

## **ВИКОРИСТАННЯ АЛГОРИТМІВ МАШИННОГО НАВЧАННЯ ДЛЯ ДІАГНОСТИКИ СИСТЕМ КЕРУВАННЯ РУХОМИМ ОБЛАДНАННЯМ**

***О. В. Третьак, аспірант***

***Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського»***

*E-mail:* [tov-vp-pbf21@lil.kpi.ua](mailto:tov-vp-pbf21@lil.kpi.ua)

**Анотація.** Досліджується застосування алгоритмів машинного навчання для автоматизованої діагностики систем керування рухомим обладнанням. Актуальність роботи зумовлена зростаючою складністю систем керування, де відмова окремих компонентів може призводити до значних економічних втрат та загроз безпеці. В умовах сучасного промислового виробництва та транспорту необхідність створення автоматизованих рішень для моніторингу технічного стану є особливо важливою.

Метою дослідження є розробка та впровадження методів машинного навчання для підвищення ефективності виявлення та прогнозування відмов у системах керування. Завдання роботи включають створення моделей на основі глибоких нейронних мереж, їх тренування на даних про роботу систем керування та оцінку їхньої продуктивності.

Аналіз даних роботи систем керування, отриманих із сенсорів рухомого обладнання, створення та тестування моделей машинного навчання беруться за методи дослідження. Для експериментів використовувалися дані з відкритих джерел та синтетично згенеровані набори. Основними інструментами були нейронні мережі типу LSTM та CNN, які реалізовано у фреймворках TensorFlow та PyTorch. Дослідження проводилося з використанням обчислювальних кластерів для пришвидшення тренувань.

Результати дослідження показали, що використання машинного навчання дозволяє досягти високої точності діагностики технічного стану. Наприклад, моделі LSTM забезпечили точність прогнозування відмов до 95 %, тоді як CNN ефективно визначали аномалії в реальному часі. Проведено порівняльний аналіз із класичними методами машинного навчання, який продемонстрував переваги глибоких нейронних мереж у швидкості адаптації до нових даних та стійкості до шуму. Водночас основними викликами залишаються потреба у великих обсягах даних для тренування моделей та забезпечення їхньої енергетичної ефективності під час використання в реальних умовах.

**Ключові слова:** машинне навчання, діагностика систем керування, нейронні мережі, прогнозування відмов, автоматизація обслуговування

**Актуальність.** Системи керування рухомих обладнання є невід'ємною частиною сучасного транспорту, промислових механізмів і роботизованих установок. Зростання складності систем, інтенсифікація їх експлуатації та підвищення вимог до надійності створюють виклики у їхньому обслуговуванні. Відмова окремих компонентів таких систем може призводити до значних економічних втрат, зниження ефективності роботи виробничих процесів і, у деяких випадках, загрожувати безпеці людей.

Нинішні підходи до технічного обслуговування часто базуються на періодичних перевірках або ручному аналізі даних, що обмежує їхню ефективність і не дозволяє оперативно реагувати на потенційні відмови. У цьому контексті автоматизація діагностики та прогнозування стану систем керування є важливим напрямом досліджень.

Останні досягнення у сфері машинного навчання, зокрема машинного навчання, відкривають нові можливості для аналізу великих обсягів даних, отриманих із сенсорів рухомого обладнання. Застосування глибоких нейронних мереж дозволяє автоматично виявляти аномалії, розпізнавати приховані закономірності та прогнозувати можливі відмови з високою точністю. Це забезпечує значне підвищення якості обслуговування систем керування, мінімізуючи ризики і витрати.

Таким чином, дослідження, спрямовані на впровадження алгоритмів машинного навчання для діагностики систем керування рухомих обладнання, мають важливе наукове і практичне значення, особливо в умовах цифровізації виробництва та зростання попиту на розумні технічні системи.

**Аналіз останніх досліджень та публікацій.** В останні роки дослідники приділяють увагу питанням автоматизації діагностики технічних систем на основі машинного навчання. Один із ключових напрямів – застосування машинного навчання, що дозволяє ефективно аналізувати великі обсяги даних і вирішувати завдання прогнозування відмов.

У роботах [1–3] представлено використання рекурентних нейронних мереж (LSTM) для аналізу часових рядів із сенсорів рухомого обладнання. Дослідження

демонструють високу точність прогнозування технічного стану, однак вони вимагають великої обчислювальної потужності, що обмежує їх застосування в реальному часі.

