

*В.П. КАЛІНЧИК, В.А. ПОБІГАЙЛО, В.В. КАЛІНЧИК, О.В. БОРИЧЕНКО, О.В. МЕЙТА*

## ЗАСТОСУВАННЯ НЕЙРОННИХ МЕРЕЖ ДЛЯ ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНОГО НАВАНТАЖЕННЯ

В роботі показано, що оперативне управління режимом електроспоживання зводиться до рішення задачі оперативного прогнозування навантаження підприємства. Проаналізовані роботи, присвячені питанням прогнозування електричних навантажень енергосистем і промислових підприємств. Показано, що для досягнення необхідної точності прогнозу доцільно використовувати адаптивні процедури прогнозування і зокрема прогнозування є застосування штучних нейронних мереж. Використання штучних нейронних мереж для прогнозування навантаження промислових підприємств обумовлено їх властивостями, такими як здатністю до навчання, надійністю при неповній вхідній інформації, швидким відгуком вивченої мережі на вхідні впливи. Розглянуті умови визначення конфігурації нейронної мережі. Представлена структура нейронної мережі для прогнозування електричного навантаження промислового підприємства. Приведений процес навчання штучної нейронної мережі з підгонкою моделі до даних з ретроспективної вибірки. Розглянуті моделі добового прогнозування навантаження були досліджені на ретроспективних даних про режими електроспоживання хімічного підприємства з нормуванням вхідних даних. Приведені графіки фактичного сумарного навантаження і прогнозу, отримані за моделями штучної нейронної мережі. Дослідження показали, що застосування штучної нейронної мережі дозволяє проводити якісний прогноз навантаження підприємства при нормальних режимах функціонування обладнання.

**Ключові слова:** електричне навантаження, прогнозування, адаптивні методи, штучні нейронні мережі.

*V.P. KALINCHUK, V.A. POBIGAYLO, V.V. KALINCHUK, O.V. BORYCHENKO, O.V. MEITA*

## APPLICATION OF NEURAL NETWORKS FOR PREDICTING ELECTRIC LOAD

The paper shows that the operational management of the power consumption regime is reduced to solving the problem of operational forecasting of the enterprise's load. The paper analyzes the works devoted to the forecasting of electric loads of power systems and industrial enterprises. It is shown that in order to achieve the required forecast accuracy, it is advisable to use adaptive forecasting procedures and, in particular, to use artificial neural networks. The use of artificial neural networks for forecasting the load of industrial enterprises is due to their properties, such as the ability to learn, reliability with incomplete input information, and the rapid response of the learned network to input influences. The conditions for determining the configuration of a neural network are considered. The structure of a neural network for predicting the electrical load of an industrial enterprise is presented. The process of training an artificial neural network with fitting the model to data from a retrospective sample is presented. The considered models of daily load forecasting were investigated on retrospective data on the modes of electricity consumption of a chemical enterprise with normalization of input data. The graphs of the actual total load and the forecast obtained by the artificial neural network models are presented. The research has shown that the use of an artificial neural network allows for a qualitative forecast of the enterprise's load under normal operating conditions of the equipment.

**Keywords:** electric load, forecasting, adaptive methods, artificial neural networks.

**Вступ.** Оперативне управління режимом електроспоживання зводиться до рішення задачі оперативного прогнозування навантаження підприємства. В галузі розробки методів прогнозування випадкових процесів проведені значні дослідження. У вітчизняній та іноземній літературі є значний обсяг робіт, присвячених питанням прогнозування електричних навантажень енергосистем і промислових підприємств. В аналізованих літературних джерелах використовуються численні математичні методи прогнозування.

При прогнозуванні електричного навантаження енергосистеми використовуються статистичні методи з використанням лінійної множинної регресії, фільтри Калмана з урахуванням кореляції між шумами в моделі, метод спектрального аналізу, метод рухомої середньої, метод Бокса-Дженкінса [1].

Значна частина робіт присвячена застосуванню методу експоненціального згладжування [2-5]. Для досягнення необхідної точності прогнозу в умовах випадкової зміни величини навантаження доцільно використовувати адаптивні процедури прогнозування. Одним із методів адаптації процедури прогнозування є застосування штучних нейронних мереж (ШНМ) [6].

**Метою роботи** є дослідження методів прогнозування електричного навантаження побудованих принципів нейронних мереж різних типів.

**Викладення основного матеріалу.** Використання штучних нейронних мереж для прогнозування

навантаження промислових підприємств обумовлено їх властивостями:

- здатністю до навчання;
- надійністю при неповній вхідній інформації;
- стійкістю до завад;
- швидким відгуком вивченої мережі на вхідні впливи;
- можливістю моделювання на персональних комп'ютерах;
- відсутністю моделі.

