

Ю. М. Шмельов, С. І. Владов, О. Ф. Кришан, С. Д. Гвоздк, Л. І. Чижова

РОЗРОБКА МЕТОДУ КЛАСИФІКАЦІЇ РЕЖИМІВ РОБОТИ АВІАЦІЙНОГО ДВИГУНА ТВ3-117 НА ОСНОВІ НЕЙРОМЕРЕЖЕВИХ ТЕХНОЛОГІЙ

Предметом дослідження в статті є режими роботи авіаційного двигуна ТВ3-117 та методи їх розпізнавання. **Мета** роботи – розробка методів класифікації режимів роботи авіаційного двигуна ТВ3-117 на основі нейромережових технологій у режимі реального часу. В статті вирішуються наступні **завдання**: формування принципів класифікації та розпізнавання станів авіаційного двигуна ТВ3-117, визначення основних кроків розв'язку задачі класифікації та розпізнавання станів авіаційного двигуна ТВ3-117 в нейромережевому базисі, розробка методу класифікації та розпізнавання станів авіаційного двигуна ТВ3-117 з використанням нейронних мереж. Використовуються такі **методи**: методи теорії ймовірностей і математичної статистики, методи нейроінформатики, методи теорії інформаційних систем та обробки даних. Отримано наступні **результати**: Сформульовані принципи класифікації та розпізнавання станів авіаційного двигуна ТВ3-117 та визначено основні кроки розв'язку даної задачі. Обґрунтовано, що розв'язок задачі класифікації режимів роботи авіаційного двигуна ТВ3-117 у нейромережевому базисі дозволяє більш ефективно і якісно вирішити цю задачу, з меншими витратами часу і обчислювальних ресурсів у порівнянні з використанням класичних методів (наприклад, методу Байєса). Досліджена багаторівнева інформаційна структура. **Висновки**: Застосування нейромережових технологій для класифікації та розпізнавання станів авіаційного двигуна ТВ3-117 дозволяє зменшити час обробки даних, причому основний час, що витрачається на розв'язок даної задачі, використовується на процес навчання нейронної мережі. Перспективами подальшого дослідження є розробка експертної системи, одним із модулів якої є модуль класифікації та розпізнавання станів авіаційного двигуна ТВ3-117, яка використовується в бортовій системі для контролю і діагностики технічного стану двигуна та взаємодіє з системами управління двигуном, що дозволяє останньому плавно та своєчасно діяти на виконавчих механізмах, з одного боку, з метою поліпшення якості управління двигуном та його підсистемами, а з іншого – підвищення його надійності у процесі його експлуатації.

Ключові слова: авіаційний двигун; нейронна мережа; перцептрон; режими роботи; класифікація.

Вступ

Авіаційний двигун ТВ3-117 як відновлюваний об'єкт протягом терміну служби вимагає безперервного контролю і діагностики його поточного стану у режимі реального часу, трудомісткість якого залежить від рівня автоматизації процесів отримання, обробки, зберігання, документування інформації щодо його поточного стану, послідовність і методи виконання яких визначають інформаційну технологію моніторингу.

Незважаючи на значний обсяг досліджень у даній області, інформаційні технології контролю і діагностики технічного стану авіаційного двигуна ТВ3-117 не є досконалими за низкою причин, основними з яких є, з одного боку, роз'єднаність баз даних випробувань, відсутність інтелектуальних компонент, що дозволяють якісно і ефективно здійснювати підтримку прийняття рішень і, як наслідок, зменшувати загальний час, що витрачається на його обслуговування; з іншого боку, нестаціонарність фізичних процесів у двигуні, складність їх математичного опису, залежність технічних характеристик двигуна від зовнішніх умов роботи, обмежений склад вимірюваних термогазодинамічних параметрів двигуна, їх технологічний розкид тощо. Зазначені фактори призводять до необхідності прийняття рішень щодо технічного стану двигуна в умовах суттєвої невизначеності.

Основними напрямками, що визначають підвищення якості інформаційних технологій контролю і діагностики технічного стану авіаційного двигуна ТВ3-117, слід вважати інтелектуалізацію процесів обробки інформації з залученням методів

інтелектуального аналізу даних, які здатні забезпечити підвищення якості розпізнавання його технічного стану при дії зазначених вище невизначених факторів, а також інтеграцію інформаційних процесів (розподілених локальних баз даних і знань в глобальну базу даних і знань).

Методи інтелектуального аналізу даних є новим напрямком, що доповнює і розвиває класичні статистичні методи дослідження, які відомі як Data Mining – "здобич" даних і виявлення знань. Data Mining використовує сучасні інтелектуальні технології, що включають в себе нейронні мережі нечітку логіку, експертні системи. Ці технології використовуються у даній роботі для вирішення широкого спектра задач контролю і діагностики технічного стану авіаційного двигуна ТВ3-117 як складного динамічного об'єкту.

Аналіз робіт в області контролю і діагностики стану авіаційних двигунів на основі нейронних мереж [1–5] показує, що в даний час такі роботи ведуться, однак, в силу низки причин (таємність, вузька спеціалізація вирішуваних задач) в більшості публікацій відсутні інженерні методики, а також теоретичні та практичні рекомендації щодо вирішення подібних задач. В роботі досліджуються постановка задачі й можливі алгоритми вибору архітектури нейронних мереж, алгоритмів їх навчання, оцінки ефективності їх роботи тощо, а також розробляється метод розв'язку задачі класифікації режимів роботи авіаційного двигуна ТВ3-117 з використанням нейромережових технологій.

Аналіз існуючих методів класифікації та розпізнавання станів авіаційних двигунів

Класифікація та розпізнавання класів станів авіаційного двигуна як динамічного об'єкта необхідні для узгодження стратегії оптимального управління його станом. Будемо вважати, що поведінка авіаційного двигуна ТВ3-117 як складного динамічного об'єкта може бути представлена у вигляді рівнянь в просторі станів:

$$\dot{X}(t) = F(X(t), U(t), V(t), A(t)); \quad (1)$$

$$Y(t) = G(X(t), U(t), V(t)), \quad (2)$$

де $X(t)$ – вектор змінних стану двигуна; $U(t)$ – вектор керуючих впливів; $V(t)$ – вектор зовнішніх впливів, що обурюють; $Y(t)$ – вектор спостережуваних (вихідних) координат; F, G – нелінійні вектор-функції. Тоді основними причинами зміни станів двигуна можна вважати зміну векторів $U(t)$ і $V(t)$, параметрів авіаційного двигуна $A(t)$, а також зміна операторів F і G при його функціонуванні.