У дослідженнях [4–6] розглядається використання згорткових нейронних мереж (CNN) для виявлення аномалій у роботі систем керування. Вказані моделі показали високу ефективність у розпізнаванні патернів у сигналах, отриманих із сенсорів, але вони менш адаптивні до зміни умов експлуатації.

Поєднання класичних методів машинного навчання описано у [7–10], таких як метод опорних векторів (SVM) і градієнтний бустинг, із глибоким навчанням. Вони дозволяють збільшити точність діагностики завдяки інтеграції переваг різних методів, однак така комбінація ускладнює інтерпретацію результатів і збільшує час обробки даних.

Попри значні досягнення в галузі, залишається низка невирішених питань. Зокрема, більшість існуючих досліджень орієнтовані на окремі аспекти діагностики, такі як виявлення аномалій чи прогнозування відмов, тоді як інтегровані рішення для комплексної діагностики залишаються недостатньо розробленими. Крім того, питання пояснюваності моделей машинного навчання та їх адаптація до нових умов експлуатації вимагають подальшого вивчення.

Тож, можна спробувати покращити існуючі або розробити універсальні методи автоматизації діагностики, які враховують як ефективність, так і адаптивність до змінних умов експлуатації.

**Мета дослідження** – розробка ефективного підходу до автоматизованої діагностики систем керування рухомих обладнанням на основі машинного навчання, зокрема шляхом інтеграції моделей згорткових нейронних мереж (CNN) та довготривалої пам'яті (LSTM).

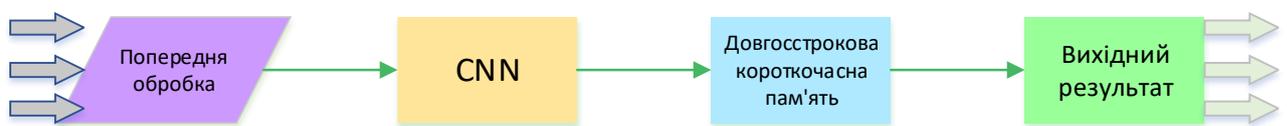
Такі дії допоможуть прогнозувати залишковий ресурс обладнання та виявляти потенційні відмови на ранніх етапах. Таким чином, треба розробити методіку інтеграції моделей CNN-LSTM для аналізу багатовимірних даних із сенсорів рухомого обладнання, після чого оцінити ефективність запропонованого підходу на основі тестування на реальних та симуляційних даних; провести порівняння

запропонованого підходу за такими критеріями, як точність, швидкість обчислень та адаптивність до змінних умов.

**Матеріали та методи дослідження.** Використаємо реальні й синтетичні набори даних для аналізу технічного стану обладнання. Дані охоплюють параметри роботи систем, зібрані з багатоканальних сенсорів (вібраційні, температурні, електричні сигнали) для моніторингу рухомого обладнання.

У якості реального датасету візьмемо набір даних прогнозованого технічного обслуговування, що містить параметри роботи обладнання (температура, вібрація, потужність). Симуляційні дані будуть згенеровані на основі моделей фізичних процесів, які враховуватимуть різні сценарії експлуатації.

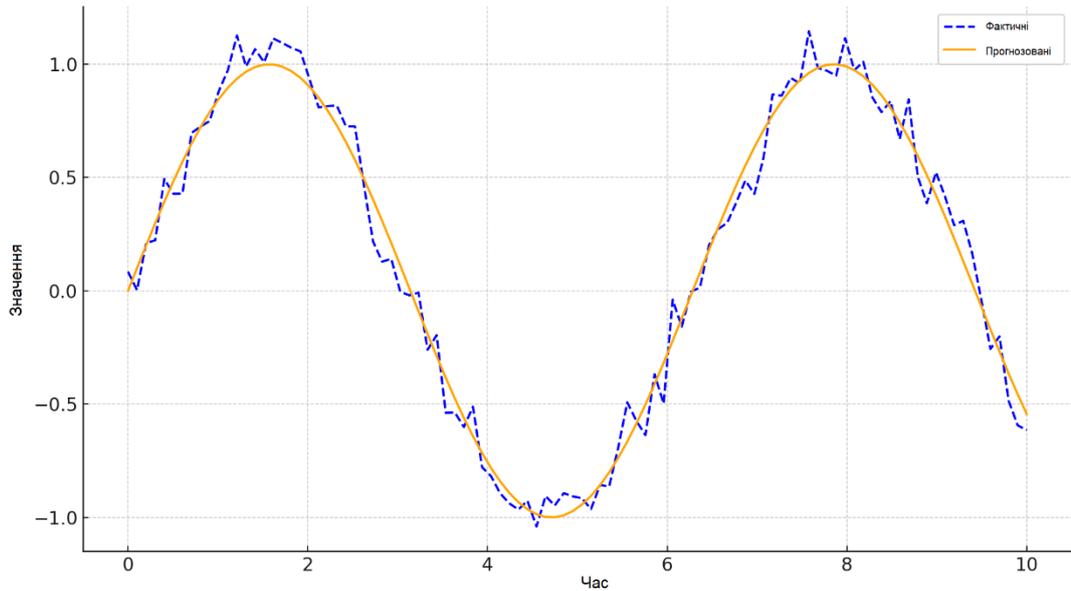
Для діагностики зробимо інтегровану модель CNN-LSTM (рис.1). CNN використовується для автоматичного виділення ключових характеристик із сигналів, LSTM (довгострокова пам'ять) – для обробки часових рядів і врахування довгострокових залежностей у даних. Відпрацювання відбувається у декілька етапів:



