

АНАЛІЗ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ ТЕХНІЧНОГО СТАНУ ОБЛАДНАННЯ

Вінницький національний технічний університет

Анотація

У роботі проведено аналіз основних методів машинного навчання, що застосовуються для прогнозування технічного стану промислового обладнання. Розглянуто класичні алгоритми машинного навчання, зокрема метод опорних векторів, випадковий ліс та градієнтний бустинг, а також методи глибокого навчання — рекурентні нейронні мережі, мережі довгої короткочасної пам'яті та згорткові нейронні мережі. Визначено переваги та обмеження кожного підходу в контексті задач прогнозного технічного обслуговування. Обґрунтовано перспективність гібридних підходів для підвищення точності прогнозування залишкового ресурсу обладнання.

Ключові слова: машинне навчання, прогнозування технічного стану, прогнозне обслуговування, залишковий ресурс, глибоке навчання, промислове обладнання.

Abstract

This paper analyzes the main machine learning methods used for predicting the technical condition of industrial equipment. Classical machine learning algorithms, including Support Vector Machines, Random Forest, and Gradient Boosting, as well as deep learning methods such as Recurrent Neural Networks, Long Short-Term Memory networks, and Convolutional Neural Networks, are considered. The advantages and limitations of each approach in the context of predictive maintenance tasks are identified. The prospects of hybrid approaches for improving the accuracy of equipment remaining useful life prediction are substantiated.

Keywords: machine learning, condition prediction, predictive maintenance, remaining useful life, deep learning, industrial equipment.

Вступ

Забезпечення безперебійної роботи промислового обладнання є одним із ключових завдань сучасного виробництва. Непередбачені відмови обладнання спричиняють значні фінансові втрати, пов'язані з незапланованими простоями, аварійними ремонтами та порушенням виробничих графіків. За оцінками дослідників, впровадження прогнозного обслуговування дозволяє скоротити витрати на обслуговування на 10–25% та зменшити кількість незапланованих зупинок на 25–30% [1].

Прогнозне технічне обслуговування (Predictive Maintenance, PdM) базується на безперервному моніторингу параметрів роботи обладнання та використанні аналітичних методів для оцінки його поточного стану та прогнозування можливих відмов. Ключовим показником у цій галузі є залишковий корисний ресурс (Remaining Useful Life, RUL) — прогнозований час, протягом якого обладнання може продовжувати працювати до настання відмови [2]. Точне прогнозування RUL дозволяє планувати обслуговування оптимальним чином, уникаючи як передчасної заміни справних компонентів, так і аварійних ситуацій.

З розвитком технологій Інтернету речей (IoT) та збільшенням обсягів даних, що генеруються промисловими сенсорами, методи машинного навчання стали основним інструментом для прогнозування технічного стану обладнання [3]. Метою даної роботи є аналіз та порівняння основних методів машинного навчання, що застосовуються для вирішення цієї задачі.

Класичні методи машинного навчання для прогнозування стану обладнання

Серед класичних алгоритмів машинного навчання, що широко застосовуються в задачах прогнозування технічного стану обладнання, слід виділити метод опорних векторів (Support Vector Machine, SVM), випадковий ліс (Random Forest, RF) та градієнтний бустинг (Gradient Boosting,

зокрема XGBoost).

Метод опорних векторів використовує побудову оптимальної гіперплощини для розділення класів у багатовимірному просторі ознак. У задачах прогнозного обслуговування SVM може застосовуватися як для класифікації (визначення, чи перебуває обладнання в нормальному або аномальному стані), так і для регресії (оцінка залишкового ресурсу). Перевагами SVM є ефективна робота з високовимірними даними та стійкість до перенавчання при обмеженому обсязі тренувальних даних. Водночас SVM потребує ретельного підбору параметрів ядра та погано масштабується на дуже великих наборах даних [4].