На рис. 1 наведено орієнтований граф, що описує процес зміни режимів роботи (класів станів) авіаційного двигуна ТВ3-117, де H_1 – клас сталих режимів, для яких $U(t) = \text{const}$, $A(t) = \text{const}$, $F(t) = \text{const}$; H_2 – клас режимів, що супроводжуються лінійним трендом параметрів, для якого $U(t) = \text{const}$, $A(t) = \text{var}$, $F(t) = \text{var}$; H_3 – клас перехідних режимів роботи (станів), для яких $U(t) = \text{var}$, $A(t) = \text{const}$, $F(t) = \text{const}$; H_4 – клас невідновлених режимів роботи (розгін, дроселювання), для яких $U(t) = \text{var}$, $A(t) = \text{var}$, $F(t) = \text{var}$.




Рис. 1. Модель процесу зміни класів станів авіаційного двигуна ТВ3-117

Крім перерахованих (справних) станів розрізняють клас несправних (відмовних) станів, що характеризується зміною класу операторів F і G в (1) і (2), при цьому класифікація станів авіаційного двигуна ТВ3-117 теоретично можлива у просторі станів, якщо використовувати змінні стану як параметри класифікації. Однак, доступними для спостереження є компоненти вектору $Y(t)$, що включають адитивні випадкові шуми вимірювань. Отже, існує проблема визначення робочого набору ознак для побудови вирішальних правил, інваріантних до випадкових шумів спостережень. Іншою проблемою підвищення якості розпізнавання є

підвищення точності визначення меж класів станів авіаційного двигуна. Ця проблема обумовлена тим, що вони істотно залежать від співвідношень між динамічними параметрами двигуна (і спектральними характеристиками всіх видів впливу і збурень, що мають випадковий характер, і, отже, є умовними).

Основним методом, на базі якого здійснюється процес класифікації режимів роботи авіаційного двигуна є байєсівський підхід [6]. При цьому оцінюється умовна ймовірність за формулою:

$$P(r_j/k) = \frac{P(r_j)P(k/r_j)}{\sum_{i=1}^n P(r_i)P(k/r_i)}, \quad (3)$$

де $P(r_j/k)$ – ймовірність j -го діагнозу, тобто розглянутий динамічний режим належить до підмножин m_j . Тут величина $P(r_j/k)$ є апостеріорної ймовірністю, тобто визначається після отримання інформації по комплексу ознак $k = (k_1, k_2, \dots, k_n)$. Елемент $P(k/r_j)$ визначає ймовірність появи реалізованого комплексу ознак у підмножині m_j .

До недоліків даного методу слід віднести:

- необхідність врахування великих обсягів апріорної і апостеріорної інформації про потужність й спектральну щільність впливів, погрішності вимірів на всіх режимах роботи двигуна;
- класифікація здійснюється тільки на сталих режимах роботи двигуна;
- низька якість класифікації через похибки оцінок масштабу розподілу, обумовлених як недостовірною апріорною інформацією про ймовірнісні характеристики класів, так і похибками обчислень, і близькістю центрів розпізнавання класів.

У [3] підвищення якості класифікації режимів роботи авіаційного двигуна здійснюється за рахунок збільшення компактності аналізованих сигналів кожного класу щодо центрів групування шляхом вибору виду нелінійного перетворення простору класифікованих параметрів. При цьому відбувається зміна відстані між класами, така при якій міри близькості класів в обраній метриці збільшуються.

У даний час процес класифікації режимів роботи авіаційних двигунів, як правило, здійснюється вручну, за участю висококваліфікованого фахівця, тривала і монотонна робота якого, з одного боку, може призвести до помилок класифікації, а з іншого боку – до значних часових витратах.

Для ліквідації перерахованих вище недоліків у роботі пропонується метод розв'язку задачі класифікації режимів роботи авіаційного двигуна ТВ3-117 на основі нейронних мереж.

Постановка задачі

Є часової ряд, утворений наборами даних за результатами вимірювання термогазодинамічних параметрів двигуна $y_1(t), y_2(t), \dots, y_N(t)$ на

деякому інтервалі спостереження від t_1 до t_2 . Потрібно виділити характерні ділянки часового ряду, що відповідають певним класам S_1, S_2, \dots, S_k станів

авіаційного двигуна ТВ3-117 $\bigcup_{\alpha=1}^k S_{\alpha} = S_0$, де S_0 – клас можливих режимів (справних станів) двигуна.

Процедура розв'язку даної задачі за допомогою нейронної мережі показана на рис. 2, де $F(t)$ – вектор бажаних вихідних реакцій нейронної мережі: $F(t) = \{F_1(t), F_2(t), \dots, F_M(t)\}$, ξ_1, \dots, ξ_M – виходи нейронної мережі; $\varepsilon_1(t), \dots, \varepsilon_M(t)$ – значення вектору помилки на виході нейронної мережі.




Рис. 2. Схема нейромережевого класифікатора станів авіаційного двигуна ТВ3-117

Навчання нейронної мережі зводиться до наступного. На входи нейронної мережі подаються "відрізки" часового ряду $y_1(t), \dots, y_N(t)$ на деякому інтервалі спостереження від t_i до t_{i+1} , що належать завідомо відомим класам (режимам роботи) двигуна S_{α} , ($\alpha = 1, 2, \dots, k$). Бажаними реакціями нейронної мережі в кожному випадку буде двійкове подання номера розпізнаного класу α .

Наприклад, класу сталих режимів авіаційного двигуна ТВ3-117 відповідає код (0, 0) на виході нейронної мережі, класу перехідних режимів – код (0, 1), класу невстановлених режимів – код (1, 0) тощо. Помилка навчання нейронної мережі визначається наступним чином:

$$E = \sum_{i=1}^m \varepsilon_i^2(t) \rightarrow \min. \quad (4)$$

Мінімуму помилки (4) відповідає навчена мережа, яка розв'язує задачу розпізнавання (класифікації) режимів роботи авіаційного двигуна ТВ3-117.

