

УДК 681.3.069:681.3.015

С. В. Жернаков, доктор технических наук, профессор
Уфимский государственный авиационный технический университет

ПРИМЕНЕНИЕ ТЕХНОЛОГИИ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ДИАГНОСТИКИ ТЕХНИЧЕСКОГО СОСТОЯНИЯ АВИАЦИОННЫХ ДВИГАТЕЛЕЙ

Рассматривается применение технологии нейронных сетей для решения задач контроля и диагностики авиационных двигателей. Приводится методика и примеры решения таких задач в нейросетевом базисе.

Введение

Газотурбинный двигатель (ГТД) как восстанавливаемый объект в течение срока службы требует непрерывного мониторинга, трудоемкость которого зависит от уровня автоматизации процессов получения, обработки, хранения, документирования информации о текущем состоянии авиационного двигателя, последовательность и методы выполнения которых определяют информационную технологию мониторинга.

Несмотря на значительный объем исследований в данной области, информационные технологии мониторинга технического состояния ГТД не являются совершенными по ряду причин, основными из которых являются, с одной стороны, разобщенность баз данных испытаний, отсутствие интеллектуальных компонент, позволяющих качественно и эффективно осуществлять поддержку принятия решений и, как следствие, сокращать общее время, затрачиваемое на обслуживание ГТД; с другой стороны, нестационарность физических процессов в авиационном двигателе, сложность его математического описания, зависимость технических характеристик двигателя от внешних условий работы, ограниченный состав измеряемых термогазодинамических параметров двигателя, их технологический разброс и т. д. Указанные факторы приводят к необходимости принятия решений о техническом состоянии двигателя в условиях существенной неопределенности.

Основными направлениями, определяющими повышение качества информационных технологий мониторинга технического состояния ГТД, следует считать интеллектуализацию процессов обработки информации с привлечением методов интеллектуального анализа данных, которые способны обеспечить повышение качества распознавания технического состояния ГТД при действии указанных выше неопределенных факторов, а также интеграцию информационных процессов (распределенных локальных баз данных и знаний в глобальную базу данных и знаний).

Методы интеллектуального анализа данных представляют собой новое направление, дополняющее и развивающее классические статистические методы исследования [1], часто именуемые в отечественной и зарубежной литературе как Data Mining – «добыча» данных и обнаружение знаний. Data Mining использует современные интеллектуальные технологии, включающие нейронные сети, нечеткую логику, экспертные системы. Эти технологии используются в данной работе для решения широкого спектра задач мониторинга технического состояния ГТД.

Анализ работ в области контроля и диагностики состояния авиационных ГТД на основе нейронных сетей [5; 8; 10–16; 18; 19; 21–25] показывает, что в настоящее время такие работы ведутся, однако в силу ряда причин (секретность, узкая специализация решаемых задач) в большинстве публикаций отсутствуют инженерные методики, а также теоретические и практические рекомендации по решению подобных задач. Ниже исследуются постановки задач и возможные алгоритмы выбора архитектуры нейронных сетей, алгоритмов их обучения, оценки эффективности их работы и т. д., разрабатывается инженерная методика решения задач контроля и диагностики состояния ГТД с использованием нейросетевых технологий.

Применение FDI-метода для решения задач контроля и диагностики ГТД

В основе предложенной методологии решения задач контроля и диагностики технического состояния ГТД используется метод FDI (Fault Detection and Identification), основанный на сравнении результатов измерений газодинамических параметров реального ГТД с расчетными параметрами, вычисленными по его математической модели [2; 3; 9; 17; 21].

На рис. 1 показана типовая реализация FDI-метода, где $\bar{U}$ – вектор управляющих воздействий; $\bar{Y}_m$ – вектор параметров, вычисленных с помощью математической модели (ММ) ГТД; $\bar{Y}_g$ – вектор выходных параметров двигателя, полученных путем измерения с помощью датчиков; $\bar{\varepsilon} = \bar{Y}_g - \bar{Y}_m$ – невязка, представляющая собой разность векторов $\bar{Y}_g$ и $\bar{Y}_m$.




Рис. 1. Реализация FDI-метода

Ниже в качестве математической модели ГТД используется нейросетевая модель ГТД. Спектр задач, решаемых с помощью такой модели в рамках FDI-метода, достаточно широк – от задач контроля и диагностики технического состояния ГТД до отладки его параметров.

Основные этапы инженерной методики построения нейросетевой модели включают:

1. Предварительный анализ данных на этапе постановки задачи и выбора архитектуры нейронной сети.
2. Преобразование данных (предобработка) для построения более эффективной процедуры настройки сети.
3. Выбор архитектуры нейронной сети.

