

УДК 004.9:005.8:519.816

JEL C45, D81, M15, O22

DOI: <https://doi.org/10.32782/2786-8273/2026-14-26>**Савіна С.С.**

кандидат економічних наук, доцент,
доцент кафедри штучного інтелекту, моделювання та статистики,
Київський національний економічний
університет імені Вадима Гетьмана
ORCID: <https://orcid.org/0000-0003-0227-7081>

Svitlana Savina

Kyiv National Economic University named after Vadym Hetman

Семашко К.А.

кандидат економічних наук,
доцент кафедри штучного інтелекту, моделювання та статистики,
Київський національний економічний
університет імені Вадима Гетьмана
ORCID: <https://orcid.org/0009-0007-4946-3179>

Kateryna Semashko

Kyiv National Economic University named after Vadym Hetman

АНСАМБЛІ МОДЕЛЕЙ У ЗАДАЧАХ ОБҐРУНТУВАННЯ РІШЕНЬ ДЛЯ УПРАВЛІННЯ ІТ-ПРОЄКТАМИ

MODEL ENSEMBLES IN DECISION JUSTIFICATION TASKS FOR IT PROJECT MANAGEMENT

Анотація. Мета дослідження – підвищення обґрунтованості управлінських рішень у процесах управління ІТ-проєктами шляхом об'єднання результатів кількох прогностичних моделей в ансамбль для класифікації рішення в контрольній точці за схемою «go/no-go» (продовжувати за планом/потрібне втручання). Методика дослідження ґрунтується на ансамблевих технологіях машинного навчання: розглянуто бустінг та реалізовано авторський алгоритм побудови ансамблю на основі спеціалізації експертів із динамічною інтеграцією моделей і зваженим голосуванням за коефіцієнтами компетентності. Результати: формалізовано алгоритм, обґрунтовано теоретичну умову доцільності комітету та продемонстровано працездатність підходу на ілюстративному прикладі з умовними проєктами. Практична значущість полягає у створенні інструменту підтримки рішень для проєктних офісів за умов неоднорідних і обмежених даних.

Ключові слова: цифрова економіка; ІТ-проєкт; життєвий цикл ІТ-проєкту; гнучкі методології; управління проєктами; підтримка прийняття рішень; ансамбль моделей; бустінг; нейронна мережа; управління ризиками; показники ефективності.

Abstract. Introduction. Managing IT projects requires continuous decisions whose quality determines whether a project meets its schedule, budget and client requirements. The most critical are made at the control points of the project life cycle, where the manager chooses between continuing under the current plan and initiating managerial intervention – a binary “go / no-go” choice. Their substantiation is complicated by the heterogeneity of IT projects, the limited statistics for new products, and reliance on subjective expert estimates. Under such conditions no single formal model is universally accurate. **Purpose.** The purpose is to develop a methodological approach to forming substantiated managerial decisions at the control points of IT projects on the basis of an ensemble of models that accounts for the specialisation of individual expert models. **Methods.** The study relies on ensemble machine-learning technologies. A threshold condition of committee expediency is derived analytically, showing that combining models improves the decision only when the accuracy of each expert exceeds 0.5. The core method is the authors' algorithm of ensemble construction based on expert specialisation with dynamic integration: qualitative attributes define specialisation axes along which homogeneous subsamples are formed, and a separate radial-basis-function expert is trained on each. The decision is made by relevant experts under a stopping rule, and in case of a tie – by weighted voting according to competence coefficients. **Results.** The algorithm is formalised, the condition of committee expediency is proved and confirmed by a numerical counter-example, and the approach is demonstrated on an illustrative example. Because each expert specialises on a logically separated data segment, their errors are weakly correlated, providing higher efficiency than boosting on heterogeneous data. **Conclusion.** The proposed approach forms a decision-support tool for project offices operating under heterogeneous and limited data. Its novelty lies in transferring the expert-specialisation ensemble algorithm to binary managerial decisions at the control points of IT projects. Further research concerns approbation on real and simulated data and generalisation to a multiclass formulation.

Keywords: digital economy; IT project; project life cycle; agile methodologies; project management; decision support; ensemble of models; boosting; neural network; risk management; performance indicators.

