

УДК 629.7:681.324

**В. И. ВАСИЛЬЕВ, С. В. ЖЕРНАКОВ****КОНТРОЛЬ И ДИАГНОСТИКА  
ТЕХНИЧЕСКОГО СОСТОЯНИЯ АВИАЦИОННЫХ ДВИГАТЕЛЕЙ  
НА ОСНОВЕ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ**

Рассматриваются нейросетевые методы решения задач контроля и диагностики технического состояния авиационного газотурбинного двигателя. Приводится инженерная методика решения этих задач. Предложена архитектура нейросетевой экспертной системы, определен состав входящих в нее нейросетевых модулей. *Мониторинг; контроль; диагностика; нейросетевая экспертная система*

**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 при-

влечением 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, часто именуемые в отечественной и зарубежной литературе как Data Mining – «добыча» данных и обнаружение знаний. Data Mining использует современные интеллектуальные технологии, включающие в себя: 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.

### 1. 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 в себя:

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.

### 2. ПОСТАНОВКА ПРОБЛЕМЫ

Анализ существующих подходов показывает, что современные системы мониторинга ГТД являются многоуровневыми. Практика автономного проектирования соответствующих подсистем нередко приводит к тому, что на различных уровнях системы используются различные методики и стандарты, отсутствует их единое метрологическое и информационное сопровождение, что требует значительных вычислительных ресурсов. Данная проблема эффективно решается путем информационной «увязки» различных уровней управления ГТД (рис. 2).

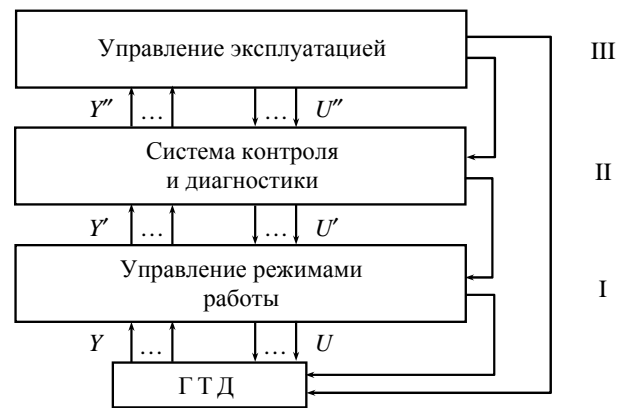


Рис. 2. Функциональная схема многоуровневой системы управления ГТД

Уровень управления (I) непосредственно взаимодействует с ГТД через датчики и исполнительные механизмы. Уровень контроля и диагностики (II) осуществляет наблюдение за работой ГТД и его системы управления и в случае обнаружения неисправностей (отказов, дефектов) фиксирует этот факт и принимает решение об изменении конфигурации системы. Верхний уровень управления эксплуатацией (III) осуществляет управление процессом эксплуатации ГТД (прогноз, планирование), обеспечивая максимальную выработку ресурса авиационного двигателя (увеличение времени его эксплуатации) и своевременное (обоснованное) снятие его с эксплуатации.

Каждый из перечисленных уровней может быть описан своими формальными и неформальными (количественными и качественными) математическими моделями.

При этом с I по III уровень в процессе мониторинга и управления эксплуатацией ГТД осуществляется Data Mining, т. е. выделение знаний из данных, необходимых для своевременного и качественного управления ГТД.

Таблица 1

Уровень управления	Цель управления	Критерии эффективности	Управляющие воздействия
I. Исполнительное (автоматическое) управление	Поддержание требуемого (оптимального) режима работы ГТД	Точность (ошибка) управления, критерий качества переходных процессов	Управление ГТД (с помощью исполнительных механизмов)
II. Контроль и диагностика	Обеспечение заданного уровня надежности (отказоустойчивости системы)	Вероятность безотказной работы системы управления ГТД, средняя наработка на отказ.	Команды на переключение резерва замены элементов
III. Управление процессом эксплуатации	Поддержание требуемой эффективности функционирования ГТД	Коэффициент готовности ГТД, вероятность выполнения поставленной задачи, ресурс эксплуатации ГТД	Сроки проведения ремонтов (регламентных работ, доработок), выбор стратегии обслуживания

Приведенная схема реализует принцип Саридиса [19, 22], означающий, что от нижнего уровня к верхним уровням управления системы интеллектуальность повышается.

