

С. В. Жернаков, С. В. Кобылев

ИСПОЛЬЗОВАНИЕ РЕКУРРЕНТНЫХ НЕЙРОСЕТЕЙ В ЗАДАЧЕ ДИАГНОСТИКИ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ГИДРОМЕХАНИЧЕСКОГО АВТОМАТА РАЗГОНА

Приводится пример построения нейросетевого классификатора, осуществляющего распознавание неисправного состояния (дефекта) в гидромеханическом регуляторе ГТД. *Рекуррентные нейронные сети; бортовые системы гидромеханики; алгоритмы контроля и диагностики*

ВВЕДЕНИЕ

Безопасность функционирования сложных технических объектов (СТО), например, авиационных газотурбинных двигателей (ГТД) требует непрерывного мониторинга их параметров. Создание ГТД V-VI поколения требует непрерывного совершенствования диагностируемой и контролируемой аппаратуры, обусловленного увеличением числа контролируемых параметров, усложнением конструкции, ростом числа датчиков и исполнительных механизмов. В этих условиях наиболее актуальной проблемой является разработка и внедрение интеллектуальных технологий – активных экспертных систем (ЭС) [1–3], способных качественно и эффективно решать поставленные задачи (на уровне специалиста – эксперта). Это особенно важно сейчас, так как своевременное обнаружение и локализация отказов позволит исключить многочисленные аварийные и катастрофические ситуации, участвовавшие в последнее время.

Роль человеческого фактора с ростом числа контролируемых и диагностируемых параметров падает [4], так как сопряжена с многочисленными ошибками контроля и принятия решений (особенно в условиях НЕ-факторов: неопределенности ситуации; многочисленные помехи и неточности измерений; неполнота и недостоверность контроля и т. д.). Спектр задач диагностики и контроля параметров авиационного ГТД существенно расширился с внедрением активных ЭС на борт летательного аппарата (ЛА). В частности, возможно проведение на борту ЛА не только регистрации и предотвращения аварийных ситуаций, но и настройки, отладки, углубленного диагноза состояния двигательных установок и ЛА. Данные возможности потребовали разработки и адаптации в среде

баз знаний (БЗ) активных ЭС, наряду с хорошо зарекомендовавшими себя методами, методиками и алгоритмами новых методологий и принципов построения ЭС комплексного мониторинга, которые должны стать составной частью общей информационно-управляющей системы.

Как известно [5], диагностику ГТД можно проводить с разной степенью подробности. В активной ЭС (рис. 1) может быть организован трехуровневый диагноз состояния и неисправностей ГТД [5]: аварийный диагноз или диагноз малой глубины; диагноз средней глубины; диагноз большой глубины. Аварийный диагноз осуществляется по таблицам неисправностей (граф причинно-следственных связей, допусковый контроль) [6–8]. Если же аварийный диагноз не дает убедительного ответа, то принятие решения активной ЭС осуществляется на основе гетерогенной БЗ, в которой наряду с традиционными знаниями (семантические сети, фреймы, продукции, логические модели), широко применяются БЗ прецедентов, реализованные на нейросетевых моделях (НСМ).

Основными требованиями, предъявляемыми к таким ЭС, являются: работа в реальном масштабе времени и гетерогенные (разнородные) БЗ (ГБЗ). Обеспечение режима реального времени осуществляется активной ЭС посредством интерфейса с внешним миром (датчики – контроллеры – исполнительные механизмы). ГБЗ включает в себя: базы концептуальных знаний (БКЗ) (понятия из конкретной предметной области; факты; формулы; зависимости; закономерности, таблицы и т. д.); базы экспертных знаний (БЭЗ) (эвристика; априорная; апостериорная; экспертная информация и т. д.); базы знаний прецедентов (БЗП).

Хранимые знания в ГБЗ могут быть статическими и динамическими. Статические ГБЗ накапливают опыт эксплуатации ГТД независимо от времени. Динамические ГБЗ накапливают

опыт в темпе реального времени: запоминается характеристика переходного процесса (переходные и неустановившиеся режимы работы); частотные характеристики и т. д. БЗП в среде активной ЭС является новой парадигмой [9–10] в процессе принятия решений при возникновении проблемных ситуаций в реальном масштабе времени.

Прецедент – это описание проблемы или ситуации в совокупности с подробным указанием действий, предпринимаемых в данной ситуации для решения данной проблемы. Прецедент включает: проблемную ситуацию, которая описывает состояние исследуемого процесса, когда произошел прецедент; решение этой проблемы; результат, который описывает состояние исследуемого процесса после произошедшей проблемной ситуации [9]. Вывод, основанный на прецедентах в активной ЭС, существенно отличается от других подходов искусственного интеллекта: вместо манипулирования общими знаниями в прикладной области, БЗП использует специфические знания относительно конкретных проблемных ситуаций из предыдущего опыта. Решение в новой проблемной ситуации осуществляется путем нахождения похожего прецедента в прошлом, и это решение многократно используется в последующих проблем-

ных ситуациях. В работе [9] представлена теория обучения, основанная на сохранении опыта в динамическом развитии памяти и использовании прецедентов как моделей обучения решению проблем. Проблемная ситуация из предыдущего опыта, которая была зафиксирована и изучена таким образом, что она может многократно использоваться в решении будущих проблем, в совокупности с принятым решением, представляет собой предыдущий или сохраняемый прецедент.

Очевидно, новый или нерешенный прецедент – описание новой проблемы, которая будет решена. Вывод, основанный на прецедентах – циклический и интегрированный процесс решения проблемы, изучение опыта принятия решений в процессе комплексного контроля и диагностики параметров ГТД. Вывод, основанный на БЗП в активной ЭС может быть реализован следующим образом (рис. 2).

Если в процессе решения задачи найдено успешное решение в проблемной ситуации, то прецедент сохраняется в БЗ для решения похожих проблем. Если попытка решения задачи ошибочна, то причина ошибки идентифицируется и запоминается в БЗ для исключения похожей ошибки в будущем.

