

І.М. НАЗАРЕНКО

(Сумський національний аграрний університет, м. Суми, Україна)

Прикладні аспекти нейронного моделювання в процесі діагностики капіталу сільськогосподарських підприємств

Метою статті є обґрунтування та розкриття можливості застосування нейромережевого моделювання в процесі діагностики капіталу сільськогосподарських підприємств. Систематизовано теоретичні та практичні аспекти застосування нейронних моделей в економіці. За допомогою графічного методу здійснено наочну ілюстрацію процесу моделювання. В дослідженні використано метод структурно-логічних схем та регресійний аналіз. В результаті проведеного дослідження побудовано нейронну модель діагностики капіталу сільськогосподарського підприємства. Вихідними даними для моделювання обрано складові власного капіталу, а результативним показником – чистий прибуток (збиток) підприємства. Обґрунтовано, що найбільш придатною за архітектурою та параметрами для моделювання впливу складових власного капіталу на фінансовий результат являється багатощаровий перцептрон. Здійснено прогноз зміни чистого прибутку від змін складових власного капіталу. Доведено, що використання штучних нейронних мереж в процесі діагностики капіталу сприятиме прийняттю ефективних управлінських рішень.

Ключові слова: нейронне моделювання, модель, капітал підприємства, фінансовий результат, управління.

И.Н. НАЗАРЕНКО

(Сумской национальной аграрный университет, г. Сумы, Украина)

Прикладные аспекты нейронного моделирования в процессе диагностики капитала сельскохозяйственных предприятий

Целью статьи является обоснование и раскрытие возможности применения нейросетевого моделирования в процессе диагностики капитала сельскохозяйственных предприятий. Систематизированы теоретические и практические аспекты применения нейронных моделей в экономике. С помощью графического метода осуществлено наглядную иллюстрацию процесса моделирования. В исследовании использован метод структурно-логических схем и регрессионный анализ. В результате проведенного исследования построено нейронную модель диагностики капитала сельскохозяйственного предприятия. Исходными данными для моделирования избраны составляющие собственного капитала, а результативным показателем – чистая прибыль (убыток) предприятия. Обосновано, что наиболее подходящей по архитектуре и параметрами для моделирования влияния составляющих собственного капитала на финансовый результат является многослойный перцептрон. Осуществлен прогноз изменения чистой прибыли от изменений составляющих собственного капитала. Доказано, что использование искусственных нейронных сетей в процессе диагностики капитала будет способствовать принятию эффективных управленческих решений.

Ключевые слова: нейронное моделирование, модель, капитал предприятия, финансовый результат, управление.

I.M. NAZARENKO

(Sumy National Agrarian University, Sumy, Ukraine)

Applied Aspects of Neural Modeling in the Process of Diagnosing the Capital of Agricultural Enterprises

The aim of the article is to study and disclose the possibility of using neural network modeling in the process of diagnosing the capital of agricultural enterprises. Systematized theoretical and practical aspects of the use of neural

models in the economy. Using the graphical method implemented graphic illustration of the modeling process. The study used structural-logic method and regression analysis. As the result of the study a neural model of diagnosing capital of agricultural enterprises is built. As the initial data for modeling taken components of equity and performance indicators - net profit (loss) of the enterprise. It is proved that the most appropriate architecture and parameters for modeling the impact of the components of equity in the financial result is a multilayer perceptron. Implemented the forecast of change in net profit from the changes in the components of equity. It is proved that the use of artificial neural networks in the process of diagnosing the capital will facilitate the adoption of effective management decisions.

Keywords: neural modeling, model, capital of the company, financial results, management.

Постановка проблеми. Розвиток ринкової економіки, інституціоналізація власності, трансформація критеріїв ефективності діяльності підприємства вносять суттєві корективи в управлінську діяльність та місію підприємств в умовах сьогодення. Недостатній рівень фінансового забезпечення, відсутність комплексної методики діагностики капіталу з урахуванням інтересів зовнішніх та внутрішніх зацікавлених осіб, являється фундаментальною проблемою аграрного менеджменту. Саме тому керівники підприємств (власники, акціонери, менеджери) повинні переглянути головні принципи управління і віддати пріоритет тим напрямкам та інструментам, які мають найбільшу цінність і забезпечують ефективну реалізацію управлінських рішень у кризовий період.

Застосування традиційних методик обмежує можливість здійснення комплексної діагностики капіталу сільськогосподарських підприємств. Відтак існує потреба у моделюванні нового системного підходу до діагностики капіталу, який являтиметься фундаментальною платформою менеджменту аграрних підприємств.

Аналіз останніх досліджень і публікацій.

Різноманітним питанням моделювання присвятили свої праці О.В. Козьменко, О.Є. Лугінін, О.М. Назаренко, С.І. Наконечний, А.І. Якимів та інші. Нейронне моделювання – один з центральних об'єктів досліджень таких вітчизняних та зарубіжних вчених як І.В. Журавльова [3], М.Л. Кравченко, Т.І. Грекова, А.В. Матвійчук, О.Г. Руденко.