При визначенні конфігурації нейронної мережі особлива увага приділяється її розмірності. Це зумовлено тим, що при великій розмірності навчання мережі займає багато часу, а при недостатній – мережа погано навчається і при функціонуванні видає не точні результати.

В основу визначення розмірностей вхідного і вихідного слоїв нейронної мережі були покладені наступні умови:

- у вхідному шарі мережі кількість елементів повинна відповідати довжині передісторії  $k$ , що використовується для прогнозу навантаження;
- вихідний шар повинен містити один елемент, який визначає прогнозоване значення навантаження  $P_{пр}$ .

Кількість проміжних слоїв і кількість елементів у них вибираються таким чином, щоб для різних наборів реалізацій електричного навантаження досягався мінімум критеріїв:

- максимальної відносної помилки прогнозу ( $\delta_{max}$ );
- часове навчання нейронної мережі ( $t_{об}$ ).

При цьому було встановлено, що достатньо одного схованого шару з числом елементів, рівним  $n_H = \lceil (n_X + n_Y) / 2 \rceil$ , де  $n_H$  - кількість елементів в схованому шарі мережі;  $n_X, n_Y$  - кількість елементів у вхідному і вихідному шарах нейронної мережі.


Таким чином, конфігурація мережі для прогнозування навантаження підприємства на один інтервал упередження ( $r = 1$ ) повинна представляти собою тришаровий перцептрон, у вхідному шарі якого знаходиться 4 нейрони, в схованому – 3, а у вихідному – 1 нейрон.

Для прогнозування на установлені в ході дослідження два інтервали випередження ( $r = 2$ ) штучна нейронна мережа повинна мати у вхідному шарі 10 нейронів, в скритому – 6, а у вихідному шарі – 1 нейрон.

Дослідження показали, що для здійснення більш точного прогнозу з допомогою штучної нейронної мережі необхідно 6 точок передісторії при одному інтервалі попередження і 13 точок при двох інтервалах. Тому, виходячи з умов прогнозування (довжини інтервалу попередження), вибирається штучна нейронна мережа з найбільш підходящою структурою:

- 6-4-1 – для прогнозу на один інтервал попередження;
- 13-7-1 – для прогнозу на два і більше інтервали попередження.

На рис. 1 представлена структура нейронної мережі для прогнозування електричного навантаження промислового підприємства.



$P_1, \dots, P_k$  - вхідні і  $P_{np}$  - вихідний сигнали мережі;  $w_{ij}^1, w_{ij}^2$  - вагові коефіцієнти ліній, які зв'язують елементи першого і другого, другого і третього шарів мережі;  $i, j$  - номери елементів в шарах, що зв'язуються лініями

Рис. 1. Структура нейронної мережі для прогнозування електричного навантаження

Точність прогнозування навантаження в суттєвому ступені залежить від навчальної вибірки. Дослідження показали, що для отримання задовільних по точності результатів досить тижневої ретроспективної вибірки по навантаженнях.

Нейронна мережа налаштовується шляхом навчання з учителем, тому ретроспективна вибірка повинна складатися з послідовності навчаючих пар

образів  $(P^j(t), D^j(t))$ , де  $P^j(t) = (P_1^j, \dots, P_k^j)$  - вхідний вектор сигналів, а  $D^j(t)$  - скаляр, що визначає бажане прогнозне значення сигналу (навантаження  $P_{np}$ ) для  $P^j(t), j = 1, 2, \dots, R$  ( $R$  - довжина вибірки).

При побудові вхідного вектора  $P^j(t)$  ретроспективної вибірки реалізації електричних навантажень розбиваються за часом так, щоб

$$P^j(t) = P^q(t), P_2^j = P^q(t + \Delta t), P_3^j = P^q(t + 2\Delta t), \dots, P_k^j = P^q(t + (k - 1)\Delta t), \quad (1)$$

де  $P^q$  -  $q$ -та реалізація електричного навантаження ( $q = 1, \dots, 7$ )

Бажане значення  $D^j(t)$  на виході нейронної мережі для  $j$ -го вхідного вектору сигналів  $P^j(t)$  визначається співвідношенням

$$D^j(t) = P^q(t + (k - 1)\Delta t + t^*), \quad (2)$$

де  $t^*$  - час прогнозу.

Таким чином, ретроспективна вибірка представляє собою набір відповідностей

$$\forall q \in [1, 7] (P^j(t) \rightarrow D^j(t)), j = 1, \dots, R. \quad (3)$$

У зв'язку зі зміною умов споживання підприємством електроенергії параметри моделі прогнозування вимагають періодичної адаптації, яка здійснюється по закінченню кожної доби і супроводжується процедурою перенавчання нейронної мережі на нових даних.

