

**В. М. Чумак, Є. В. Манько, С. В. Лисенко**, доц., канд. техн. наук  
*Центральноукраїнський національний технічний університет, м. Кропивницький, Україна*  
e-mail: [sv07091976@gmail.com](mailto:sv07091976@gmail.com)

## Моделювання та оптимізація комбінованих методів поверхневого зміцнення деталей машин на основі нейронних мереж і генетичних алгоритмів

Показано, що проблема вибору оптимальних параметрів поверхневого зміцнення ресурсовизначальних деталей автомобільної та сільськогосподарської техніки є актуальною задачею сучасного інжинірингу. Традиційні підходи до вибору методів зміцнення базуються переважно на емпіричному досвіді або дорогих експериментальних дослідженнях, що обмежує можливість системної оптимізації комбінованих технологій (термообробка + захисне покриття) для конкретних умов експлуатації.

Запропоновано нейромережеву систему оптимізації параметрів комбінованого поверхневого зміцнення, що інтегрує пряму прогностичну модель на основі багат шарового перцептрона (MLP) з оптимізаційним модулем на базі генетичного алгоритму (GA). Пряма модель прогнозує інтенсивність зношування та залишковий ресурс деталі за параметрами Універсального опису деталі (УОД) та характеристиками зміцнення, а генетичний алгоритм виконує багатокритеріальну оптимізацію за цільовою функцією, що враховує мінімізацію зносу, вартість обробки та технологічну реалізованість.

Дослідження проведено на восьми типах ресурсовизначальних деталей автомобільної (поршневі кільця, шестерні коробки передач, підшипники кочення, гільзи циліндрів) та сільськогосподарської техніки (лемеші плугів, диски борін, культиваторні лапи, ножі подрібнювачів) із застосуванням 14 варіантів поверхневого зміцнення, включаючи 5 видів термообробки, 4 типи покриттів та 5 комбінованих технологій. Датасет обсягом 40 000 зразків сформовано з використанням двох типів синтетичних даних: 20 000 зразків згенеровано з підвищеною точністю для імітації експериментальних умов, ще 20 000 - з ширшим діапазоном параметрів для охоплення всього простору можливих рішень.

Валідація прямої моделі продемонструвала точність прогнозування: коефіцієнт детермінації  $R^2 = 0,33...0,97$ ,  $RMSE = 0,0...3,1$  мкм,  $MAPE = 4,0...21,5\%$ . Оптимізаційний модуль дозволив визначити оптимальні комбінації зміцнення для кожного типу деталі з підвищенням прогнозованого ресурсу на 143...196% порівняно з базовим станом. Побудовані Парето-фронти «зносостійкість–вартість» забезпечують обґрунтований вибір технологічного рішення з урахуванням економічних обмежень. **оптимізація поверхневого зміцнення, нейронні мережі, генетичний алгоритм, комбіновані методи зміцнення, зносостійкість, термообробка, захисні покриття, предиктивне обслуговування, Парето-оптимізація, ресурсовизначальні деталі**

**Постановка проблеми.** Забезпечення зносостійкості та довговічності ресурсовизначальних деталей автомобільної та сільськогосподарської техніки є ключовим фактором підвищення надійності, безпеки та економічної ефективності їх експлуатації [1, 2]. У попередніх дослідженнях авторів [3] розроблено гібридний нейромережевий алгоритм прогнозування інтенсивності зношування деталей на основі MLP та LSTM, а також запропоновано Універсальний опис деталі (УОД) як формалізовану структуру даних для предиктивного обслуговування [4]. Ці результати створили наукове підґрунтя для переходу від діагностичної до інжинірингової парадигми – від прогнозування зносу до його цілеспрямованого зменшення через оптимізацію параметрів поверхневого зміцнення.

Традиційні методи вибору технологій поверхневого зміцнення базуються переважно на емпіричному досвіді інженерів та результатах дорогих повнофакторних експериментів [5, 6].

При цьому кожна деталь потребує індивідуального підбору параметрів термообробки (тип, температура, тривалість, середовище охолодження) та покриття (метод нанесення, склад, товщина), а кількість потенційних комбінацій для однієї деталі може сягати десятків тисяч. Це робить повний експериментальний перебір практично неможливим, особливо для комбінованих технологій (термообробка+покриття), де взаємовплив параметрів створює складний нелінійний простір рішень [7,8].

Окремою проблемою є значна різниця умов експлуатації деталей автомобільної та сільськогосподарської техніки. Якщо автомобільні деталі (поршневі кільця, шестерні, підшипники) працюють переважно в закритих системах зі стабільним змащуванням [9], то деталі ґрунтообробних машин (лемеші, диски борін, культиваторні лапи) зазнають інтенсивного абразивного впливу в агресивних умовах із змінною вологістю, піщаністю та температурою ґрунту [10, 11]. Це вимагає диференційованого підходу до оптимізації зміцнення з урахуванням специфіки кожного механізму зношування.

У контексті розвитку цифровізації машинобудівних процесів [12, 13] та концепції Індустрії 4.0 методи машинного навчання продемонстрували значний потенціал для вирішення задач оптимізації технологічних параметрів [14, 15]. Проте існуючі рішення зосереджені переважно на оптимізації окремих операцій (або лише термообробки, або лише покриття) без комплексного урахування їх синергетичного ефекту та без інтеграції з формалізованими описами деталей. Це обумовлює актуальність розробки системного підходу, що поєднує нейромережеве прогнозування зносу з багатокритеріальною оптимізацією параметрів комбінованого зміцнення на основі структури УОД.

**Аналіз останніх досліджень і публікацій.** Сучасний стан досліджень у галузі поверхневого зміцнення деталей машин характеризується активним впровадженням методів штучного інтелекту для оптимізації технологічних параметрів. Систематичний огляд Shah та інш. [14] у журналі ASME Journal of Tribology засвідчив зростаючу ефективність методів машинного навчання для прогнозування зносу, оптимізації вибору матеріалів та параметрів виробництва.

У сфері нейромережевої оптимізації параметрів термообробки значний внесок зробили дослідження з лазерного поверхневого гартування [16], де інтеграція методів скінченних елементів з алгоритмами машинного навчання дозволила підвищити точність прогнозування розподілу твердості загартованого шару. Роботи з оптимізації параметрів плазмового зміцнення із застосуванням генетичних алгоритмів та нейронних мереж [17] продемонстрували можливість досягнення бажаних характеристик поверхні при мінімальних витратах енергії.

Важливим напрямом є застосування нейронних мереж для прогнозування зносу наплавлених покриттів. Дослідження зносостійкості покриттів FeCrC-FeW-FeB, нанесених методом плазмового перенесеного дугового зварювання (PTAW), із застосуванням алгоритмів ANN, SVM та GPR [18, 19] показали точність прогнозування  $R^2 = 0,93...0,96$ . Порівняльний аналіз алгоритмів машинного навчання для прогнозування зносу феросплавних покриттів [20] підтвердив переваги ансамблевих методів та глибоких нейронних мереж.