4. Выбор структуры нейронной сети.
5. Выбор алгоритма обучения.
6. Обучение и тестирование нейронной сети.
7. Анализ точности нейросетевого решения.
8. Принятие решения на основе полученных результатов.

Диагностика технического состояния ГТД на основе нейронных сетей

Анализ опубликованных работ, посвященных применению нейронных сетей для диагностирования параметров авиационного двигателя, показывает, что в этих работах выделены основные тенденции и характерные особенности решения задач диагностики ГТД на основе НС. Вместе с тем они посвящены, как правило, решению частных задач (например, диагностированию состояния лопаток турбины ГТД [19], формированию пространства диагностических признаков состояния ГТД для построения нейросетевого классификатора [18; 19], косвенному измерению температуры газов за камерой сгорания на основе НС для диагностирования теплового состояния двигателя [25]). В них не содержится указаний на выбор архитектуры, структуры и алгоритмов обучения НС; отсутствует инженерная методика проектирования таких сетей применительно к задачам диагностики технического состояния авиационных двигателей. Ниже исследуются нейросетевые алгоритмы решения задач диагностики ГТД с целью выявления основных закономерностей их использования и разработки соответствующих методов, алгоритмов и методик реализации диагностирования технического состояния ГТД на основе НС [5; 10–16; 19].

Постановка задачи

Пусть состояние ГТД как объекта диагностирования определяется значением вектора выходных параметров Y , значения которого могут меняться при возникновении аварийных или критических ситуаций в работе авиационного двигателя. Предполагается, что все возможные его состояния можно разбить на $(r + 1)$ областей (классов) $S_0, S_1, \dots, S_r$. Нахождение вектора состояния X в области S_0 определяется как событие, соответствующее исправному состоянию ГТД. При любом из возможных отказов элементов (узлов) в работе ГТД (внезапных или постепенных) вектор X принадлежит одной из областей $S_1, \dots, S_r$, что рассматривается как событие, связанное с неисправным состоянием двигателя $\bar{S}_0$:

$$\bar{O} \in \bar{S}_0 = US_\alpha; \alpha = 1, \dots, r.$$

Тогда задача диагностирования состояния ГТД заключается в том, чтобы установить соответствие между координатами вектора наблюдений Y и пространства состояний $\{S_\alpha\}$ и на основании наблюдаемых реализаций Y оценить принадлежность вектора состояния X области S_0 или $S_\alpha \subset \bar{S}_0$, т. е. определить, к какому из классов относится состояние конкретного экземпляра ГТД.

Как отмечалось выше, в качестве основы построения систем диагностики ГТД целесообразно использовать FDI-метод. Рассмотрим особенности применения данного метода при решении задач диагностики с использованием нейросетевых алгоритмов. Реализация FDI-метода в нейросетевом базисе (рис. 2) сводится к следующей последовательности шагов:

- хранение эталонных характеристик среднестатистического ГТД в виде «информационного портрета» на базе сети НС-1;

- сравнение параметров отдельно взятого ГТД с данными, рассчитанными с помощью НС-1;
- на основании анализа вектора полученных невязок (отклонений) ΔY между значениями вектора измеренных параметров конкретного двигателя и вектора данных, рассчитанных с помощью НС-1, принимается решение о техническом состоянии ГТД (на этом этапе используется вторая нейронная сеть НС-2).




Рис. 2. Реализация FDI-метода в нейросетевом базисе

В качестве характеристик индивидуального ГТД на этапе настройки (обучения) НС-2 могут использоваться:

- а) математическая модель двигателя с имитируемыми дефектами;
- б) реальные данные по дефектным ГТД, полученные на этапе испытаний.

Сеть НС-2 (рис. 3) представляет собой бинарный нейроклассификатор, на входы которого поступают значения указанных выше отклонений (невязок) Δy_i , а выходы образуют бинарный вектор $R = \{R_1, R_2, \dots, R_m\}$, компоненты которого отражают результаты диагноза.




Рис. 3. Классификатор на основе НС-2

Для решения задачи диагностики ГТД в нейросетевом базисе используется обучающая выборка, которая формируется в два этапа. На первом этапе решается прямая задача, которая связана с созданием банка данных дефектов. С этой целью на математической модели, описывающей индивидуальный ГТД, имитируются проявления дефектов, связанных с изменением, например, КПД компрессора, КПД турбины и др. (рис. 3). На втором этапе вычисляются отклонения (невязки), вызванные тем или иным дефектом ГТД от его эталонного состояния: $\Delta Y = Y_{\text{эт}} - Y_{\text{м}}$. Согласно данным о невязках ΔY_i формируется обучающая выборка, которая в общем виде может быть представлена как $\Delta Y_i \rightarrow R$ ($i = 1, 2, \dots, n$).

