

## Формування структури і оптимальних параметрів нейронної мережі для визначення прогинів композитної пластини

С.О. Пискунов, Б.К. Рєпін

КПІ ім. Ігоря Сікорського, Київ, Україна

**Анотація:** В роботі проведено визначення структури штучної нейронної мережі (ШНМ), необхідної кількості даних для навчання та алгоритмів їх обробки для забезпечення здатності мережі розпізнавати залежності між структурою композиційного матеріалу та кількісними параметрами його деформованого стану при заданому навантаженні із досягненням прийнятної точності. Для тестування мережі використана задача про визначення прогину тришарової (скло-плівка-скло) ламінатної пластини з широким діапазоном зміни фізико-механічних характеристик і геометричних розмірів в умовах триточкового згину. Показано, що найбільш ефективною є ШНМ, що складається з двох прихованих шарів з 12 і 6 вузлами у шарах відповідно при обробці даних на основі алгоритму Левенберга-Марквардта. При цьому похибка отриманих результатів лежить в межах 0,5% для даних з діапазону, використаного для тренування мережі і в межах 5% для даних поза межами цього діапазону.

**Ключові слова:** композиційні матеріали, механічні характеристики, штучні нейронні мережі.

Композитні матеріали набувають все більш широкого застосування в різних галузях техніки. Важливим питанням при цьому є визначення фізико-механічних властивостей матеріалу в залежності від його структури та характеристик окремих компонент. Проведення комплексних експериментальних досліджень є тривалим і дорогим процесом, а тому доцільним є перехід на якісно новий рівень визначення фізико-механічних властивостей, який дозволить суттєво скоротити кількість необхідних експериментів. Одним з таких є штучні нейронні мережі (ШНМ).

Штучна нейронна мережа – це математична модель, яка складається зі штучних нейронів, або вузлів, які з'єднані між собою за допомогою зв'язків. Кожен штучний нейрон приймає вхідні сигнали  $x$ , обчислює вагову суму цих сигналів із використанням вагових коефіцієнтів  $w$  та застосовує до неї функцію активації  $g$ , що породжує вихідний сигнал  $y = g(u)$  .:

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (1)$$

де  $u$  – потенціал активації нейрона,  $\theta$  – поріг активації.

Кожна ШНМ складається з вхідного шару (групи штучних нейронів), певної кількості прихованих шарів, та вихідного шару, кількість вузлів у яких залежить від конкретної задачі. Кількість прихованих шарів та кількість прихованих вузлів у них задаються вручну. Багатошарові ШНМ можуть вирішувати більш складні задачі, такі як обробка зображень, розпізнавання мови та передбачення числових послідовностей. Точного методу визначення оптимальної кількості вузлів у прихованих шарах не існує, а пропонувані різноманітні правила для її оцінки ґрунтуються на практичних висновках або емпіричних міркуваннях [1]. Навчання штучної нейронної мережі відбувається ітеративно за допомогою алгоритму зворотного поширення помилок, який полягає в послідовному поданні вхідних даних до мережі, визначенні вихідних значень, порівнянні їх з очікуваними вихідними значеннями, розрахунку помилки, поширенні її назад через мережу та корекції вагових коефіцієнтів зв'язків між нейронами.

В якості об'єкта дослідження обрана прямокутна тришарова ламінатна пластинка, що використовується у сонячних панелях. Пластинка складається із трьох шарів: тонкої полімерної плівки товщиною  $h_c$  до 0,5 мм і модулем пружності  $E_c$  та двох шарів зі скла, кожний товщиною

$h_s$  і модулем пружності  $E_s$ . Пластина має розмір  $b \times 2l$ , розглядається в умовах трьохточкового згину на базі між опорами  $2a$  під дією сили  $F$ . В якості еталонного результату використано величини прогинів, обчислені аналітично, до якої входять 9 незалежних параметрів [2]. Для навчання і тестування ШНМ було згенеровано два набори випадковим чином скомбінованих вихідних даних по 3000 рядків і 10 стовпців у кожному. Діапазон змінення даних в наступних межах:  $l=100 \dots 500$  мм,  $a = (0,7 \dots 0,9)l$ ,  $b = (0,2 \dots 0,4)$ ,  $h_c = 0,1 \dots 0,5$  мм,  $h_s = (6 \dots 10)h_c$ ,  $E_c = (1 \dots 30)$  МПа,  $E_s = (50 \dots 100)$  ГПа,  $\nu_c = 0,4 \dots 0,5$ ,  $F = (0,4 \dots 0,5)$  Н.

Для програмування ШНМ було використане модуль “Deep Learning Toolbox” програмного середовища Matlab R2021a. Це дозволяє не програмувати штучну нейронну мережу “з нуля”, а лише задати необхідні параметри для визначення її структури та способу навчання. Для уникнення додаткової похибки нормалізація проводилась з урахуванням найбільших і найменших значень параметрів в обох діапазонах:

$$x_{i,norm} = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (2)$$

де  $\min(x_i) = \min(x_i^{train}, x_i^{test})$ ,  $\max(x_i) = \max(x_i^{train}, x_i^{test})$ .

