

УДК 330.43; 338.2

JEL Classification: C51, C53, F31

Дмитро Семенюк

(здобувач третього (освітньо-наукового) рівня вищої освіти, Національний транспортний університет)

ТЕОРЕТИЧНІ ТА ПРИКЛАДНІ АСПЕКТИ ВИКОРИСТАННЯ МАШИННОГО НАВЧАННЯ В АНАЛІЗІ ЕКОНОМІЧНИХ ДАНИХ

*У статті досліджено можливості застосування методів машинного навчання та штучного інтелекту для прогнозування економічних і макроекономічних показників в умовах зростання обсягів даних і складності економічних процесів. Предметом дослідження є сучасні алгоритми машинного навчання, зокрема ансамблеві методи, глибокі нейронні мережі та підходи *debaised machine learning*, які використовуються для аналізу часових рядів і високовимірних економічних даних. Метою роботи є оцінка ефективності зазначених методів порівняно з традиційними економетричними моделями та визначення їх переваг і обмежень у практиці економічного прогнозування.*

Методологічну основу дослідження становлять методи економетричного аналізу, машинного навчання, крос-валідації та порівняльної оцінки прогнозної точності моделей. У роботі узагальнено результати сучасних наукових досліджень щодо застосування випадкових лісів, градієнтного бустингу, нейронних мереж і факторних моделей у прогнозуванні макроекономічних показників. Показано, що методи машинного навчання здатні підвищувати точність прогнозів за рахунок урахування нелінійних залежностей і складних взаємозв'язків між змінними, однак потребують значних обсягів якісних даних і ретельного контролю перенавчання.

Практична цінність отриманих результатів полягає у можливості використання запропонованих підходів для підтримки прийняття рішень у макроекономічному аналізі, фінансовому прогнозуванні та розробці економічної політики. Зроблено висновок про доцільність поєднання класичних економетричних методів із сучасними алгоритмами машинного навчання з метою підвищення надійності та інтерпретованості прогнозів.

Ключові слова: машинне навчання, штучний інтелект, економічне прогнозування, макроекономічні показники, часові ряди, економетричні моделі.

Постановка проблеми. Стрімкий розвиток цифрових технологій та зростання обсягів доступних економічних даних істотно змінюють підходи до економічного аналізу та прогнозування. Традиційні економетричні методи, що ґрунтуються на жорстких припущеннях щодо структури даних і лінійності взаємозв'язків, часто виявляються недостатньо ефективними для роботи з високорозмірними, нелінійними та зашумленими наборами даних, характерними для сучасної економіки [1, 2]. У цьому контексті алгоритми машинного навчання набувають дедалі більшого значення як інструменти аналізу складних економічних процесів.

© Семенюк Д.Ю., 2025

Аналіз останніх досліджень і публікацій. Сучасні наукові дослідження свідчать про зростаючу роль алгоритмів машинного навчання в економічному аналізі та прогнозуванні. У працях М. Джордана та Т. Мітчелла, а також Т. Гасті, Р. Тібшірані та Дж. Фрідмана показано, що машинне навчання пропонує широкий спектр методів, здатних автоматично виявляти приховані закономірності в даних, забезпечувати високу точність прогнозів і адаптуватися до змін у динаміці економічних систем [3, 4]. На відміну від класичних економетричних моделей, алгоритми машинного навчання не потребують попереднього задання функціональної форми залежностей, що, за висновками С. Атей та С. Гу, Б. Келлі і Д. Сю, робить їх особливо привабливими для аналізу макроекономічних показників, фінансових ринків, поведінки споживачів та оцінювання економічних ризиків [5, 6].

Окрему увагу в сучасних дослідженнях приділено застосуванню методів навчання з учителем. Зокрема, Л. Брейман запропонував метод випадкових лісів, а Т. Чен і К. Гестрін — алгоритм градієнтного бустингу XGBoost, які демонструють високу ефективність у задачах прогнозування економічних часових рядів і класифікації економічних станів [7, 8]. Значний внесок у розвиток прикладного прогнозування економічних процесів зробили також Р. Хайндман та Г. Атанасопулос, узагальнивши сучасні підходи до аналізу часових рядів [9]. Паралельно активно розвиваються методи глибокого навчання, зокрема нейронні мережі, систематизовані в роботі І. Гудфеллоу, Й. Бенджіо та А. Курвіля, а також рекурентні архітектури типу LSTM, огляд яких представлено в дослідженні Б. Ліма та С. Зорена [10, 11].

Водночас застосування машинного навчання в економічних дослідженнях супроводжується низкою методологічних викликів. Як зазначає Г. Шмуелі, висока прогнозна точність моделей не гарантує їх пояснювальної спроможності, що обмежує можливості економічної інтерпретації результатів [12]. Проблеми встановлення причинно-наслідкових зв'язків у високовимірних даних детально аналізуються у працях С. Атей та Г. Імбенса, які підкреслюють необхідність поєднання машинного навчання з каузальними підходами [13]. Це зумовлює актуальність систематизації існуючих методів, критичного аналізу їх переваг і недоліків, а також пошуку шляхів інтеграції алгоритмів машинного навчання з економічною теорією та економетричними моделями.

Метою даної статті є аналіз сучасних алгоритмів машинного навчання, що застосовуються для обробки та аналізу економічних даних, узагальнення основних напрямів їх використання в економічних дослідженнях, а також визначення обмежень і перспектив подальшого розвитку цих методів у контексті інтеграції з економічною теорією.

Виклад основного матеріалу. Економічні дані як об'єкт аналізу мають низку специфічних характеристик, що відрізняють їх від даних природничих або технічних наук. Зокрема, емпіричні дослідження показують, що макро- та мікроекономічні дані характеризуються високим рівнем шуму, нелінійністю залежностей, структурною нестабільністю, високою вимірністю та обмеженістю вибірок. Такі властивості продемонстровані на прикладі макроекономічних часових рядів, зокрема ВВП, інфляції та безробіття [9, 14], фінансових ринків [6], а також високовимірних мікроекономічних даних [2, 15]. Унаслідок цього традиційні економетричні моделі часто втрачають прогнозу ефективність і стабільність оцінок, що зумовлює доцільність використання алгоритмів машинного навчання.

