

СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

УДК 629.7:681.5

В. И. ВАСИЛЬЕВ, С. В. ЖЕРНАКОВ

КЛАССИФИКАЦИЯ РЕЖИМОВ РАБОТЫ ГТД С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИИ НЕЙРОННЫХ СЕТЕЙ

Рассматриваются нейросетевые алгоритмы для классификации режимов работы авиационного газотурбинного двигателя. Формализуется задача классификации режимов работы ГТД в нейросетевом базисе. Предложена инженерная методика, которая может быть применена на этапах стендовых и летных испытаний авиационных ГТД. *Режимы работы ГТД; нейроклассификатор; алгоритм обучения; нейронные сети*

ВВЕДЕНИЕ

Классификация и распознавание классов состояний динамического объекта необходимы для согласования стратегии оптимального управления с состоянием объекта.

Будем полагать, что поведение ГТД как сложного динамического объекта может быть представлено в виде уравнений в пространстве состояний:

$$\begin{cases} \dot{X}(t) = F(X(t), U(t), V(t), A(t)); \\ Y(t) = G(X(t), U(t), V(t)); \end{cases} \quad (1)$$

где $X(t)$ – вектор переменных состояния ГТД; $U(t)$ – вектор управляющих воздействий; $V(t)$ – вектор внешних возмущающих воздействий; $Y(t)$ – вектор наблюдаемых (выходных) координат; F, G – нелинейные вектор-функции. Тогда основными причинами смены состояний ГТД можно считать изменение векторов $U(t)$ и $V(t)$, параметров авиационного двигателя $A(t)$, а также изменение операторов F и G при его функционировании.

На рис. 1 показан ориентированный граф, описывающий процесс смены режимов работы (классов состояний) авиационного двигателя [1–6].

Здесь:

- H_1 – класс установившихся режимов, для которых $U(t) = \text{const}; A(t) = \text{const}; F(t) = \text{const}$;
- H_2 – класс режимов, сопровождающихся линейным трендом параметров, для которого

$U(t) = \text{const}; A(t) = \text{var}; F(t) = \text{var}$;

- H_3 – класс переходных режимов работы (состояний), для которых $U(t) = \text{var}; A(t) = \text{const}; F(t) = \text{const}$;

- H_4 – класс неустановившихся режимов работы (разгон, дросселирование), для которых $U(t) = \text{var}; A(t) = \text{var}; F(t) = \text{var}$.

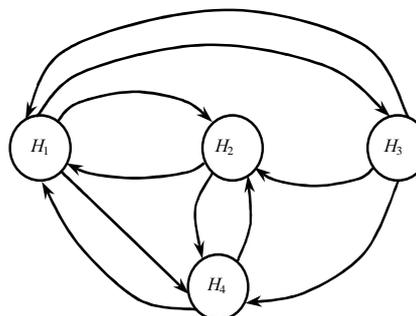


Рис.1. Модель процесса изменения классов состояний ГТД

Вообще говоря, кроме перечисленных (исправных) состояний различают класс неисправных (отказовых) состояний, характеризуемый изменением класса операторов F и G в (1).

При этом классификация состояний ГТД теоретически возможна в пространстве состояний, если использовать переменные состояния как параметры классификации. Однако доступными для наблюдения являются компоненты вектора $Y(t)$, включающие аддитивные случайные шумы измерений. Следовательно, существует проблема определения рабочего набора признаков для построения решающих правил, инвариантных к случайным шумам наблюдений. Другой проблемой повышения качества распознавания является повы-

Контактная информация: (347)273-06-72

Результаты научных исследований поддержаны грантами РФФИ: № 06-08-00446-а, 08-08-00774-а.

шение точности определения границ классов состояний авиационного двигателя. Эта проблема обусловлена тем, что они существенно зависят от соотношений между динамическими параметрами ГТД (и спектральными характеристиками всех видов воздействия и возмущений, имеющих случайный характер, и, следовательно, являются условными).

Основным методом, на базе которого осуществляется процесс классификации режимов работы авиационного двигателя, является Байесовский подход [5, 7–9]. При этом оценивается условная вероятность

$$P(r_j / k) = \frac{P(r_j)P(k / r_j)}{\sum_{i=1}^n P(r_i)P(k / r_i)}; \quad (2)$$

где $P(r_j / k)$ – вероятность j -го диагноза, т. е. рассматриваемый динамический режим принадлежит к подмножеству m_{r_j} . Здесь величина $P(r_j / k)$ является апостериорной вероятностью, т. е. определяется после получения информации по комплексу признаков $k = (k_1, k_2, \dots, k_n)$. Элемент $P(k / r_j)$ определяет вероятность появления реализованного комплекса признаков у подмножества m_{r_j} .