Розглянемо алгоритм розв'язку поставленої задачі на прикладі даних, записаних на борту для авіаційного двигуна ТВ3-117. Оцифрований фрагмент запису (осцилограми) термогазодинамічних процесів авіаційного двигуна ТВ3-117 наведено на рис. 3, де виділено 6-хвилинний інтервал польоту вертольоту Ми-8-МТВ з двома двигунами. Передбачається, що в якості розпізнавання режимів роботи двигуна тут виступають: I – сталі режими; II – режим розгону; III – режим дроселювання. Розв'язок задачі класифікації режимів роботи авіаційного двигуна ТВ3-117 проводитимемо на основі наступних кроків запропонованого методу:

1. Аналіз даних;
2. Попередня обробка даних;
3. Вибір архітектури нейронної мережі;
4. Вибір структури нейронної мережі;
5. Вибір алгоритму навчання нейронної мережі;
6. Оцінювання ефективності.

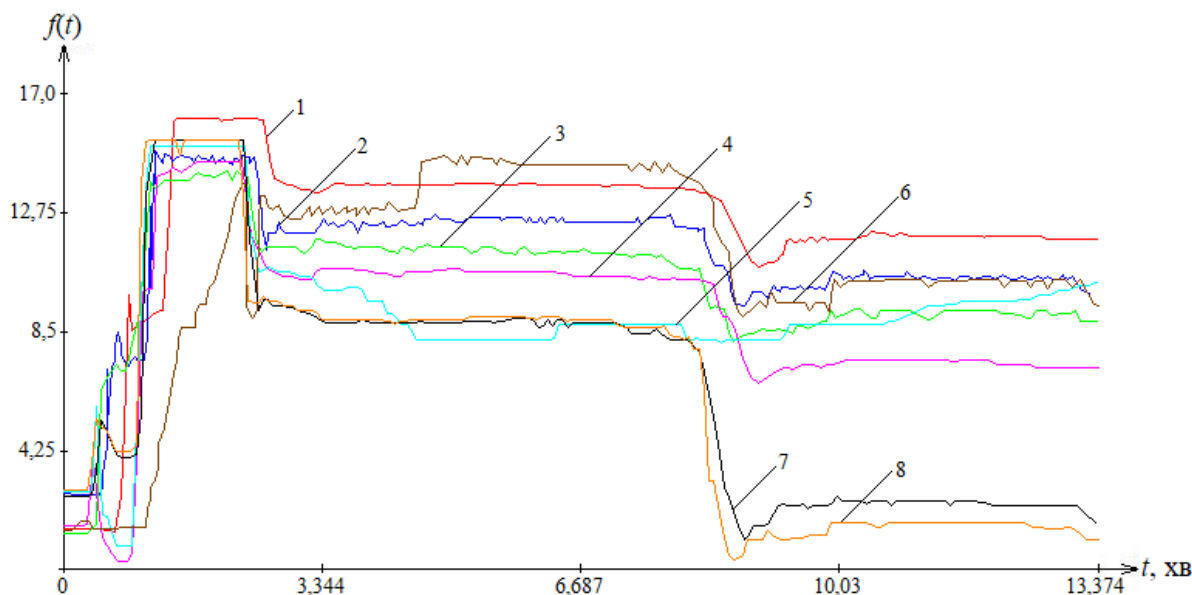


Рис. 3. Оцифрована осцилограма термогазодинамічних процесів в авіаційному двигуні ТВ3-117

На рис. 3 цифрами позначені наступні термогазодинамічні параметри: 1 – частота обертання ротора турбокомпресора першої силової установки; 2 – частота обертання ротора турбокомпресора першої силової установки; 3 – температура газів за турбіною високого тиску другої силової установки;

4 – швидкість польоту; 5 – температура газів за турбіною компресора першої силової установки; 6 – висота польоту; 7 – ручка управління двигунів другої силової установки; 8 – ручка управління двигуном першої силової установки.

Аналіз даних

Основною ознакою, за якою здійснюється виділення "еталонних" ділянок часового ряду при побудові навчальної вибірки нейронної мережі, є положення ручки управління двигуном (*RUD*). Надалі із загальної групи термогазодинамічних параметрів, наведених на оцифрованій осцилограмі, будемо розглядати ті з них, які відносяться до першого двигуна ($N = 2$): N_{1-1} – частота обертання ротора турбокомпресора (крива 1), %; T_{3-1}^* – газу за турбіною компресора (крива 5), %; RUD_1 – положення ручки управління двигуном (крива 8), %.

Ці дані у сукупності з часовою координатою t (хв) утворюють вхідний вектор $y(t) = \{N_1(t), T_3^*(t)\}$, де $t \in [7, 268; 13, 374]$. У процесі роботи з осцилограмою (рис. 3) був виділений інтервал навчання $T_{навч} \in [9, 35 \text{ хв}; 15, 35 \text{ хв}]$, відповідний двом хвилинам, в межах якого існують такі режими:

- режим розгону: $t_1 = 7, 268 \text{ хв}$; $t_2 = 7, 318 \text{ хв}$;

- сталий (0,8 номіналу) режим: $t_2 = 7, 318 \text{ хв}$;

$t_3 = 8, 268 \text{ хв}$;

- режим дроселювання: $t_3 = 8, 268 \text{ хв}$;

$t_3 = 8, 308 \text{ хв}$.

Дані знімалися кожну секунду, тому навчальна вибірка містила 120 часових відліків. При цьому на режими розгону і дроселювання припадало лише по п'ять відліків. Загальний інтервал спостережень склав шість хвилин (360 часових відліків). При розв'язку задачі класифікації режимів роботи авіаційного двигуна ТВ3-117 за допомогою нейронних мереж, процес класифікації здійснюється у часовому вікні. Для якісної класифікації, ширина часового вікна повинна бути не менше п'яти відліків, щоб розпізнати класи станів авіаційного двигуна ТВ3-117.

Попередня обробка даних

Попередня обробка вхідних даних включає нормалізацію кожного з перерахованих вище параметрів двигуна $y_i(t)$ відповідно до виразу:

$$y_i = \frac{y_i - y_{i\min}}{y_{i\max} - y_{i\min}}, \quad (5)$$

де $\overset{\circ}{y}_i$ – безрозмірна величина, яка знаходиться в діапазоні $[0; 1]$; $y_{i\min}$ й $y_{i\max}$ – мінімальне і максимальне значення y_i .