В економіці моделювання – один із важливих інструментів вивчення взаємозалежності між економічними процесами та виявлення трендів їх подальшого розвитку. Зокрема, в дослідженні О.К. Зоценко метою економетричного моделювання є визначення взаємозалежності функціонування ринку акцій та параметрів соціально-економічного розвитку країни [4]. Л.М. Шаповал та І.С. Перепелиця шляхом імітаційного моделювання обґрунтовують вибір оптимальних параметрів фінансового забезпечення сільськогосподарських підприємств [6].

Незважаючи на достатньо пильну увагу вчених до різних напрямів моделювання в економіці, прикладні аспекти використання нейронного моделювання в процесі діагностики капіталу сільськогосподарських підприємств залишаються майже не розкритими.

Метою статті є обґрунтування та розкриття можливості застосування нейронного моделювання в процесі діагностики капіталу сільськогосподарських підприємств.

Виклад основного матеріалу дослідження. Сьогодні поряд з традиційними математичними методами моделювання широкої популярності набувають й інші методи, серед яких – апарат нейронних мереж.

Нейронні мережі є системами, що самонавчаються. Головною перевагою нейронних мереж є можливість відтворення складних нелінійних залежностей за великої кількості вхідних параметрів, адаптація до змін зовнішнього середовища. Нейронна мережа вивчає запропоновані приклади, створює узагальнену модель залежностей між входами та виходами [2].

Штучна нейронна мережа – це система, яка складається з багатьох простих складових (нейронів), певним чином поєднаних між собою. Найбільш поширеними є моделі багатошарових мереж, в яких нейрони об'єднані у шари. Шар – це сукупність нейронів, на які в кожен такт часу поступає сигнал з інших нейронів, тобто виходи одних нейронів є входами інших нейронів. Після визначення кількості шарів та кількості елементів в них, нейронну мережу навчають. Помилка для конкретної конфігурації мережі визначається як різниця між виходом мережі та реальними даними.

Задачі апроксимації експериментальних даних можна вирішувати за допомогою моделей MLP (багатошаровий перцептрон), RBF (радіально-базисні функції), GRNN [2, 3, 4, 5].

В процесі функціонування мережі відбувається перетворення вхідного вектора сигналів у вихідний. Конкретний вид перетворення визначається як архітектурою нейронної мережі, так і характеристиками нейронних елементів, засобами керування та синхронізації інформаційних потоків між нейронами. Важливим фактором ефективності мережі є встановлення оптимальної кількості нейронів та типів зв'язків між ними [2].

Типова MLP – це мережа, що має вхідний шар, вихідний шар і принаймні один прихований шар (рис. 1). Теоретично, обмежень відносно числа прихованих прошарків не існує, але практично застосовують один або два.




Рис. 1. Багатошаровий персептрон

Джерело: побудовано автором за даними [2].

Нейрони організовані в пошарову структуру з прямою передачею сигналу. Кожен нейрон мережі продукує зважену суму своїх входів, пропускає цю величину через передатну функцію і видає вихідне значення. Мережа може моделювати функцію практично будь-якої складності, причому число прошарків і число нейронів у кожному шарі визначають складність функції. Визначення числа проміжних шарів і числа нейронів в них є важливим при моделюванні мережі. Більшість дослідників та інженерів, застосовуючи архітектуру до визначених проблем, використовують загальні правила, зокрема [3]:

- кількість входів і виходів мережі визначаються кількістю вхідних і вихідних параметрів досліджуваного об'єкта, явища, процесу, тощо. На відміну від зовнішніх шарів, число нейронів прихованого шару вибирається емпіричним шляхом. В більшості випадків достатня кількість нейронів становить $n_{ск} \leq n_{вх} + n_{вих}$, де $n_{вх}$, $n_{вих}$ – кількість нейронів у вхідному і, відповідно, у вихідному шарах;

- якщо складність у відношенні між отриманими та бажаними даними на виході збільшується, кількість нейронів прихованого шару повинна також збільшитися;

- якщо моделювання може поділитися на багато етапів, потрібен додатковий прихований шар (шари). Якщо процес не розділяється на етапи, тоді додаткові шари можуть допустити переzapам'ятовування і, відповідно, невірне загальне рішення.

Після того, як визначено число прошарків і число нейронів в кожному з них, потрібно знайти значення для синаптичних ваг і порогів мережі, здатних мінімізувати похибку отриманого результату. Саме для цього існують алгоритми навчання, де відбувається підгонка моделі мережі до наявних навчальних даних. Похибка для конкретної моделі мережі визначається шляхом проходження через мережу всіх навчальних прикладів і порівняння отриманих вихідних значень з бажаними значеннями. Безліч похибок створює функцію похибок, значення якої можна розглядати, як похибку мережі. Як функції похибок найчастіше використовують суму квадратів похибок.

Кожний етап алгоритму навчання називається епохою. На кожній епосі на вхід мережі по черзі подаються всі навчальні приклади, вихідні значення мережі порівнюються з бажаними значеннями і обчислюється похибка. Процес навчання припиняється або коли пройдено певну кількість епох, або коли похибка досягає певного рівня малості, або коли похибка перестає зменшуватись (користувач переважно сам вибирає потрібний критерій зупинки) [2].

