

Т. Р. Грабовенський¹, С. Є. Ляковська¹, Є. В. Мартин²

¹ Національний університет "Львівська політехніка", м. Львів, Україна

² Університет безпеки життєдіяльності, м. Львів, Україна

ПРОГНОЗУВАННЯ ТЕХНІЧНОГО СТАНУ ВИРОБНИЧОГО ОБЛАДНАННЯ ІЗ ЗАСТОСУВАННЯМ COST-SENSITIVE ПІДХОДІВ ТА ОПТИМІЗАЦІЇ ПОРОГІВ КЛАСИФІКАЦІЇ

У статті наведено дослідження застосування сучасних методів машинного навчання для задачі передиктивного технічного обслуговування на основі відкритого датасету AI4I Predictive Maintenance. Основні цілі роботи – побудова та порівняння моделей бінарної та багатокласової класифікації, що дають змогу передбачати як сам факт відмови обладнання, так і конкретний тип поломки. Враховуючи високий дисбаланс даних (частка відмов становить близько 3 %), було реалізовано підхід cost-sensitive оптимізації, за яким пропуск реальної відмови оцінюють як значно критичніший за хибну тривогу.

Для побудови моделей використано алгоритми Logistic Regression, Random Forest, XGBoost та LightGBM. Особливу увагу приділено ансамблевим методам градієнтного бустингу. Під час дослідження здійснено попереднє опрацювання даних, із масштабуванням числових ознак та інженерією нових ознак (Power, DeltaTemp, індикатор високого зношування інструменту). Для оцінювання якості моделей у бінарній класифікації використано метрику PR-AUC та показник Recall@Precision $\geq 0,90$, найрелевантніші в умовах критично важливих систем. У багатокласовій постановці застосовано confusion matrix та макроусереднені значення precision, recall та F1-score.

Як свідчать результати, серед базових моделей найкраще себе проявив XGBoost із PR-AUC = 0,64, а після гіперпараметричної оптимізації значення зросло до понад 0,90, що свідчить про високу здатність алгоритму виявляти потенційні відмови. У багатокласовій класифікації XGBoost також продемонстрував найвищу збалансованість між класами, тоді як LightGBM стикався із проблемами відсутності подальших сплітів за жорстких обмежень параметрів. Аналіз важливості ознак за допомогою SHAP-значень підтвердив ключову роль показників Tool wear, Power та Rotational speed у прогнозуванні.

Практична значущість дослідження полягає у можливості впровадження розроблених моделей у системи моніторингу обладнання для раннього виявлення ризиків та мінімізації економічних втрат. Робота демонструє ефективність поєднання cost-sensitive оптимізації та ансамблевих методів у сфері predictive maintenance та закладає основу для подальших досліджень, зокрема інтеграції time-to-failure прогнозування та глибоких нейронних мереж.

Ключові слова: машинне навчання, предиктивна аналітика, діагностика обладнання, виробничі процеси, прогнозування відмов.

Вступ / Introduction

Проблема передбачення відмов обладнання є однією із ключових у сфері промислової аналітики та управління життєвим циклом технічних систем. У світовій науковій літературі її активно досліджують упродовж останніх десятиліть, що підтверджується зростанням кількості робіт, які стосуються використання методів машинного навчання та штучного інтелекту для predictive maintenance. Зокрема, відзначають ефективність ансамблевих алгоритмів (Random Forest, Gradient Boosting), а також нейронних мереж у виявленні прихованих закономірностей у великих обсягах сенсорних даних.

Попри значний прогрес, досі залишаються нерозв'язаними кілька важливих аспектів. По-перше, у більшості досліджень основну увагу звертають лише на

бінарну класифікацію (відмова / справність), тоді як проблему ідентифікації конкретного типу відмови вивчено недостатньо. По-друге, відсутні універсальні підходи до врахування вартісних ризиків (cost-sensitive learning), коли пропуск відмови значно критичніший за помилкову тривогу. По-третє, недостатньо дослідженою залишається роль інтерпретації моделей (explainable AI), зокрема через SHAP-аналіз, що дає змогу визначати вплив окремих ознак на результат. Це визначає актуальність виконаного дослідження.

Об'єкт дослідження – процес технічного обслуговування обладнання із використанням методів машинного навчання.