В табл. 1 перечислены цели управления, критерии эффективности и способы формирования управляющих воздействий в зависимости от уровня управления ГТД. Табл. 2 дает общую характеристику математическим моделям, используемым на различных уровнях управления.

Современные системы контроля и диагностики технического состояния ГТД решают задачи автоматической классификации режимов работы авиационного двигателя, идентификации, контроля, диагностики, прогнозирования технического состояния, отладки параметров и восстановления потерянной информации и др.

### 3. 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 по-

священы, как правило, решению частных задач (например, диагностирования состояния лопаток турбины ГТД [19], формирования пространства диагностических признаков состояния ГТД для построения нейросетевого классификатора [18, 19], косвенного измерения 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.

Таблица 2

Уровень управления	Математические модели
Объект управления (элементы, детали, узлы, агрегаты, подсистемы)	Динамические модели (линеаризованные, многорежимные, поэлементные модели)
I – управление ГТД	Алгоритмы управления (дифференциальные, разностные уравнения)
II – контроль и диагностика ГТД	Логические модели, модели контроля и диагностики состояния
III – управление эксплуатацией ГТД	Модели принятия решений

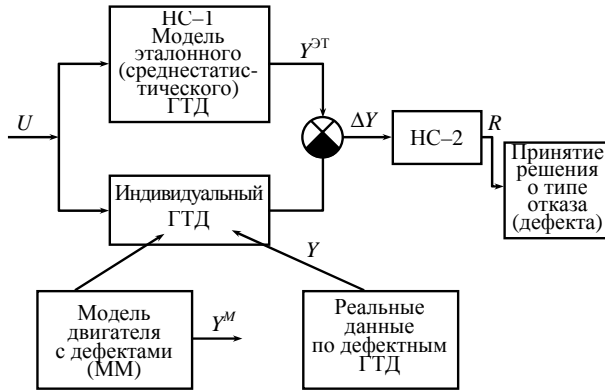


Рис. 3. Реализация FDI-метода в нейросетевом базисе

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  $\bar{S}_0$ :

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

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. 3) 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)  $\Delta Y$  между значениями вектора измеренных параметров конкретного двигателя и вектора данных, рас-




Рис. 4. Классификатор на основе НС-2

считанных с помощью НС-1, принимается решение о техническом состоянии ГТД (на этом этапе используется вторая нейронная сеть НС-2).

В качестве характеристик индивидуально-го 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. 4) представляет собой бинарный нейроклассификатор, на входы которого поступают значения указанных выше отклонений (невязок)  $\Delta y_i$ , а выходы образуют бинарный вектор  $R = \{R_1, R_2, \dots, R_m\}$ , компоненты которого отражают результаты диагноза.

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:  $\Delta Y = Y^{ЭТ} - Y^М$ . Согласно данным о невязках  $\Delta Y_i$  формируется обучающая выборка, которая в общем виде может быть представлена:  $\Delta Y_i \rightarrow R (i = 1, 2, \dots, n)$ .

В качестве диагностических признаков (входов НС-2) использовалась информация по 10 параметрам двигателя: отклонения частоты вращения  $\Delta n_2$  ротора турбокомпрессора высокого давления; расхода воздуха  $\Delta G_B$  через двигатель;

Таблица 3

## Бинарная классификация состояний ГТД

Номер состояния $N$	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%	

температуры  $\Delta T_2^*$  и давления  $\Delta P_2^*$  воздуха за компрессором; температуры газа перед турбиной  $\Delta T_3^*$ ; температуры  $\Delta T_4^*$  и давления  $\Delta P_4^*$  газа за турбиной; давления газа  $\Delta P_6^*$  на срезе реактивного сопла; расход топлива  $\Delta G_T$ ; тяги двигателя  $\Delta R$ .

Для обучения распознаванию дефектов нейронной сетью в составе обучающей выборки были выделены пять обобщенных классов состояний двигателя (табл. 3):

$S_1$  — 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  $R = [1; 0; 1]$ .

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 «голодани-

ем», деформацией статора. Уменьшение КПД турбины может быть обусловлено такими дефектами, как прогар, обрыв, эрозия рабочих лопаток турбины и лопаток соплового аппарата, а также дефекты подшипника, наличие 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. 4.