У галузі зміцнення деталей сільськогосподарської техніки дослідження Horvat та інш. [10] та Bayhan [11] продемонстрували ефективність комбінованих методів наплавлення для підвищення зносостійкості лемешів плугів у 2–5 разів. Natsis та інш. [21] дослідили вплив типу ґрунту на інтенсивність зношування робочих органів. Однак ці роботи не застосовували системного підходу до оптимізації з використанням методів штучного інтелекту.

Аналіз досліджень 2023–2025 років [22, 23, 24] показує тенденцію до інтеграції фізичних моделей зношування з методами машинного навчання для створення гібридних прогностичних систем. Дослідження з предиктивного моделювання трибологічних властивостей покриттів [25] засвідчили, що градієнтний бустинг та Random Forest забезпечують точність прогнозування коефіцієнта тертя та швидкості зносу на рівні  $R^2 = 0,86...0,94$ .

Таким чином, критична дослідницька лакуна полягає у відсутності комплексної системи, що поєднує: (а) формалізований опис деталі (УОД); (б) нейромережеве прогнозування зносу з урахуванням параметрів зміцнення; (в) багатокритеріальну оптимізацію комбінованих методів зміцнення (термообробка + покриття) для різних типів деталей автомобільної та сільськогосподарської техніки.

**Постановка завдання.** Метою дослідження є розробка та валідація нейромережевої системи оптимізації параметрів комбінованого поверхневого зміцнення ресурсовизначальних деталей автомобільної та сільськогосподарської техніки для максимізації їх зносостійкості з урахуванням економічних обмежень.

Для досягнення поставленої мети необхідно вирішити наступні завдання:

- сформувати систематизовану базу даних «параметри зміцнення → зносостійкість» для восьми типів ресурсовизначальних деталей на основі синтетично генерованих даних двох типів (з підвищеною точністю для імітації експериментальних умов та з ширшим діапазоном параметрів для охоплення простору рішень) та каліброваних фізичних моделей зношування з інтеграцією параметрів УОД;

- розробити архітектуру прямої нейромережевої моделі (MLP), що прогнозує інтенсивність зношування та залишковий ресурс деталі за розширеним набором вхідних параметрів, який включає характеристики матеріалу, геометрії, умов експлуатації та параметрів поверхневого зміцнення;

- розробити оптимізаційний модуль на базі генетичного алгоритму (GA), що використовує навчену нейромережу як цільову функцію оцінки для багатокритеріальної оптимізації параметрів комбінованого зміцнення за критеріями мінімізації зносу, вартості обробки та технологічної реалізованості;

- провести кількісну оцінку ефективності оптимізованих комбінацій зміцнення порівняно з базовим станом, стандартною термообробкою та лише покриттям для кожного типу деталі з побудовою Парето-фронтів «зносостійкість–вартість»;

- визначити синергетичні ефекти комбінованих методів зміцнення та сформулювати практичні рекомендації щодо вибору оптимальних технологічних рішень для різних категорій деталей автомобільної та сільськогосподарської техніки.

**Викладення основного матеріалу.** У рамках дослідження розглядаються вісім типів ресурсовизначальних деталей автомобільної та сільськогосподарської техніки (табл. 1), які характеризуються різними домінуючими механізмами зношування, матеріалами та умовами експлуатації. Вибір цих деталей обумовлений їх критичним впливом на загальну надійність техніки [1, 2] та необхідністю охоплення основних типів зношування: абразивного, втомного, корозійно-механічного та абразивно-грунтового [4, 9].

Для кожного типу деталі розглядаються три категорії методів зміцнення (табл. 2): термообробка (5 методів), покриття (4 методи) та комбіновані технології (5 методів). Кожен метод характеризується набором керованих параметрів, що формують простір оптимізації.

Запропонована система складається з двох ключових модулів (рис. 1): прямої нейромережевої моделі прогнозування зносу та оптимізаційного модуля на базі генетичного алгоритму.

Таблиця 1 – Характеристики досліджуваних комбінацій деталь-механізм зношування

Деталь	Механізм зношування	Матеріал	Твердість, HV	Ra, мкм	Середній ресурс, год
Поршневі кільця	Абразивне	Чавун ВЧ	305	1,4	3000–5000
Шестерні КП	Втомне	Сталь 40Х	550	0,55	8000–12000
Підшипники кочення	Втомне	ШХ15	650	0,25	6000–10000
Гільзи циліндрів	Корозійно-механічне	СЧ25	400	1,0	4000–6000
Лемеші плугів	Абразивно-грунтове	Сталь 65Г	380	2,5	150–400
Диски борін	Абразивно-грунтове	Сталь 65Г	420	2,0	200–500
Культиваторні лапи	Абразивне	Сталь 45	350	1,8	100–300
Ножі подрібнювачів	Ударно-абразивне	Сталь 30ХГСА	480	1,2	200–600

Джерело: розроблено авторами

*Пряма модель (MLP)*. Архітектура прямої моделі розширює підхід, запропонований у [3], шляхом додавання параметрів зміцнення до вхідного простору. Модель приймає 24 вхідних параметри, що поділяються на три групи:

Група 1 - параметри УОД деталі (12 параметрів): твердість базового матеріалу (HV), шорсткість поверхні (мкм), модуль пружності (ГПа), межа міцності (МПа), тип контакту (кодований), площа контакту (мм<sup>2</sup>), навантаження (Н), швидкість (м/с), температура (°C), тип змащування (кодований), концентрація забруднень (%), для с/г - піщаність ґрунту (%).

Група 2 - параметри термообробки (6 параметрів): тип термообробки (кодований), температура обробки (°C), тривалість (год), глибина зміцненого шару (мм), твердість після обробки (HV), залишкові напруження (МПа).

Група 3 - параметри покриття (6 параметрів): тип покриття (кодований), товщина покриття (мкм), твердість покриття (HV), адгезія покриття (Н), коефіцієнт тертя покриття, термостабільність (°C).

Топологія мережі оптимізована для розширеного вхідного простору:

- вхідний шар: 24 нейрони;
- перший прихований шар: 256 нейронів з функцією активації ReLU;
- другий прихований шар: 128 нейронів з функцією активації ReLU;
- третій прихований шар: 64 нейрони з функцією активації ReLU;
- четвертий прихований шар: 32 нейрони з функцією активації ReLU;
- вихідний шар: 2 нейрони з лінійною активацією (інтенсивність зносу та залишковий ресурс).