Предмет дослідження – моделі бінарної та багатокласової класифікації відмов машин на основі даних AI4I Predictive Maintenance.

Мета роботи – підвищення точності та надійності прогнозування відмов машин за допомогою сучасних алгоритмів машинного навчання, оптимізації порогів класифікації з урахуванням вартості помилок та інтерпретації результатів за допомогою explainable AI.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

- виконати попереднє опрацювання даних та інженерію ознак для формування якісної вибірки;
- побудувати та порівняти базові моделі (Logistic Regression, Random Forest, XGBoost, LightGBM) для бінарної класифікації відмов;
- виконати оптимізацію порогів класифікації з урахуванням вартості помилок (cost-sensitive approach);
- реалізувати багатокласову класифікацію для визначення типу відмови;
- виконати інтерпретацію моделей із застосуванням SHAP-аналізу;
- сформулювати рекомендації щодо практичного використання отриманих моделей для predictive maintenance.

Матеріали та методи дослідження.

Дані для дослідження

Для аналізу використано відкритий датасет AI4I Predictive Maintenance, що містить 10 000 записів із показниками роботи промислового обладнання. Датасет містить як числові сенсорні дані (оберти, крутний момент, зношування інструменту, температура процесу та навколишнього середовища), так і цільові змінні: *Machine failure* (бінарна) та *Failure type* (п'ять класів поломок).

Попередній аналіз показав значний дисбаланс класів: відмови становлять лише близько 3 % від усіх записів, причому є тільки поодинокі приклади частини типів відмов. Це створює ризик зміщення моделей у бік класу “без відмови” і зниження recall для рідкісних подій.

Попереднє оброблення даних

Для підготовки даних виконано такі кроки:

- перевірка наявності пропусків та викидів;
- перетворення категоріальних ознак (*Type*, *Failure type*) у числовий формат за допомогою label encoding;
- масштабування числових ознак із використанням StandardScaler;
- створення додаткових похідних ознак:
 - $\text{Power} = \text{Rotational speed} \times \text{Torque}$;
 - $\text{DeltaTemp} = \text{Process temperature} - \text{Air temperature}$;
 - індикатор ToolWear_gt200, що сигналізує про перевищення критичного рівня зношування.

Важливим етапом стали групова та часова валідація (GroupShuffleSplit, StratifiedGroupKFold), що дає змогу

уникнути витоку інформації між train / test і забезпечує реалістичні умови експлуатації.

Моделі та алгоритми

Для розв'язання задачі побудовано дві групи моделей:

1. Бінарна класифікація (прогноз “відмова / справність”): Logistic Regression, Random Forest, XGBoost, LightGBM.
2. Багатокласова класифікація (ідентифікація типу поломки): Random Forest, XGBoost, LightGBM.

Особливу увагу звернено на ансамблеві алгоритми (XGBoost, LightGBM), які добре працюють із табличними даними та враховують взаємодії між ознаками.

Метрики оцінювання

Для бінарної класифікації застосовано:

- PR-AUC (Average Precision) – вибрана як основна метрика через істотний дисбаланс класів;
- $\text{Recall@Precision} \geq 0.90$ – для оцінювання здатності виявляти відмови за високої точності;
- оптимізація порога за допомогою cost-sensitive функції з вагами $C_{FN}=10$, $C_{FP}=1$.

Для багатокласової класифікації використано:

- Confusion matrix;
- макроусереднені precision, recall, F1-score, що враховують рівнозначність усіх класів.

Уникнення джерел помилок

Можливі джерела похибок і способи їхнього усунення:

- Дисбаланс класів – замість простого ресемплінгу використано cost-sensitive підхід.
- Перенавчання моделей – застосовано крос-валідацію та ранню зупинку (early stopping).
- Витік інформації – забезпечено правильний розподіл train / test із груповим урахуванням.
- Інтерпретація результатів – використано SHAP-аналіз, щоб перевірити вплив ознак на прогноз.

Технічне середовище

Експерименти виконано у середовищі Python 3.10, Jupyter Notebook з використанням бібліотек *scikit-learn*, *XGBoost*, *LightGBM*, *SHAP*, *matplotlib*, *seaborn*.

