

УДК 629.7.03.004.64

А.Д. МИРЗОЕВ

Национальная академия авиации, Баку, Азербайджан

КОМПЛЕКСНАЯ СИСТЕМА ДИАГНОСТИРОВАНИЯ АВИАЦИОННЫХ ГАЗОТУРБИННЫХ ДВИГАТЕЛЕЙ

Предложена методика диагностирования авиационных газотурбинных двигателей на основе комплексной системы. Разработаны алгоритмы, реализующие отдельные этапы предложенной методики. Проведены эксперименты по практическому применению предложенной методики.

авиационный газотурбинный двигатель, техническое состояние, диагностирования, математическая статистика, нейронная сеть, блок принятия решений

Введение

С развитием сложных динамических систем возникает все большая потребность в разработке и внедрении онлайн-овых (в режиме реального времени) и оффлайн-овых методов диагностирования авиационных газотурбинных двигателей (АГТД). Среди множества разработанных методов диагностирования АГТД, методы распознавания классов технического состояния (ТС) обеспечивают наиболее удобный подход к диагностированию, особенно в тех случаях, когда другие подходы не могут быть применены или их применение сопряжено с большими затратами.

Проведенный анализ работ [1 – 8] показывает, что традиционно большинство систем диагностирования АГТД используют один из известных методов диагностирования. Однако ни один метод не является универсальным и абсолютно надежным. Естественно, что подобные системы диагностирования, построенные на основе одного классификатора, не смогут в полной мере удовлетворить возрастающие требования, предъявляемые к диагностированию двигателей, как в онлайн-овом, так и в оффлайн-овом режиме.

Цель и постановка задачи. Подытоживая вышеприведенный анализ методов систем диагностирования, целью представленной работы является

создание комплексной системы диагностирования АГТД на основе параметров, регистрируемых как бортовыми накопителями, так и в ручную (в регистрационные карты). В качестве основы при построении комплексной системы диагностирования АГТД предлагается использовать статистико-нейросетевой (СНС) подход, характеризующийся высокой степенью адаптивности и универсальностью. Применение данного подхода требует устойчивого и эффективного использования ресурсов современных информационных технологий.

Для реализации предложенной комплексной системы диагностирования АГТД рассмотрим отдельные его этапы. При этом основной задачей является правильное обоснование комбинации математической статистики с нейронными сетями.

Предлагаемая комплексная система диагностирования АГТД приведена на рис. 1.

1. Методика оценки ТС АГТД с помощью математической статистики

1.1. Алгоритм выявления аномальных значений регистрируемых параметров. Для построения эффективной системы диагностирования АГТД необходимо произвести предварительную отбраковку значений регистрируемых параметров работы двигателя. Выявление аномальных значений регистри-

руемых параметров требует определения выборочных средних значений \bar{P}_n и средних квадратических отклонений S_n всех контролируемых параметров по соответствующим формулам:

$$\bar{P}_n = \frac{1}{n} \sum_{i=1}^n P_i,$$

где n – размер выборки; i – порядковый номер регистрируемого параметра;

$$S_n = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (P_i - \bar{P}_n)^2}.$$

Для максимального и минимального значений всех параметров в рассматриваемой выборке определяются критерии аномальности по следующим выражениям:

$$U_{\min i} = \frac{P_{\min i} - \bar{P}_n}{S_n},$$

$$U_{\max i} = \frac{P_{\max i} - \bar{P}_n}{S_n}.$$

Полученные значения $U_{\min i}$ и $U_{\max i}$ необходимо сравнивать с теоретической критической величиной $U_{кр}$, значения которой для определенных уровней значимости приведены в работе [17]. Если $U_{\min i}^{(\max)} \geq U_{кр}$, то значение параметров является аномальным и должно быть исключено, в противном случае оно считается нормальным и не исключается.

В дальнейшем производится статистический анализ значений параметров АГТД с учетом допущения о том, что распределение параметров – нормальное.

1.2. Алгоритм приведения контролируемых параметров к САУ и расчетному режиму (в случае ПС-90А-76SW). Для последующего статистического анализа параметров работы двигателя требуется исключение влияния внешних факторов и режима работы двигателя, путем приведения их к Стандартным Атмосферным Условиям (САУ) и расчетному режиму работы АГТД.



Рис. 1. Обобщенная схема комплексной системы диагностирования АГТД

Приведение параметров к САУ осуществляется с учетом рекомендации [16] и в момент крейсерского режима $(H = 11 \text{ km}, M = 0,8, T_{BX}^* = 244,8 \text{ }^\circ\text{K},$

$P_{BX}^* = 0,352 \text{ кгс} / \text{см}^2)$ по формулам:

– частота вращения ротора КВД:

$$N_{KBD \text{ np.}} = N_{KBD \text{ cp.}} \sqrt{\left[291,5 / (T_{BX}^* + 273) \right]}, \%$$

– частота вращения ротора вентилятора:

$$N_{BEH \text{ np.}} = N_{BEH \text{ cp.}} \sqrt{\left[291,5 / (T_{BX}^* + 273) \right]}, \%$$

– температура газа за турбиной:

$$T_{Tnp.}^* = (T_{T \text{ cp.}}^* + 273) \left[291,5 / (T_{BX}^* + 273) \right] - 273, \text{ }^\circ\text{C}$$

– температура воздуха за КВД:

$$T_{Knp.}^* = (T_{K \text{ cp.}}^* + 273) \left[291,5 / (T_{BX}^* + 273) \right] - 273, \text{ }^\circ\text{C}$$

– расход топлива:

$$G_T \text{ np.} = G_T \text{ cp.} \cdot 1,072 / P_{BX}^* \sqrt{\left[291,5 \left[(T_{BX}^* + 273) \right] \right]}, \text{ T / час}$$

– полное давление воздуха за КВД:

$$P_{K np.}^* = P_{K np.}^* \cdot 1,072 / P_{BX}^*, \text{ кгс / см}^2;$$

– полное давление воздуха за вентилятором:

$$P_{B np.}^* = P_{B np.}^* \cdot 1,072 / P_{BX}^*, \text{ кгс / см}^2.$$

Далее производится оценка ТС ГТД путем подсчета статически возможных границ значений регистрируемых параметров.