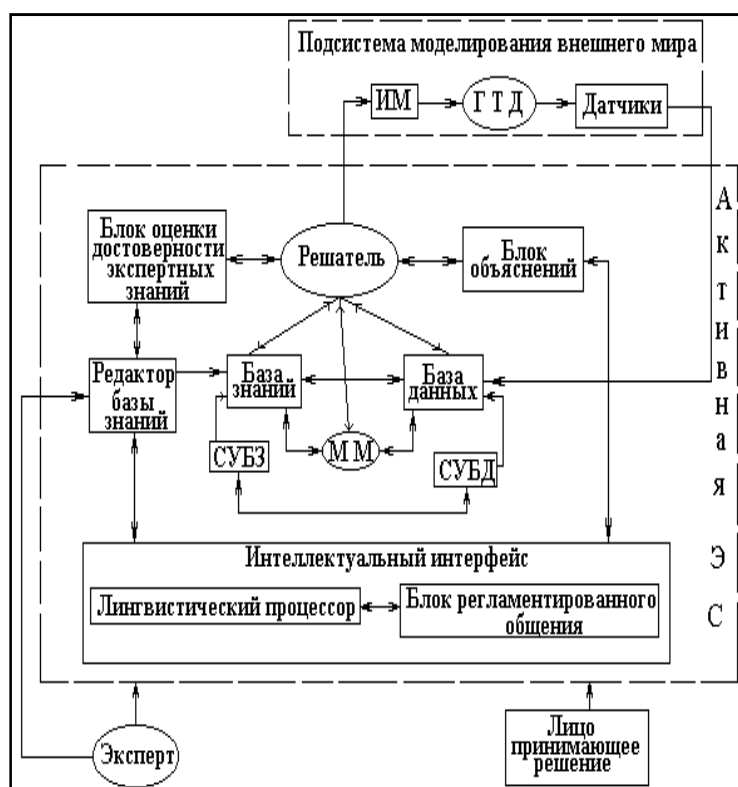


Рис. 1. Функциональная схема активной ЭС

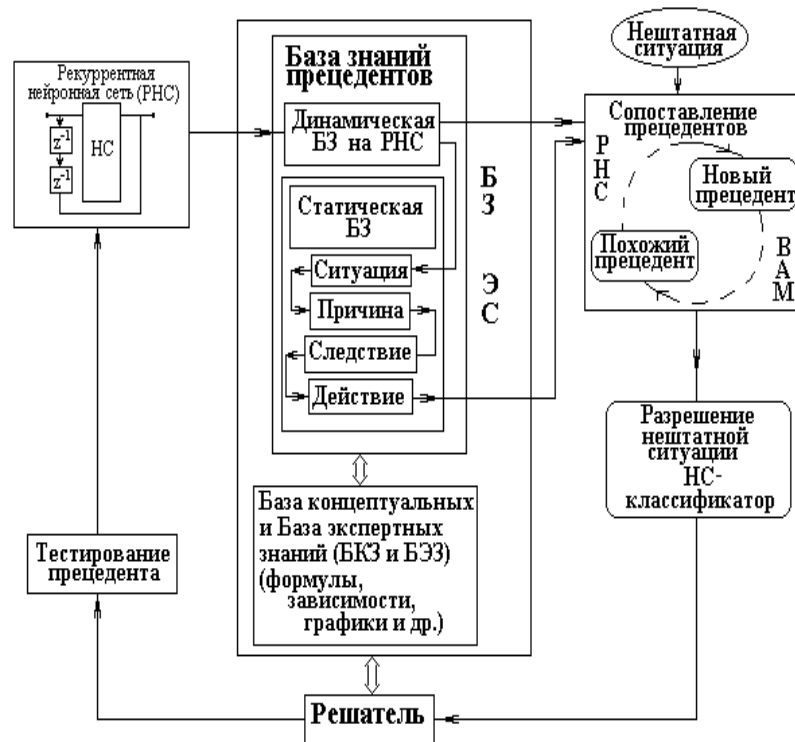


Рис. 2. База знаний прецедентов на нейронных сетях

В данной статье авторами предлагается реализация БЗП активной ЭС комплексного контроля и диагностики технического состояния гидромеханического автомата разгона ГТД на основе рекуррентных НС. Рассмотрена реализация БЗП на примере диагностики и контроля параметров временного автомата приемистости ГТД.

ПОСТАНОВКА ЗАДАЧИ

Пусть множество прецедентов $r_i \in R$, $i = \overline{1, N}$; расположено в некотором n -мерном пространстве, где каждый прецедент представлен своим вектором $\alpha_j = (\alpha_{j_1}, \dots, \alpha_{j_n})$, $j = \overline{1, n}$; а вся совокупность матрицей $C(N, n)$. Пусть прецеденты образуют в данном пространстве некоторое число L – компактных областей R_k , $k = \overline{1, L}$ (классы). Задачей анализа является выделение локальных областей: классов прецедентов, т. е. их классификация на базе рекуррентных НС, реализующих минимизацию функционала:

$$A(z_1, \dots, z_L) = \frac{1}{N} \sum_{j=1}^L \sum_{\alpha \in r_i} \|\alpha - \bar{z}_j\|^2 \rightarrow \min;$$

$$\bar{z}_j = \frac{1}{N_j} \sum_{\alpha \in r_i} \alpha;$$

где L – число классов R_j ; \bar{z}_j – среднее значение множества (центр кластера); N_j – число прецедентов в множестве r_i .

МАТЕМАТИЧЕСКАЯ МОДЕЛЬ АВТОМАТА РАЗГОНА ГТД

Разгон и торможение двигателя являются существенно неравновесными процессами с весьма большими сигналами управления; применение линейных методов в этих условиях приводит к большим погрешностям анализа и малоэффективно для разработки технических средств управления переходными процессами.

