

РОЗПІЗНАВАННЯ ВІЗУАЛЬНИХ ОБРАЗІВ СИГНАЛІВ ЗА ДОПОМОГОЮ НЕЙРОННОЇ МЕРЕЖІ

Анотація. Використання нейронних мереж на основі багатошарового персептрона запропоновано як метод для розпізнавання візуальних образів. Продемонстрована працездатність мережі на прикладі розпізнавання та класифікації електромагнітних сигналів. Моделювання виконувалось в середовищі MATLAB.

Ключові слова: композитні матеріали, нейронні мережі, багатошаровий персепtron, візуальний образ сигналу, функції активації.

Вступ. В промисловості одним із важливіших питань є контроль якості продукції. Існує велика кількість методів контролю, однак найбільш використовуваними є методи неруйнівного контролю, які не наносять шкоди контролюваному виробу.

Одним з методів неруйнівного контролю композитних матеріалів є вихорострумовий. Його можна проводити без контакту перетворювача й об'єкта та одержувати прийнятні результати контролю навіть при високих швидкостях переміщення перетворювача. Вихорострумовий метод заснований на реєстрації зміни густини вихорових струмів, тому на отриманий сигнал можуть впливати зовнішні вихорові струми. Слід враховувати шорсткість поверхні композитних матеріалів. Виникає задача – при аналізі оброблюваних сигналів, необхідно отримати інформацію щодо наявності та розмірів дефектів.

Розроблено багато методів розпізнавання образів за допомогою нейронних мереж з різною структурою і специфікою, завдяки чому відкривається широкий простір для досліджень. Сучасні технології дозволяють створювати комп'ютерні системи із залученням нейронних мереж, для яких в якості вхідних параметрів можуть використовуватися характеристики електромагнітних сигналів [1,2].

Визначення проблеми. Метою роботи є створення графічних образів електромагнітних сигналів, які отримуються при скануванні композитних матеріалі, та їх дослідження за допомогою створеної

нейронної мережі для розв'язання задачі класифікації сигналів дефектоскопії.

Основна частина. Кожна штучна нейронна мережа являє собою множину простих елементів – нейронів, які сполучені певним чином. Конкретний вигляд виконуваного мережею перетворення даних обумовлюється не тільки характеристиками нейронів, які входять до її структури, але і особливостями її архітектури, а саме топологією міжнейронних зв'язків, напрямом і способами передачі інформації між нейронами, а також засобами навчання мережі [2, 3].

При проведенні аналізу вхідних і вихідних даних значення ваг та зсувів нейронної мережі автоматично налагоджуються так, щоб мінімізувати різницю між бажаним сигналом та отримуваним на виході в результаті моделювання. Ця різниця називається помилкою навчання і для конкретної конфігурації нейронної мережі визначається шляхом пропускання через мережу всіх спостережень, які маються, та порівняння вихідних значень з бажанім, цільовим значенням. Тобто формується функція помилки (критерій якості навчання).

Багатошарові нейронні мережі прямого розповсюдження являють собою нелінійні системи, які дозволяють краще кваліфікувати ніж звичайні статистичні методи. Багатошаровий персептрон (multilayer perceptron - MLP) складається з множини вхідних вузлів, які створюють вхідний шар, одного або декількох прихованих шарів нейронів з сигмоїdalьними функціями активації, та вихідного шару нейронів з лінійними функціями активації. При навчанні MLP використовуються алгоритми зворотного розповсюдження помилки (back-propagation learning) [3]. Кожний нейрон MLP, який навчається на основі зворотного розповсюдження має нелінійну гладку функцію активації, часто використовують нелінійну сигмоїdalьну функцію типа логістичної або гіперболічного тангенса [3, 4].

Алгоритми оптимізації навчання є стратегіями, заснованими на реалізації ідеї ітеративного спуску, які забезпечують мінімізацію функціонала навчання. У процесі роботи алгоритмів, як правило, виникає задача одновимірного пошуку мінімуму уздовж заданого напрямку [2, 3].

Процес навчання мережі включає налаштування значення ваг і зсувів мережі для оптимізації продуктивності мережі. Налаштування продуктивності для мереж з прямим поширенням визначається за се-

редньоквадратичною функцією (mse) між виходами мережі (a) й цільовими виходами (t) та визначається за формулою [3]

$$F = mse = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (1)$$

Найбільший інтерес представляють такі показники як величина продуктивності градієнта і кількість перевірок достовірності, котрі використовуються для завершення навчання. При найменшому значенні градієнту навчання досягає мінімальної продуктивності. Величину градієнта можна визначати самостійно.