Твердження щодо унікальних характеристик економічних даних підтверджується численними теоретичними та емпіричними дослідженнями в галузі макроекономіки та мікроекономічного аналізу, а також фінансів. Згідно з дослідженням авторів [9, 14], випадкові впливи, неточності вимірювань та оновлення даних сприяють більшості варіацій показників, що призводить до зниження співвідношення сигнал/шум та зниження продуктивності стандартних лінійних моделей. Фінансові та макроекономічні дані демонструють нелінійні економічні зв'язки, оскільки реакції показників на зміни факторів є або асиметричними, або залежними від фази залежно від стану економічного циклу. Автори

[2] використовували дані фондового ринку США, щоб продемонструвати, що дохідність активів демонструє складні нелінійні зв'язки з макроекономічними та фінансовими факторами, які алгоритми машинного навчання можуть ефективно моделювати, але лінійні регресії не можуть точно відобразити. Багато дослідницьких робіт показали, що економічні процеси нестабільні за своєю структурою через кризи та зміни в економічній політиці або технологічні зміни. Як показали Makridakis та ін. [16], параметри економетричних моделей змінюються з часом через структурні зміни, що значно зменшує їхню прогностичну силу. Це більш характерно для періодів фінансових криз або пандемій, під час яких попередні залежності більше не застосовуються.

Економічні дані мають велику кількість вимірів у фінансовому та мікроекономічному застосуванні. Кількість пояснювальних змінних може бути більшою за кількість значень спостережень. Belloni та ін. [15] показують, що за цих обставин традиційні методи оцінювання стають ненадійними, але машинне навчання та регуляризовані підходи все ще застосовні.

У макроекономіці використовується мало вибірок, оскільки знайдені річні або квартальні дані мають короткий часовий ряд. Згідно з Mullainathan та ін. [2], класичні економетричні моделі мають серйозні обмеження через малу кількість спостережень та багато факторів, що збільшує тенденцію до упередженості оцінок.

Більшість економічних показників можна представити у вигляді часових рядів (1), які характеризуються трендами, сезонністю та циклічністю.

$$\{y_t\}_{t=1}^T \quad (1)$$

У загальному вигляді часовий ряд може бути поданий як

$$y_t = \mu_t + s_t + c_t + \varepsilon_t, \quad (2)$$

де μ_t — трендова компонента, s_t — сезонна складова, c_t — циклічна складова, ε_t — випадковий шум [9].

Для економічних даних типовою є *нестационарність*, коли математичне сподівання та дисперсія змінюються з часом:

$$\mathbb{E}(y_t) \neq \text{const}, \quad (3)$$

$$\text{Var}(y_t) \neq \text{const}. \quad (4)$$

Це ускладнює застосування класичних моделей, тоді як алгоритми машинного навчання, зокрема рекурентні нейронні мережі та ансамблеві методи, демонструють кращу адаптивність до таких умов [11, 16].

Економічні процеси рідко підпорядковуються лінійним залежностям. Узагальнену економічну модель можна подати як

$$y = f(x_1, x_2, \dots, x_p) + \varepsilon, \quad (5)$$

де функція $f(x_1, x_2, \dots, x_p)$ є невідомою та, як правило, нелінійною. Лінійна регресія (6) часто не здатна адекватно відобразити такі залежності, особливо за наявності взаємодій між змінними [12].

$$y = \beta_0 + \sum_{i=1}^F \beta_i x_i + \varepsilon \quad (6)$$

Алгоритми машинного навчання, зокрема дерева рішень, випадкові ліси та градієнтний бустинг, реалізують наближення складних нелінійних функцій:

$$f(x) = \sum_{m=1}^M \gamma_m h_m(x), \quad (7)$$

де $h_m(x)$ — слабкі базові моделі [7, 8, 17]. Це робить їх ефективними для аналізу макроекономічних та фінансових даних [6, 18]. Умови високої розмірності призводять до проблеми мультиколінеарності та нестабільності оцінок у класичних моделях. Методи машинного навчання, зокрема регуляризовані моделі та методи відбору змінних, дозволяють мінімізувати функцію втрат:

$$\mathcal{L}(\beta) = \sum_{i=1}^T (y_i - X_i \beta)^2 + \lambda \|\beta\|_1, \quad (8)$$

що лежить в основі LASSO-підходів та їх економічних застосувань [19, 20].

Економічні дані часто містять значний рівень шуму, а також пропуски, пов'язані з інституційними або методологічними змінами. Крім того, для макроекономічних рядів характерні *структурні зміни*, зумовлені кризами, реформами або зовнішніми шоками [14, 21]. Алгоритми машинного навчання, особливо ансамблеві методи, демонструють вищу стійкість до таких особливостей порівняно з параметричними моделями [22, 23].

Важливою особливістю використання машинного навчання в економіці є орієнтація на прогнозування, а не на інтерпретацію параметрів. Як зазначено у [12], оптимізація функції втрат (10) не гарантує коректного встановлення причинно-наслідкових зв'язків.

$$\min_f E[(y - f(x))^2], \quad (9)$$

Це зумовило розвиток напрямів *causal machine learning* та *double machine learning*. Каузальне (причинно-наслідкове) машинне навчання поєднує алгоритми машинного навчання з економетричними методами каузального аналізу з метою оцінювання причинно-наслідкових ефектів у складних економічних системах. Одним із ключових підходів у цьому напрямі є подвійне машинне навчання, яке використовує ML-алгоритми для моделювання допоміжних компонентів і забезпечує коректну оцінку каузальних параметрів у високорозмірних моделях [13, 24].

