

ПРОГНОЗНА АНАЛІТИКА НА ОСНОВІ ШТУЧНОГО ІНТЕЛЕКТУ ЯК ІНСТРУМЕНТ ПЕРЕДБАЧЕННЯ КРІ ТА ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ СТРАТЕГІЧНОГО ПЛАНУВАННЯ

AI-BASED PREDICTIVE ANALYTICS AS A TOOL FOR FORECASTING KPIs AND ENHANCING STRATEGIC PLANNING EFFECTIVENESS

У статті розглянуто використання прогнозової аналітики на основі штучного інтелекту для передбачення КРІ та вдосконалення стратегічного планування підприємств. Інтеграція ERP/CRM-даних, IoT-телеметрії та зовнішніх джерел забезпечує виявлення складних нелінійних залежностей і підвищує точність прогнозів. Запропоновано багаторівневу класифікацію КРІ та об'єднано роль Feature Store і MLOps-конвеєрів у подоланні проблем підготовки даних. Використання сучасних алгоритмів машинного навчання та інструментів пояснювального ШІ (SHAP, LIME) дозволяє знизити похибку прогнозів на 20–50 %, скоротити витрати на запаси й дефіцити, а також забезпечити прозорість рішень для керівництва. Автоматизація CI/CD пришвидшує отримання інсайтів і гарантує регулярне перенавчання моделей. Дослідження є цінним для керівників, менеджерів зі стратегічного планування, дата-сайєнтістів і науковців у сфері бізнес-аналітики.

Ключові слова: прогнозна аналітика, штучний інтелект, стратегічне планування, ключові показники ефективності, машинне навчання.

The article explores the application of artificial intelligence (AI)-based predictive analytics for forecasting key performance indicators (KPIs) and improving strategic enterprise planning in the context of increasing business turbulence. Particular emphasis is placed on the integration of internal corporate ERP/CRM data, IoT device telemetry, and external sources-including macro-economic indicators, weather data, and social trends-which enables the identification of complex nonlinear dependencies and supports timely managerial decision-making. The scientific novelty lies in the proposed multi-level KPI classification (descriptive, diagnostic, predictive, and prescriptive), which establishes a coherent framework for transitioning from retrospective analysis to proactive management. In addition, the study substantiates the role of centralized Feature Stores and MLOps pipelines as key instruments for overcoming data-preparation bottlenecks, thereby ensuring model reproducibility, accelerated scaling of use cases, and a stable flow of validated features for analytical algorithms. The practical significance of the study lies in the analysis of the modern technological stack of predictive solutions: algorithmic methods, cloud-based ML services, CI/CD pipelines, and explainable AI tools that enhance forecast transparency and strengthen leadership trust. It has been demonstrated that the implementation of such solutions reduces the average forecast error by 20–50%, lowers inventory costs, and prevents product shortages, while labor efficiency increases by 10–15%. CI/CD pipeline automation shortens the time to actionable insights from several weeks to hours, and the use of explainable AI ensures compliance with the EU AI Act and GDPR, while simultaneously increasing top management's readiness to integrate models into planning processes. The findings make the article valuable for senior executives, strategic planning managers, data specialists, and business analytics researchers, as they illustrate how the comprehensive integration of heterogeneous data, algorithmic solutions, and management infrastructure transforms predictive analytics into a strategic tool for enhancing enterprise competitiveness.

Key words: predictive analytics, artificial intelligence, strategic planning, key performance indicators, machine learning.

УДК 004.89:005.8:658

DOI: <https://doi.org/10.32782/dees.19-65>

Тетер Н.П.

фінансовий директор,
ТОВ «Дніпропетровський завод
бурового обладнання»;

власник,
ТОВ «ТД ДЗБО»
Алмати, Казахстан

Лера О.В.

к.е.н., доцент, професор кафедри обліку
і оподаткування,
Полтавський державний аграрний
університет

Teter Nataliia

Dnepropetrovsk Drilling Equipment
Plant LLC;
TD DZBO LLP, Alma Ata, Kazakhstan

Leha Olha

Poltava State Agrarian University

Постановка проблеми. За останні п'ятнадцять років бізнес-середовище стало значно більш волатильним: попит на продукцію коливається під впливом соціальних мереж та кліматичних аномалій, а глобальні ланцюги постачання реагують на геополітичні зрушення швидше, ніж оновлюються квартальні плани. У таких умовах класичні методи прогнозування – від ковзних середніх до експоненційного згладжування – систематично втрачають точність, оскільки ґрунтуються виключно на лінійних залежностях і коротких часових рядах продажів.