Постановка проблеми та її актуальність. Управління IT-проектами супроводжується безперервним ухваленням рішень, від якості яких прямо залежить результат проекту: дотримання строків і бюджету, відповідність продукту вимогам замовника, збалансованість завантаження команди. Особливого значення набувають рішення, що приймаються у контрольних точках життєвого циклу проекту (на межах етапів, ітерацій або спринтів), коли керівник повинен визначити, чи продовжувати роботи за наявним планом, чи ініціювати управлінське втручання – ескалацію, перегляд обсягу робіт, перерозподіл ресурсів. Таке рішення за своєю природою є бінарним і зводиться до вибору “go / no-go”: продовжувати без змін або втрутитися.

Обґрунтованість подібних рішень ускладнюється низкою чинників. По-перше, IT-проекти є суттєво неоднорідними: вони різняться за типом (розробка, інтеграція, міграція), застосованою методологією, розміром і зрілістю команди, технологічним стеком, категорією замовника. По-друге, обсяг накопиченої статистичної інформації часто обмежений, особливо для нових продуктів і напрямів, за якими історія проєктів іще не сформована. По-третє, класичні підходи спираються переважно на суб’єктивні експертні оцінки, що знижує відтворюваність і прозорість рішень.

Ціна невчасного або необґрунтованого рішення в контрольній точці зростає з наближенням до завершення проекту: вартість усунення відхилень, виявлених на пізніх етапах, у разі перевищує вартість їх раннього виявлення. Тому підвищення обґрунтованості рішень саме у проміжних контрольних точках дає найбільший практичний ефект, дозволяючи керівникові вчасно локалізувати проблемні проєкти й спрямувати управлінський вплив туди, де він найбільш потрібен.

За таких умов жодна окрема формальна модель не може бути універсально точною на всьому різноманітті проєктних ситуацій. Модель, налаштована на «усереднений» проєкт, втрачає чутливість до специфіки окремих підгруп, а модель, побудована на вузькому сегменті, не узагальнюється на решту випадків. Продуктивним напрямом розв’язання цієї суперечності є ансамблеві технології машинного навчання, за яких остаточне рішення формується шляхом узагальнення результатів кількох моделей-експертів. Дослідження механізмів побудови таких ансамблів для задачі підтримки рішень в управлінні IT-проектами й пов’язане з найважливішими практичними завданнями проєктних офісів (РМО), портфельного управління та ризик-менеджменту.

Аналіз останніх досліджень і публікацій. Теоретичні засади побудови ансамблів (комітетів) моделей систематизовано в узагальнювальних працях П. Флеча (P. Flach) з машинного навчання [5] та А. В. Матвійчука зі штучного інтелекту в економіці [2]. Основними напрямками формування ансамблів є послідовне навчання моделей, за якого кожна наступна модель зосереджується на складних для попередників прикладах (бустінг), та паралельне об’єднання незалежно побудованих моделей голосуванням (беггінг, випадкові ліси). Ефективність комітету тим вища, чим точнішими є окремі моделі й чим слабше корельовані їхні похибки; саме забезпечення різноманітності моделей – за архітектурою, навчальними вибірками або зоною спеціалізації – є ключовою умовою приросту точності.

Питання формування комітетів моделей та обґрунтування умов їх доцільності досліджувалися в контексті задач класифікації на неоднорідних даних, де об’єднання кількох моделей забезпечує вищу точність порівняно з застосуванням єдиного класифікатора. Прикладне застосування ансамблевих технологій для оцінювання кредитних ризиків, зокрема авторський алгоритм побудови ансамблю на основі спеціалізації експертів із використанням нейромереж радіально-базисної архітектури, реалізовано у працях Г. І. Великоіваненко, С. С. Савіної, В. П. Беня та інших [1; 3]. Саме цей методичний апарат – теоретичне обґрунтування доцільності комітету, реалізація бустінгу та алгоритм спеціалізації експертів – є відправною точкою цього дослідження.