Наиболее оптимальной альтернативой в этом случае представляется динамическая поэлементная модель, построенная на основе рассмотрения фундаментальных законов равновесия в основных элементах двигателя. Разнообразные варианты таких моделей хотя и рассматривались в ранних изданиях [3–4], но оказывались невостребованными, в связи с недостаточным развитием аппаратной части и программного обеспечения ЭВМ.

Программы подачи топлива на режимах приемистости и сброса могут быть разными в зависимости от конструкции, параметров и способов регулирования. Для минимизации времени приемистости необходима реализация программы, при которой регулируемые параметры близки к их предельным значениям, обу-

словленным ограничениями со стороны авиационного двигателя.

Для обеспечения разгона (или торможения) ротора двигателя необходимо приложить избыточный движущий момент, т. е. обеспечить избыточную подачу топлива. Это осуществляется с помощью специальных регулирующих устройств, устанавливаемых параллельно регуляторам статических режимов.

ГТД, как СТО, характеризуется сложными физическими процессами, протекающими в нем и его подсистемах. Процессы запуска и разгона авиационных двигателей являются определяющими режимами его эксплуатации. Специальные регуляторы – временные автоматы приемистости (автоматы разгона) обеспечивают им нормальную приемистость – способность ГТД к изменению режима работы (переход двигателя с режима минимальной на режим максимальной тяги и наоборот). Выход временного автомата приемистости ГТД из строя может привести к аварийным и катастрофическим ситуациям. Поэтому своевременное обнаружение и локализация отказов позволяют активной ЭС парировать аварийные и нештатные ситуации в процессе его эксплуатации.

На рис. 3 приведена принципиальная схема автомата разгона, у которого кроме основного дроссельного пакета изодрома 3 имеются пакеты разгона f_1 и сброса f_2 .




Рис. 3. Автомат разгона временного типа

Разгон двигателя осуществляется следующим образом: при перемещении ручки управления уменьшается слив рабочей жидкости из правой управляемой полости поршня 5, и давление в ней начинает расти. Поршень 5 начинает двигаться влево, перемещая поршень 6 и дозирующую иглу 7, осуществляя перевод двига-

теля на повышенные обороты. В случае значительного перемещения ручки управления двигателем поршень 5 движется до упора, попутно включая в работу дроссель разгона f_1 , проходное сечение которого намного больше, чем у основного дросселя 3. В связи с этим дозирующая игла движется с большей скоростью, осуществляя быстрый разгон авиационного газотурбинного двигателя. В данном случае используется регулятор с переменной структурой, аналитическое описание которого линейной моделью невозможно. Поэтому в дальнейшем будут использоваться законы сохранения в фундаментальной форме с учетом нелинейностей.

Математическая модель (ММ) временного автомата приемистости может быть представлена:

$$\begin{aligned} \frac{dy}{dt} &= \Delta v; \\ \frac{dv}{dt} &= \frac{1}{m} (F_u \Delta p - c_{\Sigma} Y_0(y) - k_v Y_1(y) v - F_c); \\ \frac{dp}{dt} &= \frac{E}{V_{\Sigma} + F_u \Delta y} (\mu f \sqrt{\frac{2}{\rho}} (p_0 f_{\Pi}^2 - \Delta p) - \\ &\quad - \mu b Z(z) \sqrt{\frac{2}{\rho}} (p_0 + \Delta p) - F_u Y_1(y) v - \\ &\quad - \mu f_{\Pi} \sqrt{\frac{2}{\rho}} \Delta p - \mu F_1(y) \sqrt{\frac{2}{\rho}} \Delta p); \\ \frac{dx}{dt} &= \frac{1}{F_d} (\mu f_{\Pi} \sqrt{\frac{2}{\rho}} \Delta p + \mu F_1(y) \sqrt{\frac{2}{\rho}} \Delta p); \\ \frac{dn}{dt} &= \frac{1}{T_{dv}} (k_{dv} (k_{du} \Delta x + \Delta f_b) - \Delta n); \end{aligned} \quad (1)$$

где $Y_0(y)$ – функция пользователя, ограничивающая перемещение поршня изодрома; $Y_1(y)$ – функция пользователя, ограничивающая скорость поршня изодрома; $Z(z)$ – функция пользователя, не позволяющая ширине щели маятникового распределителя становиться отрицательной; $F_1(y)$ – функция пользователя, определяющая включение дросселя; y – перемещение поршня; t – время; v – вязкое трение; m – масса статического поршня; F_u – площадь статического поршня; c_{Σ} – жесткость пружины чувствительного элемента; F_c – сила сухого трения; k_v – приведенный коэффициент вязкого трения; p_0 – давление питания; Δp – приращение давления; E – модуль объемной упругости жидкости, считается, что содержание нерастворенного воздуха мало, т. е. $E = \text{const}$; V_{Σ} – суммарный объем; Δy – приращение перемещения поршня; μ – коэффициент расхода; f и f_{Π} – соответственно площади входного и выходного дроссельных

пакетов; b – ширина щели распределителя (щель считается прямоугольной); ρ – плотность рабочей жидкости; x – перемещение астатического поршня; F_d – площадь астатического поршня дозирующей иглы; n – частота вращения двигателя; T_{dv} – постоянная времени двигателя; k_{dv} – коэффициент усиления двигателя; k_{di} – коэффициент усиления дозирующей иглы; Δx – перемещение дозирующей иглы; Δn – приращение частоты вращения; Δf_b – внешние воздействия, выраженное в долях расхода топлива.

Математическое описание системы регулирования составляется в предположении следующих допущений: коэффициенты расхода маятникового распределителя и дросселей считаются постоянными; соблюдаются условие неразрывности жидкости и закон Гука; на дозирующей игле сохраняется перепад давления так, что расход топлива полностью определяется ее перемещением; трубопроводы считаются короткими (сосредоточенные параметры); существенные нелинейности – не рассматриваются; давление слива равно нулю.