1.3. Алгоритм оценки ТС АГТД на основе математической статистики. Статистический подход оценки технического состояния АГТД основывается на формировании гибких диапазонов регистрируемых параметров и сравнении их значений с рассчитанными верхними и нижними границами изменений.

Статистические возможные верхние и нижние границы значений параметров, характеризующих рабочий процесс двигателя, определяются по следующим формулам:

$$P_n^B = \bar{P}_n + K_{1,n} \sqrt{S_n^2},$$

$$P_n^H = \bar{P}_n - K_{1,n} \sqrt{S_n^2},$$

где \bar{P}_n – средние значения параметров двигателей;

S_n – средние квадратичные отклонения параметров двигателей, определенные согласно п.1.1;

$K_{1,n}$ – толерантный коэффициент, зависящий от числа измерений n , принятого уровня значимости и доверительной вероятности [25].

Определение ТС АГТД на основе статистически возможных диапазонов регистрируемых параметров требует предварительного формирования классов ТС АГТД. Классы ТС АГТД, сформированные по вышеприведенной методике, могут привести к следующим вариантам:

1. $P_n^H \leq P_i \leq P_n^B$;
2. $P_i \geq P_n^B$ или $P_i \leq P_n^H$.

Результаты обработки параметров, соответствующих первому варианту, свидетельствуют о нормальном состоянии двигателя, и способствуют выдаче соответствующих сообщений.

Случаи, соответствующие второму варианту, свидетельствуют о появлении вероятности неисправного состояния по данному каналу (по рассматриваемому параметру работы ГТД) и выдаче соответствующего сообщения.

Исследования показывают, что характер закона распределения регистрируемых параметров АГТД с наработкой изменяется – происходит приближение и удаление закона распределения параметров АГТД от нормального. Следовательно, для более надежной оценки ТС АГТД требуется применение нейронных сетей (НС).

2. Условия формирования нейронной сети для оценки ТС АГТД

2.1. Отбор информативных параметров для построения нейросетевой модели. Оценка ТС АГТД с помощью НС требует правильного формирования набора входных и выходных параметров. При этом выбор информативного параметра является наиболее важной задачей, сокращающей входное и выходное пространство классификатора. Это обстоятельство позволяет снижать требования к ресурсам ЭВМ, увеличивать скорость процесса обучения и упростить архитектуры НС – модель классификатора.

Предварительный выбор информативного параметра, характеризующего работу АГТД, целесообразно проводить на основе подсчета коэффициентов парной корреляции между входными параметрами нейросетевой модели. Выбор выходного параметра (ВП) НС производится на основе критерий выхода, описывающих динамику изменения основных характеристик законов распределения параметров АГТД (асимметрия – $|A(P)|$, эксцесс – $|E(P)|$). Основными критериальными значениями при этом являются их абсолютные минимальные значения:

$$|A(P)| = |A(P)|_{\min},$$

$$|E(P)| = |E(P)|_{\min}.$$

В случае стремления характеристик законов распределения к минимальным значениям, но по разным параметрам, выбирается тот ВП НС, который имеет наибольшее количество парной корреляции с входными параметрами. В случае совпадения количества парной корреляции для различных ВП НС (для рассматриваемой выборки), целесообразно аппроксимировать обе характеристики закона распределения. Но следует отметить, что в качестве ВП нейросетевой модели могут выступать различные параметры АГТД, соответствующие определенной обучающей выборке.

Учитывая данное обстоятельство, необходимо производить многократное повторение комбинации "Отбор Признака – Построение Нейросетевой Модели – Отбор Признака". Под построением Нейросетевой Модели подразумевается выбор оптимальной архитектуры НС в зависимости от входного и выходного "ансамбля" параметров двигателя.

2.2. Алгоритм формирования многослойного персептрона. Построение нейросетевой модели сводится к нижеприведенным этапам:

- формирование архитектуры НС;
- выбор алгоритма обучения;
- оценка адекватности нейросетевой модели;
- оценка обобщения нейросетевой модели.

Под формированием архитектуры нейросетевой модели подразумевается выбор типа нейрона и необходимого количества нейронов в скрытом слое. На сегодня существует большой объем работ, посвященных формированию архитектуры нейросетевой модели диагностируемого объекта [23, 24]. Но анализ этих работ позволяет выработать общую методику формирования и корректировку архитектуры НС.

Для определения необходимого количества нейронов в скрытом слое, сопровождающихся высокой точностью аппроксимации, предлагается алгоритм выращивания сети, который рассматривается в п.п. 2.2.1. Но этот анализ одновременно приводит к вы-

воду, что выбор архитектуры сети для решения конкретной задачи должен происходить с учетом особенностей этой задачи.

