

DOI: <https://doi.org/10.36910/6775-2524-0560-2025-58-16>

УДК 004:8

Шикеринець Степан Тарасович, аспірант

<https://orcid.org/0009-0000-8748-5765>

Улічев Олександр Сергійович, к.т.н., доцент

<https://orcid.org/0000-0003-3736-9613>

Приватний вищий навчальний заклад «Європейський університет», м. Київ, Україна

ПЕРСПЕКТИВИ ВИКОРИСТАННЯ МАШИННОГО НАВЧАННЯ ДЛЯ ЗАБЕЗПЕЧЕННЯ ВІДПОВІДНОСТІ ПРОГРАМНИХ ПРОДУКТІВ ДО ДЕРЖАВНИХ НОРМАТИВНИХ ВИМОГ

Шикеринець С.Т., Улічев О.С. Перспективи використання машинного навчання для забезпечення відповідності програмних продуктів до державних нормативних вимог. Забезпечення відповідності програмних продуктів до різноманітних державних нормативних вимог, галузевих стандартів та кращих практик є одним з ключових завдань для сучасних організацій та компаній що розробляють чи впроваджують дані продукти. У статті розглядаються перспективи використання машинного навчання для забезпечення відповідності програмних продуктів до державних нормативних вимог. Проаналізовано сучасні методи машинного навчання, які можуть бути застосовані для автоматизації процесів перевірки програмних продуктів. Оцінка потенціалу впровадження машинного навчання виявила суттєві переваги, включаючи підвищення ефективності, точності та масштабованості процесів перевірки відповідності. Описано потенційні переваги та виклики впровадження цих технологій у сфері забезпечення відповідності програмних продуктів до державних стандартів. На основі отриманих результатів запропоновано практичні рекомендації щодо ефективного впровадження машинного навчання.

Ключові слова: машинне навчання, програмне забезпечення, державні нормативні вимоги, відповідність, автоматизація, верифікація.

Shykerynets S., Ulichev O. Prospects for the Use of Machine Learning to Ensure Compliance of Software Products with State Regulatory Requirements. Ensuring compliance of software products with various government regulatory requirements, industry standards and best practices is one of the key tasks for modern organizations and companies that develop or implement these products. In this article, the prospects for using machine learning to ensure compliance of software products with government regulatory requirements are discussed. Modern machine learning methods that can be applied to automate the process of verifying software products for compliance with governmental requirements have been analyzed. An assessment of the potential of implementing machine learning has discovered significant benefits, including increased efficiency, accuracy, and scalability of compliance verification processes. The potential benefits and challenges of implementing these technologies in the field of ensuring compliance of software products with state standards are described. Based on the obtained results practical recommendations for the effective implementation of machine learning are proposed.

Keywords: machine learning, software, government regulatory requirements, compliance, automation, verification.

Постановка проблеми. У сучасних організаціях програмні продукти є невід'ємною частиною бізнес-процесів, забезпечуючи ефективність та конкурентоспроможність компаній. Проте, забезпечення відповідності програмного забезпечення різноманітним державним нормативним вимогам, галузевим стандартам та практикам стає все більш складним завданням. Зростання кількості регуляторних актів, їхньої складності та взаємозв'язку створюють значні труднощі для компаній та організацій що проводять розробку та впровадження програмних продуктів. Крім того, швидкий розвиток технологій та змін у законодавстві вимагають постійного оновлення знань та адаптації процесів забезпечення відповідності, що часто призводить до високих витрат часу та ресурсів.

Традиційні методи перевірки відповідності, такі як ручний аудит та статичний аналіз, мають обмежену ефективність у контексті великих та складних програмних систем. Ці методи не завжди здатні швидко адаптуватися до змін нормативних вимог та виявляти потенційні невідповідності. У зв'язку з цим, виникає потреба у впровадженні інноваційних підходів, які можуть автоматизувати та оптимізувати процеси перевірки на забезпечення відповідності до регуляторних вимог. Машинне навчання пропонує перспективні рішення для автоматизації аналізу нормативних документів, виявлення ризиків та прогнозування потенційних проблем, що може суттєво підвищити ефективність та точність процесів перевірки відповідності програмних продуктів державним вимогам.