Прогнозна аналітика долає ці обмеження, поєднуючи статистичні методи з машинним навчанням: алгоритми автоматично виявляють нелінійні закономірності у багаторічних даних, інтегрують зовнішні джерела – погоду, валютні курси, суспільні тренди – та оновлюють модель у режимі

реального часу. За даними McKinsey, застосування таких AI-движків у ланцюгах постачання знижує середню похибку прогнозів на 20–50 %, що безпосередньо скорочує дефіцит товарів і витрати на складування, тоді як оптимізація робочої сили зменшує витрати на оплату праці на 10–15 % [1]. Масштабування вже відбувається: у глобальному опитуванні, проведеному у березні 2025 року, 78 % організацій повідомили про використання ШІ хоча б в одній бізнес-функції, і ця частка зростає на кілька відсоткових пунктів щокварталу [2; 3]. Це підтверджує, що прогнозна аналітика переходить з експериментальної площини у стратегічну практику і стає ключовим інструментом ухвалення рішень, спрямованих не на вчорашній, а на завтрашній день.

Аналіз останніх досліджень і публікацій. Сучасні дослідження у сфері прогнозової аналітики

на основі штучного інтелекту зосереджені на розробці алгоритмів і технологічних рішень, здатних підвищити точність передбачення та забезпечити їхню практичну інтерпретацію для бізнесу й промисловості. В. Lim та співавтори запропонували архітектуру Temporal Fusion Transformer, яка поєднує багатогоризонтне прогнозування з можливістю інтерпретації часових залежностей [4], тоді як Н. Zhou з колегами розробили модель Informer, орієнтовану на ефективне довгострокове прогнозування часових рядів із суттєвим зниженням обчислювальних витрат [5]. У свою чергу, S. Makridakis з співавторами у межах M4 Competition показали, що комбіновані методи дозволяють досягати кращих результатів порівняно з класичними статистичними підходами [6], а J. Huber і Н. Stuckenschmidt довели переваги машинного навчання у прогнозуванні роздрібного попиту на особливі календарні дні [7]. J. Feizabadi продемонстрував, що застосування гібридних ML-моделей (ARIMAX і нейронні мережі) знижує спотворення попиту та підвищує ефективність ланцюгів постачання [8], а Р.-D. Arsenault з колегами узагальнили підходи пояснюваного ШІ (XAI) у прогнозуванні фінансових часових рядів, що дозволяє підвищувати довіру до моделей у високоризикових галузях [9]. Питання організації даних розкрито у працях L. Orr та співавторів, які акцентували на ролі feature store систем у нових embedding-орієнтованих конвеєрах [10], тоді як R. Liu та колеги запропонували оптимізацію для point-in-time join, що дозволяє прискорювати роботу дата-пайплайнів у три рази [11]. З іншого боку, S. S. W. Fatima та A. Rahimi систематизували методи прогнозування у промисловості, підкресливши переваги машинного навчання й гібридних моделей над традиційними ARIMA та ES [12], тоді як J. Cui та співавтори показали результативність інтегрованого підходу XGBoost-RF + CNN-GRU для короткострокового прогнозування навантаження в енергетиці, досягнувши зниження RMSE та MAPE порівняно з класичними методами [13].

Сучасний науковий дискурс фіксує перехід від класичних статистичних методів до гібридних і глибинних моделей, інтегрованих з інфраструктурними рішеннями на кшталт Feature Store та MLOps, що підвищує точність прогнозів і забезпечує їхню практичну цінність для стратегічного планування. Водночас залишаються виклики, пов'язані з якістю даних, масштабованістю моделей, прозорістю результатів і відповідністю регуляторним вимогам. Недостатньо розробленими є й підходи до оцінки економічного ефекту від прогнозової аналітики. Подальший акцент робиться на точності прогнозування KPI та стратегічній гнучкості компаній через інтеграцію різномірних даних, упровадження Data Governance, Feature Store і MLOps, а також застосування сучасних алгоритмів машинного навчання й інструментів Explainable AI.

Постановка завдання. Метою дослідження є дослідження є демонстрація потенціалу прогнозової аналітики на основі штучного інтелекту для посилення стратегічного планування, мінімізації ризиків і подолання обмежень, пов'язаних із якістю даних, масштабованістю моделей та їх прозорістю.

