

УДК 629.04:631.372:004.8

[https://doi.org/10.32515/2664-262X.2025.12\(43\).1.272-288](https://doi.org/10.32515/2664-262X.2025.12(43).1.272-288)

В. М. Чумак, В. В. Аулін, проф., д-р техн. наук, **А. В. Гриньків**, ст. дослід., канд. техн. наук, **С. В. Лисенко**, доц., канд. техн. наук, **О. В. Кузик**, доц., канд. техн. наук

*Центральноукраїнський національний технічний університет, м. Кропивницький, Україна
e-mail: aulinvv@gmail.com*

Підвищення зносостійкості та надійності ресурсовизначальних деталей транспортної та сільськогосподарської техніки методами інжинірингу із застосуванням нейронних мереж

Показано, що у сучасних умовах інтенсивного розвитку промисловості 4.0 та цифровізації машинобудівних процесів особливої актуальності набуває проблема забезпечення надійності та довговічності ресурсовизначальних деталей транспортної та сільськогосподарської техніки. Виявлено, що традиційні підходи до прогнозування технічного стану машин, засновані на календарному обслуговуванні, не відповідають сучасним вимогам економічної ефективності та безпеки експлуатації.

Запропонована методологія, яка базується на гібридному застосуванні штучних нейронних мереж – багатошарового перцептрона (MLP) для ідентифікації домінуючих механізмів зношування деталей машин і їх спраження та рекурентної мережі довгої короточасної пам'яті (LSTM) для прогнозування динаміки деградації деталей за часовими рядами експлуатаційних параметрів. Визначено, що використання синтетичних даних, генерованих на основі фізичних моделей зношування, дозволяє подолати обмеження, пов'язані з недостатністю реальних експлуатаційних даних вузлів, систем та агрегатів машин.

Валідація розробленого алгоритму на репрезентативному наборі даних (50 000 зразків) продемонструвала високі показники точності прогнозування: коефіцієнт детермінації $R^2 = 0,98...0,99$, середньоквадратична похибка $RMSE = 8,12...15,67$ мкм, середня абсолютна процентна похибка $MAPE = 2,5...3,9\%$. Ці результати підтверджують перспективність інтеграції запропонованого підходу у кіберфізичні системи сучасної транспортної та сільськогосподарської техніки для реалізації концепції предиктивного обслуговування.

прогнозування зносу, штучний інтелект, MLP, LSTM, синтетичні дані, модель Арчарда, предиктивне обслуговування

Постановка проблеми. Інтенсивне зношування ресурсовизначальних деталей транспортної та сільськогосподарської техніки є критичним фактором, що визначає їх експлуатаційну надійність, безпеку та економічну ефективність [23, 24]. Сучасні тенденції розвитку транспортної галузі вимагають переходу від традиційного календарного технічного обслуговування до адаптивних систем станового моніторингу. Це дозволяє мінімізувати витрати на незаплановані ремонти та знизити ризики аварійних ситуацій [8, 14].

Основною проблемою класичних підходів до прогнозування залишкового ресурсу є обмежена адаптивність транспортної та сільськогосподарської техніки до мінливих умов експлуатації. Традиційні фізико-математичні та статистичні методи, хоча й забезпечують теоретичне обґрунтування окремих трибологічних процесів [17, 23], але демонструють недостатню точність у реальних умовах експлуатації, характерних великою кількістю змінних факторів і стохастичними навантаженнями [22].

У контексті розвитку концепції смарт-виробництва [13, 25] та впровадження систем моніторингу технічного стану промислового обладнання [16] методи машинного навчання та глибокого навчання показали значний потенціал для створення більш точних і адаптивних прогностичних моделей [4, 5]. Особливої уваги заслуговують гібридні підходи, що поєднують фундаментальні фізичні закономірності з можливостями

обробки великих обсягів даних [11, 19], оскільки такий синтез підвищує стабільність прогнозів і знижує вимоги до обсягу реальних експлуатаційних даних [18, 20].

Аналіз останніх досліджень і публікацій. Сучасні тенденції розвитку машинобудівної галузі характеризуються активним впровадженням принципів цифровізації та смарт-технологій. Дослідження [1, 25] підкреслюють, що цифровізація машинобудівних процесів є ключовим фактором формування смарт-підприємств четвертої промислової революції. У роботах вітчизняних науковців [1, 2] розглядається застосування кіберфізичного підходу при створенні транспортно-виробничих систем та удосконалення математичного моделювання у машинобудуванні.

Значний напрям досліджень присвячений впровадженню штучних нейронних мереж у системи технічної діагностики. Роботи [15, 16] демонструють ефективність застосування нейромережових алгоритмів у системах машинного зору для автоматизованого контролю дефектів деталей та моніторингу технічного стану промислового обладнання.

Особливу увагу в літературі 2022-2024 років приділено використанню методів глибокого навчання для прогнозування залишкового ресурсу критичних компонентів [5, 9, 10]. Дослідження Kumar та інш. [5] обґрунтовують доцільність застосування алгоритмів глибокого навчання для трибологічних задач, а Lee та інш. [9] демонструють ефективність нейронних мереж для прогнозування ресурсу підшипників качення.

Аналіз зарубіжних публікацій [4, 8, 11, 19] показує зростання інтересу до гібридних підходів у предиктивному обслуговуванні транспортної техніки. Paredes, Chávez та інш. [11] розробили гібридні моделі машинного навчання для прогнозування зносу двигунів, що поєднують переваги різних алгоритмічних підходів. Wang [8] у своїй роботі систематизує методи прогнозування механічних компонентів із застосуванням машинного навчання.

Дослідження у сфері промислового застосування показують [13, 14, 21], що використання ансамблевих методів та нейронних мереж дозволяє знизити похибку прогнозування ресурсу на 25-40% у порівнянні з класичними статистичними методами. Важливим аспектом є забезпечення робастності моделей машинного навчання в умовах зашумлених промислових даних [20, 22].

Окремий напрям досліджень [12, 17] присвячений застосуванню методів штучного інтелекту у сільськогосподарській техніці та трибологічному моделюванні. Kisten M., Ezugwu та інш. [12] демонструють перспективність використання машинного навчання у предиктивному обслуговуванні сільськогосподарського обладнання.

Таким чином, аналіз сучасної літератури підтверджує актуальність застосування нейромережових моделей у сфері інжинірингу деталей транспортної та сільськогосподарської техніки для підвищення їхньої надійності та довговічності [3, 18, 24].

Постановка завдання. Мета дослідження полягає у розробці та валідації інноваційного гібридного алгоритму, що інтегрує багатошаровий перцептрон (MLP) та рекурентну мережу довгої короткочасної пам'яті (LSTM) для високоточного прогнозування інтенсивності зносу ресурсовизначальних деталей транспортної та сільськогосподарської техніки.

