

МЕТОД ПІДВИЩЕННЯ РОБАСТНОСТІ НЕЙРОМЕРЕЖЕВОЇ МОДЕЛІ КОНТРОЛЮ І ДІАГНОСТИКИ ТЕХНІЧНОГО СТАНУ АВІАЦІЙНОГО ДВИГУНА ТВ3-117 В ПОЛЬОТНИХ РЕЖИМАХ**С. І. Владов, Ю. М. Шмельов, С. А. Грибанова, О. В. Гусарова, Н. В. Подгорних**Кременчуцький льотний коледж Харківського національного університету внутрішніх справ
вул. Перемоги, 17/6, м. Кременчук, 39605, Україна. E-mail: ser26101968@gmail.com

Розроблено метод підвищення робастності нейромережевої моделі контролю і діагностики технічного стану авіаційного двигуна ТВ3-117 у польотних режимах, який дозволяє зменшити помилки під час розрахунків контрольованих параметрів зазначеного авіаційного двигуна. При цьому застосовано метод нейроінформатики при розробці нейромережевої моделі авіаційного двигуна ТВ3-117, градієнтний метод з адаптивним кроком під час навчання нейронної мережі, метод зворотного поширення задля навчання нейрорегулятора, метод зворотного поширення помилки задля навчання нейромодулятора. Для розв'язання задачі редукції нейромережевої моделі розроблено алгоритм на основі багатокритеріального навчання. У роботі здійснено оцінку робастності (здатність до узагальнення нейромережевої моделі) на основі обчислення специфічної міри складності мережі – «міри Вапніка–Червоненкіса» (VCdim), за допомогою якої задля збільшення робастності моделі необхідно зменшити кількість міжнейронних зв'язків при збереженні точності обчислень. У ході досліджень проведено обчислювальні експерименти, в яких нейронні мережі початково однакової топології піддавалися редукції трьома методами – запропонованим алгоритмом і двома стандартними, а саме, методом Optimal Brain Damage (OBD) й методом штрафних функцій. Розрахунково-експериментальним шляхом доведено, що розроблений алгоритм редукції нейронних мереж підвищує робастність побудованої на її основі моделі, та алгоритм перевершує стандартні методи за точністю і швидкістю навчання. Наукова новизна отриманих результатів полягає в тому, що удосконалено метод підвищення робастності нейромережевої моделі контролю і діагностики технічного стану авіаційних газотурбінних двигунів за рахунок комбінації системи нейромережевого контролю з емулятором і контролером, що застосовується для контролю і діагностики технічного стану авіаційного двигуна ТВ3-117 у польотних режимах. Це дозволило з алгоритмом на основі багатокритеріального навчання зменшити середні помилки навчання нейронної мережі приблизно на 80 та 70 % відповідно порівняно з методом Optimal Brain Damage (OBD) й методом штрафних функцій відповідно.

Ключові слова: авіаційний двигун, нейромережева модель, робастність, помилка навчання, синаптичні зв'язки.

МЕТОД ПОВЫШЕНИЯ РОБАСТНОСТИ НЕЙРОСЕТЕВОЙ МОДЕЛИ КОНТРОЛЯ И ДИАГНОСТИКИ ТЕХНИЧЕСКОГО СОСТОЯНИЯ АВИАЦИОННОГО ДВИГАТЕЛЯ ТВ3-117 В ПОЛЕТНЫХ РЕЖИМАХ**С. И. Владов, Ю. Н. Шмелев, С. А. Грибанова, О. В. Гусарова, Н. В. Подгорных**Кременчугский летный колледж Харьковского национального университета внутренних дел
ул. Победы, 17/6, г. Кременчуг, 39605, Украина. E-mail: ser26101968@gmail.com

Разработан метод повышения робастности нейросетевой модели контроля и диагностики технического состояния авиационного двигателя ТВ3-117 в полетных режимах, который позволяет уменьшить ошибки в расчетах контролируемых параметров указанного авиационного двигателя. При этом применен метод нейроинформатики при разработке нейросетевой модели авиационного двигателя ТВ3-117, градиентный метод с адаптивным шагом при обучении нейронной сети, метод обратного распространения для обучения нейрорегулятора, метод обратного распространения ошибки для обучения нейромодулятора. Для решения задачи редукции нейросетевой модели разработан алгоритм на основе многокритериального обучения. В работе осуществлена оценка робастности (способность к обобщению нейросетевой модели) на основе вычисления специфической степени сложности сети – «меры Вапника–Червоненкіса» (VCdim), с помощью которой для увеличения робастности модели необходимо уменьшить количество межнейронных связей при сохранении точности вычислений. В ходе исследований проведены вычислительные эксперименты, в которых нейронные сети первоначально одинаковой топологии подвергались редукции тремя методами – предложенным алгоритмом и двумя стандартными, а именно, методом Optimal Brain Damage (OBD) и методом штрафных функций. Расчетно-экспериментальным путем доказано, что разработанный алгоритм редукции нейронных сетей повышает робастность разработанной на ее основе модели, и алгоритм превосходит стандартные методы по точности и скорости обучения. Научная новизна полученных результатов заключается в том, что усовершенствовано метод повышения робастности нейросетевой модели контроля и диагностики технического состояния авиационных газотурбинных двигателей за счет комбинации системы нейросетевого контроля с эмулятором и контроллером, который применяется для контроля и диагностики технического состояния авиационного двигателя ТВ3-117 в полетных режимах. Это позволило с алгоритмом на основе многокритериального обучение уменьшить средние ошибки обучения нейронной сети примерно на 80 и 70 % соответственно по сравнению с методом Optimal Brain Damage (OBD) и методом штрафных функций соответственно.