К недостаткам данного метода следует отнести:

- необходимость учета больших объемов априорной и апостериорной информации о мощности и спектральной плотности воздействий, погрешностях измерений на всех режимах работы ГТД;
- классификация осуществляется только на установившихся режимах работы ГТД;
- низкое качество классификации из-за погрешностей оценок масштаба распределения, обусловленных как недостоверной априорной информацией о вероятностных характеристиках классов, так и погрешностями вычислений и близостью центров распознаваемых классов.

В работе [10] повышение качества классификации режимов работы авиационного двигателя осуществляется за счет увеличения компактности анализируемых сигналов каждого класса относительно центров группирования путем выбора вида нелинейного преобразования пространства классифицируемых параметров. При этом происходит изменение расстояния между классами такое, при котором меры близости классов в выбранной метрике увеличиваются.

В настоящее время процесс классификации режимов работы ГТД, как правило, осуществляется вручную, с участием высококвалифи-

цированного специалиста, длительная и монотонная работа которого, с одной стороны, может привести к ошибкам классификации, а с другой стороны, к значительным временным затратам.

Для ликвидации перечисленных выше недостатков автором предлагается алгоритм решения задачи классификации режимов работы ГТД на основе нейронных сетей.

ПОСТАНОВКА ЗАДАЧИ

Имеется временной ряд, образованный наборами данных по результатам измерения термогазодинамических параметров двигателя $y_1(t), y_2(t), \dots, y_N(t)$ на некотором интервале наблюдения $t \in [t_1, t_2]$. Требуется выделить характерные участки временного ряда, соответствующие определенным классам S_1, S_2, \dots, S_k состояний авиационного двигателя: $\bigcup_{\alpha=1}^k S_\alpha = S_0$, где S_0 – класс возможных режимов (исправных состояний) ГТД.

Процедура решения данной задачи с помощью нейронной сети показана на рис. 2.

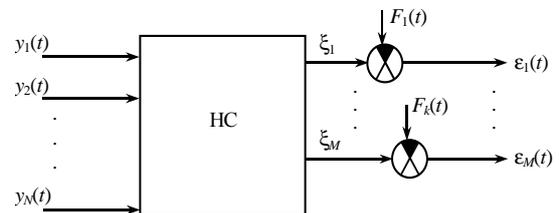


Рис. 2. Схема нейросетевого классификатора состояний авиационного двигателя

Здесь $F(t)$ – вектор желаемых выходных реакций НС: $F(t) = \{F_1(t), F_2(t), \dots, F_M(t)\}$; ξ_1, \dots, ξ_M – выходы НС; $\varepsilon_1(t), \dots, \varepsilon_M(t)$ – значения вектора ошибки на выходе НС.

Обучение НС сводится к следующему. На входы НС подаются «отрезки» временного ряда $y_1(t), \dots, y_N(t)$, $t \in [t_i, t_{i+1}]$, принадлежащие заведомо известным классам (режимам работы) двигателя S_α , ($\alpha = 1, 2, \dots, k$). Желаемыми реакциями НС в каждом случае будет двоичное представление номера распознаваемого класса α . Например, классу установившихся режимов ГТД соответствует код (0, 0) на выходе НС, классу переходных режимов – код (0, 1), классу неустановившихся режимов – код (1, 0) и т. д. Ошибка обучения НС определяется следующим образом:

$$E = \sum_{i=1}^m \varepsilon_i^2(t) \rightarrow \min. \quad (3)$$

Минимуму ошибки (3) соответствует обученная сеть, решающая задачу распознавания (классификации) режимов работы ГТД.

Рассмотрим алгоритм решения данной задачи на примере данных, записанных на борту для авиационного двигателя. Фрагмент записи (осциллограммы) термогазодинамических процессов ГТД приведен на рис. 3, где выделен шестиминутный интервал полета самолета с двухдвигательной силовой установкой. Предполагается, что в качестве распознаваемых режимов работы двигателя здесь выступают: I – установившиеся режимы; II – режим разгона; III – режим дросселирования. Решение задачи классификации режимов работы авиационного двигателя будем проводить на основе следующих шагов инженерной методики.

