

УДК 629.735.083.2:620.179.1:004.032.26

СИНТЕЗ НЕЙРОННОЇ МЕРЕЖІ ДЛЯ БАГАТОКАНАЛЬНОЇ ДІАГНОСТИКИ ЕЛЕМЕНТІВ КОНСТРУКЦІЇ В ЕКСПЛУАТАЦІЇ

Н. І. Бурау, А. Г. Протасов, П. С. Мироненко, С. С. Рупіч

Національний університет України «Київський політехнічний інститут»,
пр-т Перемоги, 37, м. Київ, 03056, e-mail: serhii.rupich@gmail.com

Для виявлення пошкодження в елементах конструкцій в експлуатації запропоновано використання систем моніторингу на основі концепції SHM, які забезпечують контроль життєвого циклу об'єкту для його надійної та безпечної експлуатації. Наведена функціональна схема комплексної інформаційної системи моніторингу, обґрунтовано сучасний підхід організації моніторингу з використанням інтелектуального компоненту – штучних нейронних мереж, які надають можливість реалізувати процес організації паралельності потоків інформації багатоканальної системи. Наведені приклад функціональної схеми системи моніторингу резервуарів з еколого-небезпечними речовинами та схема практичного використання нейронних мереж при вирішенні реальної задачі класифікації та розпізнавання. Наведено загальну схему та структуру класифікатора стану системи моніторингу для вирішення завдання визначення технічного стану об'єкту контролю. Для розпізнавання стану елементів конструкції за результатами аналізу діагностичної інформації розроблено класифікатор на основі ймовірнісної нейронної мережі PNN, архітектура якої складається з двох шарів: з радіально-базисними нейронами в першому шарі та шару конкуренції. Встановлені класи для станів об'єкту контролю та відповідні параметри для кожного з них. Сформовано навчальну множину, яка покладена в основу навчання «з учителем», для кожного класу класифікатора системи діагностування. Наведено масив навчальних векторів у матричному вигляді. Сформовано різні типи тестових множин векторів, щоб визначити доцільність та ефективність використання побудованої нейронної мережі. Визначено вектор індексів класів та повну матрицю зв'язності нейронної мережі, що встановлюють приналежність вхідного масиву інформації до відповідного цільового класу. Наведено блок-схеми нейронної мережі багатоканальної діагностики в програмному середовищі Matlab, складовими якої є два шари, вхідні та вихідні масиви даних і матриці ваг. Встановлено кількість нейронів кожного шару побудованої ймовірнісної мережі PNN багатоканальної діагностики.

Ключові слова: ймовірнісна нейронна мережа PNN, класифікатор, вектор діагностичних ознак, вектор навчальної множини, вектор тестової множини.

Для выявления повреждения в элементах конструкций в эксплуатации предложено использование систем мониторинга на основе концепции SHM, которые обеспечивают контроль жизненного цикла объекта для его надежной и безопасной эксплуатации. Приведена функциональная схема комплексной информационной системы мониторинга и обоснован современный подход организации мониторинга с использованием интеллектуального компонента – искусственных нейронных сетей, которые предоставляют возможность реализовать процесс организации параллельности потоков информации многоканальной системы. Приведены пример функциональной схемы системы мониторинга резервуаров с эколого-опасными веществами и схема практического использования нейронных сетей при решении реальной задачи классификации и распознавания. Приведена общая схема и структура классификатора состояния системы мониторинга для решения задачи определения технического состояния объекта контроля. Для распознавания состояния элементов конструкции по результатам анализа диагностической информации разработан классификатор на основе вероятностной нейронной сети PNN, архитектура которой состоит из двух слоев: с радиально-базисными нейронами в первом слое и слоя конкуренции. Установлены классы для состояний объекта контроля и соответствующие параметры для каждого из них. Сформировано обучающее множество, которое положено в основу обучения «с учителем», для каждого класса классификатора системы диагностирования. Приведены массивы обучающих векторов в матричном виде. Сформированы различные типы тестовых множеств векторов для определения целесообразности и эффективности использования построенной нейронной сети. Определены

вектор индексов классов и полная матрица связности нейронной сети, устанавливающие принадлежность входного массива информации соответствующему целевому классу. Приведены блок-схемы нейронной сети многоканальной диагностики в программной среде Matlab, составляющими которой являются два слоя, входные и выходные массивы данных и матрицы весов. Установлено количество нейронов каждого слоя построенной вероятностной сети PNN многоканальной диагностики.

Ключевые слова: вероятностная нейронная сеть PNN, классификатор, вектор диагностических признаков, вектор обучающего множества, вектор тестового множества.

The process of identifying damage to the structural elements in operation proposed use of a monitoring systems based on the concept of SHM that providing the structural health monitoring for its safe and reliable operation. The functional diagram of an integrated information system for monitoring and reasonably modern approach to the organization of monitoring the use of intelligent components - artificial neural networks, which provide the opportunity to realize the process of organizing information flows parallel multi-channel system. An example of a functional circuit monitoring system tanks ecological and hazardous substances and the scheme of the practical use of neural networks for solving the real problem of classification and recognition. Provides an overview of the status and structure of the classifier monitoring system to address the problem of determining the technical condition of the object of control. To detect the state of structural elements according to the analysis of diagnostic information developed probabilistic classifier based on a neural network PNN, whose architecture consists of two layers: a radially-basic neurons in the first layer and the layer of competition. Established classes for object state control and the corresponding parameters for each of them. Formed training set, which forms the basis of learning "teacher", for each class of classifier system diagnostics. Arrays are given training vectors in matrix form. Formed by different types of sets of test vectors to determine the feasibility and effectiveness of the built neural network. Determine the vector of indices of classes and a full array of connectivity of the neural network, establish membership input array information corresponding to the target class. A block diagram of a neural network diagnostic multichannel environment Matlab software, components of which are two layers, the input and output arrays and the weight matrix. Established the number of neurons of each layer constructed probabilistic network PNN multichannel diagnostics.