Після навчання і перевірки нейронної мережі об'єкт мережі можна використовувати для розрахунку відповідей на будь-яке вхідне значення.

Основний алгоритм зворотного розповсюдження помилки корегує параметри, які налагоджуються, в напрямку найскорішого зменшення функціоналу помилки. Методи другого порядку вимагають знання других похідних цього функціоналу помилки. До цих методів відноситься метод Ньютона, основний крок якого знаходиться за формулою:

$$x_{k+1} = x_k - H_k^{-1} g_k, \quad (2)$$

де x_k – вектор значень параметрів на k -ї ітерації; H – матриця других часткових похідних цільової функції, або матриця Гессе; g_k – вектор градієнта на k -ї ітерації. Метод Ньютона в багатьох випадках сходиться скоріше, ніж методи сполученого градієнта, але потребує великих затрат через обчислення гессіана. Для того, щоб уникнути обчислення матриці Гессена, пропонуються різні засоби її заміщення приблизними виразами, це породжує так звані квазіニュтонові алгоритми (наприклад, алгоритм метода січних плоскостей або алгоритм Левенберга-Марквардта) [2 ч. 4].

Алгоритм Левенберга – Марквардта реалізує наступну стратегію для оцінки матриці Гессе. Припускаючи, що функціонал визначається як сума квадратів помилок, що характерно при навчанні нейронних мереж з прямим розповсюдженням, гессіан можна наблизено обчислити як

$$H \cong J^T J, \quad (3)$$

а градієнт розрахувати за формулою

$$g = J^T e, \quad (4)$$

де $J = \frac{\partial J}{\partial W}$ - матриця Якобі похідних функціоналу помилки за параметрами, які налаштовуються; e - вектор помилок мережі.

Матриця Якобі може бути обчислена на основі стандартного методу зворотного розповсюдження помилки, це істотно простіше обчислення матриці Гессе. Алгоритм Левенберга – Марквардта використовує апроксимацію гессіана такого вигляду:

$$x_{k+1} = x_k - (J^T J + \mu I)^{-1} J^T e_k . \quad (5)$$

Коли коефіцієнт μ дорівнює 0, отримуємо метод Ньютона з наближенням до гессіана; коли значення μ велике, отримуємо метод градієнтного спуску з маленьким кроком. Оскільки метод Ньютона має велику точність і швидкість збіжності поблизу мінімуму, завдання полягає в тому, щоб у процесі мінімізації якомога швидше перейти до методу Ньютона. З цією метою параметр μ зменшують післяожної успішними ітерації і збільшують лише тоді, коли пробний крок показує, що функціонал помилки зростає. Така стратегія забезпечує зменшення помилки післяожної ітерації алгоритму.

Цей алгоритм має дуже ефективну реалізацію в системі MATLAB, що є інтерпретатором векторної машини, де операція скалярного добутку реалізується з високою точністю і швидкодією на математичному співпроцесорі комп'ютера. Головний недолік алгоритму Левенберга – Марквардта полягає в тому, що він вимагає багато пам'яті для зберігання матриць великих розмірів [3, 4].

Навчання нейронної мережі припиняється при виконані однієї з умов: значення функції якості навчання стало менше граничного; градієнт критерію якості став менше; досягнуто граничне число циклів навчання; перевищено максимальний час, виділений на навчання.

Експериментальні дослідження. При проведенні сканування композитних матеріалів за допомогою вихорострумового перетворювача отримуються три форми сигналів унімодальний, пологий унімодальний та бімодальний. Унімодальний сигнал з максимальною амплітудою характеризує дефекти, які перевищують розміри перетворювача, а бімодальні з найбільшим провалом вершини належать до точкових дефектів [6].

В роботі запропоновано дослідити модельні сигнали, які одержуються при скануванні поверхні композитів [5] та описуються формулою:

$$y(x) = \exp(-1.5x^2) - k * \exp(-3x^2), \quad (6)$$

де k змінюється від 0 до 1: при $k = 0.35$ одержуємо вузький унімодальний сигнал, котрий характеризує довгі тріщини, довжина яких перебільшує зону контролю. При зміні $k = 0.35\text{--}0.55$ отримуємо положистий унімодальний сигнал, характерний для тріщин меншої розмірності. Беручи $k = 0.6\text{--}1$ отримуємо бімодальний сигнал, який мають маленькі тріщини (при $k = 1$ – точковий дефект).