Економічні дані як об'єкт машинного навчання характеризуються складною структурою, нелінійністю, високою розмірністю та динамічністю. Саме ці особливості зумовлюють зростання інтересу до алгоритмів машинного навчання в економічних дослідженнях та необхідність їх критичного й методологічно обґрунтованого використання [5, 25, 26].

Методи навчання з учителем широко застосовуються для прогнозування економічних показників та розв'язання задач регресії й класифікації. Лінійна та поліноміальна регресія використовуються для оцінювання залежностей між макроекономічними змінними, тоді як дерева рішень, випадкові ліси та градієнтний бустинг забезпечують кращу точність у разі

нелінійних взаємозв'язків. Підтримуючі векторні машини (SVM) знаходять застосування в кредитному скорингу, оцінюванні ризиків і прогнозуванні банкрутств.

Формально задачі навчання з учителем можуть бути записані у вигляді, аналогічному класичним економетричним моделям. Проте, незважаючи на зовнішню схожість математичного запису, підхід машинного навчання принципово відрізняється за своєю методологією. У межах економетричного аналізу залежність між змінними задається параметрично та інтерпретується з позицій причинно-наслідкових зв'язків, тоді як у машинному навчанні функція $f(\cdot)$ розглядається як гнучка апроксимація, спрямована передусім на мінімізацію помилки прогнозування.

Алгоритми навчання з учителем є одним із найпоширеніших інструментів машинного навчання в економічному аналізі, оскільки дозволяють будувати моделі на основі пар спостережень. Основною метою таких алгоритмів є побудова апроксимації невідомої залежності (11) шляхом мінімізації емпіричної функції втрат (8)[4, 20].

$$y = f(x) + \varepsilon \quad (10)$$

Регресійні алгоритми навчання з учителем традиційно використовуються для прогнозування макроекономічних показників, таких як валовий внутрішній продукт, інфляція, безробіття та валютні курси. Лінійна регресійна модель має вигляд:

$$y_t = \beta_0 + \sum_{i=1}^p \beta_i x_{it} + \varepsilon_t \quad (11)$$

У разі високої розмірності або мультиколінеарності ефективними є регуляризовані підходи, зокрема LASSO та Ridge-регресія, що розв'язують задачу:

$$\min_{\beta} \sum_{i=1}^T (y_i - X_i \beta)^2 + \lambda \|\beta\|_q, q \in \{1, 2\} \quad (12)$$

де λ — параметр регуляризації [15, 19]. Такі методи широко застосовуються у макроекономічному прогнозуванні та аналізі великих панельних наборів даних [14, 21]. LASSO- та Ridge-регресія є методами регуляризованої лінійної регресії, що застосовуються для підвищення стабільності оцінок у задачах економічного аналізу з високою вимірністю даних та мультиколінеарністю пояснювальних змінних. Ridge-регресія використовує L_2 -регуляризацію, яка зменшує величини коефіцієнтів без їх занулення, тоді як LASSO-регресія базується на L_1 -регуляризації та забезпечує автоматичний відбір змінних шляхом обнулення частини параметрів моделі [4].

Дерева рішень є нелінійними моделями, які послідовно розбивають простір ознак на підмножини:

$$X = \bigcup_{m=1}^M R_{m1}, f(x) = \sum_{m=1}^M c_{m2} I(x \in R_{m2}), \quad (13)$$

де R_{m1} — регіони простору ознак, c_{m2} — середні значення цільової змінної [4].

На практиці більш ефективними є ансамблеві методи. Випадкові ліси будуються як усереднення багатьох дерев, що підвищує стійкість до шуму та перенавчання [7, 22].

Алгоритми градієнтного бустингу реалізують послідовне мінімізування функції втрат:

$$f_m(x) = f_{m-1}(x) + \gamma_m h_m(x), \quad (14)$$

де $h_m(x)$ — слабка модель, оптимізована за градієнтом втрат [8, 17]. Ці методи активно застосовуються в аналізі фінансових ризиків, кредитному скорингу та прогнозуванні економічних індикаторів [6, 18].

У економічних дослідженнях підтримуючі векторні машини (SVM) застосовуються для класифікації фінансових станів, оцінювання кредитоспроможності та прогнозування банкрутств підприємств [27, 28].

Штучні нейронні мережі моделюють залежність

$$y = f(x; \theta), \quad (15)$$

де θ — вектор параметрів, що оптимізується шляхом мінімізації функції втрат за допомогою градієнтних методів [10].

Особливої уваги заслуговують рекурентні нейронні мережі (RNN) та LSTM-архітектури, які описуються рекурсивними співвідношеннями:

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b), \quad (16)$$

та ефективно враховують часові залежності економічних даних [11, 29].

Навчання без учителя застосовується для виявлення прихованих структур у економічних даних без попереднього маркування. Алгоритми кластеризації, зокрема k -середніх, ієрархічна кластеризація та DBSCAN, використовуються для сегментації споживачів, аналізу ринків і виявлення аномалій. Методи зниження розмірності, такі як метод головних компонент, дозволяють скоротити кількість змінних та виявити ключові фактори, що впливають на економічні процеси [4, 30]. Формально задача навчання без учителя полягає в аналізі вибірки з метою відновлення прихованої структури розподілу $P(X)$.

$$\{x_t\}_{t=1}^T, x_t \in \mathbb{R}^p, \quad (17)$$

Кластеризація є одним із базових методів навчання без учителя, що використовується для групування економічних об'єктів за подібністю. Одним із найпоширеніших алгоритмів є метод k -середніх, який розв'язує задачу:

$$\min_{\{c_k\}_{k=1}^K} \sum_{k=1}^K \sum_{x_t \in \mathcal{L}_k} \|x_t - \mu_k\|^2, \quad (18)$$

де μ_k — центр k -го кластера [4].