В качестве диагностических признаков (входов НС-2) использовалась информация по 10 параметрам двигателя: отклонения частоты вращения Δn_2 ротора турбокомпрессора высокого давления; расхода воздуха ΔG_v через двигатель; температуры ΔT_2^* и давления ΔP_2^* воздуха за компрессором; температуры газа перед турбиной ΔT_3^* ; температуры ΔT_4^* и давления ΔP_4^* газа за турбиной; давления газа ΔP_6^* на срезе реактивного сопла; расход топлива ΔG_t ; тяги двигателя ΔR .

Для обучения распознаванию дефектов нейронной сетью в составе обучающей выборки были выделены пять обобщенных классов состояний двигателя (табл. 1):

- S_1 – исправное состояние, соответствующее вектору $R = [0; 0; 0]$;
- S_2 – дефект компрессора, соответствующий вектору $R = [0; 1; 0]$;
- S_3 – дефект турбины, соответствующий вектору $R = [1; 0; 0]$;
- S_4 – дефект камеры сгорания, соответствующий вектору $R = [0; 1; 1]$;
- S_5 – дефект реактивного сопла, соответствующий вектору $R = [1; 0; 1]$.

Таблица 1. Бинарная классификация состояний ГТД

Номер состояния	Бинарные выходы НС			Состояние	Локализация дефекта
	R_1	R_2	R_3		
1	0	0	0	ETALON	Эталонное состояние (S_0)
2	0	1	0	PiKND5%	Дефект в компрессоре (S_1)
3	0	1	0	KPDKND5	
4	0	1	0	GVND5%	
5	0	1	0	PiKVD5%	
6	0	1	0	KPDKVD5	
7	0	1	0	GVVD5%	
8	1	0	1	Fkr c5%	Дефект в реактивном сопле (S_2)
9	1	0	1	SIGSOP5	
10	1	0	1	PR_Fc5%	
11	1	0	0	KPDMVD5	Дефект в турбине (S_3)
12	1	0	0	KPDMND5	
13	1	0	0	KPDTVD5	
14	1	0	0	KPDTND5	
15	1	0	0	ATVD5%	
16	1	0	0	ATND5%	
17	0	1	1	SIGKC5%	Дефект в камере сгорания (S_4)
18	0	1	1	PR_Kc5%	

При составлении обучающей выборки учитывалось, что появление дефекта в авиационном двигателе обычно связано с изменением геометрических размеров его проточной части, что приводит к изменению характеристик его узлов и его термогазодинамических параметров. Так, уменьшение КПД компрессора и его степени сжатия, как правило, вызвано загрязнением, забоинами, вытяжкой, поломками, эрозиями лопаток компрессора, а также разрушением подшипников (выкрашиванием дорожек), масляным «голоданием», деформацией статора. Уменьшение КПД турбины может быть обусловлено такими дефектами, как прогар, обрыв, эрозия рабочих лопаток турбины и лопаток соплового аппарата, а также дефектами подшипника, наличием стружки в масле и т. д. [2; 9].

Для проверки качества работы нейросетевого классификатора (НС-2) необходимо провести его тестирование, т. е. предъявлять на вход сети данные, не входящие в состав обучающей выборки. В процессе тестирования НС-персептрон рассматривались следующие случаи:

- а) уменьшение КПД компрессора низкого давления на 1 % ($-1\% \eta_{\text{КНД}}$);
- б) уменьшение КПД компрессора низкого давления на 3 % ($-3\% \eta_{\text{КНД}}$);
- в) дефекты вида а) и б) при наличии шума ($\sigma = 0,01$; $M = 0$);
- г) двойной дефект (одновременное уменьшение КПД компрессора низкого давления на 3 % ($-3\% \eta_{\text{КНД}}$) и КПД турбины низкого давления на 3 % ($-3\% \eta_{\text{ТНД}}$).

Результаты тестирования нейросетевого классификатора, построенного на основе персептрона, с учетом перечисленных выше случаев, показали высокое качество диагностирования технического состояния ГТД, что подтверждается результатами, приведенными в табл. 2.