Keywords: probabilistic neural network PNN, classifier, diagnostic features vector, the vector of the training set, a test vector set.

Вступ. Пошкодження або дефекти в певній мірі присутні у всіх матеріалах елементів конструкції. Тому проектування відповідальних елементів конструкцій у більшості випадків ґрунтується на принципі безпечного пошкодження [1]. Виявлення дефектів обмежується змінами в матеріалі та/або геометричних властивостей елементів конструкції під час експлуатації, у тому числі змінами в граничних умовах. Для безаварійного функціонування об'єктів авіаційної техніки, машинобудування, енергетики, нафтогазової галузі, інженерних споруд необхідно своєчасно виявляти пошкодження, проводити моніторинг їхнього розвитку та прогнозування граничного стану. Одним з необхідних і перспективних сучасних шляхів забезпечення надійної, безаварійної та ефективної експлуатації таких об'єктів є моніторинг життєвого циклу їх конструкцій на основі комплексного аналізу інформації про поточний технічний стан (ТС), експлуатаційні навантаження та впливи зовнішнього середовища.

Розроблені методи, методики та технології діагностування як окремих елементів

конструкції, так і складних динамічних об'єктів надають можливість створити діагностичні системи нового класу – комплексні інтелектуальні системи моніторингу (КІСМ) ТС конструкцій в експлуатації. Такі системи за принципами побудови та функціонування можна віднести до систем, що реалізують концепцію Structural Health Monitoring (SHM) [1, 2]. Починаючи з 50-х років ХХ століття виникають поняття «штучного інтелекту» та «інтелектуальної системи», які закладають основу до встановлення нового напрямку наукового дослідження. Сучасний розвиток таких розділів штучного інтелекту як інженерне знання, комп'ютерна логіка та лінгвістика, когнітивна психологія, методи та моделі навчання, методи пошуку та прийняття рішень та інших заклало теоретичну основу для створення високоефективних програмних систем з обробки та використання знань для рішення цілого ряду прикладних задач, і, зокрема, розробку систем, що моделюють творчі можливості людини. Такі системи отримали назву «інтелектуальні». Однією з них, що набула вагомого розвитку в останні десятиліття,

де починають більш активно використовуватися ідеї та методи штучного інтелекту в теорії та практиці, є система моніторингу життєвого циклу SHM. Впровадження такої технології при розробці нових об'єктів авіаційної техніки, машинобудування, енергетики, нафтогазової галузі, інженерних споруд спеціального призначення надають можливість створювати «інтелектуальні конструкції» [3, 4].

Процес моніторингу життєвого циклу включає в себе спостереження за структурою або механічною системою з плином часу, використовуючи періодично отримані вимірювання, визначення характеристик, чутливих до пошкоджень і статистичного аналізу для визначення поточного стану системи. Вихідною метою SHM є отримання інформації, що періодично оновлюється, та надання можливості робити висновки щодо здатності об'єкту продовжувати виконувати свої функції у процесі неминучого старіння та пошкодження в результаті накопичення дефектів в умовах експлуатації.

Сучасний підхід до організації інтелектуальних систем діагностики передбачає розподіл функцій на декілька підсистем або окремих систем, метою яких є контроль технічного стану, статистична класифікація та керування взаємодією з іншими підсистемами та системами. Підсистеми представляють собою відповідний рівень в загальній побудові системи контролю, діагностики, класифікації та керування, мають свій клас вирішуваних завдань, своє алгоритмічне та програмне забезпечення. Моніторинг технологічно складних об'єктів проводиться з використанням масиву чутливих елементів, що функціонують на різних фізичних принципах. Цим забезпечується багатоканальність інформаційних діагностичних систем і повнота (весь спектр) інформації про об'єкт контролю.

Як зазначено в [1], КІСМ – багатоканальна система, яка в реальних умовах експлуатації контрольованого об'єкту забезпечує виконання таких функцій:

- прийняття, перетворення, попередня обробка та реєстрація інформації від множини датчиків первинної інформації та сигналізаторів, які встановлені на об'єкті;

- обробка інформації та визначення характеристик і параметрів експлуатаційних навантажень на елементи конструкції об'єкту контролю;

- обробка інформації відповідно до визначених методів, виділення параметрів (діагностичних ознак) зміни технічного стану;


- слідування за перевищенням

параметрами своїх граничних значень, розпізнавання функціонального технічного стану та формування сигналів появи пошкодження, несправного функціонування чи аварійного стану контрольованого об'єкту;

- візуалізація діагностичних повідомлень, автоматичне формування за запитом усієї наявної інформації для кожного діагностичного повідомлення;

- зберігання та передача інформації у зовнішні інформаційні мережі.

В узагальненому вигляді функціональну схему КІСМ показано на рис. 1.



1 – об'єкт контролю; 2 – множина датчиків первинної інформації; 3 – діагностична модель об'єкту; 4 – підсистема перетворення, аналізу інформації та формування діагностичних ознак; 5 – підсистема формування об'єктів навчальної множини ознак; 6 – класифікатор стану; 7 – блок формування результатів діагностування

Рисунок 1 – Функціональна схема системи моніторингу

За результатами обробки діагностичної інформації та виділення діагностичних ознак (підсистема 4) з використанням діагностичної моделі контрольованого об'єкту (блок 3) виконується формування об'єктів навчальної множини ознак (підсистема 5) для бездефектного стану елементів конструкції та безпосередньо розпізнавання ТС в процесі моніторингу (блок 6).

На систему діагностування накладається вимога високої швидкодії, адже від цього параметру залежить своєчасність надання технічного обслуговування. Для пошуку дефектів потрібна методологія правильного розпізнавання та класифікації ознак пошкоджень. У цілому, проблема швидкодії системи діагностики може бути успішно вирішена використанням паралельної організації потоків обробки діагностичної інформації шляхом застосування обчислювальних систем з масовим

паралелізмом. В інформаційних системах діагностики найбільш поширеним типом інтелектуального компоненту стають штучні нейронні мережі. Вони застосовуються для вирішення цілого класу задач, де використовуються не лише рівняння динаміки та правила, як в традиційних експертних системах, а й досвід, який набувається в процесі взаємодії з реальними об'єктами. Саме нейронні мережі (НМ) надають можливість реалізувати процес організації паралельності потоків інформації, що надходить з давачів первинної інформації, та застосувати їх для побудови класифікатора ТС.

