

УДК 681.32: 007.52

А.Г. КУЧЕР, С.А. ДМИТРИЕВ, А.В. ПОПОВ

Национальный авиационный университет, Киев, Украина

ОПРЕДЕЛЕНИЕ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ТРДД ПО ДАННЫМ ЭКСПЕРИМЕНТАЛЬНЫХ ИССЛЕДОВАНИЙ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ И МЕТОДОВ РАСПОЗНАВАНИЯ ОБРАЗОВ

Рассмотрено решение задачи диагностирования проточной части ТРДД при совместных неисправностях нескольких узлов двигателя на основе нейронных сетей и классических методов распознавания образов. В качестве неисправностей рассмотрены повреждения лопаток ВНА, КНД и ТНД и закоксованность топливной форсунки. Приведена методика диагностирования по результатам стендовых испытаний ГТД АИ-25 и модельного эксперимента. Проведены эксперименты по практическому применению рассмотренной методики.

диагностика, классификация, математическая модель двигателя, нейронные сети, методы распознавания образов

Введение

Задачи диагностирования использующие методы распознавания образов могут быть формально определены как отображение из пространства наблюдений в пространство решений, что представляет собой задачу классификации наблюдений. В настоящей работе решение задачи классификации осуществляется по данным обучающего эксперимента, который требует большой представительной выборки. Такую выборку трудно получить используя только результаты стендовых испытаний авиационных двигателей в связи с большими затратами на их проведение. Поэтому методика настоящего исследования основана на проведении минимального числа стендовых испытаний, построении математической модели двигателя и ее идентификации и проведении модельного эксперимента с целью получения выборки достаточного объема.

Математическая (термогазодинамическая) модель двигателя характеризуются достаточно большим количеством признаков, имеющих разную (как правило, относительно небольшую) информативность [1 – 3]. К тому же признаки связаны с прогнозируемым но-

мером класса (состояния) нелинейными связями, а между собой некоторые из них сильно коррелированы (мультикорреляция). Поэтому следующей задачей является оценка их информативности и отбор лучших наиболее значимых признаков.

Для решения задач классификации в настоящее время используется целый ряд статистических, эвристических методов распознавания образов, а также множество нейросетевых алгоритмов [4 – 11]. Учитывая то обстоятельство, что между основными узлами двигателя (объектами наблюдения) существуют сильные взаиморегулирующие связи, для эффективного разделения классов состояний, особенно при совместных отказах, необходимо использование комплекса методов. Наиболее очевидным способом реализации многомерной классификации является объединение результатов одномерных классификаций с учетом значимости признаков.

Для повышения качества классификации, а также информативности признаков и уменьшения их числа перед решением задачи распознавания можно провести факторный анализ, т.е. определить главные факторы исходной матрицы данных но с условием сохранения дисперсий не ниже 0,999 от исходных.

Экспериментальные исследования на газодинамическом стенде

Экспериментальное исследование проводилось с целью установления взаимосвязи между повреждениями конструктивных элементов проточной части, которые отвечают тому или иному виду неисправности и значением изменения термогазодинамических параметров рабочего тела проточной части ТРДД. Данное исследование направлено на решение обратной задачи – диагностирования двигателя по изменению вышеприведенных параметров с дальнейшей локализацией неисправности.

Проведенный анализ данных эксплуатации ряда ТРДД, таких как: Д-18Т, Д-36, АИ-25, Д-30КП/КП2 свидетельствует о неоднозначности присутствия отклонений от норм ТУ состояния поверхности лопаток компрессора и турбины, как в отдельности, так и в комплексе [2]. Забоины, загибы, сколы, лопаток рабочих колес, направляющих аппаратов компрессора приводит в первую очередь к нарушению условий обтекания, иными словами нарушается качество и геометрия обтекаемой поверхности, что в свою очередь, приводит к увеличению коэффициента потерь в лопаточных венцах ζ [1]. Аналогичная картина наблюдается и при влиянии эксплуатационных повреждений таких, как прогары, оплавление, отложение продуктов сгорания, коррозия, эрозия на конструктивные элементы турбины (сопловые аппараты, лопатки рабочих колес), при этом происходит изменение коэффициента скорости обтекания φ [1].


Таким образом, появление шероховатости приводит к увеличению профильных потерь в лопаточных машинах. В связи с этим, при проведении натурного эксперимента смоделированы следующие несоответствия состояния поверхности лопаток нормам ТУ: шероховатость лопаток входного направляющего аппарата (ВНА), шероховатость лопаток 1-ой ступени компрессора низкого давления (КНД), шероховатость лопаток турбины низкого давления (ТНД). Для такого двигателя как Д-30КП/КП2 характерной неисправно-