RBF – це мережа, що має шар радіальних елементів, кожен з яких відтворює гаусову поверхню відклику (рис. 2). Процес навчання складається з двох кроків: процес налаштування центрів базисних функцій та навчання нейронів в прихованому шарі.




Рис. 2. RBF-мережа

Джерело: побудовано автором за даними [4].

Для того, щоб зрозуміти поведінку радіальної базисної мережі загального вигляду, необхідно прослідкувати проходження вектора входу X . При завданні значень елементам вектора входу кожен нейрон вхідного шару видає значення відповідно до того, як близько вектор входу до вектора вагів кожного нейрона. Таким чином, нейрони з векторами вагів, що значно відрізняються з вектором входу X , матимуть виходи близькі до 0 та їх вплив на виходи лінійних нейронів вихідного шару буде незначним. Навпаки, вхідний нейрон, ваги якого близькі до вектора X , видасть значення близьке до одиниці.

GRNN-мережа в якості першого прихованого шару має радіально-базисний шар, другий прихований шар – лінійний. Мережа копіює в себе всі навчаючі спостереження та використовує їх для оцінки відгуку. Кінцева вихідна оцінка мережі отримується як зважене середнє виходів по всім

навчаючим спостереженням, де величина вагів відображає відстань від цих спостережень до тієї точки, в якій виконується оцінювання. Другий прихований шар містить елементи, які допомагають оцінити зважене середнє [4].

Процес навчання GRNN-мережі аналогічний навчанню RBF-мережі. Спочатку налаштовуються центри базисних функцій, потім навчається вихідний шар. GRNN-мережа має один управляючий параметр навчання, значення якого обираються користувачем, – ступінь згладжування.

З метою практичної апробації, застосуємо нейронне моделювання для визначення впливу складових власного капіталу на чистий прибуток.

Вихідними даними для моделювання являтимуться складові власного капіталу, а як вихід – чистий прибуток (збиток). Структура нейронної моделі наведена на рис. 3.

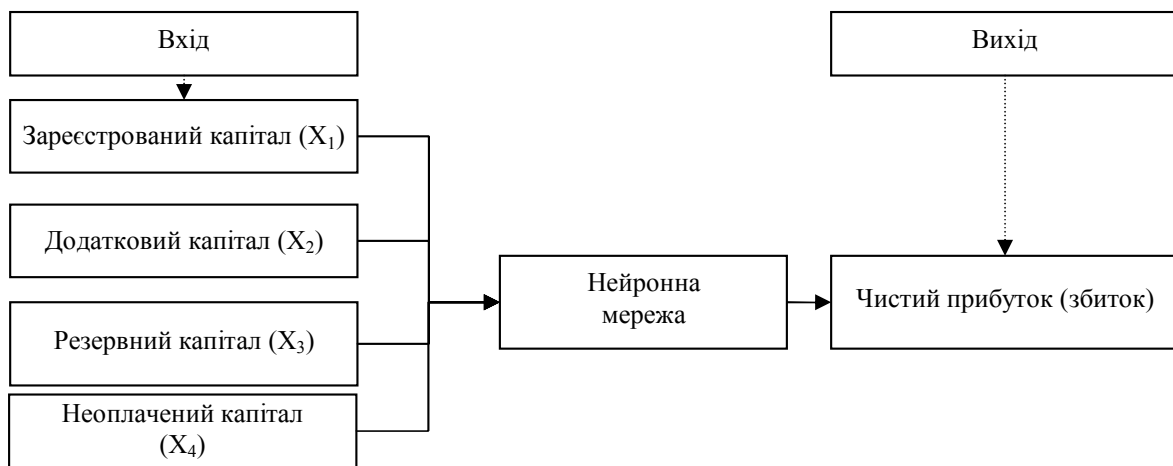


Рис. 3. Структура нейронної моделі

Джерело: побудовано автором.

Найбільш придатну модель апроксимації даних досліджено за допомогою програмного забезпечення Neural Networks Matlab.

Навчаючу вибірку для моделювання впливу складових власного капіталу на розмір чистого прибутку (збитку) сформуємо за допомогою даних Державної служби статистики України (табл. 1).

Таблиця 1

Формування навчаючої вибірки для моделювання

Розмір зареєстрованого капіталу, грн.	Розмір додаткового капіталу, грн.	Розмір резервного капіталу, грн.	Розмір неоплаченого капіталу, грн.	Розмір чистого прибутку (збитку), грн.
X_1	X_2	X_3	X_4	Y
24410722600	27284630600	2066757700	0	722867200
11419260400	30583372100	1851746900	377847300	660311400
11241846700	26526365800	2007521500	461676900	-589305900
11089936100	23498939500	2047278800	490021100	-352055400
10749123400	20671227600	2194773000	528230500	2452715100
11199743700	19163359800	2662079600	523448700	3461395400
12729056200	17089090800	3093588000	2181161200	2437524900
14330083900	18885109900	3930539300	1270064800	6846870000
19319121100	21883300500	5187708200	2673902200	5734706800
20584030500	22987405300	6223758800	2552073600	7560933600
21647329800	24768006700	7997743900	2459117400	17237851400
23548580000	28526270300	10296632800	1716479600	25252883800
25983612700	29145641800	12462417800	1984715600	26717537100
28840703700	28541969100	14112267300	2576720000	14911163200
28774508100	29371419400	15148921500	2260530900	20241466800

Джерело: систематизовано за даними Державної служби статистики України за період 2000-2014 р.р.

