

УДК 004.93

**С. О. Субботін<sup>1</sup>, О. В. Корнієнко<sup>1</sup>, І. В. Дрокін<sup>2</sup>**

<sup>1</sup>Запорізький національний технічний університет  
вул. Жуковського, 64, 69063 Запоріжжя, Україна

<sup>2</sup>Акціонерне товариство «Мотор Січ»  
Проспект Моторобудівників, 15, 69068 Запоріжжя, Україна

## **Прогнозування частоти неперіодичних сигналів на основі згорткових нейронних мереж**

*Вирішено завдання створення математичного забезпечення для побудови прогнозних моделей на основі згорткових нейронних мереж. Запропоновано метод використання згорткових нейронних мереж для прогнозування частоти неперіодичних сигналів. Вирішено практичне завдання прогнозування частоти вібрацій авіаційних двигунів при проведенні їхніх випробувань. Виконано побудову нейромережеских моделей, їхнє навчання та тестування на даних, які було зібрано з датчиків вібрацій при проведенні випробувань авіадвигуна. Порівняно результати тестування всіх побудованих моделей.*

**Ключові слова:** прогнозування, сигнал, навчання, нейронна мережа, згортка, помилка, градієнт.

### **Вступ**

Під час роботи авіаційних двигунів виникають вібрації, збільшення частоти яких до критичного рівня може свідчити про несправність двигуна, а також негативно впливає на його працездатність.

Тому актуальною проблемою є прогнозування значень частот вібрацій об'єкта діагностування через певний час. Для цього необхідно побудувати прогнозні моделі, що використовуватимуть дані з датчиків вібрацій у поточний і кілька попередніх моментів часу, та дозволять визначити наявність критичних вібрацій у майбутньому, що, у свою чергу, дасть можливість в умовах польоту пілотові зреагувати та не допустити авіакатастрофи, а в наземних умовах своєчасно вжити профілактичних заходів (виконати повне діагностування та ремонт авіадвигуна).

Одним із перспективних засобів побудови прогнозних моделей є нейронні мережі, які здатні під час навчання за рахунок узагальнення видобувати знання з даних [1]. На відміну від відомих методів цифрової обробки та прогнозування сигналів [2, 3], нейронні мережі можуть ефективно використовуватися при невідомих аналітичних залежностях між вхідними та вихідними ознаками, обмеженому на-

борі експериментальних спостережень, за наявності похибок вимірювання у даних, в умовах наявності багатовимірних, нелінійних, розподілених у часі залежностей. Також нейронні мережі є більш стійкими до шумів у вхідних даних. Тому їх доцільно обрати як базис для побудови прогнозних моделей. Відомо багато різних архітектур нейронних мереж і методів їхнього навчання [1, 4, 5]. Серед них слід виділити згорткові нейронні мережі, що враховують взаємне розташування даних у вхідних сигналах [6], і завдяки цьому мають кращі узагальнювальні властивості. Тому для побудови прогнозних моделей доцільно обрати згорткові нейронні мережі. Навчання таких нейромереж, як правило, здійснюється на основі градієнтних методів і техніки зворотного поширення помилки мережі [7].

**Метою роботи** є побудова нейромережевої моделі для прогнозування частоти вібрацій.

### Постановка задачі

Одним із видів авіатехніки, для яких прогнозування вібрацій є критичним, є гелікоптери. На АТ «Мотор Січ» випробувальним центром для гелікоптера було зібрано дані з 15 датчиків вібрацій з частотою опитування 7200 Гц. Графік фрагменту вібросигналу для одного з датчиків зображено на рис. 1.




Рис. 1. Зразок фрагменту вхідних даних

За набором спостережень потрібно побудувати нейромережеву модель, за допомогою якої можна буде прогнозувати частоту вібрацій через деякий час. Зазначимо, що при цьому важливо знати не стільки значення самої частоти, скільки встановити факт наявності вібрацій з частотою, вище заданої критичної частоти. Мінімальний час прогнозування, при якому використання моделі є доцільним, складає близько 10 хвилин — це час, за який пілот може зреагувати та змінити режим польоту або посадити гелікоптер.

### Формування вибірки даних

Фрагмент використаних даних реальних випробувань є обмеженим за часом. Тому для оцінювання працездатності методів прогнозування було застосовано аугментацію [8]. Для цього кожен сигнал було скопійовано 10 разів, після чого збільшено частоту деяких фрагментів сигналу. На рис. 2 зображено графік частоти сигналу після аугментації.

На рис. 2 показано, наскільки збільшено частоту порівняно з початковим сигналом. При цьому частота початкового сигналу постійна. Як критична вважалася частота, що перевищує базову на 20 % і більше.