Аналіз останніх досліджень і публікацій. У останні роки застосування машинного навчання для забезпечення відповідності програмного забезпечення державним нормативним вимогам стало предметом активних досліджень у науковій спільноті. Багато публікацій зосереджуються на розробці методів, які можуть автоматизувати процеси перевірки та верифікації,

підвищуючи ефективність та точність цих процедур. Одним із ключових напрямків є використання глибинного навчання для аналізу великих обсягів нормативних документів. Наприклад, дослідження Малінгерра К. [1] розглядає застосування моделей МН для аналізу технологічної готовності фермерів до впровадження технологій точного тваринництва (Precision Livestock Farming, PLF), визначаючи ключові бар'єри та драйвери прийняття інновацій. Отримані результати допомагають адаптувати дизайн технологій і бізнес-стратегії, покращуючи доступність, підтримку та інтеграцію прогресивних рішень МН у фермерські господарства.

Результати показали що модель успішно ідентифікує ключові вимоги фермерів та бар'єри впровадження технологій, спрощуючи розробку рішень і стратегії для різних груп користувачів.

Дослідник Гак І.У. з колегами [2] провели важливе дослідження, що доводить ефективність застосування машинного навчання для аналізу екологічних даних, відкриваючи перспективи для подальшого розвитку автоматизованих систем у галузі екологічного моніторингу. Дослідження Фавзі А.Г. [3] аналізує інтеграцію машинного навчання з DevOps-практиками для автоматичного виявлення аномалій у логах і метриках продуктивності програмного забезпечення. Автори пропонують гібридний підхід, який використовує компоненти для моніторингу аномалій до та після розгортання системи, що підвищує гнучкість і ефективність процесів DevOps.

Увагу привертає дослідження, яке провів Марек П. [4] щодо пояснювальних моделей машинного навчання (Explainable AI) в галузях де застосування даних моделей мають кричне значення щодо забезпечення прозорості рішень, що може бути використане для застосування щодо забезпечення відповідності програмних продуктів до нормативних вимог.

Наукова робота Муруган С. [5] розкриває застосування машинного навчання для управління фінансовими ризиками, а саме прогнозування ризиків (виявленні потенційних проблем), аналізу великих даних та оптимізації процесів. Також в роботі описано як застосування МН може допомогти у проактивному підході до управління ризиками.

Стаття Браунк А. та інших авторів [6] акцентує увагу на використанню федеративного навчання (Federated Learning, FL) у медичних дослідженнях з метою аналізу широкого набору персональних даних (пацієнтів). Федеративне навчання дає можливість тренувати моделі машинного навчання без необхідності передачі даних до централізованих серверів. Тренування відбувається на даних що зберігаються локально та відповідає вимогам GDPR. Для підвищення конфіденційності даних пропонується використання диференційної конфіденційності (Differential Privacy) та безпечного багатостороннього обчислення (Secure Multiparty Computation)ю

Виділення невирішених раніше частин загальної проблеми. Не дивлячись на вагомі досягнення у забезпеченні відповідності програмних продуктів до державних вимог завдяки застосуванню машинного навчання, існує ряд проблем, які залишаються недостатньо вивченими або потребують подальшого дослідження. Виявлення цих невирішених проблем є важливим для подальшого розвитку ефективних рішень у даній сфері.

По-перше, одна з основних проблем полягає у забезпеченні якості та доступності даних для навчання моделей. Такі дослідження, як робота Менлі К. та колег [7], аргументують, що важливість високоякісних та репрезентативних даних є ключовими для створення точних моделей. Використання якісних наборів даних дозволяє уникати помилкових висновків, пов'язаних з неповними або неточними даними. Завдяки зростанню доступності великих об'ємів даних, їхня якість стає критичним фактором.