Аналіз останніх досліджень та публікацій. Проблематика передбачуваного технічного обслуговування (predictive maintenance) є однією з ключових у сучасній промисловій аналітиці. Розвиток сенсорних технологій та систем моніторингу привів до появи великих масивів даних, які можуть бути використані для прогнозування стану обладнання та запобігання відмовам. Як зазначають Ahmed et al. (2021), “predictive maintenance спрямоване на мінімізацію простоїв і витрат шляхом завчасного виявлення можливих відмов” [1].

Особливу увагу в останніх дослідженнях звернено на використання алгоритмів машинного навчання для аналізу сенсорних даних. Zonta et al. (2020) підкреслюють, що “традиційні методи виявлення відмов поступаються сучасним моделям, зокрема ансамблевим

алгоритмам та градієнтному бустингу, які здатні працювати з великими та розбалансованими наборами даних” [2]. Це актуалізує використання таких алгоритмів, як Random Forest, XGBoost та LightGBM.

Істотного прогресу досягнуто у застосуванні градієнтного бустингу. За словами Chen & Guestrin (2016), “XGBoost забезпечує надзвичайно високу продуктивність та стійкість до шуму даних завдяки реалізації оптимізованих дерев рішень” [3]. Аналогічно, Ke et al. (2017) зазначають, що LightGBM дає змогу “істотно прискорити процес навчання моделей на великих даних завдяки технікам Gradient-based One-Side Sampling (GOSS) та Exclusive Feature Bundling (EFB)” [4].

Важливою проблемою залишається дисбаланс класів, оскільки частота відмов обладнання зазвичай істотно нижча за кількість справних випадків. Як зазначає Naque et al. (2022), “ігнорування дисбалансу може призводити до високої точності, але практично нульової здатності моделі виявляти відмови” [5]. Тому необхідно застосовувати спеціальні підходи, зокрема cost-sensitive learning, де пропуск відмови (false negative) розглядається як значно критичніший, ніж помилкова тривога (false positive).

Окрему увагу науковці приділяють питанню інтерпретації моделей. Lundberg & Lee (2017) запропонували метод SHAP, який дає змогу “пояснити вплив кожної ознаки на прогноз, роблячи моделі машинного навчання прозорішими та більш прийнятними для використання у промисловості” [6]. Це особливо актуально для критичних галузей, де довіра до систем автоматичного прогнозування має ключове значення.

Водночас аналіз літератури демонструє, що більшість робіт зосереджується на задачах бінарної класифікації (“відмова” / “немає відмови”), тоді як питання багатокласової класифікації типів відмов

залишається недостатньо дослідженим. Як зазначають Zhang et al. (2023), “визначення конкретного типу відмови може істотно підвищити ефективність планування ремонтних робіт, однак ця задача є значно складнішою через перекриття ознак між різними типами відмов” [7].

Отже, аналіз літературних джерел свідчить, що існує потреба у комплексних дослідженнях, які поєднують бінарну та багатокласову класифікацію, враховують вартісну чутливість помилок та застосовують методи пояснюваного машинного навчання. Саме ці аспекти визначають актуальність і наукову новизну нашої роботи.

Результати дослідження та їх обговорення / Research results and their discussion

Результати бінарної класифікації

На першому етапі дослідження виконано навчання моделей для задачі бінарної класифікації (Machine Failure vs. No Failure).

Серед базових алгоритмів найкращі результати показала модель XGBoost, яка досягла значення PR-AUC = 0,64 на валідаційній вибірці, що перевищує результати Random Forest (0,59) та Logistic Regression (0,41). Це підтвердило доцільність використання бустингових методів у задачах прогнозного технічного обслуговування [3,4].

Додатково виконано оптимізацію порога класифікації з урахуванням функції вартості:

$$C = C_{FN} \cdot FN + C_{FP} \cdot FP,$$

де $C_{FN} = 10$ – вартість пропущеної відмови; $C_{FP} = 1$ – вартість хибного спрацювання. Найкращий поріг $t^* = 0.0455$ дав змогу зменшити кількість пропущених відмов (FN) до 17 випадків за 176 хибних тривог (FP).