Останніми роками зростає інтерес до застосування методів машинного навчання й оптимізації в задачах моделювання складних систем і бізнес-процесів цифрового середовища. Зокрема, у праці В. А. Лахна та інших [7] розглянуто моделювання й оптимізацію дискретних еволюційних систем управління інформаційною безпекою у випадковому середовищі, у роботі О. В. Складенко та інших [8] застосовано моделі глибокого навчання для порівняння неструктурованої текстової інформації, а в дослідженні М. В. Чорненського та О. В. Складенко [4] запропоновано модель адаптивної трансформації бізнес-процесів в ERP-системах на основі подієво-орієнтованого підходу. Ці роботи демонструють ефективність поєднання методів машинного навчання й оптимізації для підтримки рішень у цифровій економіці. Проте більшість досліджень зосереджені на побудові єдиної моделі, тоді як питання поєднання кількох моделей в ансамбль із урахуванням неоднорідності проєктних даних досліджено значно менше, що й залишає простір для поданої роботи.

У сфері управління проєктами формалізації рішень традиційно приділяли увагу стандарти й методології проєктного менеджменту, узагальнені у PMBOK Guide (Project Management Institute) [6]. Емпіричні дослідження стану галузі систематично фіксують високу частку проєктів, що завершуються з перевищенням строків і бюджету або взагалі не досягають цілей, про що свідчать звіти The Standish Group [9], що підтверджує актуальність інструментів раннього виявлення проблемних проєктів. Водночас застосування саме ансамблевих моделей із динамічною спеціалізацією експертів для підтримки бінарних управлінських рішень у контрольних точках IT-проектів залишається малодослідженим, особливо для випадку неоднорідних і обмежених за обсягом даних. Це й визначає напрям та наукову новизну поданої роботи.

Мета статті. Метою статті є розроблення методичного підходу до формування обґрунтованих управлінських рішень у контрольних точках життєвого циклу IT-проектів на основі ансамблю моделей із урахуванням спеціалізації окремих моделей-експертів.

Методи дослідження. Методологічною основою дослідження є ансамблеві технології машинного навчання. Для теоретичного обґрунтування доцільності об’єднання моделей застосовано апарат теорії ймовірностей: для комітету з мажоритарним голосуванням аналітично виведено ймовірність правильного рішення та встановлено порогову умову доцільності комітету. Порівняльний аналіз способів інтеграції моделей (усе-

реднення, стекінг, бегтінг, бустінг, спеціалізація експертів) виконано за критеріями способу формування навчальних вибірок та узагальнення результатів.

Основним методом дослідження є авторський алгоритм побудови ансамблю на основі спеціалізації експертів із динамічною інтеграцією моделей: за осями якісних показників ІТ-проекту формуються однорідніші підвибірki, на кожній з яких навчається окрема модель-експерт радіально-базисної архітектури; остаточне рішення в контрольній точці ухвалює група релевантних експертів за правилом зупинки, а в разі паритету голосів – за допомогою зваженого голосування за коефіцієнтами компетентності. Для оцінювання переваг підходу використано аналіз попарних кореляцій похибок моделей і порівняння з бустінгом, а працездатність алгоритму перевірено на ілюстративному прикладі з умовними проектами.

Виклад основного матеріалу дослідження. Розглянемо комітет із трьох незалежних моделей-експертів, що класифікують рішення в контрольній точці проекту за схемою «go / no-go». Позначимо ймовірності правильної класифікації окремими експертами через p_1, p_2, p_3 , а ймовірність правильного рішення комітетом за простим (мажоритарним) голосуванням – через P_K . Правильне рішення ухвалюється у двох випадках: коли коректно класифікували всі три експерти або коли помилився рівно один із них. Деталізуючи другий випадок за тим, який саме експерт помилився, отримуємо чотири сприятливі ситуації з такими ймовірностями:

$$\begin{aligned}\theta_1 &= p_1 \cdot p_2 \cdot p_3; \theta_2 = (1 - p_1) \cdot p_2 \cdot p_3; \\ \theta_3 &= p_1 \cdot (1 - p_2) \cdot p_3; \theta_4 = p_1 \cdot p_2 \cdot (1 - p_3).\end{aligned}$$

Ймовірність правильного рішення комітетом визначається сумою ймовірностей цих чотирьох ситуацій:

$$P_K = p_1 \cdot p_2 \cdot p_3 + (1 - p_1) \cdot p_2 \cdot p_3 + p_1 \cdot (1 - p_2) \cdot p_3 + p_1 \cdot p_2 \cdot (1 - p_3). \quad (1)$$

Якщо припустити, що всі експерти мають однакову ймовірність правильної класифікації $p_1 = p_2 = p_3 = p$, вираз (1) спрощується до вигляду:

$$P_K = 3p^2 - 2p^3. \quad (2)$$

Графік залежності (2) наведено на рис. 1. За горизонтальною віссю відкладено точність окремого експерта p , за вертикальною – точність комітету P_K ; для порівняння побудовано бісектрису $P_K = p$.

