, приховану в нерозміченій вибірці, щоб краще класифікувати або прогнозувати небагато помічених прикладів. Напівкероване навчання знайшло застосування у ситуаціях, де повна розмітка даних є особливо складною або ресурсомісткою. У медицині, наприклад, доступні тисячі медичних зображень (рентген, МРТ тощо), але детально розмічені (з точним виділенням зон патології) – лише сотні, оскільки це потребує часу лікаря-радіолога. Напівкеровані алгоритми дозволяють навчити модель розпізнавання патологій,

використовуючи всі наявні зображення: вони виявляють структури в нерозмічених знімках і уточнюють модель на основі небагатьох розмічених. У результаті точність діагностичної моделі буде вищою, ніж при навчанні тільки на повністю розмічених даних. В бізнес-аналітиці подібний підхід корисний, коли необхідно швидко інтегрувати до СППР нові масиви даних. Замість того щоб чекати повної ручної перевірки та розмітки, систему можна частково навчити на наявних сирих даних, і вона почне видавати попередні рекомендації – поступово підвищуючи свою точність у міру появи додаткових розмічених прикладів. Отже, напівкероване навчання робить СППР більш гнучкими і адаптивними до нової інформації у випадках, коли оперативність важливіша за абсолютну точність або коли повна розмітка недоцільна.

*Навчання з підкріпленням (reinforcement learning, RL)* – це підхід, при якому модель (агент) навчається шляхом взаємодії зі середовищем і отримання зворотного зв'язку у вигляді винагород чи штрафів за свої дії. На відміну від керованого навчання, де агенту заздалегідь відомо, яку відповідь вважати правильною для кожного прикладу, в навчанні з підкріпленням немає наперед розміченого набору правильних рішень. Агент сам повинен спробувати різні дії і побачити їх наслідки; корисність кожної дії виражається через числову оцінку (reward). Метою агента є максимізувати сумарну винагороду у довгостроковій перспективі, тобто навчитися стратегії поведінки (послідовності дій), що приводить до найкращого результату. Навчання з підкріпленням відіграє ключову роль у вирішенні складних завдань, які вимагають адаптивності та гнучкості від алгоритмів. Наприклад, воно широко використовується в робототехніці, зокрема в системах навігації для роботів. Такі системи навчаються уникати зіткнень з перешкодами, використовуючи досвід, набутий в результаті взаємодії з середовищем і отримання зворотного зв'язку про кожне зіткнення [9, с. 196]. У завданнях керування ресурсами (наприклад, енергосистемами) RL-агенти можуть навчитися оптимально перемикаєти режими роботи обладнання залежно від навантаження, щоб мінімізувати витрати і ризики відмов. У системах підтримки рішень навчання з підкріпленням застосовується там, де потрібно автоматично виробити стратегію дій у складному динамічному середовищі. Наприклад – система керування дорожнім рухом: алгоритм з підкріпленням налаштовує режими світлофорів у реальному часі, реагуючи на зміни потоку машин, та поступово мінімізує затримки на перехрестях. Перевага навчання з підкріпленням полягає в тому, що воно здатне знаходити нестандартні, часом несподівані стратегії, які людина могла не розглянути. RL-агент діє за принципом проб і помилок і може віднайти оптимальне рішення там, де задача занадто складна для аналітичного розв'язання або де немає достатніх історичних даних для керованого навчання. Недоліком є те, що навчання потребує дуже великої кількості експериментів: агент може тисячі чи мільйони разів програти ситуацію, перш ніж навчиться діяти добре. Якщо таке навчання відбувається не на симуляції, а в реальному середовищі (наприклад, фізичний робот у виробництві), це може бути пов'язано з високими витратами або ризиками. Тому в контексті СППР навчання з підкріпленням найперспективніше там, де можна створити адекватну цифрову модель середовища і тренувати агента віртуально, або коли система сама по собі може тривалий час працювати автономно, поступово покращуючи свої рекомендації без критичних наслідків.