Як приклад багатоканальної системи моніторингу, розробленої на основі концепції SHM, на рис. 2 наведено функціональну схему КІСМ для попередження руйнування резервуарів з еколого-небезпечними речовинами, які знаходяться у важкодоступних місцях та під впливом динамічних (сейсмічних, вітрових) і кліматичних навантажень [1].

В системі моніторингу реалізуються такі вимірювальні канали:

- вібродіагностичні – для контролю модальних характеристик резервуару, контролю вібраційних характеристик фундаменту, визначення параметрів і характеристик динамічних збурень;
- тензометричні – для визначення та контролю характеристик напружено-деформованого стану зовнішньої стінки резервуару;
- інклінометричні – для визначення та

контролю просторового положення резервуару під дією динамічних збурень;

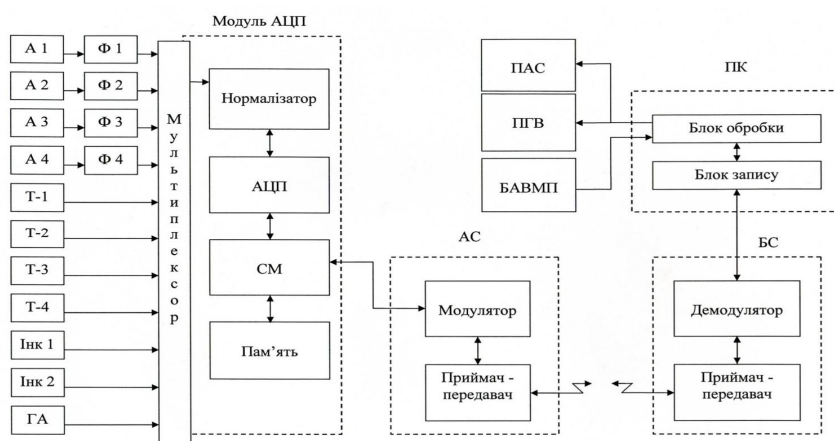
- газоаналізу – для контролю складу сумішей газів у просторі між зовнішньою та внутрішньою оболонками резервуару;

- автоматичного визначення метеорологічних параметрів для врахування їх при визначенні експлуатаційних навантажень на резервуар.

Як видно, така система моніторингу є багатоканальною, діагностична інформація з давачів первинної інформації аналізується частотно-часовими та статистичними методами. В результаті, ТС контрольованого об'єкту описується деякою множиною діагностичних ознак. Для правильного визначення ТС необхідно розробити класифікатор, який був би гнучким, забезпечував нелінійний розподіл на класи, був чутливим до малих змін діагностичних ознак, міг розрізняти стани за зміною однієї, двох або більше діагностичних ознак. Такий класифікатор доцільно розробити на основі штучних НМ.

Метою даної статті є побудова НМ для багатоканальної діагностики елементів конструкції в експлуатації.

Практичне використання НМ при вирішенні реальної задачі класифікації полягає у навчанні НМ на відомих прикладах (на навчальній множині) та подальшому віднесенні тестових образів до визначених заздалегідь станів. Реалізація цього принципу зображена у вигляді схеми налаштування НМ на рис. 3.



А – акселерометр; Ф – фільтр; Т – тензодавач; Інк – інклінометр; ГА – газоаналізатор; СМ – сигнальний мікропроцесор; АС – абонентська станція; БС – базова станція; ПАС – пристрій аварійної сигналізації; ПГВ – пристрій графічного відображення; БАНМІП – блок автоматичного визначення метеорологічних параметрів

Рисунок 2 – Приклад функціональної схеми системи моніторингу резервуарів з еколого-небезпечними речовинами

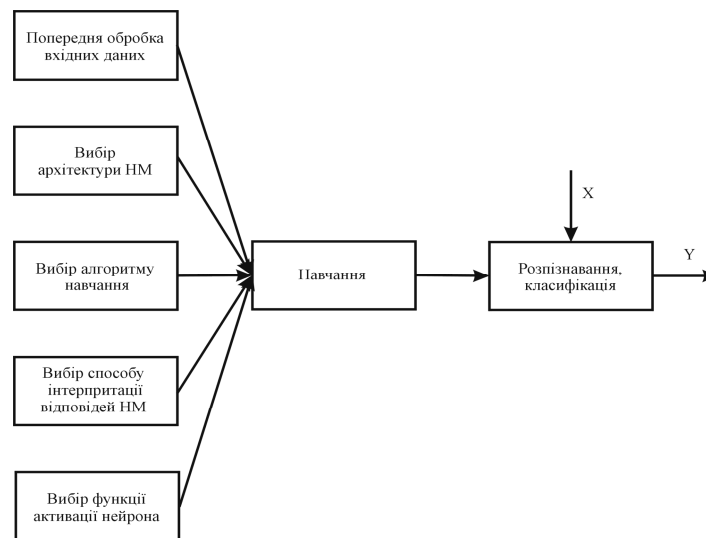


Рисунок 3 – Схема налаштування нейронної мережі для вирішення задач класифікації та розпізнавання

Елементами класифікатора є: навчальна множина образів або діагностичних ознак (вектор P); множина цільових класів (вектор T); матриця зв'язності Tc , яка встановлює приналежність вхідних векторів до відповідних класів; нейронна мережа, яка виконує процес класифікації та розпізнавання ТС елементів конструкції; тестова множина (вектор $Ptest$). Остання під час функціонування замінюється на множину реальних даних, що поступають з масиву чутливих елементів.