Як видно з рис. 1, при $p < 0,5$ крива комітету проходить нижче бісектриси, тобто комітет дає гіршу точність, ніж окремий експерт. У точці $p = 0,5$ крива перетинає бісектрису, а далі проходить над нею – комітет демонструє вищу точність, ніж окремий експерт. Звідси випливає головна умова доцільності побудови комітету: об'єднання моделей підвищує обґрунтованість рішення лише тоді, коли точність кожного окремого експерта перевищує 0,5. Якщо ж хоча б один експерт має точність, нижчу за випадкове вгадування, його участь погіршує роботу комітету.

Поведінку функції P_K зручно проаналізувати за табличними значеннями. У табл. 1 наведено значення P_K для випадку, коли точність третього експерта зафіксовано на рівні $p_3 = 0,5$, а точності перших двох експертів змінюються в межах від 0 до 1.

Як видно з табл. 1, найбільших значень функція P_K набуває вздовж лінії $p_1 = p_2$. При низьких значеннях точності окремих експертів (нижче 0,5) комітет дає нижчу точність, ніж окремий експерт; натомість при точностях, вищих за 0,5, комітет забезпечує приріст обґрунтованості рішення.

Проілюструємо умову доцільності числовим прикладом. Нехай три моделі-експерти мають точності $p_1 = 0,70$; $p_2 = 0,65$; $p_3 = 0,80$. Підстановка у формулу (1) дає:

$$P_K = 0,364 + 0,156 + 0,196 + 0,091 = 0,807.$$

Точність комітету (0,807) перевищує точність найкращого з експертів (0,80), оскільки всі три моделі задовольняють умову $p > 0,5$. Замінімо тепер третього експерта слабким, із точністю $p_3 = 0,40$:

$$P_K = 0,182 + 0,078 + 0,098 + 0,273 = 0,631.$$




Рис. 1. Залежність імовірності правильного рішення комітетом P_K від точності окремого експерта p

Джерело: сформовано авторами

Таблиця 1

Значення функції P_k при $p_3 = 0,5$

$p_1 \backslash p_2$	0,00	0,20	0,40	0,60	0,80	1,00
0,00	0,00	0,10	0,20	0,30	0,40	0,50
0,20	0,10	0,20	0,30	0,40	0,50	0,60
0,40	0,20	0,30	0,40	0,50	0,60	0,70
0,60	0,30	0,40	0,50	0,60	0,70	0,80
0,80	0,40	0,50	0,60	0,70	0,80	0,90
1,00	0,50	0,60	0,70	0,80	0,90	1,00

Джерело: сформовано авторами

Тепер точність комітету (0,631) виявляється нижчою за точність найкращого експерта (0,70). Наведений контрприклад підтверджує теоретичний висновок: включення до комітету моделі з точністю, нижчою за 0,5, знижує загальну обґрунтованість рішення.

Розроблені на сьогодні алгоритми формування ансамблів різняться за способом інтеграції моделей, схемою формування навчальних вибірок та узагальнення результатів [2; 5]. За способом інтеграції виокремлюють дві категорії ансамблів: зі статичною та динамічною інтеграцією. При статичній інтеграції характеристики конкретного прикладу, для якого проводиться класифікація, не впливають на процедуру об'єднання результатів моделей. При динамічній інтеграції процедура узагальнення коригується для кожного окремого прикладу залежно від його ознак. Основні технології формування ансамблів наведено в табл. 2.

Технології усереднення, стекінгу та бегтінгу різняться способом формування навчальних вибірок і схемою узагальнення результатів (табл. 2), тоді як бустінг будує моделі послідовно, зосереджуючи кожну наступну на прикладах, які попередні класифікували некоректно.