Процес навчання ШНМ є підгонкою моделі до даних з ретроспективної вибірки [7-9]. У процесі навчання відбувається настройка вагових коефіцієнтів  $W$  таким чином, щоб виходи мережі були якомога ближче до заданих образів для кожної навчальної пари. При навчанні ШНМ на вхід мережі подається деякий тренувальний вектор вхідних сигналів, а значення вагових коефіцієнтів варіюються до тих пір, доки мережа не навчиться відобразити набір тренувальних вхідних в набір бажаних – вихідних векторів.

Якість роботи ШНМ оцінюється співвідношенням

$$E = \sum_{i=1}^R E^j; E^j = (D^j - P_{\phi}^j)^2, \quad (4)$$

де  $E$  - помилка навчання, а  $D^j$  і  $P_{\phi}^j$  -  $j$ -те значення бажаного і фактичного виходів мережі.

Процес навчання вважається закінченим, якщо помилка  $E$  для всіх сукупностей вхідних сигналів не перевищує заданого значення  $\varepsilon \geq 0$ , або при реалізації раніше встановленої кількості ітерацій.

Для навчання ШНМ використовувався алгоритм зворотного розповсюдження помилки, заснований на методі градієнтного спуску.

Налаштування вагових коефіцієнтів за даним методом здійснювалась виходячи з виразу

$$\Delta w_{ij}^{(n)} = -\eta \frac{\partial E}{\partial w_{ij}}, \quad (5)$$

де  $w_{ij}$  - ваговий коефіцієнт синаптичного зв'язку, що з'єднує  $i$ -й нейрон шару  $n - 1$  з  $j$ -м нейроном шару;  $\eta$  - коефіцієнт швидкості навчання,  $0 < \eta < 1$ .

Алгоритм навчання ШНМ за методом зворотного розповсюдження помилки полягає в наступному:

1. Ініціалізуються вагові коефіцієнти мережі невеликими випадковими значеннями.
2. Із вибірки, що навчає на входи мережі подається  $j$ -й тренувальний набір, який розповсюджується на вихід.

3. Вираховується помилка для вхідного шару мережі

$$\delta_1^{(N)} = (y_1^{(N)} - d_1) \frac{dy_1}{ds_1}, \quad (6)$$

де 1 – номер елементу вихідного шару  $N$  нейромережі,  $y_1$  - реальний вихідний стан нейрона 1 шару  $N$  (фактичне значення навантаження  $P_\phi$ , отримане на виході мережі в процесі навчання),  $d_1$  - бажаний вихідний стан нейрону 1 шару  $N$ ,  $s_1$  - зважена сума вхідних сигналів 1-го нейрону вихідного шару.

4. Вираховуються помилки попередніх шарів шляхом зворотного розповсюдження помилок

$$\delta_j^{(n)} = \left[ \sum \delta_k^{(n+1)} w_{jk}^{(n+1)} \right] \cdot \frac{dy_j}{ds_j}, \quad n = (N - 1), \dots, 1. \quad (7)$$

Тут підсумовування по  $k$  виконується серед нейронів шару.

5. Змінюються вагові коефіцієнти нейромережі

$$\Delta w_{ij}^{(n)} = -\eta \delta_j^{(n)} y_i^{(n-1)}. \quad (8)$$

6. Повторення кроків 2-5 для наступного тренувального набору, доки помилка вихідного шару не стане менше заданої межі або не буде виконано установлену кількість ітерацій.

Підвищення ефективності роботи алгоритму було досягнуто за рахунок:

- зміни порядку спостережень у навчальних вибірках різних ітерацій;
- варіація швидкості навчання;
- визначення числа ітерацій алгоритму, необхідних для прийнятної за точністю навчання.

Використання нейронної мережі, навченої за даним методом покращує процедуру прогнозування:

- ШНМ дозволила отримати результати прогнозу з найменшою максимальною  $\delta_{max}$ ;
- невеликий час навчання мережі дозволив оперативно перенавчити її після коригування.

Не дивлячись на те, що метод зворотного розповсюдження помилок є широко розповсюдженим методом для навчання багатшарових нейронних мереж, він містить головний недолік – погано справляється з локальними мінімумами [7-10]. Це може призвести до нестабільності в роботі нейромережі.

Вихід з «ям» локальних мінімумів заснований на застосуванні статистичних методів навчання – машини Больцмана і машини Коші [11], які виконують випадкові перетворення вагових параметрів ШНМ. Дані методи не можуть бути використані в якості методів оперативного прогнозування навантаження підприємства через повільну збіжність, оскільки багато кроків при їх реалізації виконуються в неправильному напрямку.

Об'єднання статистичного методу Коші, що має більш швидку збіжність, ніж метод Больцмана, з градієнтним спуском зворотного поширення дозволяє отримати систему, яка знаходить глобальний мінімум, зберігаючи високу швидкість зворотного поширення.