Таблица 4

## 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: ( $-1\% \eta_{\text{КНД}}$ ) ( $-3\% \eta_{\text{ТНД}}$ )

Анализ табл. 4 показывает, что значения выходов нейроклассификатора в процессе его тестирования отличаются от выходов НС-2 на обучающей выборке (табл. 3), где осуществлялось обучение сети на прецеденты, характеризующиеся 5%-ным 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. 4) 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 вопроса 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 компонентов можно выделить 7 параметров:  $n_2, P_2^*, T_3^*, T_4^*, P_4^*, P_6^*, R$ .

В табл. 5 приведены результаты диагностирования состояния ГТД с помощью НС при различном числе используемых штатных датчиков (от семи до четырех).

Ошибка обучения НС при этом вычисляется по формуле

$$E_{\text{обуч.}} = \|R_{\text{эт.}} - R\|,$$

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. 3), число столбцов обучающей выборки последовательно уменьшалось от 7 до 4. На рис. 5 показана зависимость изменения ошибок обучения ( $E_{\text{обуч.}}$ ) и тестирования ( $E_{\text{тест.}}$ ) сети от количества используемых датчиков (входов сети). Результаты анализа (рис. 5) 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  $\Delta Y$  — вектор отклонений параметров на входе классификатора. Исследования, проведенные с помощью пакета Statistica 6.0, показали, что для обеспечения достаточной точности диагностирования

Таблица 5

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

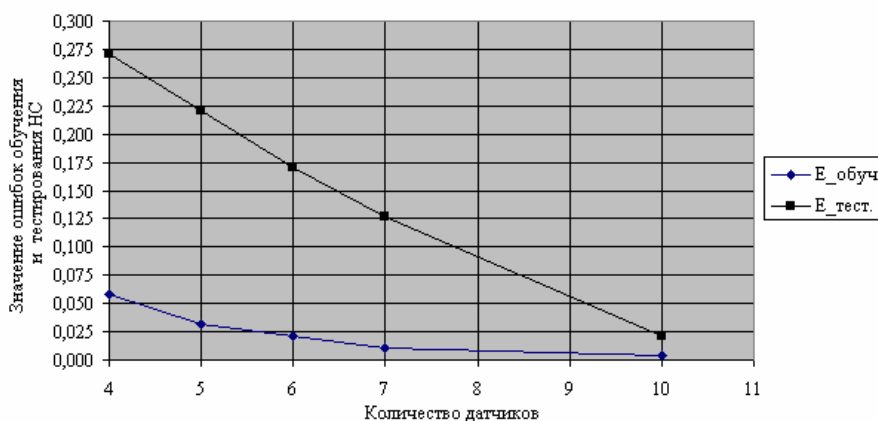


Рис. 5. Зависимость качества обучения и тестирования НС от количества измеряемых параметров ГТД

необходимо использовать полиномы не менее 12-й степени. Результаты, полученные с помощью МНК, приведены в табл. 6. Данные результаты получены для тестовой выборки (3-я и 4-я строки табл. 7) и соответствуют 1%-ному и 3%-ному уменьшению  $\eta_{\text{КНД}}$ , а также наличию аддитивной составляющей шума ( $\sigma = 0,01$ ;  $M = 0$ ).

Сравнение результатов, приведенных в табл. 6, с данными табл. 3 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. 4 и табл. 6) показывает, что они обеспечивают примерно одинаковые показатели качества диагностирования состояния ГТД, однако, в условиях наличия шумов нейронная сеть дает меньшую ошибку распознавания.

#### 4. ПОСТРОЕНИЕ НЕЙРОСЕТЕВОЙ ЭКСПЕРТНОЙ СИСТЕМЫ

Анализ современных экспертных систем и подходов к их разработке [4, 6, 7, 18, 19] показывает, что в настоящее время существуют

два основных направления в создании нейросетевых экспертных систем:

- в первом случае отказываются от традиционной архитектуры экспертной системы и развивают ее на совершенно новых принципах; для этого все понятия предметной области и отношения между ними перечисляются в явном виде на стадии ее создания;

- во втором случае сохраняют традиционную архитектуру экспертной системы и посредством нейронных сетей реализуют традиционные ее компоненты; в этом случае возможно неявное задание как понятий, так и отношений, что делает этот подход более применимым для сложных и малоисследованных предметных областей, однако принципиальная конструктивная новизна проявляется здесь на уровне подсистем, а не системы в целом.