Аудит, аналіз і контроль

Необхідним етапом нейронного моделювання являється оцінка моделі.

Для вибору найбільш придатної архітектури нейронної мережі були оцінені RBF-мережа та MLP-мережа.

1) Оцінка RBF- мережі.

На рис. 4 представлені параметри створеної RBF-мережі. Тип нейронної мережі (Network Type) – Radial Basis, масив входів (Input data), цільовий вихід (Target Data), параметри (Performance goal, Spread constant).

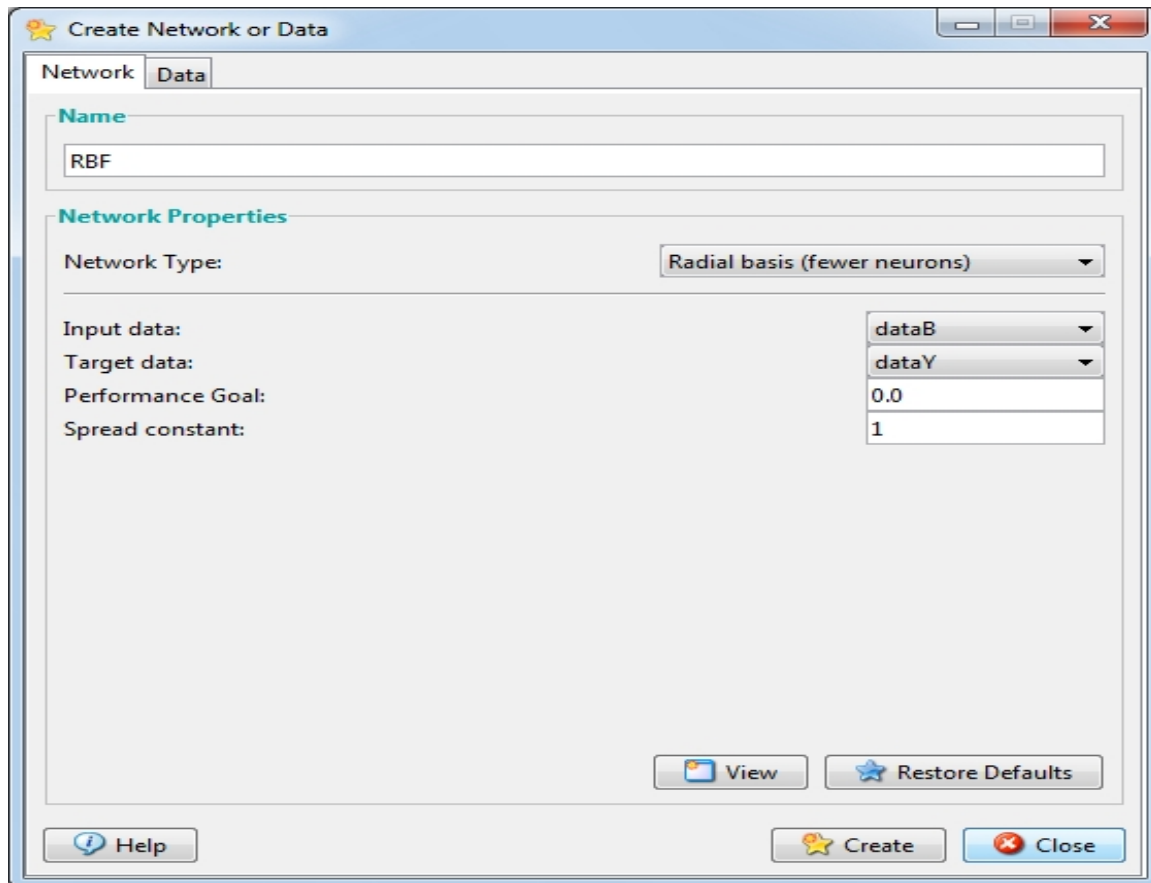


Рис. 4. Параметри RBF-мережі

Джерело: екранна форма програми.

Результати навчання *RBF* мережі наведені на рис. 5.




Рис. 5. Моделювання мережі RBF

Джерело: результати моделювання.

Згідно даних рис. 5 можемо констатувати, що значення Y навчаючої вибірки та значення виходу нейронної мережі майже співпадають.

Величина помилки мережі, яка є різницею між значеннями Y навчаючої вибірки та значення виходу нейронної мережі $RBFOutputs$, зображена на рис. 6.




Рис. 6. Вектор помилки мережі RBF

Джерело: результати моделювання.

З метою оцінки MLP-мережі, для налаштування параметрів нейронної мережі необхідно визначити кількість нейронів в прихованому шарі.

В табл. 4 відображені результати моделювання MLP-мережі з різною кількістю нейронів в прихованому шарі та значення коефіцієнта кореляції

між значеннями фінансового результату навчаючої вибірки та виходом мережі.

