

УДК 004:339.144

М.П. Тимощук

ЗАСТОСУВАННЯ МОДЕЛІ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ОПТИМІЗАЦІЇ ЗАПАСІВ ГОТОВОЇ ПРОДУКЦІЇ

Досліджується проблема оптимізації запасів готової продукції залежно від різних комбінацій таких факторів, як попит, витрати на запровадження, утримання (ведення) бізнесу та матеріальні витрати. Здійснено порівняння точності прогнозування удосконаленої моделі з аналогом і зроблено висновки щодо її вищої ефективності. Запропонована модель допомагає з великою точністю визначити оптимальний об'єм запасів готової продукції.

Ключові слова: модель, штучна нейронна мережа, запаси готової продукції.

Исследуется проблема оптимизации запасов готовой продукции в зависимости от различных комбинаций таких факторов, как спрос, затраты на внедрение, содержание (ведение) бизнеса и материальные затраты. Осуществлено сравнение точности прогнозирования усовершенствованной модели с аналогом и сделаны выводы относительно ее большей эффективности. Предложенная модель помогает с большей точностью определить оптимальный объем запасов готовой продукции.

Ключевые слова: модель, искусственная нейронная сеть, запасы готовой продукции.

In this article investigates the problem of finished products optimization based on different combinations of such factors as demand, implementation costs, maintenance (management) business and material costs. Made the comparison of forecasting accuracy of improved model and analog model and made the conclusions of its

higher efficiency. The model helps determine the optimal volume of finished products with higher accuracy.

Keywords: model, artificial neural network, finished products stocks.

Постановка проблеми. В глобальному конкурентному бізнес-середовищі виробники мають підтримувати оптимальну кількість запасів готової продукції для зниження загальних витрат і оптимізації ланцюжка поставок. Метою будь-якої компанії є поставка необхідної кількості готової продукції в визначене місце, у потрібний час і за відповідною ціною.

В нашому дослідженні відношення між вхідними й вихідним факторами є складними, тому досить важко розробити відповідну математичну модель. З цією метою буде застосовано підхід штучних нейронних мереж (ШНМ).

Огляд останніх досліджень і публікацій. Проблема досягнення оптимального рівня запасів готової продукції привернула увагу багатьох дослідників. Як показав огляд літератури, нейронні мережі є багатообіцяючим методом прогнозування й оптимізації. У [1] розроблено й запропоновано нейронну мережу для оптимізації рівня запасів готової продукції в умовах нестійкого середовища. Як зазначено у [2], ШНМ є методом довільної оцінки, який може охопити й змоделювати складні відношення вхідних і вихідних факторів, навіть без застосування математичних моделей. ШНМ широко застосовуються для моделювання складних процесів відповідно до можливостей навчання й узагальнення, розміщення нелінійних змінних, пристосованості до змін навколишнього середовища і відсутності певних даних. У [1] зазначено, що ШНМ знайшли своє застосування при плануванні виробництва. Проте, проблемі оптимального рівня запасів приділено недостатньо уваги.

Завдання дослідження. Метою дослідження є передбачення цільового вихідного фактора (розмір запасів готової продукції) на основі існуючих комбінацій чотирьох вхідних і одного вихідного факторів. У дослідженні створено модель штучної

нейронної мережі, – для підвищення точності прогнозу оптимального рівня запасів готової продукції як функції від попиту, витрат на започаткування й ведення бізнесу і матеріальних затрат. Модель тестуватиметься на даних виробничого підприємства, а результати повинні показати її придатність до прогнозування оптимального розміру запасів у відповідності до параметрів моделі. Результати навчання і тестування покращеної нейронної мережі будуть порівнюватися з результатами аналога згідно з [1]. В разі виявлення більшої ефективності покращена мережа може бути застосована для оптимізації рівня готової продукції на будь-якому виробничому підприємстві в умовах конкурентного бізнес-середовища.

Основний матеріал дослідження. Згідно з [1], багато компаній використовують модель оптимального розміру запасів (EOQ), проте вона надто проста і не об'єктивна, бо допускає такі нереалістичні припущення, як сталий попит, незмінні закупівельні ціни чи миттєве отримання готової продукції тощо. Проте такі категорії як попит чи ціна на продукт є змінними й коливаються в межах певного діапазону відповідно до ринкових і соціально-економічних умов. Тому така модель не є прийнятною для виробничого підприємства [1].

Згідно з [1], мережа аналога містить вхідний, прихований і вихідний шари. Схематично вхідні/вихідні параметри мережі показані на рисунку.