По-друге, питання пояснюваності моделей МН залишається важливим викликом. Сьогодні концепції пояснюваного штучного інтелекту (Explainable AI, xAI) активно розвиваються, проте, на основі роботи Клайн Т. та Волтера Т. [8], їхнє застосування у сфері забезпечення відповідності програмного забезпечення потребує подальшого вдосконалення. Наукова робота [8] досліджує важливість пояснення роботи машинного навчання, що дозволяє оцінити вплив окремих факторів на результати роботи моделей. Автори акцентують актуальність і перспективність впровадження xAI для створення прозорих і зрозумілих рішень, де необхідно забезпечити високу прозорість та довіру з боку регуляторних органів.

По-третє, інтеграція МН з існуючими процесами розробки та управління програмним забезпеченням, зокрема з такими як практика DevOps. Не зважаючи на існуючі перспективи використання МН для оптимізації процесів тестування та моніторингу відповідності до регуляторних вимог, практичні аспекти такої інтеграції залишаються вивченими на недостатньому рівні. Особливо це стосується сумісності між різними інструментами та платформами, а також високу складність становить управління змінами в моделях МН у реальному часі.

Четвертим невіршеним на достатньому рівні питанням є етичні та правові аспекти використання МН для забезпечення відповідності. Хоч етичні міркування активно обговорюються, необхідно розробити й встановити чіткі правила та стандарти для застосування МН у контексті дотримання відповідності державним вимогам. Це включає створення спеціалізованих етичних кодексів та нормативно-правових актів, які враховують специфіку використання машинного навчання у забезпеченні відповідності програмних продуктів державним вимогам. Крім того, існує обмежена кількість досліджень, що фокусуються на адаптивності та гнучкості моделей МН у динамічних та швидко-змінних нормативних середовищах. В умовах швидких змін нормативних вимог, системи МН повинні бути гнучкими та динамічними, здатні до швидкої адаптації та оновлення без значних втрат у продуктивності та точності. Це актуалізує питання розробки нових алгоритмів та архітектур, які можуть швидко та точно реагувати на зміни та підтримувати актуальність моделей.

Важливим аспектом є забезпечення крос-дисциплінарної (крос-галузевої) співпраці між фахівцями з машинного навчання, програмної (комп'ютерної) інженерії та нормативної політики. Успішність впровадження МН для забезпечення відповідності державним вимогам потребує інтеграції знань та досвіду з різних галузей, що дозволяє створювати більш комплексні та ефективні рішення. Такий підхід дозволяє врахувати безліч аспектів процесу забезпечення відповідності вимогам та підвищує ймовірність успішної реалізації проектів.

Таким чином, хоч існуючі дослідження демонструють значний потенціал машинного навчання у сфері забезпечення відповідності програмного забезпечення до державних нормативних вимог, проте, залишаються численні невіршені питання. Подолання цих викликів потребує подальших досліджень та розвитку інноваційних підходів та методів, що дозволять максимально ефективно використовувати можливості МН для забезпечення високої якості та безпеки програмних продуктів.

Формулювання мети дослідження. Метою даного дослідження є широкий аналіз та оцінка можливостей застосування машинного навчання (МН) для забезпечення відповідності програмних продуктів до державних нормативних вимог. Це дослідження спрямоване на визначення ефективних підходів та інструментів машинного навчання, що можуть бути інтегровані у процеси розробки та верифікації програмних продуктів для забезпечення високого рівня відповідності встановленим стандартам та вимогам.

Основна частина дослідження. Застосування сучасних методів машинного навчання (МН) стає все більш актуальним для забезпечення відповідності програмних продуктів нормативним вимогам, галузевим стандартам та найкращим практикам. Основні методи, що мають потенціал для автоматизації процесів перевірки та верифікації, включають глибинне навчання (Deep Learning, DL), обробку природної мови (Natural language processing, NLP), виявлення аномалій, навчання з підкріпленням (Reinforcement Learning, RL). Кожен з цих методів має свої унікальні можливості, переваги та обмеження, що визначають їх ефективність у контексті даного дослідження.