Ключевые слова: авиационный двигатель, нейросетевая модель, робастность, ошибка обучения, синаптические связи.

АКТУАЛЬНІСТЬ РОБОТИ. Відомо, що на етапі експлуатації авіаційного двигуна ТВ3-117 у польотних режимах контролюються технологічні його параметри в різних режимах, прямо або опосередковано. Оскільки процеси, що протікають в авіаційному двигуні ТВ3-117, носять нестационарний характер, його параметри залежать від зовнішніх умов, причому вид такої залежності часто не визначений, склад вимірних параметрів може відрізнятися в окремому випадку, може бути неповним тощо, то задачу контролю і діагностики технічного стану авіаційного двигуна ТВ3-117 можна віднести до задач в умовах неповної і нечіткої інформації [1]. Подібні задачі в даний час успішно розв'язуються за допомогою інтелектуальних нейромережових систем і моделей [2–5].

Робастність моделі, тобто стійкість результатів моделювання до збурень вхідних даних, є однією з найважливіших вимог при моделюванні технічних систем. При нейромережевому моделюванні поняття робастності часто замінюється специфічним терміном «здатність до узагальнення», буквально що означає збереження мережею точності обчислень для наборів даних, які не беруть участі в безпосередньому навчанні. Здатність до узагальнення досягається правильним настроюванням синаптичних ваг у процесі навчання.

Отже, метою роботи є розробка методу підвищення робастності нейромережевої моделі контролю і діагностики технічного стану авіаційного двигуна ТВ3-117 у польотних режимах, що дозволить зменшити помилку при розрахунках контрольованих параметрів авіаційного двигуна ТВ3-117.

МАТЕРІАЛ І РЕЗУЛЬТАТИ ДОСЛІДЖЕНЬ. Для розробки нейромережевої моделі необхідно володіти набором вимірюваних параметрів модельованого об'єкта у вигляді кортежів «вхід–вихід». Викорис-

товується інформація, отримана в процесі польоту повітряного судна. Описані параметри використовуються в якості вхідної інформації. Вихідною інформацією є режим роботи авіаційного двигуна ТВ3-117.

Для виявлення оптимальної структури і топології нейронної мережі було проведено кілька розвідувальних експериментів. У результаті було зроблений вибір на користь багатошарового перцептронну з одним прихованим шаром. Функції активації шарів мережі вибиралися з умови їх безперервності і диференційованості, оскільки саме такий вибір функцій гарантує, що побудована нейронна мережа буде універсальним апроксиматором, і може моделювати залежності будь-якої складності. У результаті, функція активації прихованого шару визначена у вигляді гіперболічного тангенса, вихідного шару – лінійної функції.

У [6] визначено, що параметри технічного стану авіаційного двигуна ТВ3-117 наступні: тиск повітря на вході в двигун (x_1), температура повітря на вході в двигун (x_2), частота обертання вентилятора (x_3), тиск повітря за компресором (x_4), частота обертання компресора (x_5), температура газу за турбіною (x_6), тиск газу за турбіною (x_7), рівень масла в масляній системі (x_8), наявність стружки в маслі (x_9), займання палива в камері згоряння (x_{10}), температура палива на вході в двигун (x_{11}), тиск палива на вході в двигун (x_{12}), температура масла на вході в двигун (x_{13}), тиск масла на вході в двигун (x_{14}), діаметр критичного перетину сопла (x_{15}), вібрація корпусу двигуна (x_{16}), помпаж двигуна (x_{17}), вважається, що дані параметри утворюють багатошарову нейронну мережу з $n = 17$ входами й одним виходом (рис. 1). Кожен i -й нейрон першого шару ($i = 1, 2, \dots, m = 17$) має $n = 17$ входів, які прописані вагами $w_{1i}, w_{2i}, \dots, w_{ni}$.

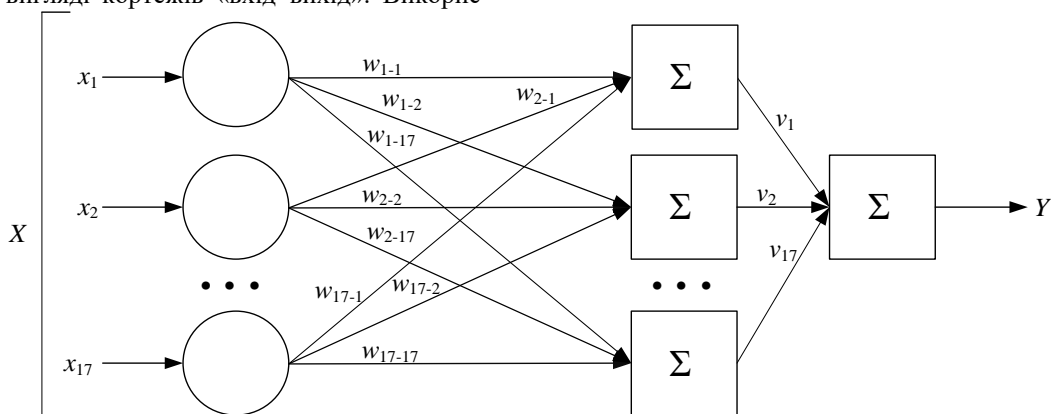


Рисунок 1 – Структура узагальненої нейронної мережі

подаючи на входи будь-які числа x_1, x_2, \dots, x_{17} , отримуємо на виході значення деякої функції $Y = F(x_1, x_2, \dots, x_{17})$, яке є відповіддю (реакцією) мережі. Відомо, що відповідь мережі залежить як від вхідного сигналу, так і від значень її внутрішніх параметрів – ваг нейронів, тобто:

$$F(x_1, x_2, \dots, x_{17}) = \sum_{i=1}^{m=17} v_i \sigma \left(\sum_{j=0}^{n=17} x_j w_{ji} \right); \quad (1)$$

де $F(x_1, x_2, \dots, x_{17})$ – будь-яка безперервна функція, певна на обмеженій множині; $\sigma(s) = \frac{1}{1 + e^{-as}}$ – сигмоїдальна функція.

Застосувавши теорему Колмогорова $F(x_1, x_2, \dots, x_n) = \sum_{i=1}^{2n+1} g_i \left(\sum_{j=1}^n h_{ij}(x_j) \right)$, де g_i і h_{ij} – безперервні функції, причому h_{ij} не залежить від функції F , для $m = 1 \dots 17$ змінних, з'ясовано, що для ре-

лізації функції $m = 1 \dots 17$ змінних досить операцій підсумовування і композиції функції однієї змінної.

Оскільки найважливішим властивістю нейронних мереж є їх можливість навчатися на основі даних про досліджуваній об'єкт і, в результаті навчання підвищувати свою функціональність, пропонується застосувати адаптивний крок навчання нейронної мережі, який реалізується у вигляді градієнтного методу [7], в якому зміна ваг описується залежністю:

$$\overline{w}_{k+1} = \overline{w}_k + \eta_k \overline{p}_k; \quad (2)$$

де η_k – розмір кроку на k -й ітерації, а вектор p_k задає напрям руху й обчислюється за формулою:

$$\overline{p}_k = \overline{g}_k + \sum_{i=1}^{\min(k-1, m)} \beta_i \overline{g}_{k-i}; \quad (3)$$

де вектор g_j задає напрям антиградієнту на j -й ітерації; β_i – коефіцієнт, який визначає вагу i -го градієнта; m визначає кількість запам'ятовуваних градієнтів; k – порядковий номер поточної ітерації.

Градієнтний метод навчання за (3) отримано при $m = 0$, а методи сполучених градієнтів, які найбільш часто вживаються при навчанні нейронних мереж, виходять шляхом підсумовування всіх попередніх напрямків (при $m = \infty$).

Загальний алгоритм адаптивного метода являє собою [7]:

1. Початок.
2. Вибір стартової точки з деякими координатами ($x_0; y_0; \dots$).
3. Перевірка критерію зупинки (число ітерацій, середньоквадратична помилка тощо).
4. Обчислення антиградієнта в поточній точці \overline{g}_j (на першій ітерації стартова точка).
5. Занесення поточного напрямку до стеку напрямків.
6. Обчислення вектору напрямку за (3).
7. Переміщення за обчисленим p_k у нову точку.
8. Повернення до кроку 2. Якщо критерій зупинки позитивний, то закінчуємо алгоритм, якщо ні – переходимо до кроку 3.
9. Кінець алгоритму. Маємо точку, близьку до мінімуму функції.

Даний метод навчання зводить до мінімуму втручання людини у навчання нейронних мереж, що робить його привабливим, оскільки не кожен користувач нейромережових технологій володіє знаннями в області методів оптимізації. Крім цього, метод є гнучким і налаштованим на навчальну вибірку методом навчання.

Навчання ж нейронної мережі з постійним кроком здійснюється за допомогою правила Хебба, яке полягає у тому, що навчання відбувається у результаті посилення сили зв'язку (синаптичної ваги) між одночасно активними нейронами. Виходячи з цього, часто використовуювані у мережі зв'язку посилюються, що пояснює феномен навчання шляхом повторення і звикання. Правило навчання Хебба записується наступним чином [8]:

$$w_{ij}(t+1) = w_{ij}(t) + x_i y_j; \quad (4)$$

при цьому передбачається, що $w_{ij}(0) = 0$, де t – час; x_i і y_j – відповідно вихідне значення i -го і j -го нейронів.

Постійний крок навчання нейронної мережі також реалізується за допомогою процедури навчання Розенблатта (навчання перцептрона), яка характеризується тим, що вагові коефіцієнти нейронної мережі змінюються тільки в тому випадку, якщо вихідна реакція мережі у не збігається з еталонною d , і містить швидкість навчання a і не змінює вагові коефіцієнти, якщо вихідні сигнали мережі збігаються з еталонними. Правило навчання Розенблатта у загальній формі має вигляд [8, С. 42–45]:

$$W(t+1) = W(t) - a(y-t)X = W(t) + a(t-y)X. \quad (5)$$

Для розв'язку задачі розпізнавання або наближення функцій багатошарові мережі прямого розповсюдження підлягають корекції вагових коефіцієнтів.