В економіці кластеризація застосовується для сегментації споживачів, групування регіонів за рівнем розвитку та аналізу ринкової структури [1, 26]. Альтернативні підходи, зокрема ієрархічна кластеризація та щільнісні методи, дозволяють виявляти складніші структури даних без попереднього задання кількості кластерів [30].

Висока розмірність економічних даних ускладнює їх інтерпретацію та аналіз. Одним із класичних підходів є метод головних компонент, який полягає в знаходженні ортогональних

напрямів максимальної дисперсії. Його широко використовують для ідентифікації ключових макроекономічних факторів та зниження розмірності панельних даних [14, 21]. Узагальненням методу є динамічні факторні моделі, які враховують часову структуру даних:

$$x_t = \Lambda f_t + \varepsilon_t, \quad (19)$$

де f_t — вектор латентних факторів [14, 21].

Ще одна важлива задача в аналізі фінансових та макроекономічних даних, зокрема для ідентифікації кризових періодів, шахрайських операцій або структурних зламів – виявлення аномалій. Формально аномальні спостереження визначаються як такі, для яких імовірність реалізації за припущеною моделлю розподілу є істотно нижчою порівняно з основною масою вибірки або ж які характеризуються значним відхиленням від типових закономірностей, притаманних досліджуваному економічному процесу. Алгоритми кластеризації та методи на основі відстаней ефективно застосовуються для таких задач, демонструючи високу чутливість до нетипових економічних явищ [18, 31].

Метод незалежних компонент орієнтований на декомпозицію спостережуваних змінних у незалежні латентні джерела. Даний метод використовується для виявлення прихованих причинних структур у економічних системах [32]. Поєднання методу незалежних змінних з методами машинного навчання відкриває нові можливості для причинного аналізу економічних процесів без жорстких структурних припущень [13, 24].

На відміну від алгоритмів навчання з учителем, методи навчання без учителя зосереджені не на точності прогнозування, а на виявленні структури даних та генерації економічних гіпотез. Вони відіграють ключову роль у попередньому аналізі даних, формуванні ознак та побудові гібридних моделей, що поєднують ML-підходи з економічною теорією [2, 5].

Глибокі нейронні мережі дедалі частіше використовуються для аналізу складних економічних систем. Рекурентні нейронні мережі (RNN) та архітектури LSTM є ефективними для прогнозування часових рядів, зокрема ВВП, інфляції та валютних курсів. Згорткові нейронні мережі можуть застосовуватися для аналізу альтернативних економічних даних, таких як супутникові знімки чи текстова інформація з новинних джерел.

Глибоке навчання є напрямом машинного навчання, що базується на багатошарових штучних нейронних мережах і забезпечує високу здатність до моделювання складних нелінійних залежностей у даних. В економічному аналізі нейронні мережі використовуються для прогнозування макроекономічних показників, аналізу фінансових ринків, оцінювання ризиків та обробки альтернативних джерел даних, таких як текстова та високочастотна інформація [3, 10].

Базовим елементом нейронної мережі є штучний нейрон, який обчислює:

$$z = \sum_{i=1}^p w_i x_i + b, \quad a = \sigma(z), \quad (20)$$

де x_i — вхідні ознаки, w_i — вагові коефіцієнти, b — зміщення, $\sigma(z)$ — нелінійна активаційна функція [30].

Багатошарова нейронна мережа реалізує композицію таких перетворень:

$$f(x) = f^{(L)} \circ f^{(L-1)} \circ \dots \circ f^{(1)}(x), \quad (21)$$

що дозволяє апроксимувати довільні неперервні функції з високою точністю [10].

Навчання нейронних мереж полягає в оптимізації параметрів моделі, зокрема вагових коефіцієнтів і зміщень, шляхом мінімізації функції втрат, що відображає відхилення прогнозованих значень від фактичних спостережень. Оптимізація здійснюється за допомогою алгоритму зворотного поширення помилки у поєднанні з градієнтними методами, які забезпечують поступове коригування параметрів моделі з метою підвищення точності прогнозування [33]. У задачах економічного прогнозування найбільш поширеними є квадратична функція втрат для регресійних моделей та логістична функція втрат у задачах класифікації економічних станів, зокрема для оцінювання ймовірності кризових явищ або змін фаз економічного циклу [20, 28].

Оскільки економічні дані характеризуються вираженою часовою залежністю та наявністю динамічних ефектів, особливого значення набувають рекурентні нейронні мережі, здатні враховувати інформацію про попередні стани системи під час формування прогнозів. Такі моделі дозволяють ефективно моделювати часові ряди макроекономічних показників, фінансових індексів та інших динамічних економічних змінних.

Подальшим розвитком рекурентних архітектур є нейронні мережі з довгою короткостроковою пам'яттю (LSTM), які завдяки спеціальним механізмам керування інформаційними потоками забезпечують збереження важливої інформації на тривалих часових інтервалах та зменшують проблему зникнення градієнта під час навчання. Це робить LSTM-мережі особливо придатними для аналізу складних нелінійних часових залежностей в економіці. У сучасних дослідженнях такі моделі успішно застосовуються для прогнозування валового внутрішнього продукту, інфляції, валютних курсів та фінансових ринкових індексів, демонструючи вищу точність порівняно з традиційними підходами [10, 11, 29, 34].

Однією з ключових переваг глибокого навчання є здатність працювати з великими та неструктурованими економічними даними. Зокрема, нейронні мережі дозволяють інтегрувати макроекономічні показники з текстовими та альтернативними джерелами даних, що підвищує якість прогнозів [1, 26]. Однак ефективність глибоких моделей значною мірою залежить від обсягу навчальної вибірки та обчислювальних ресурсів, що обмежує їх застосування в деяких економічних задачах [3, 35].

Попри високу прогностичну здатність, нейронні мережі часто критикуються за низьку інтерпретованість, що суперечить традиційним вимогам економічного аналізу. Як зазначає Shmueli в [12], оптимізація точності прогнозу не гарантує економічної інтерпретації отриманих результатів. Сучасні дослідження спрямовані на поєднання глибокого навчання з причинно-наслідковими підходами та економічною теорією, зокрема в рамках *causal machine learning* [13, 24].