Виклад основного матеріалу дослідження. Дослідження прогнозової аналітики на основі штучного інтелекту у сфері передбачення KPI та вдосконалення стратегічного планування спирається на широкий спектр сучасних наукових і прикладних джерел. Базу сформували 18 напрацювань, серед яких наукові статті, галузеві огляди, практичні кейси та регуляторні документи. Вони відображають як теоретичні засади, так і практику впровадження цифрових рішень у корпоративному управлінні. У роботах J. Amar [1] та A. Singla з колегами [2] показано, що використання AI-движків у ланцюгах постачання дозволяє зменшити похибку прогнозування на 20–50 %, що прямо впливає на скорочення витрат і дефіцитів. Дослідження A. Singla [3] підкреслює стрімке зростання кількості активних IoT-пристроїв та їхній вплив на чутливість моделей, тоді як у звітах Gartner [14] та IBM [15] висвітлюються проблеми управління якістю даних. Особливу увагу «вузьким місцям» у процесі підготовки ознак приділили А. Моццілло та співавторів [16], а також U. Bashir [17], який розкриває розвиток ринку MLOps. Еволюцію корпоративних KPI простежено у матеріалах BCG [18], MIT Sloan Review [19] та кейс Prescience Decision Solutions [20]. Масштаби впровадження ШІ та питання його пояснюваності висвітлено у звітах McKinsey [21], FP&A Trends [22], D. Balroop [23], JPMorgan [24], De Freitas [25], а також у нормативних документах – Регламенті ЄС про ШІ [26], аналітиці Legal IO [27] та Insights Global [28]. Аналіз матеріалів засвідчує, що основою будь-якої моделі прогнозування на базі ШІ є багатокomпонентний масив даних. Чим різноманітніші джерела, тим вищою є здатність моделі виявляти закономірності та коливання KPI. На одному боці – корпоративні ERP- і CRM-системи, на іншому – мільярди сигналів від IoT-пристроїв, кількість яких за два роки зросла з 16,6 до 18,8 млрд. Оскільки понад половина підприємств планують збільшити бюджети на сенсори, саме машиногенерований трафік стає найдинамічнішим зовнішнім джерелом даних для бізнес-аналітики (рис. 1).

Ці дані доповнюються відкритими урядовими та ринковими наборами – макроекономічними індикаторами, метеорологічними звітами, суспільними трендами, – які дозволяють моделям виявляти міжгалузеві залежності й випереджати класичні «коробкові» прогнози, що ґрунтуються виключно на внутрішній історії продажів.

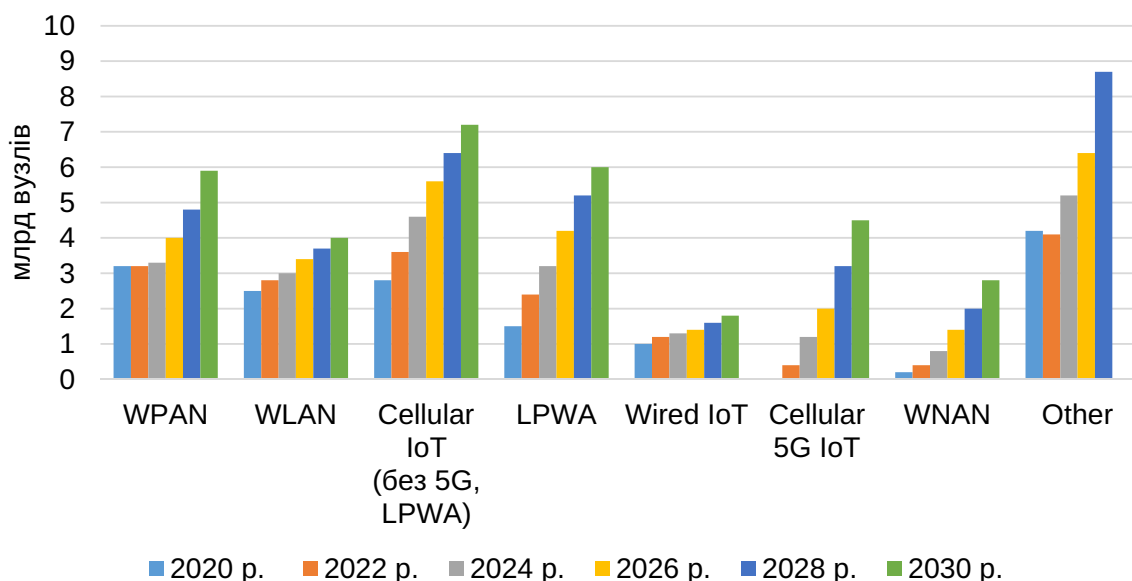


Рис. 1. Кількість активних IoT-з'єднань у світі за типами підключення

Джерело: побудовано на підставі [3]

Водночас із розширенням джерел підвищуються й вимоги до управління даними: без формалізованої системи Data Governance обсяг не перетворюється на якість. За розрахунками аналітиків Gartner, низька якість даних обходиться середньому підприємству щонайменше у 12,9 млн дол. США щорічно через помилки у плануванні та зайві операційні цикли [2]. Функції Data Governance – каталогізація активів, правила доступу, політики якості та автоматизовані перевірки походження даних – стають другим, не менш важливим контуром для методів машинного навчання, забезпечуючи сталість метрик і відтворюваність результатів моделей.

Однак навіть за наявності розвиненої системи управління даними вони не готові до тренування моделей, доки не пройдуть через інженерний конвеєр ETL/ELT: очищення, нормалізацію, усунення дублювань і семантичне збагачення. Дослідження [16] свідчить, що ці операції споживають до 80 % робочого часу дата-спеціаліста, перетворюючи інженерію даних на «вузьке місце» усієї аналітичної системи. Сучасні практики вирішують цю проблему за допомогою Feature Store – централізованого шару, у якому ознаки створюються один раз і використовуються усіма моделями. Це скорочує дублювання коду та спрощує онлайн-інференс. У результаті прогностичні алгоритми отримують безперервний потік перевірених даних, а підприємство може швидко масштабувати успішні кейси без витрат місяців на ручну підготовку кожного набору.