стью касательно конструктивных элементов проточной части является прогар жаровых труб камеры сгорания, прогар, оплавление лопаток сопловых аппаратов и лопаток 1-й ступени турбины высокого давления, вследствие неравномерности поля температур, вызванной закоксованностью топливных форсунок, поэтому при стендовых исследованиях данный вид неисправности имитировался путем постановки заглушки на топливный коллектор одной из форсунок, тем самым полностью исключив подачу топлива. При проведении натурного эксперимента был учтен низкий уровень эксплуатационной технологичности и контролепригодности ГТД АИ-25. Методика данных стендовых исследований основывалась на опыте проведения нескольких аналогичных экспериментов [1]. Шероховатость создавалась следующим образом. Калиброванный корунд смешивался с различными склеивающими материалами. Для "холодной части" использовался клей ПВА. Выбор этого клея обусловлен, в первую очередь, приемлемыми физико-химическими свойствами, что было подтверждено предварительными гонками двигателя, а также дешевизной, однако при повышенной влажности использовался другой материал. Образующая корундом и клеем смесь, при помощи малярной кисти наносилась на спинку всех лопаток рабочего колеса (РК) КНД и лопатки ВНА (рис. 1). В "горячей части" ГТД, в частности, при моделировании шероховатости ТНД использовался силикатный клей. Создаваемая суспензия наносилась аналогичным образом на спинку лопаток соплового аппарата (СА) и корытце лопаток (РК) 2-ой ступени турбины. При этом количество лопаток, подвергаемых покрытию равно двенадцати штукам. Затем покрытие удалялось при помощи водного раствора.

Основное преимущество данного подхода в отличие от химического или механического способов изменения состояния поверхности, заключается в многократности получения шероховатости. Закоксованность рабочей топливной форсунки осуществлялась путем постановки заглушек на распределительный топливный коллектор и непосредственно на патрубок форсунки.




а



б



в



г

Рис. 1. Моделирование неисправности и повреждения конструктивных элементов проточной части ТРДД:

а – повреждение лопаток ВНА; б – повреждение лопаток КНД; в – закоксованность топливной форсунки; г – повреждение лопаток ТНД

Планирование эксперимента и формирование выборки

Основной задачей при исследовании является установление взаимосвязей влияния совместных неисправностей различных узлов на изменение диагностических признаков, их качественное и количественное отклонение. Для этого при планировании эксперимента было определено количество

уровней влияния N равное двум: наличие шероховатости и её отсутствие. Количество варьируемых при этом факторов – 4: x_1 – шероховатость лопаток ВНА, x_2 – шероховатость лопаток 1-ой ступени КНД, x_3 – закоксованность рабочей топливной форсунки, x_4 – шероховатость лопаток 2-ой ступени ТНД. В итоге получаем матрицу планирования полного факторного эксперимента вида $N=2^k$, где k – количество проводимых экспериментов [12] (табл.1).

Таблица 1

Матрица планирования эксперимента

Номер опыта	Шероховатость лопаток ВНА	Шероховатость лопаток 1-й ст. КНД	Закоксованность топливной форсунки	Шероховатость лопаток 2-й ст. ТНД
	(x_1)	(x_2)	(x_3)	(x_4)
1	-	-	-	-
2	+	-	-	-
3	-	+	-	-
4	-	-	+	-
5	-	-	-	+
6	+	+	-	-
7	+	-	+	-
8	+	-	-	+
9	-	+	+	-
10	-	+	-	+
11	-	-	+	+
12	+	+	+	-
13	+	+	-	+
14	+	-	+	+
15	-	+	+	+
16	+	+	+	+

Таким образом, построен полный факторный эксперимент 2^4 . Он состоит из шестнадцати опытов и включает все возможные комбинации уровней четырех факторов. Известно, что для большинства электрических измерительных приборов характерен предварительный прогрев, как приемников, так и указателей [13]. Этот процесс необходим для повышения точности измерения. Учитывая особенности двигателя, а именно: изменение осевых и радиальных зазоров меньший запас газодинамической устойчивости ΔK_y в сравнении со среднестатистическим ГТД, большую наработку, а также характер изменения теплофизических свойств воздуха на рис. 2. представлен типовой график проведения эксперимента.




Рис. 2. График работы ТРДД газодинамического стенда при проведении исследования:
 1-5 – зоны измерения параметров;
 | – период предварительного прогрева, || – период прогрева,
 ||| – период уборки газа, предварительного охлаждения и останов двигателя

На каждом стационарном режиме работы ТРДД проводилось измерение параметров атмосферного воздуха (температуры, давления), и следующих параметров двигателя:

- $n_{вд}$ – обороты РВД в процентах;
- $n_{нд}$ – обороты РНД в процентах;
- $T_{кв}^*$ – температура за КВД в градусах С;
- $T_{т}^*$ – температура за ТНД в градусах С;
- $T_{кн}^*$ – температура за КНД в градусах С;
- $P_{кн}^*$ – избыточное давление за КНД в кг/см²;
- $P_{кв}^*$ – избыточное давление за КВД в кг/см²;
- $P_{т}^*$ – избыточное давление за ТНД в Па;

- $P_{с2}^*$ – избыточное давление на срезе сопла наружного контура в кг/см²;
- $G_{т.пр}$ – часовой приведенный расход топлива в кг;
- P – тяга двигателя в Н.

Для каждого из шестнадцати состояний (табл.1) было проведено по несколько опытов, где фиксировались отмеченные параметры (табл. 2). По этим данным на всех режимах рассчитывались их числовые характеристики: математические ожидания, дисперсии и диапазон варьирования (табл. 3) и приведенные параметры (табл. 4), и далее используя математическую модель двигателя определялись диагностические параметры. Из всех режимов наиболее ценным для распознавания состояний был режим 0,85 ном.