АНАЛИЗ ДАННЫХ

Основным признаком, по которому производится выделение «эталонных» участков временного ряда при построении обучающей выборки НС, является положение ручки управления двигателем (RUD). В дальнейшем из общей группы термогазодинамических параметров, приведенных на осциллограмме, будем рассматривать те из них, которые относятся к первому ГТД ($N = 3$):

N_{1-1} – частота вращения ротора компрессора низкого давления (кривая 2), в (%);

N_{1-2} – частота вращения ротора компрессора высокого давления (кривая 1), в (%);

T_{4-1}^* – температура газов за турбиной высокого давления (кривая 7), в (%);

RUD_1 – положение ручки управления двигателем (кривая 10), в (%).

Эти данные в совокупности с временной координатой t (мин) образуют входной вектор $y(t) = \{N_1(t), N_2(t), T_4^*(t)\}$; $t \in [9,49; 15,50]$.

Здесь цифрами обозначены следующие термогазодинамические параметры: 1 – частота вращения ротора компрессора высокого давления первой силовой установки; 2 – частота вращения ротора компрессора высокого давления первой силовой установки; 3 – частота вращения ротора компрессора высокого давления второй силовой установки; 4 – частота вращения ротора компрессора низкого давления второй силовой установки; 5 – температура газов за турбиной высокого давления второй силовой установки; 6 – скорость полета;

7 – температура газов за турбиной высокого давления первой силовой установки; 8 – высота полета; 9 – ручка управления двигателем второй силовой установки; 10 – ручка управления двигателем первой силовой установки.

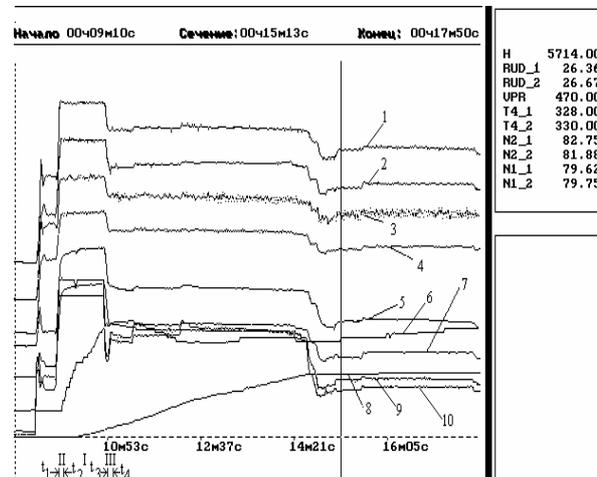


Рис.3. Осциллограмма термогазодинамических процессов в ГТД

В процессе работы с осциллограммой (рис. 3) был выделен интервал обучения $T_{обуч} \in [9,49 \text{ мин}; 15,50 \text{ мин}]$, соответствующий двум минутам, в пределах которого существуют следующие режимы:

- режим разгона: $t_1 = 9,49$ мин; $t_2 = 9,54$ мин;
- установившийся (0,8 номинала) режим: $t_2 = 9,54$ мин; $t_3 = 10,49$ мин;
- режим дросселирования: $t_3 = 10,49$ мин; $t_4 = 10,53$ мин.

Данные снимались каждую секунду, поэтому обучающая выборка содержала 120 временных отсчетов. При этом на режимы разгона и дросселирования приходилось всего по пять отсчетов. Общий интервал наблюдений составил шесть минут (360 временных отсчетов).

При решении задачи классификации режимов ГТД с помощью НС, процесс классификации осуществляется во временном окне. Для качественной классификации, ширина временного окна должна быть не меньше пяти отсчетов, чтобы распознать классы состояний авиационного двигателя.

ПРЕДВАРИТЕЛЬНАЯ ОБРАБОТКА ДАННЫХ

Предварительная обработка входных данных включает нормализацию каждого из перечисленных выше параметров двигателя $y_i(t)$ согласно выражению:

$$\tilde{y}_i = \frac{y_i - y_{i_{\min}}}{y_{i_{\max}} - y_{i_{\min}}}, \quad (4)$$

где \tilde{y}_i – безразмерная величина, находящаяся в диапазоне $[0; 1]$; $y_{i_{\min}}$ и $y_{i_{\max}}$ – минимальное и максимальное значение y_i .