Рис. 1. Крива Precision-Recall для моделі XGBoost (бінарна класифікація) / Precision-Recall curve for XGBoost model (binary classification)

Оптимізація ансамблю моделей

З метою підвищення точності реалізовано ансамблювання XGBoost та LightGBM за допомогою усереднення ймовірностей (*blending*). Результати наведено у табл. 1.

Табл. 1. Порівняння PR-AUC різних моделей (бінарна класифікація / Comparison of PR-AUC scores for different models (binary-classification)

Модель / Model	PR-AUC	Cost-optimal FN	Cost-optimal FP	Recall@ P $\geq$ 0.90
XGBoost	0,9012	11	31	0,61
LightGBM	0,8677	14	36	0,58
Blend (XGB+LGB)	0,8897	7	18	0,68

Результати демонструють, що ансамбль забезпечує кращий баланс між кількістю пропущених відмов та хибними спрацюваннями, ніж кожна окрема модель. Зокрема, у результаті оптимізації порога за функцією вартості Blend-модель знизила кількість пропущених відмов до семи, забезпечивши високий рівень точності.




Рис. 2. Confusion matrix для ансамблю XGBoost+LightGBM (бінарна класифікація) / Confusion matrix for XGBoost+LightGBM blend (binary classification)

Результати багатокласової класифікації

На другому етапі реалізовано **багатокласову класифікацію** для прогнозування не лише факту відмови, але й типу поломки (*Failure Type*). Було протестовано три моделі: Random Forest, XGBoost, LightGBM.

Показники точності наведено у табл. 2.

З отриманих результатів можна зробити висновок, що XGBoost забезпечує найкращий компроміс між високою загальною точністю та стабільністю на рідкісних класах (OSF, HDF). Однак для класу TWF (Tool Wear Failure) усі моделі показують низькі результати через невелику кількість прикладів у датасеті, що підтверджує потребу у балансуванні вибірки [5,7].

Табл. 2. Результати багатокласової класифікації (macro-avg F1) / Results of multiclass classification (macro-avg F1)

Модель / Model	Accuracy	Macro F1	Особливості результатів
Random Forest	0,959	0,733	добрі результати для класів 1-3, але низька точність для класу 4
XGBoost	0,986	0,754	висока точність для рідкісних класів (2,3), але слабкі результати для класу 4
LightGBM	0,973	0,701	проблеми з поділом на малих класах через відсутність gain у сплітах




Рис. 3. Confusion matrix для моделі XGBoost (багатокласова класифікація) / Confusion matrix for XGBoost model (multiclass classification)

Обговорення результатів дослідження. Результати багатокласової класифікації показали, що моделі здатні розпізнавати не лише сам факт відмови, але й конкретний тип поломки, проте якість прогнозів істотно залежить від вибраного алгоритму:

Random Forest досяг високої точності на основному класі *No Failure* (0), проте мав проблеми з рідкісними відмовами. Особливо слабким виявилось розпізнавання класу *Tool Wear Failure* (4), де recall був низьким, але несподівано високий recall спостерігався завдяки надмірній кількості FP.

XGBoost продемонстрував найкращий загальний баланс: macro-F1 $\approx$ 0,75, найвищий серед моделей. Він зумів краще розпізнавати рідкісні класи (*Overstrain Failure*, *Heat Dissipation Failure*), хоча для *Tool Wear Failure* (4) якість залишилась низькою через невелику кількість прикладів.

LightGBM знову зіткнувся з технічними труднощами (“no positive gain”), що обмежило його результативність. Це свідчить про чутливість алгоритму до дисбалансу класів та параметрів побудови бінів.

У підсумку, XGBoost підтвердив свою стійкість і здатність працювати із дисбалансованими багатокласовими даними, тоді як Random Forest можна використовувати як швидкий базовий орієнтир. LightGBM у цьому

випадку потребує додаткових налаштувань або збільшення вибірки для стабільної роботи.

Отже, подальший аналіз зосереджуватиметься переважно на XGBoost як найкращому кандидату для мультикласової задачі, а також на додаткових методах балансування даних, щоб поліпшити якість прогнозів для рідкісних типів поломок.