Кроме того, так как модель регулятора получается достаточно сложной и громоздкой, то с целью упрощения применяется самая простая линейная модель двигателя, а датчик частоты вращения считается безынерционным. Математическая модель (ММ) включает в себя уравнения движения вычислительного рычага и поршня, баланс расходов гидроусилителя, уравнения дозирующей иглы и авиационного двигателя.

Комплексная диагностика и контроль параметров временного автомата приемистости ГТД

осуществляется активной ЭС и ее ГБЗ, в которой хранятся эталонные характеристики временного автомата приемистости ГТД (рис. 4). Реализация БЗП на основе рекуррентных НС динамической БЗ позволяет активной ЭС совместно со статической БЗ (БКЗ и БЭЗ) эффективно решать прямые и обратные задачи комплексного контроля и диагностики параметров временного автомата разгона ГТД, граф причинно-следственных связей и таблица неисправностей которого хранятся в БЭЗ.

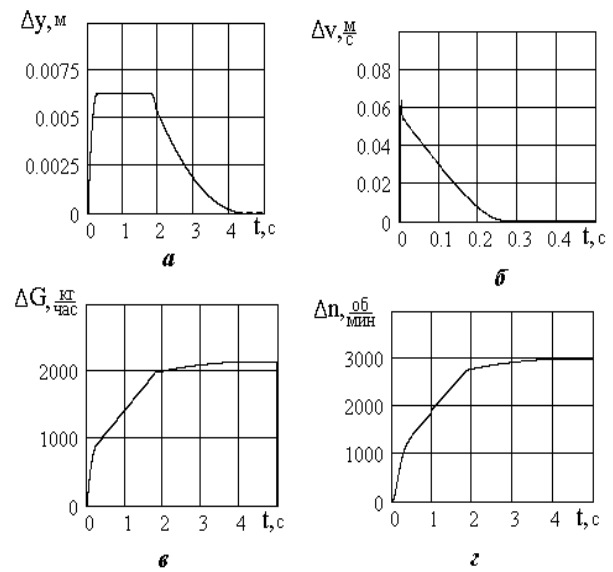


Рис. 4. Эталонные характеристики временного автомата приемистости: а – перемещение поршня; б – скорость поршня; г – расход топлива; з – частота вращения двигателя

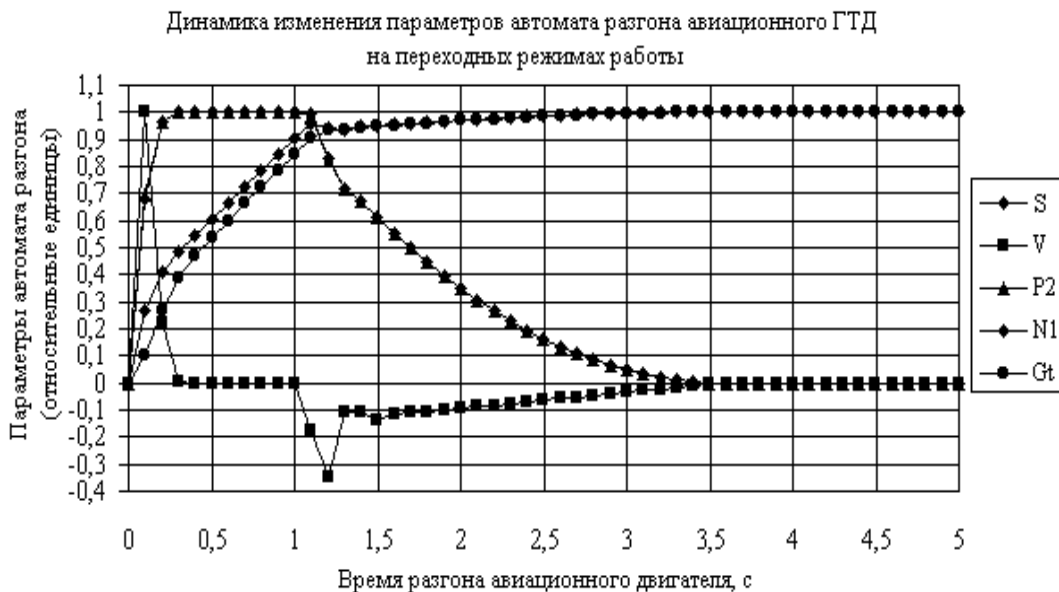


Рис. 5. Параметры автомата разгона ГТД на этапе стендовых испытаний

Типовые результаты интегрирования системы (1) при нулевых начальных условиях и динамика изменения тех же параметров в условиях стенда показаны на рис. 4 и рис. 5, где P_2 – давление воздуха за компрессором ГТД, а N_1 – частота вращения ротора компрессора низкого давления авиационного двигателя.

К основным неисправностям временного автомата разгона ГТД можно отнести: засорение дроссельных пакетов; разгерметизация (утечки, перетечки); излом упругих элементов; изменение начальной затяжки; появление выработки между корпусом и золотником; подсос воздуха в систему и т. д.

В качестве основных дефектов автомата разгона авиационного двигателя рассмотрим неисправности, связанные с изменением F_u, f, f_{Π} и F_d , а у авиационного ГТД – с изменением к.п.д. компрессора, турбины и полноты сгорания топлива в камере сгорания. Среди комплексных отказов гидромеханического автомата разгона авиационного двигателя в работе исследовалось влияние дефектов как автомата разгона, так и ГТД (конструктивные, параметрические отказы и их взаимное влияние). На рис. 6–7 показано влияние дефекта, связанного с изменением (уменьшением) площади аstaticкого поршня дозирующей иглы (F_d) и площади staticкого поршня (F_u) на характеристики временного автомата приемистости (регулятора).