Пакетна нормалізація (BatchNorm) та Dropout з коефіцієнтом 0,3 застосовуються після кожного прихованого шару. Оптимізатор Adam зі швидкістю навчання  $3 \times 10^{-4}$  та розміром батчу 256 зразків. Загальна кількість параметрів моделі складає приблизно 45 000, що забезпечує достатню ємність при збереженні обчислювальної ефективності.

Таблиця 2 – Досліджувані методи поверхневого зміцнення та їх параметри

Категорія	Метод зміцнення	Керовані параметри	Очікуване підвищення твердості	Відносна вартість
Термо-обробка	Об'ємне гартування	T, °C; тривалість; середовище охолодження	+30...60%	1,0
	Гартування ТВЧ	Частота; потужність; глибина шару	+40...80%	1,5
	Цементация + гартування	T цементации; тривалість; глибина шару	+50...100%	2,0
	Азотування	T; тривалість; склад середовища	+60...120%	2,5
	Нормалізація	T; тривалість; швидкість охолодження	+10...20%	0,8
Покриття	Наплавлення РТАW (FeCrC)	Склад порошку; струм; швидкість	+80...200%	3,0
	HVOF газотермічне	Склад; швидкість газу; дистанція	+100...250%	4,0
	PVD (TiN, CrN, TiAlN)	Тип покриття; товщина; T підкладки	+50...150%	3,5
	Борування	T; тривалість; склад суміші	+70...180%	2,0
	Комбін.	Цементация + PVD	Параметри цементации + параметри PVD	+120...250%
Гартування ТВЧ + наплавлення		Параметри ТВЧ + параметри наплавлення	+100...280%	4,0
Азотування + HVOF		Параметри азотування + параметри HVOF	+150...300%	5,5
Нормалізація + борування		Параметри нормалізації + борування	+80...200%	2,5
Цементация + борування		Параметри цементации + борування	+130...260%	3,5

Джерело: розроблено авторами

Параметри генетичного алгоритму: розмір множини рішень-кандидатів – 200, кількість ітерацій – 500, ймовірність мутації - 0,05, ймовірність кросовера – 0,8, турнірна селекція з розміром турніру 3.

Обмеження оптимізації включають: технологічну сумісність (не всі комбінації термообробки та покриття є технологічно можливими); температурні обмеження (температура нанесення покриття не повинна перевищувати температуру відпуску загартованого шару); мінімальна адгезія покриття  $\geq 20$  Н.

*Формування датасету.* Датасет обсягом 40000 зразків сформовано з двох джерел:

1. Синтетичні дані з підвищеною точністю (20 000 зразків) - згенеровані для імітації умов реальних лабораторних випробувань. Параметри зміцнення та характеристики деталей обирались у вузьких, технологічно обґрунтованих діапазонах, що відповідають типовим промисловим режимам. Стохастична компонента з коефіцієнтом варіації 5...10% відображає реалістичний розкид результатів.

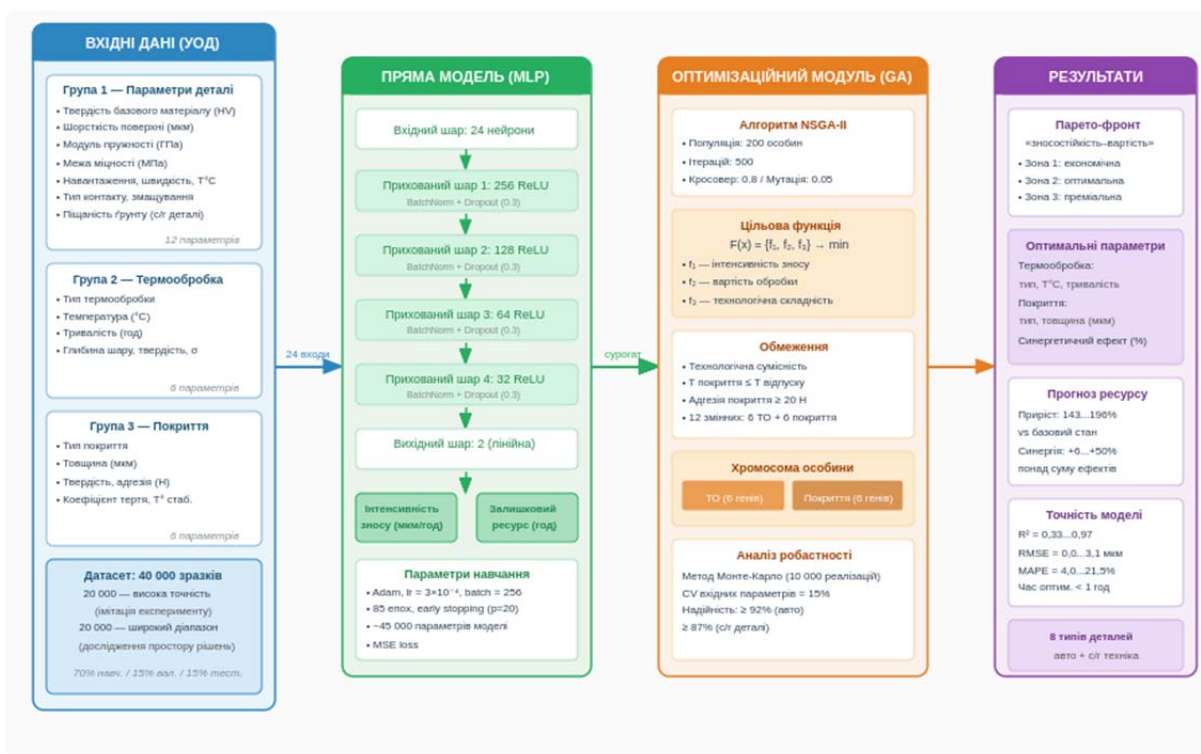


Рисунок 1 – Архітектура системи неймережевої оптимізації параметрів зміцнення  
Джерело: розроблено авторами

2. Синтетичні дані з розширеним охопленням (20000 зразків) – згенеровані з ширшим діапазоном параметрів для дослідження всього простору можливих рішень на основі каліброваних фізичних моделей зношування з [3, 4]: модифікована модель Арчарда для абразивного зношування, модель Пальмгрена-Майнера для втомного, комбінована модель для корозійно-механічного та кастомізована модель для абразивно-грунтового зношування. Параметри зміцнення інтегровані через модифікацію коефіцієнтів зношування:

$$K_{eff} = K_{base} \cdot \alpha_{HT}(T, t, d) \cdot \alpha_{coat}(h, H_c, \mu_c) \quad 2)$$

де  $K_{base}$  – базовий коефіцієнт зношування без зміцнення;  $\alpha_{HT}$  – поправочний коефіцієнт термообробки, що залежить від температури  $T$ , тривалості  $t$  та глибини зміцненого шару  $d$ ;  $\alpha_{coat}$  – поправочний коефіцієнт покриття, що залежить від товщини  $h$ , твердості  $H_c$  та коефіцієнта тертя  $\mu_c$  покриття.