Корекція ваг в отриманому комбінованому алгоритмі складається з двох компонент:

- спрямованої компоненти, обчисленої з використанням алгоритму зворотного поширення;

- випадкової компоненти, що визначається розподілом Коші [11].

Ці компоненти обчислюються для кожної ваги і їх сума є величиною, на яку змінюється вага.

Аналогічно алгоритму Коші, після обчислення зміни ваги обчислюється цільова функція. Якщо має місце поліпшення, то зміна зберігається.

Корекція вагового коефіцієнта нейромережі виробляється, виходячи з виразу

$$w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \alpha \cdot \Delta w_{ij}^{(n)}(t) + (1 - \alpha) \cdot x_c^{(n)}(t), \quad (9)$$

де  $w_{ij}^{(n)}(t)$  - ваговий коефіцієнт синаптичного зв'язку, що з'єднує  $i$ -й нейрон шару  $n-1$  з  $j$ -м нейроном шару  $n$  на кроці  $t$ ;  $w_{ij}^{(n)}(t-1)$  - ваговий коефіцієнт синаптичної карти на попередньому  $(t-1)$ -му кроці;  $\Delta w_{ij}^{(n)}(t)$  - корекція вагового коефіцієнту, вирахована за методом зворотного розповсюдження помилок;  $x_c^{(n)}(t)$  - корекція вагового коефіцієнта, вирахованого за методом Коші;  $\alpha$  - коефіцієнт, що управляє компонентами Коші і зворотного розповсюдження. Якщо  $\alpha = 0$ , то система стає повністю машиною Коші. При  $\alpha = 1$  система стає машиною зворотного функціонування.

Обчислення корекції вагового коефіцієнта нейронної мережі за методом зворотного поширення помилки представлено формулами (5) - (8).

Знаходження коефіцієнта корекції за методом Коші складається з наступних кроків:

1. Надати змінній  $T$ , що представляє штучну температуру, велике початкове значення.
2. Пред'явити мережі множини входів і обчислити виходи і цільову функцію.
3. Надати виконання довільного збільшення ваги і перерахувати вихід мережі і зміну цільової функції  $E$  у відповідності зі зробленою зміною ваги.
4. Якщо цільова функція  $E$  зменшилася (покращилася), то зберегти зміну ваги.

Якщо зміна ваги призводить до збільшення цільової функції, то імовірність збереження цієї зміни обчислюється за допомогою розподілу Больцмана

$$P(\Delta E) = e^{(-\Delta E/T)},$$

де  $P(\Delta E)$  - ймовірність зміни цільової функції;  $T$  - штучна температура.

Обирається випадкове значення  $r$  із рівномірного розподілу заданого на інтервалі  $(0, 1)$ . Якщо  $P(c)$  більше ніж  $r$ , то зміна зберігається, в іншому випадку величина ваги зберігається рівною попередньому значенню.

Це дозволяє робити випадковий крок у напрямку, що погіршує цільову функцію, дозволяючи їй «вириватися» з локальних мінімумів.

В процесі навчання послідовно повторюється виконання кроків 3-4 для кожної із ваг мережі, поступово зменшуючи температуру  $T$ , поки не буде досягнуто допустиме значення цільової функції. Мережа навчається на всіх векторах навчальної множини, поки цільова функція не стане допустимою, або поки вона не буде змінюватися на досить малу величину.

Величина випадкової зміни ваги на кроці 3 визначається виходячи з розподілу Коші  $P(x) = \frac{T(t)}{T(t)^2 + x^2}$ , де  $P(x)$  - ймовірність кроку величини  $x$  і визначається виразом

$$x_c = T(t)tg(P(x)), \quad (10)$$

де  $x_c$  - зміна ваги.

Для знаходження  $x$  обирається число із рівномірного розподілу на інтервалі  $(-\pi/2; \pi/2)$ . Це число підставляється у формулу (10), і за допомогою поточної температури обчислюється величина кроку.

В ході навчання за методом Коші швидкість зменшення температури обернено пропорційна лінійній величині  $T(t) = T_0/(1 + t)$ . Це різко зменшує час навчання.

На рис. 2 представлено структурну схему навчання штучної нейронної мережі.

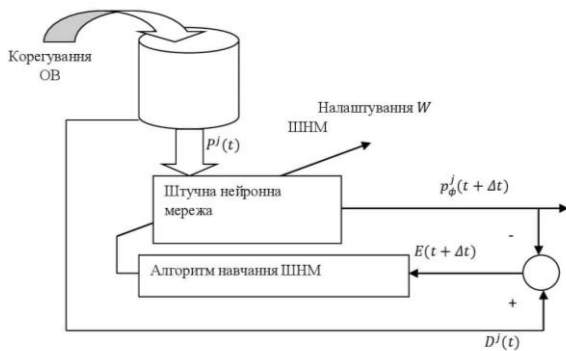


Рис. 2. Схема навчання нейронної мережі

Нормування даних. При подачі на входи ШНМ ненормованих даних може мати місце ефект насичення, коли елемент мережі виявляється чутливим лише до вхідних значень, що лежать в обмеженій області. Це приводить до неправильної роботи мережі.