Для розпізнавання режимів роботи (класів станів) авіаційного двигуна ТВ3-117 нейронною мережею необхідно з значень часового ряду спостережень виділити відліки, які в межах часового вікна $\Delta y_i(t)$ відповідають сталим режимом роботи двигуна. Це

здійснюється шляхом обчислення середнього значення (змінного середнього), в межах часового вікна, на всьому інтервалі $t \in [t_1; t_2]$, оскільки $\Delta y_i(t)$ на сталому режимі роботи тотожно дорівнює нулю, а на інших режимах роботи двигуна відмінно від нуля:

$$\Delta y_i(t) = y_i - \frac{\sum_{i=0}^{L-1} y_i}{L}, \quad (6)$$

де L – ширина "вікна".

Оптимальний розмір часового вікна знаходиться у процесі експериментальних досліджень. На цьому етапі уточнюються показники репрезентативності вихідної вибірки, а також однорідності навчальної й тестової вибірки [11].

Вибір архітектури нейронної мережі

Побудуємо нейромережевий класифікатор, представлений на рис. 4, де Δ – часова затримка, $\Delta t = 1$ с. Згідно з рис. 4 нейронна мережа повинна мати $2 \times L$ входів по L для кожного з параметрів: n_1 і T_3^* . Зазначені L параметрів є данні вимірювань, а також затримані значення, аналогічні по n_1 і T_3^* . У якості виходів нейронної мережі будемо вважати сигнали ξ_1 і ξ_2 . Для навченої мережі виходи повинні приймати значення F_1 і F_2 (табл. 1). З огляду на те, що вхідний вектор $y(t) = y_1(t), \dots, y_N(t)$, для нейронної мережі при розв'язку задачі розпізнавання режимів авіаційного двигуна ТВ3-117 відповідає набору ознак, а вихідний вектор $\bar{\xi} = [\xi_1; \xi_2]$, заданий бінарно (табл. 1), класу станів, математичну модель перцептронну можна представити у вигляді системи рівнянь (7), (8).

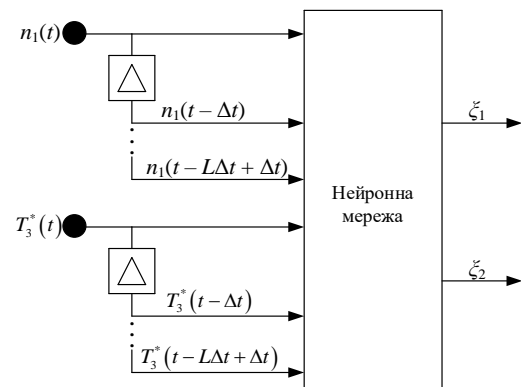


Рис. 4. Архітектура нейромережевого класифікатора

Позначимо через $A^l = \{a_1^l, a_2^l, \dots, a_{m_l}^l\}$ множину вихідних сигналів нейронів l -го шару; а через $W^l = \|W_{ij}^l\|$ матрицю вагових синаптичних зв'язків, що з'єднують нейрони l -го шару з нейронами $(l + 1)$ -го шару.

Таблиця 1. Бажані значення виходів нейромережевого класифікатора

| Розпізнані режими | Сигнали на виході нейронної мережі | |
|-------------------|------------------------------------|-------|
| | F_1 | F_2 |
| Сталий | 0 | 0 |
| Розгін | 1 | 0 |
| Дроселювання | 0 | 1 |

Тоді функціонування перцептронів можна описати наступною системою рівнянь:

- для вхідного шару ($l = 1$): $A^l = y(t)$, де $y(t)$ – вхідний вектор;

- для прихованого шару ($l = 2$):

$$a_j^2 = f \left(\sum_{i=1}^{m_1} W_{ij}^1 a_i^1 + \eta_j \right), \quad (7)$$

де $j = 1, 2, \dots, m_2$;

- для вихідного шару ($l = 3$):

$$Z_j = f \left(\sum_{i=1}^{m_2} W_{ij}^2 a_i^2 + \chi_j \right), \quad (8)$$

де $j = 1, 2, \dots, m_3$.

У (7) і (8) m_l – число нейронів l -го шару; η_j і χ_j – величини зміщення нейронів, відповідно, прихованого і вихідного шарів; $f(\bullet)$ – активаційна функція нейрона. У даному випадку $m_1 = 2L$, $m_3 = 2$.

Аналіз різних архітектур нейронних мереж [7–11] показав, що в якості нейронної мережі доцільно прийняти тришаровий перцептрон.



а)

Вибір структури нейронної мережі

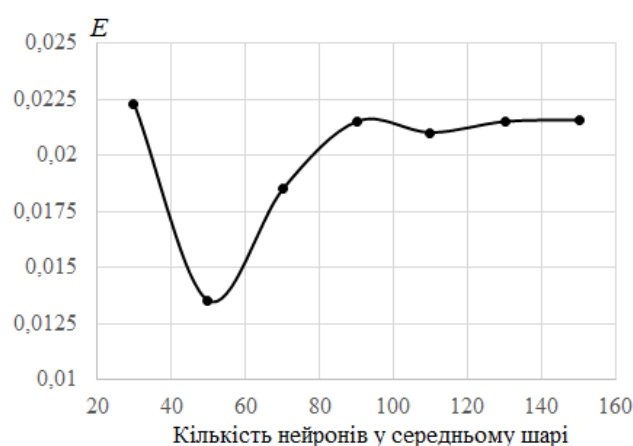
Очевидно, що малий розмір ширини "вікна" не дозволить правильно розпізнати режими роботи авіаційного двигуна ТВ3-117, а великий розмір ширини "вікна" L захопить сусідні класи, що зменшить ймовірність розпізнавання режимів. Залежність помилки навчання нейронної мережі на виході перцептронів від розміру часового вікна показана на рис. 5. У даному випадку в якості функції активації застосовувалася сигмоїдна функція виду [12]:

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}, \quad (9)$$

а число нейронів прихованого шару приймалося рівним 35.

Аналогічні дослідження проводились з метою вибору оптимальної кількості нейронів в прихованому шарі. При цьому враховувалося, що мале їх кількість призводить до неякісного навчання нейронної мережі, а велика – до ефекту перенавчання нейронної мережі [13]. На рис. 5, б показана залежність помилки навчання перцептронів (E) від кількості нейронів в прихованому шарі (m_2).