Таблица 2. Качество работы нейросетевого классификатора (НС-2)

№ строки	Значения выходов НС-2			Состояния
	R_1	R_2	R_3	
1	0,148	0,689	0,226	Дефект в компрессоре ($-1\% \eta_{\text{КНД}}$)
2 (с шумом)	0,221	0,715	0,312	
3	0,157	0,732	0,293	Дефект в компрессоре ($-3\% \eta_{\text{КНД}}$)
4 (с шумом)	0,265	0,765	0,35	
5	0,54	0,44	0,02	Дефект в компрессоре и турбине ($-1\% \eta_{\text{КНД}}$) ($-3\% \eta_{\text{КНД}}$)

Анализ табл. 2 показывает, что значения выходов нейроклассификатора в процессе его тестирования отличаются от выходов НС-2 на обучающей выборке (табл. 1), где осуществлялось обучение сети на прецеденты, характеризующиеся 5%-м отклонением параметров состояния ГТД. По значениям компонент R_i при этом можно оценить интенсивность дефекта (чем больше интенсивность дефекта, тем меньше расстояние до соответствующего прецедента). В случае двойного дефекта (5-я строка табл. 2) значения выходов сети R_1 и R_2 примерно одинаковы, что указывает на равноудаленность состояния ГТД к двум прецедентам (эталонным состояниям).

Проводилось исследование зависимости эффективности диагностирования ГТД от числа штатных датчиков (измеряемых параметров). Для исследования этого во-

проса с учетом особенностей нейросетевой реализации процедуры диагностирования использовался метод главных компонент [1; 17]. На основе ковариационного анализа данных было установлено, что среди десяти измеряемых параметров в качестве главных компонент можно выделить 7 параметров: n_2 , P_2^* , T_3^* , T_4^* , P_4^* , P_6^* , R .

В табл. 3 приведены результаты диагностирования состояния ГТД с помощью НС при различном числе используемых штатных датчиков (от семи до четырех).

Таблица 3. Изменение ошибки обучения и тестирования НС в зависимости от количества датчиков

Измеряемые параметры	Ошибка обучения ($E_{\text{обуч}}$)	Ошибка тестирования ($E_{\text{тест}}$)
$n_2, P_2^*, T_3^*, T_4^*, P_4^*, P_6^*, R, T_{2..(10)}^*$	0,035	0,0211
$n_2, P_2^*, T_3^*, T_4^*, P_4^*, P_6^*, R$	0,011	0,127
$n_2, P_2^*, T_3^*, T_4^*, P_4^*, P_6^*$	0,021	0,171
$n_2, P_2^*, T_3^*, T_4^*, P_4^*$	0,032	0,221
n_2, P_2^*, T_4^*, P_4^*	0,058	0,271

Ошибка обучения НС при этом вычисляется по формуле

$$\hat{A}_{\text{обуч}} = \|R_{\text{эт}} - R\|,$$

где $R_{\text{эт}}$ – вектор эталонных (желаемых) выходов НС-2; R – вектор фактических выходов сети; $\|\cdot\|$ – евклидова норма.

Желаемые значения $(R_{\text{эт}})_i$ на выходах НС соответствуют значениям R_1, R_2, R_3 (табл. 1), число столбцов обучающей выборки последовательно уменьшалось от 7 до 4. На рис. 4 показана зависимость изменения ошибок обучения ($\hat{A}_{\text{обуч}}$) и тестирования ($\hat{A}_{\text{тест}}$) сети от количества используемых датчиков (входов сети). Результаты анализа (рис. 4) показывают, что качество процесса диагностирования ГТД ухудшается при уменьшении числа датчиков. Вместе с тем использование 5–7 штатных датчиков оказывается достаточным для локализации дефекта с точностью до узла, так как суммарная квадратическая ошибка сети при этом не превышает 0,03 на обучающей выборке (т. е. для эталонных дефектов) и 0,225 на тестовой выборке (для заранее неизвестных дефектов).

С целью сравнительной оценки эффективности разработанного нейросетевого метода диагностирования производилось сравнение предложенного способа решения задачи с решением этой задачи на основе метода наименьших квадратов (МНК). Данный метод основан на построении аппроксимационной зависимости $R = f(\Delta Y)$, где R – вектор выходов классификатора (см. рис. 4), приведенных в табл. 3, а ΔY – вектор отклонений параметров на входе классификатора. Исследования, проведенные с помощью пакета *Statistica 6.0*, показали, что для обеспечения достаточной точности диагностирования необходимо использовать полиномы не менее 12-й степени. Результаты, полученные с помощью МНК, приведены в табл. 4. Данные результаты получены для тестовой выборки и соответствуют

1%-му и 3%-му уменьшению $\eta_{\text{КНД}}$, а также наличию аддитивной составляющей шума ($\sigma = 0,01$; $M = 0$).




