

УДК 631.32.02

DOI: <https://doi.org/10.32515/2414-3820.2025.55.31-42>**М. Л. Заєць**, доц., канд. техн. наук*Поліський національний університет, м. Житомир, Україна**e-mail: mzaec81@gmail.com***А. М. Климчук***Житомирський автомобільно-дорожній фаховий коледж Національного транспортного університету, м. Житомир, Україна**e-mail: klimchukanatoly@gmail.com*

## Оцінка продуктивності комбайна з використанням гібридної моделі та поверхонь відгуку

Автоматизоване управління системами збору врожаю здатне суттєво підвищити ефективність сільськогосподарських процесів і зменшити втрати вирощуваної продукції. Моделювання та удосконалення роботи комбайна сприяють збільшенню його загальної продуктивності. Використання методів машинного навчання відкриває можливості для точного прогнозування максимальної ефективності роботи машини.

У цьому дослідженні представлено модель роботи комбайна, яка створена за допомогою радіальної базисної функції (RBF) та гібридного методу машинного навчання – адаптивної нейронечіткої системи висновків (ANFIS), що дозволяє передбачати різні параметри комбайна для досягнення оптимальної продуктивності. Крім того, методологія поверхні відгуку (RSM) застосовується для оптимізації моделей. Порівняльний аналіз свідчить, що ANFIS показує кращі результати порівняно з RBF.

**комбайн, гібридне машинне навчання, методологія поверхні відгуку, штучний інтелект, радіальна базисна функція**

**Постановка проблеми.** Велика кількість сільськогосподарської продукції знищується з різних причин під час виробництва, переробки, а також на етапі збирання врожаю, на що витрачаються значні кошти, енергія та важка праця, і це також створює тиск на навколишнє середовище. Обсяг втрат сільськогосподарської продукції (як кількісно, так і якісно) є значним в Україні і завдає великих збитків аграрному сектору. Зусилля щодо зменшення втрат сільськогосподарської продукції є важливішими та менш затратними порівняно із заходами, спрямованими на збільшення виробництва [1]. Ідентифікація ефективних параметрів у процесі збирання врожаю є першим і важливим кроком для контролю та зменшення таких втрат. Цими параметрами є час збирання, тип збирання (механізований або ручний), правильні налаштування збиральних машин, транспортування до цільового ринку тощо. Враховуючи унікальне значення машин у сільськогосподарських виробничих системах як джерела енергії, оцінка механізмів і продуктивності обладнання є невідкладним пріоритетом управління в аграрних підприємствах. [2]

Моделювання та імітація бажаної системи (у цьому дослідженні комбайна) дають кращу оцінку продуктивності різних підсистем [14, 15]. Процес молотіння є одним із ключових на етапі збирання врожаю і оцінюється за такими показниками, як ефективність молотарки, ефективність очищення, кількість пошкодженого зерна та подрібнених стебел [1]. Моделювання систем за допомогою традиційних математичних засобів, таких як диференціальні рівняння, не є ефективним у системах з нечіткою поведінкою та недостатньо визначеними характеристиками [16]. На відміну від

класичних систем, інтелектуальні системи управління не потребують точних математичних моделей поведінки системи. Наразі інтелектуальні системи та системи на основі м'яких обчислень широко застосовуються у всіх наукових сферах [17]. Тому використання методів прогнозування, таких як м'які обчислення та інтелектуальні методи, які останнім часом набувають популярності, допомагає ефективно оцінювати бажані системи [18]. Ці методи мають різні типи, найбільш популярними серед яких є нечіткі методи та штучні нейронні мережі [19].

**Аналіз останніх досліджень і публікацій.** Комбайни займають особливе місце у збиранні сільськогосподарських культур через свої чутливі механізми та процеси, що застосовуються до стратегічних зернових продуктів [3]. Налаштування та оптимізація внутрішніх компонентів цієї машини є дуже важливими [4]. Фактори, які впливають на неправильну роботу комбайнів або будь-яких інших машин, можна виявити за допомогою кінематичного та динамічного аналізу. Ці фактори поділяються на три групи: геометричні параметри, умови роботи та властивості продукту, причому невідповідний рівень кожного з них призводить до зниження продуктивності комбайна [1]. Кожен компонент комбайна впливає на потік і рух продукту, виходячи з геометрії та властивостей продукту. Геометричні зміни впливають на продуктивність машини, і прогнозування та моделювання цих змін є ефективним напрямком у проектуванні машин та виробництві нових компонентів [5].