Для распознавания режимов работы (классов состояний) ГТД НС необходимо из значений временного ряда наблюдений выделить отсчеты, которые в пределах временного окна $\Delta\tilde{y}_i(t)$, соответствуют установившимся режимом работы авиационного двигателя. Это осуществляется путем вычитания среднего значения (скользящего среднего), в пределах временного окна, на всем интервале $t \in [t_1, t_2]$, так как $\Delta\tilde{y}_i(t)$ на установившемся режиме работы тождественно равно нулю, а на остальных режимах работы ГТД отлично от нуля:

$$\Delta\tilde{y}_i = \tilde{y}_i - \frac{\sum_{i=0}^{L-1} \tilde{y}_i}{L}, \quad (5)$$

где L – ширина «окна».

Оптимальный размер временного окна находится в процессе экспериментальных исследований.

На этом этапе уточняются показатели репрезентативности исходной выборки, а также однородности обучающей и тестовой выборки [11].

ВЫБОР АРХИТЕКТУРЫ НС

Построим нейросетевой классификатор, представленный на рис. 4.

Здесь Δ – временная задержка, $\Delta t = 1$ с. Согласно этому рисунку НС должна иметь $3 \times L$ входов по L для каждого из параметров: n_1, n_2, T_4^* . Указанные L параметров представляют собой измеренные параметры, а также задержанные значения, аналогичные по n_2 и T_4^* . В качестве выходов НС будем считать сигналы ξ_1 и ξ_2 . Для обученной сети выходы должны принимать значения F_1 и F_2 (табл. 1).

Учитывая, что входной вектор $y(t) = y_1(t), y_2(t), \dots, y_N(t)$ для НС при решении задачи распознавания режимов ГТД соответствует набору признаков, а выходной вектор $\bar{\xi} = \{\xi_1, \xi_2\}$, заданный бинарно (табл. 1), классу состояний, математическую модель персептрона можно представить в виде системы уравнений (6).

Обозначим через $A^l = \{a_1^l, a_2^l, \dots, a_{m_l}^l\}$ – множество выходных сигналов нейронов l -го слоя; а через $W^l = \|W_{ij}^l\|$ – матрицу весовых синаптических связей, соединяющих нейроны l -го слоя с нейронами $(l + 1)$ -го слоя.

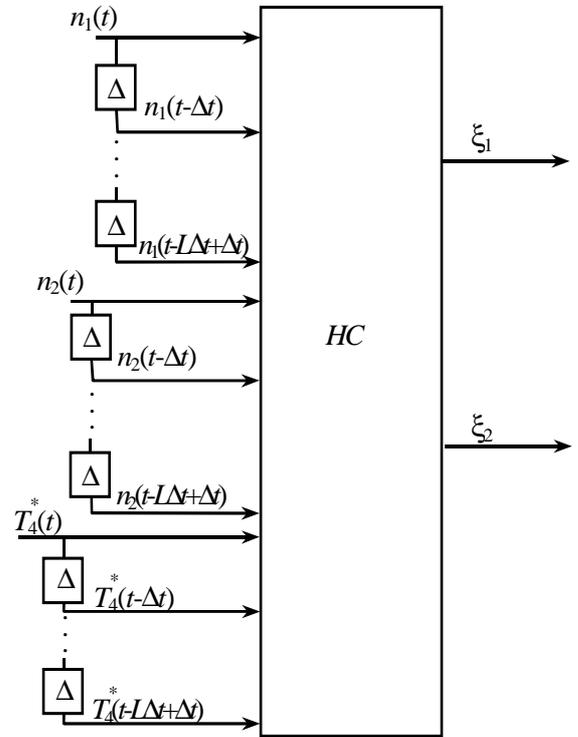


Рис. 4. Архитектура нейросетевого классификатора

Таблица 1
Желаемые значения выходов нейросетевого классификатора

Распознаваемые режимы	Сигналы на выходе НС	
	F_1	F_2
Установившийся	0	0
Разгон	1	0
Дросселирование	0	1

Тогда функционирование персептрона можно описать следующей системой уравнений:

- для входного слоя ($l = 1$) $A^1 = y(t)$, где $y(t)$ – входной вектор;
- для скрытого слоя ($l = 2$)

$$a_j^2 = f \left(\sum_{i=1}^m W_{ij}^1 a_i^1 + \eta_j \right), \quad (6)$$

$$j = 1, 2, \dots, m_2;$$

- для выходного слоя ($l = 3$)

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

$$j = 1, 2, \dots, m_3.$$

Здесь m_l – число нейронов l -го слоя; η_j и χ_j – величины смещения нейронов, соответственно, скрытого и выходного слоев; $f(\bullet)$ – активационная функция нейрона.

В нашем случае $m_1 = 3L$, а $m_3 = 2$.

Анализ различных архитектур НС показал, что в качестве нейронной сети целесообразно принять трехслойный персептрон.