*Глибоке навчання (deep learning)* є особливим підкласом машинного навчання, який базується на використанні багатосарових нейронних мереж. Глибоке навчання складається з декількох рівнів між вхідним і вихідним шарами, що дозволяє виконувати операції на багатьох етапах обробки нелінійної інформації з ієрархічною архітектурою, які використовуються для вивчення функцій і класифікації шаблонів [6, 10]. Завдяки такій архітектурі, глибокі нейронні мережі досягли проривних результатів у вирішенні завдань зі складною структурою вихідних даних, таких як зображення, тексти, мова, відеопотоки та часові ряди [3, с. 326]. Інтеграція глибокого навчання значно розширила можливості систем підтримки рішень, особливо в тих сферах, де раніше комп'ютерні програми поступалися експертам-людям через складність аналізу інформації. Однією з найуспішніших архітектур глибокого навчання є згорткові нейронні мережі (Convolutional Neural Networks, CNN), спеціально призначені для аналізу зображень: вони автоматично виділяють на них ключові особливості (краї, кути, текстури тощо) і на цій основі розпізнають об'єкти чи аномалії. У медицині застосування CNN дозволяє з високою точністю аналізувати рентгенівські та МРТ-знімки [4]. Інший напрям успішного застосування глибокого навчання – це обробка природної мови (Natural Language Processing, NLP). Архітектури рекурентних нейронних мереж (RNN), а особливо сучасні моделі з механізмом «уваги» (attention) та трансформери, дали змогу автоматично аналізувати і генерувати текстову інформацію. Для систем підтримки рішень це відкриває нові горизонти, адже значна частина даних представлена у вигляді текстів документів, звітів, повідомлень. Наприклад, юридична СППР може використовувати модель на базі NLP для аналізу текстів законів і судових рішень, швидко знаходячи релевантні прецеденти під конкретну справу. В управлінні знаннями (семантичному пошуку по базах даних) глибоке навчання дозволяє краще

розуміти зміст запитів і документів, видаючи більш точні результати для ухвалення рішень. Варто зазначити, що ефективне застосування глибокого навчання потребує наявності великих обсягів даних для тренування моделей. У багатьох сферах це створює виклики: дані можуть бути дорогими у зборі, або існують жорсткі обмеження на їх використання (наприклад, конфіденційність персональної інформації). Ще одна складність – інтерпретованість: глибокі нейронні мережі працюють як «чорний ящик», тож важко пояснити, чому модель зробила те чи інше передбачення, а для СППР прозорість і довіра користувача надзвичайно важливі. Тому паралельно з розвитком глибокого навчання ведуться дослідження методів пояснення рішень нейронних мереж (концепція Explainable AI) [8]. Для подолання нестачі даних усе ширше застосовуються генеративні моделі. Зокрема, генеративно-змагальні нейронні мережі (Generative Adversarial Networks, GAN) дозволяють генерувати синтетичні дані, статистично подібні до реальних. У перспективі, поєднання глибокого навчання з іншими передовими технологіями (наприклад, Інтернетом речей для збору великих даних, або хмарними обчисленнями для їх оперативної обробки) дозволить створювати ще більш ефективні інтелектуальні СППР, що в режимі реального часу аналізуватимуть ситуацію і підтримуватимуть прийняття рішень на принципово новому рівні якості.

У Таблиці 1 наведено узагальнену характеристику основних класів методів машинного навчання, що використовуються в системах підтримки прийняття рішень. Зокрема, описано переваги кожного з методів, що визначають умови їх ефективного застосування, а також зазначено основні недоліки, які необхідно враховувати при виборі оптимального підходу для конкретних задач СППР.