Задачу класифікації успішно вирішують такі типи НМ: 1) багатошарова НМ прямого розповсюдження; 2) двошарова LVQ (learning vector quantization) НМ – мережа класифікації вхідних векторів; 3) ймовірнісна мережа PNN (Probabilistic Neural Network). Як показав аналіз літературних джерел [5], краща ефективність досягається при використанні PNN мереж. Вони описані у роботі [6] та призначені для рішення ймовірнісних задач, в тому числі задач класифікації, тому у даній роботі розробку класифікатора будемо виконувати з використанням ймовірнісних мереж PNN.

В основу архітектури мережі PNN покладена архітектура радіально базисної мережі. Вона складається з двох шарів. Нейрони першого шару мають радіально-базисні функції активації, а другий – називається шаром конкуренції, який підраховує ймовірність приналежності вхідного вектору тому чи іншому класу, а в кінці зіставляє вектор з тим класом, ймовірність приналежності до якого вище [7]. Вхід функції активації першого шару n визначається як модуль різниці вектору ваг W і вектору входу P , помножений на зміщення b .

$$n = \|P - W\| \cdot b. \quad (1)$$

На основі (1) вихід нейрона (його функція активації) описується виразом:

$$a = radbas(n) = e^{-n^2}. \quad (2)$$

Кожному вхідному вектору НМ відповідає певне вихідне або цільове значення, а коли є масиви вхідних та вихідних значень, то формується вектор приналежності вхід / ціль. Навчальна множина містить Q пар векторів вхід/ціль. Існує K класів, до яких може належати вхідний вектор. У результаті може бути утворена матриця зв'язності Tc розміром $K \times Q$, яка складається з нулів та одиниць. Рядки цієї матриці відповідають класам приналежності, а стовпці – векторам входу. Таким чином, якщо елемент $Tc(i, j)$ матриці зв'язності дорівнює 1, то це означає, що j -й вхідний вектор належить до класу i .

Кількість нейронів першого шару формується по кількості Q пар векторів вхід/ціль навчальної множини. Вихідний шар конкуренції містить K нейронів, відповідно K класів.

У загальному вигляді вектор-стовпець діагностичних ознак A_0 , за яким відбувається розпізнавання стану, виглядає:

$$A_0 = \begin{pmatrix} a_1^0 \\ a_2^0 \\ \dots \\ a_n^0 \end{pmatrix}. \quad (3)$$

Розглянемо задачу багатокласової діагностики за вектором діагностичних ознак A_0 , який містить 5 складових. Наприклад, до діагностичних ознак a_i можуть відноситись спектральні, кореляційні, фрактальні, статистичні характеристики вимірюваних сигналів. Однак, їх кількість може варіюватися в залежності від кількості вимірювальних каналів, діагностичної цінності ознак і кількості класів ТС, проте бажано мати у векторі не менше 3-х ознак для достовірної класифікації. Для вектора, що містить 5 ознак, стан об'єкту контролю описується 6 класами. Загальна схема класифікатора стану системи моніторингу зображена на рис. 4.

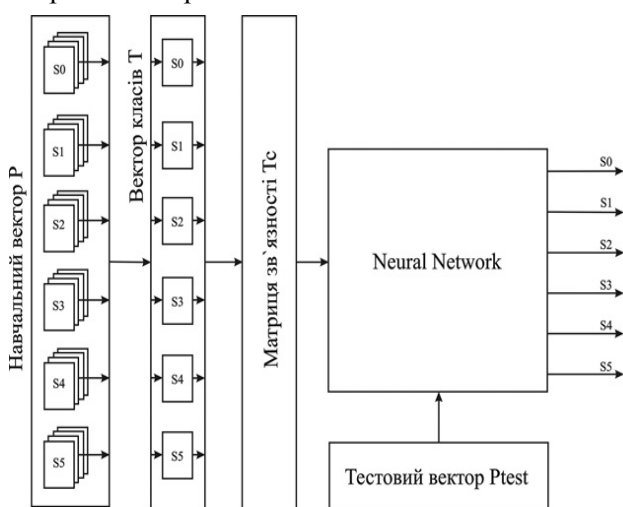


Рисунок 4 – Загальна схема класифікатора стану інформаційної системи діагностики, побудованого на основі нейронних мереж

Клас S_0 відповідає нормальному функціонуванню, для якого встановлено допустиму похибку $\pm 5\%$ від параметрів, що характеризують працездатний бездефектний стан об'єкту контролю. До цього класу також належать всі входні множини, величини параметрів ознак яких не перевищують похибку $\Delta = \pm 5\%$. До класу S_1 відносяться входні вектори, один будь-який із параметрів перевищує гранично допустиму похибку $\Delta = \pm 5\%$. До класу S_2 відносяться входні вектори, в яких одночасно два будь-які параметри перевищують $\Delta = \pm 5\%$. До класу S_3 відносяться входні вектори, в яких одночасно три будь-які параметри перевищують допустиму похибку $\Delta = \pm 5\%$. До класу S_4 відносяться входні вектори, в яких одночасно чотири будь-які параметри перевищують допустиму похибку $\Delta = \pm 5\%$. До класу S_5 відносяться входні вектори, в яких одночасно всі параметри ознак

перевищують допустиму похибку $\Delta = \pm 5\%$. Зазвичай, останні два стани не діагностують, тому що вони відповідають майже та/або повному виходу з ладу контрольованого об'єкту та не потребують ретельного моніторингу. Таким чином, формулюється задача багатокласової діагностики: розпізнавання станів $S_0 - S_5$ за вектором діагностичних ознак.