**Рис. 1. Етапи роботи системи моделі CNN-LSTM**

– Попередня обробка даних – нормалізація, усунення шумів та вибір релевантних ознак (рис.2). На вхід отримуються багатоканальні сенсорні сигнали: вібрація, температура, електричні параметри – та готуються до подальшої обробки.

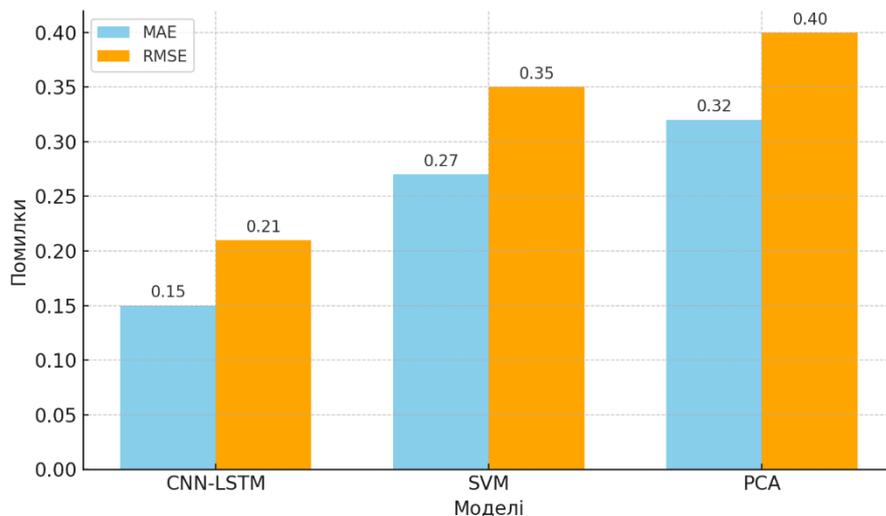
– Навчання моделей. Складається із згорткових шарів, які виділяють локальні особливості сигналу, шарів активації для нелінійного представлення, та шарів зниження розмірності. Цей етап реалізовано в середовищі Python із використанням бібліотек TensorFlow та PyTorch.



**Рис. 2. Часові ряди фактичних та прогнозованих значень**

– Блок довготривалої пам'яті відповідає за аналіз часових залежностей у даних, дозволяючи враховувати довготривалі зв'язки.

– Оцінка ефективності. Оцінюється точність прогнозування, швидкість обчислень, адаптивність до нових даних з використанням метрик середньої абсолютної похибки, середньоквадратичної похибки (рис.3). На виході отримуємо прогноз залишкового ресурсу або виявляємо відхилення у стані обладнання.



**Рис. 3. Порівняння абсолютної середньої (MAE) та середньоквадратичної похибки (RMSE) для різних моделей**

**Результати досліджень та їх обговорення.** Результати порівняння абсолютної середньої та середньоквадратичної похибки показали, що модель CNN-LSTM забезпечує значно нижчі значення помилок порівняно з іншими підходами. Це свідчить про її здатність більш точно передбачати залишковий ресурс обладнання. Тестування моделі CNN-LSTM показали її високу ефективність у порівнянні з класичними методами, такими як метод опорних векторів (SVM) та метод головних компонент [8] (PCA). Модель CNN-LSTM забезпечує мінімальні значення метрик абсолютної середньої (0,15) та середньоквадратичної (0,21) похибок, що значно перевищує показники інших методів. Для методу опорних векторів абсолютна середня похибка становить 0,27, а середньоквадратична – 0,35, тоді як для методу головних компонент ці показники ще вищі — абсолютна середня 0,32 і середньоквадратична 0,40. Ці результати свідчать про здатність моделі більш точно прогнозувати залишковий ресурс обладнання.