Технології статичної категорії (усереднення, стекінг, бегтінг, бустінг) доцільно застосовувати для однорідних даних. Оскільки ІТ-проекти є суттєво неоднорідними, найбільш адекватною для поставленої задачі є динамічна інтеграція, за якої окремі підмножини даних описуються різними спеціалізованими моделями. Саме цей принцип покладено в основу авторського алгоритму, наведеного далі.

Для класифікації рішення в контрольній точці кожен проект (спостереження) описується множиною ознак, які поділяються на кількісні та якісні. До кількісних ознак належать, зокрема: планова та фактична тривалість етапу, освоєний обсяг бюджету, показники освоєного обсягу (індекси виконання строків і вартості), розмір беклогу, кількість відкритих дефектів, плінність складу команди. Кількісні ознаки формують вхідний вектор моделей-експертів.

Класичні рекомендації до побудови математичних моделей радять обмежувати кількість вхідних факторів (орієнтовно 7 ± 2) [2]; за потреби врахувати більше показників модель доцільно зробити ієрархічною, а узагальнення результатів здійснити засобами ансамблевих технологій.

Якісні показники використовуються інакше – вони визначають осі спеціалізації, за якими початковий масив поділяється на однорідніші підгрупи. Для кожного якісного показника з номером j визначається кількість його категорій N_j , за якими з масиву виділяються підгрупи спостережень. Приклади таких осей спеціалізації для ІТ-проектів наведено в табл. 3.

Таблиця 2

Основні технології формування ансамблів моделей

Категорія інтеграції	Алгоритм	Формування навчальної вибірки	Схема узагальнення результатів
Статична (однорідні дані)	Усереднення	Єдина вибірка для всіх моделей; навчання паралельне	Усереднення результатів по ансамблю
Статична	Стекінг	Єдина вибірка; обов'язкове використання різних типів моделей	Застосування метамоделі
Статична	Бегтінг	Кілька вибірок випадкового відбору з поверненням	Голосування (усереднення) по ансамблю
Статична	Бустінг	Для кожної наступної моделі – нова вибірка зі змінним розподілом	Зважене усереднення (голосування)
Динамічна (неоднорідні дані)	Спеціалізація експертів	Підвибірки за категоріями якісних показників	Зважене голосування релевантних експертів

Джерело: сформовано авторами

Таблиця 3

Приклади якісних показників як осей спеціалізації для ІТ-проектів

Якісний показник	Категорії (рівні)	Кількість рівнів N_j
Тип проекту	розробка; інтеграція; міграція	3
Методологія	Agile; Waterfall	2
Категорія замовника	внутрішній; зовнішній	2
Зрілість команди	сформована; нова	2

Джерело: сформовано авторами

Підгрупи, утворені за різними якісними показниками, перетинаються між собою: той самий проєкт одночасно потрапляє у підгрупу за типом, за методологією тощо. Такий логічно обумовлений поділ (на відміну від випадкового відбору в беггінгу) приводить до отримання однорідніших масивів даних, на кожному з яких будується окрема модель-експерт.

Розглянемо формалізацію алгоритму ансамблю на основі спеціалізації експертів. Нехай з масиву початкових даних виділено K якісних показників, які використовуватимуться при формуванні спеціалізації. Для кожного показника з номером j ($j = 1, \dots, K$) визначено кількість категорій N_j . За кожним рівнем i ($i = 1, \dots, N_j$) кожного показника j з масиву спостережень виділяється підгрупа, на якій будується відповідна модель-експерт L_{ji} (нейромережа радіально-базисної архітектури). Загальну схему алгоритму наведено на рис. 2.

За базову модель для кожного експерта доцільно обрати нейромережу радіально-базисної архітектури: у попередніх дослідженнях [1; 3] моделі такої архітектури демонстрували вищі показники точності на неоднорідних даних невеликого обсягу порівняно з багат шаровим перцептроном. Тип і конфігурація мережі для кожної підвибірки визначаються експериментально; за наявності кількох конфігурацій з близькою точністю перевагу надають моделі з меншою кількістю нейронів проміжного шару як простіший і стійкіший.

Для аналізу нового проєкту в контрольній точці за значеннями його якісних показників визначається

група релевантних експертів M , кожен з яких компетентний класифікувати саме такий проєкт: за цим проєктом наявні всі необхідні дані, а навчальні вибірки експертів сформовано за відповідними значеннями якісних показників. Отже, рішення щодо конкретного проєкту ухвалюється комітетом, утвореним з моделей $L_{ji} \in M$.