Многослойный персептрон может обучаться быстрее, если функция активации НС является антисимметричной [15]. Учитывая данное обстоятельство и нелинейное преобразование (представления) входных и выходных параметров нейросетевой модели, целесообразно использовать антисимметричную функцию активации – гиперболический тангенс:

$$f(x) = \frac{2}{1 + e^{-2x}} - 1,$$

После выбора архитектуры НС необходимо назначить значения весов и смещения, которые осуществляются с помощью процедур обучения. Корректировку весов и смещений сети можно осуществить по различным стратегиям, определяющим алгоритм обучения для минимизации разности между желаемым сигналом и откликом НС. Это разность позволяет сформировать так называемый функционал ошибки, характеризующий качество обучения.

$$J = \frac{1}{2} \sum_{q=1}^Q \sum_{i=1}^{S^M} \left(t_i^q - a_i^{qS^M} \right)^2,$$

где J – качество обучения;

Q – объем выборки;

M – число слоев сети;

q – номер выборки;

S^M – число нейронов выходного слоя;

$a_i^{qS^M}$ – отклик сети:

$$a_i^{qS^M} = f\left(\sum_{j=0}^R w_{ij} P_j + b_j\right),$$

где w_{ij} и b_j – синаптические веса и смещение НС;

R – число входных элементов сети;

t_i^q – желаемый сигнал.

В работе [11] приведены детальные характеристики алгоритмов обучения сети при оценке ТС

ГТД. Из анализа этих характеристик следует, что наилучшим коэффициентом достоверности (адекватности) обладает комбинированный алгоритм обучения на основе градиентного спуска с возмущением (алгоритм GDM) и метод Левенберга-Марквардта.

Стратегия корректировки параметров обучения комбинированного алгоритма приведена в формуле (1):

$$X_{k+1} = \begin{cases} X_k - H^{-1}g_k, & \text{если } J > J_\Phi; \\ \alpha X_k + (1-\alpha)\eta g_k, & \text{если } J < J_\Phi, \end{cases} \quad (1)$$

где X – приращение параметра обучения;

α – параметр возмущения;

J_Φ – качество обучения, при котором фиксируется алгоритм Левенберга-Марквардта ($J_\Phi = 10^{-4}$);

η – скорость обучения;

g_k – вектор градиента функционала ошибки на k -й итерации;

e_k – ошибка обучения на k -й итерации;

H^{-1} – обратная матрица Гессе;

J^T – матрица Якоби ошибки.

Обоснованность применения комбинированного алгоритма обучения связана, кроме улучшения оценки ТС АГТД, с увеличением скорости сходимости функционала ошибки.

Как известно, процесс увеличения скорости сходимости функционала ошибки характеризуется ”хорошим” выбором начальных значений синаптических весов и смещений.

Если синаптические веса и смещения сети принимают большие начальные значения, то нейроны, скорее всего, достигнут режима ”насыщения”, что вызовет торможение процесса сходимости функционала ошибки. Если же синаптическим весам и смещениям присвоить малые начальные значения, то алгоритм комбинированного обучения будет работать ”вяло” [20]. При этом обучение сети начинается с метода Левенберга-Марквардта, после дости-

жения $J = J_\Phi$ фиксируются, и присваиваются параметры процесса обучения к параметрам обучения алгоритма GDM.

Для достоверности оценки многослойного персептрона АГТД автором предлагается применять коэффициенты качества:

$$K_{k1} = (1 - S) * 100\%,$$

$$S = \sqrt{\frac{\sum_{i=1}^N \sum_{j=1}^n \delta_{ij}^2}{N * n}},$$

$$\delta = (P_{НС} - P_{ИСТ}) / \Delta_{\max},$$

где S – среднеквадратичное отклонение отклика сети;

δ – отношение разности отклика сети с истинным значением параметров к максимальной погрешности измерительной аппаратуры;

$P_{НС}$ – отклик НС;

$P_{ИСТ}$ – истинное значение выходного параметра.

Также, с целью определения адекватности, можно воспользоваться следующей формулой:

$$K_{k2} = (P_{НС} - P_{ИСТ}) / P_{ИСТ} * 100\%.$$

Если сеть после обучения достаточно адекватно описывает учебные данные, то необходимо в последующем определить уровень обобщения сети. Необходимо проверить гипотезу о том, что сеть хорошо описывает не только данные, использованные как учебные, но и тестовые данные. Если выполняется условие (1), то можно сделать вывод о появлении эффекта ”переобучения” сети [10, 14], следовательно, необходимо заново возвратиться к формированию архитектуры сети:

$$(K_k^O - K_k^T) > K_k^D, \quad (1)$$

где K_k^T и K_k^O – коэффициент качества за обучающий и тестовый набор данных соответственно;

K_k^D – допустимая погрешность аппроксимации, равная 5 %.

Выбор двух коэффициентов качества сделан в целях перепроверки качества аппроксимации ВП многослойного персептрона. С целью увеличения производительности процесса обучения необходимо, для достижения нейросетевой моделью наилучших показателей обобщения, масштабировать входные и выходные параметры двигателя по формуле [26, 27]:

$$P_n = \frac{2(P_i - P_{\min})}{(P_{\max} - P_{\min}) - 1}.$$

2.2.1. Алгоритм “выращивания” сети. Для эффективной оценки ТС АГТД с помощью НС обычно требуется использование жестко структурированных сетей довольно большого размера. В этом контексте возникает практический вопрос минимизации размера сети без потери производительности. При уменьшении размера НС увеличивается вероятность обучения информативных признаков, содержащихся в примерах и, таким образом, повышается качество обобщения.

Пошаговую минимизацию параметров сети предлагается производить алгоритмом “выращивания” сети, приведенным на рис. 2.