Рис. 2. Графік масштабування частоти сигналу

У результаті було отримано близько 20 годин даних для кожного датчика. Після цього сигнал було розбито на  $Z = 71237$  послідовних фрагментів довжиною в одну секунду кожний. Для кожного фрагменту сигналу було застосовано швидке перетворення Фур'є [9], щоб визначити частоту сигналу. Далі кожну з отриманих спектрограм було розділено на  $P = 12$  частин, і в кожній частині виділено максимальну амплітуду (рис. 3).



Рис. 3. Приклад спектрограми після перетворення

У результаті отримано  $D \times Z \times P$  значень, де  $D = 15$  — кількість датчиків, за якими побудовано навчальну вибірку, що використовувалася для побудови моделі.

Вхідними параметрами моделі є максимальні значення амплітуд для кожної з  $P$  частин за час  $U$ . Вихідними значеннями є 0 або 1 залежно від наявності вібрацій з частотою, що перевищує критичне значення, на проміжку розміром  $S$  через час  $T$ . На рис. 4 схематично зображено процес створення вибірки. Кожна чарунка на рисунку містить  $D \times P$  значень.  $U$  значень чорних чарунок використовуються як вхідні,  $T$  значень світло-сірих чарунок не використовуються, а за  $S$  значень сірих чарунок визначається вихідне значення для відповідного екземпляра вибірки.



Рис. 4. Схематичне зображення створення вибірки

У результаті отримано  $Z - U - S - T + 1$  екземплярів вибірки, де кожен екземпляр — тривимірний масив з  $U \times D \times P$  значень.

### Синтез моделі на основі згорткової нейронної мережі

Зазвичай згорткові нейронні мережі використовуються для роботи із зображеннями. При цьому кожне зображення розглядається як тривимірний масив, де два виміри визначають ширину та висоту, а третій — кількість каналів залежно від колірної моделі (наприклад, 3 для RGB) [10]. Дані, що було отримано у попередньому розділі, так само являють собою тривимірні масиви, що можуть бути оброблені згортковою нейронною мережею.

Згорткова нейронна мережа складається із шарів згортки, субдискретизації і повнозв'язних шарів. Приклад операції згортки зображено на рис. 5. Шари субдискретизації зменшують розміри вхідних карт ознак шляхом вибору максимального або середнього значення з деякої області [10]. Повнозв'язні шари працюють так само, як в багатошаровому персептроні [11].

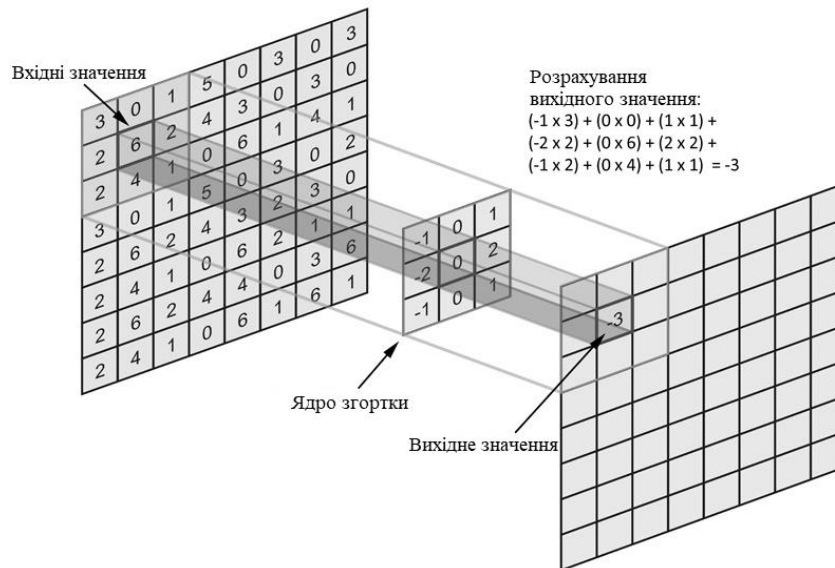


Рис. 5. Операція згортки

Навчання нейромережі пропонується проводити на основі градієнтного методу [12] та техніки зворотного поширення помилки [7]. У процесі навчання мінімізується функція помилки мережі  $E$ , яка визначає різницю між виходами мережі та реальними значеннями. Як функцію помилки доцільно використовувати середньоквадратичну помилку  $E$ , що обчислюється за формулою

$$E = \sqrt{\sum_{i=1}^N (R_i - M_i)^2},$$

де  $R_i$  — реальне значення вихідного параметра  $y_i$ ;  $M_i$  — розрахункове значення параметра  $y_i$ , що отримане за допомогою моделі,  $i = 1, \dots, Y$ ,  $Y$  — кількість вихідних параметрів моделі.