Три параметри, що включають зазор у молотильному апараті, швидкість вентилятора та зазори решіт, впливають на пошкодження зерна, втрати та кількість сторонніх матеріалів у класичних комбайнах. Згідно з дослідженням Спенглера та ін. [6, 7, 8], оптимізація молотильно-сепараційної системи (МСС) знизилася загальні втрати машини на 4–6 % у Німеччині в 1986 році. Збирання врожаю за допомогою комбайна – це складний нелінійний процес, який залежить від великої кількості даних [18].

Багато математичних моделей використовуються для моделювання зв'язків між вхідними та вихідними параметрами процесу, але класична логіка вимагає точного визначення цих зв'язків для опису цих явищ [9]. Використання методів штучного інтелекту, таких як штучні нейронні мережі, нечітка логіка тощо, дозволяє розробляти прогностичні моделі для дуже складних даних, які можна порівнювати та аналізувати [10]. Одним із таких методів є нечіткий (фаззі) метод. Нечіткий метод має багато переваг, серед яких – обробка нечітких або неповних даних. Цей метод використовує лінгвістичні позначення для моделювання складних систем [11].

Штучна нейронна мережа – це ще один метод обробки. Загалом метод штучних нейронних мереж використовується у різних галузях, таких як математика, інженерія, економіка, екологія та сільське господарство [12]. Перевага обох систем полягає у структурі ANFIS. ANFIS широко застосовується для моделювання складних систем, контролю або оцінки параметрів. Основою ANFIS є комбінований алгоритм навчання для ідентифікації параметрів із використанням нечіткої системи висновків. Ця система поєднує метод найменших квадратів та метод зворотного поширення помилки для навчання функцій належності, працюючи з усіма навчальними даними, щоб досягти найкращого результату [11].

Існує кілька досліджень, присвячених моделюванню, вивченню або оптимізації продуктивності комбайнів. Деякі з них наведені нижче і можуть допомогти окреслити мету та новизну цього дослідження: Craessaerts та співавт. [15] досліджували методологію на основі генетичних алгоритмів для вибору вхідних параметрів з метою ідентифікації процесу очищення на комбайні в двох частинах: спочатку для вибору вхідних змінних, що впливають на втрати через решета, а потім для визначення вмісту сторонніх матеріалів (MOG) у зерновому бункері. Maertens та De Baerdemaeker [16]

розробили динамічну модель сепарації, щоб уникнути використання нелінійних, складних і невизначених залежностей. Zhao та ін. [17] запропонували метод непрямого моніторингу втрат зерна у сепараційному відділі на основі аналізу зв'язку між втратами зерна та потоком зерна під решетою. Mirza Zadeh та співавт. [18] застосували метод багатосарового перцептрона (ANN) для прогнозування сепарації зерна комбайном. Вони використовували параметри швидкості подачі, висоти стебла, частоти обертання молотильного барабана та коефіцієнта зазору як незалежні змінні. Результати показали коефіцієнт кореляції 0,9.

**Постановка завдання.** Враховуючи те, що аналіз процесу збирання зернових колосових та технічних культур та процесу обмолоту із застосуванням методів м'яких обчислень для моделювання та вивчення продуктивності комбайнів є обмеженою. Водночас методи м'яких обчислень можуть знизити складність системи та процесу і підвищити точність моделей. У цьому дослідженні запропоновано використати моделі ANFIS і RBF, які раніше не застосовувалися для моделювання комбайна, з метою визначення та оцінки ефективності цих методів у моделюванні роботи зернозбиральної машини. Крім того, для одночасної оптимізації втрат продукції, вмісту сторонніх матеріалів та кількості пошкодженого зерна застосовано методологію поверхні відгуку (RSM). До цього часу досліджень з оптимізації з урахуванням цих залежних параметрів за допомогою методу RSM не проводилося, що і становить основну новизну даної роботи.

Встановлення закономірностей по обґрунтуванню робочих параметрів зернозбиральних комбайнів, являється досить актуальною задачею, при застосуванні їх в умовах сучасних технологій та систем ведення господарської діяльності.

**Матеріали та методи дослідження.** Збір і вимірювання необхідних даних проводилися з комбайна John Deere T6 800i на базі господарства СТОВ «Старокотельнянське» Житомирської області. Характеристики молотильно-сепарувальної системи були такими: Молотильний барабан (TD) діаметром 660 мм і довжиною 1670 мм, оснащений 10-билами, з частотою обертання від 450 до 950 об/хв., модульне регульоване підбарабання типу "слайдер" кут охоплення  $135^{\circ}$ . Решета з сумарною площею 4,9 м<sup>2</sup>. Вентилятор із частотою обертання від 550–1350 об/хв, Зазор між барабаном і підбарабанням становив 10 мм на вході та 3 мм на виході. Експерименти виконувалися у формі багатофакторного експерименту з трьома повторами на трьох рівнях змінних.