Глибинне навчання (DL) є одним із найпотужніших інструментів МН, який дозволяє моделювати складні залежності та виявляти приховані патерни в даних. Завдяки багаторівневим нейронним мережам, глибинне навчання може аналізувати великі обсяги інформації, що є необхідними для автоматичного аналізу нормативних документів та визначення відповідності програмних продуктів встановленим стандартам. Однією з ключових переваг глибинного навчання (DL) є його здатність до самонавчання та адаптації до нових даних, що дозволяє системам постійно вдосконалюватися та гнучко реагувати на зміни в нормативно-правових актах. Проте, глибинні моделі вимагають значних обчислювальних ресурсів та великих обсягів навчальних даних, що може бути обмежуючим фактором в контексті даного напрямку застосування.

Обробка природної мови (NLP) може бути інструментом для автоматизації аналізу текстів нормативно-правових документів. Обробка природної мови (NLP) дозволяє системам розуміти, інтерпретувати та виділяти ключові вимоги з великих обсягів тексту. Дана особливість таких моделей значно спрощує процес інтеграції нормативно-правових вимог у розробку та аналіз програмних продуктів. Однією з переваг напрямку обробки природної мови (NLP) є здатність до семантичного аналізу, що дозволяє точніше визначати зміст та контекст вимог. Проте, NLP може стикатися з труднощами при обробці складних юридичних текстів, де необхідна висока точність та глибинне і однозначне розуміння нюансів мови та понять.

Виявлення аномалій (anomaly detection, AD) є ще одним важливим методом МН, який використовується для ідентифікації невідповідностей та потенційних ризиків у програмних системах. Цей метод дозволяє автоматично виявляти нетипові патерни в роботі системи, що можуть свідчити про порушення нормативних вимог. Виявлення аномалій (AD) є корисним для проактивного управління ризиками, оскільки дозволяє своєчасно реагувати на потенційні загрози під час створення програмних продуктів. Однак, цей метод може бути менш ефективним у випадках, коли аномалії не мають чітких патернів або коли дані є недостатньо якісними.

Навчання з підкріпленням (Reinforcement Learning, RL) також має переваги як от здатність адаптуватися до динамічних умов та навчатися на основі досвіду. Це дозволяє системам швидко реагувати на нові виклики та зміни у законодавстві. Також навчання з підкріпленням (RL) може виявляти та виправляти проблемні місця нетипову поведінку, які суперечить нормативно-правовим вимогам або іншим стандартам. Проте застосування навчання з підкріпленням (RL) має і свої недоліки. Незважаючи на попередньо перелічені переваги, процес навчання RL-моделей може бути ресурсомістким та тривалим. Також для таких систем є складним завдання забезпечення стабільності та повторюваності результатів. Не варто забувати і про ризик того що такі системи можуть приймати несподівані рішення, які важко передбачити. А такі ризики у сфері забезпечення відповідності нормативно-правовим вимогам може призвести до неочікуваних порушень з відповідними наслідками.

Крім використання окремих методів, важливо розглядати їхню інтеграцію для досягнення максимального корисного ефекту. Для прикладу, поєднання глибинного навчання (DL) з обробкою природної мови (NLP) дозволяє створювати системи, здатні одночасно аналізувати текстові вимоги та інтегрувати їх у процеси верифікації програмних продуктів. Такий підхід сприяє комплекснішому та гнучкішому аналізу, забезпечуючи високу точність та ефективність перевірок. Проте, тут існують певні обмеження, пов'язані з застосуванням цих методів. Основними проблемами є потреба якісних та репрезентативних даних. Також складність інтеграції різних методів та забезпечення їхньої взаємодії. Для подолання даних недоліків необхідно продовжувати розробку нових алгоритмів та методів інтеграції, що дозволять ефективніше використовувати потенціал машинного навчання.

Відповідно, глибинне навчання (DL), обробка природної мови (NLP), виявлення аномалій (AD) та навчання з підкріпленням (RL) представляють собою потужні інструменти, які можуть значно покращити процеси забезпечення відповідності програмних продуктів до нормативно-правових вимог. Але для їх ефективного застосування необхідно вирішити низку технічних та методологічних завдань, що дозволить максимально використовувати їхні переваги та мінімізувати обмеження.

