

УДК 004.8'231:629.113:355/359

DOI <https://doi.org/10.32782/tnv-tech.2025.2.18>

ТЕХНОЛОГІЇ МАШИННОГО НАВЧАННЯ В ПРОГНОЗУВАННІ ОБСЛУГОВУВАННЯ ДВИГУНІВ АВТОТРАНСПОРТУ У ВІЙСЬКОВІЙ ЛОГІСТИЦІ

Савка А. Я. – аспірант Національного університету «Львівська політехніка»

ORCID ID: 0009-0004-9198-6713

У цьому дослідженні розглянуто перспективи впровадження технологій штучного інтелекту (ШІ) у сферу технічного обслуговування транспорту логістики, що використовується у збройних силах. Сучасні виклики військової логістики вимагають високої надійності, швидкості реагування та максимальної готовності техніки до виконання завдань у різноманітних умовах. У зв'язку з цим особливого значення набувають підходи до прогностичного обслуговування, які дозволяють виявляти потенційні несправності ще до їхнього фактичного виникнення. На відміну від традиційних методів, які ґрунтуються на регламентному підході або реагуванні на вже наявні поломки, прогностичне обслуговування використовує можливості машинного навчання для аналізу великих обсягів сенсорних даних у реальному часі. Це створює умови для формування гнучких, динамічних і більш ефективних стратегій експлуатації техніки. Транспорт логістики, що є ключовою складовою тилового забезпечення – транспортування боєприпасів, пального, продовольства, техніки та особового складу – має бути не лише функціональним, а й максимально доступним для використання у будь-який момент. У цьому контексті застосування ШІ дозволяє мінімізувати ризики раптових відмов і зменшити навантаження на ремонтні підрозділи. Крім того, автоматизовані системи аналізу технічного стану забезпечують підвищення точності прогнозів, що, своєю чергою, покращує планування місій та логістичних операцій. Однак інтеграція ШІ в оборонну інфраструктуру супроводжується низкою викликів. Йдеться, зокрема, про потребу в стандартизованих сенсорних системах, безпечних каналах передачі даних, а також гарантуванні кіберстійкості – адже витік або маніпуляція даними у військовому середовищі може мати критичні наслідки. Незважаючи на ці виклики, потенціал застосування ШІ в обслуговуванні транспорту логістики відкриває нові горизонти для підвищення ефективності, економічності та готовності техніки до виконання бойових і тилових завдань. Такий підхід формує основу для переходу до нової моделі технічного управління, заснованої на інтелектуальній аналітиці, гнучкості та випереджувальному прийнятті рішень.

Ключові слова: штучний інтелект, машинне навчання, військова логістика.

Savka A. Ya. Machine learning technologies in predicting vehicle engine maintenance in military logistics

This study examines the prospects for the introduction of artificial intelligence (AI) technologies in the field of maintenance of logistics vehicles used by the armed forces. Modern challenges of military logistics require high reliability, responsiveness, and maximum readiness of equipment to perform tasks in various conditions. In this regard, predictive maintenance approaches are of particular importance, as they allow for the detection of potential malfunctions before they occur. Unlike traditional methods that are based on a routine approach or response to existing breakdowns, predictive maintenance uses machine learning capabilities to analyze large amounts of sensor data in real time. This creates the conditions for flexible, dynamic, and more efficient strategies for the operation of equipment. Logistics transport, which is a key component of logistics support – transportation of ammunition, fuel, food, equipment, and personnel – must be not only functional but also as accessible as possible for use at any time. In this context, the use of AI minimizes the risk of sudden failures and reduces the workload of repair units. In addition, automated systems for analyzing technical condition provide an increase in the accuracy of forecasts, which, in turn, improves mission planning and logistics operations. This includes the need for standardized sensor systems, secure data transmission channels, and cyber resilience, as data leakage or manipulation in a military environment can have critical consequences. Despite these challenges, the potential of AI in logistics transport services opens new horizons for improving efficiency, cost-effectiveness, and readiness of equipment for combat and logistics missions. This approach forms the basis for the transition

to a new model of technical management based on intelligent analytics, flexibility, and proactive decision-making.