Незалежні змінні: А – зазор між молотильним барабаном і підбарабанням, В – швидкість вентилятора, С – ступінь відкритості решіт. Залежні змінні: BS – кількість пошкодженого (тріщини) зерна в бункері; втрати продукту (PL); матеріал, відмінний від зерна МОГ (домішки).

Моделювання за допомогою методів машинного навчання досліджувалося в багатьох роботах, що охоплюють широкий спектр застосувань. Серед усіх методів машинного навчання гібридні підходи продемонстрували кращу ефективність у порівнянні з традиційними методами. Саме тому в цьому дослідженні для моделювання продуктивності комбайна було обрано гібридний метод ANFIS, а також метод поверхонь відгуків.

**Виклад основного матеріалу.** У даному дослідженні було використано радіальну базисну функцію (RBF) на основі штучної нейронної мережі (ANN) для побудови моделі зв'язку між незалежними та залежними змінними. Мережа RBF є тришаровою нейромережею прямого поширення сигналу (feed-forward). Її структура зображена на рис. 1.




Рисунок 1 – Структура нейронної мережі з радіальними базисними функціями (RBF)  
 Джерело: розроблено автором на підставі [2]

У RBF-мережі вхідні дані безпосередньо надходять до прихованого шару, де після множення на відповідні вагові коефіцієнти передаються до блоку підсумовування, який формує вихідні сигнали.

Структура та робота шарів RBF-мережі: Вхідний шар складається з нейронів, які розподіляють вхідні сигнали між нейронами прихованого шару. Він не виконує обчислень, а лише передає дані далі.

Прихований шар виконує нелінійне відображення вхідного простору у простір прихованих ознак. Це відображення базується на радіальній базисній функції, яка вимірює відстань між вхідним вектором та центром кожного нейрона.

У цьому дослідженні для визначення нейронів як локальних приймачів сигналу використовувалась Гаусова функція (1) [19].

$$\phi_i(x) = \exp \left[ - \frac{\|x - c_i\|^2}{2\sigma^2} \right]_{i=1,2,\dots,m}, \quad (1)$$

де  $\phi(x)$  – вихід радіального нейрона;

$x$  – вхідний вектор;

$c$  – центр (центроїд) радіальної функції;

$\sigma$  ширина (радіус) впливу Гаусової функції.

Усі нейрони вхідного та прихованого шарів мають однакову розмірність, що забезпечує коректне відображення простору [19].

Вихідний шар отримує сигнали з прихованого шару, підсумовує їх із урахуванням вагових коефіцієнтів і формує остаточний вихід системи.

Де  $c_i$  та  $\sigma_i$  – це центр і ширина  $i$ -го прихованого шару відповідно. Вихід мережі є лінійним відображенням  $\phi(x)$  у  $Y$ . Це відображення обчислюється за рівнянням (2) і являє вихід мережі [19].

$$Y = \sum_{i=1}^r w_{ik} \phi_i(x)_{k=1,2,\dots,m}, \quad (2)$$

де  $k$  – це вузол вихідного шару;

$w_{ik}$  – вага з'єднань між прихованим шаром та вихідним шаром;

$\phi_i(x)$  – відповідь прихованого шару для вузлів вихідного шару.

Насправді RBF-мережа виконує такі операції для навчання мережі: алгоритм неконтрольованого навчання використовується для навчання центрів і ширини основних функцій; призначення ваг, пов'язаних із з'єднаннями між прихованим та вихідним шарами.

Для навчання мережі були використані експериментальні дані про зернозбиральний комбайн. Навчена мережа повинна бути здатною встановлювати зв'язок між вхідними та вихідними даними, щоб передбачати та моделювати поведінку системи. Тому фактори А, В та С були розглянуті як вхідні змінні (незалежні змінні), а фактори BS, PL і MOG – як вихідні змінні (залежні змінні) мережі.

Ці фактори були обрані на основі можливості налаштування оператором і їх впливу на ефективність системи, 70% даних були обрані як навчальні, а 30% – як тестові. Метою процесу навчання є зменшення похибки між цільовими значеннями та вихідними значеннями мережі. Для порівняння цільових і вихідних значень мережі використовувалася середньоквадратична помилка (MSE).

Процес навчання розпочався з п'яти нейронів у прихованому шарі, і на кожному наступному кроці навчання до попередньої кількості нейронів додавалося ще п'ять. Додавання нейронів до прихованого шару тривало доти, доки спостерігалось зменшення похибки та встановлення її стабільного тренду.

Адаптивна нейро-нечітка інферентна система (ANFIS) – це підхід до моделювання нелінійних складних задач, який використовує модель Сугено з нечіткими вхідними даними та правилами для створення потужного інструменту прогнозування [6, 7]. ANFIS є класом адаптивних прямоспрямованих мереж, які мають 5 шарів (рис. 2).