Последующим шагом в формировании нейросетевой модели АГТД является идентификация ТС на основе предварительно сформированных классов.

2.2.2. Идентификация ТС АГТД на основе НС. Учитывая, что нейрон выходного слоя, соответствующий ВП, с гиперболическо-тангенциальной функцией активации может принадлежать только интервалу $[-1; 1]$, то для кодирования классов ТС целесообразно использовать ниже приведенные варианты:

1. $\bar{P}_i \in [0, 5; -0, 5]$,
2. $\bar{P}_i \in [0, 5; 1]$,
3. $\bar{P}_i \in [-0, 5; -1]$.

Результат моделирования ВП презентуемому первому варианту свидетельствует о выдаче сообщения нормального состояния двигателя. А резуль-

таты моделирования презентуемому второму и третьему вариантам свидетельствуют о тенденции ВП к завышенному и заниженному состоянию, что способствует вероятности возникновения неисправности АГТД по данному каналу и формирует соответствующее сообщение.

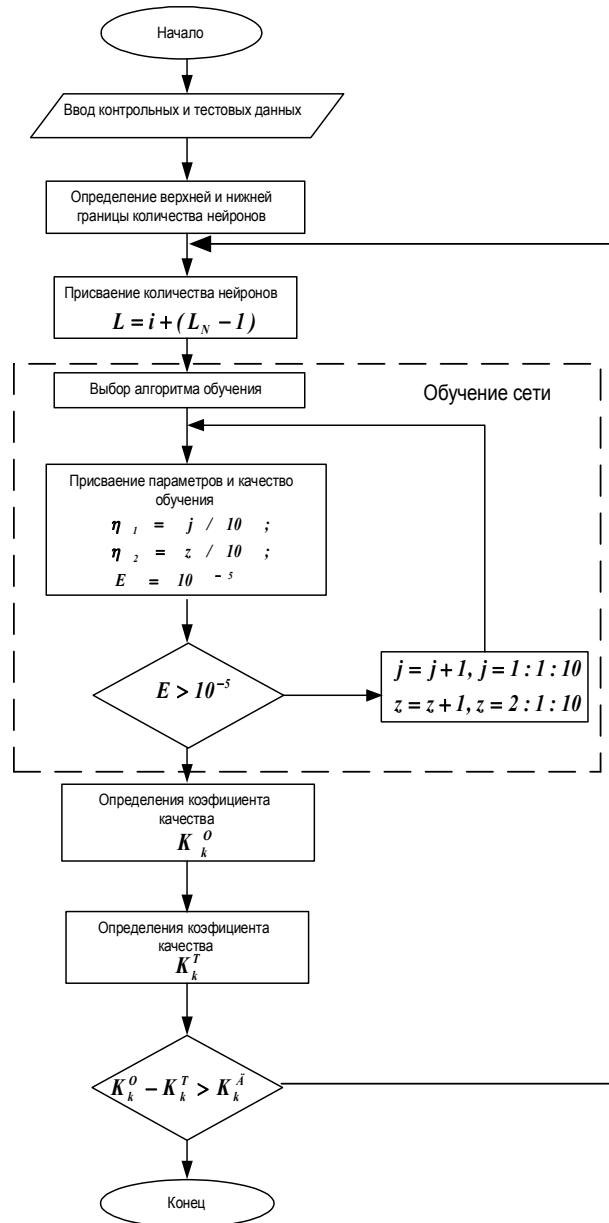


Рис. 2. Алгоритм корректировки многослойного персептрона

Однако следует отметить, что применение МСП является предпочтительным в случаях предварительного формирования классов ТС АГТД. Поэтому в системе диагностирования АГТД должна быть

предусмотрена подсистема классификации состояния. В случае отсутствия принципа формирования классов для учебного набора данных, успешное решение такой задачи возможно с применением самоорганизующей сети Кохонена.

2.3. Сеть Кохонена. Самоорганизующая сеть Кохонена использует конкурирующую функцию активации. Конкурирующая функция активации анализирует значения элементов вектора d и формирует выходы нейронов, равные 0, для всех нейронов, кроме одного нейрона-победителя, имеющего на входе максимальное значение. Такая активационная характеристика может быть описана следующим образом:

$$T_i = \begin{cases} 1, & i = i^*, i^* = \arg(\max d_i); \\ 0, & i \neq i^*, \end{cases}$$

где d_i – это результат суммирования вычисленного евклидова расстояния R , между вектором входа Z и строками матрицы весов W с вектором смещения b ;

T_i – выход из конкурирующего слоя. Отрицательное евклидово расстояние R определяется следующим образом:

$$R = -\sqrt{\sum_{j=1}^i (z_j - w_j)^2}.$$

Правило коррекции параметров обучения слоя Кохонена заключается в том, чтобы построить нужным образом элементы матрицы весов [18, 19]. Предположим, что нейрон i^* «победил» при подаче входа $Z(q)$ на шаге самообучения q , тогда строка i^* матрицы весов корректируется в соответствии с правилом Кохонена следующим образом:

$$w_{i^*}(q) = w_{i^*}(q-1) + \eta(z(q) - w_{i^*}(q-1)).$$

Следует отметить, что для полноценной оценки ТС АГТД нецелесообразно применять только лишь один из типов НС, так как каждый тип НС позволяет решать узкий круг прикладных задач.

Учитывая данное обстоятельство, возникает острая необходимость в создании и применении едино-

го нейросетевого аппарата на основе комбинации различных типов НС позволяющего находить приемлемое решение различных типов задач.