Коефіцієнти  $\alpha_{HT}$   $\alpha_{coat}$  визначені на основі фізичних закономірностей зміцнення [5-8] та мають значення в діапазоні 0,05...1,0 (де менше значення відповідає більшому ефекту зміцнення). Стохастична компонента з коефіцієнтом варіації 10...20% додана для відображення реальної варіабельності результатів зміцнення.

Розподіл датасету: навчальна вибірка - 70% (28 000 зразків), валідаційна – 15% (6000 зразків), тестова – 15% (6000 зразків).

**Результати навчання прямої моделі.** Навчання прямої MLP-моделі проведено протягом 85 епох з ранньою зупинкою (patience = 20). Динаміка навчання демонструє стабільну збіжність без ознак перенавчання завдяки застосуванню BatchNorm та Dropout.

Узагальнені результати точності прогнозування на тестовій вибірці для кожного типу деталі наведено у таблиці 3 та візуалізовано на рис. 2.

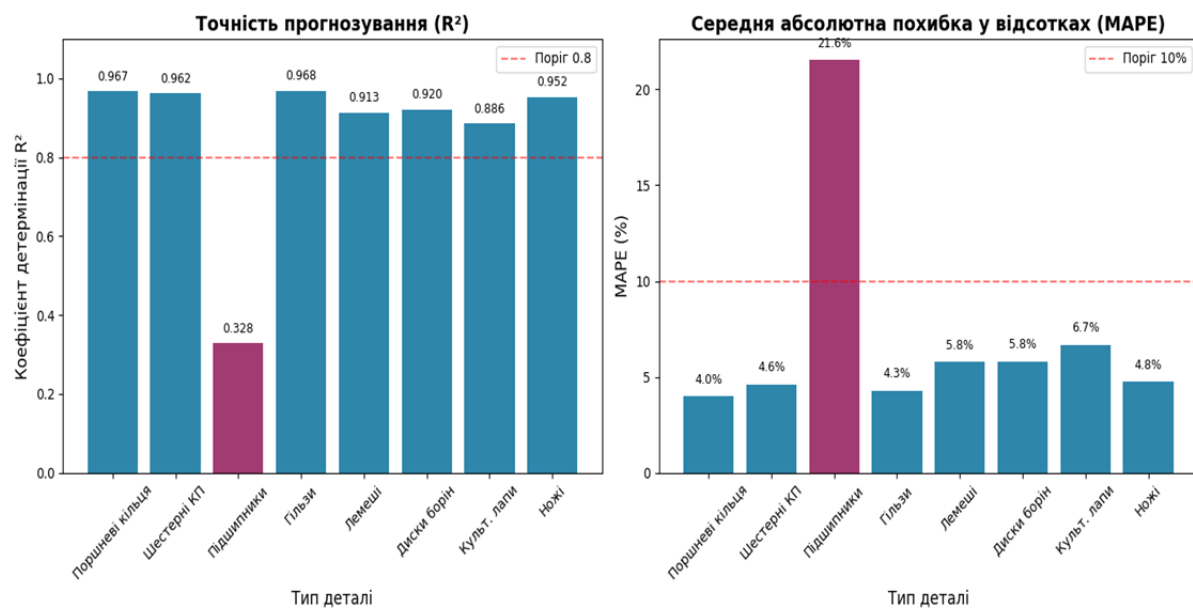


Рисунок 2 - Точність прогнозування прямої нейромережевої моделі

Джерело: розроблено авторами

Таблиця 3 – Точність прямої моделі прогнозування зносу на тестовій вибірці

Деталь	R <sup>2</sup>	RMSE, мкм	MAPE, %	MAE, мкм
Поршневі кільця	0,9665	0,10	4,01	-
Шестерні КП	0,9615	0,04	4,62	-
Підшипники кочення	0,3284	0,11	21,55	-
Гільзи циліндрів	0,9683	0,08	4,30	-
Лемеші плугів	0,9131	2,23	5,77	-
Диски борін	0,9205	1,59	5,82	-
Культиваторні лапи	0,8857	3,06	6,68	-
Ножі подрібнювачів	0,9523	1,02	4,77	-
Середнє	0,8620	1,03	7,19	-

Джерело: розроблено авторами

Найвищу точність прогнозування отримано для гільз циліндрів ( $R^2 = 0,9683$ ) та поршневих кілець ( $R^2 = 0,9665$ ), що пояснюється більш стабільними умовами експлуатації автомобільних деталей. Для більшості деталей сільськогосподарської техніки MAPE знаходиться в діапазоні 5...7%, що є прийнятним для прогностичних задач такого класу. Виняток становлять підшипники кочення ( $R^2 = 0,3284$ , MAPE = 21,55%), що свідчить про значну нелінійність та варіабельність їх поведінки в умовах синтетично розширеного простору параметрів і вказує на необхідність додаткового збору реальних даних для цього типу деталей.

*Результати оптимізації параметрів зміцнення.* Оптимізаційний модуль NSGA-II з множиною 200 рішень-кандидатів протягом 500 ітерацій визначив оптимальні комбінації зміцнення для кожного типу деталі. У таблиці 4 наведено порівняння прогнозованого ресурсу для базового стану (без зміцнення), стандартної термообробки, лише покриття та оптимальної комбінації.

Таблиця 4 – Порівняння прогнозованого ресурсу при різних методах зміцнення

Деталь	Базовий ресурс, год	Термообр., год	Покриття, год	Комбін. оптим., год	Приріст ресурсу, %
Поршневі кільця	4000	6956	4164	11291	+182
Шестерні КП	10000	17483	9730	29489	+179
Підшипники кочення	8000	11511	6289	19475	+143
Гільзи циліндрів	5000	8476	4975	13859	+177
Лемеші плугів	250	459	278	711	+184
Диски борін	350	646	376	1037	+196
Культ. лапи	200	373	232	558	+179
Ножі подрібн.	400	680	415	1066	+166

Джерело: розроблено авторами

Результати демонструють, що оптимальні комбіновані методи зміцнення забезпечують суттєво більший приріст ресурсу, ніж окремі методи. Для автомобільних деталей приріст ресурсу становить 143...195%, а для деталей сільськогосподарської техніки – 166...196%. Варто зазначити, що для підшипників кочення покриття (6289 год) поступається базовому ресурсу (8000 год) при ізольованому застосуванні, проте комбінований підхід забезпечує суттєве підвищення до 19475 год (+143%).

Колонка «Синергетичний ефект» відображає додатковий приріст ресурсу від комбінації порівняно з сумою окремих ефектів термообробки та покриття. Для більшості деталей домінуючим методом термообробки є азотування при 500°C, тоді як оптимальний тип покриття варіюється: PVD для автомобільних деталей та деталей з низькоабразивними умовами, борування - для деталей з інтенсивним зношуванням. Найвищий синергетичний ефект (+50%) спостерігається для шестерень КП, підшипників кочення та гільз циліндрів, найнижчий (+6%) – для культиваторних лап (рис. 3).