Рисунок 2 – Структура ANFIS

Джерело: розроблено автором на підставі [2]

Ця система генерує нечіткі правила на основі вхідних та вихідних даних (тобто навчальних даних). Просте правило, що використовує нечітку модель Сугено, виглядає так: якщо  $x$  належить  $A_i$ , а  $y$   $B_i$ , коли  $z=f(x,y)$ . Де  $A$  і  $B$  – нечіткі категорії, а  $z=f(x,y)$  – зазвичай є поліноміальною функцією [6, 8]. У цьому дослідженні навчальні та тестові дані для розробки ANFIS були тими ж, що й для розробки моделі RBF.

Адаптивна інферентна система була розроблена за допомогою програмного забезпечення MATLAB 2012. Використаний алгоритм був комбінованим, обраним для зміни початкових функцій відповідності. Для визначення ефективної навчальної мережі метод ANFIS був розроблений на основі різних типів функцій відповідності.

Трикутна функція належності (trim type function) у поєднанні з лінійним методом і використанням трьох функцій забезпечила найкращу відповідність для моделювання мережі, згідно з порівнянням параметрів. Параметри порівняння включали: середньоквадратичну помилку (RMSE), коефіцієнт кореляції ( $r$ ). Середню абсолютну помилку (MAE), для порівняння цільових і вихідних значень мереж визначили з рівняння

$$R_{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (A - P)^2}, \quad (3)$$

$$R = \left( 1 - \left( \frac{\sum_{i=1}^n (A - P)^2}{\sum_{i=1}^n A_i^2} \right)^{\frac{1}{2}} \right), \quad (4)$$

$$MAE = \sum_{i=1}^N \frac{|A - P|}{N}, \quad (5)$$

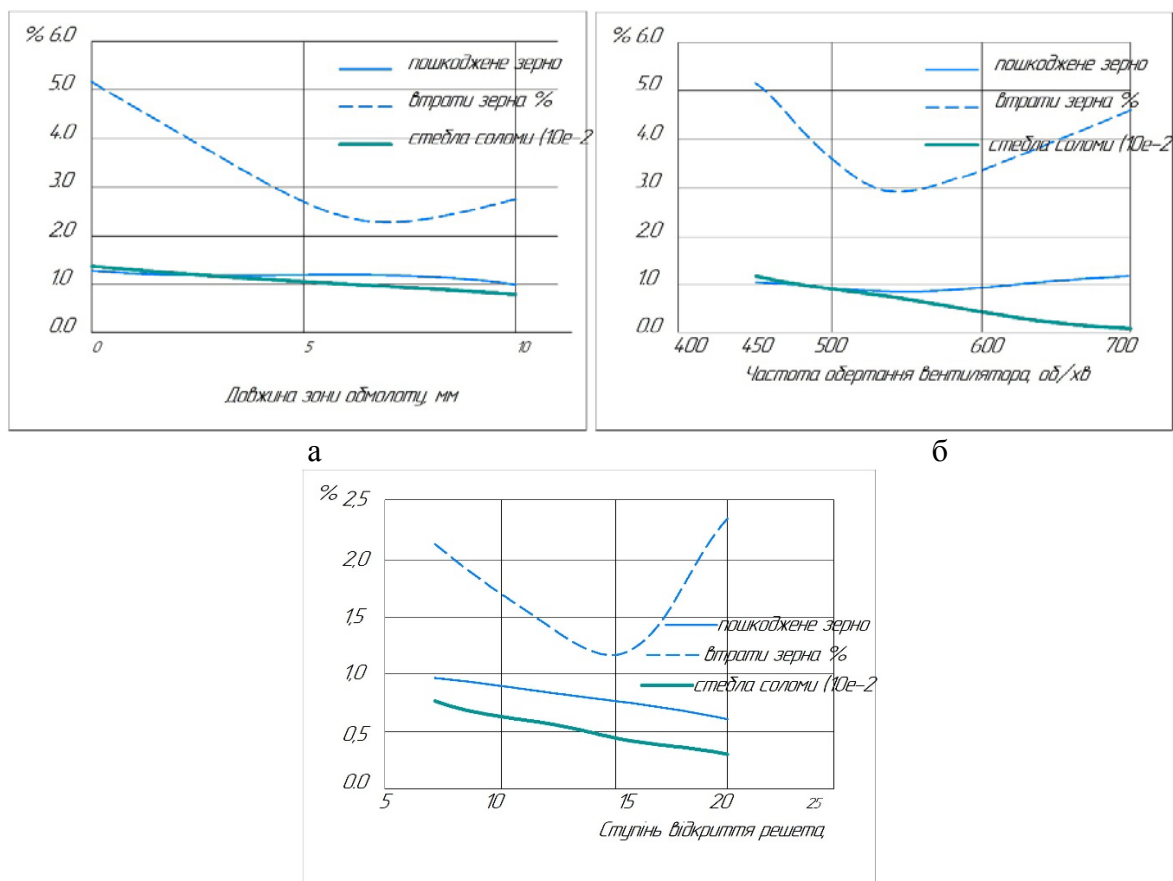
де  $A$  – це фактичні значення;

$P$  – передбачені значення;

$N$  – кількість даних.