Решение данной задачи в нейросетевом базисе требует соответствующей формализации, заключающейся в следующем: пусть состояние автомата приемистости и авиационного ГТД как системы диагностирования определяется значением вектора параметров Q , значения которого могут меняться при возникновении аварийных или критических ситуаций в работе авиационного двигателя и его регулятора. Предполагается, что все возможные состояния регулятора и авиационного газотурбинного двигателя можно разбить на $(r + 1)$ областей (классов) W_0, W_1, \dots, W_r . Нахождение вектора состояния G в области W_0 определяется как событие, соответствующее исправному состоянию регулятора и ГТД. При любом из возможных отказов элементов (узлов) в работе регулятора и ГТД (внезапных или постепенных) вектор G принадлежит одной из областей W_1, \dots, W_r , что рассматривается как событие, связанное с неисправным состоянием ГТД и его регулятора:

$$G \in \bar{W}_\alpha = W_\alpha; \quad \alpha = 1, \dots, r.$$

Тогда задача диагностирования состояния ГТД и его регулятора заключается в том, чтобы установить соответствие между координатами

вектора наблюдений Q и пространства состояний W_α и, на основании наблюдаемых реализаций Q , оценить принадлежность вектора состояния G области W_0 или $W_\alpha \subset \bar{W}_0$, т. е. определить, к какому из классов состояний относится состояние конкретного образца ГТД и его регулятора.

Целью решаемой ниже задачи является исследование алгоритмов построения нейросетевого классификатора, осуществляющего распознавание неисправного состояния (дефекта) в ГТД и его регуляторе с точностью до узла, а также разработка соответствующей инженерной методики для реализации этих задач.

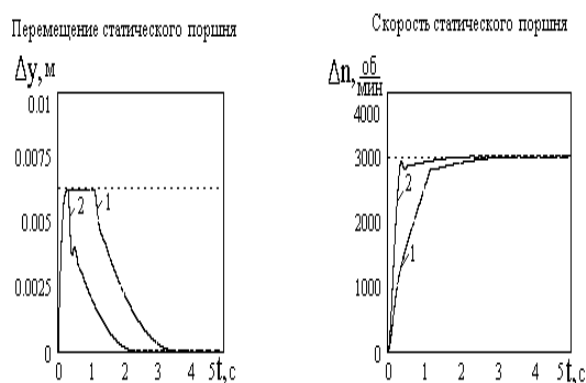


Рис. 6. Влияние дефекта F_d на характеристики автомата разгона (1 – исправное состояние; 2 – наличие дефекта)




Рис. 7. Влияние дефекта F_u на характеристики автомата разгона (1 – исправное состояние; 2 – наличие дефекта)