Основными вопросами, требующими своего решения, после выбора архитектуры НС являются:

- определение ширины «окна» L ;
- выбор вида функции активации нейронов;
- поиск оптимального количества нейронов в скрытом слое;
- выбор алгоритма обучения.

Перечисленные выше вопросы реализуются на следующем этапе.

ВЫБОР СТРУКТУРЫ НС

Очевидно, что малый размер ширины «окна» не позволит правильно распознать режимы работы ГТД, а большой размер ширины «окна» L захватит соседние классы, что уменьшит достоверность распознавания режимов. Зависимость ошибки обучения НС на выходе персептрона от размера временного окна показана на рис. 5. В данном случае в качестве функции активации применялась сигмоидная функция вида [12]:

$$f(x) = \frac{1 - \exp(-x)}{1 + \exp(-x)}, \quad (7)$$

число нейронов скрытого слоя принималось равным 35.

Аналогичные исследования проводились с целью выбора оптимального количества нейронов в скрытом слое. При этом учитывалось, что малое количество приводит к некачественному обучению НС, а большое – к эффекту переобучения НС [13]. На рис. 6 показана зависимость ошибки обучения персептрона (E) от количества нейронов в скрытом слое (m_2).

При обучении персептрона принималось значение ширины «окна» $L = 10$, что соответствует $3 \times L = 30$ входам НС. Анализ рис. 5, 6 показывает, что при решении задачи классификации (расознавания) режимов работы ГТД достаточно принимать ширину временно-

го окна равной 8–12, а число нейронов скрытого слоя 35–45.

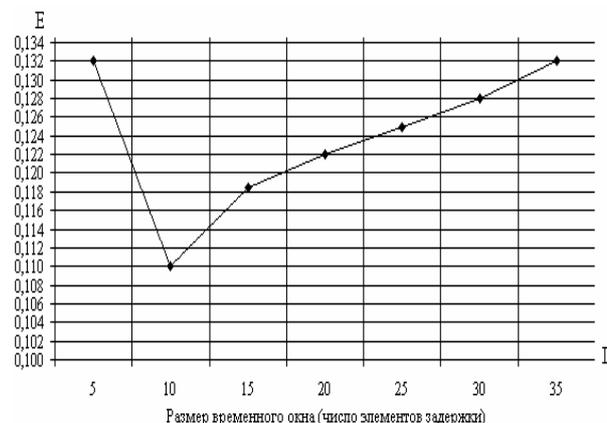


Рис. 5. Зависимость ошибки обучения НС от ширины временного окна

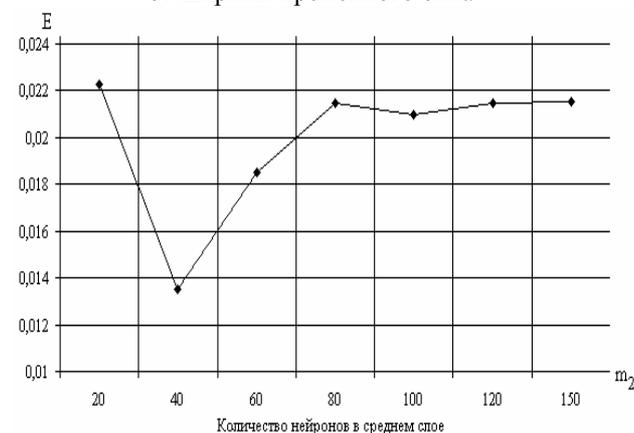


Рис. 6. Зависимость ошибки обучения от сложности НС

ВЫБОР АЛГОРИТМА ОБУЧЕНИЯ

На данном этапе исследовались процессы обучения НС классификатора с помощью следующих алгоритмов обучения [14–24]:

1) алгоритм обратного распространения ошибки (Back Propagation)

$$W_{hk}^{(3)}(t) = W_{hk}^{(3)}(t-1) + \eta \delta_k^{(3)}(t) \cdot F_h^{(2)};$$

$$W_{jh}^{(2)}(t) = W_{jh}^{(2)}(t-1) + \eta \delta_h^{(2)}(t) \cdot F_j^{(1)}; \quad (8)$$

$$W_{ij}^{(1)}(t) = W_{ij}^{(1)}(t-1) + \eta \delta_j^{(1)}(t) \cdot Y_j^{(s)};$$

где η – величина, задающая скорость сходимости;

$$\delta_k^{(3)}(t) = 2f'(t)(F_k^{(3)}(t) - F_k^{(s)});$$

$$\delta_h^{(2)}(t) = f'(t) \sum_{k=1}^k W_{hk}^{(3)}(t-1) \cdot \delta_k^{(3)}(t);$$

$$\delta_j^{(1)}(t) = f'(t) \sum_{h=1}^H W_{jh}^{(2)}(t-1) \delta_h^{(2)}(t);$$

где $f'(t)$ – производная активационной функции нейрона (в данном случае сигмоидная функция).