Наукова новизна отриманих результатів дослідження – у цій роботі вперше для задачі прогнозування технічного стану виробничого обладнання виконано комплексний аналіз моделей XGBoost, LightGBM та Random Forest у контексті cost-sensitive навчання. Запропоновано підхід, який поєднує оптимізацію порога класифікації за функцією вартості помилок та оцінювання моделі за метрикою PR-AUC, що є інформативнішою для незбалансованих даних. Наукова новизна роботи полягає у застосуванні cost-sensitive оптимізації для підвищення точності виявлення критичних відмов без істотного збільшення кількості хибних тривог; інтеграції time-aware розподілу вибірки для підвищення достовірності моделювання в умовах часової залежності даних; порівняльному аналізу ансамблевих моделей (XGBoost, LightGBM, Random Forest) із визначенням їх придатності для прогнозування відмов різних типів; розробленні процедури вибору оптимального порога класифікації на основі мінімізації функції витрат, що враховує різну вартість помилок типів I та II; демонстрації ефективності багатокласової класифікації відмов з метою не лише прогнозування факту несправності, але й визначення її типу.

Практична значущість результатів дослідження – отримані результати дають змогу точніше прогнозувати технічні збої та оптимізувати процеси технічного обслуговування, що робить запропонований підхід перспективним для впровадження у промислових системах моніторингу.

Висновок / Conclusions

У дослідженні виконано системний аналіз підходів до прогнозування технічних відмов обладнання на основі відкритого набору даних AI4I Predictive Maintenance. Основну увагу приділено порівнянню сучасних алгоритмів машинного навчання з урахуванням дисбалансу класів. Показано, що базові моделі (логістична регресія, випадковий ліс) забезпечують прийнятну якість, однак значно поступаються ансамблевим методам. Найкращий результат продемонстрував XGBoost, досягши значення $PR-AUC \approx 0,90$, що перевищує інші алгоритми. Запропоновано застосування time-aware / group split для уникнення витоку інформації та відтворення реальних експлуатаційних умов. Це дало змогу отримати коректнішу оцінку узагальнювальної здатності моделей. Додатково було реалізовано підхід cost-sensitive thresholding, що враховує різну вартість помилок першого та другого типів. Оптимізація порога класифікації дала можливість істотно зменшити кількість критично небезпечних пропусків відмов, що є ключовим у сфері технічного обслу-

говування. Задачу розширено до багатокласової класифікації, де моделі прогнозували не лише факт відмови, а і її тип. Це дає змогу використовувати прогнозні результати для детальнішої діагностики та вибору адекватних профілактичних дій. Незважаючи на високі результати, залишаються виклики, пов'язані з нечисленністю окремих класів відмов (наприклад, Tool Wear Failure), що ускладнює їх точну ідентифікацію. Подальші дослідження можуть бути спрямовані на використання методів генерації синтетичних даних та глибоких нейронних мереж. Отримані результати підтверджують доцільність використання ансамблевих алгоритмів, оптимізації порогів та розширення формулювання задачі для підвищення надійності систем технічного обслуговування.

References

1. Ahmed, N., Aljahdali, H. M., & Siddiqui, M. H. (2021). Predictive maintenance using machine learning for industrial machinery: A survey. *Journal of King Saud University – Computer and Information Sciences*, 33(10), 1189-1201. <https://doi.org/10.1016/j.jksuci.2021.01.007>
2. Zonta, T., da Costa, C. A., da Rosa Righi, R., de Lima, M. J., da Trindade, E. S., & Li, G. P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering*, 150, 106889. <https://doi.org/10.1016/j.cie.2020.106889>
3. Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). ACM. <https://doi.org/10.1145/2939672.2939785>
4. Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T. Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30, 3146-3154. <https://papers.nips.cc/paper/2017/hash/6449f44a102fde848669bdd9eb6b76fa-Abstract.html>
5. Haque, M. A., Hasan, M. K., Islam, S., & Alhumyani, H. (2022). Handling imbalanced data in machine learning: A survey. *Knowledge-Based Systems*, 248, 108759. <https://doi.org/10.1016/j.knosys.2022.108759>
6. Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems* (pp. 4765-4774). Curran Associates Inc. <https://doi.org/10.48550/arXiv.1705.07874>
7. Zhang, H., Zhao, R., Wang, J., & Li, X. (2023). Multi-failure mode prediction in predictive maintenance: A deep learning approach. *Reliability Engineering & System Safety*, 232, 109032. <https://doi.org/10.1016/j.ress.2023.109032>
8. Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., Francisco, R. P., Basto, J. P., & Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
9. Zhang, C., Xu, X., Wang, J., & Zhong, R. Y. (2022). Data-driven predictive maintenance for complex equipment: A review. *Engineering Applications of Artificial Intelligence*, 109, 104653. <https://doi.org/10.1016/j.engappai.2021.104653>
10. Tuli, S., Casale, G., & Jennings, N. R. (2022). TranAD: Deep transformer networks for anomaly detection in multivariate time series data. *Proceedings of the VLDB Endowment*, 15(6), 1201-1214. <https://doi.org/10.14778/3514061.3514067>