Для проведення розрахунків моделі впорядковуються за їх рейтингом (точністю на тестовій вибірці). Аналіз проєкту починається з моделей, які мають найвищий рейтинг. Коли більше половини задіяних експертів віднесли проєкт до одного класу («go» або «no-go»), процедура класифікації припиняється (правило зупинки). Якщо ж виникає ситуація, коли кількість задіяних експертів є парною і голоси розподіляються порівну, процедуру простого голосування замінюють на зважене.

У разі зваженого голосування для кожного експерта L_{ji} використовується відсоток правильно класифікованих на тестовій вибірці прикладів t_{ji} . На основі значень t_{ji} обчислюються коефіцієнти компетентності обраних експертів:

$$k_{ji} = \frac{t_{ji}}{\sum t_{ji}}, \quad (3)$$

де сумування у знаменнику здійснюється за всіма релевантними експертами $L_{ji} \in M$. Остаточне рішення визначається порівнянням сум коефіцієнтів компетентності експертів, що проголосували за «go», та експер-




Рис. 2. Схема алгоритму побудови ансамблю на основі спеціалізації експертів

Джерело: сформовано авторами

тів, що проголосували за «no-go»: обирається той клас, для якого сума ваг є більшою.

Оскільки підгрупи, утворені за різними якісними показниками, мають різний обсяг, при визначенні розміру навчальної вибірки доцільно орієнтуватися на найменший масив, аби зберегти можливість коректного порівняння експертів. Це породжує практичне обмеження підходу: за надто дрібних підгруп якість навчання окремих експертів знижується, тому кількість осей спеціалізації K та рівнів N_j слід узгоджувати з обсягом наявних даних.

Як зазначалося вище, однією з умов підвищення ефективності роботи комітету є незалежність похибок його окремих моделей. Для перевірки статистичної незалежності розподілу похибок можна скористатися спрощеним підходом – аналізом попарних кореляцій похибок усіх пар моделей комітету. Що нижчі коефіцієнти кореляції, то більший приріст точності здатний забезпечити комітет.

За алгоритмом бустінгу моделі ансамблю будуються послідовно: кожна наступна модель навчається переважно на прикладах, які попередні класифікували некоректно, унаслідок чого задача для кожного наступного класифікатора ускладнюється, а комітет здатний підсилити слабкі моделі [5]. Проте саме через послідовну «фільтрацію» прикладів похибки бустінг-моделей виявляються частково скорельованими, що обмежує приріст точності на неоднорідних даних.

Оскільки в запропонованому алгоритмі кожен експерт спеціалізується на логічно відокремленому сегменті даних, його похибки слабо корелюють з похибками інших експертів. Це зумовлює очікувану вищу ефективність порівняно з бустінгом, у якому послідовно побудовані моделі частково успадковують структуру помилок попередників, через що кореляція їхніх похибок є вищою. Таким чином, за умов неоднорідності в масиві початкових даних доцільно надавати перевагу комітету зі спеціалізацією експертів; бустінг же залишається раціональним вибором для однорідних даних.

Для ілюстрації методу розглянемо спершу типовий випадок. Нехай для проекту за значеннями його якісних показників відібрано трьох релевантних експертів, упорядкованих за рейтингом, і два з них першими віднесли проект до класу «no-go». Оскільки більше половини задіяних експертів дали однакову відповідь, спрацьовує правило зупинки, і комітет ухвалює рішення «no-go» – ініціювати управлінське втручання, не залучаючи решти експертів.

Складнішим є випадок паритету голосів. Нехай для нового проекту в контрольній точці відібрано групу з чотирьох релевантних експертів. За результатами послідовного голосування два експерти віднесли проект до класу «go», а два – до класу «no-go». Виникла ситуація паритету голосів при парній кількості експертів, тому застосовується зважене голосування.

Нехай точності відібраних експертів на тестових вибірках становлять: для «go» – $t = 0,68$ і $t = 0,60$; для «no-go» – $t = 0,72$ і $t = 0,55$. Сума ваг за клас «go» дорівнює $0,68 + 0,60 = 1,28$, а за клас «no-go» – $0,72 + 0,55 = 1,27$. Оскільки $1,28 > 1,27$, комітет ухвалює обґрунтоване рішення «go» – продовжувати проект за планом.