Для кожного з класів формуються вектори навчальних множин такі, щоб відповідали вищезазначеним умовам. Навчальними векторами класу S_0 є: сам вектор діагностичних ознак A_0 ; два вектори з максимально допустимими похибками $(+\Delta \cdot A_0)$ та $(-\Delta \cdot A_0)$; різні комбінації відхилень елементів A_0 у допустимому проміжку похибок $[0,95; 1,05]$.

$$P_{S_0} = [A_0; \pm \Delta \cdot A_0; D \cdot A_0], \quad (4)$$

де

$$D = \begin{pmatrix} \forall [0,95; 1,05] & \forall [0,95; 1,05] & \dots & \forall [0,95; 1,05] \\ \forall [0,95; 1,05] & \forall [0,95; 1,05] & \dots & \forall [0,95; 1,05] \\ \vdots & \vdots & \ddots & \vdots \\ \forall [0,95; 1,05] & \forall [0,95; 1,05] & \dots & \forall [0,95; 1,05] \end{pmatrix}. \quad (5)$$

Для кожного стану (від S_1 до S_5) були обрані такі граничні похибки елементів навчальної множини векторів: $\pm 5,5\%$; $\pm 10\%$; $\pm 15\%$; $\pm 20\%$; $\pm 25\%$; $\pm 50\%$. При цьому, кожна множина характеризується всіма можливими комбінаціями. Тобто, для визначення стану S_1 НМ навчається на такій сукупності векторів (у загальному випадку):

$$P_{1N}^{S_1} = \begin{pmatrix} \pm \Delta_N \cdot a_1^0 \\ a_2^0 \\ \dots \\ a_n^0 \end{pmatrix}; P_{2N}^{S_1} = \begin{pmatrix} a_1^0 \\ \pm \Delta_N \cdot a_2^0 \\ \dots \\ a_n^0 \end{pmatrix}; \dots; P_{nN}^{S_1} = \begin{pmatrix} a_1^0 \\ a_2^0 \\ \dots \\ \pm \Delta_N \cdot a_n^0 \end{pmatrix}, \quad (6)$$

де $\pm \Delta_N$ – задані похибки для навчання.

З формули (6) формується єдиний вектор входу класу S_1 :

$$P_{S_1} = [P_{1N}^{S_1}; P_{2N}^{S_1}; \dots; P_{nN}^{S_1}]. \quad (7)$$

Оскільки вектор діагностичних ознак має 5 елементів, то навчальні вектори також мають 5 елементів. У матричному записі вираз (7) можна представити:

$$P_{S_1} = \Delta_N^{S_1} \cdot A_0, \quad (8)$$

де $\Delta_N^{S_1}$ – матриця розміром $m \times n$ (n – кількість елементів вектору-стовпця A_0 ; m – кількість можливих комбінацій, що відповідають стану S_1):

$$\Delta_N^{S_1} = \begin{pmatrix} \pm\Delta_N & 1 & \dots & 1 \\ 1 & \pm\Delta_N & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & \pm\Delta_N \end{pmatrix}. \quad (9)$$

Для стану $S1$ в матриці $\Delta_N^{S_1}$ діагональні елементи відповідають похибкам $\pm\Delta_N^{S_1}$. Всі інші елементи цієї матриці дорівнюють 1, що свідчить про незмінність відповідних елементів вектора A_0 , але можуть приймати будь-яке значення з проміжку допустимих похибок $[0,95; 1,05]$.

Для стану $S2$ навчання в матричному вигляді відбувається за множиною векторів:

$$P_{S_2} = \Delta_N^{S_2} \cdot A_0, \quad (10)$$

де

$$\Delta_N^{S_2} = \begin{pmatrix} \pm\Delta_N & \pm\Delta_N & 1 & \dots & 1 & 1 \\ 1 & \pm\Delta_N & \pm\Delta_N & \dots & 1 & 1 \\ \pm\Delta_N & 1 & 1 & \dots & \pm\Delta_N & 1 \\ 1 & 1 & \pm\Delta_N & \ddots & 1 & \pm\Delta_N \\ 1 & 1 & 1 & \dots & \pm\Delta_N & \pm\Delta_N \end{pmatrix}. \quad (11)$$

Матриця $\Delta_N^{S_2}$ описує всі комбінації будь-яких двох елементів відмінних від вектора ознак, що відповідають умові класу $S2$. Як і для $\Delta_N^{S_1}$, одиничні елементи $\Delta_N^{S_2}$ вказують на незмінні ознаки вектора A_0 . Ці елементи також можуть приймати будь-яке значення в межах допустимих похибок.

Для стану $S3$ навчання в матричному вигляді відбувається наступним чином:

$$P_{S_3} = \Delta_N^{S_3} \cdot A_0, \quad (12)$$

де

$$\Delta_N^{S_3} = \begin{pmatrix} \pm\Delta_N & \pm\Delta_N & \pm\Delta_N & \dots & 1 & 1 \\ \pm\Delta_N & \pm\Delta_N & \pm\Delta_N & \dots & \pm\Delta_N & 1 \\ \pm\Delta_N & 1 & 1 & \dots & 1 & \pm\Delta_N \\ 1 & \pm\Delta_N & 1 & \ddots & \pm\Delta_N & \pm\Delta_N \\ 1 & 1 & \pm\Delta_N & \dots & \pm\Delta_N & \pm\Delta_N \end{pmatrix} \quad (13)$$

Матриця $\Delta_N^{S_3}$ описує всі комбінації будь-яких трьох елементів відмінних від вектора ознак, що відповідають умові класу $S3$.

Для стану $S4$ матриця $\Delta_N^{S_4}$ описує всі комбінації будь-яких чотирьох елементів відмінних від вектора ознак, що відповідають

умові класу:

$$\Delta_N^{S_4} = \begin{pmatrix} \pm\Delta_N & \pm\Delta_N & \pm\Delta_N & \pm\Delta_N & 1 \\ \pm\Delta_N & \pm\Delta_N & \pm\Delta_N & 1 & \pm\Delta_N \\ \pm\Delta_N & \pm\Delta_N & 1 & \pm\Delta_N & \pm\Delta_N \\ \pm\Delta_N & 1 & \pm\Delta_N & \pm\Delta_N & \pm\Delta_N \\ 1 & \pm\Delta_N & \pm\Delta_N & \pm\Delta_N & \pm\Delta_N \end{pmatrix}. \quad (14)$$

Для стану $S5$ матриця $\Delta_N^{S_5}$ виглядає наступним чином:

$$\Delta_N^{S_5} = \begin{pmatrix} \pm\Delta_N \\ \pm\Delta_N \\ \pm\Delta_N \\ \pm\Delta_N \\ \pm\Delta_N \end{pmatrix}. \quad (15)$$

Відповідно до формули (15), $\Delta_N^{S_5}$ – це матриця-стовпець, елементами якої є похибки, більші за допустиму. Одиничні елементи у $\Delta_N^{S_5}$ відсутні, оскільки клас $S5$ характеризує такий ТС об'єкту контролю, коли спостерігається перевищення порогових значень за всіма діагностичними ознаками, що може характеризувати передаварійний стан об'єкту контролю.