Співвідношення даних тренування/валідації обрано 75/25. Оскільки кожного разу при запуску коду дані для тестування та валідації вибираються з масиву випадковим чином, навчена ШНМ щоразу має дещо різну точність. Через це було проведено ряд тренувань. Тренування ШНМ може проводитись за різними алгоритмами. Для визначення оптимального алгоритму тренування було вибрано ШНМ що має два приховані шари з однаковою у них кількістю вузлів і проведено по 10 тренувань/тестувань. Після цього було проведено оцінку точності визначення прогину порівняно з аналітичним результатом і відібрано найкращий результат для кожної конфігурації.

Для тестування ШНМ було розглянуто десять алгоритмів, усі з яких базуються на методі зворотного поширення помилки. Для кожного алгоритму було послідовно здійснено збільшення кількості вузлів у прихованих шарах та проаналізовано змінення похибки. Два з випробуваних алгоритмів (алгоритм Левенберга-Марквардта та Байєсівська регуляризація) мали на порядок вищу точність результатів ніж інші, продемонстрували стабільне зниження похибки при збільшенні кількості вузлів та дозволили досягти значення похибки 5% при 4 вузлах і менше 1% вже при восьми вузлах у кожному прихованому шарі.

На другому етапі було проведено дослідження структури ШНМ з метою вибору оптимального варіанту. Протестовано п'ять НМ з такою структурою:

Один прихований шар, кількість вузлів і від 1 до 30 – ШНМ [i];

Два приховані шари з кількістю вузлів і у шарі 1 від 1 до 20, кількість вузлів у шарі 2 дорівнює половині кількості вузлів у шарі 1, округленої до більшого цілого числа – ШНМ [i, ½i];

Два приховані шари з однаковою кількістю вузлів і від 1 до 15 – ШНМ [i, i];

Два приховані шари, кількість вузлів і у шарі 2 - від 1 до 20, кількість вузлів у шарі 1 дорівнює половині кількості вузлів у шарі 2, округленої до більшого цілого числа – ШНМ [½i, i];

Три приховані шари: кількість вузлів і у шарі 1 від 1 до 15, у шарах 2 і 3 дорівнює відповідно округленим до цілого числа двом третинам і одній третині від кількості вузлів у шарі 1 – ШНМ [i, ⅔i, ⅓i].

Усі НМ мають 9 вхідних вузлів і один вихідний. Тренування проводилась за визначеним в попередньому дослідженні алгоритмом Левенберга-Марквардта.

Для кожної конфігурації ШНМ було проведено тренування на відповідному наборі даних, після чого було проведено симуляцію використовуючи дані з набору даних для тестування. Було проведено по 10 тренувань/тестувань, порівняно оцінку прогину з аналітичним результатом і відібрано найкращий результат для кожної конфігурації. Це дозволило

визначити, що для даної задачі та за даної кількості даних нейронні мережі у конфігурації  $[i, \frac{1}{2}i]$ , при кількості вузлів у шарах від 12 і більше, є найбільш оптимальними. Також були проведені дослідження впливу кількості даних у наборі для тренування на точність результатів і показано, що для отримання достатньо точних результатів для даної задачі бажаною є кількість рядків у наборів 1000 і більше.

Важливим етапом дослідження є перевірка здатності НМ забезпечувати отримання достовірних результатів не тільки в діапазоні даних, в якому проводилось тренування, а і для даних з інших діапазонів. Додаткові тестування мережі були проведені при різних комбінаціях даних для навчання і тестування, зокрема було проведено тренування мережі даними у двох різних діапазонах з “пробілом” між ними та подальше тестування мережі на даних, що належать до області “пробілу”, а також тренування НМ у одному діапазоні даних і перевірка достовірності результатів для даних, що лежать за його межами. У першому випадку точність отриманих результатів лежала в межах 0,5%, в другому випадку точність була набагато нижчою (в межах 2–5% в залежності від комбінацій даних для тренування і тестування).

В цілому отримані в даній роботі результати дозволили сформулювати методіку для проектування, навчання і тестування штучної нейронної мережі для визначення прогинів композитної пластини на основі даних про її структуру і фізико-механічні характеристики складових. Отримані результати можуть бути використані також для визначення зведених механічних характеристик композитних матеріалів і елементів конструкцій.

### Список літератури

1. Heaton, Jeff. Introduction to Neural Networks with Java. St. Louis: Heaton Research, Inc, 2005.
2. Analysis of laminated glass beams for photovoltaic applications. Schulze, Stefan-H., International Journal of Solids and Structures, 2012. pp. 2027-2036.

## Formation of the structure and optimal parameters of the neural network for determining the composite plate deflections

S. Pyskunov, B. Repin

**Abstract:** The paper defines the structure of an artificial neural network (ANN), the required amount of data for training and algorithms for their processing to ensure the ability of the network to recognize dependencies between the structure of the composite material and the quantitative parameters of the deformed state under a given load with acceptable accuracy. To test the network, the problem of determining the deflection of a three-layer (glass-film-glass) laminate plate with a wide range of changes in physical and mechanical characteristics and geometric dimensions under conditions of three-point bending was used. It is shown that the most effective is the ANN consisting of two hidden layers with 12 and 6 nodes in the layers, respectively, when processing data based on the Levenberg-Marquardt algorithm. At the same time, the error of the obtained results lies within 0.5% for data from the range used for training the network and within 5% for data outside this range.

**Keywords:** composite materials, mechanical characteristics, artificial neural networks.