Таблиця 1

**Переваги та недоліки основних класів методів машинного навчання**

| <b>Клас методів</b>             | <b>Переваги</b>                                                                                                                                                                                                       | <b>Недоліки</b>                                                                                                                                                                                                                               |
|---------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <i>Кероване навчання</i>        | висока точність моделей за умови великої розміченої вибірки; можливість оцінити якість прогнозу на тестових даних; ефективність для задач з чітко визначеними вихідними параметрами (класифікація, прогнозування).    | потребує трудомісткої розмітки великих обсягів даних; ризик перенавчання за нестачі або нерепрезентативності даних; не виявляє нових знань поза межами визначених вихідних змінних.                                                           |
| <i>Некероване навчання</i>      | дає змогу виявляти приховані закономірності та структури без еталонних відповідей; не потребує попереднього маркування даних експертами; може відкрити нові знання, неочевидні при ручному аналізі.                   | результати важко інтерпретувати та перевірити на правильність; немає гарантії практичної корисності виявлених шаблонів; відсутні стандартні метрики оцінки якості без еталонних даних.                                                        |
| <i>Напівкероване навчання</i>   | зменшує потребу в великому обсязі розмічених даних, залучаючи нерозмічені; покращує точність моделей порівняно з навчанням лише на небагатьох розмічених даних; поєднує переваги керованого та некерованого підходів. | потребує хоча б невеликого набору розмічених даних для початку; ризик накопичення помилок, якщо некоректно розмічені дані додаються автоматично; складніше налаштувати й валідувати результати.                                               |
| <i>Навчання з підкріпленням</i> | дає можливість навчатися оптимальної стратегії дій у динамічному середовищі; може знайти нестандартні рішення, недоступні при інших підходах; не потребує попередніх даних з відповідями, лише сигнал винагороди.     | навчання потребує багатьох спроб і може бути довготривалим; висока чутливість до якості формулювання сигналу винагороди; ризик небажаної поведінки агента при неправильній винагороді або безпечності.                                        |
| <i>Глибоке навчання</i>         | найвищі показники точності на складних задачах (зображення, мова тощо); автоматичне виокремлення ознак з сирих даних; можливість роботи з неструктурованими даними (текст, звук).                                     | вимога дуже великого обсягу даних для навчання; значні обчислювальні ресурси для тренування моделей; низька інтерпретованість моделей (ефект «чорної скриньки»); можливе перенавчання та упередження при обмежених або незбалансованих даних. |

**Висновки.** У ході дослідження здійснено огляд п'яти основних категорій методів машинного навчання (керованого, некерованого, напівкерованого, з підкріпленням та глибокого навчання) у контексті їх застосування в системах підтримки прийняття рішень. Кожен з розглянутих підходів відіграє особливу роль: кероване навчання забезпечує моделі для передбачення результатів і класифікації, некероване – виявляє приховані знання у даних, напівкероване – дозволяє ефективно використовувати великі