2.4. Алгоритм построения комбинированной нейросетевой модели. В рамках решаемой задачи предлагается применение многослойного персептрона (МСП) и сети Кохонена (СК) для комбинированной НС. Наряду с преимуществами, приведенными в п. 2.2 и 2.3, следует подчеркнуть возможность комбинированной НС производить двухэтапную идентификацию ТС АГТД, где на первом этапе многослойный персептрон выполняет роль аппроксиматора выходного параметра (диагностируемого параметра) и формирует классы ТС ГТД на основе данной аппроксимации.

При этом результатом последующего анализа является отнесение двигателя к одному из состояний (простейший случай – к дефектным или бездефектным двигателям). Выбор в качестве аппроксиматора МСП обусловлен владением богатого спектра архитектурных свойств, что не свойственно другим НС [9, 13].

При распознавании ТС АГТД наиболее часто используются так называемые LVQ-сети и радиально-базисные сети (РБНС) [21, 22]. LVQ-сеть и РБНС имеют, кроме низкого качества распознавания, еще один недостаток: данные типы сети производят кластеризацию выходных данных на основе заранее формализованных классов ТС авиационных ГТД, т.е. применяют процедуру обучения “с учителем”. Данное обстоятельство обуславливает применение сетей, владеющих свойством самоорганизации и высокой степенью точности, осуществляющих классификацию с применением обучения “без учителя” – сетей Кохонена. Блок-схема комбинированной НС приведена на рис. 3.

Дальнейшая оценка ТС АГТД производится с помощью комбинации математической статистики и нейронной сети, которые входят в единый блок принятия решений.

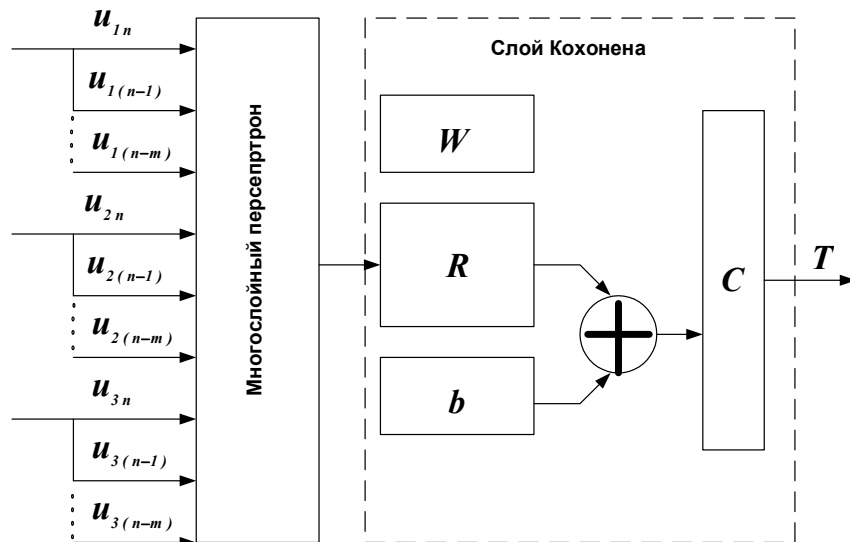


Рис. 3. Структура комбинированной НС

3. Построение блока принятия решений

Основной задачей блока принятия решений является обработка результатов идентификации ТС на основе двух классификаторов и выдачи соответствующей рекомендации о дальнейшей эксплуатации авиационного ГТД.

При отсутствии формализованных правил принятия решений и наличия только пар данных результатов классификации предпочтительно строить блок принятия решений на основе логической модели [12]. Функциональная схема логической модели АГТД представлена на рис. 4.

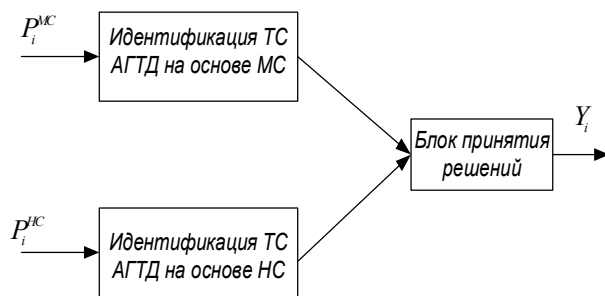


Рис. 4. Блок схема логической модели объекта

Фактическое значение блока принятия решений Y_i зависит от состояния блоков MS_i и NS_i , определяющих ТС авиационных ГТД по методам математической статистики и нейронной сети соответственно.

Формально Y_i является конъюнкцией переменных MS_i и NS_i :

$$Y_i = MS_i * NS_i.$$

Выходы блоков MS_i и NS_i принимают значение 0, в случае неисправного состояния ГТД. Возможные наборы значений блоков MS_i и NS_i , а также Y_i сводятся в так называемые таблицы состояний диагностируемого объекта.

4. Эксперименты и результаты

Для экспериментальной проверки предложенной комплексной системы диагностирования были использованы параметры двигателя ПС-90А-76SW, зарегистрированные с помощью бортового накопителя РСМСИА, который имел реальную неисправность – “Вибрация двигателя”. В протоколе АСД-Диагноз-90 была зафиксирована критическая вибрация двигателя при перелете воздушного судна из Багдада во Франкфурт. Фрагмент фиксации критической вибрации, наблюдающейся в горизонтальном полете, приведен на рис. 5. Обработка полета была произведена согласно вышеуказанной методике. Качество результатов по отдельным алгоритмам приведено в табл. 1 и на рис. 6 – 8.