Key words: *artificial intelligence, machine learning, military logistics.*

Постановка проблеми. У сучасних умовах ведення бойових дій надійність військової техніки, її готовність до використання та ефективність технічного обслуговування мають вирішальне значення для бойової спроможності армії. Військові транспортні засоби, оснащені високотехнологічними системами, становлять основу сучасних збройних сил. Зокрема, двигун – ключовий компонент будь-якого транспортного засобу – потребує своєчасного та регулярного обслуговування для забезпечення його стабільної роботи. Проте традиційні підходи до технічного обслуговування часто потребують значних ресурсів і часу. Завдяки розвитку інноваційних технологій, таких як штучний інтелект (ШІ), ми спостерігаємо суттєву трансформацію у напрямку від реактивного до прогностного техобслуговування. Метою цього дослідження є аналіз потенціалу та наслідків застосування ШІ у сфері обслуговування двигунів броньованих бойових машин.

Прогнозне технічне обслуговування передбачає виявлення можливих несправностей або збоїв у роботі двигуна ще до їх фактичного настання, що дає змогу вчасно реагувати та запобігати поломкам. Цей підхід ґрунтується на аналізі даних, застосуванні розвиненої аналітики та технологій штучного інтелекту (особливо машинного навчання), що дає змогу точно визначати потреби в технічному втручанні. Важливою складовою прогностного обслуговування є Інтернет речей (IoT), який забезпечує збір і моніторинг даних у реальному часі, дозволяючи ретельно контролювати стан двигуна. Завдяки цьому підходу військова логістика отримує змогу ефективно попереджати збої в роботі техніки, що позитивно впливає на якість логістичних операцій під час бойових дій.

Застосування прогностного обслуговування має великий потенціал змінити стратегії та структуру військових підрозділів. Перехід до проактивної моделі технічного обслуговування дозволяє продовжити термін служби техніки, підвищити її ефективність і зменшити експлуатаційні витрати. Крім того, впровадження прогностного підходу сприяє централізації процесів обслуговування в межах усієї операційної структури. Це дає змогу краще координувати дії технічного персоналу, уникати дублювання роботи та оперативніше реагувати на сигнали про потенційні несправності, що загалом покращує ефективність роботи на полі бою.

Попри вагомі переваги, впровадження прогностного технічного обслуговування в умовах військової служби супроводжується низкою труднощів. Серед основних викликів – потреба у стандартизації джерел даних, загрози кібербезпеці, брак кваліфікованих фахівців і відсутність прозорості в роботі моделей ШІ. Проте, за умови цілеспрямованого розвитку інфраструктури, інвестування в підготовку персоналу та вирішення технічних питань, збройні сили можуть повністю розкрити потенціал цього підходу. Це, своєю чергою, дозволить підвищити готовність техніки, продовжити її термін служби та забезпечити більшу ефективність у сучасних умовах ведення бойових дій [3].

Аналіз останніх досліджень і публікацій. Цей розділ присвячений аналізу існуючих наукових праць і досягнень у галузі прогностного технічного обслуговування двигунів військових транспортних засобів. Особливу увагу приділено логістичним аспектам у військовій сфері. Враховуючи специфіку військової техніки та її експлуатаційні вимоги, необхідність у прогностному обслуговуванні не просто актуальна, а критично важлива.

Серед основоположних праць у цій галузі варто виділити дослідження *Суреша Чандри Падхі*, який розробив теоретичну модель прогнозного техобслуговування для військової техніки. У своїй роботі він акцентував увагу на ключових параметрах, таких як температура, ефективність роботи двигуна та витрати пального [2].

Працю Падхі доповнив дослідник Праджіт Сенгупта, який зосередився на можливості застосування алгоритмів машинного навчання для передбачення ймовірних відмов у роботі військових автомобілів. Його результати підтвердили ефективність методів розпізнавання шаблонів для виявлення потенційних проблем до того, як вони спричинять поломки.

З розвитком технологій прогнозне обслуговування стало набагато точнішим завдяки використанню сенсорів і телеметричних пристроїв. У дослідженні Саматаса Г. Г. показано, як інтеграція IoT-пристроїв із машинним навчанням підвищує точність прогнозних моделей. Такі моделі здатні обробляти дані в реальному часі, не лише щодо двигунів, а й інших механічних компонентів військових машин [1].

Дослідник Сюй Г. пішов ще далі, продемонструвавши, як штучний інтелект може бути використаний не лише для виявлення несправностей, а й для оцінки залишкового ресурсу елементів двигуна.