На теперішній час для моделювання нейронних мереж існує велика кількість програмного забезпечення. В роботі запропоновано використовувати інструментарій Neural Networks Toolbox пакету прикладних програм MATLAB R2010b, котрий забезпечений широким набором команд й функцій для проектування та дослідження як статичних, так і динамічних нейронних мереж.

Мета дослідження – створити нейронну мережу, котра спроможна розпізнавати візуальний образ сигналів.

В роботі за допомогою розробленої функції *create_pic_of_sign.m* та формули (6) створюються зображення сигналів в градаціях сірого розміром 21×13 . Далі виконується конвертація значень сигналу з одномірної матриці в двомірну та проводиться кодування наступним чином. Заожною коміркою по ширині закріплени координати перетворювача по осі x , а по висоті – значення сигналу у цих точках так, щоб сама нижня комірка приймала значення від 0 до 0,077, а найвища – від 0,924 до 1,001. Після виконання конвертації сигналу отримуємо двомірну матрицю, в якій кожна точка сигналу відповідає нулю у відповідній комірці. За допомогою вбудованої в середовище Matlab функції *imwrite(A,filename)* створюємо зображення в градаціях сірого.

Для перегляду зображень сигналів створена функція *plotsign(c)*, за допомогою якої можна побачити сигнали унімодальної (рис. 1) та бімодальної (рис 2) форми.




Рисунок 1 – Унімодальний сигнал




Рисунок 2 – Бімодальний сигнал

Для використання створених зображень у середовищі Matlab необхідно імпортувати та обробити ці зображення. Для цього створена функція *Imgread_m(x)*, яка після імпорту рисунка обробляє його наступним чином. Оскільки зображення збережені в градаціях сірого, тобто значення кожного пікселу лежать у проміжку 0 ч 255, а для експериментів використовується логічний формат кодування «1» або «0». Необхідно провести заміну значення 0 на 1, а 255 на 0. Після обробки двомірна матриця конвертується у вектор з 273 елементів, а функція *Imgread_m(x)* повертає у середовище цей вектор.

В процесі дослідження до створених сигналів добавлялись значення шуму. Для цього розроблена функція *noise_img(img, n_p)*, яка дозволяє додавати шум-точки на зображення сигналів. Наприклад, додамо 25 шум-точок на зображення унімодального сигналу (рис. 3).




Рисунок 3 – Унімодальний сигнал з 25 шум-точками

Для розпізнавання сигналів використовувалась двошарова нейронна мережа - багатошаровий пересептрон з 273 нейронами у вхідному шарі (кількість компонентів вхідного вектора), 30 нейронів у прихованому шарі та 2 нейрони у вихідному шарі (за кількістю компонент вихідного вектора).

Для створення нейронної мережі прямого поширення застосовували функцію *feedforwardnet (hiddenSizes,trainFcn)*, де *hiddenSizes* – вектор-рядок з одного або декількох розмірів прихованого шару; *trainFcn* – функція навчання.

Для перевірки ефективності створеної нейронної мережі тестування проводилось на трьох зображеннях сигналів: унімодальна форма, полога унімодальна форма та сигнали бімодальної форми. Спочатку навчання проводилось на модельних сигналах без шуму. Потім на сигналах, до яких додавали 30 шум-точок[6]. Створені дві структури нейронних мереж містили в прихованому шарі 30 нейронів та використовували логістичну сігмоїдальну функцію (*logsig*). Вихідний шар складався з 3 нейронів (за кількістю форм сигналів) та застосовував лінійну функцію (*purelin*).

Тестування проводилось наступним чином: на створену нейрону мережу подавались зображення сигналів, до яких поступово додавались шум-точки в діапазоні від 0 до 100. Для кожного значення шум-точок формувалось 100 зашумованих послідовностей і підраховувався вихід мережі. Вихідний сигнал оброблявся М-функцією *compet* з метою вибрати один з трьох сигналів. Після цього оцінювалась кількість помилкових класифікацій та підраховувався процент помилок. Відповідний графік похибок мережі наведено на рис. 4.