2) алгоритм быстрого распространения (Quick Propagation):

$$\Delta W_{ij}(t) = -\eta \left[\frac{\partial E(W(t))}{\partial W_{ij}} + \gamma W_{ij}(t) \right] + \alpha_{ij}^{(t)} \cdot \Delta W_{ij}(t-1), \quad (9)$$

где α – коэффициент момента, $\alpha \in [0; 1]$; γ – коэффициент минимизации абсолютных значений весовых коэффициентов (обычно $\gamma = 10^{-4}$);

3) алгоритм сопряженных градиентов (Conjugate Gradients):

$$\begin{aligned} \Delta W(t) &= \eta \cdot p(t) + \alpha \cdot (W(t) - W(t-1)); \\ p(t) &= -[H(W(t))]^{-1} \cdot g(W(t)); \end{aligned} \quad (10)$$

где $p(t)$ – вектор направления градиента; $g(W(t))$ – значение градиента; H – матрица Гессе (гессиан);

4) алгоритм Quasi Newton:

$$\begin{aligned} W(t+1) &= W(t) + \Delta W; \\ \Delta W &= \eta p(W). \end{aligned} \quad (11)$$

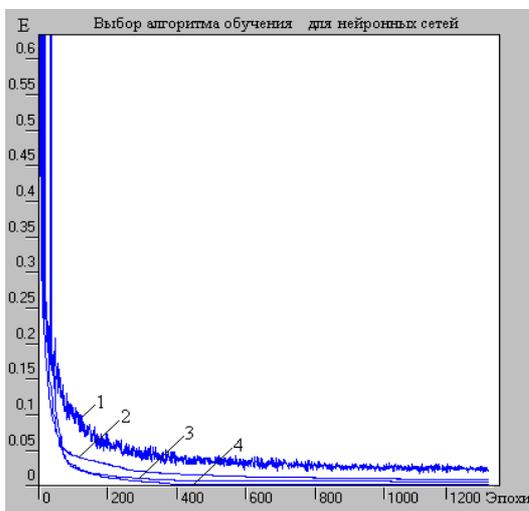


Рис. 7. Зависимость ошибки обучения НС от числа циклов: 1 – Back Propagation; 2 – Quick Propagation; 3 – Conjugate Gradients; 4 – Quasi Newton

График зависимости ошибки обучения НС от числа циклов (для различных алгоритмов обучения) приведен на рис. 7. Как видно из этого рисунка, наибольшей скоростью сходимости обладают алгоритмы (10) и (11). Требуемое число циклов обучения составляет 600÷1000.

ОЦЕНКА ЭФФЕКТИВНОСТИ

Как уже отмечалось выше, после процесса обучения НС на интервале обучения (33% выборки), необходимо проверить эффективность ее работы на тестовой выборке, составляющей 67% объема всей выборки.

Как видно из рис. 8, 9 эталонные значения выходов НС принимают значения 0 или 1, а фактические сигналы на выходе НС (в силу инерционности процесса перемещения временного «окна») могут принимать непрерывные значения в интервале [0; 1]. Поэтому приходится округлять вычисленные значения ξ_1 и ξ_2 до ближайшего целого числа:

$$\bar{\xi}_i = \begin{cases} 0, & \text{если } \xi_i \leq 0,5; \\ 1, & \text{если } \xi_i \geq 0,5. \end{cases} \quad (12)$$

При этом могут иметь место ошибки I и II рода, т. е. отнесение состояния S_i к классу S_j .

На рис. 10 участки ошибочной классификации НС выделены более темным цветом.