В качестве основных требований, предъявляемых к современным системам контроля и диагностики ГТД, выделяют использование в них, наряду с количественными моделями, максимально учитывающими физические процессы, происходящие в двигателе, также и качественные модели на основе нейронных сетей, учитывающих индивидуальные

Таблица 6

Результаты тестирования классификатора, построенного на основе МНК

№ строки	Выходы 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	

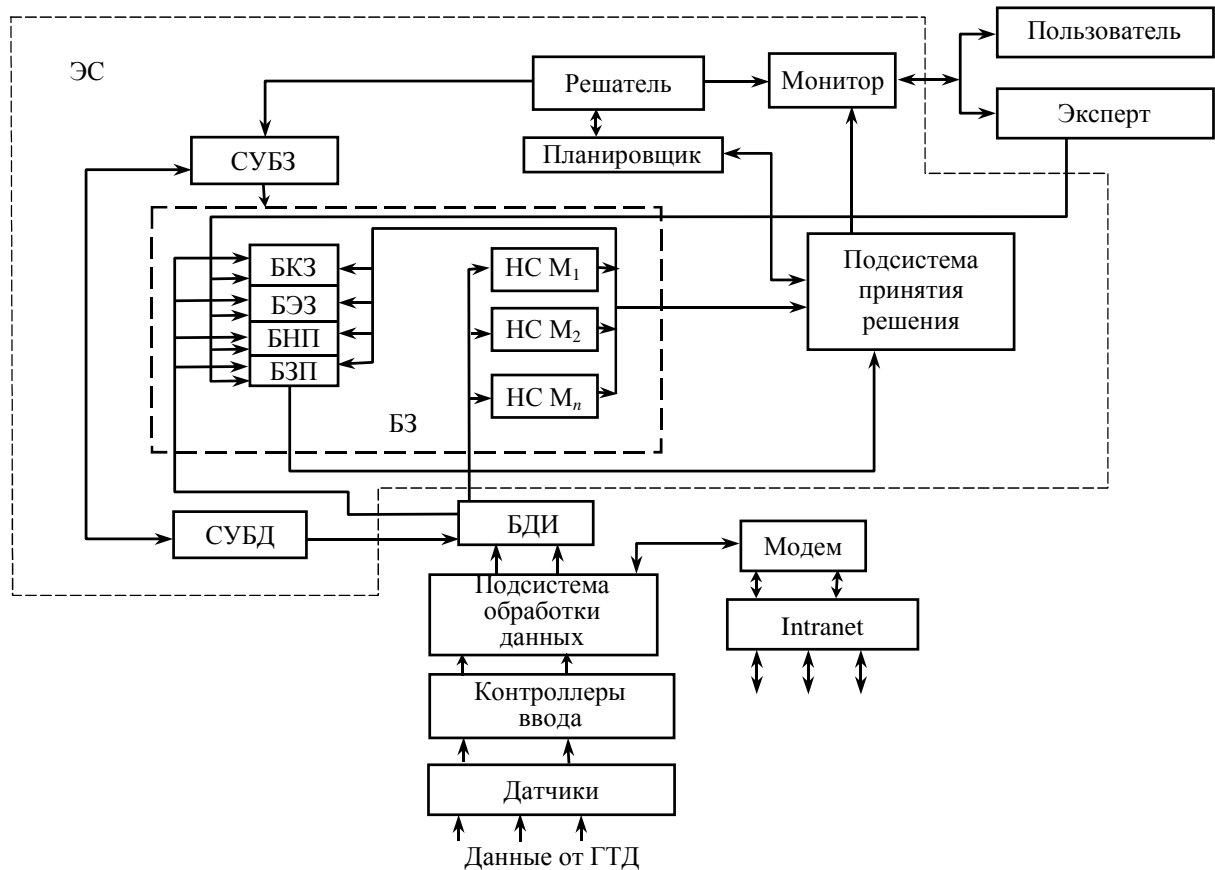


Рис. 6. Структура нейросетевой ЭС контроля и диагностики ГТД

характеристики отдельных ГТД. Данный подход использовался при разработке нейросетевой экспертной системы «Эксперт Нейро».