Різноманітність корпоративних і зовнішніх даних, описаних вище, дозволяє сформувати повний спектр зрілості показників, де кожен рівень

відповідає на різні запитання щодо «здоров'я» бізнесу. На базовому рівні знаходяться описові KPI, що фіксують факти минулого; наступним є діагностичні KPI, які пояснюють причини змін. Далі йдуть прогностичні показники, які з використанням методів машинного навчання ідентифікують провідні закономірності; і, нарешті, прескриптивні KPI, що автоматично рекомендують оптимальні дії. Ця чотирирівнева класифікація давно використовується в аналітиці даних і дедалі активніше впроваджується у корпоративні системи метрик, оскільки забезпечує плавний перехід від ретроспективних «спідометрів» до управлінського «GPS-навігатора».

Переваги руху вгору цією ієрархією вимірюються не лише точністю прогнозів, а й швидкістю стратегічних поворотів. Дослідження [3] показало, що лише 34 % компаній уже створюють нові KPI із застосуванням ШІ, проте 90 % з них повідомили про покращення якості метрик і швидкості ухвалення рішень. Компанії, що впровадили ШІ, демонструють суттєво вищу операційну ефективність, точність вимірювань, часову чутливість і фінансові результати порівняно з тими, що не використовують ці технології, як показано на рис. 2. Ці дані підтверджують, що інтеграція ШІ істотно посилює ключові бізнес-показники та приносить відчутні переваги.

Практика свідчить, що трансформація традиційних метрик у «розумні» KPI здатна докорінно змінювати корпоративну тактику. Так, онлайн-рейтер Wayfair замінив показник втрачених продажів на індекс утримання на рівні категорій: аналітика ШІ виявила, що до 60 % втрат на рівні

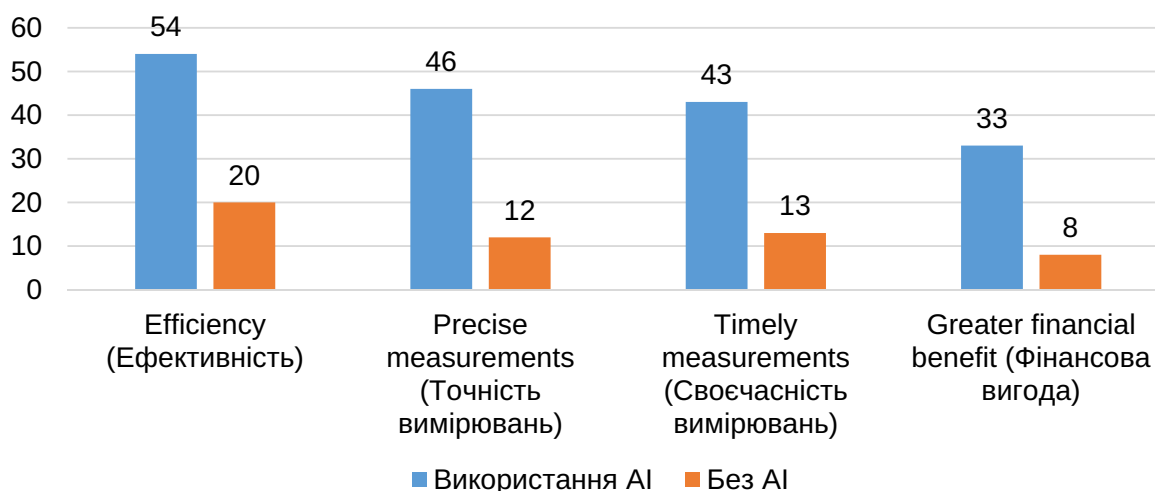


Рис. 2. Вплив впровадження штучного інтелекту на операційну ефективність, точність вимірювань, часову чутливість і фінансові результати

Джерело: побудовано на підставі [3]

окремих товарів компенсувалися покупками альтернативних позицій у тій самій категорії; нова метрика дозволила скорегувати рекомендації та підвищити прибутковість асортименту [3].

У промисловості перетворення класичного показника OEE у прогнозний формат дало подібний ефект: впровадження обслуговування на основі ШІ дозволяє зменшити незаплановані простої обладнання та скоротити витрати на ремонти. Такі трансформації ілюструють, що описові KPI – за умови високої якості даних і налагоджених конвеєрів підготовки ознак – можуть еволюціонувати в показники, які не лише описують процеси, а й активно ними керують, тим самим підсилюючи стратегічну гнучкість організації.