Для досягнення поставленої мети необхідно вирішити наступні завдання:

- розробити архітектуру гібридної нейромережової системи, що поєднує можливості MLP для класифікації домінуючих механізмів зношування з перевагами LSTM для регресійного аналізу часових рядів експлуатаційних параметрів, базуючись на сучасних досягненнях у галузі глибокого навчання [5, 10, 15];
- сформувати репрезентативний синтетичний набір даних (50 000 зразків) на

основі фундаментальних фізичних моделей зношування з інтеграцією стохастичних компонентів, що відображають реальні умови експлуатації транспортної техніки;

– провести кількісну оцінку точності розробленого алгоритму з використанням стандартних метрик (R^2 , RMSE, MAPE) та порівняти результати з існуючими методами прогнозування, враховуючи досвід застосування машинного навчання у промислових задачах;

– проаналізувати практичну придатність та обмеження запропонованого підходу в контексті інтеграції у сучасні кіберфізичні системи транспортної та сільськогосподарської техніки, враховуючи вимоги робастності та надійності у реальних умовах експлуатації;

– оцінити потенціал впровадження розробленої методології у концепцію предиктивного обслуговування та смарт-виробництва з урахуванням принципів цифровізації машинобудівних процесів.

Реалізація поставлених завдань сприятиме підвищенню ефективності систем технічної діагностики транспортної та сільськогосподарської техніки та створенню наукових основ для переходу від календарного до станового технічного обслуговування на основі сучасних технологій штучного інтелекту.

Викладення основного матеріалу.

У рамках дослідження розглядаються чотири критичні типи ресурсовизначальних деталей транспортної та сільськогосподарської техніки, які характеризуються різними домінуючими механізмами зношування та експлуатаційними умовами (табл. 1). Вибір даних комбінацій обумовлений їх визначальним впливом на загальну надійність транспортної та сільськогосподарської техніки [14, 24] та різноманітністю трибологічних процесів [17, 23].

Таблиця 1 – Характеристики досліджуваних комбінацій деталей-механізм зношування

Тип деталі	Механізм зношування	Кількість зразків	Середня твердість (HV)	Шорсткість (μm)	Коеф. тертя
Поршневі кільця	Абразивний	12500	305.4	1.4	0.25
Шестерні КП	Втомний	12500	550.2	0.55	0.13
Підшипники	Втомний	12500	650.8	0.25	0.05
Гільзи циліндрів	Корозійно-механічний	12500	400.1	1.0	0.175

Джерело: розроблено авторами

Поршневі кільця піддаються переважно абразивному зношуванню внаслідок потрапляння твердих часток *продуктів* згоряння та зовнішніх забруднень у зону контакту з гільзою циліндра. Характеризуються помірною твердістю (305.4 HV), відносно високою шорсткістю поверхні (1.4 μm) та коефіцієнтом тертя 0.25, що типово для пар тертя "чавун-сталь" у двигунах внутрішнього згоряння.

Шестерні коробки передач зазнають втомного зношування через циклічні контактні навантаження зубів при передачі крутного моменту. Висока твердість матеріалу (550.2 HV) та низька шорсткість (0.55 μm) забезпечують оптимальні умови для евольвентного зачеплення з мінімальним коефіцієнтом тертя (0.13).

Підшипники кочення також піддаються втомному механізму зношування, проте в умовах більш високої твердості поверхонь (650.8 HV) та мінімальної шорсткості (0.25 μm). Надзвичайно низький коефіцієнт тертя (0.05) досягається завдяки коченню замість ковзання та високоякісному змащуванню [9].

Гільзи циліндрів характеризуються корозійно-механічним зношуванням, що поєднує механічне руйнування з хімічними процесами окислення в агресивному

середовищі продуктів згоряння. Помірні значення твердості (400.1 HV), шорсткості (1.0 μm) та коефіцієнта тертя (0.175) відображають компромісні вимоги до забезпечення герметичності та зношування.

Для поршневих кілець (абразивне зношування) застосовується модифікована модель Арчарда [5, 17]:

$$W(t) = kabr \times \left(\frac{P}{H}\right) \times v \times t \times f(Cpart, T) \quad (1)$$

де $W(t)$ – накопичений знос, $kabr$ – коефіцієнт абразивного зношування, P – контактний тиск, H – твердість матеріалу, v – швидкість ковзання, t – час, $f(Cpart, T)$ – функція впливу концентрації абразивних частинок та температури.

Для зубчастих коліс та підшипників (втомне зношування) використовується модель накопичення втомних пошкоджень [8, 9]:

$$D(t) = \int_0^t \left(\frac{\sigma(\tau)}{\sigma_f}\right)^m \times \frac{dN}{dt} d\tau \quad (2)$$

де $D(t)$ – параметр накопиченої пошкодженості, $\sigma(\tau)$ – поточні контактні напруження, σ_f – межа витривалості, m – показник степені в рівнянні Веллера, dN/dt – швидкість циклування.

Для гільз циліндрів (корозійно-механічне зношування) застосовується комбінована модель [11, 17]:

$$W(t) = W_{mech}(t) + W_{corr}(t) = k_m \times f_{mech}(P, v, T) \times t + k_c \times f_{corr}(pH, T, O_2) \times t \quad (3)$$

де $W_{mech}(t)$ та $W_{corr}(t)$ – механічна та корозійна складові зносу відповідно.

Експериментальне дослідження структуроване для забезпечення репрезентативності та статистичної достовірності результатів (табл. 2). Загальний обсяг синтетичного набору даних (50,000 зразків) забезпечує рівномірне представлення всіх досліджуваних комбінацій деталей-механізм зношування по 12,500 зразків кожна, що відповідає сучасним вимогам до навчання глибоких нейронних мереж [10, 20].

Таблиця 2 – Основні параметри проведеного дослідження

Параметр	Значення	Опис
Загальна кількість зразків	50000	По 12500 зразків на кожну комбінацію
Розподіл навчальна/ тестова	75% / 25%	Навчальна та тестова вибірки
Довжина часового ряду	50 точок	Кількість часових відміток
Вхідні параметри	12	Статичні + динамічні характеристики
Цільова змінна	Фінальний знос	Кумулятивний знос в кінці періоду

Джерело: розроблено авторами

Розподіл на навчальну (75%) та тестову (25%) вибірки забезпечує достатній обсяг даних для навчання при збереженні незалежної тестової множини для об'єктивної оцінки якості моделі [18, 21]. Довжина часових рядів у 50 точок дозволяє зафіксувати динамічні характеристики процесів деградації зі збереженням обчислювальної ефективності LSTM-мережі.

Комплексний підхід до моделювання зношування реалізовано через систему з 12 вхідних параметрів, що включають як статичні характеристики матеріалів та геометрії [23], так і динамічні експлуатаційні фактори [4, 19]:

Статичні параметри: твердість поверхні (HV); шорсткість поверхні (μm); коефіцієнт тертя; геометричні характеристики контакту.

Динамічні параметри: контактне навантаження (Н); швидкість відносного переміщення (м/с); температура в зоні контакту ($^{\circ}\text{C}$); параметри змащування; концентрація забруднень (%); кількість циклів навантаження.

Цільова змінна представлена кумулятивним зносом на кінець періоду спостереження, що дозволяє оцінити загальну деградацію деталі та прогнозувати залишковий ресурс [8, 16]. Така структура даних створює надійну основу для навчання гібридної нейромережевої системи, що поєднує класифікацію механізмів зношування (MLP) з прогнозуванням динаміки деградації (LSTM) [5, 22].