Метод навчання мережі полягає у послідовному виконанні таких етапів.

*Етап ініціалізації.* Задати навчальну вибірку даних  $\langle x, y \rangle$  та структуру нейромережі. Ваговим коефіцієнтам нейронів (включаючи коефіцієнти для ядер згортки) задати випадкові значення з діапазону  $[-0,1; 0,1]$ . Задати: кількість циклів (епох) навчання  $Epochs = 0$ , максимальну кількість циклів (епох) навчання  $MaxEpochs$ , крок навчання  $\alpha$ .

*Етап корекції ваг.* Послідовно у циклі для  $Epochs = 0, 1, \dots, MaxEpochs$ , де  $MaxEpochs$  — максимально допустима задана кількість епох навчання, виконується навчання мережі на основі екземплярів вибірки шляхом виконання етапу навчання мережі на основі екземпляра та коректується крок навчання  $\alpha$ .

*Етап навчання мережі на основі екземплярів вибірки* [10]. Послідовно на входи нейромережі подається  $i$ -й екземпляр навчальної вибірки,  $i = 1, 2, \dots, S_{tr}$ , де  $S_{tr}$  — кількість екземплярів навчальної вибірки. Для поточного екземпляра розраховуються вихідні значення нейронної мережі.

Вихідні значення згорткових шарів обчислюються за формулою

$$O_{i,j,l} = \psi \left( \sum_{h=0}^H \sum_{m=0}^M \sum_{n=0}^N \sum_{k=0}^K In_{i+m,j+n,k,h} \cdot F_{m,n,k,h,l} + B_{h,l} \right), l = 0, \dots, L, i = 0, \dots, I, j = 0, \dots, J,$$

де  $O$  — вихідні значення;  $In$  — вхідні значення;  $H$  — кількість вхідних карт ознак;  $M$  — ширина ядер згортки;  $N$  — висота ядер згортки;  $K$  — глибина (третій вимір) вхідних карт ознак;  $L$  — кількість вихідних карт ознак,  $I$  — ширина вихідних карт ознак;  $J$  — висота вихідних карт ознак;  $F$  — ядра згортки;  $B$  — зміщення;  $\psi$  — випрямляюча функція активації  $\max(0, x)$ .

Вихідні значення повнозв'язних шарів обчислюються за формулою

$$O_i = \psi \left( \sum_{h=0}^H In_h \cdot w_{i,h} + w_{i,0} \right), i = 0, \dots, I,$$

де  $H$  — кількість входів повнозв'язного шару;  $I$  — кількість вихідних нейронів повнозв'язного шару;  $w = \{w_{i,h}\}$  — вагові коефіцієнти;  $w_{i,h}$  — вага  $h$ -го входу  $i$ -го нейрона повнозв'язного шару;  $\psi$  — функція активації гіперболічний тангенс.

Після цього обчислюється середньоквадратична помилка мережі  $E$ .

Далі обчислюються градієнти помилок нейронів вихідного шару:

$$G_i = (O_i - R_i) \cdot (1 - O_i^2), i = 0, \dots, I,$$

де  $I$  — кількість вихідних нейронів;  $O$  — вихідний вектор нейронної мережі;  $R$  — бажаний вихідний вектор;  $G$  — градієнти помилок вихідного шару.

Якщо як функцію активації  $\psi$  використовувати функцію гіперболічний тангенс

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}},$$

то її похідна після спрощення матиме вигляд  $1 - \text{Tanh}(x)^2$ , а в даному випадку  $O$  — це вже обчислене значення  $\text{Tanh}(x)$ .

Після цього обчислюються градієнти для нейронів повнозв'язних шарів

$$G_i = \sum_{j=0}^J Gr_j \cdot w_{i,j} \cdot (1 - O_i^2), \quad i = 0, \dots, I, \quad j = 0, \dots, J,$$

де  $I$  — кількість нейронів поточного шару;  $J$  — кількість нейронів наступного шару;  $Gr$  — градієнти помилок наступного шару;  $G$  — градієнти помилок поточного шару;  $O$  — вихідний вектор поточного шару;  $w$  — вагові коефіцієнти нейронів наступного шару.