«Розумні» KPI, визначені на попередньому етапі, висувають до аналітичної системи дві ключові вимоги: швидко трансформувати гетерогенні потоки даних у надійні прогнози та залишатися зрозумілими для менеджерів. Відповідно, технологічний стек прогнозних рішень охоплює три взаємодоповнювальні рівні: алгоритмічні методи, хмарну інфраструктуру з практиками MLOps та інструменти explainable AI, які роблять моделі прозорими для керівництва.

На алгоритмічному рівні застосовуються кілька спеціалізованих підходів, оптимальних для різних класів завдань. Градієнтний бустинг (переважно XGBoost або LightGBM) забезпечує високу точність під час прогнозування різнорідних товарних рядів: заміна ковзних середніх ансамблем XGBoost знижує RMSE і дає змогу інтерпретувати значущість цінкових та промоційних факторів у кожній категорії. Для довгих сезонних рядів, де критичною є стійкість до викидів, ефективним зарекомендував себе Prophet: у проєкті прогнозування річного

GMV перехід від моделі в Excel до Prophet скоротив час побудови сценаріїв із двох тижнів до двох годин, забезпечивши кращі показники MAPE у всіх 14 бізнес-вертикалях [20]. У випадках, коли необхідно моделювати нелінійні залежності між зовнішніми параметрами та цільовою метрикою, доцільним стає застосування рекурентних нейронних мереж. Зрештою, для десятків тисяч паралельних рядів усе частіше впроваджуються трансформери та їхні комбінації з MLP-архітектурами: вони вирізняються швидкістю навчання та зручністю масштабування, хоча за рівнем інтерпретованості поки поступаються методам бустингу.

Для виходу моделей за межі середовища ноутбуків організації переносять обчислення у хмарні ML-сервіси та будують конвеєри MLOps, які включають автоматизоване тестування, розгортання та моніторинг. Ринок MLOps у 2024 р. оцінювався у 79 млрд дол. США, а кількість пошукових запитів зросла на 1620 % за останні п'ять років, що свідчить про перехід дисципліни від експериментальної фази до стандартної організаційної практики [17]. Інтеграція моделей у CI/CD-конвеєр зводить ручні операції до мінімуму: новий код і дані автоматично тестуються, розгортаються у тестовому середовищі та, за умови збереження необхідної точності, переводять прогнозний потік у продуктивний режим. Такий процес скорочує час отримання інсайтів із тижнів до годин і, що особливо важливо, підтримує регулярне перенавчання, потрібне для KPI-провісників.

Проте вища точність не гарантує автоматично довіри. Дослідження [21] показало, що 40 % керівників вважають непрозорість моделей головним ризиком ШІ, однак лише 17 % запровадили механізми для його пом'якшення [21]. Практика

доводить, що методи пояснення, зокрема SHAP і LIME, долають цю прогалину: вони обчислюють граничний внесок кожної ознаки у конкретний прогноз, дозволяючи, наприклад, фінансовому директору побачити, що відхилення прогнозу EBITDA спричинене зростанням логістичних витрат, а не коливанням попиту. Такий «рентгенівський» погляд підвищує готовність топ-менеджменту інтегрувати оцінки ШІ у бюджетні та інвестиційні моделі, водночас забезпечуючи відповідність вимогам Регламенту ЄС про ШІ щодо пояснюваності.

Отриманий технологічний стек охоплює повний життєвий цикл впровадження — від формулювання бізнес-цілей і пріоритизації KPI до контролю якості моделей. На етапі побудови дата-сайєнтисти обирають архітектуру, виконують інженерію ознак і налаштовують гіперпараметри з автоматизованим пошуком, документуючи процес у репозиторіях. Далі модель інтегрується у мікросервіс і через конвеєр CI/CD розгортається у продуктивному середовищі, під'єднуючись до операційних систем — від планувальника закупівель до аналітичних панелей. Завершальний, але постійний етап — моніторинг дрейфу даних і точності у режимі реального часу з автоматичним перенавчанням та впровадженням оновлень без зупинки бізнес-процесів. Така наскрізна схема перетворює прогнозну аналітику з пілотного проєкту на стабільний інструмент щоденної підтримки стратегічного планування.

Перехід від ретроспективного контролю до проактивного управління, описаний вище, знаходить відображення у трансформації бюджетних

механізмів. Моделі ковзного прогнозування, що базуються на прогнозній аналітиці, вже застосовуються у 49 % фінансових департаментів, що на два відсоткових пункти більше, ніж торік [22].

Той самий технологічний стек підсилює і корпоративну систему управління ризиками: 64 % банків і страхових компаній уже використовують моделі NLP для моніторингу ринкових і кредитних факторів, а 78 % фінансових установ застосовують AI-сценарії у стрес-тестах, що дозволяє моделювати макрошоки швидше й ґрунтовніше, ніж класичні методи VAR. Таким чином, прогнозна аналітика стає частиною регулярної процедури ICAAP, скорочуючи час реагування з днів до годин [23].