Рис. 4. Зависимость качества обучения и тестирования НС от количества измеряемых параметров ГТД

Сравнение результатов, приведенных в табл. 4, с данными табл. 1 показывает, что диагностируемые дефекты выявляются. Как и ранее, по значениям выходов классификатора можно судить об интенсивности дефекта. Сравнительный анализ качества работы нейросетевого и МНК классификаторов (табл. 2 и табл. 4) показывает, что они обеспечивают примерно одинаковые показатели качества диагностирования состояния ГТД, однако в условиях наличия шумов нейронная сеть дает меньшую ошибку распознавания.

Таблица 4. Результаты тестирования классификатора, построенного на основе МНК

№ строки	Значения выходов классификатора			Состояния
	R_1	R_2	R_3	
1	0,037	0,648	0,334	Дефект в компрессоре (–1 % $\eta_{\text{КНД}}$)
2 (с шумом)	0,211	0,687	0,214	
3	0,082	0,692	0,356	Дефект в компрессоре (–3 % $\eta_{\text{КНД}}$)
4 (с шумом)	0,288	0,715	0,231	

Особенностью рассмотренных выше классификаторов является обучение их характеристик на обучающем множестве (обучение с учителем). Вместе с тем представляет интерес исследование возможности построения алгоритмов диагностирования состояния ГТД без учителя, т. е. в режиме самообучения. Реализация таких алгоритмов в нейросетевом базисе возможна на основе сетей Кохонена (рис. 5), которые считаются самообучаемыми (самоорганизующимися). Основу обучения таких сетей составляет конкуренция между нейронами. В рассматриваемом случае сеть Кохонена имеет 10 входов и 5 выходов $R_1 \dots R_5$ (по числу обобщенных классов состояний в табл. 1).




Рис. 5. Классификатор на основе НС Кохонена

Весовые коэффициенты синаптических связей каждого i -го нейрона выходного слоя НС Кохонена образуют вектор:

$$w_i = [w_{i_1}, w_{i_2}, \dots, w_{i_{i_0}}]^T, \quad (i = 1, 2, \dots, n).$$

При активации НС Кохонена входным вектором ΔY в конкурентной борьбе побеждает тот нейрон, веса которого в наименьшей степени отличаются от соответствующих компонентов входного вектора, т. е. для нейрона-победителя w_p выполняется отношение

$$d(\Delta Y, w_p) = \min d(\Delta Y, w_i), \quad 1 \leq i \leq n. \quad (1)$$

Здесь $d(\Delta Y, w_i)$ – расстояние (в смысле выбранной метрики) между векторами ΔY и $w = (w_1, w_2, \dots, w_n)^T$; n – количество выходов НС выходного слоя (в данном случае $n = 5$). Нейрон-победитель образует вокруг себя некоторую топологическую окрестность $S_p(k)$ с определенной энергетикой, а все нейроны, лежащие в пределах данной окрестности, подвергаются адаптации, в ходе которой их векторы весовых коэффициентов изменяются в направлении вектора ΔY по правилу [19]:

$$w_i(k+1) = w_i(k) + \eta_i(k) [\Delta Y - w_i(k)], \quad (2)$$

где $\eta_i(k)$ – коэффициент обучения i -го нейрона из окрестности $S_p(k)$ в k -й момент времени. Значение коэффициента обучения уменьшается с увеличением рас-

стояния между i -м нейроном и победителем, а весовые коэффициенты нейронов, находящихся за пределами окрестности $S_p(k)$, не изменяются.

Целью обучения НС Кохонена на основе конкуренции нейронов считается такое упорядочение нейронов (подбор значений их весовых коэффициентов), которое минимизирует значение ожидаемого искажения, оцениваемого погрешностью аппроксимации входного вектора ΔY , значениями весовых коэффициентов нейрона-победителя. При L входных векторах $(\Delta Y)_j$, $(j = 1, 2, \dots, L)$ и евклидовой метрике эта погрешность может быть выражена как

$$E = \frac{1}{L} \sum_{j=1}^L \|(\Delta Y)_j - w_p(j)\|^2, \quad (3)$$

где $w_p(j)$ – весовые коэффициенты нейрона-победителя при предъявлении сети вектора $(\Delta Y)_j$.

Результаты процесса обучения НС Кохонена (после 700–800 циклов обучения) приведены в табл. 5.

Таблица 5. Результаты работы НС Кохонена

Выходы сети	R_1	R_2	R_3	R_4	R_5
Количество состояний (частоты выигрышей)	5	7	1	2	3
Состояния	Дефект в компрессоре	Дефект в турбине	Исправное состояние	Дефект в камере сгорания	Дефект в реактивном сопле

Как видно из табл. 5, сеть Кохонена самостоятельно провела кластерный анализ. Сравнение этих результатов с данными (табл. 1), где приведены эталонные состояния двигателя, показывает их полное совпадение с классификацией НС Кохонена. Здесь 2-я строка определяет количество диагностируемых состояний, отнесенных НС к соответствующему классу (из общего количества 18 предъявленных ей состояний).

