

УДК 004.032.26

*Аббакумова А. Г., студентка 2 курсу спеціальності 126 «Інформаційні системи та технології»*

*Гітис В. Б., к.т.н., доцент, доцент кафедри інтелектуальних систем прийняття рішень*

## **ОПТИМІЗАЦІЯ АРХІТЕКТУРИ НЕЙРОННОГО МОДУЛЮ ІНФОРМАЦІЙНОЇ СИСТЕМИ ДЛЯ ПРОГНОЗУВАННЯ ПОКАЗНИКІВ МЕТАЛУРГІЙНОГО ВИРОБНИЦТВА**

*Донбаська державна машинобудівна академія, м. Краматорськ*

При рішенні задачі прогнозування багатовимірних стохастичних часових рядів в умовах структурної і параметричної невизначеності в загальному випадку природа спостережуваної послідовності невідома [1].

Останнім часом в економіці для прогнозування часових рядів досить часто застосовують нейронні мережі, тому що вони володіють такими перевагами:

- можливість обліку сезонності попиту при підготовці навчальної вибірки;
- нейронна мережа є універсальним апроксиматором, що дозволяє підібрати функцію будь-якої складності, не скуту строгим аналітичним виразом [2].

Метою роботи є дослідження впливу архітектур і параметрів нейронних мереж на точність моделювання часових рядів.

Штучні нейронні мережі є одним з найбільш адекватних інструментів прогнозування часових рядів, що дозволяють за минулими спостереженнями відновлювати нелінійне відображення виду [3]

$$x(t) = F(x(t-1), x(t-2), \dots, x(t-k)) + e(t) = x(t) + e(t), \quad (1)$$

де  $x(t)$  – оцінка (прогноз) значення  $x(t)$ , отримана на виході нейромережі;

$e(t)$  – помилка прогнозування;

$k$  – порядок моделі.

Нейромережа представляє в даному випадку нелінійну авторегресійну модель (NAR-модель).

В якості основи для побудови NAR-моделей доцільно використовувати багатошарові мережі з прямою передачею інформації.

До прямоспрямованих нейронних мереж відносяться перцептрони та РБФ-мережі. Ці дві архітектури найбільш придані до відтворення NAR-моделі і мають свої переваги та недоліки. Проте ефективність застосування тієї чи іншої мережі залежить від умов конкретної задачі. Тому потрібно провести експериментальні дослідження на предмет того, яка з запропонованих архітектур буде більш ефективною у вирішенні задачі прогнозування вибраного показника.

На першому етапі потрібно визначити необхідну кількість нейронів кожної мережі. Оцінити число нейронів в прихованих шарах можна за допомогою

нерівності для оцінки числа вагових коефіцієнтів в мережі необхідного для освоєння заданого числа прикладів в навчальній вибірці [4]:

$$\frac{N_y N_p}{1 + \log_2 N_p} \leq N_w \leq N_y \left( 1 + \frac{N_p}{N_x} \right) (N_x + N_y + 1) + N_y, \quad (2)$$

де  $N_w$  – число вагів в мережі;

$N_p$  – число елементів навчальної вибірки;

$N_x$  і  $N_y$  – відповідно розмірність вхідного і вихідного сигналу.

Тоді число прихованих нейронів ( $N_n$ ) в двошаровій мережі можна визначити по формулі

$$N_n = \frac{N_w}{N_x + N_y}. \quad (3)$$

Підставляючи граничні значення  $N_w$  можна отримати мінімальне ( $N_{wmin}$ ) і максимальне ( $N_{wmax}$ ) число нейронів в прихованому шарі мережі.

Для тестування мереж були використані дані по продажам продукції одним із металургійних підприємств регіону.

При плануванні обсягу продажів металів слід враховувати сезонний фактор, оскільки від нього залежить попит на металеву продукцію. Тому у NAR-моделі доцільно прирівняти порядок моделі до кварталу, тобто порядок моделі буде дорівнювати трьом позиціям. Тоді число входів нейронної мережі також складе 3.

Теоретично найбільш точні результати дасть модель із найменшим періодом планування, тобто величиною у 1 місяць. Тоді число виходів нейронної мережі також складе 1.

Вихідні дані представлені 5 роками, тобто 60 місяцями. Тоді кількість навчальних прикладів складе 57.

Підставляючи ці значення у формулу (2), отримано наступну кількість вагових коефіцієнтів нейромереж:  $N_{wmin} = 9$ ,  $N_{wmax} = 101$ .

Підставляючи кількість вагових коефіцієнтів у формулу (3), отримано наступну кількість нейронів:  $N_{nmin} = 3$ ,  $N_{nmax} = 26$ .