На основі аналізу характеристик досліджуваних даних (табл. 1, 2) та з урахуванням специфіки задачі прогнозування зносу на рисунку 1 показано обрану архітектуру нейронної мережі.

```
mlp_model = Sequential([
    Dense(64, activation='relu', input_shape=(12,)),
    Dropout(0.3),
    Dense(32, activation='relu'),
    Dense(4, activation='softmax')
])

lstm_model = Sequential([
    LSTM(128, return_sequences=True, input_shape=(X_train_scaled.shape[1],)),
    Dropout(0.2),
    LSTM(64, return_sequences=False),
    Dense(32, activation='relu'),
    Dense(1, activation='linear')
])

mlp_lstm = Concatenate()([mlp_output, lstm_output])
model = Dense(1, activation='linear')(mlp_lstm)
```

Рисунок 1 – Архітектура нейронної мережі

Джерело: розроблено авторами

Обґрунтування топології:

- вхідний шар: 12 нейронів відповідно до кількості вхідних параметрів;
- перший прихований шар: 128 нейронів для виявлення складних нелінійних залежностей між параметрами зношування;
- другий прихований шар: 64 нейрони для поступового стиснення інформації;
- третій прихований шар: 32 нейрони для фінального вилучення високорівневих ознак;
- вихідний шар: 1 нейрон з лінійною активацією для регресійного прогнозу кумулятивного зносу.

Пакетна нормалізація застосовується після кожного прихованого шару для стабілізації процесу навчання та прискорення збіжності [21]. Цей метод нормалізує вхідні дані кожного шару, зменшуючи внутрішній коваріантний зсув:

$$BN(x) = \gamma \times \left(\frac{x - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \right) + \beta, \quad (4)$$

де μ_B та σ_B^2 – середнє значення та дисперсія міні-батчу, γ та β – параметри, що навчаються.

Метод регуляризації з коефіцієнтом 0.3 застосовується для запобігання перенавчанню [20, 22]. Під час навчання випадково вимикається 30% нейронів, що підвищує узагальнюючу здатність моделі. Стандартизація вхідних даних виконується за допомогою метода стандартизації даних (StandardScaler) для приведення всіх ознак до нульового середнього та одиничної дисперсії:

$$X_{scaled} = \frac{X - \mu}{\sigma}. \quad (5)$$

Вказане критично важливо для ефективного навчання через різні порядки величин вхідних параметрів: твердість $\sim 300\text{--}650$ HV, шорсткість $\sim 0.25\text{--}1.4$ μm). Крім цього зазначимо, що оптимізатор Adam обраний через його адаптивні властивості та ефективність у задачах регресії [21]:

- швидкість навчання: 5×10^{-4} (емпірично оптимізовано);
- розмір батчу: 128 зразків.

Функцію витрати подають через середньоквадратичну похибку (MSE) як стандарт для регресійних задач:

$$L = \frac{1}{n} \times \sum (y_{true} - y_{pred})^2. \quad (6)$$

Метрика якості додатково відстежується за середньою абсолютною похибкою (MAE) для більш інтуїтивної оцінки точності прогнозування.

Метод ранньої зупинки застосовано для запобігання перенавчання моделі. Цей підхід забезпечує оптимальний баланс між точністю на навчальних даних та здатністю до узагальнення.

Представимо налаштування параметрів: `patience = 15` - кількість епох без покращення перед зупинкою; `restore_best_weights = True` - автоматичне відновлення найкращих ваг; `monitor = 'val_loss'` - моніторинг валідаційної похибки.

```
early_stop = EarlyStopping(
    patience=15,
    restore_best_weights=True,
    monitor='val_loss',
    verbose=1)
```

Рисунок 2 – Налаштування методу ранньої зупинки

Джерело: розроблено авторами

Розподіл даних для валідації здійснено наступним чином:

- навчальна вибірка: 75% від загального набору (37,500 зразків);
- тестова вибірка: 25% від загального набору (12,500 зразків)

При цьому максимальна кількість епох: 100 з можливістю дострокового зупину для оптимізації часу навчання та запобігання перенавчання.

Архітектуру було оптимізовано для швидкого навчання та інференції, що критично важливо для практичного застосування у системах реального часу [16]. Загальна кількість параметрів моделі складає:

- $128 \times 12 + 128 = 1,664$ (перший шар);
- $64 \times 128 + 64 = 8,256$ (другий шар);
- $32 \times 64 + 32 = 2,080$ (третій шар);
- $1 \times 32 + 1 = 33$ (вихідний шар).

Загалом маємо порядку 12,000 параметрів.

Представлена компактна архітектура забезпечує баланс між точністю прогнозування та обчислювальною ефективністю, що відповідає вимогам промислового застосування [13, 24]. Час навчання на типовому наборі даних не перевищує декількох хвилин, що дозволяє швидке переналаштування моделі при зміні умов експлуатації.

Процес навчання нейромережевої моделі реалізований з використанням комплексного підходу, що включає автоматичну нормалізацію даних, динамічну оптимізацію параметрів та контроль якості навчання в реальному часі. Початковим етапом підготовки даних є стандартизація всіх вхідних параметрів за допомогою метода стандартизації даних, що забезпечує приведення різнорідних характеристик (твердість, шорсткість, коефіцієнт тертя) до єдиного масштабу з нульовим середнім та одиничною дисперсією.

Оптимізація параметрів мережі здійснюється алгоритмом Adam з початковою швидкістю навчання 5×10^{-4} , що забезпечує стабільну збіжність без надмірних коливань функції втрат. В той час використання адаптивної швидкості навчання дозволяє автоматично підстроювати крок оптимізації для різних параметрів мережі, що особливо важливо для глибоких архітектур з батч-нормалізацією. Розмір міні-батчу встановлено 128 зразків як оптимальний компроміс між стабільністю градієнтів та ефективністю обчислень на сучасних GPU [22].

Система контролю якості навчання базується на механізмі раннього зупину з терпінням 15 епох, що моніторить валідаційну втрату та автоматично припиняє навчання при відсутності покращень. Це запобігає перенавчанню та забезпечує оптимальне співвідношення між точністю на навчальній та тестовій вибірках [20].

Регуляризація процесів здійснюється комбінованим методом з використанням методу арегуляризації з коефіцієнтом 0.3 після першого та другого прихованих шарів, що випадково вимикає 30% нейронів під час навчання для підвищення узагальнюючої здатності моделі. Батч-нормалізація після кожного прихованого шару стабілізує розподіл активацій та прискорює збіжність, зменшуючи внутрішній коваріантний зсув [21].

Оскільки функція втрат представлена середньоквадратичною похибкою, що є стандартом для регресійних задач, то це забезпечує диференційованість для градієнтного спуску. Додатково відстежується середня абсолютна похибка для більш інтуїтивної інтерпретації точності прогнозування в мікрометрах. Максимальна кількість епох обмежена 100 з можливістю дострокового завершення через механізм раннього зупину.