Коефіцієнт кореляції є характеристикою лінійного взаємозв'язку між двома випадковими величинами X і Y , та розраховується за формулою:

$$r_{xy} = \frac{\overline{xy} - \bar{x} \cdot \bar{y}}{\sqrt{(\overline{x^2} - \bar{x}^2)(\overline{y^2} - \bar{y}^2)}} = \frac{\text{cov}(X, Y)}{\sqrt{\text{var}(X) \text{var}(Y)}}, \quad (1)$$

де, $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$, $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$, $\overline{xy} = \frac{1}{n} \sum_{i=1}^n x_i y_i$, $\overline{x^2} = \frac{1}{n} \sum_{i=1}^n x_i^2$ – середні значення;

n – кількість спостережень [1].

Коефіцієнт кореляції приймає значення в інтервалі $-1 \leq r_{xy} \leq 1$. Позитивне значення коефіцієнта кореляції свідчить про прямий зв'язок між X і Y (із зростанням однієї випадкової величини зростає середнє значення іншої), від'ємне – про зворотний зв'язок (із зростанням однієї вибіркової величини

середнє значення іншої убаває). Якщо $r_{xy} \rightarrow \pm 1$ – зв'язок тісний, якщо $r_{xy} \rightarrow 0$ – лінійного зв'язку немає.

В даному випадку X – значення виходу нейронної мережі (MLPout), Y – еталонні значення навчаючої вибірки.

Таблиця 2

Оцінка MLP-мережі

№ моделі	Кількість нейронів в прихованому шарі	Коефіцієнт кореляції (R)
1.	1	-0,53
2.	2	0,36
3.	3	-0,15
4.	4	0,31
5.	5	0,91
6.	6	0,90
7.	7	0,93
8.	15	0,99

Джерело: розраховано автором.

Згідно даних табл. 2 найбільше значення коефіцієнта кореляції (0,99) має остання модель. Даний коефіцієнт характеризує величину зв'язку між

виходом нейронної мережі $MLP outputs$ та значенням еталона Y . Графік моделювання цієї моделі наведений на рис. 7.




Рис. 7. Моделювання мережі MLP

Джерело: результати моделювання.

Величину помилки мережі MLP представлено на рис. 8.




Рис. 8. Вектор помилки мережі MLP

Джерело: результати моделювання.

На рис. 9 представлені параметри мережі MLP.

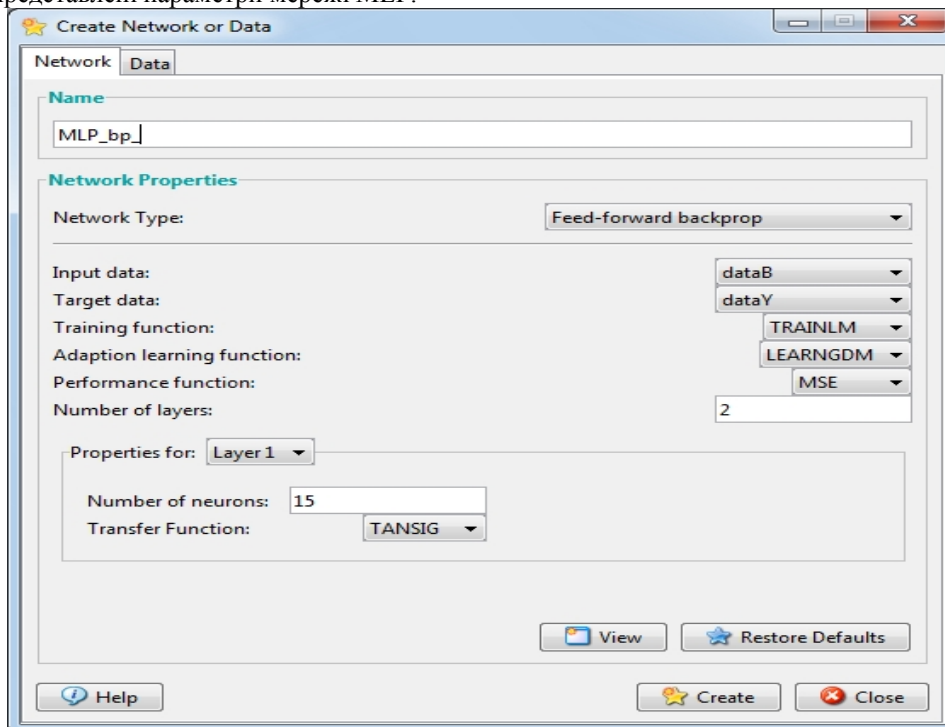


Рис. 9. Параметри навчання мережі MLP

Примітка: (Алгоритм навчання – Feed-forward backpropagation, функція навчання (training function) – TRAINLM, кількість нейронів в прихованому шарі (Number of neurons) – 15, передаточна функція – TANSIG) (вікно програми Neural Networks).

Джерело: екранна форма програми.

Параметри мережі MLP представлено на рис. 10.