Таблица 1

Характеристики процесса обучения НС

$K_k^O, \%$	$K_k^T, \%$	L	J	k
99,96	18,755	11	2,43E-06	27
99,994	99,999	14	9,01E-06	45
99,881	100	16	4,18E-06	19
99,966	99,487	19	2,50E-06	20
99,878	99,908	20	4,39E-06	25
99,803	56,073	21	9,91E-06	31
99,659	35,527	30	8,77E-06	21
98,088	92,764	31	6,84E-06	20
99,495	99,947	32	8,58E-06	25
99,953	100	33	5,25E-06	15
99,684	88,646	34	6,92E-06	26
99,691	90,379	35	2,44E-06	97
99,438	99,722	38	9,28E-06	23
99,858	100	41	4,18E-06	16
97,62	100	43	7,38E-01	100
99,894	96,081	46	8,26E-01	100
99,154	99,622	47	7,68E-06	19
98,922	96,396	50	8,51E-06	28
99,776	83,812	55	8,36E-06	18
99,642	99,492	58	8,99E-06	18
99,897	100	60	9,06E-06	17

Таблица 2

Результаты распознавания ТС АГТД
(состояние "0" – исправное, "1" - неисправное)

№ изме- рений	MS	NS	Y	MS	NS	Y
	$V_{3П}$	$V_{3П}$	$V_{3П}$	V_{PK}	V_{PK}	V_{PK}
698(29)	1	1	1	1	1	1
699(30)	0	1	0	1	1	1
700(31)	0	1	0	1	1	1
701(32)	1	1	1	1	0	0
702(33)	1	1	1	1	0	0
703(34)	1	1	1	1	1	1
704(35)	1	1	1	1	1	1
705(36)	1	1	1	1	1	1
706(37)	1	1	1	1	1	1
707(38)	1	1	1	1	1	1
708(39)	0	0	0	1	1	1
709(40)	0	0	0	1	1	1
710(41)	0	0	0	1	1	1
711(42)	1	1	1	1	1	1
712(43)	1	1	1	0	1	0
713(44)	0	1	0	0	0	0
714(45)	0	0	0	0	0	0
715(46)	0	0	0	0	1	0
716(47)	0	0	0	0	1	0
717(48)	0	0	0	0	1	0
718(49)	0	0	0	0	1	0

Как следует из табл. 1, наилучшим коэффициентом качества за приемлемое количество итераций процесса обучения обладает многослойный перцептрон с 33 нейронами в скрытом слое. Как видно из рис. 6 – 8 и табл. 2, оба классификатора с высокой точностью распознали завышенную и заниженную вибрацию разделительного корпуса и задней подвески ротора вентилятора соответственно.

Полученные результаты подтвердились методами неразрушающего контроля эксплуатирующей организации.

Выводы

Анализ результатов, полученных с помощью предложенной системы диагностирования АГТД, позволяет сделать следующие выводы:

- методика отбора информативных признаков позволяет сократить входное и выходное пространство нейросетевой модели и тем самым способствует увеличению ее производительности;
- алгоритм “выращивания” сети позволяет, за приемлемое время обучения, уточнить необходимое

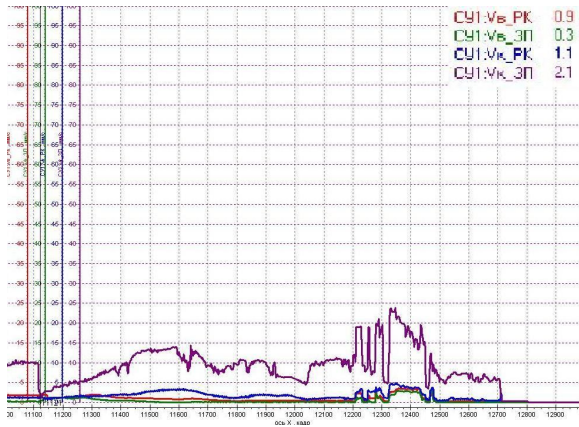


Рис. 5. Фрагмент визуализация предельных вибраций

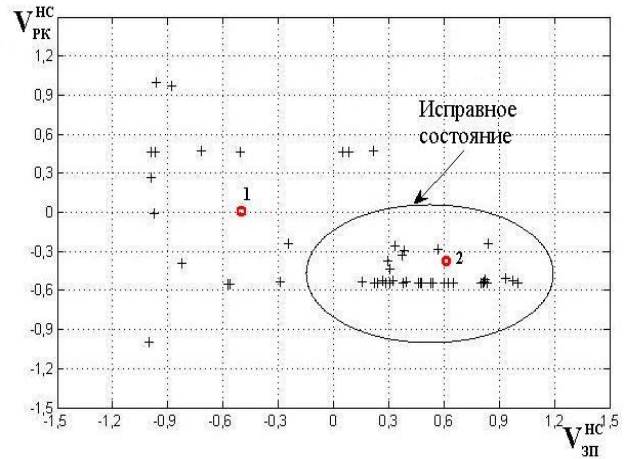
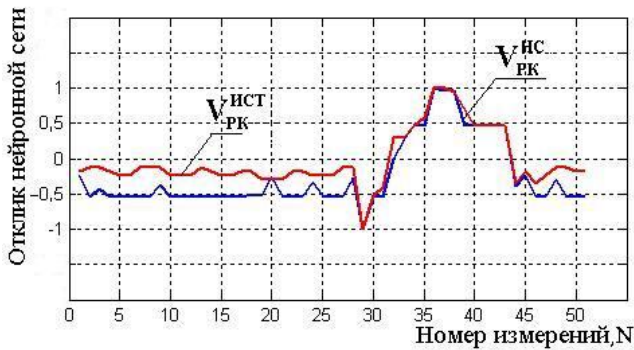
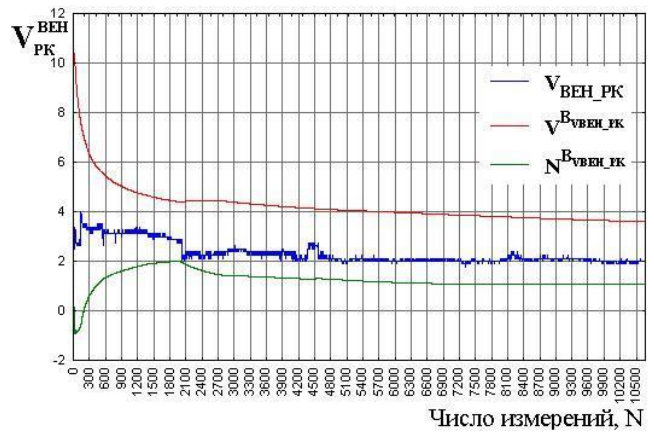