Вектори навчання станів $S1 - S5$ у матричному вигляді мають узагальнений вид:

$$P_{S_k} = \Delta_N^{S_k} \cdot A_0. \quad (16)$$

Загальна навчальна множина представляє собою матрицю:

$$P = [P_{S_0}; P_{S_1}; P_{S_2}; P_{S_3}; P_{S_4}; P_{S_5}]. \quad (17)$$

Рядки матриці P відповідають кількості діагностичних ознак, а кількість стовпчиків – дорівнює R вхідним векторам. На рис. 5 показано кількість сформованих навчальних векторів по класах. Їх загальна кількість складає $R = 378$. Як видно, клас $S0$ навчається на $R_0 = 6$ векторах, класи $S1$ та $S4$ – на $R_1 = R_4 = 60$, класи $S2$ та $S3$ – на $R_2 = R_3 = 120$, клас $S5$ на $R_5 = 12$ векторах.

Після етапу навчання НМ необхідно перевірити правильність її функціонування. Для цього на вхід мережі подається тестова множина векторів, кожен з яких відноситься до певного класу $S0 - S5$. Сформовано 3 варіанти тестових множин. Для першого варіанту значення похибки складає $\pm 2,5\%$, тобто елементи всіх вхідних векторів не перевищують допустиму

похибку в $\pm 5\%$. В другому варіанті для класу S_0 елементи всіх вхідних векторів стану знаходяться в межах діапазону A , а діагностичні параметри для станів $S_1 - S_5$ мають відхилення на $\pm 9\%$ від значень A_0 , відповідно до класу. Тобто, для класу S_1 будь-який один елемент тестового вектору має похибку $\pm 9\%$, а інші не відрізняються від вектора діагностичних ознак A_0 більше, ніж на $\pm 5\%$. Аналогічно для станів $S_2 - S_5$, де кількість елементів, відмінних від A_0 на $\pm 9\%$, у відповідності до класу два, три і т. д. В третьому випадку тестова множина векторів класів $S_0 - S_5$ формується за алгоритмом, який наведено для варіанту 2, зі збільшеною похибкою елементів до $\pm 12\%$.




Рисунок 5 – Кількість навчальних векторів по класах станів $S_0 - S_5$

На рис. 6 наведено кількість векторів тестової множини по класах. Їх загальна кількість складає 84. Клас S_0 тестується на 22 векторах, класи S_1 та S_4 – на 10-х, класи S_2 та S_3 – на 20-х, клас S_5 на 2-х векторах для кожного з трьох варіантів множин.

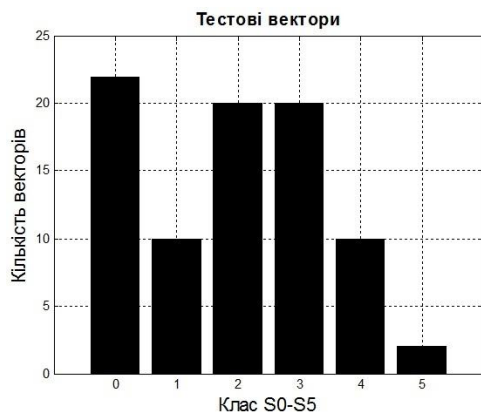


Рисунок 6 – Кількість тестових векторів по класах $S_0 - S_5$ для класифікатора станів інформаційної діагностичної системи

Процес навчання НМ вимагає набір прикладів її бажаної класифікації – входів P і бажаних (цільових) виходів T . Такий метод називається навчання «з учителем». Ймовірнісна мережа PNN навчається саме за таким принципом. Для визначеної вище навчальної множини, кожному вектору входу класів $S_0 - S_5$ повинно відповідати цільове значення класу. Оскільки, навчальних векторів $R = 378$, то вектор-рядок цільових виходів має R цілей. У програмній реалізації класам присвоюються такі значення: $S_0 - 1$, $S_1 - 2$, $S_2 - 3$, $S_3 - 4$, $S_4 - 5$, $S_5 - 6$. Вихід T_0 має розмір $1 \times R_0$ всі елементи якого дорівнюють 1; T_1 розмірністю $1 \times R_1$ з елементами 2; $T_2 - 1 \times R_2$ з елементами 3 і т.д.

Вектор цільових виходів T дорівнює:

$$T = [T_0; T_1; T_2; T_3; T_4; T_5]. \quad (18)$$

Вектор T також можна назвати вектором індексів класів.

Як зазначалося вище, кожній парі векторів вхід/ціль можна поставити у відповідність матрицю зв'язності T_c . Повна матриця зв'язності має вигляд:

$$T_c = \begin{matrix} & \begin{matrix} 1 & R_0 & R_1 & R_2 & R_3 & R_4 & R_5 \end{matrix} \\ \begin{matrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{matrix} & \begin{pmatrix} \dots 1 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 \\ \dots 0 & 1 & \dots 1 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 \\ \dots 0 & 0 & \dots 0 & 1 & \dots 1 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 \\ \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 1 & \dots 1 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 \\ \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 1 & \dots 1 & 0 & \dots 0 & 0 & \dots 0 \\ \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 0 & \dots 0 & 1 & \dots 1 \end{pmatrix} \end{matrix}, \quad (19)$$

яка визначає приналежність перших R_0 векторів до класу S_0 , від R_0+1 до R_1 векторів - до класу S_1 , від R_1+1 до R_2 - до класу S_2 і т. д.