Таблица 2

Анализируемые выборки значений измеряемых параметров (режим 0,85 ном.)

Номер выборки	$n_{вд}$, об/мин	$n_{нд}$, об/мин	$T_{кн}^*$, К	$T_{кв}^*$, К	$T_{т}^*$, К	$P_{кн}^*$, Па	$P_{кв}^*$, Па	$P_{т}^*$, Па	P , кг	$G_{т}$, л/ч	f , Гц
1	14190	8686,6	330	607,5	735	149340	539320	123442	974,03	600	3699
2	14112	8686,6	327	606	734	148770	536800	123419	951,58	600	3692
3	14262	8751,6	327	604	731	148870	539400	123443	954,76	620	3693
4	14282	8761	329	603	731	149165	539370	123446	951,58	580	3692

Таблица 3

Значение метрологических характеристик (режим 0,85 ном.)

Хар-ка	Измеряемые параметры										
	$n_{вд}$, об/мин	$n_{нд}$, об/мин	$T_{кн}^*$, К	$T_{кв}^*$, К	T_m^* , К	$P_{кн}^*$, Па	$P_{кв}^*$, Па	P_m^* , Па	P , кг	G_m , л/ч	f , Гц
1	2	3	4	5	6	7	8	9	10	11	12
\bar{x}_i	14212	8721,1	328,25	605,13	733,25	149040	538720	123440	957,99	600,33	3694
S	138,02	71,561	2,5923	3,6543	2,5155	471,62	2333,4	22,884	20,087	24,884	6,2643
$D[\bar{x}]$	4045,7	1087,5	1,42,71	2,8359	1,3438	47236	1,156·10 ⁶	111,21	85,689	131,5	8,3333
$S_{\sigma\Delta}$	124,68	64,226	2,306	3,3207	2,0272	426,65	2123,8	20,911	18,443	20,552	5,7518
ε_i	400	205	7	11	6	1357	6757	65	60	65,397	18

Таблица 4

Исходное нормальное (бездефектное) состояние $P_h=736$ мм рт.ст.=98882 Па; $T_h=15^\circ\text{C}=288\text{K}$

№ п/п	Пар-тр	Ед. изм.	Значение параметра	Режим работы двигателя				
				М.Г.	0,4 ном.	0,6 ном.	0,7 ном.	0,85 ном.
1	2	3	4	5	6	7	8	9
1	$n_{нд}$	об/мин	измеренное	3792	6268,6	7560,3	8058	8686,6
			прив. к САУ	3792	6268,6	7560,3	8058	8721,6
2	$n_{вд}$	об/мин	измеренное	9572,3	13005	14177	14656	15167
			прив. к САУ	9410,3	12545	13492	13839	14112
3	P	Н	измеренное	162,47	429,83	661,21	769,28	957,94
4	τ	сек	измеренное	66	56	42	34	30
5	$\Delta P_{кн}^*$	Па	измеренное	8104	21780	33429	37988	46598
			прив. к САУ	8302,2	22312	34247	38917	47738
6	$T_{кн}^*$	К	измеренное	298	309,5	318	323	327
			прив. к САУ	298	309,5	318	321,5	327
7	$\Delta P_{кв}^*$	Па	измеренное	88131	2,34·10 ⁵	3,31·10 ⁵	3,67·10 ⁵	4,27·10 ⁵
			прив. к САУ	90286	2,39·10 ⁵	3,39·10 ⁵	3,76·10 ⁵	4,37·10 ⁵
8	$T_{кв}^*$	К	измеренное	388	478	528	558	606
			прив. к САУ	388	478	528	558	606
9	ΔP_m^*	Па	измеренное	3038	9065	14749	16964	21609
			прив. к САУ	3112,3	9286,7	15110	17379	22137
10	T_m^*	К	измеренное	700	666	698	718	734
			прив. к САУ	700	666	698	718	734
11	$\Delta P_{с2}^*$	Па	измеренное	2431,2	8104	12156	14182	17728
			прив. к САУ	2490,7	8302,2	12453	14529	18161

В качестве диагностических признаков (факторов), наиболее полно отражающих техническое состояние двигателя, предлагается использовать параметры:

- $\pi_{кнд}^*$ – степень повышения давления за КНД;
- $\pi_{квд}^*$ – степень повышения давления за КВД;
- $\eta_{кнд}^*$ – к.п.д. КНД;
- $\eta_{квд}^*$ – к.п.д. КВД;
- S – скольжение роторов;
- $G_{в.пр}$ – приведенный расход воздуха во внутреннем контуре;
- $G_{\Sigma,пр}$ – приведенный суммарный расход воздуха;

- $\pi_{тнд}^*$ – степень понижения давления за ТНД;
 - $\pi_{твд}^*$ – степень понижения давления за ТВД;
 - $\eta_{тнд}^*$ – к.п.д. ТНД;
 - $\eta_{твд}^*$ – к.п.д. ТВД;
 - $C_{уд.пр}$ – удельный приведенный расход топлива;
 - $P_{уд.пр}$ – удельная приведенная тяга двигателя;
 - $\eta_{г}^*$ – к.п.д. горения.
- Исходные данные (выборки) для задач классификации формировались на основе этих параметров для каждого состояния в следующей последовательности и количестве:

60 точек – нормальное состояние;
 20 – шероховатость ВНА;
 20 – шероховатость КНД;
 20 – заглушена форсунка;
 20 – шероховатость ТНД;
 20 – шероховатость ВНА и КНД;
 20 – шероховатость ВНА и заглушена форсунка;
 20 – шероховатость ТНД и ВНА;
 20 – шероховатость КНД и заглушена форсунка;
 20 – шероховатость КНД и ТНД;
 20 – шероховатость ТНД и заглушена форсунка;
 20 – шероховатость ВНА, КНД и заглушена форсунка;
 20 – шероховатость КНД, ТНД и ВНА;
 20 – шероховатость ТНД, ВНА и заглушена форсунка;
 20 – шероховатость КНД, ТНД и заглушена форсунка;
 20 – шероховатость КНД, ТНД, ВНА и заглуше-
 на форсунка.

Результатом проведения модельного эксперимента являются две выборки обучающая и проверочная – матрицы размером 360 на 14. Обучающая строится на основе полученных математических ожиданий и дисперсий отмеченных параметров, а проверочная имеет в два раза увеличенную дисперсию, что позволяет оценить эффективность полученных результатов.

Методы решения задач классификации

Для решения задачи классификации по четырнадцати признакам применялись классические методы распознавания образов – кластерного анализа, ближайшего соседа, минимизации риска, дискриминантного анализа, а также многослойные (двух, трех и четырехслойные) нейронные сети (МНС) [4 – 7, 9 – 11]. Для распознавания состояния двигателя на основе нейросетевой классификации использовался модуль Neural Toolbox пакета Matlab 7.01.

При распознавании двухслойной нейронной сети, первый слой содержал 17, а второй - 16 нейронов по количеству возможных состояний. Отмечен-

ное число нейронов первого слоя является оптимальным для этой задачи по критерию качество-время обучения сети.

Все нейроны первого и(или) второго слоев имели функцию активации tansig :

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

или – сигмоидную функцию активации logsig :

$$\Psi(x) = \frac{1}{1 + e^{-x}}.$$

Для обучения МНС применялись градиентные алгоритмы, наиболее быстрыми среди которых является алгоритм Левенберга-Марквардта и алгоритм регуляризации *Bayesia*. В качестве цели обучения была задана среднеквадратическая ошибка 0,05 и максимальное количество циклов обучения – 200. Хорошими показателями сходимости по временному критерию обладает также алгоритм обратного распространения ошибки, при максимальном числе циклов обучения – 10000.

Основным вычислительным элементом многослойной НС является нейрон. Он выполняет параметрическое нелинейное преобразование входного вектора x в скалярную величину y . Нейроны образуют сеть, которая характеризуется следующими параметрами и свойствами: M – число слоев сети, N_μ – число нейронов μ -го слоя, связи между нейронами в слое отсутствуют. Выходы нейронов μ -го слоя, $\mu = 1, 2, \dots, M-1$ поступают на входы нейронов только следующего $\mu + 1$ -го слоя. Внешний векторный сигнал x поступает на входы нейронов только первого слоя, выходы нейронов последнего M -го слоя образуют вектор выходов сети $y^{(M)}$. Каждый i -й нейрон μ -го слоя (μ_i -й нейрон) преобразует входной вектор $x^{(\mu,i)}$ в выходную скалярную величину $y^{(\mu,i)}$:

$$y^{(\mu,i)} = \Psi \left(w_0^{(\mu,i)} + \sum_{j=1}^N w_j^{(\mu,i)} x_j^{(\mu,i)} \right),$$

где $w^{(\mu,i)} = (w_0^{(\mu,i)}, w_1^{(\mu,i)}, \dots, w_N^{(\mu,i)})^T$ – вектор весовых коэффициентов нейрона; $x_j^{(\mu,i)}$ – j -я компонента N -мерного входного вектора $x^{(\mu,i)}$; $\Psi(x)$ – функция активации.

Процесс обучения сети по алгоритму Левенберга-Марквардта, осуществляется в результате минимизации целевой функции – некоторого критерия качества $F(w)$, который характеризует интегральную меру близости выходов сети $y^{(M)}(k)$ и указаний учителя $y^*(k)$:

$$F(w) = \frac{1}{k} \sum_{m=1}^k Q(\varepsilon(w, m)), \quad (1)$$

где k – номер текущего цикла обучения НС, $m = 1, 2, \dots, k-1$ – номера предыдущих циклов обучения НС, w – составной вектор-столбец весовых коэффициентов сети, составляющими которого являются вектор-столбцы:

$$w^{(\mu)} = (w^{(\mu,1)T}, w^{(\mu,2)T}, \dots, w^{(\mu, N_\mu)T})^T,$$

где (μ, i) – i -й нейрон каждого слоя $\mu = M, M-1, \dots, 1$, M – число слоев сети.

Мгновенный критерий качества $Q(\varepsilon(w, k))$, входящий в интегральный критерий качества $F(w)$, зависит от вектора ошибки сети $Q(\varepsilon(w, m))$: $\varepsilon(w, m) = y^{(M)}(m) - y^*(m)$ и часто имеет вид квадратичной формы:

$$Q(\varepsilon(w, m)) = \varepsilon^T(w, m) \cdot R \cdot \varepsilon(w, m),$$

где R – положительно определенная матрица.