При навчанні перцептронів приймалося значення ширини "вікна" $L = 10$, що відповідає $2 \times L = 20$ вхідів нейронної мережі. Аналіз рис. 5 показує, що при розв'язку задачі класифікації (розпізнавання) режимів роботи авіаційного двигуна ТВ3-117 досить приймати ширину часового вікна рівній 8...12, а число нейронів прихованого шару 35...45.



б)

Рис. 5. Залежність помилки навчання нейронної мережі: а – від ширини часового вікна; б – від складності нейронної мережі

Вибір алгоритму навчання

Обґрунтування вибору алгоритму навчання детально описано у [14]. Визначено, що застосування адаптивного алгоритму є гнучким рішенням при навчанні нейронних мереж, які застосовуються для задач контролю і діагностики технічного стану авіаційного двигуна ТВ3-117, зокрема, і для

класифікації його режимів роботи. Даний алгоритм базується на градієнтному методі [15], в якому зміна ваг описується залежністю:

$$\vec{w}_{k+1} = \vec{w}_k + \eta_k \vec{p}_k, \quad (10)$$

де η_k – розмір кроку на k -й ітерації, а вектор \vec{p}_k задає напрямок руху і обчислюється за формулою:

$$\vec{p}_k = \vec{g}_k + \sum_{i=1}^{\min(k-1, m)} \beta_i \vec{g}_{k-1}, \quad (11)$$

де вектор \vec{g}_j задає напрямок антиградієнта на j -й ітерації; β_i – коефіцієнт, який визначає вагу i -го градієнта; m визначає кількість запам'ятовуваних градієнтів; k – порядковий номер поточної ітерації.

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

Також варто відзначити, що синтез нейромережевої системи доцільно проводити за допомогою пакета прикладних програм Neural Network Toolbox системи MATLAB, в якій реалізовано три нейрорегулятора: регулятор прогнозу NN Predictive Controller; регулятор на основі моделі авторегресії з ковзним середнім NARMA-L2 Controller; регулятор на основі еталонної моделі Model Reference Controller [16]. Визначено, що для розв'язку задачі контролю і діагностики технічного стану авіаційного двигуна ТВ3-117, зокрема, і класифікації його режимів роботи, найбільш ефективно NN Predictive Controller [15]. Регулятор використовує модель керованого об'єкта у вигляді нейронної мережі для того, щоб спрогнозувати його майбутню поведінку. Крім того, регулятор обчислює сигнал управління, який оптимізує поведінку об'єкта на заданому інтервалі часу.

На рис. 6 наведена структурна схема запропонованої нейромережевої системи, розроблена в Simulink. Ця структура включає блок керованого об'єкта (Subsystem) і блок регулятора NN Predictive Controller, а також блоки генерації еталонного ступеневої сигналу з випадковою амплітудою Random Reference, блок побудови графіків.

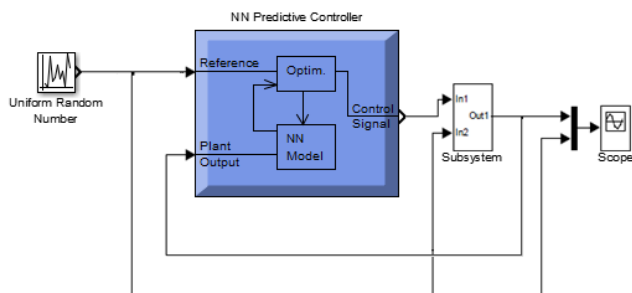


Рис. 6. Схема нейромережевої системи на базі нейрорегулятора NN Predictive Controller

Особливість даної системи полягає в тому, що перед тим як встановлювати роздільну нейрорегулятора, виконується ідентифікація керованого об'єкта, а саме – авіаційного двигуна ТВ3-117, тобто відбувається побудова його нейромережевої моделі. Процедура ідентифікації дозволяє побудувати нейронну мережу, яка буде моделювати динаміку роботи двигуна і

використовується S -функцією для обчислення оптимального сигналу керування на двигун. Програма генерації навчальної послідовності генерує навчальні дані шляхом впливу низки випадкових східчастих сигналів на модель Simulink керованого об'єкта (двигуна). Після створення мережі починається процес її навчання. Вектори входу представляються як числові масиви вибірок, що відповідає груповому поданням даних.

Обґрунтовано, що нейрорегулятор навчається на основі нейромодулятора, який навчається за методом зворотного поширення помилки (рис. 7). Опис розв'язку задачі навчання нейрорегулятора на основі нейромодулятора наведено у [17].

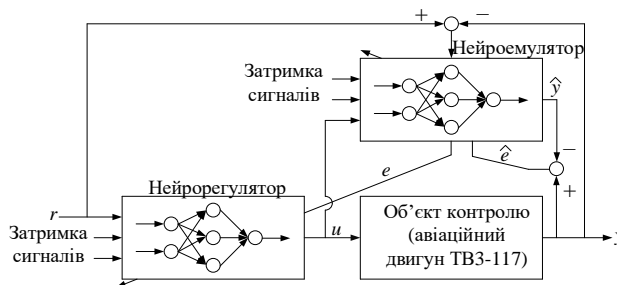


Рис. 7. Схема нейромережевого контролю з емулятором і контролером

Для навчання нейрорегулятора визначається багаточасова мережа прямого розповсюдження з випадково вибраними вагами та навчальний набір, що складається з пар мережевого 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

$$E(w) = \sum_{j,p} (y_{j,p}^{(N)} - d_{j,p})^2, \quad (12)$$

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.

Оцінювання ефективності

Як вже зазначалося вище, після процесу навчання нейронної мережі на інтервалі навчання (33 % вибірки), необхідно перевірити ефективність її роботи на тестовій вибірці, що становить 67 % обсягу всієї вибірки. Еталонні значення виходів нейронної мережі приймають значення 0 або 1, а фактичні сигнали на виході нейронної мережі (в силу інерційності процесу переміщення часового ("вікна") можуть приймати безперервні значення в інтервалі $[0; 1]$). Тому доводиться округляти обчислені значення ξ_1 і ξ_2 до найближчого цілого числа:

$$\bar{\xi}_i = \begin{cases} 0, & \text{якщо } \xi_i \leq 0,5; \\ 1, & \text{якщо } \xi_i > 0,5. \end{cases} \quad (13)$$

При цьому можуть мати місце помилки I і II роду, тобто віднесення стану S_i до класу S_j . Для визначення достовірності класифікації можна скористатися наступними формулами, де $K_{ном}$, $K_{як}$ – коефіцієнти помилковою і якісної класифікації:

$$K_{ном} = \frac{T_{ном}}{T_0} \cdot 100\%; \quad (14)$$

$$K_{як} = \left(1 - \frac{T_{ном}}{T_0}\right) \cdot 100\%, \quad (15)$$

де $T_{ном}$ – сумарний час ділянок, відповідних помилкової класифікації; T_0 – тривалість тестової вибірки (у даному випадку $T_0 = 4$ хв).