Також питання пояснюваності моделей (xAI) машинного навчання (МН) залишається важливим викликом. Існуючі методи xAI часто недостатньо ефективні для пояснення рішень у складних нормативно-правових середовищах, де необхідно забезпечити високу прозорість та довіру з боку регуляторних органів. Пояснюваність моделей машинного навчання є надзвичайно важливою, оскільки розробники та регулятори повинні мати змогу зрозуміти, як і чому система приймає рішення. Це актуально у випадках, коли невідповідності можуть мати серйозні наслідки для безпеки, конфіденційності чи відповідності законодавству. Без належної пояснюваності, моделі машинного навчання можуть бути сприйняті як "чорні ящики" (BlackBox), що ускладнює їхнє прийняття та довіру з боку регуляторно-контролюючих органів та розробників програмних продуктів.

Однією з основних проблем у застосуванні пояснюваних моделей є баланс між складністю моделі та її здатністю бути поясненою. Більш складні моделі, такі як глибинні нейронні мережі (Deep Neural Network, DNN), можуть досягати високої точності, але їхні внутрішні механізми важко а то й неможливо інтерпретувати. В свою чергу це створює дилему: як зберегти високу точність прогнозів з однієї точки зору, та одночасно забезпечуючи достатню прозорість рішень з другої. Відповідь на це питання лежить у розвитку нових методів xAI, які дозволяють забезпечувати пояснюваність без значного зниження продуктивності моделей. Дослідження показують, що існують різні підходи до покращення пояснюваності моделей МН. Наприклад, методи локальної пояснюваності, такі як LIME (Local Interpretable Model-agnostic Explanations) [9] та SHAP (SHapley Additive exPlanations) [10], дозволяють аналізувати окремі рішення моделей, надаючи зрозумілі пояснення для користувачів. Але дані методи мають свої обмеження, оскільки вони зосереджені на локальних поясненнях і не завжди можуть відображати глобальну поведінку моделі. На даний час, стає все більш актуальним розвиток моделей, які заздалегідь проєктовані та розроблені для

підвищення і прощення пояснюваності. В таких моделях намагаються поєднати високу точність результатів із забезпеченням чіткого розуміння процесу прийняття рішень.

Іншим важливим аспектом є інтеграція пояснених моделей з процесами управління відповідністю програмних продуктів до державних вимог. Це включає в себе створення стандартів та методів, що забезпечують систематичний підхід до пояснення рішень моделей машинного навчання у контексті нормативно-правової бази. Впровадження таких методів та стандартів сприятиме підвищенню довіри до автоматизованих систем та полегшить їхнє використання та впровадження.

Також важливою складовою є кваліфікація спеціалістів, що працюють з даними моделями. Вони повинні мати глибоке розуміння як технічних аспектів машинного навчання, так і нормативно-правових вимог, щоб ефективно впроваджувати та управляти поясненими моделями. Це дозволить створювати більш ефективні та надійні системи, що відповідають високим стандартам якості.

Наступним аспектом який необхідно вирішити є інтеграція машинного навчання (ML) з існуючими процесами та підходами розробки програмних продуктів, такими як DevOps. Така інтеграція дасть можливість для кращої автоматизації процесів тестування відповідності програмних продуктів. Однією з основних проблем такої інтеграції є сумісність між різними інструментами та платформами, що використовуються в DevOps та машинному навчанні (ML). Ще одним викликом є управління змінами в моделях машинного навчання у реальному часі. Оскільки моделі машинного навчання потребують постійного оновлення та перенавчання на нових даних для підтримки їхньої актуальності та точності. Інтеграція цих процесів з DevOps практиками вимагає створення ефективних механізмів для безперервного навчання та оновлення моделей, що може виявитися комплексним та складним завданням через необхідність забезпечення стабільності та безпеки систем що розробляються.