На рівні інвестиційного ухвалення рішень прогнози ШІ переводять CAPEX і M&A-рішення з площини експертної оцінки у керований даними процес. За даними [24], лише п'ять найбільших хмарних гігантів інвестують понад 1 трлн дол. США у CAPEX у період 2024–2027 рр.; така концентрація капіталу підвищує цінність моделей, які ранжують проєкти за NPV у квартално оновлюваному режимі, що показано на рис. 3.

Попри впроваджені процедури Data Governance, якість і повнота первинних даних залишаються ключовим «вузьким місцем». Додатковий ризик становлять «тіньові дані»: за даними IBM, кожен третій витік інформації пов'язаний із неінвентаризованими наборами, а середня вартість інциденту сягає 4,88 млн дол. США [15]. Неповні чи спотворені вибірки зумовлюють дрейф KPI-прогнозів і підсилюють помилки у прийнятті управлінських рішень.

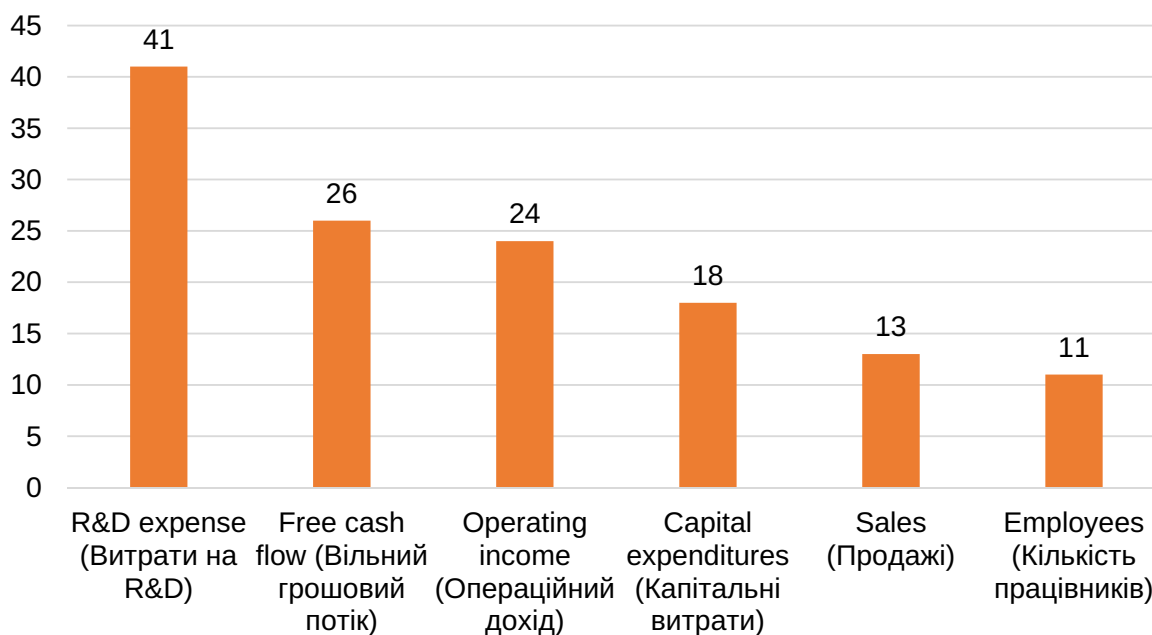


Рис. 3. Економічна концентрація в індексі S&P 500, %

Джерело: побудовано на підставі [24]

Брак прозорості моделей посилює людський фактор: більшість ініціатив із впровадження ШІ зазнають невдачі через опір персоналу та відсутність підтримки з боку керівництва. Попри те, що 79 % стратегів визнають алгоритми критично важливими, лише 20 % застосовують їх у щоденній роботі [25]. За відсутності пояснюваності моделі залишаються «чорними скриньками», що стримує їхнє поширення навіть за доведеної точності. Регуляторні вимоги підвищують ставки: Регламент ЄС про ШІ класифікує корпоративні системи як високоризикові й вимагає пояснюваності, надійності та моніторингу [26]. Водночас дотримання GDPR стає фінансово відчутним: лише у 2024 році штрафи сягнули 1,2 млрд євро [27], а їхнє порушення веде до санкцій і репутаційних втрат.

Стійкість AI-ініціатив також обмежується технічним і фінансовим боргом: компанії змушені витратити ресурси на реархітектуризацію рішень. У нафтогазовій сфері одна година простою коштує близько 500 тис. дол. США, і помилки у прогнозних конвеєрах належать до головних причин таких втрат [28]. За відсутності FinOps-стратегії, резервування потужностей і автоматизованого оновлення моделей довгостроковий ефект прогнозної аналітики опиняється під загрозою.