Масиви P і T_c задають навчальну множину, що дозволяє сформувати мережу, промодельовати її, використовуючи масив входів P , та впевнитись, що мережа правильно вирішує задачу класифікації на елементах тестової множини.

Для програмної реалізації розробленої НМ використано пакет прикладних програм (ППП) Matlab. Функція $net = \text{newpnn}(P, T, \text{spread})$ формує в ППП Matlab ймовірнісну мережу PNN . Spread – параметр впливу, за замовчуванням 1,0. Перший шар PNN мережі побудований на радіально-базисних нейронах, які мають функцію активації з нормальним (Гаусівським) розподілом. Точність класифікації залежить від параметру впливу spread . Цей параметр spread відповідає σ_j^2 в нормальному розподілі, який встановлює перекриття радіально-базисних

функцій. Якщо параметр впливу близький до нуля, то мережа буде діяти як класифікатор станів. Коли параметр spread зростає, то ймовірна мережа буде враховувати вплив прилеглих сусідніх станів. При значно малих значеннях spread функція Гаусівського розподілу охоплює малу кількість впливів, що відображається на якості оцінки класифікатора. Тобто, він впливає на похибку навчання та подальшу ефективність класифікації.

На рис. 7 наведено блок-схему ймовірної НМ *PNN* у програмному середовищі *Matlab*, де $x\{1\}$ – вхідна множина векторів, $y\{1\}$ – результат.

Розкритий блок *Neural Network* представлено на рис. 8, складовими якого є 2 шари: *layer 1* і *layer 2*, та 2 процеси: *process input* і *output*, які виконують функції трансформації даних, що поступають на НМ та отримуються після проходження через НМ, в зрозумілому для програмного середовища коді. Структура сформованої НМ повністю відповідає ймовірній *PNN*-мережі. На вхід системи подається масив $x\{1\}$, який відповідає вектору входу P . Цей вхід подається на перший

радіально-базисний шар НМ. Вихід першого шару є $a\{1\}$ – масив розміром $M \times 1$, де M – кількість нейронів першого шару. Входом конкуруючого другого шару є масив $a\{1\}$. На виході НМ отримуємо матрицю (або масив) $y\{1\}$, що показує результат класифікації.

Структуру першого шару НМ класифікатора стану інформаційної системи діагностики наведено на рис. 9, що підтверджує факт його побудови на нейронах з радіально-базисними функціями активації. Блок *TDL* слугує лінією затримки масиву вхідних векторів; *weight* – блок, що містить ваги шару НМ; *bias* – зсув b , який потрібен для корекції чутливості нейрона.

Структура другого шару НМ класифікатора стану інформаційної системи діагностики наведена на рис. 10. На відміну від першого шару, в цьому відсутні зміщення та нейрони мають конкуруючу функцію активації *compnet*, яка формує на виході значення 1, якщо вхідний вектор відповідає певному класу, і 0 - в інших випадках. Тобто, шар конкуренції обчислює ймовірність приналежності вхідного вектора до того чи іншого класу, а потім вибирає клас з найбільшою ймовірністю.




Рисунок 7 – Структурна схема блоку класифікатора в програмному середовищі Matlab




Рисунок 8 – Блок-схема сформованої нейронної мережі для класифікатора стану інформаційної системи діагностики




Рисунок 9 – Перший шар нейронної мережі класифікатора стану інформаційної системи діагностики

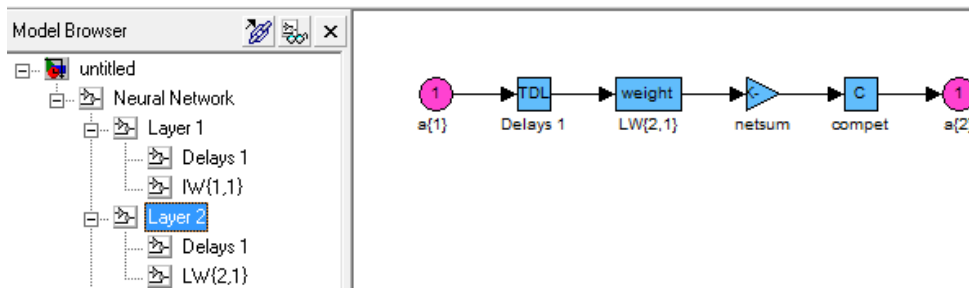


Рисунок 10 – Другий шар нейронної мережі класифікатора стану інформаційної системи діагностики

Отримано структури $IW\{1,1\}$ та $LW\{2,1\}$, що відповідають ваговим матрицям першого та другого шарів відповідно, які наведено на рис. 11 та рис. 12.

прихованого першого шару, що дорівнює кількості навчальних векторів. Матриця ваг $IW\{1,1\}$ має розмірність $i \times j$:

$$IW\{1,1\} = (w_{i,j}), \quad (20)$$

де $i = 1 \dots R$ (кількість навчальних векторів), $j = 1 \dots n$ (n – кількість елементів матриці діагностичних ознак).

Блок-функція $dist$ обчислює евклідову відстань між вектором входу P і вектором ваг W нейрона. Евклідова відстань розраховується за формулою:

$$\|P - W\| = \|p_i - w_j\| = \sqrt{(p_i - w_j)^T \cdot (p_i - w_j)}. \quad (21)$$

Шар конкуренції має 6 нейронів, що відповідають 6 станам об'єкту контролю (класи $S0 - S5$). Принцип дії – нейрон переможець «забирає усе». Тобто, той вихід нейрона, значення відстані до параметрів певного класу якого є меншим, набуває 1, а іншим нейронам присвоюються нулі.