Критерієм зупинки навчання служить відсутність покращення валідаційної втрати протягом 15 послідовних епох з автоматичним відновленням найкращих ваг моделі. Це забезпечує вибір оптимальної точки зупинки, що максимізує точність на незалежних даних. Процес навчання супроводжується детальним логуванням метрик якості кожні 10 епох для контролю збіжності та виявлення потенційних проблем на ранніх стадіях.

Технічна реалізація процесу навчання оптимізована для мінімізації часових витрат з можливістю завершення навчання на типовому наборі даних за декілька хвилин на сучасному апаратному забезпеченні. Така ефективність критично важлива для практичного застосування в умовах необхідності швидкого переналаштування моделі при зміні експлуатаційних параметрів або характеристик досліджуваних деталей.

Експериментальна валідація розробленої нейромережевої системи проведена в рамках комплексного порівняльного аналізу з альтернативними методами машинного навчання на репрезентативному наборі даних, що містить 50,000 зразків різних комбінацій деталей-механізм зношування. Результати досліджень, узагальнені в табл. 3. Вони продемонстрували виняткову ефективність запропонованого підходу у порівнянні з традиційними методами прогнозування.

Крім цього розроблена нейромережева модель показала найвищі показники точності серед досліджених алгоритмів з коефіцієнтом детермінації $R^2 = 0.9856$, середньоквадратичною похибкою $RMSE = 12.45$ мкм та середньою абсолютною процентною похибкою $MAPE = 3.21\%$. Ці результати значно перевершують показники

альтернативних методів: Random Forest ($R^2 = 0.9234$, RMSE = 18.76 мкм; MAPE = 5.87%); SVM ($R^2 = 0.8567$, RMSE = 25.43 мкм, MAPE = 8.92%); ARIMA ($R^2 = 0.6789$, RMSE = 34.21 мкм, MAPE = 12.45%). Зазначене наочно демонструється на рис. 3.




Рисунок 3 – Порівняльні графіки алгоритмів машинного навчання за показниками коефіцієнта детермінації (а) та середньоквадратичної помилки (б)

Джерело: розроблено авторами

Детальний аналіз результатів по окремих типах деталей (табл. 3) виявив найкращу ефективність прогнозування для поршневих кілець з абразивним механізмом зношування. При цьому модель досягла коефіцієнта детермінації $R^2 = 0.9923$ з мінімальною середньоквадратичною похибкою RMSE = 8.12 мкм та найнижчою процентною похибкою MAPE = 2.45%. Визначене можливо пояснити більш передбачуваним характером абразивного зношування у порівнянні з втомними та корозійно-механічними процесами, що підтверджується груповою діаграмою (рис. 4).




Рисунок 4 – Групова діаграма порівняння ефективності всіх алгоритмів для кожної комбінації деталей-механізм зношування за показником R^2

Джерело: розроблено з використанням робіт [5,17]

Таблиця 3 – Детальні результати ефективності алгоритмів для кожної комбінації деталь-механізм зношування

Комбінація	Алгоритм	R ²	RMSE	MAPE (%)
Поршневі кільця+Абразивний	MLP+LTSM	0.9923	8.12	2.45
	Random Forest	0.9456	14.23	4.76
	SVM	0.8834	19.87	7.23
	ARIMA	0.7234	28.45	10.12
Шестерні КП+Втомний	MLP+LTSM	0.9812	15.67	3.89
	Random Forest	0.9123	21.34	6.45
	SVM	0.8445	28.76	9.12
	ARIMA	0.6523	37.89	13.45
Підшипники+Втомний	MLP+LTSM	0.9834	11.23	3.12
	Random Forest	0.9189	17.45	5.67
	SVM	0.8567	23.12	8.45
	ARIMA	0.6789	31.67	11.89
Гільзи циліндрів+Корозійно-механічний	MLP+LTSM	0.9845	14.78	3.45
	Random Forest	0.9167	20.12	6.23
	SVM	0.8423	29.34	9.78
	ARIMA	0.6598	38.23	13.12

Джерело: розроблено авторами

Графік середньої абсолютної відсоткової помилки (рис. 5) демонструє, що всі значення MAPE для розробленої моделі знаходяться в діапазоні відмінної якості прогнозування (<4%), тоді як альтернативні методи показують значно гірші результати. Для шестерень коробки передач з втомним механізмом зношування модель має $R^2 = 0.9812$ з $RMSE = 15.67$ мкм та $MAPE = 3.89\%$. Це демонструє здатність ефективно моделювати складні циклічні процеси деградації зубчастих передач.



Рисунок 5 – Графік середньої абсолютної відсоткової помилки (MAPE) з індикаторами якості прогнозування

Джерело: розроблено авторами

Підшипники кочення з втомним зношуванням характеризувалися показниками $R^2 = 0.9834$, $RMSE = 11.23$ мкм, $MAPE = 3.12\%$, що корелює з їх високою твердістю

поверхні (650.8 HV) та мінімальним коефіцієнтом тертя (0.05). Про це свідчать діаграми розподілу матеріальних характеристик (рис. 6).




Рисунок 6 – Діаграми розподілу основних матеріальних характеристик досліджуваних типів деталей: твердість (а), шорсткість поверхні (б), коефіцієнт тертя (в), робоча температура (г)

Джерело: розроблено з використанням результатів роботи [9]

Динаміка процесу навчання (рис. 7) продемонструвала стабільну збіжність без ознак перенавчання, що підтверджується близькістю кривих навчання та валідації протягом усього процесу оптимізації. Теплова карта ефективності (рис. 4) наочно ілюструє переваги розробленого алгоритму для всіх досліджуваних комбінацій деталей-механізм зношування, де зелений колір відповідає найвищій ефективності.

Аналіз розподілу помилок найкращого алгоритму (рис. 6) показав, що найбільші відхилення прогнозів спостерігаються для шестерень коробки передач, що пов'язано зі складністю моделювання втомних процесів у зубчастих передачах під змінними навантаженнями. Водночас, графіки RMSE та MAPE демонструють стабільно низькі значення помилок для всіх типів деталей.

Порівняльний аналіз ефективності, представлений в табл. 4 та візуалізований на рис. 1, підтвердив переваги глибокого навчання для задач прогнозування зносу, де традиційні статистичні методи (ARIMA) показали втричі гіршу точність ($R^2 = 0.6789$) порівняно з розробленою неймережевою системою. Ансамблеві методи (Random Forest) продемонстрували помірну ефективність ($R^2 = 0.9234$), проте поступилися нейронним мережам у точності прогнозування на 6.2%.

Стабільність результатів підтверджена крос-валідацією на незалежній тестовій вибірці, що складає 25% від загального обсягу даних (12,500 зразків). Відсутність значущих відмінностей між показниками на навчальній та тестовій вибірках. Зазначене демонструється динамікою навчання на рис. 3 та свідчить про високу узагальнюючу здатність моделі і її придатність для практичного застосування в умовах реальної експлуатації транспортної та сільськогосподарської техніки.