Для створення, навчання й тестування мережі використано реальні дані виробничої компанії. Згідно з [1], на виробничому підприємстві було зібрано 81 комбінації вхідних-вихідних факторів. Зразок вхідних і вихідних даних подано в табл. 1.

Згідно з [1], набори вхідних-вихідних параметрів, що складають 81 комбінацію, випадково поділені на дві частини: навчальна вибірка становить 78 % даних, тестова вибірка – решта 22 %. Тому навчальна вибірка включає 63 комбінації параметрів. Після навчання ваги заморожуються і модель тестується.

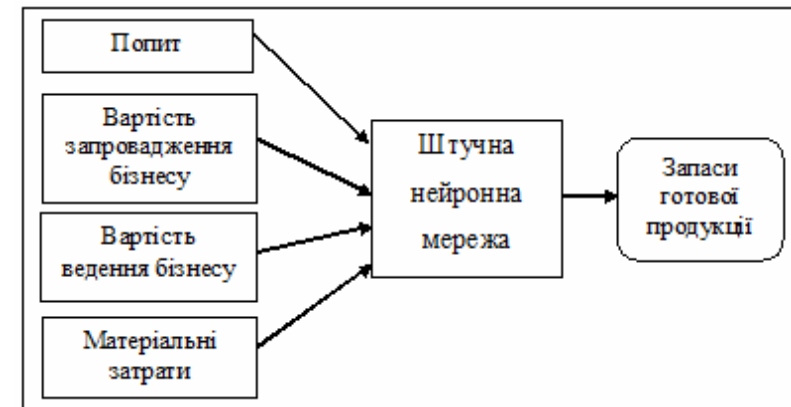


Рис. Схематична діаграма ШНМ

Таблиця 1
Фактичні значення вхідних і вихідних факторів

Вхідні фактори [D, S, H, M]	Вихідний фактор Q	Вхідні фактори [D, S, H, M]	Вихідний фактор Q
[1000 20 0,4 1]	500	[1000 20 1,2 5]	410
[1000 20 0,4 3]	450	[1000 20 2,0 1]	460
[1000 20 0,4 5]	400	[1000 20 2,0 3]	425
[1000 20 1,2 1]	475	[1000 20 2,0 5]	405
[1000 20 1,2 3]	440	[1000 40 0,4 1]	625

Згідно з [1] встановлено такі умови навчання мережі: максимальна кількість ітерацій – 10000; значення середньоквадратичної похибки наприкінці навчання – 0,0001; коефіцієнт навчання

чання – 0,5; постійна ітерації – 0,1. Для навчання нейронної мережі у [1] використано алгоритм зворотного поширення похибки. В якості функцій перетворення в прихованому і вихідному шарах застосовано ‘tansig’ і ‘purelin’ відповідно. Функцією навчання вибрано ‘trainscg’ – функція, яка навчає нейронну мережу з використанням комбінації метода спряженого градієнта з квазіньютонівим підходом в модифікації Моллера SCG. За допомогою команди ‘premnmx’ здійснено попередню обробку (нормалізацію) навчальної вибірки; згодом при використанні команди ‘postmnmx’ здійснено пост обробку даних. Для розрахунку приростів ваг і зміщень нейронної мережі методом градієнтного спуску зі збуренням використано функцію ‘leargdm’.

Далі в [1] здійснено регресійний аналіз, зокрема, знайдено значення середньої абсолютної похибки *MAPE* і коефіцієнта детермінації R^2 . Знаходження R^2 і *MAPE* допомагає оцінити ефективність мережі на етапі її навчання і тестування, а також знайти її оптимальну архітектуру. У [1] наведено значення вищевказаних показників при 8, 10, 12 і 15 прихованих нейронів відповідно, а також обгрунтовано, що найкращі результати навчання дає мережа, яка містить один прихований шар і десять прихованих нейронів (див. табл. 2).

Запропонуємо покращену нейронну мережу. Нашим завданням є порівняння ефективності навчання й прогнозування покращеної мережі з ефективністю ШНМ у [1]. Також потрібно здійснити передбачення вихідних факторів для нової комбінації вхідних факторів.

За своєю структурою й основними елементами покращена мережа значно простіша від ШНМ, наведеної в [1], як це буде показано нижче. Удосконалена модель мережі складається з вхідного, прихованого і вихідного шарів. Вхідні фактори (попит, вартість запровадження, вартість утримання (ведення) бізнесу і матеріальні затрати) потрапляють до вхідного шару, проходять обробку у прихованому шарі і дають результат через вихідний шар у вигляді оптимальної кількості запасів готової продукції.