Слід наголосити на методичному характері результату: наведені числові значення є умовними й ілюструють механіку алгоритму, а не є емпіричною оцінкою ефективності для реальних ІТ-проектів. Апробація підходу на реальних або імітаційно згенерованих проектних даних становить окремий напрям подальших досліджень.

Висновки. У статті запропоновано методичний підхід до формування обґрунтованих управлінських рішень у контрольних точках ІТ-проектів на основі ансамблю моделей. Рішення формалізовано як бінарну задачу класифікації «go / no-go» – продовжувати проект за планом або ініціювати управлінське втручання.

Теоретично обґрунтовано головну умову доцільності побудови комітету: об'єднання моделей підвищує обґрунтованість рішення лише за умови, що точність кожного окремого експерта перевищує 0,5; включення слабкої моделі погіршує роботу комітету, що підтверджено як аналітично, так і числовим контрприкладом і табличними розрахунками функції P_K .

Формалізовано авторський алгоритм побудови ансамблю на основі спеціалізації експертів із динамічною інтеграцією моделей, упорядкуванням експертів за рейтингом, правилом зупинки та зваженням голосування за коефіцієнтами компетентності. Обґрунтовано, що завдяки спеціалізації на логічно відокремлених сегментах даних похибки експертів слабо корелюють, що забезпечує очікувану вищу ефективність порівняно з бустінгом на неоднорідних даних. Працездатність підходу продемонстровано на ілюстративному прикладі з умовними проектами.

Перевагою запропонованого алгоритму є придатність до застосування за умов неоднорідних і обмежених за обсягом даних, характерних для нових ІТ-продуктів, за якими ще не накопичено достатньої статистики для класичних технологій формування ансамблів. Водночас підхід має обмеження: він потребує наявності змістовних якісних показників для формування осей спеціалізації та достатнього обсягу спостережень у кожній підгрупі; за їх відсутності доцільніше застосовувати бустінг на однорідних даних.

Наукова новизна одержаних результатів полягає у перенесенні алгоритму побудови ансамблю на основі спеціалізації експертів на нову предметну область – підтримку бінарних управлінських рішень у контрольних точках ІТ-проектів – та в узгодженні цього алгоритму зі специфікою проектних даних через вибір якісних показників як осей спеціалізації. На відміну від відомих підходів, які здебільшого спираються на єдину прогностичну модель або на статичне об'єднання моделей, запропонований підхід забезпечує врахування якісного контексту проекту й зберігає прозорість внеску кожного експерта.

Перспективи подальших досліджень пов'язані з апробацією підходу на реальних і імітаційно згенерованих проектних даних, розширенням множини якісних осей спеціалізації, узагальненням бінарної задачі до багатокласової постановки (наприклад, класифікація стану проекту за схемою «успіх / ризик / провал») та інтеграцією алгоритму в інформаційну систему проектного офісу.

Бібліографічний список:

1. Великоіваненко Г. І., Савіна С. С., Колечко Д. В., Бень В. П. Побудова ансамблів моделей кредитного скорингу. *Нейро-нечіткі технології моделювання в економіці*. 2018. № 7. С. 34–77. DOI: <https://doi.org/10.33111/nfmte.2018.034>.
2. Матвійчук А. В. Штучний інтелект в економіці: нейронні мережі, нечітка логіка : монографія. Київ : КНЕУ, 2011. 439 с. DOI: <https://doi.org/10.33111/nfmte.2015.154>.
3. Савіна С. С., Бень В. П. Об'єднання моделей logit-регресій як комітету експертів для оцінки кредитоспроможності позичальника. *Нейро-нечіткі технології моделювання в економіці*. 2015. № 4. С. 154–188. DOI: <https://doi.org/10.33111/nfmte.2015.154>.
4. Чорненський М. В., Скляренко О. В. Модель адаптивної трансформації бізнес-процесів у ERP-системах на основі подієво-орієнтованого підходу. *Таврійський науковий вісник. Серія: Технічні науки*. 2026. № 3. С. 211–220. DOI: <https://doi.org/10.32782/tnv-tech.2026.3.22>.
5. Flach P. A. Machine Learning: The Art and Science of Algorithms that Make Sense of Data. Cambridge : Cambridge University Press, 2012. 396 p. DOI: <https://doi.org/10.1017/CBO9780511973000>.
6. A Guide to the Project Management Body of Knowledge (PMBOK Guide). 7th ed. Newtown Square : Project Management Institute, 2021. 370 p.
7. Lakhno V. A., Kasatkin D. Y., Skliarenko O. V., Kolodinska Y. O. Modeling and Optimization of Discrete Evolutionary Systems of Information Security Management in a Random Environment. *Machine Learning and Autonomous Systems. Smart Innovation, Systems and Technologies*. Singapore : Springer, 2022. Vol. 269. P. 9–22. DOI: https://doi.org/10.1007/978-981-16-7996-4_2.
8. Skliarenko O., Pashko A., Lytvynenko L., Kolodinska Y. Deep learning models for solving the problem of comparing unstructured textual information. *Bulletin of Taras Shevchenko National University of Kyiv. Physics and Mathematics*. 2025. Vol. 80, No. 1. P. 157–163. DOI: <https://doi.org/10.17721/1812-5409.2025/1.21>.
9. The Standish Group. CHAOS Report. Boston : The Standish Group International, 2020.