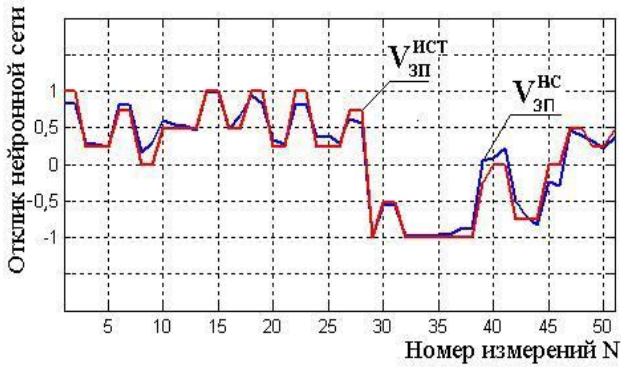
Рис. 7. Кластеризация данных сетью Кохонена



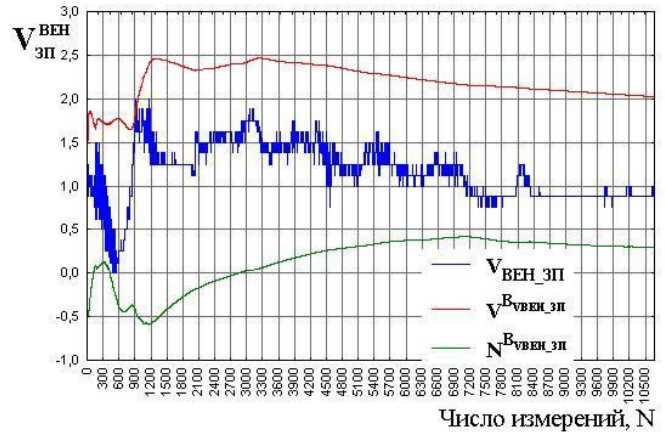
а



а



б



б

Рис. 6. Моделирование выходного параметра в нейросетевом базисе:

- а – вибрация ротора вентилятора в зоне разделительного корпуса;
- б – вибрация ротора вентилятора в зоне задней подвески

Рис. 8. Диапазоны возможных границ ВП:

- а – вибрация ротора вентилятора в зоне разделительного корпуса;
- б – вибрация ротора вентилятора в зоне задней подвески

количество нейронов в скрытом слое в целях избегания эффекта “переобучения”;

– разработанная комплексная система диагностирования показала свою эффективность: комбинированная НС позволяет производить с высокой точностью двухэтапную идентификацию ТС диагностируемого объекта;

– комбинированный алгоритм обучения способствует быстрому достижению наилучшего качества обучения с точки зрения точности оценки АГТД и времени принятия решения.

Данный подход и методика диагностирования могут быть применены для других типов АГТД.

Анализ результатов, полученных с помощью предложенной системы диагностирования АГТД, позволяет сделать следующие выводы:

– методика отбора информативных признаков позволяет сократить входное и выходное пространство нейросетевой модели и, тем самым, способствует увеличению его производительности;

– алгоритм “выращивания” сети позволяет за приемлемое время обучения уточнить необходимое количество нейронов в скрытом слое в целях избегания эффекта “переобучения”;

– разработанная комплексная система диагностирования показала свою эффективность, комбинированная НС позволяет производить с высокой точностью двухэтапную идентификацию ТС диагностируемого объекта;

– комбинированный алгоритм обучения способствует быстрому достижению наилучшего качества обучения с точки зрения точности оценки АГТД и времени принятия решения.

Данный подход и методика диагностирования может быть применена для других типов авиационных ГТД.

Литература

1. Рыбалко В.В. Параметрическое диагностирование энергетических объектов на основе факторно-

го анализа в среде Statistic // Мастерская решений. – 2004. – № 2 (6). – С. 78-83.

2. Kobayashi T., Simon D.L. Application of a Bank of Kalman Filters for Aircraft Engine Fault Diagnostics // Proc. of ASME Turbo Expo 2003. – Atlanta, USA; GT2003-38550. – P. 751-758.

3. Sampath S., Gulati A., Singh R. Fault Diagnostics using Genetic Algorithm for Advanced cycle Gas Turbine // Proc. of ASME Turbo Expo 2002. – Amsterdam, The Netherlands. – P. 211-251.

4. Bajwa A.R., Kulkarni D. Engine Data Analysis Using Decision Trees // Paper presented at the 36 Joint Propulsion Conference, 2000. – AIAA 2000-3627. – P. 591-601.