Нормування виконано за наступною формулою, що приводить дані, які подаються на вхід ШНМ, до інтервалу  $[0,1]$

$$P_i^H = (P_i - P_{min}) / (P_{max} - P_{min}),$$

де  $P_{min}$  і  $P_{max}$  - мінімальне й максимальне значення навантаження в вибірці, що розглядається;  $P_i$  і  $P_i^H$  ненормоване і нормоване значення навантажень, що подаються на  $i$ -й вхід мережі.

Функція активації. Поведінка нейронної мережі залежить як від значень вагових коефіцієнтів, так і від виду функції активації, яка є функцією передачі, перетворюючої вхідний сигнал нейрона у вихідний.

Для прогнозування електричного навантаження в якості активаційної функції обрана сигмоїдальна функція, що має безперервні похідні, необхідні для роботи алгоритму зворотного поширення помилки, і більша схожість з реальними нейронами, ніж, наприклад, широко використовувані лінійні або порогові функції [12].

Сигмоїдальна функція для  $i$ -го нейрону представляється співвідношенням

$$\sigma(s_i) = \frac{1}{1 + e^{-s_i}},$$

де  $s_i$  - сумарний зважений вхід  $i$ -го нейрону.

В деяких випадках ШНМ може при навчанні потрапити в такий стан, коли модифікація ваг не приводить до дійсних змін мережі. Така ситуація ("параліч" мережі) може збільшити час її навчання на декілька порядків.

"Параліч" мережі виникає, коли значна частина нейронів отримує чималі ваги. Це призводить до того, що величини виходів таких нейронів наближаються до своєї межі, а їх похідні - до нуля. Оскільки алгоритм зворотного розповсюдження помилки (АЗРП) при обчисленні величин зміни ваг використовує ці похідні, то зміни ваг стають близькими до нуля. Якщо подібні умови виникають у багатьох нейронах мережі, то навчання може сповільнитися аж до повної зупинки.

Для вирішення даної проблеми рекомендується на ваги, що живлять нейрони з граничними значеннями виходів діяти стискаючою функцією (подібною функції активації), яка б сильно зменшувала величини дуже великих ваг і менше впливало б на малі ваги.

Використання стискаючої функції дозволяє вивести нейрони зі стану насичення без порушення, досягнутого в мережі навчання. Наприклад в якості стискаючої функції може використовуватися функція виду  $W_{ij} = \frac{5}{1 + \exp(-w_{ij}/5)}$ , діапазон змін значень якої є інтервал  $(+5, -5)$ .

Навчена на ретроспективних наборах нейронна мережа дозволяє не тільки розрізняти вхідні дані з навчальної вибірки, а і, формуючи свої власні уявлення про них здатна інтерпретувати тенденції зміни в процесі і справлятися з сигналами, відсутніми в навчальній вибірці, класифікуючи їх за накопиченим в процесі навчання знань.

Розглянуті моделі добового прогнозування навантаження були досліджені на ретроспективних даних про режими електроспоживання хімічного підприємства з нормуванням вхідних даних. Результат одного з прогнозів представлений на рис. 3. Видно, що графік навантаження, отриманий за моделлю ННМ, більш близький до графіку фактичного навантаження, ніж графік прогнозу навантаження за моделлю ШНМ. Причому, середньоквадратична похибка прогнозу навантаження для моделі ШНМ становить .

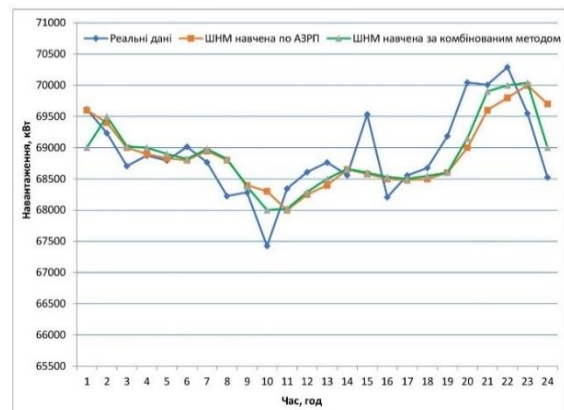


Рис. 3. Графіки фактичного сумарного навантаження і прогнозу, отримані за моделями ШНМ

Дослідження показали, що ШНМ дозволяє проводити якісний прогноз навантаження підприємства при нормальних режимах функціонування обладнання. Відзначається також висока стабільність в роботі нейромереж. При невеликій кількості наборів час навчання мережі збільшується, покращується якість налаштування її параметрів  $W$ , підвищується точність прогнозу навантаження.