Незважаючи на високу точність, модель може потребувати оптимізації для роботи з великими обсягами даних або для обробки складних багатоканальних сигналів із високою кореляцією.

Фактичні значення залишкового ресурсу містять невеликий рівень шуму, притаманного реальним сенсорним даним, тоді як прогнозовані значення повторюють загальні тренди з високим рівнем точності. Це підкреслює здатність моделі ефективно обробляти багатоканальні сенсорні дані та враховувати їх часові залежності. Модель CNN-LSTM може поєднувати можливості згорткових нейронних мереж для обробки просторових залежностей з рекурентними мережами, які ефективно аналізують часові характеристики. Варто зазначити, що точність моделі залежить від якості вхідних даних, і надмірний шум може негативно вплинути на результати. Подальша оптимізація архітектури та розширення набору навчальних даних дозволять покращити її продуктивність у реальних умовах експлуатації.

**Висновки і перспективи.** CNN-LSTM поєднує можливості згорткових шарів для обробки просторових залежностей та рекурентних шарів для аналізу часових характеристик. Модель можна використовувати для обробки багатоканальних

сенсорних даних. Гнучкість архітектури дозволяє адаптувати її для різних сценаріїв експлуатації та типів обладнання.

Модель здатна покращити ефективність прогнозування та дозволяє своєчасно виявляти потенційні збої в роботі обладнання. Це сприяє зниженню експлуатаційних витрат і підвищенню безпеки. Але на даний момент модель протестована на відносно невеликому наборі даних, що може обмежувати її узагальнюваність. Для впровадження у реальних умовах можуть бути потрібні оптимізації, які зменшать ресурсоємність моделі.

Таким чином, запропонований підхід із використанням архітектури CNN-LSTM демонструє значні переваги у задачах прогнозування стану обладнання. Висока точність, гнучкість та відповідність сучасним вимогам роблять цей метод доцільним для впровадження у системи автоматизованого обслуговування. Подальше дослідження моделі та її адаптація під специфічні умови експлуатації в подальшому дозволять розширити її застосування.

### **Список використаних джерел**

1. Maurice Artelt Hybrid Approaches and Datasets for Remaining Useful Life Prediction: A Review. *Procedia CIRP*. 2024. Т. 130. С. 294–300. URL: <https://doi.org/10.1016/j.procir.2024.10.090>.
2. Bruneo D., De Vita F. On the Use of LSTM Networks for Predictive Maintenance in Smart Industries. 2019 IEEE International Conference on Smart Computing (SMARTCOMP). 2019. С. 241–248. DOI: 10.1109/SMARTCOMP.2019.00059.
3. Chen X. A novel gear RUL prediction method by diffusion model generation health index and attention guided multi-hierarchy LSTM. *Scientific Reports*. 2024. Т. 14, №1. URL: <https://doi.org/10.1038/s41598-024-52151-y>.
4. Mirlekar S., Kanojia K. P., Chourasia B. A Stacked CNN-BiLSTM Model with Majority Technique for Detecting the Intrusions in Network. *International Journal of Intelligent Systems and Applications in Engineering*. 2024. № 12(5s). С. 152–162.
5. Traini E., Bruno G., Lombardi F. Design of a Physics-Based and Data-Driven Hybrid Model for Predictive Maintenance. *IFIP Advances in Information and Communication Technology*. 2021. С. 536–543. URL: [https://doi.org/10.1007/978-3-030-85914-5\\_57](https://doi.org/10.1007/978-3-030-85914-5_57).
6. Shcherbakov M., Sai C. A hybrid deep learning framework for intelligent predictive maintenance of Cyber-Physical Systems. *ACM Transactions on Cyber-Physical Systems*. 2022. С. 1–22. URL: <https://doi.org/10.1145/3486252>.

7. Chen C., та ін. The advance of digital twin for predictive maintenance: The role and function of machine learning *Journal of Manufacturing Systems*. 2023. Т. 71. С. 581–594. URL: <https://doi.org/10.1016/j.jmsy.2023.10.010>.

8. Serradilla O., та ін. Deep learning models for predictive maintenance: a survey, comparison, challenges and prospect.s *Applied Intelligence*. 2022. URL: <https://doi.org/10.1007/s10489-021-03004-y>.

9. Lu L., Zhang C., Cao K., Deng T., Yang Q. A Multichannel CNN-GRU Model for Human Activity Recognition. *IEEE Access*. 2022. Т. 10. С. 66797–66810. DOI: 10.1109/ACCESS.2022.3185112.