Градиентные методы обучения МНС основаны на использовании градиента целевой функции (1). Эти методы носят итеративный характер, так как компоненты градиента являются, в общем случае, нелинейными функциями. Обозначим текущий градиент $g = \frac{\partial Q}{\partial w}$. Тогда процесс обучения МНС будет основан на итерационной процедуре, реализуемой в соот-

ветствии с формулой: $w_{k+1} = w_k + \alpha_k \varphi(w_k)$, где w_k, w_{k+1} – текущее и новое приближения значений весов и порогов НС к оптимальному решению, соответственно, α_k – шаг сходимости, $\varphi(w_k)$ – направление поиска в N -мерном пространстве весов. Способ определения $\varphi(w_k)$ и α_k на каждой итерации зависит от особенностей конкретного метода.

Для каждого входного вектора x из обучающего множества должен быть определен вектор желаемых выходов сети y^* . Если обучаемая МНС используется в качестве классификатора состояний двигателя – одного нормального и 15 дефектных, то выходами могут быть обычные порядковые номера состояний: 1 – нормальное, 2÷15 –дефектные.

Алгоритм Левенберга-Марквардта требует наличия информации о значениях вторых производных целевой функции. Алгоритм может обучать НС пока ее веса, входы и функции активации имеют производные. В алгоритме Левенберга-Марквардта используется алгоритм обратного распространения ошибки для вычисления якобиана J целевой функции относительно весов и порогов сети. Каждый вес и порог изменяются в соответствии с корректирующим правилом, которое в матричной форме имеет вид:

$$H = J^T J, \quad g = J^T \varepsilon, \quad w_{k+1} = w_k - [H_k + \eta E]^{-1} g_k$$

где H – гессиан, J – якобиан, g_k – текущий градиент, w_k, w_{k+1} – текущее и новое значения вектора весов и порогов нейронной сети, ε – вектор ошибок, η – скаляр, E – единичная матрица.

Адаптивное значение η увеличивается в η^+ раз до тех пор, пока значение целевой функции не уменьшится. После чего изменения вносятся в сеть и η уменьшается в η^- раз.

Алгоритм Левенберга-Марквардта имеет вид:

Шаг 1. Инициализация: задаются начальные значения параметров сети и алгоритма обучения, а также граничные значения параметров окончания работы алгоритма.

Счетчик числа циклов обучения $k = 1$.

Шаг 2. Проверка сходимости и условий окончания обучения. Если сходимость достигнута, $k > Epochs$ или обучение должно быть прекращено – окончание работы.

Шаг 3. Если $\eta \leq \eta_{max}$, то переход к шагу 4, иначе к шагу 7.

Шаг 4. Вычислить значение ошибки и скорректировать соответствующими образом веса и пороги сети:

$$H = J^T J, \quad g = J^T \varepsilon, \quad w_{k+1} = w_k - [H_k + \eta E]^{-1} g_k.$$

Шаг 5. Вычислить новое значение целевой функции. Если оно меньше текущего, то вернуть прежние параметры сети, изменить η : $\eta = \eta \eta^-$ и выйти из цикла, иначе зафиксировать параметры сети и изменить η : $\eta = \eta \eta^+$.

Шаг 6. Переход к шагу 4.

Шаг 7. $k = k + 1$.

Шаг 8. Переход к шагу 2.

Результаты эксперимента

Модельные эксперименты показали, что НС успешно решают задачу классификации состояния авиационного двигателя, обеспечивая при этом достаточно высокую надежность классификации не только для данных обучающей но и для проверочной выборкам при сравнительно небольшом времени обучения. Применение предлагаемого подхода открывает новые возможности в разработке методов ранней безразборной диагностики распознаваемых дефектов узлов авиационных двигателей с использованием компьютерных систем сбора и обработки данных.

Исходными данными предъявляемыми для обучения и последующей проверки нейронной сети являются две матрицы приведенные соответственно на рис. 3 и рис. 4, где показаны графики параметров. В табл. 5 приводятся минимальное и максимальное значение каждого фактора обучающей и проверочной выборки. На рис. 6 приводятся результаты распознавания обучающей и проверочной выборки.

Согласно первому рисунку все точки обучающей выборки предъявляемые к распознаванию классифицируются правильно так как лежат на соответствующих уровнях. На проверочной выборке неправильно классифицируется только четыре точки. Положительные результаты являются следствием хорошей разнесенности точек в пространстве состояний, удачного выбора метода распознавания и параметров сети, что видно на графике о ходе процесса распознавания (рис. 5), где ошибка классификации уменьшилась за 103 итерации почти на пять порядков. На рис. 7 и 8 приводятся результаты распознавания по обучающей и проверочной выборкам методами распознавания образов: кластерного анализа (с наилучшим критерием (мерой) – Махаланобиса), ближайшего соседа, минимизации риска и дискриминантного анализа. Лучшие результаты дают два последних метода. По качеству распознавания они близки к методам классификации на основе нейронных сетей, а по временным критериям их превосходят. То, что каждый метод имеет свои ошибки классификации, подтверждает необходимость комплексного подхода к решению задачи распознавания.