У підсумку, успішна інтеграція прогнозної аналітики на основі ШІ у стратегічне планування вимагає системного підходу до забезпечення повноти й якості даних, включно з «тіньовими» наборами, підвищення прозорості моделей, а також залучення керівництва і працівників. Це стає частиною життєвого циклу MLOps поряд із виконанням нових регуляторних вимог [26], реалізацією FinOps-стратегій, резервуванням потужностей та автоматизованими процесами оновлення моделей. Лише такий комплексний підхід дасть змогу організації прогнозувати ключові показники з високою точністю та зберігати довгострокову цінність AI-ініціатив, мінімізуючи ризики фінансових санкцій, втрат і падіння довіри.

Висновки. Прогнозна аналітика на основі штучного інтелекту довела ефективність у передбаченні ключових показників ефективності та підтримці стратегічного планування в умовах зростаючої ринкової волатильності. Інтеграція ERP/CRM-даних, IoT-телеметрії та зовнішніх джерел (макроекономічних індикаторів, погодних даних і соціальних трендів) дозволяє виявляти складні нелінійні залежності та своєчасно реагувати на зміни попиту й перебої у постачанні. Застосування сучасних алгоритмів машинного навчання – градієнтного бустингу, рекурентних мереж і трансформерів – істотно зменшує похибку прогнозів, сприяючи скороченню витрат на запаси, уникненню дефіцитів і підвищенню ефективності праці.

Ключовою умовою впровадження є якісні дані та формалізоване управління ними, що

у поєднанні з Feature Store і MLOps забезпечує відтворюваність моделей і масштабування успішних кейсів. Технологічний стек, який включає хмарні ML-сервіси, CI/CD-конвеєри та інструменти пояснюваного ШІ, скорочує час до отримання інсайтів і підвищує довіру керівництва, водночас відповідаючи вимогам Регламенту ЄС про ШІ та GDPR. Комплексний підхід до поєднання гетерогенних даних, сучасних алгоритмів і управлінської інфраструктури дозволяє підвищити точність прогнозів, зміцнити стратегічну гнучкість і зберегти довгострокову цінність AI-ініціатив.

БІБЛІОГРАФІЧНИЙ СПИСОК:

1. Amar J. AI-driven Operations Forecasting in data-light Environments. *McKinsey & Company*. 15.02.2022. URL: <https://www.mckinsey.com/capabilities/operations/our-insights/ai-driven-operations-forecasting-in-data-light-environments> (дата звернення: 01.09.2025).
2. Singla A., Sukharevsky A., Yee L., Chui M., Hall B. The state of AI: How organizations are rewiring to capture value. *McKinsey & Company*. URL: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai> (дата звернення: 01.09.2025).
3. Sinha S. State of IoT 2024: Number of connected IoT devices growing 13% to 18.8 billion globally. *IoT Analytics*. URL: <https://iot-analytics.com/number-connected-iot-devices/> (дата звернення: 08.09.2025).
4. Lim B., Arik S. Ö., Loeff N., Pfister T. Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*. 2021. Vol. 37. Issue 4. P. 1748–1764. DOI: <https://doi.org/10.1016/j.ijforecast.2021.03.012>.
5. Zhou H., Zhang S., Peng J., Zhang S., Li J., Xiong H., Zhang W. Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. *ArXiv preprint*. 2020. arXiv:2012.07436. URL: <https://arxiv.org/abs/2012.07436> (дата звернення: 01.09.2025).
6. Makridakis S., Spiliotis E., Assimakopoulos V. The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*. 2020. Vol. 36. Issue 1. P. 54–74. DOI: <https://doi.org/10.1016/j.ijforecast.2019.04.014>.
7. Huber J., Stuckenschmidt H. Daily retail demand forecasting using machine learning with emphasis on calendric special days. *International Journal of Forecasting*. 2020. Vol. 36. Issue 4. P. 1420–1438. DOI: <https://doi.org/10.1016/j.ijforecast.2020.02.005>.
8. Feizabadi J. Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications*. 2020. Vol. 25, Issue 2. P. 119–142. DOI: <https://doi.org/10.1080/13675567.2020.1803246>.
9. Arsenault P.-D., Wang S., Patenaude J.-M. A Survey of Explainable Artificial Intelligence (XAI) in Financial Time Series Forecasting. *ACM Computing Surveys*. 2025. Vol. 57. № 10. Article 265. 37 p. DOI: <https://doi.org/10.1145/3729531>.
10. Orr L., Sanyal A., Ling X., Goel K., Leszczynski M. Managing ML Pipelines: Feature Stores and the Coming Wave of Embedding Ecosystems. *arXiv*

preprint. 2021. arXiv:2108.05053. URL: <https://arxiv.org/pdf/2108.05053> (дата звернення: 01.09.2025).

11. Liu R., Park K., Psallidas F., Zhu X., Mo J., Sen R., Interlandi M., Karanasos K., Tian Y., Camacho-Rodríguez J. Optimizing Data Pipelines for Machine Learning in Feature Stores. *Proceedings of the VLDB Endowment*. 2023. Vol. 16. № 13. P. 4230–4239. DOI: <https://doi.org/10.14778/3625054.3625060>.