Особливості військової логістики значно відрізняються від цивільних систем. Праджіт Сенгупта у своєму дослідженні [3] врахував ці аспекти, зокрема вплив зовнішніх умов, таких як рельєф місцевості та погодні умови. Він також розглянув практичні питання, пов'язані з ремонтом і заміною деталей в умовах, максимально наближених до бойових.

Попри значний прогрес, у дослідженнях залишаються певні білі плями. Зокрема, потрібні більш масштабні дослідження, які охоплюють різні типи військової техніки та умови експлуатації. Також бракує універсальних моделей, адаптованих до потреб саме військової логістики. Подальші дослідження мають бути спрямовані на створення стійких і адаптивних рішень, які враховують реальні виклики бойових дій [4, 5].

Методи та засоби розв'язання задачі. У цьому дослідженні методика розв'язання задачі поділяється на три ключові етапи. Перший етап передбачає збір даних із сенсорів та систем моніторингу, встановлених на броньованих транспортних засобах. Далі дані проходять стадію обробки, під час якої видаляється некоректна або зайва інформація та виправляється дисбаланс у класах даних. Заключний етап полягає в навчанні багаторівневої моделі машинного навчання на очищеному наборі даних з метою передбачення можливих відмов обладнання. Ефективність побудованої моделі оцінюється за ключовими метриками точності [6].

Для тренування використовувався набір даних про технічний стан двигунів автотранспортних засобів, що містить близько 19 тисяч записів із такими характеристиками: оберти двигуна, тиск мастила, тиск пального, температура охолоджуючої рідини, загальний стан двигуна тощо. Цей синтетичний набір даних було використано для навчання моделей машинного навчання, орієнтованих на прогнозування технічного обслуговування.

У візуалізації даних (рис. 1) відображено взаємозв'язок між параметрами, де кольорами позначено різні стани двигуна.

Збір і підготовка даних. Інформація була зібрана за допомогою телеметрії з різних частин військової техніки, що забезпечило повну картину її технічного стану. Попередня обробка даних – критично важливий етап, що гарантує достовірність прогнозних моделей. Для підвищення якості набору даних були усунуті

Таблиця 1

Зразок набору вхідних даних

Engine rpm	Lub oil pressure	Fuel pressure	Coolant pressure	Lub oil temp	Coolant temp	Engine Condition
700	2.49359182	11.7909273	3.17898079	84.1441629	81.6321865	1
767	4.59690302	7.49656199	1.43277623	84.9241433	80.2655148	0
1053	2.5338470	4.2121939	4.7054738	75.8420977	75.9815723	0




Рис. 1. Візуалізація набору даних Engine Health

пропущені значення, викиди та нерелевантна інформація. Також застосовано методи нормалізації та масштабування, а дисбаланс між класами було скориговано, що дозволило моделі ефективно навчатися як на нормальних, так і на аварійних ситуаціях.

Етапи побудови моделі. Процес створення моделі прогнозного обслуговування включав такі кроки:

1. *Очищення даних*
 - Усунення помилок, пропущених значень, аномалій;
 - Масштабування та стандартизація ознак.
2. *Початковий аналіз (EDA)*
 - Виявлення закономірностей, кореляцій та аномалій;
 - Побудова візуалізацій для кращого розуміння структури даних.
3. *Формування та відбір ознак*
 - Створення нових показників із наявних;
 - Вибір найбільш інформативних ознак для тренування.
4. *Вибір моделі*
 - Визначення оптимального алгоритму машинного навчання для задачі.
5. *Навчання моделі*
 - Навчання моделі на підготовлених даних.
6. *Оцінка ефективності*
 - Вимірювання точності, повноти, F1-міри та інших метрик на валідаційному наборі.




Рис. 2. Workflow-діаграма тренування моделі

Використані моделі та гіперпараметри

Для класифікації стану двигуна були випробувані наступні алгоритми:

Таблиця 2

Таблиця основних параметрів

№	Модель	Основні параметри
1	Random Forest Classifier	n_estimators=100, max_depth=50
2	Decision Tree Classifier	max_depth=100
3	Gaussian Naive Bayes	–
4	Logistic Regression	–
5	K-Nearest Neighbors	n_neighbors=25
6	AdaBoost Classifier	n_estimators=150, learning_rate=0.5

Тестування та адаптація. Для перевірки реальної ефективності моделей проводилося тестування в умовах, наближених до реальних сценаріїв експлуатації. Це дало змогу оцінити адаптивність і надійність моделей у змінних умовах. Також була розроблена система постійного моніторингу та оновлення моделей, що дозволяє підтримувати їхню актуальність відповідно до нових умов експлуатації, змін у середовищі та технічних параметрах техніки.