На відміну від традиційних економетричних моделей, алгоритми машинного навчання орієнтовані насамперед на мінімізацію помилки прогнозування, а не на інтерпретацію параметрів моделі. Це створює методологічні труднощі для економічного аналізу, де ключовим є пояснення причинно-наслідкових зв'язків. У зв'язку з цим у сучасних дослідженнях дедалі частіше застосовуються гібридні підходи, що поєднують економетричні методи з алгоритмами машинного навчання [1, 13].

Класична економетрика та машинне навчання мають різні дослідницькі цілі та методологічні засади. Економетрика орієнтована на перевірку економічних гіпотез, ідентифікацію каузальних ефектів та інтерпретацію параметрів моделей, які мають чіткий економічний зміст [35, 36]. Машинне навчання, натомість, фокусується на гнучкій апроксимації залежностей у даних без явного задання функціональної форми з метою підвищення прогнозової точності [2, 4]. Ключові відмінності між цими підходами узагальнено в табл. 1.

Важливою відмінністю є ставлення до припущень щодо структури даних. Класична економетрика базується на припущеннях лінійності, екзогенності та коректної специфікації моделі, порушення яких призводить до зміщених або неефективних оцінок. Алгоритми

машинного навчання є менш чутливими до нелінійностей, мультиколінеарності та високої вимірності, що робить їх придатними для аналізу складних економічних даних [7, 30].

Таблиця 1. Порівняння класичної економетрики та машинного навчання

Критерій	Класична економетрика	Машинне навчання
Основна мета	Пояснення, каузальність	Прогнозування
Форма моделі	Параметрична	Непараметрична
Припущення	Жорсткі	Мінімальні
Робота з великими даними	Обмежена	Ефективна
Інтерпретованість	Висока	Обмежена
Прогнозна точність	Помірна	Висока

Джерело: узагальнено та систематизовано автором на основі [1, 2, 4, 5, 7, 9, 12]

Разом із тим обмежена інтерпретованість результатів залишається ключовим недоліком машинного навчання. Це зумовило розвиток напрямів інтерпретованого штучного інтелекту (*explainable artificial intelligence*), спрямованих на підвищення прозорості та пояснюваності складних моделей, а також причинно-наслідкового орієнтованого машинного навчання (*causal machine learning*), зокрема методів подвійного (незміщеного) машинного навчання (*double/debiased machine learning*), які поєднують причинно-наслідкову логіку економетрики з гнучкістю алгоритмів машинного навчання у високовимірних економічних середовищах. [5, 24].

Таким чином, машинне навчання та класична економетрика слід розглядати як взаємодоповнювальні підходи, порівняльні характеристики яких подано в табл. 1, що значно розширює аналітичні можливості сучасних економічних досліджень.

Незважаючи на високий прикладний потенціал, використання методів машинного навчання в економічному аналізі супроводжується низкою обмежень. Одним із ключових є обмежена інтерпретованість складних моделей, що ускладнює економічне тлумачення результатів і знижує довіру до них з боку дослідників та практиків. Для економічної науки важливо не лише отримати точний прогноз, а й пояснити механізми формування результатів, що залишається проблематичним для багатьох ML-алгоритмів [1].

Суттєвим викликом є також ризик перенавчання, особливо в умовах відносно малих макроекономічних вибірок, структурних зламів і нестабільності економічних процесів. Навіть із застосуванням регуляризації та процедур крос-валідації прогностична здатність моделей може знижуватися у разі зміни економічного середовища [9, 14]. Окрім цього, алгоритми машинного навчання не забезпечують каузальності за замовчуванням, оскільки виявляють переважно кореляційні залежності, які без теоретичного обґрунтування можуть призводити до хибних управлінських або політичних висновків [35, 36].

Водночас перспективи розвитку машинного навчання в економіці є значними. Найбільш перспективним напрямом є інтеграція ML з економетричними та структурними моделями, а також розвиток каузального машинного навчання (*causal machine learning*), зокрема підходів подвійного (незміщеного) машинного навчання (*double/debiased machine learning*), які поєднують гнучкість алгоритмів із каузальною логікою економетрики [13, 24]. Паралельно розвиваються методи інтерпретованого штучного інтелекту (*explainable AI*), спрямовані на підвищення прозорості моделей.

Подальший розвиток глибокого навчання відкриває нові можливості для аналізу великих масивів економічних даних, зокрема фінансових, текстових і мережевих, а також для задач *nowcasting* та моніторингу економічної активності в реальному часі [31, 33]. У підсумку машинне навчання не замінює класичну економетрику, а доповнює її, формуючи сучасну

дано-орієнтовану парадигму економічного аналізу з підвищеною масштабованістю та прогнозною ефективністю.

Висновки. У статті узагальнено сучасні підходи до застосування алгоритмів машинного навчання в економічному аналізі та прогнозуванні. Отримані результати підтверджують, що економічні моделі даних мають специфічні властивості — нелінійність і високий рівень шуму, структурну нестабільність, невеликі вибірки та високу розмірність — які суттєво обмежують ефективність класичних економетричних методів і визначають доцільність використання інструментів машинного навчання. Алгоритми контрольованого, неконтрольованого та глибокого навчання виявляються високоадаптивними та здатними моделювати складні економічні процеси, включаючи макроекономічне прогнозування, аналіз фінансових ринків та виявлення прихованих структур на основі даних.