References:

1. Velykoivanenko, H. I., Savina, S. S., Kolehko, D. V., & Ben', V. P. (2018). Pobudova ansambliv modelei kredytnoho skorynhu [Building the ensembles of credit scoring models]. *Nejro-nechitki tekhnolohii modeliuвання v ekonomitsi*, 7, 34–77. DOI: <https://doi.org/10.33111/nfmte.2018.034> [in Ukrainian].
2. Matviichuk, A. V. (2011). Shtuchnyi intelekt v ekonomitsi: nejronni merezhi, nechitka lohika [Artificial intelligence in economics: neural networks, fuzzy logic]. Kyiv: KNEU [in Ukrainian].
3. Savina, S. S., & Ben', V. P. (2015). Objednannia modelej logit-rehresij yak komitetu ekspertiv dlia otsinky kredytspromozhnosti pozychalnika [Combining logit-regression models as a committee of experts for assessing a borrower's creditworthiness]. *Nejro-nechitki tekhnolohii modeliuвання v ekonomitsi*, 4, 154–188. DOI: <https://doi.org/10.33111/nfmte.2015.154> [in Ukrainian].
4. Chornenkyi, M. V., & Skliarenko, O. V. (2026). Model adaptivnoi transformatsii biznes-protsesiv u ERP-systemakh na osnovi podiievo-orientovanoho pidkhodu [A model of adaptive transformation of business processes in ERP systems based on an event-driven approach]. *Tavriyskyi naukovyi visnyk. Seriya: Tekhnichni nauky*, (3), 211–220. DOI: <https://doi.org/10.32782/tnv-tech.2026.3.22> [in Ukrainian].
5. Flach, P. A. (2012). Machine Learning: The Art and Science of Algorithms that Make Sense of Data. Cambridge: Cambridge University Press. <https://doi.org/10.1017/CBO9780511973000>
6. Project Management Institute. (2021). A Guide to the Project Management Body of Knowledge (PMBOK Guide) (7th ed.). Newtown Square: PMI.
7. Lakhno, V. A., Kasatkin, D. Y., Skliarenko, O. V., & Kolodinska, Y. O. (2022). Modeling and Optimization of Discrete Evolutionary Systems of Information Security Management in a Random Environment. In *Machine Learning and Autonomous Systems. Smart Innovation, Systems and Technologies* (Vol. 269, pp. 9–22). Singapore: Springer. DOI: https://doi.org/10.1007/978-981-16-7996-4_2
8. Skliarenko, O., Pashko, A., Lytvynenko, L., & Kolodinska, Y. (2025). Deep learning models for solving the problem of comparing unstructured textual information. *Bulletin of Taras Shevchenko National University of Kyiv. Physics and Mathematics*, 80 (1), 157–163. DOI: <https://doi.org/10.17721/1812-5409.2025/1.21>
9. The Standish Group. (2020). CHAOS Report. Boston: The Standish Group International.

Дата надходження статті: 19.08.2026

Дата прийняття статті до публікації: 21.09.2026

Дата публікації статті: 30.09.2026