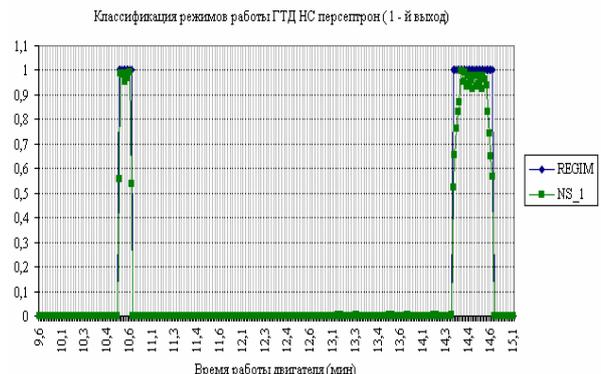


Рис. 8. Классификация режимов работы ГТД (персептрон, 1-й выход)

Данные подходы нашли свое отражение в виде комбинированного решающего правила в программном модуле, выполняющем нейросетевую классификацию режимов работы авиационного двигателя и адаптированного в нейросетевой нечеткой экспертной системе Эксперт Нейро.

Для определения достоверности классификации можно воспользоваться следующими формулами (13). Здесь $K_{\text{ош}}$, $K_{\text{кач}}$ – коэффициенты ошибочной и качественной классификации:

$$\begin{aligned} K_{\text{ош}} &= \frac{T_{\text{ош}}}{T_0} \cdot 100\%; \\ K_{\text{кач}} &= \left(1 - \frac{T_{\text{ош}}}{T_0} \right) \cdot 100\%, \end{aligned} \quad (13)$$

где $T_{\text{ош}}$ – суммарное время участков, соответствующих ошибочной классификации; T_0 –

длительность тестовой выборки (в нашем случае $T_0 = 4$ мин).

В табл. 2 и 3 приведены результаты сравнительного анализа ошибок классификации и качества классификации режимов работы двигателя для различных классов архитектур НС.

Анализ (табл. 2, 3) показывает, что применение для процесса распознавания режимов ГТД других архитектур НС, дает примерно те же результаты, что и перцептрон.

Таблица 2
Ошибки классификации режимов
для различных архитектур НС в (%)

Архитектура НС	Ошибка классификации на выходе 1 (ϵ_1)	Ошибка классификации на выходе 2 (ϵ_2)
Перцептрон	0,4131	0,1322
Элмана	0,4251	0,1961
Хемминга	0,4773	0,3268
РБФ	0,5412	0,8171

Таблица 3
Коэффициент качества классификации режимов
для различных архитектур НС в (%)

Архитектура НС	Выход_1 (ξ_1)	Выход_2 (ξ_2)
Перцептрон	99,96	99,99
Элмана	99,96	99,98
Хемминга	99,95	99,97
РБФ	99,95	99,92

При этом суммарные требуемые затраты на решение задачи классификации режимов ГТД в нейросетевом базисе не превышают 30 - 40 минут (Pentium – IV, 3,5 ГГц, среда моделирования – MATLAB). Основное время, затрачиваемое на решение задачи, используется на процесс обучения НС.

ВЫВОДЫ

Таким образом, на основании полученных результатов исследований можно сделать следующие выводы:

1. Решение задачи классификации режимов работы авиационного двигателя в нейросетевом базисе позволяет более эффективно и качественно решить данную задачу, с меньшими затратами времени и вычислительных ресурсов.

2. Решение задачи сводится к использованию рекуррентной НС, где входами ее являются текущие и задержанные параметры, причем оптимальный размер временного окна выбирается 8–12, а количество нейронов в скрытом слое 35–45.

3. Показано, что наименьшая ошибка обучения НС обеспечивается с использованием алгоритма сопряженных градиентов и квазиньютоновского алгоритма.

4. Анализ качества классификации режимов работы ГТД с помощью нейронной сети на основе данных, полученных в процессе летных испытаний авиационных двигателей показывает, что качество распознавания режимов их работы составляет практически 100%, а ошибка распознавания в рассматриваемом примере не превысила 0,4% на тестовой выборке.