Предложенные 14 диагностических признаков имеют различный уровень информативности, некоторые сильно коррелированы между собой. Так наибольшие коэффициенты парной корреляции между признаками равны:

$$r(\eta_{тнд}^*, \pi_{тнд}^*) = 0,9976;$$

$$r(\eta_{твд}^*, \pi_{твд}^*) = 0,9988;$$

$$r(\pi_{твд}^*, \eta_{квд}^*) = 0,9739;$$

$$r(\eta_{твд}^*, \eta_{квд}^*) = 0,9736.$$

В целях уменьшения размерности модели за счет исключения малозначимых и сильно коррелирующих признаков была проведена коррекция модели. В частности, признаки $\eta_{тнд}^*$, $\eta_{твд}^*$ и $\eta_{квд}^*$ исключены, а признаки T_2 – температура газов перед турбиной и T_m – температура за турбиной введены в модель.

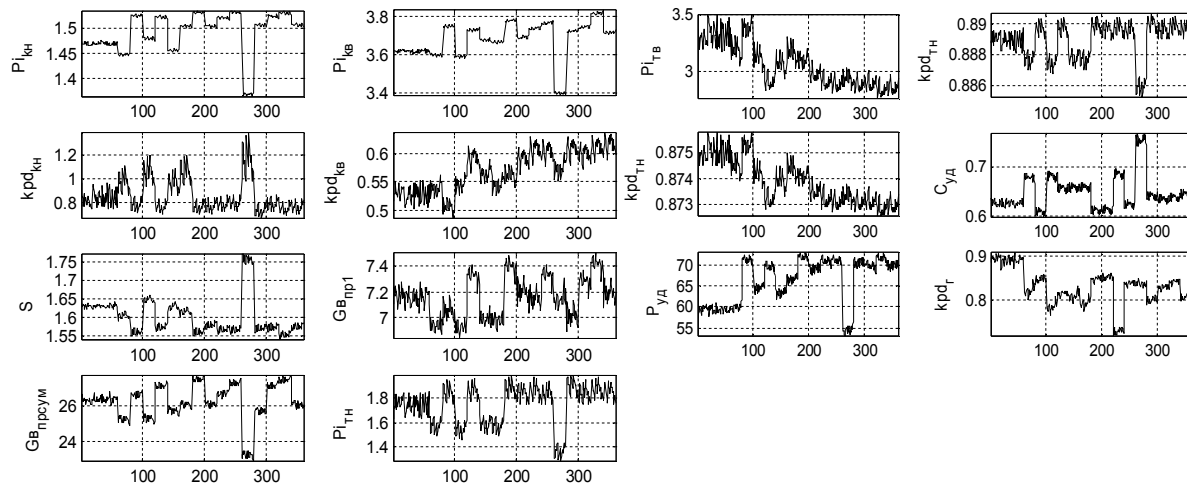


Рис. 3. Обучающая выборка:
 1 блок-60 точек – нормальное состояние;
 2-16 блоки по 20 точек – дефектные состояния согласно табл. 1

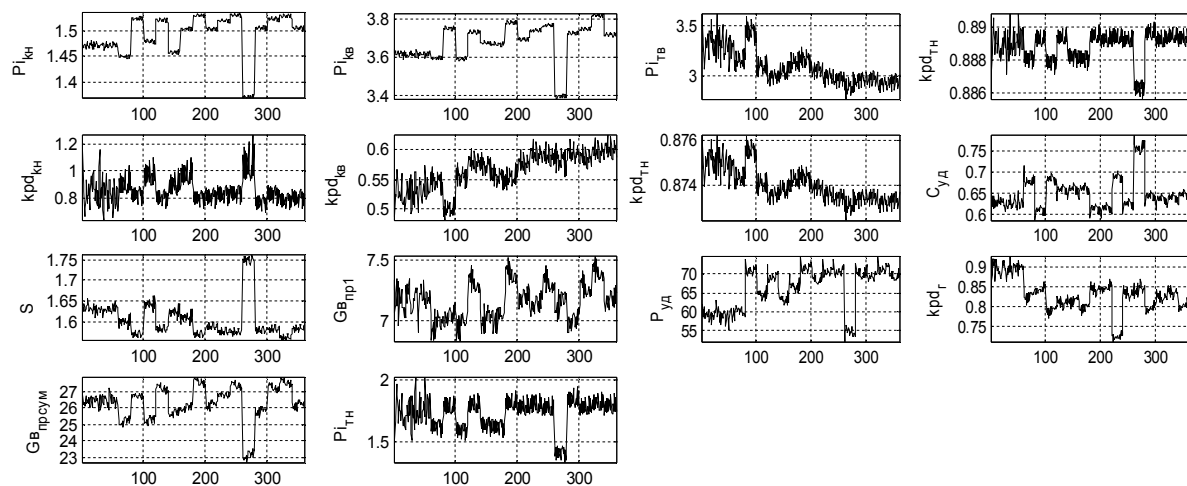


Рис. 4. Проверочная выборка:
 1 блок-60 точек – нормальное состояние;
 2-16 блоки по 20 точек – дефектные состояния согласно табл. 1