Використання цього параметра допомагає обрати найкращу структуру та найкращу мережу, а також дає змогу оцінити наближеність моделі до реальних даних.

Дане дослідження було проведено на зернозбиральному комбайні, і дані були зафіксовані експериментальним шляхом та представленні на рис. 3.



а – Вплив відстані обмолоту на BS, PL, MOG; б – Вплив швидкості вентилятора на BS, PL, MOG; в – Вплив відкриття решета на BS, PL, MOG.

Рисунок 3 – Вплив вхідних змінних на вихідні змінні

Джерело: розроблено автором

Рисунок 3 демонструє початкові результати зафіксованих даних та їх взаємозв'язки. Згідно з даними рис.3,а, збільшення значення довжини зони обмолоту – А зменшує BS і MOG, але спочатку зменшує PL, а потім збільшує його. Це свідчить про те, що існує оптимальне значення для параметра А. Згідно з рис.3,б, зі збільшенням частоти обертання вентилятора системи очистки – В значення MOG зменшується, а щодо двох інших параметрів – спочатку зменшуються, а потім зростають.

Згідно з рис.3,в, зв'язок між ступенем відкриття решіт – С та BS і MOG є протилежним. Відкриття решета до певного діапазону зменшує PL, але після цього діапазону воно зростає.

Дослідження критичних точок дозволяє визначити оптимальний діапазон кожної змінної.

Основною метою дослідження було вивчення та отримання моделей на основі методів поверхонь відгуків RBF та нейромережі ANFIS розглядалось, як один із ключових етапів побудови точної моделі етапу навчання. Процес навчання моделей RBF та ANFIS був виконаний, і отримані проаналізовані результати. Ці результати дозволяють обрати найкращу модель для подальшого етапу тестування. Процес прогнозування було здійснено за допомогою мереж ANFIS та RBF. Для моделювання параметри BS, PL та MOG були розглянуті як залежні змінні (вихід мережі), а А, В і С – як незалежні змінні (входи мережі).

Результати навчання для методів RBF та ANFIS наведено у табл. 1 та 2.

Таблиця 1 – Результати навчання RBF-мережі

Кількість нейронів	Вихід	Коефіцієнт кореляції (r)	Середньоквадратична помилка (MSE)
8	BS	0,84	$1,028 \times 10^{-2}$
	PL	0,90	200
	MOG	0,95	0,1
10	BS	0,90	$6,87 \times 10^{-3}$
	PL	0,94	129,19
	MOG	0,96	$7,81 \times 10^{-2}$
12	BS	0,98	$1,09 \times 10^{-3}$
	PL	0,99	7,918
	MOG	0,97	$5,5 \times 10^{-2}$
14	BS	0,981	$1,06 \times 10^{-3}$
	PL	0,99	7,918
	MOG	0,987	$5,5 \times 10^{-2}$

Джерело: розроблено автором на підставі [6], [8]

Таблиця 2 – Результати навчання мережі ANFIS

Структура	Вихід	Тип функції відповідності	MSE	Метод оптимізації
3×3×3	BS	Трикутна	$1,24 \times 10^{-5}$	Гібридний
	PL		$6,90 \times 10^{-4}$	
	MOG		$5,91 \times 10^{-5}$	
3×3×3	BS	Трапецієподібна	$1,42 \times 10^{-5}$	Гібридний
	PL		$7,50 \times 10^{-4}$	
	MOG		$6,74 \times 10^{-5}$	

Продовження таблиці 2

3×3×3	BS	Обагр. дзвіночкова	$4,65 \times 10^{-5}$	Гібридний
	PL		$2,73 \times 10^{-3}$	
	MOG		$1,87 \times 10^{-4}$	
3×3×3	BS	Гаусова	$3,31 \times 10^{-5}$	Гібридний
	PL		$17,4 \times 10^{-4}$	
	MOG		$9,38 \times 10^{-5}$	

Джерело: розроблено автором на підставі [6], [8]

На основі результатів таблиць 1 і 2, для подальшого тестування були обрані такі моделі: RBF-мережа з 14 нейронами у прихованому шарі, яка показала найнижчі значення MSE: для BS –  $1,06 \times 10^{-3}$ ; для PL – 7,918; для MOG –  $5,5 \times 10^{-2}$ ; ANFIS-мережа з трикутною функцією належності, яка забезпечила найнижчі значення MSE: для BS –  $1,2396 \times 10^{-5}$ ; для PL –  $6,9 \times 10^{-4}$ ; для MOG –  $5,907 \times 10^{-5}$ .