Результаты тестирования неизвестных состояний ГТД с помощью сети Кохонена приведены в табл. 6. По аналогии с рассмотренными ранее примерами качество работы НС Кохонена при этом исследовалось на тестовой выборке в условиях без шума (см. 1-ю и 3-ю строки табл. 6), а также в условиях аддитивной составляющей белого шума ($\sigma = 0,01$; $M = 0$), для 1% и 3%-го изменения КПД компрессора низкого давления (см. 2-ю и 4-ю строки табл. 6). Последняя строка табл. 6 соответствует двойному дефекту, состоящему в одновременном изменении КПД компрессора и турбины низкого давления.

Анализ результатов тестирования классификатора на основе НС Кохонена показывает, что нейроном-победителем (для строк 1, 2, 3, 4) является нейрон, имеющий выход R_1 , а это означает, что в соответствии с табл. 1 выявляется дефект в компрессоре. Как и ранее, по числовому значению на каждом из выходов НС можно судить об интенсивности дефекта. В 5-й строке табл. 6 – два нейрона-победителя,

т. к. максимальные значения сигналов имеют место для выходов R_1 и R_2 . Согласно табл. 1 НС Кохонена выявляет при этом указанный выше двойной дефект (уменьшение КПД компрессора и турбины низкого давления).

Таблица 6. Результаты тестирования классификатора, построенного на основе НС Кохонена

№ строки	Значения выходов классификатора					Состояния
	R_1	R_2	R_3	R_4	R_5	
1	0,61	0,086	0,01	0,012	0,1	Дефект в компрессоре ($-1\% \eta_{кнд}$)
2 (с шумом)	0,72	0,15	0,21	0,14	0,26	
3	0,67	0,125	0,24	0,034	0,18	Дефект в компрессоре ($-3\% \eta_{кнд}$)
4 (с шумом)	0,75	0,31	0,37	0,184	0,32	
5	0,51	0,48	0,01	0,02	0,01	Дефект в компрессоре и турбине ($-3\% \eta_{кнд}$; $-3\% \eta_{кнд}$)

Сравнительный анализ нейросетевых (табл. 2, табл. 6) и классического (табл. 4) методов классификации технического состояния ГТД показывает, что они практически одинаковы по качеству работы. Но если для персептрона и МНК используется процесс обучения с учителем (заранее известны классы состояний), то при диагностировании авиационного двигателя с помощью самоорганизующейся карты Кохонена разбиение диагностического пространства признаков на классы осуществляется автоматически, количество кластеров в данном случае заранее неизвестно, что является преимуществом.

Как уже отмечалось, завершающим этапом реализации FDI-метода (см. рис. 1) является принятие решения о типе отказа в ГТД на основе анализа числового вектора R . Графическая интерпретация принятия решения для персептрона и МНК показана на рис. 6, где вершины куба соответствуют центрам кластеров (эталонных состояний ГТД) (табл. 1). Фактический вектор состояния двигателя S может принимать значения в любой точке внутри данного куба:

$$S = (R_1, R_2, R_3)^T, \quad 0 \leq R_i \leq 1.$$

Определение технического состояния ГТД осуществляются по правилу «ближайшего соседа» [19], на основании которого ГТД зачисляется в тот класс, которому принадлежит его ближайший сосед (или большинство из его ближайших соседей). Решающее правило, на основании которого осуществляется принятие решения (постановка диагноза) записывается следующим образом:

$$S \rightarrow S_p, \text{ если } d(S, S_p) \rightarrow \min_i, \quad (4)$$

где d – расстояние до центра ближайшего (p -го) кластера (прецедента). При этом расстояние d вычисляется, например, с использованием евклидовой метрики (4).