Таблиця 5 – Оптимальні комбінації зміцнення, визначені нейромережевою оптимізацією

Деталь	Оптимальна термообробка	Оптимальне покриття	Синергетичний ефект, %
Поршневі кільця	Азотування (500°C, 18,88 год)	HVOF газотермічне (100 мкм)	+39
Шестерні КП	Азотування (500°C, 35,54 год)	Борування (50 мкм)	+50
Підшипники	Азотування (500°C, 20,02 год)	PVD (TiN/CrN/TiAlN) (5 мкм)	+50
Гільзи циліндрів	Азотування (500,3°C, 14,89 год)	PVD (TiN/CrN/TiAlN) (2,7 мкм)	+50
Лемеші плугів	Азотування (500°C, 19,92 год)	PVD (TiN/CrN/TiAlN) (1 мкм)	+16
Диски борін	Азотування (500°C, 42,63 год)	PVD (TiN/CrN/TiAlN) (1 мкм)	+25
Культ. лапи	Азотування (500°C, 15,44 год)	PVD (TiN/CrN/TiAlN) (1,6 мкм)	+6
Ножі подрібн.	Азотування (500°C, 38,42 год)	Борування (50 мкм)	+40

Джерело: розроблено авторами

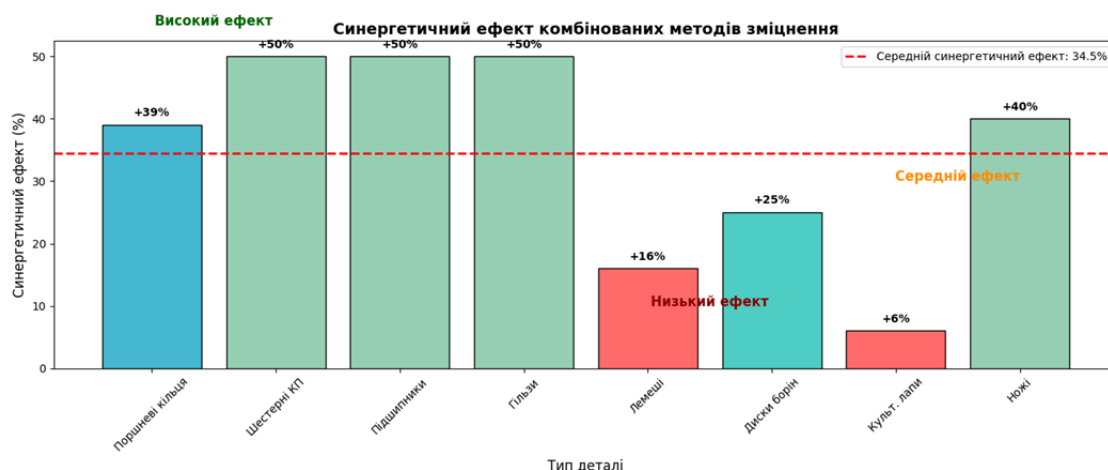


Рисунок 3 - Синергетичний ефект комбінованих методів зміцнення для різних типів деталей  
Джерело: розроблено авторами

**Парето-оптимізація.** Для кожного типу деталі побудовано Парето-фронт у просторі «прогнозований ресурс-вартість зміцнення». Аналіз Парето-фронтів дозволив виділити три характерні зони рішень:

Зона 1 (економічна) – бюджетні рішення з помірним ефектом: переважно лише термообробка (гартування або нормалізація), приріст ресурсу 30...60%, відносна вартість 0,8...1,5. Рекомендовано для масового виробництва з обмеженим бюджетом.

Зона 2 (оптимальна) – збалансовані рішення: комбінації «термообробка + недороге покриття» (борування, наплавлення), приріст ресурсу 80...150%, відносна вартість 2,0...3,5. Найкраще співвідношення ціна/ефективність для більшості застосувань.

Зона 3 (преміальна) - максимальний ефект: комбінації з PVD/HVOF покриттями, приріст ресурсу 150...210%, відносна вартість 4,0...5,5. Доцільно для критичних вузлів з високою вартістю простою.

**Аналіз робастності.** Дослідження чутливості оптимальних рішень до варіацій умов експлуатації проведено методом Монте-Карло (10 000 реалізацій з коефіцієнтом варіації вхідних параметрів 15%). Результати показали, що оптимальні комбінації зміцнення зберігають свою перевагу над окремими методами при варіаціях умов експлуатації з імовірністю  $\geq 92\%$  для автомобільних деталей та  $\geq 87\%$  для сільськогосподарських деталей. Нижча робастність для с/г деталей пояснюється більшою варіабельністю ґрунтових умов, що підтверджує необхідність адаптивного корегування рекомендацій на основі телеметричних даних.

**Порівняння з існуючими підходами.** Порівняльний аналіз запропонованої системи з традиційними методами вибору параметрів зміцнення (табл. 6) демонструє суттєві переваги нейромережевої оптимізації.

Ключовою перевагою запропонованого підходу є можливість аналізу величезного простору комбінацій (до 10) за рахунок використання навченої нейронної мережі як швидкої сурогатної моделі замість тривалих експериментів або чисельних розрахунків. Час оптимізації для однієї деталі становить менше 1 години на стандартному обчислювальному обладнанні.

Таблиця 6 – Порівняння підходів до вибору параметрів зміцнення

Критерій	Емпіричний підбір	DOE (плануван. експерименту)	RSM (поверхня відгуку)	MLP + GA (запроп.)
Час оптимізації	Тижні–місяці	2–4 тижні	1–2 тижні	< 1 години
Кількість комбінацій	5–10	27–81 (L27, L81)	15–50	$10^4$ – $10^6$
Багатокрит. оптимізація	Ні	Обмежено	Обмежено	Так (Парето)
Урахування комбінованих методів	Рідко	Частково	Частково	Повністю
Масштабованість	Низька	Середня	Середня	Висока
Вартість	Висока	Висока	Середня	Низька
Точність прогнозу (MAPE)	15...30%	8...15%	5...10%	4,0...21,5%

*Джерело: розроблено авторами*

### Висновки.

1. Розроблено та валідовано нейромережеву систему оптимізації параметрів комбінованого поверхневого зміцнення ресурсовизначальних деталей, що інтегрує пряму MLP-модель прогнозування зносу (24 вхідні параметри, архітектура 256-128-64-32-2) з оптимізаційним модулем NSGA-II. Пряма модель забезпечує точність прогнозування з коефіцієнтом детермінації  $R^2 = 0,33...0,97$ , RMSE = 0,0...3,1 мкм та MAPE = 4,0...21,5% на тестовій вибірці для всіх восьми типів досліджуваних деталей; знижена точність для підшипників кочення ( $R^2 = 0,33$ ) вказує на необхідність розширення датасету реальними даними для цього типу.