Водночас встановлено, що використання машинного навчання в економіці супроводжується значними методологічними обмеженнями, включаючи обмежену інтерпретованість, ризик перенавчання та відсутність причинно-наслідкового зв'язку за задумом. Орієнтація більшості алгоритмів машинного навчання на мінімізацію помилки прогнозування ускладнює економічну інтерпретацію результатів і вимагає обережного використання таких моделей у прикладних дослідженнях та розробці політики. Це вказує на важливість критичного погляду на результати машинного навчання та їх інтеграції з економічною теорією та економетричними методами. Таким чином, перспективи подальшого розвитку полягають у формуванні гібридних підходів, що інтегрують машинне навчання з класичною економетрикою, структурними моделями та каузальним аналізом. Найбільш перспективними напрямками є каузальне машинне навчання, подвійне/ незміщене машинне навчання та explainable AI, які поєднують високу точність прогнозування з каузальною інтерпретацією та вищою прозорістю моделі. У цьому контексті машинне навчання слід розглядати не як альтернативу економетриці, а як її логічне продовження, що формує сучасну орієнтовану на дані парадигму економічних досліджень.

ЛІТЕРАТУРА

1. *Varian H. R.* Big data: New tricks for econometrics // *Journal of Economic Perspectives*. 2014. Vol. 28, No. 2. P. 3–28. DOI: <https://doi.org/10.1257/jep.28.2.3>
2. *Mullainathan S., Spiess J.* Machine learning: An applied econometric approach // *Journal of Economic Perspectives*. 2017. Vol. 31, No. 2. P. 87–106. DOI: <https://doi.org/10.1257/jep.31.2.87>
3. *Jordan M. I., Mitchell T. M.* Machine learning: Trends, perspectives, and prospects // *Science*. 2015. Vol. 349(6245). P. 255–260. DOI: <https://doi.org/10.1126/science.aaa8415>
4. *Hastie T., Tibshirani R., Friedman J.* *The Elements of Statistical Learning*. 2nd ed. New York: Springer, 2009. DOI: <https://doi.org/10.1007/978-0-387-84858-7>
5. *Athey S.* The impact of machine learning on economics // *The Economics of Artificial Intelligence*. 2019. P. 507–547. DOI: <https://doi.org/10.7208/chicago/9780226613475.003.0009>
6. *Gu S., Kelly B., Xiu D.* Empirical asset pricing via machine learning // *The Review of Financial Studies*. 2020. Vol. 33(5). P. 2223–2273. DOI: <https://doi.org/10.1093/rfs/hhaa009>
7. *Breiman L.* Random forests // *Machine Learning*. 2001. Vol. 45. P. 5–32. DOI: <https://doi.org/10.1023/A:1010933404324>
8. *Chen T., Guestrin C.* XGBoost: A scalable tree boosting system // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. P. 785–794. DOI: <https://doi.org/10.1145/2939672.2939785>
9. *Hyndman R. J., Athanasopoulos G.* *Forecasting: Principles and Practice*. 3rd ed. Melbourne: OTexts, 2021. URL: <https://otexts.com/fpp3/>
10. *Goodfellow I., Bengio Y., Courville A.* *Deep Learning*. Cambridge: MIT Press, 2016. URL: <https://www.deeplearningbook.org>
11. *Lim B., Zohren S.* Time-series forecasting with deep learning: A survey // *Philosophical Transactions of the Royal Society A*. 2021. Vol. 379. DOI: <https://doi.org/10.1098/rsta.2020.0209>