Коли будуть розраховані градієнти повнозв'язних шарів, необхідно розрахувати градієнти для згорткових шарів:

$$G_{i,c,j+a,k+b} = \sum_{m=0}^M \sum_{n=0}^N Gr_{m,n,j,k} \cdot F_{i,c,m,a,b} \cdot (1 - O_{i,c,j+a,k+b}^2),$$

$$i = 0, \dots, I, \quad c = 0, \dots, C, \quad j = 0, \dots, J, \quad a = 0, \dots, A, \quad k = 0, \dots, K, \quad b = 0, \dots, B,$$

де  $I$  — кількість карт ознак поточного шару;  $C$  — глибина карт ознак поточного шару;  $J$  — ширина карт ознак наступного шару;  $A$  — ширина ядер згортки;  $K$  — висота карт ознак наступного шару;  $B$  — висота ядер згортки;  $M$  — кількість карт ознак наступного шару;  $N$  — глибина карт ознак наступного шару;  $Gr$  — градієнти помилок наступного шару;  $G$  — градієнти помилок поточного шару;  $O$  — вихідні карти ознак поточного шару;  $F$  — вагові коефіцієнти нейронів (ядер згортки) наступного шару.

Після розрахування градієнтів необхідно виконати корекцію вагових коефіцієнтів. Для згорткових шарів корекція виконується за формулою

$$F_{i,j,k,m,n} = F_{i,j,k,m,n} - \sum_{v=0}^V \sum_{p=0}^P \sum_{q=0}^Q O_{i,k,p+m,q+n} \cdot G_{j,v,p,q} \cdot \alpha,$$

$$i = 0, \dots, I, \quad j = 0, \dots, J, \quad k = 0, \dots, K, \quad m = 0, \dots, M, \quad n = 0, \dots, N,$$

де  $I$  — кількість карт ознак поточного шару;  $J$  — кількість карт ознак наступного шару;  $K$  — глибина карт ознак поточного шару;  $M$  — ширина ядер згортки;  $N$  — висота ядер згортки;  $V$  — глибина карт ознак наступного шару;  $P$  — ширина карт ознак наступного шару;  $Q$  — висота карт ознак наступного шару;  $G$  — градієнти помилок поточного шару;  $O$  — вихідні карти ознак поточного шару;  $F$  — вагові коефіцієнти нейронів (ядер згортки) поточного шару.

Для повнозв'язних шарів корекція вагових коефіцієнтів виконується за формулою

$$w_{i,j} = w_{i,j} - O_i \cdot G_j \cdot \alpha, \quad i = 0, \dots, I, \quad j = 0, \dots, J,$$

де  $I$  — кількість нейронів поточного шару;  $J$  — кількість нейронів наступного шару;  $G$  — градієнти помилок;  $O$  — вихідний вектор поточного шару;  $w$  — вагові коефіцієнти нейронів поточного шару.

## Експерименти та результати

Для побудови нейромережових моделей було розроблено програмне забезпечення мовою C#, яке дозволяє виконувати побудову згорткових нейронних мереж і їхнє навчання на заданій вибірці даних.

За допомогою розробленого програмного забезпечення було побудовано 5 прогнозних моделей з різними параметрами. При цьому в кожній моделі використовувалася нейронна мережа з такими шарами:

- 1) згортковий шар, кількість ядер згортки — 10;
- 2) шар субдискретизації (розмір —  $3 \times 1$ );
- 3) згортковий шар, кількість ядер згортки — 15;
- 4) шар субдискретизації (розмір —  $2 \times 1$ );
- 5) згортковий шар, кількість ядер згортки — 20;
- 6) шар субдискретизації (розмір —  $2 \times 1$ );
- 7) повнозв'язний шар;
- 8) вихідний шар.

Навчання моделей запускалося декілька разів. Кожного разу змінювалися лише початкові значення вагових коефіцієнтів і швидкість навчання.

У табл. 1 наведено параметри моделей, що використовувалися при проведенні експериментів.

Таблиця 1. Параметри моделей

| Номер моделі | $U$  | $S$ | $T$ | Розмір ядра згортки 1 шару | Розмір ядра згортки 3 шару | Розмір ядра згортки 5 шару | Кількість нейронів прихованого шару |
|--------------|------|-----|-----|----------------------------|----------------------------|----------------------------|-------------------------------------|
| 1            | 600  | 300 | 300 | $10 \times 15 \times 12$   | $8 \times 1 \times 1$      | $6 \times 1 \times 1$      | 50                                  |
| 2            | 900  | 300 | 600 | $13 \times 15 \times 12$   | $7 \times 1 \times 1$      | $6 \times 1 \times 1$      | 100                                 |
| 3            | 1200 | 600 | 600 | $10 \times 15 \times 12$   | $8 \times 1 \times 1$      | $6 \times 1 \times 1$      | 120                                 |
| 4            | 1500 | 600 | 900 | $16 \times 15 \times 12$   | $10 \times 1 \times 1$     | $4 \times 1 \times 1$      | 150                                 |
| 5            | 1800 | 900 | 900 | $10 \times 15 \times 2$    | $8 \times 1 \times 1$      | $6 \times 1 \times 1$      | 150                                 |

У табл. 2 наведено результати тестування побудованих моделей. Тут позначено:  $P_{\text{пом}}$  — оцінка ймовірності прийняття помилкових рішень; Positive — екземпляри, для яких визначено наявність вібрацій; Negative — екземпляри, для яких визначено відсутність вібрацій з частотою вище критичного рівня; True — вірне визначення; False — помилкове визначення. Для всіх моделей показано кращі результати, які було досягнуто під час навчання.