Для навчання покращеної нейронної мережі використаємо алгоритм зворотного поширення похибки. В якості нелінійної трансферної функції застосуємо сигмоїдну функцію зваженої суми вхідних даних. Встановимо максимальну кількість навчальних епох – 1000, а кількість нейронів прихованого шару – 5. В якості функцій перетворення в прихованому і вихідному шарах застосуємо «tansig» і «purelin» відповідно. Функцією навчання оберемо «trainlm», що навчає нейронну мережу, використовуючи алгоритм Левенберга-Марквардта LM [3, 4]. Розв’язок задачі отримаємо у середовищі програми MATLAB.

Наведемо показники ефективності покращеної ШНМ (табл. 2).

Таблиця 2

Порівняння ефективності навчання штучних нейронних мереж

Показники	Ефективність навчання мережі [1]				Ефективність навчання удосконаленої ШНМ
	1	10	12	15	
Кількість прихованих шарів	1	1	1	1	1
Кількість прихованих нейронів	8	10	12	15	5
<i>MAPE</i>	0,0093	0,005	0,0429	0,0119	$5,976 * 10^{-12}$
R^2	0,9998	0,9998	0,9998	0,9997	1,0000

Згідно з [1], найкращі результати отримано при навчанні мережі з одним прихованим шаром і десятьма прихованими нейронами. Проте, показники ефективності удосконаленої ме-

режі з одним прихованим шаром і 5-ма прихованими нейронами є значно кращими: $MAPE = 5,976 * 10^{-12}$ і $R^2 = 1,0000$. Як видно з табл. 2, ефективність покращеної мережі в порівнянні з мережею, запропонованою в [1], значно вища. При навчанні запропонованої мережі використано кращий алгоритм навчання – алгоритм Левенберга-Марквардта [3, 4]. Це дозволило знизити значення похибок, зменшити кількість ітерацій (1000) і кількість нейронів прихованого шару (5).

Спрогнозуємо значення вихідного фактора для основі нової комбінації вхідних даних. Здійснимо тренування (навчання) покращеної ШНМ на основі векторів вихідних і вихідного фактора 1-7 і 9, 10-го на основі даних табл. 2, а також прогнозування 8-го вихідного фактора на основі восьми елементів векторів вхідних факторів. Однак, як видно з нижченаведених результатів:

% задавання значень параметрів ШНМ:

1. net.trainParam.epochs = 1000;
2. Actualoutput = 425 (значення фактичного вихідного фактора);
3. ANNoutput = 425,8619 (значення прогнозованого вихідного фактора);
4. $MAPE = 0,0020$

для одного елемента вихідного фактора на основі одного елемента вхідних факторів отримано прогнозне значення з похибкою $MAPE$, меншою від похибок навчання, наведених у [1] (див. табл. 2), де мінімальне значення $MAPE = 0,005$; при меншій кількості прихованих нейронів (при 5-ти, в той час як у [1] – при 10-ти). Отримані результати є кращими від аналогів. У відповідній програмі прогноз здійснюється для одного значення вихідного фактора. Але таким же чином можна прогнозувати по одному значенню вихідні фактори на основі будь-яких інших комбінацій вхідних факторів.

Висновки. Отже, метою дослідження є передбачення цільового фактора на основі існуючих комбінацій чотирьох вхід-

них і одного вихідного факторів, по яких мережа не навчалася. Для цього запропоновано покращену мережу, здійснено її навчання й тестування, та проведено порівняння з аналогом [1].

Покращена модель нейронної мережі була розроблена для оптимізації запасів готової продукції залежно від різних комбінацій таких факторів, як попит, витрати на запровадження, утримання (ведення) бізнесу та матеріальні затрати. Здійснено порівняння удосконаленої моделі з аналогом [1] і зроблено висновки щодо її вищої ефективності. В подальших дослідженнях буде здійснюватись удосконалення моделі оптимізації запасів готової продукції.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Paul S.K. An artificial neural network model for optimization of finished goods inventory / S.K. Paul, A.Azeem // *International Journal of Industrial Engineering Computations*. – 2011. – № 2. – P. 431-438.
2. Ntuen C.A. A neural network model for a holistic inventory system / C.A. Ntuen. *Proceedings of the International Industrial Engineering Conference*. – 1991. – P. 435-444.
3. Осовский С. Нейронные сети для обработки информации / Пер. с польск. И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.
4. Gill P. *Practical Optimization* / P. Gill, W. Murray, M. Wright. – N.Y.: Academic Press, 1981.

Стаття надійшла до редакції 16.03.2012

Рецензент – доктор економічних наук, професор, завідувач кафедри «Економічна теорія та кібернетика» Одеського національного морського університету **Г.С. Махуренко**.