Це коригування базується на відомих методах тренування нейронних мереж, які складаються з трьох типів [9–12]:

1. Тренування з учителем. Задано набір тренувальних векторів – вхідні значення та бажані результати нейронної мережі. Вагові коефіцієнти у процесі навчання вибираються таким чином, щоб отримані результати були максимально наближені до бажаних результатів.

2. Тренування з оцінкою. Спочатку потрібний вектор вихідних сигналів не задано, однак за результатами роботи нейронна мережа отримує позитивний або негативний рейтинг.

3. Тренування без учителя. Установлюється набір векторів вхідних даних, які обробляються на основі законів самоорганізації, що призводить нейронну мережу до стану, в якому вона здатна розв'язувати задачі.

Схема нейромережового контролю з емулятором та контролером показана на рис. 2. У цьому випадку нейрорегулятор навчається на зворотній моделі об'єкта керування, а нейроемудлятор навчається за реальною моделлю об'єкта управління (двигуна).

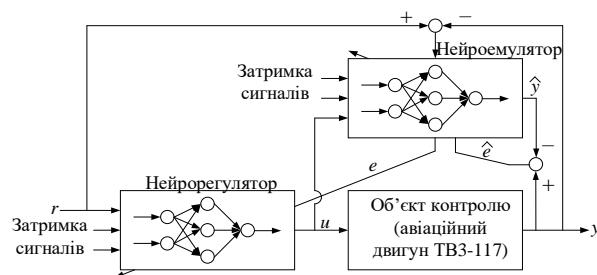


Рисунок 2 – Схема нейромережового контролю з емулятором і контролером

Нейрорегулятор навчається на основі нейроемудлятора, який навчається за методом зворотного поширення помилки. Для навчання нейроемудлятора визначається багатошарова мережа прямого розповсюдження з випадково вибраними вагами та навчальний набір, що складається з пар мережового входу – бажаного виходу $\{X, D\}$, а також вихідного значення мережі Y .

Задача навчання нейрорегулятора полягає в підборі вагових коефіцієнтів для мінімізації деякої цільової функції – суми квадратів помилок мережі на прикладах з навчальної множини, тобто

$$E(w) = \sum_{j,p} (y_{j,p}^{(N)} - d_{j,p})^2; \quad (6)$$

де $y_{j,p}^{(N)}$ – реальний вихід N -го вихідного шару мережі для p -го нейрона на j -му навчальному прикладі, $d_{j,p}$ – бажаний вихід.

Для знаходження мінімуму і визначення вагових коефіцієнтів, що входять до складу функції $y_{j,p}^{(N)}(x)$ застосовується метод найшвидшого спуску [13], при якому на кожному кроці навчання змінюються вагові коефіцієнти відповідно до виразу:

$$\Delta w_{ij}^{(n)} = -\eta \frac{\partial E}{\partial w_{ij}^{(n)}}; \quad (7)$$

де $w_{ij}^{(n)}$ – ваговий коефіцієнт, який скликає j -й нейрон n -го шару й i -й нейрон $(n-1)$ шару, η – параметр швидкості навчання.

Для цього, за отриманими ваговим коефіцієнтам мережі необхідно визначити частинні похідні цільової функції E :

$$\frac{\partial E}{\partial w_{ij}^{(n)}} = \frac{\partial E}{\partial y_j^{(n)}} \frac{\partial y_j^{(n)}}{\partial s_j^{(n)}} \frac{\partial s_j^{(n)}}{\partial w_{ij}^{(n)}}; \quad (8)$$

де $y_j^{(n)}$ – вихід, $s_j^{(n)}$ – сума входів j -го нейрона n -го шару. Знаючи функцію активації, можна обчислити $\frac{\partial y_j^{(n)}}{\partial s_j^{(n)}}$. Для сигмоїдальної функції $\frac{\partial y_j^{(n)}}{\partial s_j^{(n)}}$ буде дорівнювати:

$$\frac{\partial y_j^{(n)}}{\partial s_j^{(n)}} = \alpha y_j^{(n)} (1 - y_j^{(n)}). \quad (9)$$

Вихід i -го нейрона $(n-1)$ -го шару $\frac{\partial s_j^{(n)}}{\partial w_{ij}^{(n)}}$ можна представити у виді:

$$\frac{\partial s_j^{(n)}}{\partial w_{ij}^{(n)}} = y_j^{(n-1)}. \quad (10)$$

Таким чином, продиференціювавши (8) по $y_j^{(N)}$ з урахуванням (10) й теореми Колмогорова за вагами нейронів вихідного шару обчислимо частинні похідні цільової функції:

$$\frac{\partial E}{\partial w_{ij}^{(n)}} = (y_j^{(N)} - d_j) \frac{\partial y_j^{(N)}}{\partial s_j^{(N)}} y_j^{(N-1)}. \quad (11)$$

Увівши у (11) заміну $\delta_j^{(n)} = \frac{\partial E}{\partial y_j^{(n)}} \frac{\partial y_j^{(n)}}{\partial s_j^{(n)}}$, отримаємо значення нейронів у вихідному шарі:

$$\delta_j^{(N)} = (y_j^{(N)} - d_j) \frac{\partial y_j^{(N)}}{\partial s_j^{(N)}}. \quad (12)$$