Рисунок 7 – Графіки зміни коефіцієнта детермінації в процесі навчання алгоритмів (суцільні лінії - навчальна вибірка, пунктирні - валідаційна)

Джерело: розроблено авторами




Рисунок 6 – Графіки розподілу помилок алгоритму MLP+LTSM по типах механічних деталей: RMSE (а) та MAPE (б)

Джерело: розроблено авторами на основі робіт [18,19]

Таблиця 4 – Порівняльні показники ефективності досліджених алгоритмів машинного навчання

Алгоритм	R^2 (коефіцієнт детермінації)	RMSE	MAPE (%)	Ранг
MLP+LTSM	0.9856	12.45	3.21	1
Random Forest	0.9234	18.76	5.87	2
SVM	0.8567	25.43	8.92	3
ARIMA	0.6789	34.21	12.45	4

Джерело: розроблено авторами

Оцінка практичної придатності розробленої нейромережевої системи для промислового застосування вимагає комплексного аналізу обчислювальних вимог, стійкості до реальних умов експлуатації та потенційних обмежень використання синтетичних даних. Компактна архітектура моделі з приблизно 12,000 параметрів забезпечує оптимальний баланс між точністю прогнозування та обчислювальною ефективністю, що критично важливо для інтеграції у системи реального часу.

Вимоги до обчислювальних ресурсів є мінімальними завдяки оптимізованій архітектурі нейронної мережі. Час навчання на повному наборі даних (50,000 зразків) не перевищує декількох хвилин на сучасному апаратному забезпеченні, а час інференції для одного прогнозу складає менше мілісекунди, що дозволяє реалізацію предиктивного обслуговування в режимі реального часу. Модель може ефективно функціонувати на стандартних промислових контролерах без необхідності спеціалізованого обладнання.

Аналіз стійкості до зашумлених даних показав високу робастність розробленої системи завдяки використанню батч-нормалізації та dropout регуляризації. Експериментальне додавання гаусівського шуму з коефіцієнтом варіації до 20% до вхідних параметрів призвело до зниження точності лише на 3-5%, що підтверджує придатність моделі для роботи в умовах реальних промислових даних з природними флуктуаціями сенсорних вимірювань.

Виявлено, що основним обмеженням дослідження є використання виключно синтетичних даних, генерованих на основі теоретичних моделей зношування. Хоча такий підхід дозволив створити великий репрезентативний набір даних та забезпечити контрольовані умови експерименту, реальні процеси зношування можуть включати додаткові фактори, що не враховані в синтетичних моделях. При цьому включається вплив мікроструктури матеріалу, локальні концентрації напружень, нерівномірність змащування та інші стохастичні фактори.

В той час валідація на реальних експериментальних даних залишається критично важливим етапом для підтвердження практичної ефективності розробленої системи. Тому рекомендується поетапне впровадження з початковою валідацією на обмеженій кількості реальних об'єктів та поступовим розширенням області застосування після підтвердження точності прогнозів.

Визначено, що можливості адаптації до різних типів деталей обмежені необхідністю переналаштування моделі для кожного нового типу матеріалу або механізму зношування. Результати показали значні відмінності в точності прогнозування для різних комбінацій деталей-механізм (від $R^2 = 0.9812$ до $R^2 = 0.9923$), що свідчить про специфічність навчених зв'язків. Показано, що для нових типів деталей може знадобитися збір додаткових навчальних даних та часткове переналаштування архітектури мережі.

Виявлено, що температурна стабільність алгоритмів машинного навчання в промислових умовах може становити додаткову проблему, особливо для мобільних систем діагностики транспортної та сільськогосподарської техніки. Проте, використання стандартизованих вхідних параметрів частково нівелює цю проблему, оскільки температурні ефекти враховуються в процесі нормалізації даних.

Інтеграційні виклики включають необхідність забезпечення якості вхідних даних від сенсорних систем, калібрування вимірювальних приладів та синхронізацію з існуючими системами технічного обслуговування транспортної та сільськогосподарської техніки. При цьому рекомендується розробка комплексної системи контролю якості даних з автоматичним виявленням аномальних вимірювань та процедурами їх корекції.

Доведено, що економічна ефективність впровадження розробленої системи значною мірою залежить від масштабу застосування та вартості незапланованих ремонтів. Попередні оцінки показують потенційну економію 15...25 % витрат на технічне обслуговування завдяки переходу від календарного до станового обслуговування. В той час остаточна оцінка вимагає детальних економічних розрахунків для конкретних умов експлуатації.

Інтеграція розробленої нейромережевої системи прогнозування зносу у сучасні кіберфізичні системи транспортної та сільськогосподарської техніки відкриває широкі можливості для реалізації концепції предиктивного обслуговування та створення інтелектуальних систем управління технічним станом. При цьому архітектура системи предиктивного обслуговування базується на багаторівневій структурі, що включає рівень сенсорів для збору первинних даних, рівень обробки та аналізу для реалізації нейромережевих алгоритмів, та рівень прийняття рішень для формування рекомендацій щодо технічного обслуговування техніки.

В процесі досліджень виявлено, що сенсорна підсистема повинна забезпечувати збір всіх дванадцяти вхідних параметрів, ідентифікованих як критичні для точного прогнозування зносу. Це включає датчики твердості для моніторингу зміни механічних властивостей поверхонь, профілометри для оцінки шорсткості, трибометричні датчики для вимірювання коефіцієнта тертя, датчики навантаження та швидкості для контролю експлуатаційних режимів, температурні сенсори для моніторингу теплового стану, а також хімічні аналізатори мастильних матеріалів для оцінки їх деградації.

Визначено, що реалізація системи вимагає високочастотного збору даних з частотою не менше 1 Гц для статичних параметрів та до 1000 Гц для динамічних характеристик вібрації та акустичних сигналів. Така інтенсивність збору даних потребує ефективних алгоритмів фільтрації та попередньої обробки сигналів для зменшення обчислювального навантаження на основну нейромережеву систему.

При інтеграції з існуючими системами управління технічним станом є потреба в розробці стандартизованих інтерфейсів обміну даними, сумісних з промисловими протоколами зв'язку такими як CAN-bus для транспортної та сільськогосподарської техніки, ISOBUS для сільськогосподарських машин, та Ethernet-базовані рішення для стаціонарного обладнання. Критично важливим є забезпечення кібербезпеки системи через використання шифрування даних та автентифікації пристроїв у мережі [13, 25].

В даній роботі архітектура обчислювальної підсистеми оптимізована для розгортання на периферійних пристроях (edge computing) для мінімізації затримок та зменшення навантаження на мережеві ресурси. Компактність моделі з 12,000 параметрами дозволяє реалізацію на промислових контролерах з обмеженими обчислювальними ресурсами або спеціалізованих мікропроцесорах з підтримкою нейромережевих обчислень.

Система управління рішеннями повинна забезпечувати автоматичне формування рекомендацій щодо технічного обслуговування на основі прогнозів залишкового ресурсу з урахуванням планових графіків роботи техніки, наявності запасних частин та трудових ресурсів. Інтеграція з ERP системами підприємств дозволить оптимізувати логістику запасних частин та планування ремонтних робіт транспортної та сільськогосподарської техніки.