Для подолання цих викликів необхідно паралельно розробляти та впроваджувати гнучкі та масштабовані архітектури, що дозволять відносно легко та швидко інтегрувати системи машинного навчання з існуючими DevOps інструментами. Варто зазначити що автоматизація процесів оновлення та моніторингу моделей машинного навчання допоможе забезпечити їхню безперебійну роботу у режимі реального часу.

Важливим питанням є етичні та правові аспекти використання машинного навчання (MN) для забезпечення відповідності програмних продуктів до державних нормативних вимог. Хоч етичні аспекти і активно обговорюються в науковій спільноті, існує суттєва потреба у розробці чітких правил та стандартів для застосування машинного навчання (MN) у даному контексті. Це включає створення спеціалізованих етичних кодексів та нормативно-правових документів, що враховують специфіку використання машинного навчання у даній сфері. Відсутність стандартів застосування машинного навчання може призвести до порушень конфіденційності, дискримінації або інших етичних проблем.

Крім того, існує обмежена кількість досліджень, що фокусуються на адаптивності та гнучкості моделей машинного навчання у динамічних середовищах пов'язаних зі змінними нормативно-правовими вимогами. Системи машинного навчання повинні бути здатні до швидкої адаптації та оновлення без значних втрат у продуктивності та точності в умовах швидких змін нормативних вимог. Це вимагає розробки нових алгоритмів та архітектур, які можуть ефективно реагувати на зміни та підтримувати актуальність моделей. Поточні методи часто не можуть забезпечити достатньої гнучкості для роботи в умовах постійних змін, що обмежує їхнє застосування у реальному робочому середовищі. Для подолання таких викликів необхідно сфокусуватися на створенні адаптивних моделей, що будуть мати змогу швидко інтегрувати нові нормативні вимоги без необхідності повного перенавчання

Також однією з проблем у даному контексті застосуванні машинного навчання (MN) є забезпечення високої якості та доступності даних для навчання моделей. Збір та анотація таких даних часто є складним процесом через конфіденційність інформації та відсутність стандартизованих репрезентативних наборів даних. Важливо впроваджувати стандартизовані процесів збору та таких даних. Розробка чітко визначених протоколів для збору даних сприятиме підвищенню їхньої якості та сумісності між різними проектами тільки якщо буде забезпечена відповідність вимогам конфіденційності та безпеки. Співпраця з державними органами та іншими зацікавленими сторонами може забезпечити доступ до потрібних даних та сприяти створенню репрезентативних наборів, які відповідають специфічним нормативно-правовим вимогам.

Висновки та перспективи подальших досліджень. У даній статті було розглянуто перспективи використання машинного навчання (МН) для забезпечення відповідності програмних продуктів до державних нормативно-правових вимог. Проведене дослідження дозволило проаналізувати ключові аспекти, що впливають на ефективність та успішність впровадження машинного навчання у даній сфері використання, а також визначити основні недоліки та виклики, які потребують додаткового вивчення та вирішення:

1. Концепції пояснюваного штучного інтелекту (Explainable AI, XAI) активно розвиваються. Проте їхнє застосування у даній сфері потребує подальшого вдосконалення. Пояснюваність моделей є критично важливим аспектом для забезпечення довіри та використання з боку розробників, користувачів та регуляторних державних органів. Необхідно розробляти нові та вдосконалювати вже існуючі методи і архітектури. Ці методи повинні дозволити отримувати однозначні та чіткі пояснення рішень моделей без значного зниження їх точності та продуктивності.

2. Адаптивність та гнучкість моделей МН у динамічних нормативних середовищах також є невирішеним питанням. В умовах швидких змін нормативно-правових вимог від систем машинного навчання вимагається здатність до швидкої адаптації та оновлення без значних втрат у продуктивності та точності. Впровадження методів безперервного навчання може стати ключовим фактором у вирішенні даного виклику.

3. Інтеграція машинного навчання з DevOps практиками дозволяє автоматизувати процеси тестування та забезпечувати постійну актуальність та точність моделей. Проте, практичні аспекти такої інтеграції з моделями машинного навчання у реальному часі, залишаються недостатньо вивченими.