В табл. 1 та 2 представлені помилки прогнозів, що виконуються за допомогою ШНМ.

Таблиця 1 – Похибки прогнозу, виконаного за допомогою ШНМ, для процесів зміни навантаження з дискретністю  $\Delta t = 5$  хв і часу упередження  $t^* = \Delta t$

Помилка прогнозу і час навчання ШНМ	$\delta_{max}$	$e, \%$	$t_{навч}, c$
Нейронна мережа навчена по АЗРП	0,934-1,104	0,437-0,537	4-6
Нейронна мережа, навчена за комбінованим методом	0,705-0,951	0,306-0,433	12-25

Прогнозування на один інтервал випередження при  $\Delta t = 5$ , реалізованих за допомогою нейронних мереж, навчених за алгоритмом зворотного розповсюдження похибки і комбінованого методу, не задовольняв необхідної точності  $\delta_{amax}$  при 1-відсотковій глибині вимірювання навантаження. Для мережі навченої за алгоритмом зворотного розповсюдження похибки, гранично допустиме  $\delta_{max}$ , рівне 1,479% установлене при  $\Delta P = 0,7\%$ .

При прогнозуванні на два інтервали випередження граничне значення похибки  $\delta_{max}$  для мережі, навченої за алгоритмом зворотного розповсюдження, визначалось при  $\Delta P = 0,8\%$ . Мережа, навчена за допомогою комбінованого методу, дозволила досягти граничного значення  $\delta_{max}$  при  $\Delta P = 1,3\%$ .

Таблиця 2 – Похибки прогнозу, виконаного за допомогою ШНМ для процесів вимірювання навантаження з дискретністю  $\Delta t = 5$  хв і часу упередження  $t^* = 2\Delta t$

Помилка прогнозу і час навчання ШНМ	$\delta_{max}$	$e, \%$	$t_{навч}, c$
Нейронна мережа навчена по АЗРП	0,627-0,94	0,315-0,451	16-17
Нейронна мережа, навчена за комбінованим методом	0,37-0,51	0,163-0,281	26-54

Нейромережа, навчена по АЗРП і доповнена корекцією прогнозних значень, виконала прогноз при  $\Delta t = 5$  хв і  $t^* = \Delta t$  з максимальною відносною похибкою прогнозування, що не перевищує 1,106% при  $\Delta P = 1\%$  і 2,449% при  $\Delta P = 55\%$ .

Максимальна відносна похибка прогнозу на два інтервали випередження, виконаного за допомогою ШНМ з різними алгоритмами навчання і корекцією прогнозних значень, не перевищувала установленого обмеження  $\delta_{amax}$  за відносною похибкою.

Особливістю хімічних підприємств є досить рівний графік навантаження з незначними випадковими

відхиленнями і похибка прогнозування навантаження на таких підприємствах незначна (часто менше 1%). Проте, застосовуючи деякі коригування вхідних даних та виконуючи підбір нормуючої формули, запропоновані моделі прогнозування можна застосувати і для інших підприємств.

Нейромережа, навчена за алгоритмом зворотного розповсюдження похибки (рис. 2), дозволила виконати прогноз навантаження з похибкою  $\delta_{max}$ , що змінюється в межах (0,945-1,472)% при (1-55)-процентній зміні навантаження  $\Delta P$ . Для нейромережі, навченої за комбінованим методом, максимальна відносна похибка прогнозу приймала значення (0,516-1,135)% для  $\Delta P = (1 - 55)\%$ .

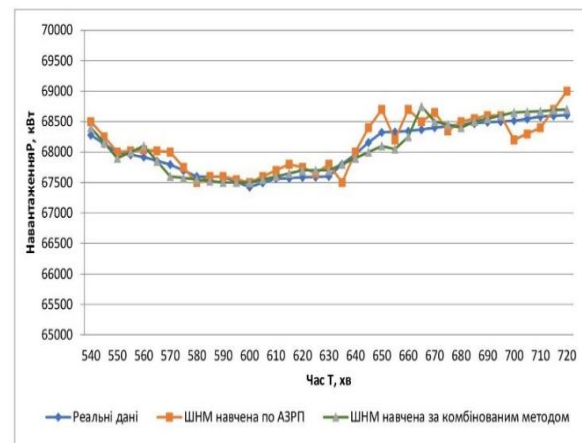


Рис. 4. Результати прогнозу навантаження підприємства, виконаного на основі ШНМ з корекцією прогнозних значень для  $\Delta t = 5$  і  $t^* = 2\Delta t$

На рис. 4 видно, що максимальне значення відносною похибки прогнозування встановлюється в момент виникнення керуючого впливу при  $\Delta P = 5\%$ . Для мережі, навченої за алгоритмом зворотного розповсюдження похибки, він складає  $\delta_{max}$ , а для ШНМ, навченої за комбінованим методом -  $\delta_{max}$ .