Для знаходження $\alpha y_j^{(n)}$ вагових коефіцієнтів нейронів внутрішніх шарів представимо (8) у наступному вигляді:

$$\begin{aligned} \frac{\partial E}{\partial y_j^{(n)}} &= \sum_k \frac{\partial E}{\partial y_k^{(n+1)}} \frac{\partial y_k^{(n+1)}}{\partial s_k^{(n+1)}} \frac{\partial s_k^{(n+1)}}{\partial y_j^{(n)}} = \\ &= \sum_k \frac{\partial E}{\partial y_k^{(n+1)}} \frac{\partial y_k^{(n+1)}}{\partial s_k^{(n+1)}} w_{jk}^{(n+1)}. \end{aligned} \quad (13)$$

Зауважимо, що $\delta_k^{(n+1)} = \sum_k \frac{\partial E}{\partial y_k^{(n+1)}} \frac{\partial y_k^{(n+1)}}{\partial s_k^{(n+1)}}$, що дозволяє через (6) виразити значення $\delta_j^{(n)}$ нейронів n -го шару за допомогою нейронів $(n+1)$ -го $\delta_k^{(n+1)}$ шару. Отримати значення $\delta_j^{(n)}$ для всіх нейронів всіх шарів можна через рекурсивну формулу для останнього шару $\delta_j^{(N)}$:

$$\delta_j^{(n)} = \left(\sum_k \delta_k^{(n+1)} w_{jk}^{(n+1)} \right) \frac{dy_j}{ds_j}. \quad (14)$$

Таким чином, (7) для корекції вагових коефіцієнтів набирає вигляду:

$$\Delta w_{ij}^{(n)} = -\eta \delta_j^{(n)} y_j^{(n-1)}. \quad (15)$$

Навчання нейрорегулятора за допомогою алгоритму зворотного поширення відбувається в кілька етапів [13]:

1. Присвоєння довільних початкових значень вагових коефіцієнтів нейронної мережі і отримання значень цільової функції при даних значеннях.

2. На вхід нейронної мережі подається вектор навчальної множини, і потім обчислюються значення на виході нейронної мережі, які формують вектор пам'яті з значень кожного нейрона.

3. Обчислюються значення $\delta_j^{(N)}$ нейронів у вихідному шарі за (12), а за рекурсивною формулою (14) обчислюються значення $\delta_j^{(n)}$ за допомогою нейронів $(n+1)$ -го $\delta_k^{(n+1)}$ шару, а далі за (15) змінюються ваги нейронної мережі.

4. Коригування вагових коефіцієнтів мережі: $w_{ij}^{(n)} = -w_{ij}^{(n)} + \Delta w_{ij}^{(n)}$.

5. Обчислюється цільова функція за (6) й, якщо вона відносно мала, можна вважати, що нейронна мережа успішно пройшла процедуру навчання. В іншому випадку, переходимо до виконання кроку 2.

У даній роботі оцінка робастності або здатність до узагальнення нейромережевої моделі проводиться на основі обчислення специфічної міри складності мережі, що позначається як VCdim і, що отримала назву «міра Вапніка–Червоненкіса». У [14] доведено, чим менше значення міри, тим вище робастність мережі. Доведено також, що значення VCdim обернено пропорційно кількості нейронів синаптичних ваг. Отже, для збільшення робастності моделі потрібно зменшити кількість міжнейронних зв'язків при збереженні точності обчислень.

Задля підвищення робастності функціонування навченої нейромережевої моделі з обраними характеристиками описує наступний вираз:

$$y = \left(\sum_{j=1}^M w_{j1}^{(2)} \left(\frac{e^{\frac{2 \sum_{i=1}^N w_{ij}^{(1)} x_j - 1}{2 \sum_{i=1}^N w_{ij}^{(1)} x_j + 1}} - 1 \right) \right) - 1; \quad (16)$$

де N – кількість нейронів вхідного шару; M – кількість нейронів прихованого шару; x_j – вхідні параметри моделі; y – вихідний параметр моделі; $w_{ij}^{(1)}$ – синаптичні ваги прихованого (першого) шару $i = \overline{1, N}$, $j = \overline{1, M}$, визначені на етапі навчання.

Редукція нейромережевої моделі проводиться на етапі навчання, включивши в якості критерію успішності навчання додаткову умову: значення ваг всіх шарів мережі у процесі навчання повинні бути скориговані так, щоб:

- функція помилки мережі на навчальній множині була мінімальна;
- абсолютні значення синаптичних коефіцієнтів були мінімальні (в подальшому це призведе до їх виключення і спрощення структури нейронної мережі).

Тоді процес навчання описує двокритеріальною оптимізаційною задачею виду:

$$E^{(0)(l)}(w) = \frac{1}{2} \left(\sum_{j=1}^M w_{j1}^{(2)} \left(\frac{e^{\frac{2 \sum_{i=1}^N w_{ij}^{(1)} x_j - 1}{2 \sum_{i=1}^N w_{ij}^{(1)} x_j + 1}} - 1 \right) - d^{(l)} \right)^2 \Rightarrow \min; \quad (17)$$

$$E^{(l)}(w) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^M \frac{(w_{ij}^{(1)})^2}{1 + \sum_{k=1}^M (w_{ik}^{(1)})^2} + \frac{1}{2} \sum_{j=1}^M \frac{(w_{j1}^{(2)})^2}{1 + \sum_{k=1}^M (w_{k1}^{(2)})^2}; \quad (18)$$

де $l = \overline{1, q}$ – номер навчального прикладу; $d(l)$ – стаціонарний вихідний вектор з номером l . У представленій моделі умова (17) відповідає за мінімізацію помилки на навчальній множині, а (18) – за зменшення абсолютних значень ваг.