4. Етичні міркування які активно обговорюються вимагають створення чітко визначених стандартів для застосування машинного навчання які враховують специфіку даної сфери. Впровадження таких стандартів сприятиме підвищенню довіри до автоматизованих систем даного типу.

5. Забезпечення високої якості та доступності даних є фундаментальним для успішного застосування машинного навчання у даній сфері. Збір і анотація даних мають перешкоди у вигляді конфіденційності інформації та відсутності якісних стандартизованих наборів. Для подолання цих перешкод необхідно використовувати методи аугментації даних, які дозволяють підвищити різноманітність та обсяг навчальних наборів без компрометації конфіденційності. Необхідно також впроваджувати стандартизацію процесів збору та анотації даних.

На основі проведеного аналізу, можна зробити висновок, що для максимального використання потенціалу машинного навчання у поточній сфері необхідно засовувати комплексний підхід. Він включає в себе вдосконалення методів збору та анотації даних, розвиток пояснюваних моделей, інтеграцію машинного навчання з DevOps практиками, розробку етичних та правових рамок, а також забезпечення адаптивності систем у динамічних середовищах.

Перспективи подальших досліджень полягають у розробці нових та вдосконаленні існуючих методів та інструментів, що дозволять ефективніше інтегрувати машинне навчання у даному напрямку, забезпечуючи високу відповідність програмних продуктів до державних вимог. Майбутні дослідження повинні мати на меті не лише подолання існуючих викликів, але й відкриття нових можливостей для використання машинного навчання у даній сфері використання. Це сприятиме підвищенню якості, безпеки та надійності програмного забезпечення, що в свою чергу забезпечить його відповідність сучасним та майбутнім вимогам та стандартам, а це є критично важливим для успішної діяльності сучасних організацій та програмних продуктів що розробляються та впроваджуються.

Список бібліографічного опису:

1. Mallinger, K., Corpaci, L., Neubauer, T., Tikász, I. E., Goldenits, G., & Banhazi, T. (2024). Breaking the barriers of technology adoption: Explainable AI for requirement analysis and technology design in smart farming. *Smart Agricultural Technology*, 9, 100658. <https://doi.org/10.1016/j.atech.2024.100658>.
2. Haq, I. U., Lee, B. S., Rizzo, D. M., & Perdrial, J. N. (2024). An automated machine learning approach for detecting anomalous peak patterns in time series data from a research watershed in the northeastern United States critical zone. *Machine Learning with Applications*, 100543. <https://doi.org/10.1016/j.mlwa.2024.100543>.
3. Hany, A., Wassif, K., & Moussa, H. (2023). Framework for Automatic Detection of Anomalies in DevOps. *Journal of King Saud University - Computer and Information Sciences*. <https://doi.org/10.1016/j.jksuci.2023.02.010>.
4. Pawlicki, M., Pawlicka, A., Uccello, F., Szelest, S., D'Antonio, S., Kozik, R., & Choraś, M. (2024b). Evaluating the necessity of the multiple metrics for assessing explainable AI: A critical examination. *Neurocomputing*, 128282. <https://doi.org/10.1016/j.neucom.2024.128282>.

5. Murugan, M. S., T, S. K., & Marappan, R. (2023). Large-scale data-driven financial risk management & analysis using machine learning strategies. *Measurement: Sensors*, 100756. <https://doi.org/10.1016/j.measen.2023.100756>.
6. Brauneck, A., Schmalhorst, L., Kazemi Majdabadi, M. M., Bakhtiari, M., Völker, U., Baumbach, J., Baumbach, L., & Buchholtz, G. (2023). Federated Machine Learning, Privacy-Enhancing Technologies, and Data Protection Laws in Medical Research: Scoping Review. *Journal of Medical Internet Research*, 25, Стаття e41588. <https://doi.org/10.2196/41588>.
7. Manley, K., Nyelele, C., & Egoh, B. N. (2022). A review of machine learning and big data applications in addressing ecosystem service research gaps. *Ecosystem Services*, 57, 101478. <https://doi.org/10.1016/j.ecoser.2022.101478>.
8. Klein, T., & Walther, T. (2024). Advances in explainable artificial intelligence (xAI). *Finance Research Letters*, 106358. <https://doi.org/10.1016/j.frl.2024.106358>.
9. Cheng, T., Ju, M., Zhang, W., Wu, C., Liu, Q., & Ban, Q. (2025). Investigating the impact of diversion projects on river health using the spherical fuzzy cloud TOPSIS model and the SHapley Additive exPlanation technique. *Ecological Indicators*, 170, 113112. <https://doi.org/10.1016/j.ecolind.2025.113112>.
10. Hassan, S. U., Abdulkadir, S. J., Zahid, M. S. M., & Al-Selwi, S. M. (2025). Local interpretable model-agnostic explanation approach for medical imaging analysis: A systematic literature review. *Computers in Biology and Medicine*, 185, 109569. <https://doi.org/10.1016/j.combiomed.2024.109569>.