Рис. 5. Ход процесса обучения НС

Таблица 5

Минимальное – максимальное значение фактора

Фактор	Обучающая выборка		Проверочная выборка	
x1	1,3656	1,5365	1,3633	1,5388
x2	3,3780	3,8303	3,3789	3,8291
x3	0,6646	1,3982	0,6168	1,4631
x4	0,4885	0,6360	0,4947	0,6343
x5	1,5411	1,7734	1,5359	1,7812
x6	6,7975	7,5161	6,8201	7,5253
x7	22,8404	27,8252	22,5851	27,9777
x8	1,2985	1,9847	1,2816	2,0482
x9	2,7563	3,5533	2,7618	3,4977
x10	0,8853	0,8906	0,8851	0,8910
x11	0,8724	0,8760	0,8724	0,8758
x12	0,5975	0,7717	0,5896	0,7831
x13	52,8594	73,6509	52,8218	74,1349
x14	0,7118	0,9339	0,7078	0,9464




Рис. 6. Результаты распознавания обучающей и проверочной выборки нейросетевыми методами

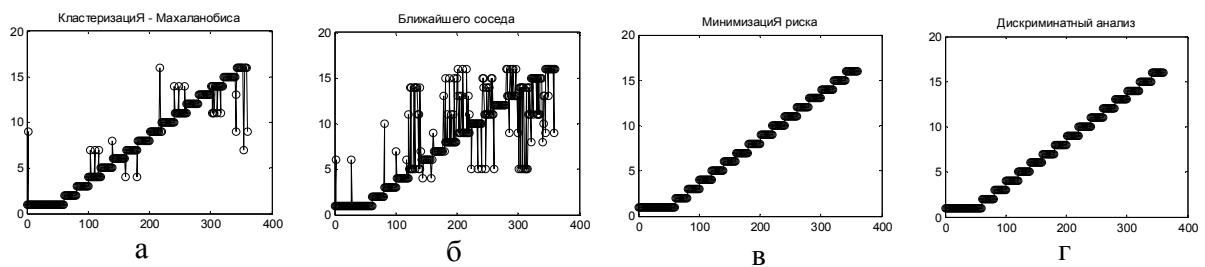


Рис. 7. Результаты распознавания обучающей выборки методами распознавания образов: а – кластеризации, б – ближайшего соседа, в – минимизации риска, г – дискриминантного анализа

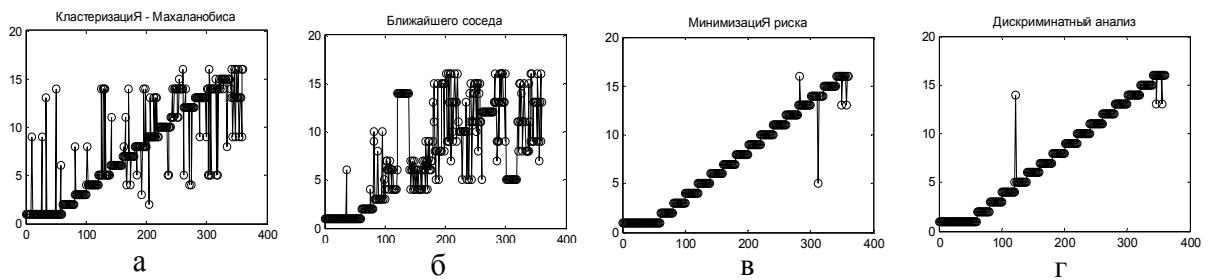


Рис. 8. Результаты распознавания проверочной выборки методами распознавания образов: а – кластеризации, б – ближайшего соседа, в – минимизации риска, г – дискриминантного анализа




Рис. 9. Обучающие выборки для главных факторов

Для выявления малозначимых признаков кроме критериев парной корреляции, модуля коэффициента корреляции, оценок значимости признаков на основе МНС можно использовать методы факторного анализа. Но основной задачей факторного анализа является регулирования количества значимых признаков. Главные факторы, которые являются линейной комбинацией исходных параметров:

$$F_j = \sum_{i=1}^n \alpha_{ji} X_i; \quad \sum_{i=1}^n \alpha_{ji}^2 = 1, \quad j = \overline{1, n},$$

где α_{ji} – косинус угла между j -й осью и i -м признаком, линейно независимы и априорно включены в модель в порядке их значимости. Метод получения направлений главных осей основывается на нахождении собственных чисел и векторов корреляционной матрицы R : $RF = \lambda F$.

На рис. 9 приводятся две оптимальных по числу главных факторов обучающих выборки из 8-ми главных факторов, обеспечивающих сохранение дисперсий не ниже 0,999. Первая получена на основе 14 исходных параметров, во вторую вместо отмеченных коэффициентов потерь включены температуры T_2 и T_m . На рис. 10 – результаты распознавания обучающей и проверочной выборки классическими методами распознавания образов. В заключение отметим, что основе анализа обратной матрицы факторов первым двум главным факторам можно

придать ясный физический смысл – первый характеризует влияние контура низкого, второй – высокого давления.