Рассмотрим данную процедуру на примере задачи диагностирования двойного дефекта, связанного с уменьшением КПД компрессора и турбины низкого давления на 3 %. Величина вектора на выходе НС-2 персептрон в данном случае

$R = (0,54; 0,44; 0,02)^T$. Тогда, учитывая эталонные состояния $S_0 \dots S_4$ авиационного двигателя (табл. 1) и используя формулу (4), можно вычислить расстояние d от соответствующего прецедента до центров кластеров:

$$d(S, S_0) = 0,697; \quad d(S, S_3) = 0,637;$$

$$d(S, S_1) = 0,778; \quad d(S, S_4) = 1,25;$$

$$d(S, S_2) = 1,17.$$




Рис. 6. Графическая интерпретация процесса диагностирования технического состояния ГТД: S_0 – центр кластера (прецедент), соответствующий исправному (эталонному) состоянию ГТД; S_1 – центр кластера, соответствующий дефекту в компрессоре; S_2 – центр кластера, соответствующий дефекту в реактивном сопле; S_3 – центр кластера, соответствующий дефекту в турбине; S_4 – центр кластера, соответствующий дефекту в камере сгорания

Анализ полученных значений $d(S, S_i)$ показывает, что результатом решения данной задачи будет $S \in S_0 \cup S_1 \cup S_3$, т. е. предъявляемый нейронной сети прецедент примерно равноудален от следующих состояний: исправное состояние (S_0), дефект в компрессоре (S_1) и дефект в турбине (S_3). Таким образом, диагноз сети – умеренный по интенсивности дефект в 2 узлах авиационного двигателя (компрессоре и турбине низкого давления).

На основании приведенных выше результатов, можно сформулировать следующие выводы.

1. Нейросетевые технологии можно эффективно применять для решения задач диагностирования технического состояния ГТД. Они позволяют работать как с реальными данными, полученными для индивидуального и эталонного (среднестатистического) авиационного двигателя, так и с данными, вычисленными с помощью его математической модели, на основании сравнения которых можно принимать обоснованные решения о характере и месте расположения того или иного дефекта.

2. В отличие от методов диагностирования, основанных на расчете термогазодинамических параметров ГТД с помощью нелинейных поэлементных моделей двигателя, реализация нейросетевого метода диагностирования базируется на обучении нейронной сети по данным малой обучающей выборки с проверкой качества полученной нейросетевой модели на специальном образом организованной тестовой выборке.

3. Проведенный сравнительный анализ показал возможность решения поставленных задач диагностирования состояния ГТД с помощью различных архитектур нейронных сетей (персептрон, самоорганизующаяся сеть Кохонена), а также метода наименьших квадратов, обеспечивающих высокую достоверность распознавания дефектов, включая двойные дефекты в различных узлах авиационного двигателя.

4. Показано, что для снижения сложности (избыточности нейронной сети) необходимо уменьшать число нейронов скрытого слоя при заданном уровне ошибки обучения сети. Минимальное число нейронов скрытого слоя для случая 10 штатных датчиков термогазодинамических параметров двигателя и пяти классов типовых дефектов узлов ГТД может быть снижено до 10–15 при высоком качестве распознавания состояния авиационного двигателя. При уменьшении числа штатных датчиков до 4–7 обеспечивается приемлемое качество диагностирования.

5. Преимуществом использования сети Кохонена для решения задачи диагностирования ГТД является отсутствие указаний эксперта, т. е. возможность автоматической классификации (кластеризации) состояний двигателя по предъявляемой сети обучающей выборке, состоящей из реальных или вычисленных (эталонных) данных для различных режимов работы двигателя.

6. Проверка эффективности работы нейронных сетей и МНК в условиях аддитивной (случайной) помехи показало сохранение высокого качества диагностирования ГТД, т. е. робастность этих методов по отношению к искажению входных данных.

7. Принятие решений о месте и характере дефекта в реальном ГТД может производиться на основе сравнения выхода нейроклассификатора, построенного на базе персептрона или сети Кохонена, с множеством прецедентов путем использования правила ближайшего соседа. По величине метрики (расстояния до ближайшего прецедента) при этом можно судить об интенсивности дефекта или о кратности дефекта (т. е. числе одновременно проявляющихся дефектов).

Список литературы

1. Айвазян, С. А. Прикладная статистика. Исследование зависимостей / С. А. Айвазян, И. С. Енюков, Л. Д. Мешалкин. – М. : Финансы и статистика, 1985. – 385 с.
2. Ахмедзянов, А. М. Диагностика состояния ВРД по термогазодинамическим параметрам / А. М. Ахмедзянов, Н. Г. Дубравский, А. П. Тунаков. – М. : Машиностроение, 1983. – 206 с.
3. Васильев, В. И. Автоматический контроль и диагностика систем управления силовыми установками летательных аппаратов / В. И. Васильев, Ю. М. Гусев, А. И. Иванов и др. – М. : Машиностроение, 1989. – 240 с.
4. Васильев, В. И. Экспертные системы: управление эксплуатацией сложных технических объектов : учеб. пособие / В. И. Васильев, С. В. Жернаков. – Уфа : УГАТУ, 2003. – 106 с.
5. Васильев, В. И. Нейросетевой контроль параметров газотурбинного двигателя / В. И. Васильев, С. В. Жернаков, Л. Б. Уразбахтина // Нейрокомпьютеры: разработка и применение. – М. : Радиотехника. – 2001. – № 1. – С. 37–43.
6. Васильев, С. Н. Интеллектуальное управление динамическими системами / С. Н. Васильев, А. К. Жерлов, Е. А. Федосов, Б. Е. Федун. – М. : Физматлит, 2000. – 352 с.