Економічна ефективність впровадження системи обумовлена можливістю переходу від календарного до станового технічного обслуговування, що згідно з результатами досліджень може забезпечити зниження витрат на незаплановані ремонти на 20...30% та збільшення коефіцієнта готовності техніки на 5...8%. Показано, що

додатковий економічний ефект досягається через оптимізацію складських запасів запасних частин та зменшення простоїв обладнання.

Масштабованість системи забезпечується модульною архітектурою, що дозволяє поетапне впровадження починаючи з найбільш критичних вузлів, систем, агрегатів та поступове розширення на весь парк техніки. Також визначено, що хмарна інфраструктура може використовуватися для централізованого зберігання історичних даних, аналітики тенденцій та навчання моделей на агрегованих даних від множини об'єктів транспортної та сільськогосподарської техніки.

Перспективи розвитку методів інжинірингу із застосуванням нейронних мереж, включають інтеграцію з технологіями доповненої реальності для візуалізації прогнозів безпосередньо на обладнанні, використання технологій цифрових двійників для моделювання альтернативних стратегій обслуговування, та розробку адаптивних алгоритмів машинного навчання, здатних автоматично коригувати прогнози на основі накопичуваного досвіду експлуатації.

Висновки. 1. Показано, що розроблена архітектура глибокої нейронної мережі з чотирма повнозв'язними шарами (128-64-32-1 нейронів) забезпечує найвищу точність прогнозування зносу ресурсовизначальних деталей транспортної та сільськогосподарської техніки серед досліджених методів машинного навчання з коефіцієнтом детермінації $R^2 = 0.9856$, середньоквадратичною похибкою $RMSE = 12.45$ мкм та середньою абсолютною процентною похибкою $MAPE = 3.21\%$.

2. Порівняльний аналіз ефективності підтвердив переваги запропонованого підходу над альтернативними алгоритмами: Random Forest ($R^2 = 0.9234$), SVM ($R^2 = 0.8567$) та ARIMA ($R^2 = 0.6789$), що демонструє перевагу глибокого навчання для складних трибологічних задач прогнозування деградації матеріалів. Найкращі результати прогнозування отримані для поршневих кілець з абразивним механізмом зношування ($R^2 = 0.9923$, $RMSE = 8.12$ мкм, $MAPE = 2.45\%$), що пояснюється більшою передбачуваністю абразивних процесів у порівнянні з втомними та корозійно-механічними механізмами деградації.

Для всіх досліджуваних комбінацій деталей-механізм зношування (поршневі кільця, шестерні КП, підшипники, гільзи циліндрів) значення середньої абсолютної процентної похибки не перевищували 4%, що відповідає критеріям відмінної якості прогнозування згідно з міжнародними стандартами оцінки моделей машинного навчання.

3. Застосування комплексних методів регуляризації, включаючи батч-нормалізацію після кожного прихованого шару та dropout з коефіцієнтом 0.3, забезпечило стабільність навчання без ознак перенавчання та високу узагальнюючу здатність моделі на незалежних тестових даних. При цьому компактна архітектура з приблизно 12,000 параметрами забезпечує оптимальний баланс між точністю прогнозування та обчислювальною ефективністю з часом навчання, що не перевищує декількох хвилин, та часом інференції менше мілісекунди, що дозволяє реалізацію систем реального часу.

4. Аналіз практичної придатності підтвердив високу робастність системи до зашумлених промислових даних з можливістю збереження точності при додаванні гаусівського шуму з коефіцієнтом варіації до 20%, що забезпечує надійність функціонування в реальних умовах експлуатації. В той час розроблена концепція інтеграції у кіберфізичні системи передбачає багаторівневу архітектуру з сенсорною підсистемою для збору дванадцяти критичних параметрів, обчислювальною підсистемою для реалізації нейромережевих алгоритмів та системою управління рішеннями для оптимізації технічного обслуговування.

5. Економічна ефективність впровадження системи предиктивного обслуговування транспортної та сільськогосподарської техніки на основі розробленого алгоритму оцінюється в 20-30% зниження витрат на незаплановані ремонти та 5-8% збільшення коефіцієнта готовності техніки завдяки переходу від календарного до станового обслуговування. Основним обмеженням дослідження є використання виключно синтетичних даних, що вимагає подальшої валідації на реальних експериментальних даних, розширення спектра досліджуваних матеріалів та розробки адаптивних алгоритмів для автоматичного коригування прогнозів в умовах змінних експлуатаційних факторів.

Список літератури

1. Аулін В. В., Гриньків А. В., Головатий А. О. Кіберфізичний підхід при створенні транспортно-виробничих систем. *Центральноукраїнський науковий вісник. Технічні науки*. 2020. Вип. 3 (34). С. 331–343.
2. Головатий А. О., Чумак В. М., Манько Є. В. та ін. Вдосконалення математичного моделювання машинобудівних технологій для смарт-підприємств в системі машинного зору. *Центральноукраїнський науковий вісник. Технічні науки : зб. наук. пр. Кропивницький : ЦНТУ*, 2025. Вип. 11(42), ч. 2. С. 143–159. URL: [https://doi.org/10.32515/2664-262X.2025.11\(42\).2.143-159](https://doi.org/10.32515/2664-262X.2025.11(42).2.143-159) (дата звернення: 01.09.2025).
3. Індус М. П., Левченко О. В. *Математичне моделювання технічних систем*. К. : Либідь, 2019. 312 с.
4. Zhang B., Zhang S., Li W. Bearing performance degradation assessment using long short-term memory recurrent network. *Computers in Industry*. 2019. Vol. 106. P. 14–29. URL: <https://doi.org/10.1016/j.compind.2018.12.01> (дата звернення: 15.09.2025).
5. Singh K., Kumar S., Singh K. K. та ін. Computational data-driven based optimization of tribological performance of graphene filled glass fiber reinforced polymer composite using machine learning approach. *Materials Today: Proceedings*. 2022. Vol. 66. P. 3838–3846. URL: <https://doi.org/10.1016/j.matpr.2022.06.25> (дата звернення: 15.09.2025).
6. Susto G. A., Schirru A., Pampuri S. та ін. Machine Learning for Predictive Maintenance: A Multiple Classifier Approach. *IEEE Transactions on Industrial Informatics*. 2015. Vol. 11(3). P. 812–820. URL: <https://doi.org/10.1109/TII.2014.2349359> (дата звернення: 02.09.2025).
7. Shah R., Pai N., Thomas G. та ін. Machine Learning in Wear Prediction. *Journal of Tribology*. 2025. Vol. 147(4). Art. 040801. URL: <https://doi.org/10.1115/1.4066865> (дата звернення: 01.09.2025).
8. Wang X., Qin Q., Dai S. та ін. Machine Learning-Based Prediction of Mechanical Properties for Large Bearing Housing Castings. *Materials*. 2025. Vol. 18, Iss. 17. P. 4036. URL: <https://doi.org/10.3390/ma18174036> (дата звернення: 18.08.2025).
9. Liu Y., Pan D., Zhang H. та ін. Remaining Useful Life Prediction of Bearing via a Double Attention-Based Deep Neural Network. 2022 *IEEE Smart World, Ubiquitous Intelligence & Computing, Scalable Computing & Communications, Digital Twin, Privacy Computing, Metaverse : матеріали міжнар. конф.* (м. Haikou, China, 15–18 грудня 2022 р.). Piscataway : IEEE, 2023. P. 92. URL: <https://doi.org/10.1109/SmartWorld-UIC-ATC-ScalCom-DigitalTwin-PriComp-Metaverse56740.2022.00092> (дата звернення: 12.09.2025).
10. Asmai S. A., Basari A. S. H., Shibghatullah A. S. та ін. Neural network prognostics model for industrial equipment maintenance. 2011 *11th International Conference on Hybrid Intelligent Systems (HIS) : матеріали міжнар. конф.* (м. Melacca, Malaysia, 5–8 грудня 2011 р.). Piscataway : IEEE, 2011. P. 637–642. URL: <https://doi.org/10.1109/HIS.2011.6122176> (дата звернення: 18.08.2025).
11. Paredes J., Chávez D., Isa-Jara R. та ін. A hybrid machine learning algorithm approach to predictive maintenance tasks: A comparison with machine learning algorithms. *Results in Engineering*. 2025. Vol. 25. P. 105137. URL: <https://doi.org/10.1016/j.rineng.2025.105137> (дата звернення: 18.08.2025).
12. Kisten M., Ezugwu A. E., Olusanya M. O. Explainable Artificial Intelligence Model for Predictive Maintenance in Smart Agricultural Facilities. *IEEE Access*. 2024. Vol. 12. P. 24348–24367. URL: <https://doi.org/10.1109/ACCESS.2024.3365586> (дата звернення: 26.08.2025).
13. Tran K. P. Artificial Intelligence for Smart Manufacturing: Methods and Applications. *Sensors*. 2021. Vol. 21(16). P. 5584. URL: <https://doi.org/10.3390/s21165584> (дата звернення: 20.08.2025).
14. Mondal S., Goswami S. S. Machine learning applications in automotive engineering: Enhancing vehicle safety and performance. *Journal of Process Management New Technologies*. 2024. Vol. 12, № 1–2. P. 61–71. URL: <https://doi.org/10.5937/jpmnt12-50607> (дата звернення: 18.08.2025).
15. Jin L. Application of neural network method in engineering prediction. *Journal of Physics: Conference Series*. 2021. Vol. 2083, № 4. Art. 042080. doi.org/10.1088/1742-6596/2083/4/042080 (дата звернення: 17.08.2025).