масиви нерозмічених даних, навчання з підкріпленням – автоматизує пошук оптимальної стратегії дій, а глибоке навчання – дає змогу працювати зі складними неструктурованими даними і отримувати з них нову інформацію. Інтеграція цих методів у СППР вже продемонструвала здатність підвищувати якість рішень завдяки переходу від інтуїтивних чи евристичних підходів до доказових рекомендацій, отриманих на основі даних. Важливим висновком є те, що не існує єдиного універсального методу МН, який був би найкращим для всіх випадків. Вибір підходу має базуватися на характері задачі, доступних даних і вимогах до результату. Отже, ключова рекомендація для практиків полягає у розумінні сильних і слабких сторін кожного методу та обґрунтованому виборі інструментарію МН відповідно до специфіки поставленої проблеми. Перспективи подальших досліджень у напрямі використання машинного навчання в СППР охоплюють кілька важливих питань. По-перше, це розробка методик підвищення інтерпретованості моделей, особливо глибоких нейронних мереж, щоб рішення, які пропонує система, були прозорими і зрозумілими для людини. Це критично для таких сфер, як медицина чи фінанси, де необхідно пояснювати, чому СППР рекомендує те чи інше рішення. По-друге, актуальною є тема автоматизованого машинного навчання (AutoML) у контексті СППР – створення систем, які самостійно підбирають оптимальну модель МН під конкретну задачу, налаштовують її параметри і перевіряють якість (тобто, щоб СППР могла конструювати нові модулі штучного інтелекту з мінімальним втручанням експертів). По-третє, потребують уваги етично-правові аспекти: забезпечення конфіденційності даних, недопущення упередженості алгоритмів, вбудовування механізмів контролю людиною критично важливих рішень. Нарешті, перспективним є напрям гібридних рішень – поєднання методів машинного навчання з методами багатокритеріального аналізу, оптимізації та економіко-математичного моделювання для створення комплексних СППР, що враховують і великі дані, і експертні знання. Таким чином, основні методи машинного навчання вже зараз є невід’ємною складовою сучасних систем підтримки рішень, і їхня роль буде лише зростати. Подальші дослідження та розробки у цьому напрямку сприятимуть появі нових інтелектуальних СППР, які допомагатимуть людям приймати більш обґрунтовані, точні та ефективні рішення у різноманітних сферах діяльності.

#### Список використаних джерел:

1. Системи і методи підтримки прийняття рішень : підручник. П. І. Бідюк та ін. Київ : КПІ ім. І. Сікорського, 2022. 610 с. URL: [https://ela.kpi.ua/bitstream/123456789/48418/1/Systemy\\_i\\_metody\\_pidtrymky\\_pryiniattia\\_rishen.pdf](https://ela.kpi.ua/bitstream/123456789/48418/1/Systemy_i_metody_pidtrymky_pryiniattia_rishen.pdf) (дата звернення: 28.04.2025).
2. Bharadiya J. Machine Learning and AI in Business Intelligence: Trends and Opportunities. *International Journal of Computer (IJC)*. 2023. Vol. 48, № 1. URL: <https://www.researchgate.net/publication/371902170> (дата звернення: 28.04.2025).
3. Goodfellow I., Bengio Y., Courville A. Deep learning. Cambridge : MIT Press, 2016. 775 p.
4. A guide to deep learning in healthcare. A. Esteva et al. *Nature Medicine*. 2019. Vol. 25, № 1. P. 24–29.
5. Кононова К. Ю. Машинне навчання: методи та моделі : підручник. Харків : ХНУ імені В. Н. Каразіна, 2020. 280 с.
6. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. 2015. Vol. 521, № 7553. P. 436–444.
7. Москаленко В. В., Кріпак С. А. Дослідження методів машинного навчання для аналізу та прогнозування закупівельних даних. *Таврійський науковий вісник. Серія: Технічні науки*. 2023. № 4. С. 61–68. DOI: <https://doi.org/10.32782/tnv-tech.2023.4.8>.
8. Samek W. et al. Explaining deep neural networks and beyond: a review of methods and applications. *Proceedings of the IEEE*. 2021. Vol.109, № 3. P. 247–278.
9. Степовий С. М. Використання машинного навчання як інноваційного інструменту в управлінні підприємством. *Інвестиції: практика та досвід*. 2024. № 6. С. 194–200. DOI: <https://doi.org/10.32702/2306-6814.2024.6.194>.
10. Субботін С. О. Нейронні мережі: теорія та практика : навчальний посібник. Житомир : Вид. О. О. Євенок, 2020. 184 с.
11. Шаркаді М. М., Роботишин М. В., Маляр М. М. Моделі і методи машинного навчання для завдань передбачення. *Науковий вісник Ужгородського університету. Серія «Математика і інформатика»*. 2020. № 1(36). С. 112–122. DOI: [https://doi.org/10.24144/2616-7700.2020.1\(36\).112-122](https://doi.org/10.24144/2616-7700.2020.1(36).112-122).