Результати. У межах нашого комплексного дослідження та порівняльного аналізу моделей машинного навчання для прогнозування стану двигунів броньованої техніки було протестовано низку алгоритмів. Кожну модель ретельно оцінили за точністю та загальною ефективністю. До дослідження було включено широкий спектр методів – від Random Forest і SVC до алгоритмів, таких як Decision Tree, GaussianNB, Logistic Regression, KNeighborsClassifier та AdaBoostClassifier.

Результати експериментів показали, що точність моделей коливалась у межах від 77,46 % до 85,93 %. Варто зазначити, що рівень складності алгоритму не завжди прямо впливав на його ефективність.

Так, Decision Tree, відомий своєю простотою та легкістю інтерпретації, продемонстрував найнижчий рівень точності – 77,46 %. Імовірно, така модель стикнулася із проблемами надмірного або недостатнього узагальнення, що знизило її результативність. У той же час Random Forest та GaussianNB показали високі результати, перевищивши 84 % точності, що вказує на їхню здатність ефективно розпізнавати закономірності у даних і робить їх перспективними у цьому контексті. Неочікувано високу ефективність продемонструвала Logistic Regression, досягнувши 85,01 % точності, що зрівнює її з більш складними підходами. Найкращим за точністю став ансамблевий метод AdaBoostClassifier, який досяг 85,93 %. Цей алгоритм покращує продуктивність слабких моделей шляхом повторного зважування прикладів під час навчання. SVC та KNeighborsClassifier показали також високі результати – 85,52 % та 85,4 % відповідно. Зведені дані представлено у Таблиці 3.

Таблиця 3

Результати

No.	Model	Head 3
1	Random Forest Classifier	84.45 %
2	Decision Tree Classifier	77.46 %
3	GaussianNB	84.68 %
4	Logistic Regression	85.01 %
5	KNeighborsClassifier	85.4 %
6	AdaBoostClassifier	85.93 %
7	SVC	85.52 %

Отримані результати підтверджують деяку перевагу ансамблевих методів, зокрема AdaBoostClassifier, а також більш складних алгоритмів, таких як SVC і KNeighborsClassifier, у завданні прогнозування технічного стану двигуна транспортного засобу. Водночас незначна різниця в точності між найуспішнішими моделями свідчить про необхідність подальшого тонкого налаштування для досягнення ще вищої ефективності.

Подальші дослідження можуть бути зосереджені на глибшій оптимізації параметрів цих моделей або на розширенні вхідних даних за рахунок додаткових характеристик, специфічних для транспортного засобу, що дозволить підвищити точність прогнозів. Крім того, вже навчені моделі можуть бути використані для оцінки стану двигуна – приклад такого прогнозу наведено на рисунку 3.

Висновки. Інтеграція сучасних технологій у військові операції відкриває нові можливості для застосування машинного навчання (ML) – одного з ключових напрямів штучного інтелекту. Особливе місце в цьому контексті займає прогнозне технічне обслуговування транспорту логістики, яке поєднує інтелектуальні цифрові

```
import numpy as np

X_test = np.array([[1674,2.501620349,3.624157065,2.043074697,76.77232668,74.64194049]])

# Make predictions on the test data
predicted_condition = abc.predict(X_test)

# Print the predicted engine condition
print("Predicted Engine Condition:", predicted_condition)
```

Predicted Engine Condition: [0]

Рис. 3. Результат прогнозування стану двигуна

рішення з традиційними підходами до експлуатації військової техніки. Такий симбіоз дозволяє істотно підвищити бойову готовність і продовжити ресурс техніки.

Застосування алгоритмів машинного навчання у сфері технічного обслуговування транспорту відкриває новий рівень аналітики сенсорних даних [8]. Такі алгоритми здатні швидко та точно виявляти перші ознаки можливих несправностей, що, своєю чергою, дає змогу формувати своєчасні й ефективні графіки обслуговування. Це знижує ризик раптових відмов техніки й підвищує загальну ефективність операцій [9]. Таким чином, машинне навчання стає основою надійності й передбачуваності у функціонуванні транспорту.