PREDICTION OF INDUSTRIAL EQUIPMENT CONDITION USING COST-SENSITIVE APPROACHES AND CLASSIFICATION THRESHOLD OPTIMIZATION

This paper presents a comprehensive study on the application of modern machine learning methods for predictive maintenance based on the open AI4I Predictive Maintenance dataset. The primary goal of the research is to develop and compare both binary and multiclass classification models that enable not only the prediction of machine failures but also the identification of specific failure types. Considering the strong class imbalance (failures account for approximately 3 % of the dataset), a cost-sensitive optimization approach was implemented, where false negatives (missed failures) were penalized much more heavily than false positives (false alarms).

The models investigated in this study include Logistic Regression, Random Forest, XGBoost, and LightGBM, with a particular focus on ensemble gradient boosting methods. Data preprocessing steps encompassed feature scaling, categorical encoding, and feature engineering, including the creation of new features such as Power, DeltaTemp, and a binary indicator of excessive tool wear. For binary classification, model performance was evaluated using the PR-AUC metric and Recall@Precision ≥ 0.90 , both of which are critical in safety-related domains. For multiclass classification, performance was assessed using confusion matrices and macro-averaged precision, recall, and F1-score.

The experimental results demonstrated that among the baseline models, XGBoost achieved the best performance with PR-AUC=0.64, and after hyperparameter optimization, the score improved significantly to over 0.90, confirming its strong ability to detect failures. In the multiclass setup, XGBoost again outperformed other models, providing better balance across classes, while LightGBM faced challenges due to "no further splits with positive gain" warnings under restrictive parameter settings. Feature importance analysis using SHAP values highlighted the dominant role of Tool wear, Power, and Rotational speed in predicting failures.

The practical contribution of this work lies in the demonstrated potential of machine learning models for early failure detection and proactive maintenance planning, enabling significant cost savings and operational reliability improvements. The study also emphasizes the effectiveness of combining cost-sensitive optimization with ensemble methods and establishes a foundation for future research directions, including time-to-failure regression and the use of deep neural networks.

Keywords: predictive maintenance, machine learning, XGBoost, LightGBM, cost-sensitive classification, SHAP analysis.

Інформація про авторів:

Грабовенський Теодор Романович, магістр кафедри систем штучного інтелекту.

Email: teodor.hrabovenskyi.mknssh.2024@lpnu.ua; <https://orcid.org/0009-0006-9360-7021>

Ляковська Соломія Євгенівна, канд. техн. наук, доцент кафедри систем штучного інтелекту.

Email: solomiya.y.liaskovska@lpnu.ua; <https://orcid.org/0000-0002-0822-0951>

Мартин Євген Володимирович, д-р техн. наук, професор кафедри інформаційних технологій та електронних комунікаційних систем.

Email: evmartun@gmail.com; <https://orcid.org/0000-0001-9095-7057>

Цитування за ДСТУ: Грабовенський Т. Р., Ляковська С. Є., Мартин Є. В. Прогнозування технічного стану виробничого обладнання із застосуванням cost-sensitive підходів та оптимізації порогів класифікації. *Український журнал інформаційних технологій*. 2025, т. 7, № 2. С. 100-105.

Citation APA: Hrabovenskyi, T. R., Liaskovska, S. Ye., & Martyn, Y. V. (2025). Prediction of industrial equipment condition using cost-sensitive approaches and classification threshold optimization. *Ukrainian Journal of Information Technology*, 7(2), 100-105. <https://doi.org/10.23939/ujit2025.02.100>