References:

1. Mallinger, K., Corpaci, L., Neubauer, T., Tikász, I. E., Goldenits, G., & Banhazi, T. (2024). Breaking the barriers of technology adoption: Explainable AI for requirement analysis and technology design in smart farming. *Smart Agricultural Technology*, 9, 100658. <https://doi.org/10.1016/j.atech.2024.100658>.
2. Haq, I. U., Lee, B. S., Rizzo, D. M., & Perdrial, J. N. (2024). An automated machine learning approach for detecting anomalous peak patterns in time series data from a research watershed in the northeastern United States critical zone. *Machine Learning with Applications*, 100543. <https://doi.org/10.1016/j.mlwa.2024.100543>.
3. Hany, A., Wassif, K., & Moussa, H. (2023). Framework for Automatic Detection of Anomalies in DevOps. *Journal of King Saud University - Computer and Information Sciences*. <https://doi.org/10.1016/j.jksuci.2023.02.010>.
4. Pawlicki, M., Pawlicka, A., Uccello, F., Szelest, S., D'Antonio, S., Kozik, R., & Choraś, M. (2024b). Evaluating the necessity of the multiple metrics for assessing explainable AI: A critical examination. *Neurocomputing*, 128282. <https://doi.org/10.1016/j.neucom.2024.128282>.
5. Murugan, M. S., T, S. K., & Marappan, R. (2023). Large-scale data-driven financial risk management & analysis using machine learning strategies. *Measurement: Sensors*, 100756. <https://doi.org/10.1016/j.measen.2023.100756>.
6. Brauneck, A., Schmalhorst, L., Kazemi Majdabadi, M. M., Bakhtiari, M., Völker, U., Baumbach, J., Baumbach, L., & Buchholtz, G. (2023). Federated Machine Learning, Privacy-Enhancing Technologies, and Data Protection Laws in Medical Research: Scoping Review. *Journal of Medical Internet Research*, 25, Article e41588. <https://doi.org/10.2196/41588>.
7. Manley, K., Nyelele, C., & Egoh, B. N. (2022). A review of machine learning and big data applications in addressing ecosystem service research gaps. *Ecosystem Services*, 57, 101478. <https://doi.org/10.1016/j.ecoser.2022.101478>.
8. Klein, T., & Walther, T. (2024). Advances in explainable artificial intelligence (xAI). *Finance Research Letters*, 106358. <https://doi.org/10.1016/j.frl.2024.106358>.
9. Cheng, T., Ju, M., Zhang, W., Wu, C., Liu, Q., & Ban, Q. (2025). Investigating the impact of diversion projects on river health using the spherical fuzzy cloud TOPSIS model and the SHapley Additive exPlanation technique. *Ecological Indicators*, 170, 113112. <https://doi.org/10.1016/j.ecolind.2025.113112>.
10. Hassan, S. U., Abdulkadir, S. J., Zahid, M. S. M., & Al-Selwi, S. M. (2025). Local interpretable model-agnostic explanation approach for medical imaging analysis: A systematic literature review. *Computers in Biology and Medicine*, 185, 109569. <https://doi.org/10.1016/j.combiomed.2024.109569>.