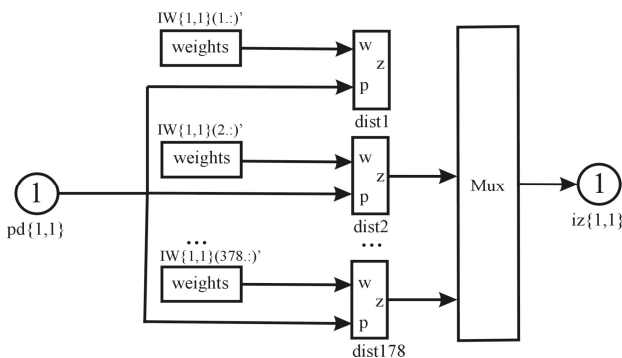


Рисунок 11 – Матриця ваг $IW\{1,1\}$ першого шару нейронної мережі класифікатора стану інформаційної системи діагностики

Великим недоліком мережі PNN є необхідність значної кількості нейронів

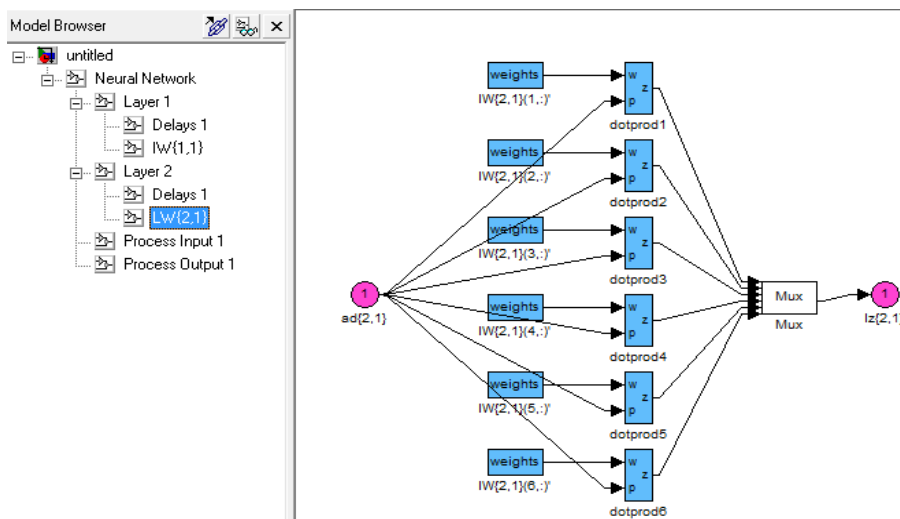


Рисунок 12 – Матриця ваг $LW\{2,1\}$ другого шару нейронної мережі класифікатора стану інформаційної системи діагностики

Таким чином, побудовано класифікатор на ймовірнісній НМ, який може бути використано у системі структурного моніторингу.

ВИСНОВКИ

Побудована НМ для класифікатора стану елементів конструкції багатоканальної системи діагностики, яка призначена для визначення поточного ТС в умовах експлуатації та прийняття рішень щодо подальшого функціонування об'єкта. Обґрунтовано застосування ймовірнісної нейронної мережі для побудови класифікатора технічного стану об'єкту в системі моніторингу ТС елементів конструкції в експлуатації, що відповідає концепції SHM.

Сформовано вектори навчальної множини ознак, що відповідають 6-ти різним класам і за якими проведено навчання «з учителем», для налаштування параметрів НМ. Сформовано 3 варіанти векторів тестової множини для перевірки працездатності побудованого класифікатора та ефективності його функціонування. За приналежністю вхідних векторів до цільового класу отримано вектор індексів класів та матрицю зв'язності. Обґрунтовано вплив на похибку навчання та ефективність класифікації параметра впливу *spread*, який встановлює перекриття радіально-базисних функцій та відповідає σ_j^2 в нормальному розподілі.

В програмному середовищі *Matlab* розроблено блок-схеми класифікатора, що побудований на ймовірнісній мережі PNN з двома шарами, нейрони першого з яких мають радіально-базисні функції активації, а другий – шар конкуренції. Для кожного з шарів НМ отримано та приведено структури матриць ваг.

Розроблений класифікатор буде використаний для оцінки ефективності розпізнавання в подальших наукових дослідженнях.

1. Бурау Н. І. Структурно-функціональний синтез систем діагностики конструкцій в експлуатації / Н. І. Бурау, О. М. Павловський, Д. В. Шевчук // Вісник Тернопільського національного технічного університету. – 2013. – № 4 (72). – С. 77-86.
2. Рупіч С. С. Ефективність діагностичних систем на основі концепції *Structural Health Monitoring* / С. С. Рупіч / Ефективність інженерних рішень у приладобудуванні : збірник тез доповідей: ювілейна X науково-практична конференція студентів, аспірантів та молодих вчених. – К. : ВПІ ВПК «Політехніка». – 2014. – С. 50.
3. *Structural Health Monitoring 2003: From Diagnostics & Prognostics to Structural Health Menegment* // *Proceedings of the 4th International Workshop on Structural Health Monitoring*. - Stanford University, Stanford, CA., September 15-17. - 2003. - 1552 p.
4. Speckmann H. *Structural Health Monitoring: a contribution to the intelligent aircraft structure*. [Електронний ресурс] / Н. Speckmann, H. Roesner // *Proc. 9th European NDT Confer. (ECNDT - 25-29 Sept. - 2006, Berlin, Germany*. – Режим доступу: <http://www.ndt.net/article/ecndt2006/doc/Tu.1.1.1.pdf>.
5. Мецєряков В. А. *Применение нейросетевых технологий для решения задачи дискриминантного анализа в Matlab* / В. А. Мецєряков. – Режим доступа: <http://matlab.ru/upload/resources/EDU%20Conf/pp%20360-366%20Mestherjakov.pdf>.
6. Бурау Н. І. *Розпізнавання технічного стану об'єктів на основі штучних нейронних мереж: монографія* / Н. І. Бурау, О. В. Зажицький. – К. : НАУ, 2014. – 120 с.
7. Медведев. В. С. *Нейронные сети MATLAB 6* / В. С. Медведев, В. Г. Потемкин. – М. : Диалог МИФИ, 2002. – 488 с.

Поступила в редакцію 13.12.2015р.

Рекомендували до друку: докт. техн. наук, проф. Райтер П. М., докт. фіз.-мат. наук, проф. Снарський А. О.