12. *Shmueli G.* To explain or to predict? // *Statistical Science*. 2010. Vol. 25(3). P. 289–310. DOI: <https://doi.org/10.1214/10-STS330>
13. *Athey S., Imbens G.* Recursive partitioning for heterogeneous causal effects // *Proceedings of the National Academy of Sciences*. 2016. Vol. 113(27). P. 7353–7360. DOI: <https://doi.org/10.1073/pnas.1510489113>
14. *Diebold F. X.* Big data dynamic factor models for macroeconomic measurement and forecasting // *Advances in Economics and Econometrics*. 2014. P. 115–122. DOI: <https://doi.org/10.1017/CBO9781139060035.006>
15. *Belloni A., Chernozhukov V., Hansen C.* High-dimensional methods and inference on structural and treatment effects // *Journal of Economic Perspectives*. 2014. Vol. 28(2). P. 29–50. DOI: <https://doi.org/10.1257/jep.28.2.29>
16. *Makridakis S., Spiliotis E., Assimakopoulos V.* Statistical and machine learning forecasting methods: Concerns and ways forward // *PLOS ONE*. 2018. Vol. 13(3). DOI: <https://doi.org/10.1371/journal.pone.0194889>
17. *Friedman J. H.* Greedy function approximation: A gradient boosting machine // *Annals of Statistics*. 2001. Vol. 29(5). P. 1189–1232. DOI: <https://doi.org/10.1214/aos/1013203451>.
18. *Kräussl R., Lehnert T., Rinne K.* The role of machine learning in financial economics // *Journal of Financial Econometrics*. 2020. Vol. 18(3). P. 393–402. DOI: <https://doi.org/10.1093/jfinc/nbaa010>
19. *Fan J., Lv J.* A selective overview of variable selection in high dimensional feature space // *Statistica Sinica*. 2010. Vol. 20. P. 101–148.
20. *James G., Witten D., Hastie T., Tibshirani R.* *An Introduction to Statistical Learning*. 2nd ed. New York: Springer, 2021. DOI: <https://doi.org/10.1007/978-1-0716-1418-1>
21. *Stock J. H., Watson M. W.* Dynamic factor models, factor-augmented vector autoregressions, and structural vector autoregressions in macroeconomics // *Handbook of Macroeconomics*. 2016. Vol. 2. P. 415–525. DOI: <https://doi.org/10.1016/bs.hesmac.2016.04.002>
22. *Biau G., Scornet E.* A random forest guided tour // *TEST*. 2016. Vol. 25. P. 197–227. DOI: <https://doi.org/10.1007/s11749-016-0481-7>
23. *Arlot S., Celisse A.* A survey of cross-validation procedures for model selection // *Statistics Surveys*. 2010. Vol. 4. P. 40–79. DOI: <https://doi.org/10.1214/09-SS054>
24. *Chernozhukov V., Chetverikov D., Demirer M. et al.* Double/debiased machine learning for treatment and structural parameters // *The Econometrics Journal*. 2018. Vol. 21(1). P. C1–C68. DOI: <https://doi.org/10.1111/ectj.12097>
25. *World Bank.* *Data-driven Development: Machine Learning in Economics*. Washington, DC: World Bank, 2022.
26. *OECD.* *Artificial Intelligence in Society*. Paris: OECD Publishing, 2019. DOI: <https://doi.org/10.1787/eedfee77-en>
27. *Fawcett T.* An introduction to ROC analysis // *Pattern Recognition Letters*. 2006. Vol. 27(8). P. 861–874. DOI: <https://doi.org/10.1016/j.patrec.2005.10.010>
28. *Atiya A. F., El-Shishiny H., El-Dessouky M. et al.* A comparison of state-of-the-art machine learning techniques for forecasting economic time series // *IEEE Transactions on Neural Networks*. 2010. Vol. 21(5). P. 818–833. DOI: <https://doi.org/10.1109/TNN.2010.2044809>
29. *Zhang G., Patuwo B. E., Hu M. Y.* Forecasting with artificial neural networks // *International Journal of Forecasting*. 1998. Vol. 14(1). P. 35–62. DOI: [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)
30. *Bishop C. M.* *Pattern Recognition and Machine Learning*. New York: Springer, 2006. DOI: <https://doi.org/10.1007/978-0-387-45528-0>
31. *OECD.* *Artificial Intelligence, Machine Learning and Big Data in Finance*. Paris: OECD Publishing, 2021. DOI: <https://doi.org/10.1787/7d7ee4d7-en>
32. *Moneta A., Chlaß N., Entner D., Hoyer P. C.* Causal inference by independent component analysis // *Oxford Bulletin of Economics and Statistics*. 2013. Vol. 75(5). P. 705–730. DOI: <https://doi.org/10.1111/obes.12002>
33. *Bengio Y.* Learning deep architectures for AI // *Foundations and Trends in Machine Learning*. 2009. Vol. 2(1). P. 1–127. DOI: <https://doi.org/10.1561/22000000006>
34. *Galeshchuk S.* Neural networks performance in exchange rate prediction // *Neurocomputing*. 2016. Vol. 172. P. 446–452. DOI: <https://doi.org/10.1016/j.neucom.2015.03.100>
35. *Ng A.* Machine learning and AI via brain simulations // *Communications of the ACM*. 2016. Vol. 59(4). P. 18–20. DOI: <https://doi.org/10.1145/2890784>
36. *Marushchak S., Fadyeyeva I., Halachev P., Zharkenov N., Pakhomov S.* The role of artificial intelligence and machine learning in forecasting economic trends // *Data and Metadata*. 2024. No. 3., P. 247. DOI: <https://doi.org/10.56294/dm2024.247>

REFERENCES

1. *Varian H. R.* (2014). Big data: New tricks for econometrics. *Journal of Economic Perspectives*, Vol. 28, No. 2, pp. 3–28. <https://doi.org/10.1257/jep.28.2.3>

2. Mullainathan S., Spiess J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, Vol. 31, No. 2, pp. 87–106. <https://doi.org/10.1257/jep.31.2.87>
3. Jordan M. I., Mitchell T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, Vol. 349, Iss. 6245, pp. 255–260. <https://doi.org/10.1126/science.aaa8415>
4. Hastie T., Tibshirani R., Friedman J. (2009). *The Elements of Statistical Learning* (2nd ed.). Springer, New York. <https://doi.org/10.1007/978-0-387-84858-7>
5. Athey S. (2019). The impact of machine learning on economics. In: *The Economics of Artificial Intelligence*, pp. 507–547. <https://doi.org/10.7208/chicago/9780226613475.003.0009>
6. Gu S., Kelly B., Xiu D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, Vol. 33, No. 5, pp. 2223–2273. <https://doi.org/10.1093/rfs/hhaa009>
7. Breiman L. (2001). Random forests. *Machine Learning*, Vol. 45, pp. 5–32. <https://doi.org/10.1023/A:1010933404324>
8. Chen T., Guestrin C. (2016). XGBoost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785–794. <https://doi.org/10.1145/2939672.2939785>
9. Hyndman R. J., Athanasopoulos G. (2021). *Forecasting: Principles and Practice* (3rd ed.). OTexts, Melbourne. Available at: <https://otexts.com/fpp3/>
10. Goodfellow I., Bengio Y., Courville A. (2016). *Deep Learning*. MIT Press, Cambridge. Available at: <https://www.deeplearningbook.org>
11. Lim B., Zohren S. (2021). Time-series forecasting with deep learning: A survey. *Philosophical Transactions of the Royal Society A*, Vol. 379. <https://doi.org/10.1098/rsta.2020.0209>
12. Shmueli G. (2010). To explain or to predict? *Statistical Science*, Vol. 25, No. 3, pp. 289–310. <https://doi.org/10.1214/10-STS330>
13. Athey S., Imbens G. (2016). Recursive partitioning for heterogeneous causal effects. *Proceedings of the National Academy of Sciences*, Vol. 113, No. 27, pp. 7353–7360. <https://doi.org/10.1073/pnas.1510489113>
14. Diebold F. X. (2014). Big data dynamic factor models for macroeconomic measurement and forecasting. In: *Advances in Economics and Econometrics*, pp. 115–122. <https://doi.org/10.1017/CBO9781139060035.006>
15. Belloni A., Chernozhukov V., Hansen C. (2014). High-dimensional methods and inference on structural and treatment effects. *Journal of Economic Perspectives*, Vol. 28, No. 2, pp. 29–50. <https://doi.org/10.1257/jep.28.2.29> (Accessed 18 November 2025).
16. Makridakis S., Spiliotis E., Assimakopoulos V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *PLOS ONE*, Vol. 13, No. 3. <https://doi.org/10.1371/journal.pone.0194889>
17. Friedman J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, Vol. 29, No. 5, pp. 1189–1232. <https://doi.org/10.1214/aos/1013203451>
18. Kräussl R., Lehnert T., Rinne K. (2020). The role of machine learning in financial economics. *Journal of Financial Econometrics*, Vol. 18, No. 3, pp. 393–402. <https://doi.org/10.1093/jfinec/nbaa010>
19. Fan J., Lv J. (2010). A selective overview of variable selection in high dimensional feature space. *Statistica Sinica*, Vol. 20, pp. 101–148.
20. James G., Witten D., Hastie T., Tibshirani R. (2021). *An Introduction to Statistical Learning* (2nd ed.). Springer, New York. <https://doi.org/10.1007/978-1-0716-1418-1>
21. Stock J. H., Watson M. W. (2016). Dynamic factor models, factor-augmented vector autoregressions, and structural vector autoregressions in macroeconomics. In: *Handbook of Macroeconomics*, Vol. 2, pp. 415–525. <https://doi.org/10.1016/bs.hesmac.2016.04.002> (Accessed 25 October 2025).
22. Biau G., Scornet E. (2016). A random forest guided tour. *TEST*, Vol. 25, pp. 197–227. <https://doi.org/10.1007/s11749-016-0481-7> (Accessed 23 November 2025).
23. Arlot S., Celisse A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, Vol. 4, pp. 40–79. <https://doi.org/10.1214/09-SS054>
24. Chernozhukov V., Chetverikov D., Demirer M. et al. (2018). Double/debiased machine learning for treatment and structural parameters. *The Econometrics Journal*, Vol. 21, No. 1, pp. C1–C68. <https://doi.org/10.1111/ectj.12097>
25. World Bank. (2022). *Data-driven Development: Machine Learning in Economics*. World Bank, Washington, DC.
26. OECD. (2019). *Artificial Intelligence in Society*. OECD Publishing, Paris. <https://doi.org/10.1787/eedfee77-en>
27. Fawcett T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, Vol. 27, No. 8, pp. 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
28. Atiya A. F., El-Shishiny H., El-Dessouky M. et al. (2010). A comparison of state-of-the-art machine learning techniques for forecasting economic time series. *IEEE Transactions on Neural Networks*, Vol. 21, No. 5, pp. 818–833. <https://doi.org/10.1109/TNN.2010.2044809>
29. Zhang G., Patuwo B. E., Hu M. Y. (1998). Forecasting with artificial neural networks. *International Journal of Forecasting*, Vol. 14, No. 1, pp. 35–62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7) (Accessed 6 December 2025).