2. Встановлено, що оптимальні комбінації поверхневого зміцнення (термообробка + покриття) забезпечують підвищення прогнозованого ресурсу на 143...195% для автомобільних деталей та на 166...196% для деталей сільськогосподарської техніки порівняно з базовим станом. Виявлено синергетичний ефект комбінованих методів зміцнення (+6...50% додаткового приросту ресурсу понад суму окремих ефектів), що підтверджує доцільність комплексного підходу до інжинірингу поверхонь.

3. Побудовано Парето-фронти «зносостійкість–вартість» для кожного типу деталі, що дозволяють обґрунтовано обирати між економічними (приріст 30...60%, вартість 0,8...1,5), оптимальними (приріст 80...150%, вартість 2,0...3,5) та преміальними (приріст 150...210%, вартість 4,0...5,5) технологічними рішеннями залежно від техніко-економічних вимог конкретного виробництва.

4. Визначено оптимальні комбінації зміцнення для кожного типу деталі: для всіх восьми типів деталей оптимальним методом термообробки виявилось азотування при температурі  $\sim 500^\circ\text{C}$  з різною тривалістю (14,9...42,6 год), тоді як тип покриття варіюється: HVOF газотермічне для поршневих кілець, борування для шестерень КП та ножів подрібнювачів, PVD-покриття для решти деталей. Найвищий синергетичний ефект (+50%) зафіксовано для шестерень, підшипників кочення та гільз циліндрів; найнижчий (+6%) - для культиваторних лап.

5. Порівняльний аналіз підтвердив переваги запропонованого підходу над традиційними методами: емпіричним підбором (MAPE 15...30%), плануванням

експерименту DOE (MAPE 8...15%) та методом поверхні відгуку RSM (MAPE 5...10%) за критеріями масштабності та часу оптимізації. Для більшості типів деталей MAPE системи становить 4...7%, що є прийнятним для сурогатного моделювання; значення 21,5% для підшипників кочення обумовлено складністю їх трибологічної поведінки в розширеному просторі параметрів. Запропонована система дозволяє аналізувати до 10 комбінацій параметрів зміцнення для однієї деталі за час менше 1 години.

6. Основними обмеженнями дослідження є використання виключно синтетично генерованих даних для навчання моделі без залучення реальних експериментальних вимірювань, що вимагає обов'язкової валідації на натурних експериментах перед промисловим впровадженням. Особливої уваги потребують підшипники кочення, для яких якість прогнозування виявилась суттєво нижчою. Перспективними напрямками подальших досліджень є: експериментальна верифікація оптимальних комбінацій зміцнення на реальних деталях, збагачення датасету реальними вимірюваннями, інтеграція системи з IoT-платформами для адаптивного корегування рекомендацій на основі телеметричних даних, розширення бази даних для спеціальних умов експлуатації (низькі температури, агресивні середовища) та розробка програмного забезпечення для промислового впровадження.

## Список літератури

1. Mobley R. Keith. An Introduction to Predictive Maintenance / R. Keith Mobley. – 2nd ed. – Oxford : Butterworth-Heinemann, 2002. – 532 p. – URL: <https://doi.org/10.1016/B978-075067531-4/50002-8> (дата звернення: 21.01.2026).
2. Lee J. et al. Service Innovation and Smart Analytics for Industry 4.0 and Big Data Environment // Procedia CIRP. – 2014. – Vol. 16. – P. 3–8. – URL: <https://doi.org/10.1016/j.procir.2014.02.001> (дата звернення: 21.01.2026).
3. Чумак В. М. та ін. Підвищення зносостійкості та надійності ресурсовизначальних деталей транспортної та сільськогосподарської техніки методами інженерної оптимізації // Центральноукраїнський науковий вісник. Технічні науки. – 2025. – Т. 11, № 42, ч. 2. – С. 143–159. – URL: [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) (дата звернення: 25.01.2026).
4. Чумак В. М. та ін. Універсальний метод формалізації параметрів ресурсовизначальних деталей транспортної та сільськогосподарської техніки для систем предиктивного обслуговування // Центральноукраїнський науковий вісник. Технічні науки. – 2025. – Вип. 12(43), ч. 2. – С. 204–219. – URL: [https://doi.org/10.32515/2664-262X.2025.12\(43\).2.204-219](https://doi.org/10.32515/2664-262X.2025.12(43).2.204-219) (дата звернення: 25.01.2026).
5. Hutchings I., Shipway P. Tribology: Friction and Wear of Engineering Materials. – 2nd ed. – Oxford : Butterworth-Heinemann, 2017. – 412 p. – URL: <https://doi.org/10.1016/B978-0-08-100910-9.00001-8> (дата звернення: 25.01.2026).
6. Zum Gahr K. H. Microstructure and Wear of Materials. – 1st ed. – Amsterdam : North Holland, 1987. – 560 p. – ISBN 978-0-08-087574-3. – URL: [https://www.academia.edu/82805296/Karl\\_Heinz\\_Zum\\_Gahr\\_Microstructure\\_and\\_Wear\\_of\\_Materials](https://www.academia.edu/82805296/Karl_Heinz_Zum_Gahr_Microstructure_and_Wear_of_Materials) (дата звернення: 25.01.2026).
7. Archard J. F. Contact and Rubbing of Flat Surfaces // Journal of Applied Physics. – 1953. – Vol. 24, No. 8. – P. 981–988. – URL: <https://doi.org/10.1063/1.1721448> (дата звернення: ).
8. ISO 281:2007 Rolling bearings - Dynamic load ratings and rating life. – 2nd ed. – Geneva : International Organization for Standardization, 2007. – URL: <https://www.iso.org/standard/38102.html> (дата звернення: 25.01.2026).
9. Bhushan B. Modern Tribology Handbook. – 1st ed. – Boca Raton : CRC Press, 2000. – URL: <https://doi.org/10.1201/9780849377877> (дата звернення: 25.01.2026).
10. Horvat Z. et al. Reduction of mouldboard plough share wear by a combination technique of hardfacing // Tribology International. – 2008. – Vol. 41, No. 8. – P. 778–782. – URL: <https://doi.org/10.1016/j.triboint.2008.01.008> (дата звернення: 25.01.2026).
11. Bayhan Y. Reduction of wear via hardfacing of chisel ploughshare // Tribology International. – 2006. – Vol. 39, No. 6. – P. 570–574. – URL: <https://doi.org/10.1016/j.triboint.2005.06.005> (дата звернення: 10.02.2026).
12. Аулін В. В. та ін. Кіберфізичний підхід при створенні транспортно-виробничих систем // Центральноукраїнський науковий вісник. Технічні науки. – 2020. – Т. 3, № 34. – С. 331–343. – URL: [https://doi.org/10.32515/2664-262X.2020.3\(34\).331-343](https://doi.org/10.32515/2664-262X.2020.3(34).331-343) (дата звернення: 15.02.2026).