Багатокритеріальна задача (17)–(18) на кожній ітерації навчання розв'язується методом послідовних поступок, при цьому умова (16) вважається важливіше, ніж умова (17).

Для розв'язання задачі редукції нейромережевої моделі було розроблений алгоритм на основі багатокритеріального навчання:

1. За наявного масиву вихідних даних задати:
 - 1.1. q – кількість навчальних прикладів;
 - 1.2. σ – поріг відсікання малозначних ваг;
 - 1.3. ε – величина помилки нейромережевої моделі;
 - 1.4. МАХ – гранична кількість епох навчання.
2. Лічильник епох навчання встановити в 1, тобто $k = 1$.
3. Покласти номер навчального прикладу l рівним.
4. Для l -го навчального прикладу сформулювати багатокритеріальну оптимізаційну задачу виду (17)–(18).

5. Розв'язати оптимізаційну задачу (17). В якості чисельного алгоритму мінімізації вибрати метод змінної метрики з моментом.

5.1. Знайти вектор p_n напрямку оптимізації для синаптичних ваг вихідного шару $w_{j1}^{(2)n}$, $j = \overline{1, M}$ методом змінної метрики.

5.2. Визначити крок η_n для корекції ваг вихідного шару в напрямку p_n методом спрямованої мінімізації.

5.3. Перерахувати значення синаптичних ваг вихідного шару:

$$w_{j1}^{(2)n+1} = w_{j1}^{(2)n} + \eta_n p_n + \alpha (w_{j1}^{(2)n} - w_{j1}^{(2)n-1}); \quad (19)$$

де $\alpha \in [0, 1]$ – коефіцієнт моменту.

5.4. Знайти вектор p_n напрямку мінімізації для ваг прихованого шару $w_{ij}^{(1)n}$ $i = \overline{1, N}$, $j = \overline{1, M}$ методом змінної метрики.

5.5. Визначити крок η_n для корекції ваг прихованого шару в напрямку p_n методом спрямованої мінімізації.

5.6. Перерахувати значення ваг прихованого шару за формулою:

$$w_{ij}^{(1)n+1} = w_{ij}^{(1)n} + \eta_n p_n + \alpha (w_{ij}^{(1)n} - w_{ij}^{(1)n-1}). \quad (20)$$

6. Розв'язати оптимізаційну задачу (18). В якості чисельного алгоритму мінімізації вибрати метод градієнтного спуску. В якості початкової точки роботи алгоритму прийняти оптимальну точку, знайдену на кроці 5 в процесі мінімізації критерію $E^{(0)(l)}(w)$.

6.1. Перерахунок ваг вихідного шару:

$$w_{j1}^{(2)n+1} = w_{j1}^{(2)n} \left(1 - \eta \frac{1 + 2 \sum_{k \neq j}^M (w_{k1}^{(2)n+1})^2}{\left(1 + \sum_{k=1}^M (w_{k1}^{(2)n+1})^2 \right)^2} \right); \quad (21)$$

6.2. Перерахунок ваг вихідного шару:

$$w_{ij}^{(1)n+1} = w_{ij}^{(1)n} \left(1 - \eta \frac{1 + 2 \sum_{k \neq j}^{25} (w_{ik}^{(1)n+1})^2}{\left(1 + \sum_k (w_{ik}^{(1)n+1})^2 \right)^2} \right). \quad (22)$$

7. Якщо $l < q$, то $l = l + 1$. Повернення до кроку 4. Інакше – до кроку 8.

8. Редукувати нейромережеву модель:

8.1. Синаптичні зв'язки з вагою менше σ за абсолютним значенням вважати незначними і видалити з мережі;

8.2. Якщо в результаті видалення синаптичних зв'язків нейрон прихованого шару виявиться непов'язаним з вхідними або вихідними нейронами, видалити непов'язаний нейрон.

9. Завершити обчислення, якщо:

а) Помилка мережі $E^{(0)}(w)$ менше заданої похибки ε :

$$E^{(0)}(w) = \frac{1}{2} \sum_{i=1}^q (y^{(i)}(w) - d^{(i)})^2 \leq \varepsilon. \quad (23)$$

б) Досягнуто максимальну кількість епох навчання: $k = \text{max}$.

Інакше повернутися до кроку 3.

Для порівняння ефективності розробленого алгоритму з існуючими методиками редукції нейронних мереж було обрано наступні:

- метод OBD (Optimal Brain Damage);
- метод штрафної функції.

Далі були проведені обчислювальні експерименти, в ході яких нейронні мережі початково однакової топології піддавалися редукції трьома методами (запропонованим алгоритмом і двома стандартними). У результаті експерименти продемонстрували перевагу запропонованого алгоритму за точністю як на навчальній, так і на тестовій множині (табл. 1).