30. Bishop C. M. (2006). *Pattern Recognition and Machine Learning*. Springer, New York. <https://doi.org/10.1007/978-0-387-45528-0>
31. OECD. (2021). *Artificial Intelligence, Machine Learning and Big Data in Finance*. OECD Publishing, Paris. <https://doi.org/10.1787/7d7ee4d7-en>
32. Moneta A., Chlaß N., Entner D., Hoyer P. C. (2013). Causal inference by independent component analysis. *Oxford Bulletin of Economics and Statistics*, Vol. 75, No. 5, pp. 705–730. <https://doi.org/10.1111/obes.12002>
33. Bengio Y. (2009). Learning deep architectures for AI. *Foundations and Trends in Machine Learning*, Vol. 2, No. 1, pp. 1–127. <https://doi.org/10.1561/2200000006>
34. Galeshchuk S. (2016). Neural networks performance in exchange rate prediction. *Neurocomputing*, Vol. 172, pp. 446–452. <https://doi.org/10.1016/j.neucom.2015.03.100>
35. Ng A. (2016). Machine learning and AI via brain simulations. *Communications of the ACM*, Vol. 59, No. 4, pp. 18–20. <https://doi.org/10.1145/2890784>
36. Marushchak S., Fadyeyeva I., Halachev P., Zharkenov N., Pakhomov S. (2024). The role of artificial intelligence and machine learning in forecasting economic trends. *Data and Metadata*, No. 3. <https://doi.org/10.56294/dm2024.247>

Dmytro Semeniuk
(Postgraduate, National Transport University)

THEORETICAL AND APPLIED ASPECTS OF USING MACHINE LEARNING IN ECONOMIC DATA ANALYSIS

The article explores modern approaches to macroeconomic forecasting based on machine learning methods and their integration with classical econometric models. The subject of the study is data-driven forecasting of key macroeconomic indicators under conditions of high dimensionality, structural instability, and limited observability of economic processes. The purpose of the research is to systematize contemporary machine learning tools used in macroeconomic analysis, assess their methodological foundations, and identify the advantages and limitations of their application for forecasting and inference.

The methodological framework combines econometric theory, statistical learning, and modern machine learning techniques. Particular attention is paid to regularization methods, tree-based algorithms, ensemble models, and neural networks, including recurrent architectures designed for time series analysis. The study also considers approaches to model validation, loss minimization, and overfitting control in the context of economic data characterized by noise, nonlinearity, and regime shifts. Alongside predictive performance, the article emphasizes the growing importance of interpretability and causal reasoning in applied macroeconomic modeling.

The results demonstrate that machine learning models substantially improve short- and medium-term forecasting accuracy compared to traditional linear specifications, especially when dealing with large information sets and nonlinear relationships. At the same time, purely predictive models are shown to have limited explanatory power and may produce biased estimates when used for policy evaluation. This has stimulated the development of explainable artificial intelligence and causal machine learning approaches, including double and debiased machine learning, which combine the flexibility of machine learning algorithms with the causal logic of econometrics. These methods enable valid inference on structural and treatment effects in high-dimensional settings while mitigating regularization bias.

Keywords: machine learning, artificial intelligence, economic forecasting, macroeconomic indicators, time series, econometric models.

Стаття прийнята до друку 18 листопада 2025 року