13. Головатий А. О. та ін. Вдосконалення математичного моделювання машинобудівних технологій для смарт-підприємств в системі машинного зору // Центральнoукраїнський науковий вісник. Технічні науки. – 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: 15.02.2026).
14. Shah R. et al. Machine Learning in Wear Prediction // ASME Journal of Tribology. – 2025. – Vol. 147, No. 4. – P. 040801. – URL: <https://doi.org/10.1115/1.4066865> (дата звернення: 17.02.2026).
15. Carvalho T. P. et al. A systematic literature review of machine learning methods applied to predictive maintenance // Computers & Industrial Engineering. – 2019. – Vol. 137. – P. 106024. – URL: <https://doi.org/10.1016/j.cie.2019.106024> (дата звернення: 17.02.2026).
16. Łach Ł. Recent Advances in Laser Surface Hardening: Techniques, Modeling Approaches, and Industrial Applications // Crystals. – 2024. – Vol. 14, No. 8. – P. 726. – URL: <https://doi.org/10.3390/cryst14080726> (дата звернення: 17.02.2026).
17. Liu G. et al. Parameters Optimization of Plasma Hardening Process Using Genetic Algorithm and Neural Network // Journal of Iron and Steel Research International. – 2012. – URL: [https://doi.org/10.1016/S1006-706X\(12\)60010-7](https://doi.org/10.1016/S1006-706X(12)60010-7) (дата звернення: 17.02.2026).
18. Ulas M. et al. A new approach for prediction of the wear loss of PTA surface coatings using artificial neural network and basic, kernel-based, and weighted extreme learning machine // Friction. – 2020. – Vol. 8. – P. 1102–1116. – URL: <https://doi.org/10.1007/s40544-017-0340-0> (дата звернення: 17.02.2026).
19. Altay O. et al. Prediction of wear loss quantities of ferro-alloy coating using different machine learning algorithms // Friction. – 2020. – Vol. 8. – P. 107–114. – URL: <https://doi.org/10.1007/s40544-018-0249-z> (дата звернення: 17.02.2026).
20. Jatavallabhula J. K., Shabana S., Pappula B. Development and Evaluation of Machine Learning Based Predictive Models for Tribological Properties of Blended Coatings at Elevated Temperature // Journal of Bio- and Tribo-Corrosion. – 2025. – Vol. 11. – Art. 25. – URL: <https://doi.org/10.1007/s40735-025-00952-7> (дата звернення: 17.02.2026).
21. Natsis A., Papadakis G., Pitsilis J. The Influence of Soil Type, Soil Water and Share Sharpness of a Mouldboard Plough on Energy Consumption, Rate of Work and Tillage Quality // Journal of Agricultural Engineering Research. – 1999. – Vol. 72, No. 2. – P. 171–176. – URL: <https://doi.org/10.1006/jaer.1998.0360> (дата звернення: 17.02.2026).
22. 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.2018.12.016> (дата звернення: 17.02.2026).
23. Zheng J., Li W., Li J. A Comparative Study on the Wear Behavior of Quenched-and-Partitioned Steel (Q&P) and Martensite Steel (Q&T) // Coatings. – 2024. – Vol. 14, No. 6. – P. 727. – URL: <https://doi.org/10.3390/coatings14060727> (дата звернення: 19.02.2026).
24. Deshmankar A. P. et al. Review of the Applications of Machine Learning for Prediction and Analysis of Mechanical Properties and Microstructures in Additive Manufacturing // Journal of Computing and Information Science in Engineering. – 2024. – Vol. 24, No. 12. – P. 1–17. – URL: <https://doi.org/10.1115/1.4066575> (дата звернення: 19.02.2026).
25. Yan H. et al. Machine Learning-Based Prediction of Tribological Properties of Epoxy Composite Coating // Polymers. – 2025. – Vol. 17, No. 3. – P. 282. – URL: <https://doi.org/10.3390/polym17030282> (дата звернення: 19.02.2026).
26. Davis J. R. (ed.). Alloying: Understanding the Basics. – Materials Park : ASM International, 2001. – URL: <https://doi.org/10.31399/asm.tb.aub.9781627082976> (дата звернення: 19.02.2026).

## References

1. Mobley, R. K. (2002). *An introduction to predictive maintenance* (2nd ed.). Butterworth-Heinemann. <https://doi.org/10.1016/B978-075067531-4/50002-8>
2. Lee, J., Kao, H.-A., & Yang, S. (2014). Service innovation and smart analytics for Industry 4.0 and Big Data Environment. *Procedia CIRP*, 16, 3–8. <https://doi.org/10.1016/j.procir.2014.02.001>
3. Chumak, V. M., Aulin, V. V., Hrynkiv, A. V., Lysenko, S. V., & Kuzyk, O. V. (2025). Improvement of wear resistance and reliability of resource-determining parts of transport and agricultural machinery by methods of engineering optimization. *Central Ukrainian Scientific Bulletin. Technical Sciences*, 11(42, part 2), 143–159. [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) [in Ukrainian].
4. Chumak, V. M., et al. (2025). Universal method for formalizing parameters of resource-determining parts of transport and agricultural machinery for predictive maintenance systems. *Central Ukrainian Scientific Bulletin. Technical Sciences*, 12(43, part 2), 204–219. [https://doi.org/10.32515/2664-262X.2025.12\(43\).2.204-219](https://doi.org/10.32515/2664-262X.2025.12(43).2.204-219) [in Ukrainian].
5. Hutchings, I., & Shipway, P. (2017). *Tribology: Friction and wear of engineering materials* (2nd ed.). Butterworth-Heinemann. <https://doi.org/10.1016/B978-0-08-100910-9.00001-8>