16. Ali Y. Artificial Intelligence Application in Machine Condition Monitoring and Fault Diagnosis. *Artificial Intelligence – Emerging Trends and Applications*. IntechOpen, 2018. URL: doi.org/10.5772/intechopen.74932 (дата звернення: 2.09.2025).
17. Olivares D. C. Feature Engineering for Data-Based Predictive Maintenance : дис. ... докт. техн. наук : 08.00.11. Universidad de Sevilla, 2025. 154 с.
18. Baptista M., de Medeiros I. P., Malere J. P. та iн. Comparative case study of life usage and data-driven prognostics techniques using aircraft fault messages. *Computers in Industry*. 2016. Vol. 87. P. 68–81. URL: https://doi.org/10.1016/j.compind.2016.12.008 (дата звернення: 03.09.2025).
19. Ismoilov N., Jang S.-B. A Comparison of Regularization Techniques in Deep Neural Networks. *Symmetry*. 2018. Vol. 10, Iss. 11. Art. 648. URL: https://doi.org/10.3390/sym10110648 (дата звернення: 03.09.2025).
20. Chien C.-F., Ku C.-C., Lu Y.-Y. Ensemble learning for demand forecast of After-Market spare parts to empower data-driven value chain and an empirical study. *Computers & Industrial Engineering*. 2023. Vol. 184. Art. 109670. URL: https://doi.org/10.1016/j.cie.2023.109670 (дата звернення: 03.09.2025).
21. Dix M., Manca G., Fay A. Measuring the Robustness of Supervised ML Models to Label Noise in Industrial Data. 2025 *IEEE 8th International Conference on Industrial Cyber-Physical Systems (ICPS)* : матерiали мiжнар. конф. 2025. Art. 11087835. URL: https://doi.org/10.1109/ICPS65515.2025.11087835 (дата звернення: 03.09.2025).
22. Lisiecki A. Tribology and Surface Engineering. *Coatings*. 2019. Vol. 9, Iss. 10. Art. 663. URL: https://doi.org/10.3390/coatings9100663 (дата звернення: 30.08.2025).
23. Hofmann M., Neukart F., Bäck T. Artificial Intelligence and Data Science in the Automotive Industry. *arXiv*. 2017. URL: https://doi.org/10.48550/arXiv.1709.01989 (дата звернення: 30.08.2025).
24. Hermann M., Pentek T., Otto B. Design Principles for Industrie 4.0 Scenarios. 2016 *49th Hawaii International Conference on System Sciences (HICSS)* : матерiали мiжнар. конф. (м. Гонолулу, Гаваї, США, 5–8 сiч. 2016 р.). IEEE, 2016. P. 3928–3937. URL: https://doi.org/10.1109/HICSS.2016.488 (дата звернення: 30.08.2025).

References

1. Aulin, V. V., Hryn'kiv, A. V., & Holovaty, A. O. (2020). Cyber-physical approach to the creation of transport and production systems. *Tsentralknukrains'kyi naukovi visnyk. Tekhnichni nauky*, 3(34), 331–343 [in Ukrainian].
2. Holovaty, A. O., Chumak, V. M., Man'ko, Ye. V., et al. (2025). Improvement of mathematical modeling of mechanical engineering technologies for smart enterprises in the machine vision system. *Tsentralknukrains'kyi naukovi visnyk. Tekhnichni nauky*, 11(42), part 2, 143–159. Kropyvnytskyi: CNTU [in Ukrainian]. https://doi.org/10.32515/2664-262X.2025.11(42).2.143-159 (accessed September 1, 2025).
3. Indus, M. P., & Levchenko, O. V. (2019). Mathematical modeling of technical systems. Kyiv: Lybid' [in Ukrainian].
4. Zhang, B., Zhang, S., & Li, W. (2019). Bearing performance degradation assessment using long short-term memory recurrent network. *Computers in Industry*, 106, 14–29. doi.org/10.1016/j.compind.2018.12.01 (accessed September 15, 2025).
5. Singh, K., Kumar, S., Singh, K. K., et al. (2022). Computational data-driven based optimization of tribological performance of graphene filled glass fiber reinforced polymer composite using machine learning approach. *Materials Today: Proceedings*, 66, 3838–3846. https://doi.org/10.1016/j.matpr.2022.06.25 (accessed September 15, 2025).
6. Susto, G. A., Schirru, A., Pampuri, S., et al. (2015). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE Transactions on Industrial Informatics*, 11(3), 812–820. https://doi.org/10.1109/TII.2014.2349359 (accessed September 2, 2025).
7. Shah, R., Pai, N., Thomas, G., et al. (2025). Machine learning in wear prediction. *Journal of Tribology*, 147(4), Article 040801. https://doi.org/10.1115/1.4066865 (accessed September 1, 2025).
8. Wang, X., Qin, Q., Dai, S., et al. (2025). Machine learning-based prediction of mechanical properties for large bearing housing castings. *Materials*, 18(17), 4036. https://doi.org/10.3390/ma18174036 (accessed 18/08/2025).
9. Liu, Y., Pan, D., Zhang, H., et al. (2023). Remaining useful life prediction of bearing via a double attention-based deep neural network. In *2022 IEEE Smart World, Ubiquitous Intelligence & Computing, Scalable Computing & Communications, Digital Twin, Privacy Computing, Metaverse* (pp. 92). Piscataway: IEEE. https://doi.org/10.1109/SmartWorld-UIC-ATC-ScalCom-DigitalTwin-PriComp-Metaverse56740.2022.00092 (accessed September 12, 2025).
10. Asmai, S. A., Basari, A. S. H., Shibghatullah, A. S., et al. (2011). Neural network prognostics model for industrial equipment maintenance. In *2011 11th International Conference on Hybrid Intelligent Systems (HIS)* (pp. 637–642). Piscataway: IEEE. https://doi.org/10.1109/HIS.2011.6122176 (accessed August 18, 2025).
11. Paredes, J., Chávez, D., Isa-Jara, R., et al. (2025). A hybrid machine learning algorithm approach to predictive maintenance tasks: A comparison with machine learning algorithms. *Results in Engineering*, 25, 105137. https://doi.org/10.1016/j.rineng.2025.105137 (accessed August 18, 2025).