Таблиця 1 – Результати роботи алгоритму в порівнянні зі стандартними методами

Метод редукції	Помилка навчання (середня), %	Помилка узагальнення (середня), %	Кількість епох навчання
Розроблений алгоритм	0,8	1,2	15064
ODB	4,3	5,6	20000
Метод штрафної функції	2,7	3,3	20000

Такий результат свідчить про те, що алгоритм підвищує робастність моделі без втрати точності і, як наслідок, зменшує помилку при розрахунку параметрів авіаційного двигуна ТВ3-117, що контролюються. У результаті редукції буде знижено значення коефіцієнта міри складності мережі $VCdim$, і тим самим підвищена робастність нейромережевої моделі авіаційного двигуна ТВ3-117.

ВИСНОВКИ. Розроблений алгоритм редукції нейронних мереж підвищує робастність моделі, побудованої на її основі. Алгоритм перевершує стандартні методи за точністю і швидкістю навчання.

ЛІТЕРАТУРА

1. Ntantis E. L., Li Y. G. The impact of measurement noise in GPA diagnostics analysis of a gas turbine engine. *International Journal of Turbo & Jet Engine*. 2013. Vol. 30 (4). P. 401–408.
2. Жернаков С. В., Васильев В. И., Муслухов И. И. Бортовые алгоритмы контроля параметров ГТД на основе технологии нейронных сетей. *Вестник УГАТУ*. 2009. Т. 12, № 1 (30). С. 61–74.
3. Жернаков С. В. Применение технологии нейронных сетей для диагностики технического состояния авиационных двигателей. *Интеллектуальные системы в производстве*. 2006. № 2. С. 70–83.
4. Васильев В. И., Жернаков С. В. Контроль и диагностика технического состояния авиационных двигателей на основе интеллектуального анализа

данных. *Вестник УГАТУ*. 2006. Т. 7, № 2 (12). С. 71–81.

5. Жернаков С. В., Равилов Р. Ф. Тренд-анализ параметров авиационного ГТД на основе технологии нейронных сетей. *Вестник УГАТУ*. 2009. Т. 15, № 4 (44). С. 25–32.

6. Диагностика состояния двигателя вертолета Ми-8МТВ с применением нейронных сетей / Шмелев Ю. Н., Владов С. И., Бойко С. Н., Климова Я. Р., Вишневецкий С. Я. *Вісник Хмельницького національного університету*. 2018. № 3.2018. С. 165–170.

7. Владов С. И., Климова Я. Р. Применение адаптивного метода обучения нейронной сети для диагностики двигателя вертолета Ми-8МТВ. *Інформаційні технології: наука, техніка, технологія, освіта, здоров'я (MicroCAD-2018)* : матеріали XXVI Міжнародної науково-практичної конференції, 16–18 травня, 2018 р. Харків : НТУ «ХПІ», 2018. Ч. 1. С. 14.

8. Головкин В. А. Нейронные сети : обучение, организация и применение. Книга 4 : учебник для вузов. Москва : ИПРЖР, 2001. 256 с.

9. Шанин Д. А., Пшихопов В. Х., Медведев М. Ю. Нейросетевой адаптивный регулятор для задачи управления моделью вертолета посредством глобальной обратной связи. *Известия Южного федерального университета. Технические науки*. 2008. № 11 (88). С. 107–110.

10. Применение нейросетевого адаптивного регулятора для управления объектом с неопределенностью / Пшихопов В. Х., Шанин Д. А., Медведев М. Ю., Чикин В. В. *Известия Южного федерального университета. Технические науки*. 2008. № 7 (84). С. 136–140.

11. Шанин Д. А., Пшихопов В. Х., Медведев М. Ю. Построение нейросетевых регуляторов для синтеза адаптивных систем управления. *Информационно-измерительные и управляющие системы*. 2008. № 3, т. 6. С. 48–52.

12. Nodland D., Zargarzadeh H., Jagannathan S. Neural network-based optimal adaptive output feedback control of a helicopter UAV. *IEEE Transactions on Neural Networks and Learning Systems*. 2013. Vol. 24 (7). P. 1061–1073.

13. Shmelov Y., Vladov S., Klimova Y., Kirukhina M. Expert system for identification of the technical state of the aircraft engine TV3-117 in flight modes. *System Analysis & Intelligent Computing: IEEE First International Conference on System Analysis & Intelligent Computing (SAIC)*, 08–12 October 2018. P. 77–82.

14. Vapnik V. N., Chervonenkis A. On the uniform convergence of relative frequencies of events to their probabilities. *Theory of Probability and its Applications*. 1971. Vol.16. P. 264–280.