7. Герман, О. В. Введение в теорию экспертных систем и обработку знаний. – Минск : Дизайн ПРО, 1995. – 255 с.
8. Дмитриев, С. А. Особенности использования *FU-GE-NE-SYS* алгоритмов в процессе синтеза нейронной модели состояния авиационного двигателя / С. А. Дмитриев, А. Г. Кучер, Л. А. Журавлева и др. // Авиационно-космическая техника и технологии. – Вып. 19. – Харьков : ХГАТУ, 2000. – С. 372–376.
9. Епифанов, С. В. Синтез систем управления и диагностирования газотурбинных двигателей / С. В. Епифанов, Б. И. Кузнецов, И. Н. Богаенко и др. – Киев : Техника, 1998. – 312 с.
10. Жернаков, С. В. Диагностика и прогнозирование состояния газотурбинного двигателя гибридными нейронечеткими экспертными системами // Известия РАН. Теория и системы управления. – 1999. – № 5. – С. 95–101.
11. Жернаков, С. В. Применение экспертных систем с нейросетевыми базами знаний к диагностике и контролю устройств авиационных двигателей // Информационные технологии. – М. : Машиностроение. – 2000. – № 12. – С. 37–44.
12. Жернаков, С. В. Нейросетевая экспертная система комплексного мониторинга и управления эксплуатацией авиационных двигателей // Нейрокомпьютеры: разработка, применение. – М. : Радиотехника. – 2001. – № 6. – С. 33–40.
13. Жернаков, С. В. Применение динамических экспертных систем с нейросетевыми базами знаний в процессе эксплуатации авиационных двигателей / Информационные технологии. – М. : Машиностроение. – 2001. – № 6. – С. 42–48.
14. Жернаков, С. В. Интеллектуальный мониторинг и диагностика параметров газотурбинного двигателя гибридными экспертными системами // Автоматизация и современные технологии. – М. : Машиностроение. – 2001. – № 12. – С. 16–22.
15. Жернаков, С. В. Активная диагностическая экспертная система // Проблемы машиностроения и надежности машин. – М. : РАН. – 2002. – № 1. – С. 92–99.
16. Жернаков, С. В. Контроль и диагностика параметров газотурбинного двигателя нейронными сетями // Нейрокомпьютеры: разработка, применение. – М. : Радиотехника. – 2003. – № 8–9. – С. 51–66.
17. Надежность, диагностика, контроль авиационных двигателей / В. Т. Шепель, М. Л. Кузьменко, С. В. Сарычев и др. – Рыбинск : РГТА, 2001. – 352 с.
18. Научный вклад в создание авиационных двигателей / под ред. В. А. Скибина и В. И. Солониной. Кн. 1. – М. : Машиностроение, 2000. – 625 с.
19. Нейрокомпьютеры в авиации (самолеты) / под ред. В. И. Васильева, Б. Г. Ильясова, С. Т. Кусимова. – М. : Радиотехника, 2004. – 496 с.
20. Трахтенгерц, Э. А. Компьютерная поддержка принятия решений – М. : СИНТЕГ, 1998. – 376 с.
21. Advanced Multivariable Control Systems of Aeroengines // Eds.: Sun Jianguo, V. I. Vasilyev, B.G. Ilyasov, Beijing, China, BUAA Press, 2005. – 621 p.
22. Isermann, R. Fault Diagnosis of Machines via Parameter Estimation and Knowledge Processing. – Automatica 29, 1993, p.815–836.
23. Narendra, K. S. Neural Networks for Control. Theory and Practice // Proceedings of the IEEE, Vol. 84, No. 10, 1996, p.1385–1405.
24. Patton, R. J. Issues in Fault Diagnosis for Dynamic Systems / R. J. Patton, P. M. Frank, R. N. Clark. – 2000, Springer – Verlag, London, 536 p.
25. Zedda, M. Fault Diagnosis of a Turbofan Engine Using Neural Networks: a Quantitative Approach / M. Zedda, R. Singh // Proceedings of the 34 th AIAA /ASME/ SAE/ASEE, Joint Propulsion Conference & Exhibit, 1998, p. 1–10.