Впровадження ML у систему прогнозного обслуговування може докорінно змінити підхід до експлуатації техніки й управління ресурсами. Завдяки здатності алгоритмів виявляти закономірності й прогнозувати необхідні втручання, військові підрозділи можуть точніше планувати технічні роботи, зосереджуючи увагу на ключових етапах підготовки до місій [13, 14, 15].

Втім, на цьому шляху існують і виклики. Зокрема, складність обробки великих обсягів різномірних сенсорних даних, потреба в надійній системі передачі інформації, а також питання кібербезпеки. Захист інформації, яку генерують та обробляють ML-системи, є критично важливим у військовому контексті, де будь-яке порушення безпеки може мати серйозні наслідки [10].

Попри ці труднощі, потенціал машинного навчання для покращення експлуатації транспорту є надзвичайно великим. Подолання зазначених бар'єрів відкриває шлях до суттєвих змін у системі технічного обслуговування: від зниження витрат і підвищення ефективності до значного зростання бойової готовності. Таким чином, впровадження ML у повсякденне обслуговування техніки знаменує собою початок нової епохи у військовій сфері.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ:

1. Mobley R. K. An introduction to predictive maintenance. Amsterdam : Elsevier, 2002.
2. Narayanan T. S. A., Padhy S. C. Artificial Intelligence for Predictive Maintenance of Armoured Fighting Vehicles Engine. Indian Journal of Artificial Intelligence and Neural Networking (IJAINN). 2023. Vol. 3, No. 5.
3. Sengupta P., Mehta A., Rana P. S. Predictive Maintenance of Armoured Vehicles using Machine Learning Approaches [Електронний ресурс]. DOI: <https://doi.org/10.48550/arXiv.2307.14453>
4. Samatas G.G., Moumgiakmas S.S., Papakostas G.A. Predictive Maintenance – Bridging Artificial Intelligence and IoT // Proceedings of the 2021 IEEE World AI IoT

Congress (AIIoT), Seattle, WA, USA, 10–13 May 2021. Piscataway, NJ : IEEE, 2021. P. 413–419.

5. Xu G., Liu M., Wang J. та ін. Data-driven fault diagnostics and prognostics for predictive maintenance: A brief overview // Proceedings of the 2019 IEEE 15th International Conference on Automation Science and Engineering (CASE), Vancouver, Canada, 22–26 August 2019. Piscataway, NJ : IEEE, 2019. P. 103–108.

6. Longo N., Serpi V., Jacazio G., Sorli M. Model-based predictive maintenance techniques applied to the automotive industry // PHM Society European Conference. 2018. Vol. 4. Utrecht, The Netherlands, 3–6 July 2018.

7. Xiao Z., Cheng Z., Li Y. A review of fault diagnosis methods based on machine learning patterns // 2021 Global Reliability and Prognostics and Health Management (PHM-Nanjing). 2021. P. 1–4.

8. Theissler A., Perez-Velázquez J., Kettelgerdes M., Elger G. Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry // Reliability Engineering & System Safety. 2021. Vol. 215. P. 107864.

9. Torcianti A., Matzka S. Explainable artificial intelligence for predictive maintenance applications using a local surrogate model // 4th International Conference on Artificial Intelligence for Industries (AI4I). 2021. P. 86–88.

10. Zhang W., Yang D., Wang H. Data-driven methods for predictive maintenance of industrial equipment: A survey // IEEE Systems Journal. 2019. Vol. 13, No. 3. P. 2213–2227.

11. Souza R. M., Nascimento E. G. S., Miranda U. A. та ін. Deep learning for diagnosis and classification of faults in industrial rotating machinery // Computers & Industrial Engineering. 2021. Vol. 153. P. 107060.

12. Longo N., Serpi V., Jacazio G., Sorli M. Model-based predictive maintenance techniques applied to the automotive industry // PHM Society European Conference. 2018. Vol. 4. Utrecht, The Netherlands, 3–6 July 2018.

13. Tessaro I., Mariani V. C., Coelho L. S. Machine learning models applied to predictive maintenance in automotive engine components // Proceedings. 2020. Vol. 64. P. 26.