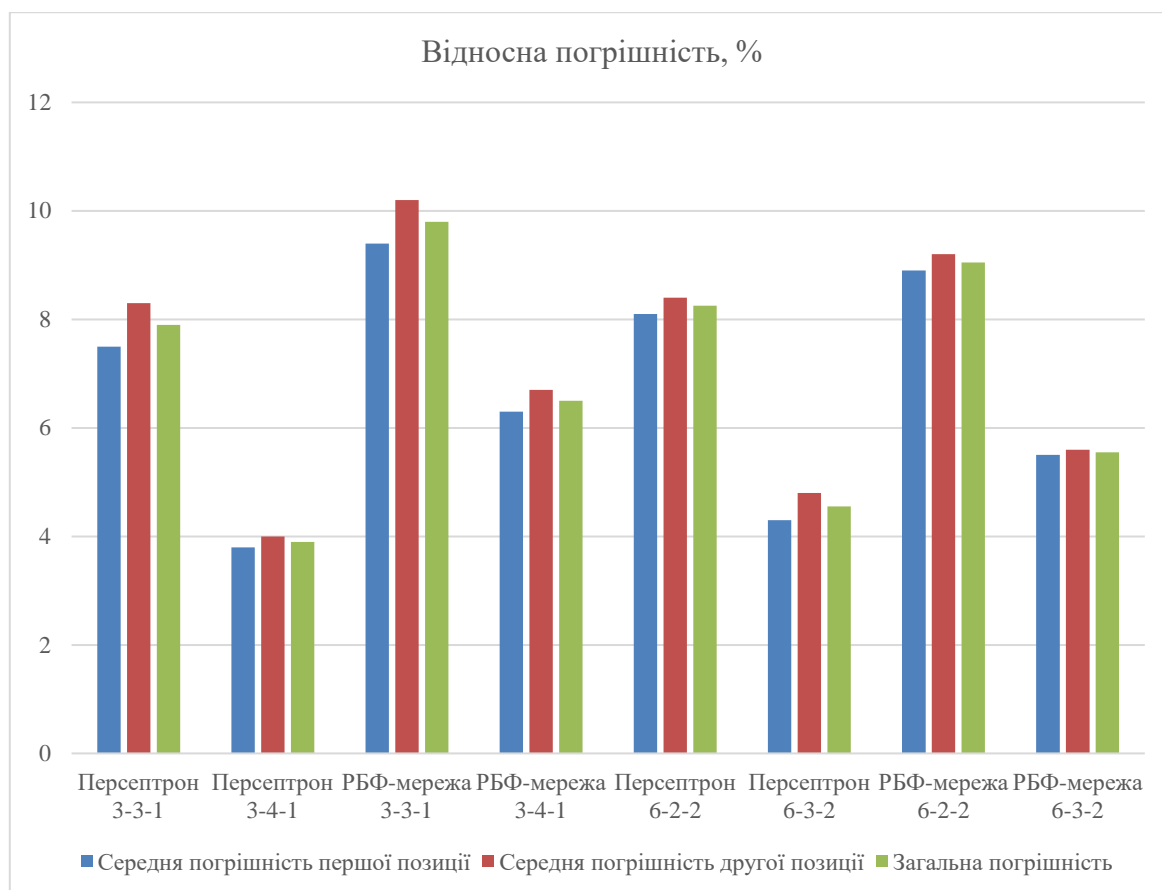
Усі значення округлені до найближчого більшого цілого.

Точність, що досягається, залежить від конкретної задачі. Тому можна спробувати розширити горизонт планування на 2 місяці. Проте для компенсації похибки слід також пропорційно збільшити порядок моделі. Тоді кількість входів нейромережі складе 6, а виходів – 2. Кількість навчальних прикладів при цьому скоротиться до 27.

Підставляючи нові параметри у формули (2) і (3), отримано наступні результати:  $N_{wmin} = 10$ ,  $N_{wmax} = 101$ ;  $N_{nmin} = 2$ ,  $N_{nmax} = 13$ .

Для визначення оптимальної архітектури нейромережі було побудовано низку персептронів і РБФ-мереж для досягнення прийнятної похибки (5 %). При цьому підбор кількості скритих нейронів починався з мінімальних значень, тобто використовувався конструктивний підхід.

На рис. 1 показана гистограма відносної погрішності тестування нейронних мереж.



*Рисунок 1 – Гістограма відносної погрішності тестування нейронних мереж*

Як видно з рисунка, персептрон з 4 скритими нейронами задовольняє рівню похибки у 5 % і при цьому має найменшу кількість нейронів.

**Висновок.** Таким чином, за результатами теоретичних та експериментальних досліджень різноманітних парадигм та архітектур нейронних мереж, для реалізації інформаційної системи оцінювання показників металургійного виробництва доцільно використовувати персептрон з архітектурою 3-4-1.

#### *Список літератури*

1. Руденко О.Г. Штучні нейронні мережі: [навч. посіб.] / О. Г. Руденко, Є.В. Бодянський. – Харків : Компанія СМІТ, 2006. – 404 с.
2. Кизим Н.А. Нейронные сети: теория и практика применения / Н. А. Кизим, Е. Н. Ястремская, В. Ф. Сенчуков. – Монография. – Х.: ИД «ИНЖЭК», 2016. – 240 с.
3. Wong F. S. Time series forecasting using backpropagation neural networks / Wong F. S. // *Neurocomputing*. – 1990/91. – Vol. 2. – P. 147–159.
4. Widrow B. 30 years of adaptive neural networks: perceptron, madaline and backpropagation / Widrow B., Lehr M. A. // *Proceedings of the IEEE*. –1990. – Vol. 78, №. 9. – P. 1415–1442.