Рисунок 4 – Помилки створеної мережі від кількості шум-точок

В ході подальших експериментів створену нейронну мережу застосовували таким чином. Навчання проводилось на зображеннях двох сигналів унімодальному (при $k=0.1$) та бімодальному (при $k=0.9$). Використовувалась та ж сама двошарова нейронна мережа. Тільки у прихованому шарі застосовувалось 30 нейронів, у вихідному шарі використовувалось 2 нейрони, оскільки працювали по черзі з двома формами сигналів. Для кожного типу сигналів використовувалось 1000 прикладів для навчання, яке проводилось на модельних та окремо на зашумованих сигналах.

Тестування мережі проводилось для різних значень k із формули (6), які не брали участі в процесі навчання. Використовували 500 прикладів для кожного типу сигналів та послідовно додавали шум-точки в діапазоні від 0 до 70, потім знаходили середнє значення для кожного значення шум-точки. Отримані результати наведені в таблицях 1 та 2.

Таблиця 1
Оцінка похибок нейронної мережі при навчанні
на модельних сигналах

Сигнал для тестування роботи мережі	0	10	20	30	40	45	50	55	60	65	70
$k=0$	100	97.8	90.8	88.4	84.8	83.6	82.6	79.6	79.4	80.6	76.6
$k=0.2$	100	98	95	92.4	89.2	89.4	88.8	86	83.8	86.2	88.2
$k=0.3$	100	82.6	72.8	73	76.4	71	71.4	67.4	71.4	73	70.4
$k=0.6$	100	99.6	99	95.6	92.2	91.4	88	87.4	82.4	82.4	78.2
$k=0.8$	100	99.6	98.2	95.6	93.4	90.8	89.4	87	85.4	84.4	80.4
$k=1$	100	99.8	98.4	95.4	92.4	92.6	89.6	87	84.8	81.2	81.6

Таблиця 2

Оцінка похибок нейронної мережі при навчанні на сигналах з шумом

Сигнал для тестиування роботи мережі	0	10	20	25	30	35	40	45	50	55	60	65	70
k =0	100	99	99.4	99.4	99	99.4	99.2	99.4	99.2	99	98.8	99	98.4
k =0.2	100	100	100	100	100	100	100	100	99.8	99.6	99.8	99.8	99.4
k =0.3	100	99.8	99	98.8	98.2	98.4	98.6	98.2	97.6	97.6	97.2	95.8	96.6
k =0.6	100	99.6	98.8	98.4	96.6	95	96.2	95.6	92.2	93.2	89.2	86.4	87.2
k =0.8	100	96.2	90.2	89.8	90	91.6	89.6	87	89.6	87.2	87.4	85.2	84
k =1	100	100	100	100	100	100	100	100	100	99.8	99.8	99.8	99.6

Висновки. Проведені дослідження показали принципіальну можливість застосування нейронних мереж для розпізнавання сигналів, які представлені візуальними образами. Навчання мережі на різних наборах сигналів з шумом дозволило навчити її працювати з спотвореними даними, що характерно при проведенні неруйнівного контролю у реальних умовах.

Створена нейронна мережа демонструє якість розпізнавання приблизно 90%, якщо до ідеального сигналу додається не більше 30% шум-точок від загальної кількості точок на зображені.

Дослідження показали, що при навчанні нейронної мережі на сигналах з шумом, вона демонструє кращі результати розпізнавання образів сигналів.

ЛІТЕРАТУРА

- Хайкин С. Нейронные сети: полный курс, 2-е изд.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006.
- Аксенов С.В. Организация и использование нейронных сетей (методы и технологии) / С.В. Аксенов, В.Б. Новосельцев . – Томск: Изд-во НТЛ, 2006. – 128 с.
- Медведев В.С. Нейронные сети. MATLAB 6 / В.С. Медведев, В.Г. Потемкин – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.
- Дьяконов В., Круглов В. Математические пакеты расширения MATLAB. Специальный справочник. – СПб.: Питер, 2001. – 480 с.
- Хандецкий В.С. Спектральная идентификация сигналов в дефектоскопии композитов с использованием теории статистических испытаний / Хандецкий В.С., Герасимов В.В. // Вісник ДНУ: Фізика. Радіоелектроніка. – Дніпропетровськ: – 2003. № 10. – С. 128 – 132.
- Матвеева Н.А. Моделирование нейросети для решения задачи классификации в дефектоскопии // Системні технології. Регіон. міжвуз. зб. наук. праць. - Дніпропетровськ: ДНВП «Системні технології», 2011. -Вип. 1(72). - С. 37-44.