Прийняте рішення по зниженню навантаження підприємства зазвичай здійснюється по його прогнозним значенням на два-три інтервали. Тому, як правило, необхідно мати точний прогноз на першому прогнозованому інтервалі.

Враховуючи це рекомендовано використовувати процедуру корегування, починаючи зі значень, що забезпечує необхідну точність прогнозування на другому інтервалі прогнозування.

**Висновок.** Запропоновані адаптивні процедури оперативного прогнозування навантаження для підприємств з безперервною технологією в нормальних умовах їх функціонування і в умовах реалізації керуючих впливів по регулюванню режиму електроспоживання на основі штучних нейронних мереж, що забезпечують точність прогнозу навантаження в межах установлених обмежень.

Розроблений комбінований метод навчання штучних нейронних мереж, що забезпечує прогнозування півгодинного активного навантаження підприємства.

## Список літератури

1. В. П. Калінчик. Застосування статистичних методів прогнозування для планування електроспоживання/ В. П. Калінчик, В. В. Калінчик, Д. О. Мельник, К. А. Василенко/ Матеріали XXVI Міжнародної науково-практичної інтернет - конференції «Проблеми та перспективи розвитку сучасної науки в країнах Європи та Азії» – Переяслав-Хмельницький. – 2020.- С.167-169.
2. Galliana F. D. Identification of stochastic electric load model from physical data / Galliana F. D., Handschin E., Frechter A. R.// IEEE Transaction on Automatic Control. – Vol. Ac – 19. – No. 6. – 1974. – P. 887 -893
3. Gupta P. C. Adaptive short term forecasting of hourly loads using weather information / Gupta P. C., Yamada K., // IEEE Transaction on Power Apparatus and Systems. – Vol. Pas. – 91. - 1972. – P. 2085 – 2094
4. В. П. Калінчик. Адаптивні моделі прогнозування електричного навантаження виробничих споживачів// В. П. Калінчик, О. В. Мейта, В. В. Калінчик, Ю. М. Чуняк// - Енергетика: економіка, технології, екологія. – 2022. - № 1. – С.46-56.
5. В. П. Калінчик. Узагальнена модель адаптивного прогнозування режимів електроспоживання виробничих об'єктів/ В. П. Калінчик, О. В. Мейта, В. А. Побігайло, В. В. Калінчик, О. В. Бориченко, А. М. Копчиков// - Вісник Національного технічного університету «ХПІ». Серія: Проблеми удосконалення електричних машин і апаратів. Теорія і практика. - № 1(9)- 2023.-С.60-62.
6. Калінчик В. П. Застосування нейронних мереж для планування електроспоживання/ Калінчик В.П., Мельник Д.О.// Матеріали XII науково-технічної конференції інституту енергозбереження та енергоменеджменту. «Енергетика. Екологія. Людина» – Київ: ІЕЕ, 2020. – С.116-120.
7. Живогляд О. С. Прогнозування електроспоживання на базі нейронної мережі Живогляд О.С. // - ElectronAcoustEng. – Vol.2, no.1 - 2020. – С. 39-42.
8. Д. М. Карпа. Нейромережеві засоби прогнозування споживання енергоресурсів енергоресурсів / В Д. М. Карпа, І. Г. Цмоць, Ю. В. Опотяк// - Науковий вісник НЛТУ України.- т. 28, № 5 - 2018, С. 140-146.
9. І . В. Калінчик. Оцінка та прогнозування стану систем електроспоживання об'єктів промисловості/ І . В. Калінчик// - Енергетика: економіка, технології, екологія. Спецвипуск. – 2013. С. 41-46.
10. Метод зворотного поширення помилки [Електронний ресурс] – Режим доступу <https://uk.wikipedia.org/wiki/>.
11. Нейронні мережі. STATISTICA Neural Networks: Методологія і технології сучасного аналізу даних / за редакцією В. П. Боровикова. - 2-е вид., перероб. і дод. - Гаряча лінія-Телеком, 2008. - 392 с.
12. Rumelhart D.E., Hinton G.E.,Williams R.j. Learning internal representations by error propagation // Parallel distributed processing, vol. 1. - Cambridge, MA: MIT Press, 1986. P. 318.