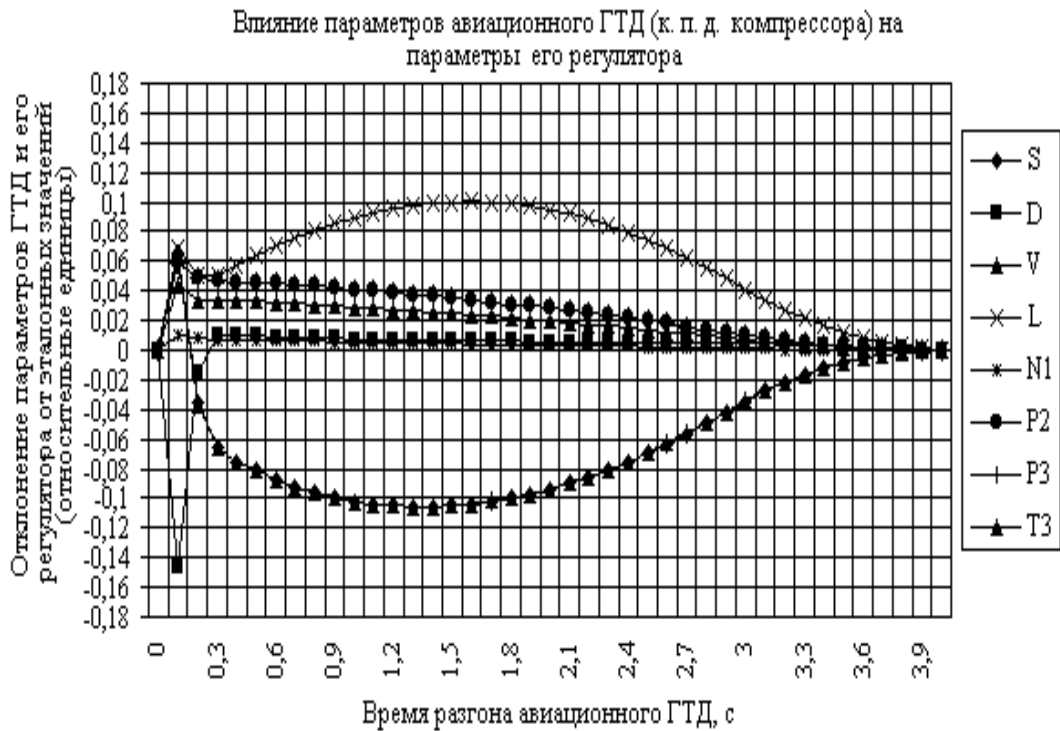


Рис. 8. Влияние дефекта в авиационном двигателе на параметры его регулятора

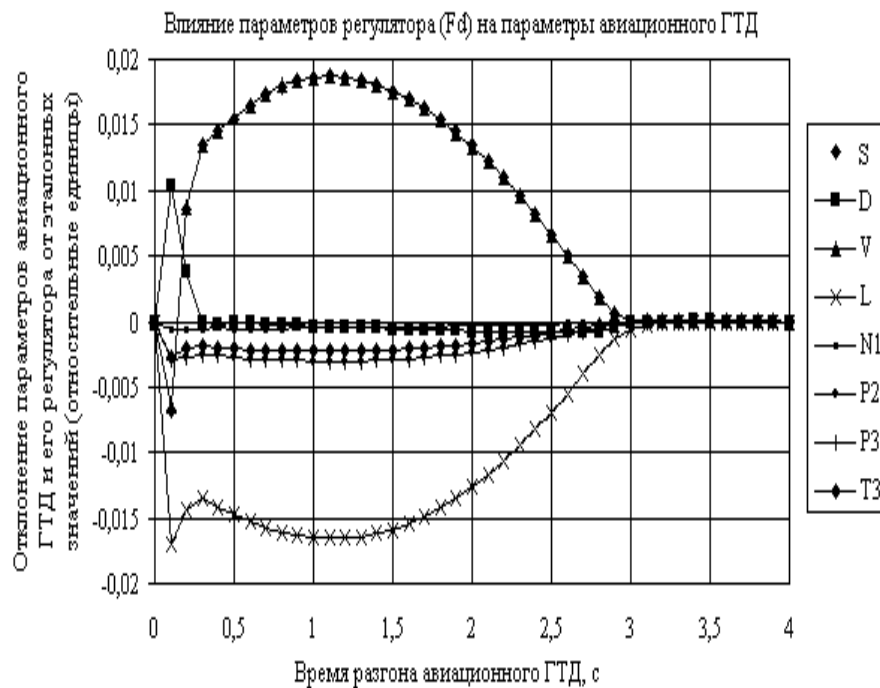


Рис. 9. Влияние дефекта регулятора на параметры авиационного двигателя

В качестве основы построения систем диагностики ГТД целесообразно использовать FDI (Fault Detection and Identification) метод. Рассмотрим особенности применения данного метода при решении задач диагностики авиационного двигателя и его регулятора с использованием нейросетевых алгоритмов. При этом, если

при построении классических экспертных систем эталонная (среднестатистическая) модель ГТД хранится в виде математической модели (компоненты базы знаний) и представлена системой алгебраических и дифференциальных уравнений, как правило, не учитывающих индивидуальные особенности конкретного двигателя

ля, то применение нейронных сетей позволяет устранить этот недостаток. Реализация FDI метода в нейросетевом базисе (рис. 10) сводится к следующей последовательности шагов:

- хранение эталонных характеристик индивидуального (среднестатистического) ГТД в виде «информационного портрета» на базе сети НС1;
- сравнение параметров отдельно взятого ГТД – с данными, рассчитанными с помощью НС1;
- на основании анализа вектора полученных «невязок» (отклонений) между значениями вектора измеренных параметров конкретного двигателя и вектора данных, рассчитанных с помощью НС1, принимается решение о техническом состоянии ГТД (на этом этапе используется вторая нейронная сеть НС2).

Здесь в качестве характеристик индивидуального ГТД на этапе настройки (обучения) НС2 могут использоваться:

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

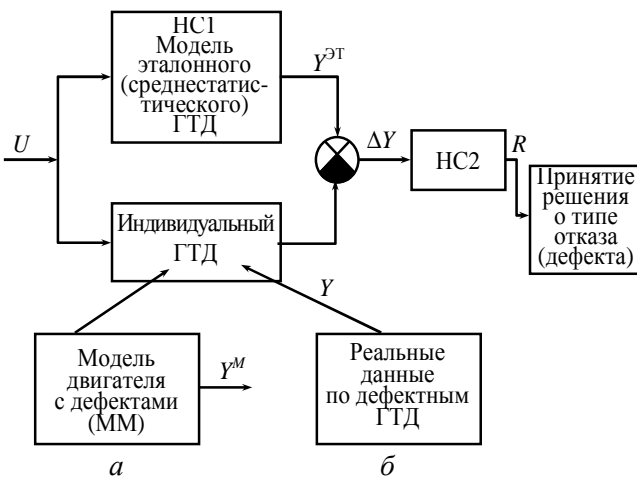


Рис. 10. Реализация FDI метода в нейросетевом базисе

Задача построения обученной модели эталонного (среднестатистического) двигателя НС1 подробно рассматривалась автором при решении задачи идентификации многорежимной модели ГТД [10, 11]. Сеть НС2 (рис.11) это 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. 11. Классификатор на основе НС2

Для построения сети НС2 воспользуемся разработанной методикой проектирования НС.

Первый этап – получение исходных данных (построение обучающей выборки)

Для решения задачи диагностики 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, к.п.д. компрессора, к.п.д. турбины и др., а также дефектов его регулятора, описанных выше.

На втором этапе вычисляются отклонения (невязки), вызванные тем или иным дефектом ГТД и его регулятором от его эталонного состояния: $\Delta Y = Y^{ЭТ} - Y^M$. Согласно данным о невязках ΔY_i формируется обучающая выборка, которая в общем виде может быть представлена: $\Delta Y_i \rightarrow R (i = 1, 2, \dots, n)$.

Рассмотрим в качестве диагностируемого объекта двухконтурный авиационный двигатель с регулятором временного типа. Данные, фрагмент которых приведен ниже (в таблице), получены путем математического моделирования термогазодинамических процессов по его нелинейной поэлементной модели (1) для режима «Максимальный» (расход топлива на данном режиме поддерживается постоянным: $G_T = \text{const}$).

В качестве диагностических признаков (входов НС2) используется информация по 8 параметрам двигателя и регулятора на режиме разгона – отклонения четырех параметров регулятора: S – перемещения поршня (м); V – скорости поршня (м/с); D – ширины щели клапана (м); L – длины щели клапана (м) и четырех параметров ГТД: ΔN_1 – частоты вращения ротора турбокомпрессора низкого давления (об/мин); ΔP_2^* – давления воздуха за компрес-

сором (Па); ΔP_3^* – давление газа перед турбиной (Па); ΔT_3^* – температуры газа перед турбиной (К).