12. Kisten, M., Ezugwu, A. E., & Olusanya, M. O. (2024). Explainable artificial intelligence model for predictive maintenance in smart agricultural facilities. *IEEE Access*, 12, 24348–24367. doi.org/10.1109/ACCESS.2024.3365586 (accessed August 26, 2025).
13. Tran, K. P. (2021). Artificial intelligence for smart manufacturing: Methods and applications. *Sensors*, 21(16), 5584. https://doi.org/10.3390/s21165584 (accessed August 20, 2025).
14. Mondal, S., & Goswami, S. S. (2024). Machine learning applications in automotive engineering: Enhancing vehicle safety and performance. *Journal of Process Management New Technologies*, 12(1–2), 61–71. https://doi.org/10.5937/jpmnt12-50607 (accessed August 18, 2025).
15. Jin, L. (2021). Application of neural network method in engineering prediction. *Journal of Physics: Conference Series*, 2083(4), Article 042080. https://doi.org/10.1088/1742-6596/2083/4/042080 (accessed August 17, 2025).
16. Ali, Y. (2018). Artificial intelligence application in machine condition monitoring and fault diagnosis. In *Artificial Intelligence – Emerging Trends and Applications*. IntechOpen. doi.org/10.5772/intechopen.74932 (accessed September 2, 2025).
17. Olivares, D. C. (2025). Feature engineering for data-based predictive maintenance (Doctoral dissertation, Universidad de Sevilla) [in Spanish].
18. Baptista, M., de Medeiros, I. P., Malere, J. P., et al. (2016). Comparative case study of life usage and data-driven prognostics techniques using aircraft fault messages. *Computers in Industry*, 87, 68–81. https://doi.org/10.1016/j.compind.2016.12.008 (accessed September 3, 2025).
19. Ismoilov, N., & Jang, S.-B. (2018). A comparison of regularization techniques in deep neural networks. *Symmetry*, 10(11), 648. https://doi.org/10.3390/sym10110648 (accessed September 3, 2025).
20. Chien, C.-F., Ku, C.-C., & Lu, Y.-Y. (2023). Ensemble learning for demand forecast of after-market spare parts to empower data-driven value chain and an empirical study. *Computers & Industrial Engineering*, 184, 109670. https://doi.org/10.1016/j.cie.2023.109670 (accessed September 3, 2025).
21. Dix, M., Manca, G., & Fay, A. (2025). Measuring the robustness of supervised ML models to label noise in industrial data. In *2025 IEEE 8th International Conference on Industrial Cyber-Physical Systems (ICPS)*, Article 11087835. IEEE. https://doi.org/10.1109/ICPS65515.2025.11087835 (accessed September 3, 2025).
22. Lisiecki, A. (2019). Tribology and surface engineering. *Coatings*, 9(10), 663. https://doi.org/10.3390/coatings9100663 (accessed August 30, 2025).
23. Hofmann, M., Neukart, F., & Bäck, T. (2017). Artificial intelligence and data science in the automotive industry. *arXiv*. https://doi.org/10.48550/arXiv.1709.01989 (accessed August 30, 2025).
24. Hermann, M., Pentek, T., & Otto, B. (2016). Design principles for Industrie 4.0 scenarios. In *2016 49th Hawaii International Conference on System Sciences (HICSS)* (pp. 3928–3937). IEEE. https://doi.org/10.1109/HICSS.2016.488 (accessed August 30, 2025).

Vitaliy Chumak, Viktor Aulin, Prof., Dr. tech. sci., **Andrii Hrynkiv**, Sr. Researcher, PhD tech. sci., **Serhii Lysenko**, Assoc. Prof., PhD tech. sci., **Oleksandr Kuzyk**, Assoc. Prof., PhD tech. sci.
Central Ukrainian National Technical University, Kropyvnytskyi, Ukraine

Increasing the Wear Resistance and Reliability of Resource-Determining Parts of Transport and Agricultural Machinery by Engineering Methods Using Neural Networks

It is shown that in modern conditions of intensive development of Industry 4.0 and digitalization of machine-building processes, the problem of ensuring the reliability and durability of resource-determining parts of transport and agricultural machinery is of particular relevance. It is found that traditional approaches to predicting the technical condition of machines, based on calendar maintenance, do not meet modern requirements of economic efficiency and operational safety.

A methodology is proposed, which is based on the hybrid application of artificial neural networks - a multilayer perceptron (MLP) for identifying the dominant mechanisms of wear of machine parts and their conjugation and a recurrent long short-term memory network (LSTM) for predicting the dynamics of part degradation based on time series of operational parameters. It was determined that the use of synthetic data generated on the basis of physical models of wear allows overcoming the limitations associated with the lack of real operational data of machine components, systems and assemblies.

Validation of the developed algorithm on a representative data set (50,000 samples) demonstrated high prediction accuracy: coefficient of determination $R^2 = 0.98...0.99$, root mean square error $RMSE = 8.12...15.67 \mu m$, mean absolute percentage error $MAPE = 2.5...3.9\%$. These results confirm the prospects of integrating the proposed approach into cyber-physical systems of modern transport and agricultural machinery for implementing the concept of predictive maintenance.

wear prediction, artificial intelligence, MLP, LSTM, synthetic data, Archard model, predictive maintenance

Одержано (Received) 16.09.2025

Прорецензовано (Reviewed) 17.09.2025

Прийнято до друку (Approved) 19.09.2025