## References (transliterated)

1. Kalinchyk V.P., Kalinchyk V.V., Melnyk D.O., Vasylenko K.A. Zastosuvannia statystychnykh metodiv prohnozuvannia dlia planuvannia elektrospozhyvannia. Materialy KhKhVI Mizhnarodnoi naukovopraktychnoi internet - konferentsii «Problemy ta perspektivy rozvytku suchasnoi nauky v krainakh Yevropy ta Azii». Pereiaslav-Khmelnitskyi. 2020. Pp.167-169.
2. Galliana F.D., Handschin E., Frechter A. R. Identification of stochastic electric load model from physical data. IEEE Transaction on Automatic Control. Vol. Ac-19. No. 6. 1974. P. 887 -893
3. Gupta P. C., Yamada K. Adaptive short term forecasting of hourly loads using weather information. IEEE Transaction on Power Apparatus and Systems. Vol. Pas. 91. 1972. P. 2085 – 2094
4. Kalinchyk V.P., Meita O.V., Kalinchyk V.V., Chuniak Yu.M. Adaptivni modeli prohnozuvannia elektrychnoho navantazhennia vyrobnychkh spozhyvachiv. Enerhetyka: ekonomika, tekhnologii, ekolohiia. 2022. No 1. Pp.46-56.
5. Kalinchyk V.P., Meita O.V., Pobihailo V.A., Kalinchyk V.V., Borychenko O.V., Kopchikov A.M. Uzaalнена model adaptivnoho prohnozuvannia rezhymiv elektrospozhyvannia vyrobnychkh ob'ektiv. Visnyk Natsionalnoho tekhnichnoho universytetu «KhPI». Seria: Problemy udoskonaliuvannia elektrychnykh mashyn i aparativ. Teoriia i praktyka. No 1(9). 2023. Pp. 60-62.
6. Kalinchyk V.P., Melnyk D.O. Zastosuvannia neuronnykh merezh dlia planuvannia elektrospozhyvannia. Materialy KhII naukovotekhnichnoi konferentsii instytutu enerhozberezhennia ta enerhomenedzhmentu. «Enerhetyka. Ekolohiia. Liudyna». Kyiv: IEE, 2020. Pp.116-120.
7. Zhyvohliad O.S. Prohnozuvannia elektrospozhyvannia na bazi neuronnoi merezhi. ElectronAcoustEng. Vol. 2, No. 1. 2020. Pp. 39-42.
8. D. M. Karpa, I. H. Tsmots, Yu. V. Optiak. Neiomerezhevi zasoby prohnozuvannia spozhyvannia enerhoressursiv enerhoressursiv. Naukovyi visnyk NLTU Ukrainy. T. 28, No 5. 2018, Pp. 140-146.
9. I.V. Kalinchyk. Otsinka ta prohnozuvannia stanu system elektrospozhyvannia ob'ektiv promyslovosti. Enerhetyka: ekonomika, tekhnologii, ekolohiia. Spetsvypusk. 2013. Pp. 41-46.
10. Metod zворотnoho poshyrennia pomylky [Elektronnyi resurs] – Rezhym dostupu <https://uk.wikipedia.org/wiki/>.
11. Neironni merezhi. STATISTICA Neural Networks: Metodolohiia i tekhnologii suchasnoho analizu danykh. Za redaktsieiu V.P. Borovykova. 2-e vyd., pererob. i dod. Hariacha liniia-Telekom, 2008. 392 p.
12. Rumelhart D.E., Hinton G.E.,Williams R.j. Learning internal representations by error propagation. Parallel distributed processing, vol. 1. Cambridge, MA: MIT Press, 1986. 318 p.

Надійшла (received) 30.03.2024

## Відомості про авторів / About the authors

**Калінчик Василь Прокопович (Kalinchik Vasyl Prokopovich)** – кандидат технічних наук, доцент, Національний технічний університет України КПІ ім. Ігоря Сікорського, доцент кафедри електропостачання; м. Київ; ORCID: <https://orcid.org/0000-0003-4028-0185>.

**Побігайло Віталій Анатолійович (Pobigaylo Vitalii Anatolievich)** – кандидат технічних наук, доцент, Національний технічний університет України КПІ ім. Ігоря Сікорського, доцент кафедри електропостачання; м. Київ; ORCID: <https://orcid.org/0000-0003-2673-7329>.

**Калінчик Віталій Васильович (Kalinchik Vitalii Vasyllovich)** – кандидат технічних наук, Національний технічний університет України КПІ ім. Ігоря Сікорського, старший викладач кафедри охорони праці та промислової та цивільно безпеки; м. Київ; ORCID: <https://orcid.org/0000-0003-3931-646X>.

**Бориченко Олена Володимирівна (Borychenko Olena Volodymyrivna)** кандидат технічних наук, доцент, Національний технічний університет України КПІ ім. Ігоря Сікорського, доцент кафедри електропостачання; м. Київ; ORCID: <https://orcid.org/0000-0002-6127-2945>.

**Мейта Олександр Вячеславович (Meita Aleksandr Vyacheslavovich)** – кандидат технічних наук, доцент, доцент кафедри автоматизації електромеханічних та мехатронних комплексів, Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського» м. Київ; ORCID: <https://orcid.org/0000-0002-4132-5202>.