Таблиця 2. Результати тестування

| Номер моделі | True positive | False positive | True negative | False negative | $P_{\text{пом}}$ |
|--------------|---------------|----------------|---------------|----------------|------------------|
| 1            | 37,2 %        | 0,3 %          | 58,9 %        | 3,5 %          | 3,8 %            |
| 2            | 46,4 %        | 0,7 %          | 48,9 %        | 4,0 %          | 4,7 %            |
| 3            | 50,1 %        | 49,2 %         | 0,4 %         | 0,4 %          | 49,6 %           |
| 4            | 0,0 %         | 0,0 %          | 43,5 %        | 56,5 %         | 56,5 %           |
| 5            | 0,0 %         | 0,0 %          | 43,3 %        | 56,7 %         | 56,7 %           |

З табл. 1 та 2 можна зробити висновок, що зі збільшенням значення  $T$  для побудованих моделей зростає відносна частина екземплярів з критичною частотою.

З табл. 2 видно, що в моделях 3–5, які побудовано для проміжку часу понад 5 хвилин, на виході значення мало змінюються, що свідчить про те, що запропо-

нований метод не підходить для прогнозування на великі проміжки часу. Але моделі 1 та 2, які побудовано для прогнозування вібрацій через 5 та 10 хвилин відповідно, показали досить добрі результати.

Результати проведених експериментів дозволяють рекомендувати розроблене математичне забезпечення для використання на практиці для короткотермінового прогнозування значень частоти вібрації авіадвигунів.

## Висновки

Вирішено актуальну задачу прогнозування частоти вібрацій авіадвигунів шляхом побудови прогнозних нейромоделей.

Наукова новизна роботи полягає в тому, що дістав подальшого розвитку метод синтезу згорткових нейронних мереж, який за допомогою специфічного кодування сигналу використано для прогнозування частоти неперіодичних сигналів, що дозволяє архітектуру глибокої нейромережі для розпізнавання зображень зробити придатною до вирішення завдання прогнозування.

Практична цінність отриманих результатів полягає в тому, що розроблено програмне забезпечення, яке реалізує запропонований метод і дозволяє виконувати побудову згорткових нейронних мереж, їхнє навчання та тестування на вибірках даних і вирішено практичне завдання прогнозування частоти вібрацій авіадвигунів.

Перспективи подальших досліджень полягають у визначенні оптимальних параметрів нейронних мереж, а також у побудові моделей, що дозволятимуть виконувати прогнозування частоти через більший час.

1. Руденко О.Г., Бодяньський Є.В. Штучні нейронні мережі. Харків: Компанія СМІТ, 2006.
2. Walter Enders. Applied Econometric Time Series. 2nd ed. Wiley, 2004.
3. Сергиенко А.Б. Цифровая обработка сигналов. Санкт-Петербург: БХВ-Петербург, 2011.
4. Хайкин С. Нейронные сети: полный курс. Москва: Вильямс, 2006.
5. Bishop C.M. Pattern recognition and machine learning. Heidelberg: Springer, 2006.
6. Goodfellow Ian, Bengio Yoshua, Courville Aaron. Deep Learning (Adaptive Computation and Machine Learning series). The MIT Press, 2016.
7. Nielsen Michael A. Neural Networks and Deep Learning. Determination Press, 2015.
8. Аргументация данных для обучения нейронной сети. URL: <https://habr.com/company/smartengines/blog/264677>
9. Fast Fourier transform. URL: [https://en.wikipedia.org/wiki/Fast\\_Fourier\\_transform](https://en.wikipedia.org/wiki/Fast_Fourier_transform)
10. CS231n: Convolutional Neural Networks for Visual Recognition. URL: <http://cs231n.github.io>
11. Rashid Tariq. Make Your Own Neural Network. CreateSpace Independent Publishing Platform, 2016.
12. Bertsekas D.P. Convex Optimization Theory. Athena Scientific, 2009.

Надійшла до редакції 09.08.2018