Спектр задач, решаемых данной экспертной системой, широк: классификация режимов работы двигателя, идентификация, контроль, диагностика, прогнозирование технического состояния ГТД, отладка параметров двигателя.

Нейросетевая экспертная система «Эксперт Нейро» разработана на базе «пустой» гибридной экспертной оболочки C-PRIZ, расширенной средой моделирования MATLAB. Ее структура приведена на рис. 6, где БЗ — база знаний; НСМ — нейросетевые модули; БКЗ — база концептуальных знаний; БЭЗ — база экспертных знаний; БНП — база нечетких правил; БЗП — база знаний прецедентов; БДИ — база данных испытаний; СУБД и СУБЗ — системы управления базами данных и базами знаний. «Эксперт Нейро» относится к четвертому поколению экспертных систем [4], которым присущ динамизм БЗ и подсистем логического вывода, а также наличие ярко выраженных адаптивных свойств, развитого интерфейса не только с пользователем, но и с внешней средой.

К отличительным особенностям разработанной ЭС следует отнести:

- наличие нейросетевой базы знаний, образованной нейросетевыми модулями, решающими широкий спектр задач контроля и диагностики технического состояния ГТД;

- наличие базы нечетких правил и базы знаний прецедентов, повышающих эффективность и качество решения задач контроля и диагностики ГТД;

- наличие сетевого компонента, позволяющего в режиме реального времени обмениваться протоколами испытаний серийных ГТД и накапливать опыт их эксплуатации, одновременно выделяя и дополняя знания в БЗ.

Ядром нейронечеткой ЭС, координирующим процесс межмодульного взаимодействия, а также поддерживающим интерфейс с пользователем, является управляющая программа-монитор, обеспечивающая внутренний «сценарий работы» с блоками системы и интерфейс с различными средами моделирования.

Машина логического вывода образована тремя основными компонентами: решателем, планировщиком и модулем принятия решения. Решатель формирует задачу





Рис. 7. Классы решаемых задач и основные модули нейросетевой ЭС

и осуществляет ее решение. Планировщик осуществляет планирование необходимых вычислительных ресурсов для решения поставленной задачи. Модуль принятия решения формирует решающее правило, на основании которого нейросетевая ЭС принимает решение о техническом состоянии ГТД.

База знаний нейросетевой ЭС представляет собой объединение разнородных знаний: экспертную и нейросетевую базу знаний.

Составными компонентами экспертной базы знаний являются: базы концептуальных и экспертных знаний, базы нечетких правил в виде функций принадлежности лингвистических переменных и базы знаний прецедентов,

которые широко используются в процессе решения практических задач ЭС С-PRIZ.

Нейросетевая БЗ представлена нейросетевыми модулями, обеспечивающими решение широкого спектра задач контроля и диагностики авиационного ГТД.

Данные, учитывающие индивидуальные особенности конкретного ГТД или среднестатистического по парку двигателя, поступают на нейросетевые модули из БДИ (временная БД реляционного типа), управляемой СУБД, встроенной в ЭС. Контроль над СУБЗ и СУБД осуществляется решателем в процессе решения поставленной задачи.

Классы решаемых задач и реализующие их модули нейросетевой ЭС показаны на рис. 7.

Взаимодействие нейросетевой ЭС с ГТД осуществляется через датчики, контроллеры ввода и подсистему обработки данных. Связь с сетевыми ресурсами в рамках предприятий отрасли или отдельно взятого предприятия может осуществляться через модем и сеть Intranet. «Эксперт Нейро» функционирует под управлением ОС Windows XP и требует от 640 Кбайт основной памяти, а также от 1,5 Мбайт на жестком диске. При разработке «Эксперт Нейро», наряду со встроенным языком объектно-ориентированного типа (НУТ), использовались другие языки программирования (С++, Ассемблер) и среды разработки интерфейса, совместимые между собой по данным.

Нейросетевые модули, входящие в состав БЗ нейросетевой ЭС, могут работать независимо друг от друга. При этом они совместимы по данным не только между собой, но и со всеми компонентами нейросетевой ЭС и ее утилитами.