Заключение

Таким образом, при идентификации технического состояния конструктивных узлов проточной части ТРДД по параметрам, зарегистрированным на установившемся режиме, успешно решена задача распознавания образов (портрета состояния объекта диагностирования) по экспериментальным данным. Разработана методика распознавания состояния двигателя на основе нейронных сетей и классических методов распознавания образов с использованием методов факторного анализа. При проведении модельного эксперимента и классификации состояния ГТД определено необходимое и достаточное количество диагностических признаков (главных факторов). Определены параметры двухслойной НС и методы распознавания образов (минимизации риска и дискриминантного анализа), которые позволяют с достаточно большой точностью, определить техническое состояние конструктивных элементов проточной части ГТД с точность диагностирования до узла. Предлагаемый подход открывает новые перспективы в области параметрической диагностики авиационных газотурбинных двигателей.

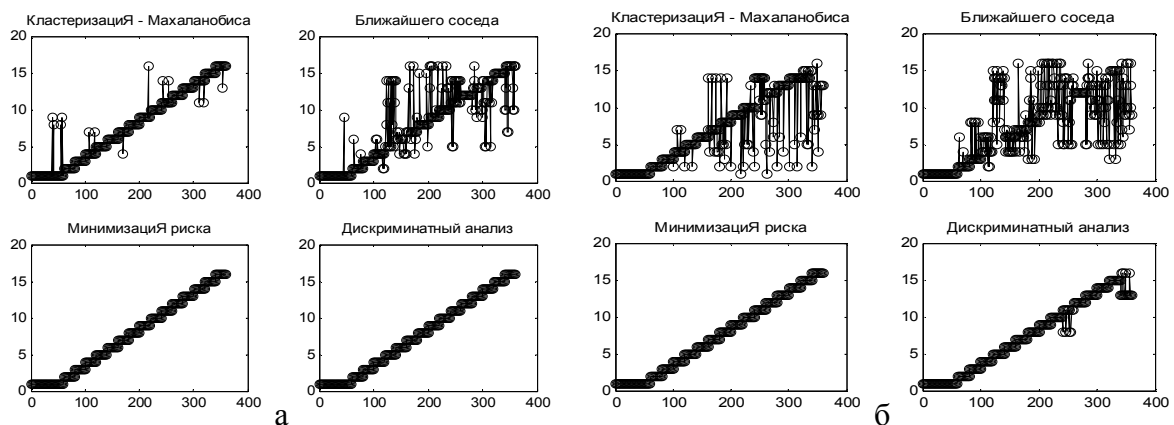


Рис. 10. Результаты распознавания для 8-ми ГФ по:
 а – обучающей и б – проверочной выборках методами распознавания образов кластеризации, ближайшего соседа, минимизации риска и дискриминантного анализа

Литература

1. Дмитриев С.А. Диагностирование проточной части ГТД на установившихся и неуставившихся режимах работы: Автореф. дис.... д-ра техн. наук. – К.: КМУГА, 1996. – 30 с.
2. Попов О.В. Исследование динамических характеристик ТРДД с перемежающимися неисправностями проточной части на установившихся режимах его работы // *Авіаційно-космічна техніка і технологія: Наук.-техн. журн.* – 2007. – № 2/38. – С. 63-67.
3. Епифанов С.В., Кузнецов Б.И., Богаенко И.М. Синтез систем управления и диагностирования газотурбинных двигателей. – К.: Техника, 1998. – 312 с.
4. Кучер О.Г., Якушенко О.С., Сухоруков В.Ю. Розпізнавання технічного стану авіаційних ГТД з використанням нейронних мереж // *Вісник двигунобудування: Наук.-техн. журн.* – 2002. – № 2. – С. 101-106.
5. Фомин А.Я., Тарловский Г.Р. Статистическая теория распознавания образов. – М.: Радио и связь, 1986. – 388 с.
6. Эдуард А. Патрик. Основы теории распознавания образов / Пер. с англ.; Под ред. Б.Р. Левина. – М.: Сов. радио, 1980. – 408 с.
7. Интеллектуальные средства диагностики и прогнозирования надежности авиадвигателей / В.И. Дубровин, С.А. Субботин, А.В. Богуслаев, В.К. Яценко: Монография. – Запорожье: ОАО “Мотор-Сич”, 2003. – 279 с.
8. Верхаген К., Дёйн Р., Грун Ф. Распознавание образов. Состояние и перспективы / Пер. с англ. Н.Г. Гуревич; Под ред. И.Б. Гуревич. – М.: Радио и связь, 1985. – 104 с.
9. Горбань А.Н., Дунин-Барковский В.Л., Кирдин А.Н. Нейроинформатика. – Новосибирск: Наука, СО РАН, 1998. – 296 с.
10. Уоссермен Ф. Нейрокомпьютерная техника: теория и практика. – М.: Мир, 1992. – 127 с.
11. Жернаков С.В. Активная экспертная система испытаний авиационных двигателей // *Авіаційно-космічна техніка і технологія: Зб. Наук. праць.* – Х.: ХАИ, 2001. – Вип. 26. Теплові двигуни та енергоустановки. – С. 168-173.
12. Адлер Ю.П., Маркова Е.В., Грановский Ю.В. Планирование эксперимента при поиске оптимальных условий. – М.: Наука, 1976. – 279 с.
13. Преображенский В.П. Теплотехнические измерения и приборы: Учебник для вузов. – М.: Энергия, 1978. – 704 с.

Поступила в редакцію 7.06.2007

Рецензент: д-р техн. наук, профессор В.В. Панин, Национальный авиационный университет, Киев.