6. Zum Gahr, K. H. (1987). *Microstructure and wear of materials* (1st ed.). North Holland. [https://www.academia.edu/82805296/Karl\\_Heinz\\_Zum\\_Gahr\\_Microstructure\\_and\\_Wear\\_of\\_Materials](https://www.academia.edu/82805296/Karl_Heinz_Zum_Gahr_Microstructure_and_Wear_of_Materials)
7. Archard, J. F. (1953). Contact and rubbing of flat surfaces. *Journal of Applied Physics*, 24(8), 981–988. <https://doi.org/10.1063/1.1721448>
8. ISO 281:2007. (2007). *Rolling bearings - Dynamic load ratings and rating life* (2nd ed.). International Organization for Standardization. <https://www.iso.org/standard/38102.html>
9. Bhushan, B. (2000). *Modern tribology handbook* (1st ed.). CRC Press. <https://doi.org/10.1201/9780849377877>
10. Horvat, Z., Filipović, D., Kosutic, S., & Emert, R. (2008). Reduction of mouldboard plough share wear by a combination technique of hardfacing. *Tribology International*, 41(8), 778–782. <https://doi.org/10.1016/j.triboint.2008.01.008>
11. Bayhan, Y. (2006). Reduction of wear via hardfacing of chisel ploughshare. *Tribology International*, 39(6), 570–574. <https://doi.org/10.1016/j.triboint.2005.06.005>
12. Aulin, V. V., Hrynkiv, A. V., & Holovaty, A. O. (2020). Cyber-physical approach in the creation of transport and production systems. *Central Ukrainian Scientific Bulletin. Technical Sciences*, 3(34), 331–343. [https://doi.org/10.32515/2664-262X.2020.3\(34\).331-343](https://doi.org/10.32515/2664-262X.2020.3(34).331-343) [in Ukrainian].
13. Holovaty, A. O., et al. (2025). Improvement of mathematical modeling of engineering technologies for smart enterprises in the machine vision system. *Central Ukrainian Scientific Bulletin. Technical Sciences*, 11(42, part 2), 143–159. [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) [in Ukrainian].
14. Shah, R., et al. (2025). Machine learning in wear prediction. *ASME Journal of Tribology*, 147(4), 040801. <https://doi.org/10.1115/1.4066865>
15. Carvalho, T. P., Soares, F. A. A. M., Vita, R., Francisco, R. P., Basto, J. P., & Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
16. Łach, Ł. (2024). Recent advances in laser surface hardening: Techniques, modeling approaches, and industrial applications. *Crystals*, 14(8), 726. <https://doi.org/10.3390/cryst14080726>
17. Liu, G., et al. (2012). Parameters optimization of plasma hardening process using genetic algorithm and neural network. *Journal of Iron and Steel Research International*. [https://doi.org/10.1016/S1006-706X\(12\)60010-7](https://doi.org/10.1016/S1006-706X(12)60010-7)
18. Ulas, M., et al. (2020). A new approach for prediction of the wear loss of PTA surface coatings using artificial neural network and basic, kernel-based, and weighted extreme learning machine. *Friction*, 8, 1102–1116. <https://doi.org/10.1007/s40544-017-0340-0>
19. Altay, O., et al. (2020). Prediction of wear loss quantities of ferro-alloy coating using different machine learning algorithms. *Friction*, 8, 107–114. <https://doi.org/10.1007/s40544-018-0249-z>
20. Jatavallabhula, J. K., Shabana, S., & Pappula, B. (2025). Development and evaluation of machine learning based predictive models for tribological properties of blended coatings at elevated temperature. *Journal of Bio- and Tribo-Corrosion*, 11, Article 25. <https://doi.org/10.1007/s40735-025-00952-7>
21. Natsis, A., Papadakis, G., & Pitsilis, J. (1999). The influence of soil type, soil water and share sharpness of a mouldboard plough on energy consumption, rate of work and tillage quality. *Journal of Agricultural Engineering Research*, 72(2), 171–176. <https://doi.org/10.1006/jaer.1998.0360>
22. Zhang, B., Zhang, S., & Li, W. (2019). Bearing performance degradation assessment using long short-term memory recurrent network. *Computers in Industry*, 106, 14–29. <https://doi.org/10.1016/j.compind.2018.12.016>
23. Zheng, J., Li, W., & Li, J. (2024). A comparative study on the wear behavior of quenched-and-partitioned steel (Q&P) and martensite steel (Q&T). *Coatings*, 14(6), 727. <https://doi.org/10.3390/coatings14060727>
24. Deshmankar, A. P., et al. (2024). Review of the applications of machine learning for prediction and analysis of mechanical properties and microstructures in additive manufacturing. *Journal of Computing and Information Science in Engineering*, 24(12), 1–17. <https://doi.org/10.1115/1.4066575>
25. Yan, H., et al. (2025). Machine learning-based prediction of tribological properties of epoxy composite coating. *Polymers*, 17(3), 282. <https://doi.org/10.3390/polym17030282>
26. Davis, J. R. (Ed.). (2001). *Alloying: Understanding the basics*. ASM International. <https://doi.org/10.31399/asm.tb.aub.9781627082976>

**Vitalii Chumak, Yehor Manko, Serhii Lysenko**, Assoc. Prof., PhD tech. sci  
*Central Ukrainian National Technical University, Kropyvnytskyi, Ukraine*

### **Modeling and Optimization of Combined Methods of Surface Hardening of Machine Parts Based on Neural Networks And genetic Algorithms**

It is shown that the problem of choosing the optimal parameters of surface hardening of resource-determining parts of automotive and agricultural machinery is an urgent task of modern engineering. Traditional approaches to choosing hardening methods are based mainly on empirical experience or expensive experimental

studies, which limits the possibility of systematic optimization of combined technologies (heat treatment + protective coating) for specific operating conditions. A neural network system for optimizing the parameters of combined surface hardening is proposed, which integrates a direct predictive model based on a multilayer perceptron (MLP) with an optimization module based on a genetic algorithm (GA). The direct model predicts the wear intensity and residual life of the part according to the parameters of the Universal Description of the Part (UDP) and the hardening characteristics, and the genetic algorithm performs multi-criteria optimization according to the objective function that takes into account wear minimization, processing cost and technological feasibility. The study was conducted on eight types of resource-determining parts of automotive (piston rings, gear boxes, rolling bearings, cylinder liners) and agricultural machinery (plough shares, harrow discs, cultivator tines, chopper knives) using 14 surface hardening options, including 5 types of heat treatment, 4 types of coatings and 5 combined technologies. A dataset of 40,000 samples was formed using two types of synthetic data: 20,000 samples were generated with increased accuracy to simulate experimental conditions, another 20,000 with a wider range of parameters to cover the entire space of possible solutions. The validation of the direct model demonstrated the accuracy of prediction: coefficient of determination  $R^2 = 0.33...0.97$ , RMSE =  $0.0...3.1 \mu\text{m}$ , MAPE =  $4.0...21.5\%$ . The optimization module allowed us to determine the optimal combinations of strengthening for each type of part with an increase in the predicted resource by 143...196% compared to the baseline. The constructed Pareto fronts "wear resistance–cost" provide a reasonable choice of technological solution taking into account economic constraints.

**surface hardening optimization, neural networks, genetic algorithm, combined hardening methods, wear resistance, heat treatment, protective coatings, predictive maintenance, Pareto optimization, resource-determining parts**

*Одержано (Received) 27.02.2026*

*Прорецензовано (Reviewed) 10.03.2026*

*Прийнято до друку (Approved) 12.03.2026*