5. Tang G., Yates C.L., Chen D. Comparative study of two neural networks applied to jet engine fault diagnosis for turbofan engine // Proc. of ASME TURBO EXPO 2000, 2000-GT-0032. – P. 71-81.

6. Бажнов Е.Г., Ютаков А.А. Система диагностики газотурбинной двигательной установки на основе вейвлет-анализа и нейронных сетей // Успехи современного естествознания. Материалы XXXII Международной конференции «Информационные технологии в науке, образовании, телекоммуникации и бизнесе, IT+SE 2005». – Украина, Крым, Ялта-Гурзуф, изд. ЗГУ, 2005. – № 5. – С. 114-115.

7. Васильев В.И., Гусев Ю.М., Иванов А.И. и др. Автоматический контроль и диагностика систем управления силовыми установками летательных аппаратов. – М.: Машиностроение, 1989. – 332 с.

8. Ахмедзянов А.М., Юлдыбаев Л.Х. Вопросы технической диагностики состояния авиационных двигателей // Испытания авиационных двигателей. – Уфа: УАИ. – 1987. – № 5.

9. Абдуллаев П.Ш., Мирзоев А.Д. Диагностирование авиационных газотурбинных двигателей с использованием нейронных сетей // Elmi Məstuaələr. – 2006. – Cild 8. – № 3. – С. 3-7.

10. Shahtahtinskiy M.G., Abdullayev P.S., Mirzoyev A.C., Yakushenko A.S., Ohmakevich V.N.

Application Of Soft Computing Methods In Complex Condition Monitoring System For Aviation Gas Turbine Engines // Материалы 8 международной научно-технической конференции “АВИА – 2007”. – К.: НАУ. – 2007. – Т.2. – С. 31.14-31.17.

11. Шахтактинский М.Г., Абдуллаев П.Ш., Мирзоев А.Д. Нейронная идентификация технического состояния авиационных газотурбинных двигателей // Milli Aviasiya Akademiyasının Elmi Əsərləri. – 2005. – № 2. – С. 12-22.

12. Диагностирование и прогнозирование технического состояния авиационного оборудования: Учеб. пособие для вузов гражд. авиации / В.Г. Воробьев, В.В. Глухов, Ю.В. Козлов и др. Под ред. И.М. Синдеева. – М.: Транспорт, 1984. – 191 с.

13. Шахтактинский М.Г., Кучер А.Г., Абдуллаев П.Ш., Якушенко А.С., Мирзоев А.Д. Данные для обучения нейронной сети распознаванию ТС ГТД // Труды юбилейной международной научно-технической конференции, посвященной 15-летию национальной академии авиации. – 2007. – С. 122-125.

14. Gupta M., Jin L., Homma N. Static and Dynamic Neural Networks. – John Willey and Sons, 2003.

15. Шахтактинский М.Г., Абдуллаев П.Ш., Мирзоев А.Д., Якушенко А.С. Выбор оптимальной архитектуры нейронной сети для диагностирования авиационных ГТД // Milli Aviasiya Akademiyasının elmi əsərləri. – 2006. – №2. – С. 61-67.

16. Бюллетень № 94148-БЭ-АБ О внедрении в эксплуатацию второй очереди автоматизированной системы диагностирования АСД – Диагноз – 90 двигателя ПС-90А. – 64 с.

17. Мюллер П., Нойман П., Шторм Р. Таблицы по математической статистике. – М.: Финансы и статистика, 1982. – 287 с.

18. Kohonen T. Self-Organization and Associative Memory. – Springer-Verlag, Berlin-Heidelberg-New York-Tokio, 3 edition, 1989. – 255 p.

19. Kohonen T. Improved versions of learning vector quantization // Proceedings of the International Joint Conference on Neural Networks. – San Diego: IEEE, June 1990. – Vol. 1. – P. 545-550.

20. Хайкин С. Нейронные сети: полный курс. – М.: ООО И.Д. Вильямс, 2006. – 1104 с.

21. LVQ_PAK: The Learning Vector Quantization Program Package / T. Kohonen, J. Hynninen, J. Kangas and others. – Helsinki: Helsinki University of Technology, 1995. – 30 p.

22. Дубровин В.И., Субботин С.А., Согорин А.А. Радиально-базисные нейронные сети в задачах технической диагностики // Радиоэлектроника. Информатика. Управління. – 1999. – № 2 – С. 110-114.

23. Brotherton T., Johnson T. Anomaly Detection for Advanced Military Aircraft using Neural Networks// The 2001 IEEE Aerospace Conference, Big Sky, MT, March 2001. – P. 113-120.

24. Madhavan P.G. A new recurrent neural network learning algorithm for time series prediction // Journal of Intelligent Systems. – 1997. – № 7. – N 1, 2. – P.103-116.

25. Пашаев А.М., Садыхов Р.А., Макаров Н.В., Абдуллаев П.Ш. Диагностика авиационных газотурбинных двигателей. – Баку: Sigma, 2004. – 188 с.

26. Медведев В.С., Потемкин В.Г. Нейронные сети Matlab 6 / Под общ. ред. В.Г. Потемкина. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.

27. Дьяконов В.П., Круглов В.В. Matlab 6.5 SP1/7/7 SP1/7 SP2 + Simulink 5/6 Инструменты искусственного интеллекта и биоинформатики // Серия "Библиотека профессионала". – М.: СОЛОН – ПРЕСС, 2006. – 456 с.

Поступила в редакцию 3.10.2007

Рецензент: академик, д-р техн. наук, проф. Т.А. Алиев, Институт кибернетики Национальной академии наук Азербайджана, Баку.