Результати, отримані на виході мереж, були порівняні з цільовими (еталонними) даними, а результати порівняння подано у табл. 3.


Таблиця 3 – Результати порівняння параметрів

Модель	Параметр	RMSE (середньоквадратична помилка)	R (коефіцієнт кореляції)	MAE (середня абсолютна помилка)
ANFIS	BS	$1,24 \times 10^{-5}$	0,999	$8,814 \times 10^{-6}$
	PL	$1,746 \times 10^{-3}$	0,999	$1,165 \times 10^{-3}$
	MOG	$2,96 \times 10^{-4}$	0,999	$7,95 \times 10^{-5}$
RBF	BS	0,0401	0,9775	0,02
	PL	5,66	0,986	2,48
	MOG	0,2414	0,9753	0,083

Джерело: розроблено автором на підставі [6], [8]

Згідно з даними табл. 3, ANFIS з RMSE, що становить  $1,24 \times 10^{-5}$ ,  $1,746 \times 10^{-3}$  та  $2,96 \times 10^{-4}$ , і відповідним значенням коефіцієнта кореляції R – 0,999, 0,999 та 0,999 для BS, PL та MOG відповідно, показало найкращі результати у порівнянні з мережею RBF. Це зумовлено нижчим значенням квадратичним відхиленням та вищим значенням R порівняно з мережею RBF. Тому ANFIS було обрано як найкращу модель прогнозування в даному дослідженні.

Процес оптимізації було виконано за допомогою методу поверхні відгуку. Метод RSM є статистичним підходом, який дозволяє встановити взаємозв'язки між кількома пояснювальними змінними (вхідними змінними) та однією або кількома змінними відгуку (вихідними змінними). Основна ідея методу RSM полягає у використанні послідовності запланованих експериментів для досягнення оптимального відгуку [14].






Рисунок 4 – Результати процесу оптимізації

Джерело: розроблено автором

**Висновки.** У даному дослідженні фактори продуктивності зернозбирального комбайна, зокрема BS, PL та MOG, було змодельовано на основі трьох факторів – А, В та С – із використанням багатошарового перцептрона (MLP) та радіально-базисної функції (RBF) штучних нейронних мереж. За результатами статистичного аналізу та перевірки функціональних параметрів, за допомогою кореляційного тесту було встановлено, що взаємозв'язок між цими параметрами є статистично значущим на рівні ймовірності 5%.

Після моделювання та аналізу отриманих результатів було встановлено, що зі збільшенням кількості нейронів у прихованому шарі якість результатів покращується. Найкращі результати та найвище значення коефіцієнта кореляції було отримано при 20 нейронах у прихованому шарі.

Враховуючи результати, завдяки високій адаптивності та низькій похибці, можна стверджувати, що модель RBF має високу цінність для моделювання цієї системи.