Випадковий ліс — це ансамблевий метод, що базується на побудові множини дерев рішень з подальшим агрегуванням їхніх прогнозів. Random Forest демонструє високу стійкість до шуму в даних, здатність працювати з різнотипними ознаками та можливість оцінки важливості окремих параметрів для прогнозування. Дослідження показують, що RF забезпечує точність виявлення аномалій на рівні 99% при аналізі даних промислових сенсорів [5]. Крім того, Random Forest дозволяє визначити значущість окремих ознак, що є цінним для інтерпретації результатів та розуміння факторів деградації обладнання.

Градієнтний бустинг, зокрема його реалізація XGBoost, є ще одним потужним ансамблевим методом, що послідовно будує дерева рішень, кожне з яких виправляє помилки попередніх. XGBoost відзначається високою точністю прогнозування та вбудованою регуляризацією, що запобігає перенавчанню. Цей метод успішно застосовується для оцінки RUL промислового обладнання, зокрема турбінних двигунів та виробничих ліній [6].

Методи глибокого навчання для прогнозування технічного стану

Методи глибокого навчання здатні автоматично виявляти складні нелінійні залежності в даних без необхідності ручного конструювання ознак, що робить їх особливо привабливими для аналізу багатовимірних часових рядів сенсорних даних [7].

Рекурентні нейронні мережі (Recurrent Neural Networks, RNN) призначені для обробки послідовних даних та мають здатність запам'ятовувати попередні стани, що є важливим для аналізу часових рядів параметрів обладнання. Однак стандартні RNN страждають від проблеми зникаючого градієнта, що обмежує їх здатність моделювати довгострокові залежності.

Мережі довгої короткочасної пам'яті (Long Short-Term Memory, LSTM) вирішують цю проблему завдяки спеціальній архітектурі з механізмами забування та оновлення інформації. LSTM ефективно захоплюють як короткострокові, так і довгострокові залежності в даних, що дозволяє моделювати поступовий процес деградації обладнання. Дослідження підтверджують високу ефективність LSTM для прогнозування RUL авіаційних двигунів та промислових підшипників [8].

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) традиційно використовуються для обробки зображень, але також демонструють ефективність при роботі з часовими рядами сенсорних даних. CNN здатні автоматично виділяти локальні просторові ознаки з багатоканальних сигналів датчиків, що дозволяє виявляти характерні патерни деградації компонентів обладнання [9].

Комбіновані архітектури, зокрема CNN-LSTM, поєднують переваги обох підходів: CNN відповідає за вилучення просторових ознак із багатоканальних сенсорних даних, тоді як LSTM моделює їхню часову динаміку. Такі гібридні моделі демонструють покращену точність прогнозування RUL порівняно з використанням кожного методу окремо [9].

Порівняльний аналіз та вибір методу

Вибір конкретного методу машинного навчання для прогнозування технічного стану обладнання залежить від низки факторів: обсягу та якості доступних даних, вимог до точності прогнозування, обчислювальних ресурсів та необхідності інтерпретації результатів.

Класичні методи, такі як Random Forest та XGBoost, доцільно використовувати при обмеженому обсязі даних, коли важлива інтерпретованість результатів та швидкість навчання моделі. Вони забезпечують достатню точність для багатьох практичних задач і не потребують значних обчислювальних ресурсів для тренування. SVM ефективний при роботі з високовимірними даними та невеликими вибірками [4].

Методи глибокого навчання, зокрема LSTM та гібридні архітектури CNN-LSTM, є перспективнішими при наявності великих обсягів сенсорних даних та складних нелінійних залежностях у процесах деградації. Однак вони потребують значних обчислювальних ресурсів та великих наборів даних для тренування, а також є менш інтерпретованими [10].

Перспективним напрямком є використання гібридних підходів, що поєднують класичні методи для попереднього відбору ознак з глибокими нейронними мережами для кінцевого прогнозування. Такий комбінований підхід дозволяє досягти балансу між точністю прогнозування, інтерпретованістю та ефективністю використання обчислювальних ресурсів.