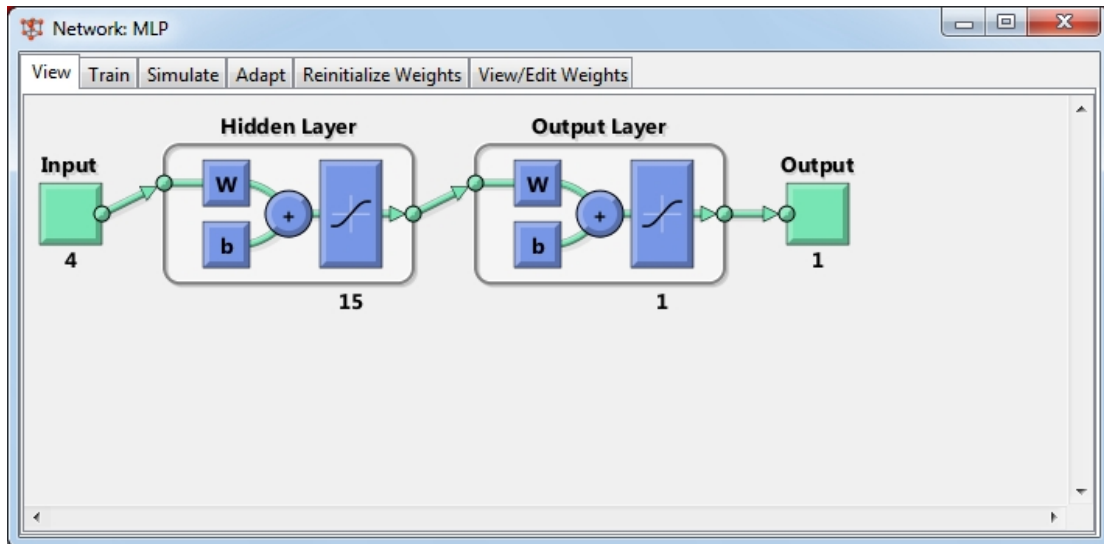


Рис.10. Параметри (входи (Input), прихований шар (Hidden Layer), Вихід (Output Layer) (вікно програми Neural Networks)

Джерело: екранна форма програми.

Якість навчання мережі MLP за допомогою програми Matlab можна здійснити за допомогою коефіцієнта кореляції R. Даний коефіцієнт повинен приймати значення від -1 до 1.

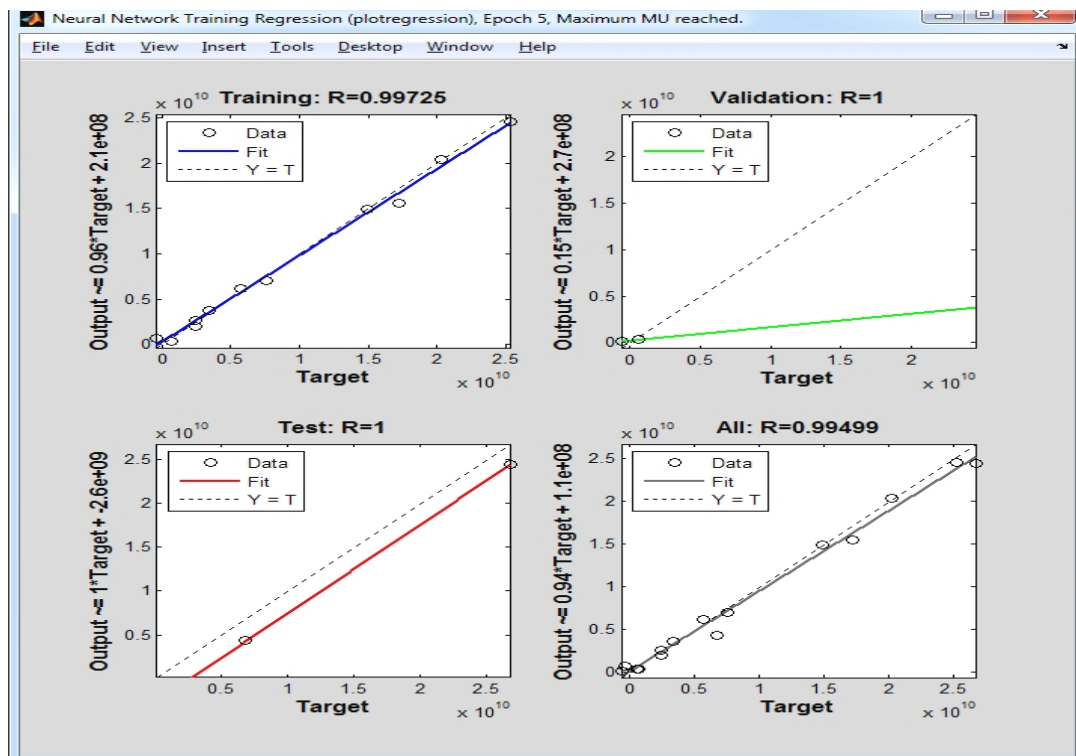


Рис. 11. Вікно регресії MLP (оцінка якості мережі) (вікно програми Neural Networks)

Джерело: екранна форма програми.

Дані навчання мережі потрібно оцінювати таким чином: чим ближче значення до 1, тим тісніший зв'язок між даними навчання y та виходом нейронної мережі y_{nn} .

Для порівняння якості досліджуваних нейронних моделей розрахуємо коефіцієнт кореляції між виходом моделі та еталоном.

Результати навчання нейронних мереж представлено в табл. 3.