## Список літератури

1. Ефективний обмолот змішаних посівів зернових та зернобобових культур на зернофураж. Київ : ДБНУ «Агротех», 2014. 252 с.
2. Сисолін П.В., Рибак Т.І., Сало В.М. Сільськогосподарські машини: теоретичні основи, конструкція, проектування. Книга 2. Київ : Урожай, 2002. 364 с.
3. Сисолін П.В., Сало В.М., Кропівний В.М. Сільськогосподарські машини: теоретичні основи, конструкція, проектування. Київ : Урожай, 2001. 384 с.
4. Хайліс Г.А. Коновалюк Д.М. Розрахунок робочих органів збиральних машин: навч. посіб. Київ : НМК ВО, 1991. 199 с.
5. Maertens, K., M. Reyniers, and J. De Baerdemaeker, Design of a Dynamic Grain Flow Model for a Combine Harvester. 2001.
6. Spengler, A., S. Mehne, and A. Feiffer. Combine harvesting at large scale enterprises in Europe. in *Electronic*
7. Proceedings of the International Conference on Crop Harvesting and Processing, Louisville, Ky. 2003.
8. Maertens, K. and J. De Baerdemaeker, Design of a virtual combine harvester. *Mathematics and Computers in Simulation*, 2004. 65(1–2): p. 49–57.
9. Maertens, K., Data-driven techniques for the on-the-go evaluation of separation processes in combine harvesters. 2004, Ph. D. Thesis. Department of Agro-Engineering and Economics, Katholieke Universiteit Leuven,
10. Leuven, Belgium. Hemmat, A., V. I. Adamchuk and P. Jasa, 2008. Use of an instrumented disc coulter for mapping soil mechanical resistance. *Soil & Tillage Research*, 98: 150–163.
11. Fallahi, S. and M. H. Raoufat, 2008. Row-crop planter attachments in a conservation tillage system: A comparative study. *Soil & Tillage Research*, 98: 27–34.
12. Karayel, D., 2009. Performance of a modified precision vacuum seeder for no-till sowing of maize and soybean. *Soil & Tillage Research*, 104: 121–125.
13. Soyguder, S., Intelligent system based on wavelet decomposition and neural network for predicting of fan speed for energy saving in HVAC system. *Energy and Buildings*, 2011. 43(4): p. 814–822.
14. Chen, X.-t. and L.-h. Zhang, High-quality voice conversion system based on GMM statistical parameters and RBF neural network. *The Journal of China Universities of Posts and Telecommunications*, 2014. 21(5): p. 68–75.
15. Craessaerts, G., et al., A genetic input selection methodology for identification of the cleaning process on a combine harvester, Part II: Selection of relevant input variables for identification of material other than grain (MOG) content in the grain bin. *Biosystems Engineering*, 2007. 98(3): p. 297–303.
16. Maertens, K. and J. De Baerdemaeker, Design of a virtual combine harvester. *Mathematics and Computers in Simulation*, 2004. 65(1): p. 49–57.
17. Zhao, Z., et al., Grain separation loss monitoring system in combine harvester. *Computers and electronics in agriculture*, 2011. 76(2): p. 183–188.

18. Mirzazadeh, A., et al., Intelligent modeling of material separation in combine harvester's thresher by ANN. *International Journal of Agriculture and Crop Sciences*, 2012. 4(23): p. 1767–1777.
19. Maertens, K., et al., PH-Power and Machinery: An Analytical Grain Flow Model for a Combine Harvester, Part I: Design of the Model. *Journal of agricultural engineering research*, 2001. 79(1): p. 55–63.
20. Maertens, K., et al., PA-Precision Agriculture: An Analytical Grain Flow Model for a Combine Harvester, Part II: Analysis and Application of the Model. *Journal of agricultural engineering research*, 2001. 79(2): p. 187–193.
21. Miu, P.I. and H.-D. Kutzbach, Modeling and simulation of grain threshing and separation in threshing units - Part I. *Computers and Electronics in Agriculture*, 2008. 60(1): p. 96–104.
22. Комбайни. *John Deere*: веб-сайт. URL : <https://www.deere.ua/ru/зерноуборочные-комбайны/серия-s/s760/> (дата звернення: 01.06.2025).

## References

1. Efektyvnyi obmolot zmishanykh posiviv zernovykh ta zernobobovykh kultur na zernofurazh. (2014). Kyiv: DBNU «Ahrotekh» [in Ukraine].
2. Sysolin, P.V., Rybak, T.I., & Salo, V.M. (2002). Silskohospodarski mashyny: teoretychni osnovy, konstruktsiia, proektuvannia. Knyha 2. Kyiv: Urozhai [in Ukraine].
3. Sysolin P.V., Salo V.M., Kropivnyi V.M. (2001). Silskohospodarski mashyny: teoretychni osnovy, konstruktsiia, proektuvannia. K.: Urozhai, 384 s. [in Ukraine].
4. Khailis H.A. Konovaliuk D.M. (1991). Rozrakhunok robochykh orhaniv zbyralnykh mashyn: Navch. posibnyk. K.: NMK VO, 199 s. [in Ukraine].
5. Maertens, K., M. Reyniers, and J. De Baerdemaeker, ( 2001). Design of a Dynamic Grain Flow Model for a Combine Harvester.
6. Spengler, A., S. Mehne, and A. Feiffer. Combine harvesting at large scale enterprises in Europe. in Electronic
7. Proceedings of the International Conference on Crop Harvesting and Processing, Louisville, Ky. 2003. [in English].
8. Maertens, K. and J. De Baerdemaeker, (2004). Design of a virtual combine harvester. *Mathematics and Computers in Simulation*, 65(1–2): p. 49–57. [in English].
9. Maertens, K. (2004). Data-driven techniques for the on-the-go evaluation of separation processes in combine harvesters., Ph. D. Thesis. Department of Agro-Engineering and Economics, Katholieke Universiteit Leuven. [in English].
10. Leuven, Belgium. Hemmat, A., V. I. Adamchuk and P. Jasa. (2008). Use of an instrumented disc coulter for mapping soil mechanical resistance. *Soil & Tillage Research*, 98: 150–163. [in English].
11. Fallahi, S. and M. H. Raoufat, (2008). Row-crop planter attachments in a conservation tillage system: A comparative study. *Soil & Tillage Research*, 98: 27–34. [in English].
12. Karayel, D. (2009). Performance of a modified precision vacuum seeder for no-till sowing of maize and soybean. *Soil & Tillage Research*, 104: 121–125. [in English].
13. Soyguder, S. (2011). Intelligent system based on wavelet decomposition and neural network for predicting of fan speed for energy saving in HVAC system. *Energy and Buildings*, 43(4): p. 814–822. [in English].
14. Chen, X.-t. and L.-h. Zhang. (2014). High-quality voice conversion system based on GMM statistical parameters and RBF neural network. *The Journal of China Universities of Posts and Telecommunications*, 21(5): p. 68–75. [in English].
15. Craessaerts, G., et al. (2007). A genetic input selection methodology for identification of the cleaning process on a combine harvester, Part II: Selection of relevant input variables for identification of material other than grain (MOG) content in the grain bin. *Biosystems Engineering*, 98(3): p. 297–303. [in English].
16. Maertens, K. and J. De Baerdemaeker. (2004). Design of a virtual combine harvester. *Mathematics and Computers in Simulation*, 65(1): p. 49–57. [in English].
17. Zhao, Z., et al., Grain separation loss monitoring system in combine harvester. *Computers and electronics in agriculture*, 2011. 76(2): p. 183–188. [in English].