METHOD OF INCREASING THE ROBUSTNESS OF CONTROL AND DIAGNOSTICS NEURAL NETWORK MODEL OF TV3-117 AIRCRAFT ENGINE TECHNICAL STATE IN FLIGHT MODES

S. Vladov, Yu. Shmelov, S. Hrybanova, O. Husarova, N. Podhornykh

Kremenchuk Flight College of Kharkiv National University of Internal Affairs

vul. Peremogy, 17/6, Kremenchuk, 39605, Ukraine. E-mail: ser26101968@gmail.com

Purpose. The purpose of this work is to develop the method for increase the robustness of the neural network model for control and diagnostics of the TV3-117 aircraft engine technical state in flight modes, which allows to reduce errors

in the calculation of the controlled parameters of the specified aircraft engine. **Methodology.** The work is based on neuroinformatics method in developing a neural network model of the TV3-117 aircraft engine, gradient method with adaptive step in training a neural network, back propagation method for training a neuroregulator, back propagation method for training a neuromodulator. To solve the problem of reducing the neural network model, an algorithm based on multicriteria training has been developed. The work estimates robustness (the ability to generalize a neural network model) based on the calculation of a specific degree of network complexity – “Vapnik-Chervonenkis measures” (VCdim), with which to increase the robustness of the model it is necessary to reduce the number of interneuron connections while maintaining the accuracy of calculations. **Results.** During the research, computational experiments were carried out in which neural networks of initially the same topology were subjected to reduction by three methods – the proposed algorithm and two standard ones, namely, the Optimal Brain Damage (OBD) method and the penalty function method. It is proved by calculation and experiment that the developed algorithm for reducing neural networks increases the robustness of the model developed on its basis, and the algorithm surpasses standard methods in accuracy and speed of training. **Originality.** The method of increasing the robustness of the neural network model for monitoring and diagnosing of aircraft gas turbine engines technical state has been improved by combining the neural network control system with an emulator and a controller, which is used to control and diagnose of TV3-117 aircraft engine technical state in flight modes. This allowed using the algorithm based on multicriteria training to reduce the average neural network learning errors by about 80 and 70 %, respectively, compared to the Optimal Brain Damage (OBD) method and the penalty function method, respectively. **Practical value.** The developed method is a component of the intelligent system of control and diagnostics of TV3-117 aircraft engine technical state in flight modes. References 14, table 1, figure 2.

Key words: aircraft engine, neural network model, robustness, learning error, synaptic connections.

REFERENCES

1. Ntantis, E. L., Li, Y. G. (2013), “The impact of measurement noise in GPA diagnostics analysis of a gas turbine engine”, *International Journal of Turbo & Jet Engine*, vol. 30 (4), pp. 401–408.
2. Gernakov, S., Vasiliev, V. (2009), “Onboard algorithms for controlling GTE parameters based on neural network technology”, *Bulletin of USATU*, vol. 12, no. 1 (30), pp. 61–74.
3. Gernakov, S. (2006), “The use of neural network technology to diagnose the technical condition of aircraft engines”, *Intelligent Systems in Manufacturing*, no. 2, pp. 70–83.
4. Vasiliev, V., Gernakov, S. (2006), “Monitoring and diagnostics of the technical condition of aircraft engines based on data mining”, *Bulletin of USATU*, vol. 7, no. 2 (12), pp. 71–81.
5. Gernakov, S., Ravilov, R. (2009), “Trend analysis of aircraft gas turbine engine parameters based on neural network technology”, *Bulletin of USATU*, vol. 15, no. 4 (44), pp. 25–32.
6. Shmelev, Yu., Vladov, S., Boyko, S., Klimova, Y., Vishnevsky, S. (2018), “Diagnostics of the state of the Mi-8MTV helicopter with the use of neural networks”, *Herald of Khmelnytskyi national university*, no. 3, pp. 165–170.
7. Vladov, S., Klimova, Y. (2018), “The use of the adaptive method of training the neural network for diagnosing the engine of the Mi-8MTV helicopter”, *Information technologies: science, engineering, technology, education, health (MicroCAD-2018)*, 16–18 May 2018, part 1, p. 14.
8. Govovko, V. (2001), *Nejronnye seti : obuchenie, organizaciya i primenenie. Kniga 4 : uchebnik dlya vuzov* [Neural networks: training, organization and application 4th ed.], Moscow, Publishing house “IPRZHR”, Russia.
9. Shanin, D., Pshikhopov, V., Medvedev, M. (2008), “Neural network adaptive controller for the task of helicopter model control through global feedback”, *News of South Federal University. Technical science*, no. 11 (88), pp. 107–110.
10. Pshikhopov, V., Shanin, D., Medvedev, M., Chikin, V. (2008), “Application of a neural network adaptive controller to control an object with uncertainty”, *News of South Federal University. Technical science*, no. 7 (84), pp. 136–140.
11. Shanin, D., Pshikhopov, V., Medvedev, M. (2008), “Construction of neural network regulators for the synthesis of adaptive control systems”, *Information-measuring and control systems*, no. 3, vol. 6, pp. 48–52.
12. Nodland, D., Zargazadeh, H., Jagannathan, S. (2013), “Neural network-based optimal adaptive output feedback control of a helicopter UAV”, *IEEE Transactions on Neural Networks and Learning Systems*, vol. 24 (7), pp. 1061–1073.
13. Shmelov, Y., Vladov, S., Klimova, Y., Kirukhina, M. (2018), “Expert system for identification of the technical state of the aircraft engine TV3-117 in flight modes”, *System Analysis & Intelligent Computing: IEEE First International Conference on System Analysis & Intelligent Computing (SAIC)*, 08–12 October 2018, pp. 77–82.
14. Vapnik, V. N., Chervonenkis, A. (1971), “On the uniform convergence of relative frequencies of events to their probabilities”, *Theory of Probability and its Applications*, vol. 16, pp. 264–280.

Стаття надійшла 19.01.2020