У табл. 2 і 3 наведені результати порівняльного аналізу помилок класифікації та якості класифікації режимів роботи двигуна для різних класів архітектур нейронних мереж.

Таблиця 2. Помилки класифікації режимів для різних архітектур нейронних мереж, %

| Архітектура нейронної мережі | Помилка класифікації на виході 1 (ε_1) | Помилка класифікації на виході 2 (ε_2) |
|---|--|--|
| Персептрон | 0,3491 | 0,1042 |
| Елмана | 0,3611 | 0,1681 |
| Хеммінга | 0,4133 | 0,2988 |
| Мережа радіально-базисних функцій (РБФ) | 0,4772 | 0,7891 |
| Хопфілда | 0,4258 | 0,2654 |
| Самоорганізована карта Кохонена | 0,4683 | 0,2913 |
| Мережа адаптивного резонансу | 0,5117 | 0,8409 |
| Мережі векторного квантування сигналів | 0,5532 | 0,9176 |

Таблиця 3. Коефіцієнт якості класифікації режимів для різних архітектур нейронних мереж, %

| Архітектура нейронної мережі | Вихід 1 (ξ_1) | Вихід 2 (ξ_2) |
|---|---------------------|---------------------|
| Персептрон | 99,96 | 99,99 |
| Елмана | 99,96 | 99,98 |
| Хеммінга | 99,95 | 99,97 |
| Мережа радіально-базисних функцій (РБФ) | 99,95 | 99,92 |
| Хопфілда | 99,95 | 99,94 |
| Самоорганізована карта Кохонена | 99,96 | 99,92 |
| Мережа адаптивного резонансу | 99,94 | 99,87 |
| Мережі векторного квантування сигналів | 99,95 | 99,96 |

Аналіз (табл. 2, 3) показує, що застосування для процесу розпізнавання режимів авіаційного двигуна ТВ3-117 інших архітектур нейронних мереж, дає приблизно ті ж результати, що і персептрон.

Висновки

Таким чином, на підставі отриманих результатів досліджень можна зробити наступні висновки:

Розв'язок задачі класифікації режимів роботи авіаційного двигуна ТВ3-117 у нейромережевому базисі дозволяє більш ефективно і якісно вирішити цю задачу, з меншими витратами часу і обчислювальних ресурсів.

Список літератури

1. Pashayev A. M., Askerov D. D., Ardil C., Sadiqov R. A., Abdullayev P. S. Complex Condition Monitoring System of Aircraft Gas Turbine Engine. International Journal of Aerospace and Mechanical Engineering. 2007. Vol. 1. No. 11. P. 689–695.
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. Stamatis A. G. Evaluation of gas path analysis methods for gas turbine diagnostics. Journal of Mechanical Science and Technology. 2011. Vol. 25. Issue 2. P. 469–477.

4. Ntantis E. L. Diagnostic Methods for an Aircraft Engine Performance. *Journal of Engineering Science and Technology*. 2015. Review 8 (4). P. 64–72.
5. Kiakojoori S., Khorasani K. Dynamic neural networks for gas turbine engine degradation prediction, health monitoring and prognosis. *Neural Computing & Applications*. 2016. Vol. 27. No. 8. P. 2151–2192.
6. O'Hagan A. The Bayesian Approach to Statistics. *Handbook of Probability: Theory and Applications*. 2008. P. 85–100.
7. Бодяньський Є. В., Тесленко Н. О., Дейнеко А. О. Еволюційна нейронна мережа з ядрними функціями активації й адаптивний алгоритм її навчання. *Наукові праці. Комп'ютерні технології*. 2011. Випуск 148. Том 160. С. 53–58.
8. Mansour W., Ayoubi R., Ziade H., Velazco R., EL Falou W. An optimal implementation on FPGA of a hopfield neural network. *Advances in Artificial Neural Systems*. 2011. Vol. 2011. P. 7:1–7:9.
9. Kohonen T. Essentials of the self-organizing map. *Neural Networks*. 2013. Vol. 37. P. 52–65.
10. Бодяньський Є. В., Винокурова О. А. Робастний алгоритм навчання радіально-базисної адаптивної фаззи-вейвлет-нейронної мережі. *Адаптивні системи автоматичного управління*. 2007. № 11. С. 3–15.
11. Бодяньський Є. В., Дейнеко А. О., Дейнеко Ж. В., Шаламов М. О. Адаптивне навчання нейронної мережі опорних векторів найменших квадратів. *Інформаційно-керуючі системи на залізничному транспорті*. 2015. № 2. С. 71–74.
12. Elfving S., Uchibe E., Doya K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning. *Neural Networks*. 2018. Vol. 107. P. 3–11.
13. Yamanashi Y., Umeda K., Yoshikawa N. Pseudo Sigmoid Function Generator for a Superconductive Neural Network. *IEEE Transactions on Applied Superconductivity*. 2013. Vol. 23. Issue 3. P. 1701004.
14. Владов С. І. 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)*, 16–18 травня, 2018 р., Харків. 2018. Ч.1. С. 14.
15. Шмелєв Ю. Н., Владов С. І., Бойко С. Н., Климова Я. Р., Вишневіський С. Я. Диагностика состояния двигателя вертолета Ми-8МТВ с применением нейронных сетей. *Вісник Хмельницького національного університету*. 2018. № 3. С. 165–170.
16. Василець Т. Ю., Варфоломійєв О. О., Тютюн Р. В., Алфьоров Ю. О., Власов А. О. Синтез нейрорегулятора NN Predictive Controller для управління трьохмасовою електромеханічною системою. *Системи обробки інформації*. 2017. Випуск 3 (149). С. 88–95.
17. 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)*. 2018, 08–12 October, Kiev. P. 77–82.