Результати роботи нейронних мереж

Y (еталон)	Вихід нейронної мережі	
	MLP outputs	RBF outputs
722 867 200	722994771,154	722867200,0000150
660 311 400	660233946,767	660311400,0000040
-589305900	-105869294,810	-589305900,0000080
-352055400	-351981100,000	-352055400,0000000
2452715100	2452818737,760	2452715100,0000100
3461395400	3460975041,178	3461395400,0000000
2437524900	2437725934,749	2437524900,0000000
6846870000	6846867072,168	6846870000,0000000
5734706800	5734701596,100	5734706800,0000000
7560933600	7560966200,562	7560933600,0000000
17237851400	17237887867,660	17237851400,0000000
25252883800	25253065008,000	25252883800,0000000
26717537100	26614221667,959	26717537100,0000000
14911163200	14911376457,042	14911163200,0000000
20241466800	20242785243,824	20241466800,0000000 ¹

Джерело: результати проведеного автором моделювання.

Результати порівняльного аналізу досліджуваних нейронних мереж представлено в табл. 4.

Таблиця 4

Оцінка моделей нейронних мереж

Модель	Коефіцієнт кореляції
RBF	1
MLP	0,99

Джерело: розраховано автором.

Згідно даних табл. 4 найбільше значення коефіцієнта кореляції має RBF-мережа. Відповідно, для моделювання впливу складових капіталу на фінансовий результат за результатами оцінки моделей нейронних мереж краще підходить дана модель. Враховуючи думку В. Журавльової про те, що RBF – мережі, мають свої особливості, вони

доволі складні та не можуть бути використані для екстраполяції [3]. Тому, в якості базової архітектури використаємо MLP-мережу.

Результат використання отриманої моделі для апроксимації функції $y=f(x_1, x_2, x_3, x_4)$ представлено на рис. 12.




Рис. 12. Апроксимація нейронною мережею MLP

Джерело: результати моделювання.

Для оцінки якості моделі розрахуємо коефіцієнт детермінації. Результати розрахунку представлені в

табл. 5. є сумарною мірою якості математичної моделі та розраховується за формулою:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (2)$$

\bar{y} - вибіркове середнє,
 y_i - вихідні дані навчальної вибірки,
 \hat{y}_i - результати моделювання [1].

Таблиця 5

Оцінка якості мережі MLP

Назва моделі	Коефіцієнт детермінації
MLP	0,99

Джерело: розраховано автором.

Згідно даних табл. 5, можемо констатувати, що побудована модель являється якісною і придатною для моделювання впливу складових власного капіталу на чистий прибуток (збиток)

сільськогосподарських підприємств України. Відповідно, отриману нейронну мережу можна представити наступним чином (рис. 13).




Рис. 13. Схема нейронної мережі

Джерело: побудовано автором.

У побудованій нейронній мережі X_1 – розмір зареєстрованого капіталу; X_2 – розмір додаткового капіталу; X_3 – розмір резервного капіталу; X_4 – розмір неоплачений капіталу; Y_{out} – прогнозований розмір чистого прибутку (збитку).

Розроблену модель використаємо для проведення аналізу «що-якщо», який надасть можливість дослідити зміну вихідної величини (Y_{out}) в залежності від змін вхідних величин (X_1 ; X_2 ; X_3 ; X_4).

За допомогою побудованої нейронної моделі доведемо можливість прогнозування фінансового результату діяльності підприємства. Враховуючи попередні результати кореляційно-регресійного аналізу та взаємозв'язок власного капіталу з чистим прибутком, проаналізуємо в межах факторного зв'язку зміну результативного показника від складових власного капіталу.

Зміну значення відповідного фактору при фіксованому значенні інших факторів аналізуватимемо в наступній варіантній послідовності:

1) варіант 1 – зміна значення чистого прибутку, якщо розмір зареєстрованого капіталу 23548580000 грн. збільшити до 23548588000 грн. при фіксованих параметрах інших змінних;

2) варіант 2 - зміна значення чистого прибутку, якщо розмір додаткового капіталу з 2188330050 грн. збільшити до 21888300500 грн. при фіксованих параметрах інших змінних;

3) варіант 3 – зміна значення чистого прибутку, якщо розмір резервного капіталу з 3093588000 грн. збільшити до 3098588000 грн. при фіксованих параметрах інших змінних.

Результати моделювання представлені в табл. 6.

Результати моделювання

Варіанти моделювання	Розмір зареєстрованого капіталу, грн.	Розмір додаткового капіталу, грн.	Розмір резервного капіталу, грн.	Розмір неоплаченого капіталу, грн.	Розмір отриманого чистого прибутку (збитку), грн.
	X_1	X_2	X_3	X_4	Y_{out}
Варіант 1	23548588000	28526270300	10296632800	1716479600	25253065588
Варіант 2	19319121100	21888300500	5187708200	2673902200	5775763095
Варіант 3	12729056200	17089090800	3098588000	2181161200	2439535963

Джерело: розраховано за допомогою побудованої нейронної моделі.

Відповідно, результати дослідження дають підстави стверджувати про збільшення фінансового результату від збільшення відповідної складової власного капіталу (порівняння значення Y_{out} табл. 6 з значеннями Y табл. 1). Випробування отриманої нейронної моделі підтвердило гіпотезу про залежність фінансового результату від розміру складових власного капіталу. Зростання зареєстрованого капіталу (x_1), додаткового капіталу (x_2), резервного капіталу (x_3) має позитивний вплив на збільшення величини чистого прибутку.