СПИСОК ЛИТЕРАТУРЫ

1. Барзилович, Е. Ю. Модели технического обслуживания сложных систем / Е. Ю. Барзилович. М. : Высшая школа, 1982. 258 с.
2. Боев, Б. В. Идентификация и диагностика в информационно-управляющих системах авиационной энергетики / Б. В. Боев, В. В. Бугровский, М. П. Вершинин. М. : Наука, 1988. 168 с.
3. Васильев, В. И. Автоматический контроль и диагностика систем управления силовыми установками летательных аппаратов / В. И. Васильев, Ю. М. Гусев, А. И. Иванов. М. : Машиностроение, 1989. 240 с.
4. Кеба, И. В. Диагностика авиационных газотурбинных двигателей / И. В. Кеба. М. : Транспорт, 1980. 248 с.
5. Клюев, В. В. Контроль. Диагностика. Энциклопедия / В. В. Клюева. М. : Машиностроение, 2000. Т. VII. 665 с.
6. Сиротин, Н. Н. Техническая диагностика авиационных газотурбинных двигателей / Н. Н. Сиротин, Ю. М. Коровкин. М. : Машиностроение, 1979. 272 с.
7. Белкин, Ю. С. Интегральные системы автоматического управления силовыми установками самолетов / Ю. С. Белкин, Б. В. Боев, О. С. Гуревич. М. : Машиностроение, 1983. 283 с.
8. Волков, Л. И. Управление эксплуатацией летательных комплексов / Л. И. Волков. М. : Высшая школа, 1981. 368 с.
9. Глухов, В. В. Техническое диагностирование динамических систем / В. В. Глухов. М. : Транспорт, 2000. 96 с.
10. Уразбахтина, Л. Б. Выбор стратегии управления объектом, основанный на распознавании образов его состояний / Л. Б. Уразбахтина, В. И. Васильев // Междунар. НТК «Мягкие измерения и вычисления». СПб. : СГЭТУ, 1998. Т. 2. С. 87–91.
11. Царегородцев, В. Г. Оптимизация предобработки данных: константа Липшица обучающей выборки и свойства обученных нейронных сетей / В. Г. Царегородцев // Нейрокомпьютеры: разработка, применение. 2003. № 7. С.3–8.

12. **Миркес, Е. М.** Нейрокомпьютер. Проект стандарта / Е. М. Миркес. Новосибирск : Наука, 1999. 337 с.

13. **Долматова, Л. М.** Что считать результатом обучения: интерпретация зависимостей посредством анализа топологии обученной нейронной сети / Л. М. Долматова // Известия АН. Теория и системы управления. 1996. № 5. С. 71–76.

14. **Аведьян, Э. Д.** Алгоритмы настройки многослойных нейронных сетей / Э. Д. Аведьян // Автоматика и телемеханика. 1995. № 5. С.107–118.

15. **Буцев, А. В.** Локальная аппроксимация на искусственных нейросетях / А. В. Буцев. А. А. Первозванский // Автоматика и телемеханика. 1995. № 5. С. 127–136.

16. **Васильев, В. И.** Интеллектуальные системы управления с использованием нейронных сетей / В. И. Васильев, Б. Г. Ильясов, С. С. Валеев, С. В. Жернаков. Уфа : УГАТУ, 1997. 92 с.

17. **Галушкин, А. И.** Теория нейронных сетей / А. И. Галушкин. М. : ИПРЖР «Радиотехника», 2000. 416 с.

18. **Горбань, А. Н.** Нейронные сети на персональном компьютере / А. Н. Горбань, Д. А. Россиев. Новосибирск : Наука, 1996. 276 с.

19. **Дубровин, В. И.** Интеллектуальные средства диагностики и прогнозирования надежности авиадвигателей / В. И. Дубровин, С. А. Субботин, А. В. Богуслаев. Запорожье : Мотор–Сич, 2003. 279с.

20. **Медведев, В. С.** Нейронные сети / В. С. Медведев, В. Г. Потемкин. М. : Диалог-МИФИ, 2002. 496 с.

21. **Архангельский, В. И.** Нейронные сети в системах автоматизации / В. И. Архангельский, И. Н. Богаенко, Г. Г. Грабовский. Киев : Техника, 1999. 364 с.

22. **Осовский, С.** Нейронные сети для обработки информации / С. Осовский. М. : Финансы и статистика, 2002. 344 с.

23. **Терехов, В. А.** Исследование устойчивости процессов обучения многослойной нейронной сети / В. А. Терехов, И. Ю. Тюкин // Автоматика и телемеханика. 1999. № 10. С. 136–143.

24. **Уоссермен, Ф.** Нейрокомпьютерная техника /Ф. Уоссермен. М. : Мир, 1992. 223 с.

ОБ АВТОРАХ



Васильев Владимир Иванович, проф., зав. каф. выч. техники и защиты информации. Дипл. инж. по пром. электронике (УГАТУ, 1970). Д-р техн. наук по системному анализу и автоматич. управлению (ЦИАМ, 1990). Иссл. в обл. многомерных многофункциональных и интеллектуальных систем.



Жернаков Сергей Владимирович, зав. каф. инф.-изм. техники. Дипл. инж. по пром. электронике (УГАТУ, 1984). Д-р техн. наук по системн. анализу, управлению и обработке информации (УГАТУ, 2005). Иссл. в обл. интеллектуальных систем.