Висновки

Проведений аналіз показав, що кожна група методів машинного навчання має свої переваги та обмеження у задачах прогнозування технічного стану обладнання. Класичні методи (SVM, Random Forest, XGBoost) забезпечують високу інтерпретованість та ефективність при обмежених даних, тоді як методи глибокого навчання (LSTM, CNN, гібридні архітектури) здатні виявляти складні приховані закономірності у великих обсягах сенсорних даних.

Для задач прогнозного обслуговування промислового обладнання в рамках концепції Індустрії 4.0 найбільш перспективними є гібридні підходи, що поєднують переваги класичних та глибоких методів. Подальші дослідження будуть спрямовані на розробку та експериментальну перевірку гібридної моделі прогнозування технічного стану обладнання на основі реальних даних промислових сенсорів.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Carvalho T. P., Soares F. A., Vita R., Francisco R., Basto J., Alcalá S. A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, vol. 137, 2019. DOI: 10.1016/j.cie.2019.106024.
2. Ferreira C., Gonçalves G. Remaining useful life prediction and challenges: a literature review on the use of machine learning methods. *Journal of Manufacturing Systems*, vol. 63, pp. 550–562, 2022. DOI: 10.1016/j.jmsy.2022.05.010.
3. Zonta T., da Costa C. A., da Rosa Righi R., de Lima M. J., da Trindade E. S., Li G. P. Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering*, vol. 150, 2020. DOI: 10.1016/j.cie.2020.106889.
4. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd ed. Springer, 2009. 745 p.
5. Pejić Bach M., Topalović A., Krstić Ž., Iveć A. Predictive Maintenance in Industry 4.0 for the SMEs: A Decision Support System Case Study Using Open-Source Software. *Designs*, vol. 7, no. 4, 2023. DOI: 10.3390/designs7040098.
6. Nikolaou P., Madhusudanan N., Toska E., Adams S. Remaining useful lifetime prediction for predictive maintenance in manufacturing. *Computers & Industrial Engineering*, vol. 184, 2023. DOI: 10.1016/j.cie.2023.109592.
7. Bengio Y., Goodfellow I., Courville A. *Deep Learning*. The MIT Press, 2016. 800 p.
8. Zhou J., Qin Y., Chen J., Liu Q., Qian Q., Xiang L., Zhu F. Remaining useful life prediction of machine based on deep learning: a comprehensive survey. *Measurement Science and Technology*, vol. 35, no. 6, 2024. DOI: 10.1088/1361-6501/ad2bcc.
9. Li X., Wang L., Wang C. et al. A method for predicting remaining useful life using enhanced Savitzky-Golay filter and improved deep learning framework. *Scientific Reports*, vol. 14, 2024. DOI: 10.1038/s41598-024-74989-y.
10. Hector I., Panjanathan R. Predictive maintenance in Industry 4.0: a survey of planning models and machine learning techniques. *PeerJ Computer Science*, vol. 10, 2024. DOI: 10.7717/peerj-cs.2016.

Пакула Антон Артурович – студент групи 174-23а, факультет інтелектуальних інформаційних технологій та автоматизації, Вінницький національний технічний університет, Вінниця, e-mail: anton.pakula.2000@gmail.com

Гармаш Володимир Володимирович – к.т.н., доцент кафедри програмного забезпечення, Вінницький національний технічний університет, Вінниця, e-mail: garmash.v.v@vntu.edu.ua

Pakula Anton Arturovych – student of group 174-23a, Faculty of Intelligent Information Technologies and Automation, Vinnytsia National Technical University, Vinnytsia, e-mail: anton.pakula.2000@gmail.com

Harmash Volodymyr Volodymyrovych – Ph.D., Associate Professor of the Department of Software Engineering, Vinnytsia National Technical University, Vinnytsia, e-mail: garmash.v.v@vntu.edu.ua