18. Mirzazadeh, A., et al. (2012). Intelligent modeling of material separation in combine harvester's thresher by ANN. *International Journal of Agriculture and Crop Sciences*, 4(23): p. 1767–1777. [in English].
19. Maertens, K., et al., PH-Power and Machinery: An Analytical Grain Flow Model for a Combine Harvester, Part I: Design of the Model. *Journal of agricultural engineering research*, 2001. 79(1): p. 55–63. [in English].
20. Maertens, K., et al., PA-Precision Agriculture: An Analytical Grain Flow Model for a Combine Harvester, Part II: Analysis and Application of the Model. *Journal of agricultural engineering research*, 2001. 79(2): p. 187–193. [in English].
21. Miu, P.I., & Kutzbach, H.-D. (2008). Modeling and simulation of grain threshing and separation in threshing units - Part I. *Computers and Electronics in Agriculture*, 60(1): p. 96–104. [in English].
22. Combines. John Deere: website. URL: <https://www.deere.ua/ru/zernoborochnyie-kombainyi/seriya-s/s760/> [in Ukraine].

**Maksym Zayets**, Assoc. Prof., PhD tech. sci.

*Polissia National University, Zhitomir, Ukraine*

**Anatoliy Klymchuk**, Lecturer

*Zhytomyr Automobile and Road College of the National Transport University, Zhytomyr, Ukraine*

### **Influence of Parameters of Disc Coulters on the Transmission Capacity of Cutting Crop Residues in the System of Zero Tillage**

Automated control of harvesting systems can significantly improve the efficiency of agricultural processes and reduce crop losses. Modeling and enhancing the performance of the combine harvester contribute to increasing its overall productivity. The use of machine learning methods opens up possibilities for accurate prediction of the machine's maximum efficiency.

This study presents a combine harvester performance model developed using the Radial Basis Function (RBF) and a hybrid machine learning method—Adaptive Neuro-Fuzzy Inference System (ANFIS)—which allows predicting various combine parameters to achieve optimal performance. Additionally, the Response Surface Methodology (RSM) is applied for model optimization. Comparative analysis shows that ANFIS demonstrates better results compared to RBF.

The study of critical points enables the determination of the optimal range for each variable. The main goal of this research was to study and develop models based on RSM methods, RBF, and the ANFIS neural network, considered as key steps in constructing an accurate learning-stage model. The training process of the RBF and ANFIS models was carried out, and the obtained results were analyzed. These results allow selecting the best model for further testing. The prediction process was performed using ANFIS and RBF networks. For modeling, the parameters BS, PL, and MOG were considered dependent variables (network outputs), while A, B, and C were treated as independent variables (network inputs).

The optimization process was conducted using the Response Surface Methodology. The RSM method is a statistical approach that establishes relationships between several explanatory variables (input variables) and one or more response variables (output variables). The main idea of RSM is to use a sequence of designed experiments to achieve an optimal response.

**combine harvester, hybrid machine learning, response surface methodology, artificial intelligence, radial basis function**

*Одержано (Received) 12.11.2025*

*Прорецензовано (Reviewed) 04.12.2025*

*Прийнято до друку (Approved) 23.12.2025*