Исправному ГТД и регулятору соответствует 1-я строка таблицы. Строки 2÷15 соответствуют дефектному двигателю и регулятору с 3% отклонением одного и следующих параметров состояния регулятора: *REG_f1* – изменение площади обводного дроссельного пакета; *REG_Fd* – изменение площади астатического поршня дозирующей иглы; *REG_Fu* – изменение площади статического поршня; *REG_P0* – изменение давления питания регулятора и параметров состояния авиационного ГТД: *KPDK* – изменение к.п.д. компрессора низкого давления; *KPDT* – изменение к. п. д. турбины низкого давления; *SIGKC* – изменение коэффициента полноты сгорания топлива в камере сгорания. Указанные строки образуют фрагмент временной выборки, соответствующей 0,1 с процесса разгона авиационного ГТД, который осуществляется в течение 4 с. Таким образом, каждому состоянию авиационного двигателя и регулятора в таблице соответствуют 40 строк, а суммарная обучающая выборка для НС2 содержит 320 значений параметров ГТД и его регулятора.

Для обучения распознаванию дефектов нейронной сетью, в составе обучающей выборки выделим восемь обобщенных классов состояний двигателя и его регулятора:

S_1 – исправное состояние, соответствующее вектору $R = [0; 0; 0]$;

S_2 – дефект в компрессоре, соответствующий вектору $R = [1; 0; 0]$;

S_3 – дефект в турбине, соответствующий вектору $R = [0; 0; 1]$;

S_4 – дефект в камере сгорания, соответствующий вектору $R = [1; 0; 1]$;

S_5 – дефект в *f1* регулятора, соответствующий вектору $R = [1; 1; 0]$;

S_6 – дефект в *Fd* регулятора, соответствующий вектору $R = [1; 1; 1]$;

S_7 – дефект в *Fu* регулятора, соответствующий вектору $R = [0; 1; 0]$;

S_8 – дефект в *P0* регулятора, соответствующий вектору $R = [0; 1; 1]$.

Анализ литературы по диагностике и контролю ГТД [6–8, 12, 13] показывает, что появление того или иного дефекта в авиационном двигателе обычно связано с изменением геометрических размеров его проточной части, что соответственно приводит к изменению характеристик узлов двигателя и его термогазодинамических параметров. Так, уменьшение к.п.д. компрессора и его степени сжатия, как правило, связано с загрязнением, забоинами, вытяжкой, поломками, эрозиями лопаток компрессора, а также с разрушением подшипников (выкрашиванием дорожек), масляным «голоданием», деформацией статора. Уменьшение к.п.д. турбины может быть обусловлено такими дефектами, как прогар, обрыв, эрозия рабочих лопаток турбины и лопаток соплового аппарата, а также может быть вызвано дефектами подшипника, наличием стружки в масле и т. д. [12, 13].

Таблица 1

Отклонение параметров ГТД и регулятора от эталонных значений, %

<i>S</i>	<i>D</i>	<i>V</i>	<i>L</i>	<i>N1</i>	<i>P2</i>	<i>P3</i>	<i>T3</i>	<i>CL1</i>	<i>CL2</i>	<i>CL3</i>	Состояние
0,000	0,000	0,000	0,000	0,000	0,000	0,000	0,000	1	0	0	ETLON
-0,053	0,006	-0,053	0,037	0,004	0,027	0,027	0,020	1	0	0	
-0,056	0,004	-0,028	0,033	0,005	0,029	0,031	0,021	1	0	0	KPDK_3%
-0,057	0,008	-0,057	0,041	0,005	0,032	0,032	0,024	0	0	1	
-0,061	0,007	-0,051	0,036	0,006	0,033	0,033	0,025	0	0	1	KPDT_3%
-0,064	0,004	-0,064	0,057	0,004	0,035	0,035	0,024	1	0	1	
-0,069	0,004	-0,069	0,062	0,004	0,034	0,034	0,024	1	0	1	SIGKC_3%
0,016	0,003	0,016	-0,031	-0,002	-0,013	-0,013	-0,009	1	1	0	
0,020	0,002	0,020	-0,032	-0,002	-0,013	-0,013	-0,009	1	1	0	REG_f1_3%
0,009	0,000	0,009	-0,008	0,000	-0,002	-0,002	-0,001	1	1	1	
0,009	0,000	0,012	-0,009	0,000	-0,003	-0,002	-0,050	1	1	1	REG_Fd_3%
0,009	-0,001	0,009	0,008	0,000	0,001	0,001	0,001	0	1	0	
0,010	-0,001	0,010	0,006	0,000	0,001	0,001	0,001	0	1	0	REG_Fu_3%
0,001	-0,001	0,001	0,006	0,000	0,001	0,001	0,001	0	1	1	REG_P0_3%

В процессе предобработки данных, снимаемых с индивидуального ГТД и его регулятора, осуществляется их нормировка согласно (2), а также оценка репрезентативности обучающей выборки.

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

$$\tilde{y}_i = \frac{y_i - y_{i_{\min}}}{y_{i_{\max}} - y_{i_{\min}}}, \quad (2)$$

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

Как показали результаты исследований, в качестве архитектуры НС2 (рис. 12), реализующей функции классификатора состояний ГТД, целесообразно выбрать рекуррентную 3-слойную сеть типа персептрон. Количество нейронов входного слоя при этом равно $n = 8$ (по числу измеряемых параметров двигателя и его регулятора), количество нейронов выходного слоя выбирается равным $m = 3$ (по числу компонент вектора R). Здесь Δ – временная задержка, $\Delta t = 0,1$ с. Согласно этому рисунку НС должна иметь $8 \times L$ входов по L для каждого из параметров: $S, D, V, L, N_1, P_2^*, P_3^*, T_3$. Указанные L параметров представляют собой измеренные параметры авиационного ГТД и его регулятора, а также задержанные значения этих параметров. В качестве выходов НС будем считать сигналы ξ_1, ξ_2 и ξ_3 . Для обученной сети выходы должны принимать значения R_1, R_2 и R_3 .