References

1. Pashayev, A. M., Askerov, D. D., Ardil, C., Sadiqov, R. A., Abdullayev, P. S. (2007), "Complex Condition Monitoring System of Aircraft Gas Turbine Engine", *International Journal of Aerospace and Mechanical Engineering*, Vol. 1, No. 11, P. 689–695.
2. Zhernakov, S. V., Vasilev, V. I., Musluhov, I. I. (2009), "Onboard algorithms for monitoring parameters of gas turbine engines based on neural network technology" ["Bortovyie algoritmyi kontrolya parametrov GTD na osnove tehnologii neyronnyih setey"], *Bulletin of USATU*, Vol. 12, No. 1 (30), P. 61–74.
3. Stamatias, A. G. (2011), "Evaluation of gas path analysis methods for gas turbine diagnostics", *Journal of Mechanical Science and Technology*, Vol. 25, Issue 2, P. 469–477.
4. Ntantis, E. L. (2015), "Diagnostic Methods for an Aircraft Engine Performance", *Journal of Engineering Science and Technology*, Review 8 (4), P. 64–72.
5. Kiakojoori, S., Khorasani, K. (2016), "Dynamic neural networks for gas turbine engine degradation prediction, health monitoring and prognosis", *Neural Computing & Applications*, Vol. 27, No. 8, P. 2151–2192.
6. O'Hagan, A. (2008), "The Bayesian Approach to Statistics", *Handbook of Probability: Theory and Applications*, P. 85–100.
7. Bodyanskiy, E. V., Teslenko, N. O., Deyneko, A. O. (2011), "An evolutionary neural network with nuclear activation functions and an adaptive algorithm for its training" ["Evoluyutslyna neyronna merezha z yadernimi funktsiyami aktivatsiyi y adaptivnyi algoritmyi yivi navchannya"], *Scientific works. Computer Technology*, Issue 148, Vol. 160, P. 53–58.
8. Mansour, W., Ayoubi, R., Ziade, H., Velazco, R., EL Falou, W. (2011), "An optimal implementation on FPGA of a hopfield neural network", *Advances in Artificial Neural Systems*, Vol. 2011, P. 7:1–7:9.
9. Kohonen, T. (2013), "Essentials of the self-organizing map", *Neural Networks*, Vol. 37, P. 52–65.
10. Bodyanskiy, E. V., Vinokurova, O. A. (2007), "Robust learning algorithm for radial-basis adaptive phase-wavelet neural network" ["Robastniy algoritmyi navchannya radialno-bazisnoyi adaptivnoyi fazzi-veyvlet-neyronnoyi merezhi"], *Adaptive automatic control systems*, No. 11, P. 3–15.
11. Bodyanskiy, E. V., Deyneko, A. O., Deyneko, Zh. V., Shalamov, M. O. (2015), "Adaptive training of the neural network of reference vectors of least squares" ["Adaptivne navchannya neyronnoyi merezhi opornih vektoriv naymenshih kvadrativ"], *Information and control systems on the railway transport*, No. 2, P. 71–74.
12. Elfving, S., Uchibe, E., Doya, K. (2018), "Sigmoid-weighted linear units for neural network function approximation in reinforcement learning", *Neural Networks*, Vol. 107, P. 3–11.
13. Yamanashi, Y., Umeda, K., Yoshikawa, N. (2013), "Pseudo Sigmoid Function Generator for a Superconductive Neural Network", *IEEE Transactions on Applied Superconductivity*, Vol. 23, Issue 3, P. 1701004.
14. Vladov, S. I. Klimova, Ya. R. (2018), "Application of the adaptive training method of the neural network for diagnostics of the Mi-8MTV helicopter engine" ["Primenenie adaptivnogo metoda obucheniya neyronnoy seti dlya diagnostiki dvigatelya vertoleta Mi-8MTV"], *Information Technologies: Science, Technology, Technology, Education, Health (MicroCAD-2018)*, May 16–18, 2018, Kharkiv, Part 1, P. 14.
15. Shmelev, Yu. N., Vladov, S. I., Boyko, S. N., Klimova, Ya. R., Vishnevskiy, S. Ya. (2018), "Diagnostics of the state of the Mi-8MTV helicopter engine using neural networks" ["Diagnostics sostoyaniya dvigatelya vertoleta Mi-8MTV s primeneniem neyronnyih setey"], *Bulletin of the Khmelnytsky National University*, No. 3.2018, P. 165–170.

16. Vasilets, T. Yu., Varfolomiev, O. O., Tyutyun, R. V., Alforov, Yu. O., Vlasov, A. O. (2017), "Synthesis of the NN Predictive Controller for controlling a three-mass electromechanical system" ["Sintez neyroregulyatora NN Predictive Controller dlya upravlinnya trohmasovoyu elektromehaničnoyу sistemoyu"], *Information processing systems*, Issue 3 (149), P. 88–95.

17. 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, Kiev, P. 77–82.

Надійшла (Received) 31.10.2018

Відомості про авторів / Сведения об авторах / About the Authors

Шмельов Юрій Миколайович – кандидат технічних наук, Кременчуцький льотний коледж Національного авіаційного університету, заступник начальника коледжу з навчальної роботи, викладач кафедри енергозабезпечення і систем управління, Кременчук, Україна; e-mail: ref.nv.klknau@gmail.com; ORCID ID: <https://orcid.org/0000-0002-7344-3924>.

Шмелев Юрий Николаевич – кандидат технических наук, Кременчугский летный колледж Национального авиационного университета, заместитель начальника колледжа по учебной работе, преподаватель кафедры энергообеспечения и систем управления, Кременчуг, Украина.

Shmelov Yurii – PhD (Engineering Sciences), Kremenchuk Flight College of National Aviation University, Deputy College chief for curriculum, Teacher at the Department of Energy Supply and Control Systems, Kremenchuk, Ukraine.

Владов Сергій Ігорович – кандидат технічних наук, Кременчуцький льотний коледж Національного авіаційного університету, завідувач лабораторії організації наукової діяльності, ліцензування та акредитації, викладач кафедри енергозабезпечення і систем управління, Кременчук, Україна; e-mail: nml.nv.klknau@gmail.com; ORCID ID: <https://orcid.org/0000-0001-8009-5254>.

Владов Сергей Игоревич – кандидат технических наук, Кременчугский летный колледж Национального авиационного университета, заведующий лабораторией организации научной деятельности, лицензирования и аккредитации, преподаватель кафедры энергообеспечения и систем управления, Кременчуг, Украина.