#### ЗАКЛЮЧЕНИЕ

1. Разработаны и исследованы нейросетевые методы и алгоритмы, обеспечивающие решение широкого спектра плохо формализуемых задач, связанных контролем и диагностикой технического состояния параметров ГТД. Показано, что применение этих методов и алгоритмов позволяет осуществлять решение задачи диагностики технического состояния ГТД в нейросетевом базисе. При этом применение НС позволяет решить задачу диагностики ГТД с точностью до узла; при уменьшении числа штатных датчиков до 5–7 обеспечивается приемлемое качество диагностирования; сохраняется высокое качество диагностирования технического состояния ГТД в условиях аддитивной случайной помехи.

2. Разработана архитектура нейросетевой экспертной системы «Эксперт Нейро», определен состав входящих в нее нейросетевых модулей, реализующих предложенные нейросетевые алгоритмы и технологии обработки информации для решения задач контроля и диагностики технического состояния ГТД.

#### 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 [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. Федунев. М. : Физматлит, 2000. 352 с.
7. Герман, О. В. Введение в теорию экспертных систем и обработку знаний / О. В. Герман. 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 [и др.] // Авиационно-космическая техника и технологии. Харьков : ХГАТУ, 2000. Вып. 19. С. 372–376.
9. Епифанов, С. В. Синтез систем управления и диагностирования газотурбинных двигателей / С. В. Епифанов [и др.]. Киев : Техника, 1998. 312 с.
10. Жернаков, С. В. Диагностика и прогнозирование состояния газотурбинного двигателя гибридными нейронечеткими экспертными системами / С. В. Жернаков // 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 / С. В. Жернаков // Информационные технологии. М. : Машиностроение. 2000. № 12. С. 37–44.
12. Жернаков, С. В. Нейросетевая экспертная система комплексного мониторинга и управления эксплуатацией авиационных двигателей / С. В. Жернаков // 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 / С. В. Жернаков // Информационные технологии. М. : Машиностроение, 2001. № 6. С. 42–48.
14. Жернаков, С. В. Интеллектуальный мониторинг и диагностика параметров газотурбинно-

- го двигателя гибридными экспертными системами / С. В. Жернаков // Автоматизация и современные технологии. М. : Машиностроение, 2001. № 12. С. 16–22.
15. **Жернаков, С. В.** Активная диагностическая экспертная система / С. В. Жернаков // Проблемы машиностроения и надежности машин. М. : РАН, 2002. № 1. С. 92–99.
  16. **Жернаков, С. В.** Контроль и диагностика параметров газотурбинного двигателя нейронными сетями / С. В. Жернаков // Нейрокомпьютеры: разработка, применение. М. : Радиотехника, 2003. № 8–9. С. 51–66.
  17. **Шепель, В. Т.** Надежность, диагностика, контроль авиационных двигателей / В. Т. Шепель [и др.]. Рыбинск : РГТА, 2001. 352 с.
  18. **Научный вклад** в создание авиационных двигателей. Кн. 1 / под ред. В. А. Скибина и В. И. Солонина. 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 / Э. А. Трахтенгерц. 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 / R. Isermann // Automatica 29. 1993. P. 815–836.
  23. **Narendra, K. S.** Neural networks for control. Theory and practice / K. S. Narendra // Proc. of the IEEE. 1996. Vol. 84, No. 10. P. 1385–1405.
  24. **Patton, R. J.** Issues in Fault Diagnosis for Dynamic Systems / R. J. Patton, P. M. Frank, R. N. Clark. London : Springer-Verlag, 2000. 536 p.
  25. **Zedda, M.** Fault diagnosis of a turbofan engine using neural networks: a quantitative approach / M. Zedda, R. Singh // Proc. of the 34th AIAA / ASME / SAE / ASEE Joint Propulsion Conference & Exhibit. 1998. P. 1–10.

#### ОБ АВТОРАХ

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



**Жернаков Сергей Владимирович**, проф. каф. выч. техники и защиты информации. Дипл. инж. по промэлектронике (УГАТУ, 1984). Д-р техн. наук по сист. анализу, управлению и обр. информации (УГАТУ, 2005). Иссл. в обл. интел. систем.