14. Furch J., Turo T., Krobot Z., Stastny J. Using telemetry for maintenance of special military vehicles // Intelligent Systems in Production Engineering and Maintenance. 2018. P. 267–275. DOI: 10.1007/978-3-319-76072-8_28

15. Virca I., Badea D. Study on the Predictive Maintenance of Vehicles and its Management Using the Specific “Keep the Machine Running” Application // International conference KNOWLEDGE-BASED ORGANIZATION. 2019. Vol. 25. P. 291–297. DOI: 10.2478/kbo-2019-0048

REFERENCES:

1. Mobley, R. K. (2002). *An introduction to predictive maintenance*. Amsterdam, The Netherlands: Elsevier.

2. Narayanan, T. S. A., & Padhy, S. C. (2023, August). Artificial intelligence for predictive maintenance of armoured fighting vehicles engine. *Indian Journal of Artificial Intelligence and Neural Networking (IJAINN)*, 3(5). ISSN: 2582-7626.

3. Sengupta, P., Mehta, A., & Rana, P. S. (2023). Predictive maintenance of armoured vehicles using machine learning approaches. *arXiv*. <https://doi.org/10.48550/arXiv.2307.14453>

4. Samatas, G. G., Moumgiakmas, S. S., & Papakostas, G. A. (2021, May 10–13). Predictive maintenance – Bridging artificial intelligence and IoT. In *2021 IEEE World AI IoT Congress (AIIoT)* (pp. 413–419). Seattle, WA, USA: IEEE.

5. Xu, G., Liu, M., Wang, J., Ma, Y., Wang, J., Li, F., & Shen, W. (2019, August 22–26). Data-driven fault diagnostics and prognostics for predictive maintenance: A brief overview. In *2019 IEEE 15th International Conference on Automation Science and Engineering (CASE)* (pp. 103–108). Vancouver, BC, Canada: IEEE.

6. Longo, N., Serpi, V., Jacazio, G., & Sorli, M. (2018, July 3–6). Model-based predictive maintenance techniques applied to the automotive industry. In *PHM Society European Conference* (Vol. 4). Utrecht, The Netherlands.
 7. Xiao, Z., Cheng, Z., & Li, Y. (2021). A review of fault diagnosis methods based on machine learning patterns. In *2021 Global Reliability and Prognostics and Health Management (PHM-Nanjing)* (pp. 1–4). IEEE.
 8. Theissler, A., Perez-Velázquez, J., Kettelgerdes, M., & Elger, G. (2021). Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry. *Reliability Engineering & System Safety*, 215, 107864.
 9. Torcianti, A., & Matzka, S. (2021). Explainable artificial intelligence for predictive maintenance applications using a local surrogate model. In *2021 4th International Conference on Artificial Intelligence for Industries (AI4I)* (pp. 86–88). IEEE.
 10. Zhang, W., Yang, D., & Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal*, 13(3), 2213–2227.
 11. Souza, R. M., Nascimento, E. G. S., Miranda, U. A., Silva, W. J. D., & Lepikson, H. A. (2021). Deep learning for diagnosis and classification of faults in industrial rotating machinery. *Computers & Industrial Engineering*, 153, 107060.
 12. Longo, N., Serpi, V., Jacazio, G., & Sorli, M. (2018, July 3–6). Model-based predictive maintenance techniques applied to the automotive industry. In *PHM Society European Conference* (Vol. 4). Utrecht, The Netherlands.
 13. Tessaro, I., Mariani, V. C., & Coelho, L. D. S. (2020). Machine learning models applied to predictive maintenance in automotive engine components. In *Proceedings* (Vol. 64, p. 26). MDPI.
 14. Furch, J., Turo, T., Krobot, Z., & Stastny, J. (2018). Using telemetry for maintenance of special military vehicles. In *Intelligent Systems in Production Engineering and Maintenance* (pp. 267–275). https://doi.org/10.1007/978-3-319-76072-8_28
 15. Virca, I., & Badea, D. (2019). Study on the predictive maintenance of vehicles and its management using the specific “Keep the Machine Running” application. *International Conference KNOWLEDGE-BASED ORGANIZATION*, 25, 291–297. <https://doi.org/10.2478/kbo-2019-0048>
-