10. Meriem H., Nora H., Samir O. Predictive Maintenance for Smart Industrial Systems: A Roadmap. *Procedia Computer Science*. 2023. Т. 220. С. 645–650. URL: <https://doi.org/10.1016/j.procs.2023.03.082>.

### References

1. Artelt, M., et al. (2024). Hybrid Approaches and Datasets for Remaining Useful Life Prediction: A Review. *Procedia CIRP*, 130, 294–300. Available at: <https://doi.org/10.1016/j.procir.2024.10.090>

2. Bruneo, D., & De Vita, F. (2019). On the Use of LSTM Networks for Predictive Maintenance in Smart Industries. 2019 *IEEE International Conference on Smart Computing (SMARTCOMP)*, 241–248. Available at: <https://doi.org/10.1109/SMARTCOMP.2019.00059>

3. Chen, X. (2024). A novel gear RUL prediction method by diffusion model generation health index and attention guided multi-hierarchy LSTM. *Scientific Reports*, 14(1). Available at: <https://doi.org/10.1038/s41598-024-52151-y>

4. Mirlekar, S., Kanojia, K. P., & Chourasia, B. (2024). A Stacked CNN-BiLSTM Model with Majority Technique for Detecting the Intrusions in Network. *International Journal of Intelligent Systems and Applications in Engineering*, 12(5s), 152–162.

5. Traini, E., Bruno, G., & Lombardi, F. (2021). Design of a Physics-Based and Data-Driven Hybrid Model for Predictive Maintenance. *IFIP Advances in Information and Communication Technology*, 536–543. Available at: [https://doi.org/10.1007/978-3-030-85914-5\\_57](https://doi.org/10.1007/978-3-030-85914-5_57)

6. Shcherbakov, M., & Sai, C. (2022). A hybrid deep learning framework for intelligent predictive maintenance of Cyber-Physical Systems. *ACM Transactions on Cyber-Physical Systems*, 1–22. Available at: <https://doi.org/10.1145/3486252>

7. Chen, C., et al. (2023). The advance of digital twin for predictive maintenance: The role and function of machine learning. *Journal of Manufacturing Systems*, 71, 581–594. Available at: <https://doi.org/10.1016/j.jmsy.2023.10.010>

8. Serradilla, O., et al. (2022). Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects. *Applied Intelligence*. Available at: <https://doi.org/10.1007/s10489-021-03004-y>

9. Lu, L., Zhang, C., Cao, K., Deng, T., & Yang, Q. (2022). A Multichannel CNN-GRU Model for Human Activity Recognition. *IEEE Access*, 10, 66797–66810. Available at: <https://doi.org/10.1109/ACCESS.2022.3185112>

10. Meriem, H., Nora, H., & Samir, O. (2023). Predictive Maintenance for Smart Industrial Systems: A Roadmap. *Procedia Computer Science*, 220, 645–650. Available at: <https://doi.org/10.1016/j.procs.2023.03.082>

## **USING MACHINE LEARNING ALGORITHMS FOR DIAGNOSTICS OF MOVING EQUIPMENT CONTROL SYSTEMS**

*O. Tretiak*

**Abstract.** *The article investigates the application of machine learning algorithms for automated diagnostics of mobile equipment control systems. The relevance of the work is due to the growing complexity of control systems, where the failure of individual components can lead to significant economic losses and safety threats. In the conditions of modern industrial production and transport, the need to create automated solutions for monitoring the technical condition is especially important.*

*The purpose of the research is to develop and implement machine learning methods to increase the efficiency of detecting and predicting failures in control systems. The tasks of the work include creating models based on deep neural networks, training them on data about the operation of control systems, and assessing their performance.*

*Analysis of control system operation data obtained from mobile equipment sensors, creation and testing of machine learning models are taken as research methods. Open source data and synthetically generated sets were used for experiments. The main tools were neural networks such as LSTM and CNN, which are implemented in the TensorFlow and PyTorch frameworks. The study was conducted using computing clusters to speed up training.*

*The results of the study showed that the use of machine learning allows achieving high accuracy in technical condition diagnostics. For example, LSTM models provided failure prediction accuracy of up to 95%, while CNN effectively identified anomalies in real time. A comparative analysis was conducted with classical machine learning methods, which demonstrated the advantages of deep neural networks in terms of speed of adaptation to new data and noise resistance. At the same time, the main challenges remain the need for large amounts of data for training models and ensuring their energy efficiency when used in real conditions.*

**Key words:** *machine learning, control system diagnostics, neural networks, failure prediction, maintenance automation*