Відповідно, актуальності набуває питання практичного апробування нейронного моделювання в процесі економічного дослідження впливу складових капіталу суб'єкта господарювання на фінансовий результат, який безпосередньо залежить від структурної побудови капіталу суб'єктів господарювання. Моделювання інструментарію застосування економіко-математичних методів (в тому числі нейронного моделювання) діагностики в менеджменті суб'єктів агробізнесу на даному етапі розвитку економіки України являється домінуючим та пріоритетним питанням, яке потребує науково-прикладного обґрунтування та вирішення.

Висновки. Аналітичним інструментом моделювання являються нейронні мережі. За допомогою нейронного моделювання можна відтворити складні нелінійні залежності. Найбільш придатним за архітектурою та параметрами для моделювання впливу складових власного капіталу на фінансовий результат являється багатоваріантний перцептрон (Multilayer Perceptron). Застосування нейромережевого моделювання в практичній діяльності сільськогосподарських підприємств сприятиме вирішенню актуальних управлінських завдань (визначення оптимальної структури капіталу; підвищення якості та точності фінансового аналізу; прогнозування перспектив розвитку підприємства), що мають постійний характер в умовах провадження господарської діяльності.

4 Список використаних джерел

1. Бородич, С. А. Економетрика [Текст] : Учебн. пособие. – Минск : Новое знание, 2001. – 408 с.
2. Горбань, А. Н. Нейронные сети на персональном компьютере [Текст] / А. Н. Горбань, Д. А. Россиев ; Рос. акад. наук, Сиб. отд-ние, вычислит. центр. – Новосибирск. – М. : Наука, 1996. – 276 с.
3. Журавльова, І. В. Використання нейронних мереж у процесі форсайту функціонування інтелектуального капіталу підприємства [Текст] / І. В. Журавльова //

Науковий вісник Буковинського державного фінансово-економічного університету. Економічні науки. – 2014. – Вип. 26. – С. 81-89.

4. Зоценко, О. К. Економетричне моделювання взаємозалежності функціонування ринку акцій та параметрів соціально-економічного розвитку України [Текст] / О. К. Зоценко // Облік і фінанси. – 2014. – № 2(64). – С. 126-130.

5. Кравченко, М. Л. Моделирование экономических систем с применением нейронных сетей [Электронный ресурс] / М. Л. Кравченко, Т. И. Грекова // Вестник Томского государственного университета. – 2006. – № 290. – Режим доступа: <http://cyberleninka.ru/article/n/modelirovanie-ekonomicheskikh-sistem-s-primeneniem-neyronnyh-setey>. - Название с экрана.

6. Шаповал, Л. П. Імітаційне моделювання фінансового забезпечення сільськогосподарських підприємств [Текст] / Л. П. Шаповал, І. С. Перепелиця // Облік і фінанси. – 2015. – № 3(69). – С. 124-129.

7. Muller, B. Neural Networks: an introduction [Text] / B. Muller, J. Reinhardt ; Springer-Verlag Berlin Heidelberg. – Berlin, 1990.

4 References

1. Borodych, S. A. (2001). *Ekonometrika [Econometrics]*. Minsk: Novoe znanye.
2. Horban, A. N. (1996). *Neyronnyie seti na personalnom kompyutere [Neural network on PC]*. Moskva: Nauka.
3. Zhuravlova, I. V. (2014). Vykorystannia neironnykh merezh u protsesi forsaitu funktsionuvannia intelektualnogo kapitalu pidpriemstva [The use of neural networks in the forsyth functioning intellectual capital of the company]. *Naukovyi visnyk Bukovynskoho derzhavnoho finansovo-ekonomichnoho universytetu. Ekonomichni nauky*, Vol. 26, 81-89.
4. Zotsenko, O. K. (2014). Ekonometrychne modeliuвання vzaemozalezhnosti funktsionuvannia rynku aksii ta parametriv sotsialno-ekonomichnoho rozvytku Ukrainy [Econometric Modelling of Interrelation between Stock Market Functioning and Parameters of Social & Economic Development of Ukraine]. *Oblik i finansy*, No. 2(64), 126-130.
5. Kravchenko, M. L. & Grekova, T. I. (2006). Modelirovanie ekonomicheskikh sistem s primeneniem neyronnykh setey [Modeling of economic systems with the use of neural networks]. *Vestnik Tomskogo gosudarstvennogo universiteta*. No. 290. Retrieved from <http://cyberleninka.ru/article/n/modelirovanie-ekonomicheskikh-sistem-s-primeneniem-neyronnykh-setey>.
6. Shapoval, L. P. & Perepelytsia, I. S. (2015). Imitatsiine modeliuвання finansovoho zabezpechennia silskohospodarskykh pidpriemstv [Simulation Modelling of Financial Support for Agricultural Companies]. *Oblik i finansy*, No. 3(69), 124-129.
7. Muller, B. & Reinhardt, J. (1990). *Neural Networks: an introduction*. Berlin: Springer-Verlag Berlin Heidelberg.