12. Fatima S. S. W., Rahimi A. A Review of Time-Series Forecasting Algorithms for Industrial Manufacturing Systems. *Machines*. 2024. Vol. 12. № 6. Article 380. DOI: <https://doi.org/10.3390/machines12060380>.

13. Cui J., Kuang W., Geng K., Bi A., Bi F., Zheng X., Lin C. Advanced Short-Term Load Forecasting with XGBoost-RF Feature Selection and CNN-GRU. *Processes*. 2024. Vol. 12. № 11. Article 2466. DOI: <https://doi.org/10.3390/pr12112466>.

14. Gartner. Data quality: Why it matters and how to achieve it. *Gartner*. 2025. URL: <https://www.gartner.com/en/data-analytics/topics/data-quality> (дата звернення: 01.09.2025).

15. IBM. Cost of a data breach report 2024. *IBM*. 2024. URL: <https://www.ibm.com/reports/data-breach> (дата звернення: 01.09.2025).

16. Mozzillo A., Zecchini L., Gagliardelli L., Aslam A., Bergamaschi S., Simonini G. Evaluation of Dataframe Libraries for Data Preparation on a Single Machine. *Cornell University*. 2023. DOI: <https://doi.org/10.48550/arxiv.2312.11122>.

17. Bashir U. MLOps in 2024: 1620% Surge in Search Interest and a US\$79bn Market on the Horizon. *Blainy*. 16.12.2024. URL: <https://blainy.com/data-and-insights/ml-ops-adoption/> (дата звернення: 01.09.2025).

18. Schrage M., Kiron D., Candelon F., Khodabandeh S., Chu M. In collaboration with The Future of Strategic Measurement: Enhancing KPIs With AI. *BCG*. 2024. URL: <https://web-assets.bcg.com/54/43/28953bcd41d99e7dd354f5517e13/the-future-of-strategic-measurement-enhancing-kpis-with-ai.pdf> (дата звернення: 01.09.2025).

19. Schrage M., Kiron D., Candelon F., Khodabandeh S., Chu M. The Future of Strategic Measurement: Enhancing KPIs with AI. *MIT Sloan Management Review*. 2024. URL: <https://sloanreview.mit.edu/projects/the-future-of-strategic-measurement-enhancing-kpis-with-ai/> (дата звернення: 01.09.2025).

20. Prescience Decision Solutions. Accelerating Forecasting Accuracy with ML: Transforming GMV Predictions for a Global eCommerce Leader. *Prescience Decision Solutions*. URL: <https://prescienceds.com/accelerating-forecasting-accuracy-with-ml-transforming-gmv-predictions-for-a-global-ecommerce-leader/> (дата звернення: 01.09.2025).

21. Giovine C., Roberts R. Building AI trust: The key role of explainability. *McKinsey & Company*. URL: <https://www.mckinsey.com/capabilities/quantumblack/our-insights/building-ai-trust-the-key-role-of-explainability> (дата звернення: 01.09.2025).

22. Gobin H. The 2024 FP&A Trends Survey Results: Key Insights and Findings Unveiled. *FPA Trends*. URL: <https://fpa-trends.com/article/2024-fpa-trends-survey-results-unveiled> (дата звернення: 01.09.2025).

23. Balroop D. AI in Finance: Revolutionizing Risk Management and Fraud Detection in 2024. *LinkedIn*. URL: <https://www.linkedin.com/pulse/ai-finance-revolutionizing-risk-management-fraud-2024-dave-balroop-ibo3c> (дата звернення: 01.09.2025).

24. JPMorgan. AI investment trends 2025: Beyond the bubble. *JPMorgan*. 2024. URL: <https://am.jpmorgan.com/se/en/asset-management/per/insights/market-insights/investment-outlook/ai-investment/> (дата звернення: 01.09.2025).

25. De Freitas J. Why People Resist Embracing AI. *Harvard Business Review*. URL: <https://hbr.org/2025/01/why-people-resist-embracing-ai> (дата звернення: 01.09.2025).

26. AI Act. *European Commission*. 2024. URL: <https://digital-strategy.ec.europa.eu/en/policies/regulatory-framework-ai> (дата звернення: 01.09.2025).

27. Legal IO. Total GDPR fines in 2024 reached €1.2 billion in 2024. *Legal IO*. URL: <https://www.legal.io/articles/5568592/Total-GDPR-fines-in-2024-reached-%E2%82%AC1-2-billion-in-2024> (дата звернення: 01.09.2025).

28. Insights Global. AI in Oil and Gas: Preventing Equipment Failures Before They Cost Millions. *Insights Global*. URL: <https://www.insights-global.com/ai-in-oil-and-gas-preventing-equipment-failures-before-they-cost-millions/> (дата звернення: 01.09.2025).