Vladov Serhii – PhD (Engineering Sciences), Kremenchuk Flight College of National Aviation University, Head of Organization of Scientific Activities, Licensing and Accreditation Laboratory, Teacher at the Department of Energy Supply and Control Systems, Kremenchuk, Ukraine.

Кришан Олексій Федорович – кандидат економічних наук, Кременчуцький льотний коледж Національного авіаційного університету, декан факультету авіаційного транспорту, електроенергетики і управління, викладач кафедри управління і адміністрування, Кременчук, Україна; e-mail: avia.nv.klknau@gmail.com; ORCID ID: <https://orcid.org/0000-0002-2967-0126>.

Крышан Алексей Федорович – кандидат экономических наук, Кременчугский летный колледж Национального авиационного университета, декан факультета авиационного транспорта, электроэнергетики и управления, преподаватель кафедры управления и администрирования, Кременчуг, Украина.

Kryshan Olexii – PhD (Economics Sciences), Kremenchuk Flight College of National Aviation University, Dean of Faculty of Aviation Transport, Electricity and Management, Teacher at the Department of Management and Administration, Kremenchuk, Ukraine.

Гвоздик Станіслав Денисович – Кременчуцький льотний коледж Національного авіаційного університету, викладач кафедри авіаційного транспорту, Кременчук, Україна; e-mail: keps.nv.klknau@gmail.com; ORCID ID: <https://orcid.org/0000-0003-4867-0209>.

Гвоздик Станислав Денисович – Кременчугский летный колледж Национального авиационного университета, преподаватель кафедры авиационного транспорта, Кременчуг, Украина.

Gvozdk Stanislav – Kremenchuk Flight College of National Aviation University, Dean of Faculty of Aviation Transport, Teacher at the Department of Aviation Transport, Kremenchuk, Ukraine.

Чижова Людмила Іванівна – Кременчуцький льотний коледж Національного авіаційного університету, голова циклової комісії української та іноземної мов, Кременчук, Україна; e-mail: uim.nv.klknau@gmail.com; ORCID ID: <https://orcid.org/0000-0002-4105-1520>.

Чижова Людмила Ивановна – Кременчугский летный колледж Национального авиационного университета, председатель цикловой комиссии украинского и иностранного языков, Кременчуг, Украина.

Chyzhova Liudmyla – Kremenchuk Flight College of National Aviation University, Teacher at the Department of Ukrainian and Foreign Languages, Kremenchuk, Ukraine.

РАЗРАБОТКА МЕТОДА КЛАССИФИКАЦИИ РЕЖИМОВ РАБОТЫ АВИАЦИОННОГО ДВИГАТЕЛЯ ТВ3-117 НА ОСНОВЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

Предметом исследования в статье является режимы работы авиационного двигателя ТВ3-117 и методы их распознавания. **Цель** работы – разработка методов классификации режимов работы авиационного двигателя ТВ3-117 на основе нейросетевых технологий в режиме реального времени. В статье решаются следующие **задачи**: формирование принципов классификации и распознавания состояний авиационного двигателя ТВ3-117, определение основных шагов решения задачи классификации и распознавания состояний авиационного двигателя ТВ3-117 в нейросетевом базисе, разработка метода

классификации и распознавания состояний авиационного двигателя ТВ3-117 с использованием нейронных сетей. Используются следующие **методы**: методы теории вероятностей и математической статистики, методы нейроинформатики, методы теории информационных систем и обработки данных. Получены следующие **результаты**: Сформулированы принципы классификации и распознавания состояний авиационного двигателя ТВ3-117 и определены основные шаги решения данной задачи. Обосновано, что решение задачи классификации режимов работы авиационного двигателя ТВ3-117 в нейросетевом базисе позволяет более эффективно и качественно решить эту задачу, с меньшими затратами времени и вычислительных ресурсов по сравнению с использованием классических методов (например, метода Байеса). **Выводы**: Применение нейросетевых технологий для классификации и распознавания состояний авиационного двигателя ТВ3-117 позволяет уменьшить время обработки данных, причем основное время, затрачиваемое на решение данной задачи, используется на процесс обучения нейронной сети. Перспективами дальнейшего исследования является разработка экспертной системы, одним из модулей которой является модуль классификации и распознавания состояний авиационного двигателя ТВ3-117, которая используется в бортовой системе для контроля и диагностики технического состояния двигателя и взаимодействует с системами управления двигателем, позволяет последнему плавно и своевременно действовать на исполнительных механизмах, с одной стороны, с целью улучшения качества управления двигателем и его подсистемами, а с другой – повышение его надежности в процессе его эксплуатации.

Ключевые слова: авиационный двигатель; нейронная сеть; перцептрон; режимы работы; классификация.

RESEARCH OF CLASSIFICATION METHOD OF TV3-117 ENGINE RATINGS OPERATIONS BASED ON NEURAL NETWORK TECHNOLOGIES

The **subject matter** of the article is TV3-117 engine ratings and recognition methods. The **goal** of the work is to create methods for classification TV3-117 engine ratings based on neural network technologies in real time. The following tasks were solved in the **article**: the principles formation on classification and recognition of TV3-117 engine's conditions, determination of main steps for solving problem of classification and recognition TV3-117 engine conditions in the neural network basis, development of a method for the classification and recognition TV3-117 engine conditions using neural networks. The following **methods** used are – methods of probability theory and mathematical statistics, methods of neuroinformatics, methods of the information systems theory and data processing. The following **results** were obtained – the principles of classification and recognition TV3-117 engine conditions are formulated and the main steps for solving this problem are defined. It is substantiated that solving the problem of classifying the TV3-117 engine ratings in the neural network basis allows solve this problem more efficiently with less time and computational resources than using classical methods (for example, the Bayes method). **Conclusions**: using the neural network technologies for the classification and recognition the TV3-117 engine conditions allows to reduce the processing time, and most of the time spent on solving this problem is used to train the neural network. Prospects for further research are the development of an expert system, one of the modules is the module of classification and recognition TV3-117 engine conditions which is used in the board system to monitor and diagnose the engine technical condition and interact with the engine control systems, allows is to effect to the executive mechanism fluently and in time, from the one hand, to improve the quality control engine and its subsystems from the other hand in order to increase its reliability during its operation.

Keywords: engine; neural network; perceptron; engine ratings; classification.