Учитывая, что входной вектор $y(t) = \{y_1(t), y_2(t), \dots, y_N(t)\}$ для НС при решении задачи распознавания режимов ГТД соответствует набору признаков, а выходной вектор $\xi = \{\xi_1, \xi_2, \xi_3\}$, заданный бинарно, классу состояний, математическую модель персептрона можно представить в виде системы уравнений (3).

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

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

- для скрытого слоя ($l = 2$)
 $a_j^2 = f \left(\sum_{i=1}^{m_1} W_{ij}^1 a_i^1 + \eta_j \right), \quad j = 1, 2, \dots, m_2;$

- для выходного слоя ($l = 3$)
 $Z_j = f \left(\sum_{i=1}^{m_2} W_{ij}^2 a_i^2 + \chi_j \right), \quad j = 1, 2, \dots, m_3. \quad (3)$

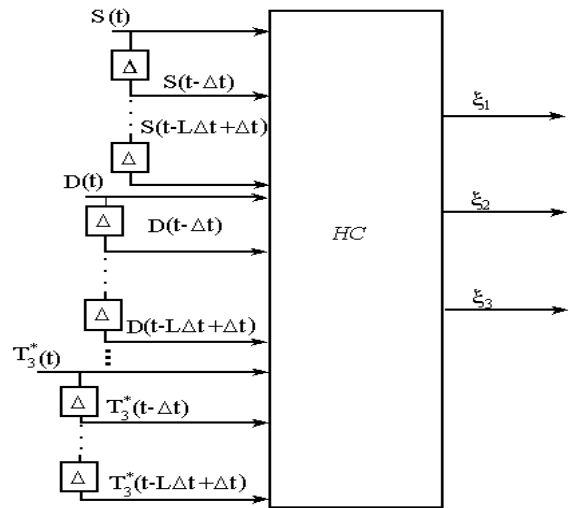


Рис. 12. Архитектура нейросетевого классификатора

Здесь m_l – число нейронов l -го слоя; η_j и χ_j – величины смещения нейронов, соответственно, скрытого и выходного слоев; $f(\bullet)$ – активационная функция нейрона. В нашем случае $m_1 = 8L$, а $m_3 = 3$. Анализ различных архитектур НС показал, что в качестве нейронной сети целесообразно принять рекуррентный трехслойный персептрон.

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

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

Перечисленные выше вопросы реализуются на следующем этапе.

Очевидно, что малый размер ширины «окна» не позволит правильно распознать техническое состояние авиационного двигателя и регулятора на переходных и неустановившихся режимах его работы, а большой размер ширины «окна» L захватит «избыточную» информацию

(соседние классы состояния), что уменьшит достоверность распознавания технического состояния ГТД и регулятора в целом. Зависимость ошибки обучения НС на выходе персептрона от размера временного окна показана на рис. 13. В данном случае в качестве функции активации применялась сигмоидная функция вида [14]:

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

число нейронов скрытого слоя принималось равным 35.

В процессе экспериментальных исследований рассматривались вопросы выбора оптимальной «ширины» временного окна для рекуррентной НС рис. 13, а также зависимость изменения ошибки обучения нейронной сети от ее сложности (количества нейронов в скрытом слое) рис. 14. Как видно из рисунка, структура нейросетевого классификатора (НС2) имеет минимальную сложность при количестве нейронов скрытого слоя, равном 75÷90. НС2 обучается за 1000÷1500 циклов с ошибкой обучения $E = 3,15 \cdot 10^{-9}$, вычисляемой по формуле:

$$E = \frac{1}{2} \sum_{r=1}^R \sum_{i=1}^n (Y_i^{(r)} - Y_{io}^{(r)})^2,$$

где $Y_i^{(r)}$ – i -й выход НС в r -м эксперименте, т. е. при предъявлении сети r -го входного образа $U^{(r)}$; $Y_{io}^{(r)}$ – i -й желаемый выход НС для входа $U^{(r)}$; R – число различных экспериментов (размерность обучающей выборки); $n = 3$. В качестве алгоритма обучения, обеспечивающего его наилучшую сходимость, использовался квазиньютоновский алгоритм (5). Аналогичные исследования проводились с целью выбора оптимального количества нейронов в скрытом слое. При этом учитывалось, что малое их количество приводит к некачественному обучению НС, а большое – к эффекту переобучения НС [14].

При обучении рекуррентного персептрона принималось значение ширины «окна» $L = 10$, что соответствует $8L = 80$ входам НС. Анализ рис. 13 – 14 показывает, что при решении задачи классификации (распознавания) технического состояния авиационного ГТД и его регулятора достаточно принимать ширину временного окна равной 8÷12, а число нейронов скрытого слоя 75÷90.

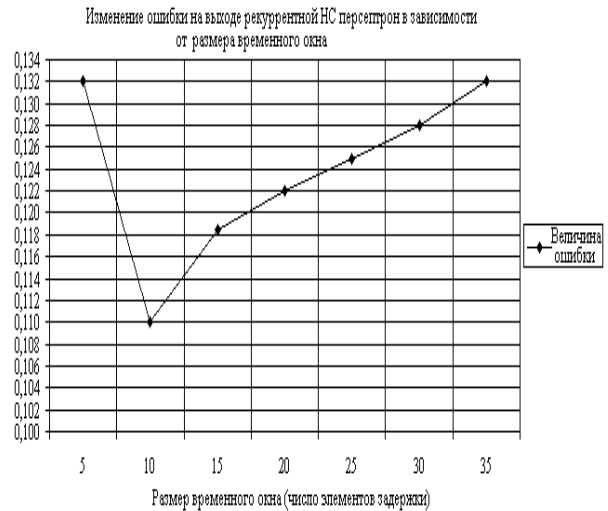


Рис. 13. Зависимость ошибки обучения НС от ширины временного окна

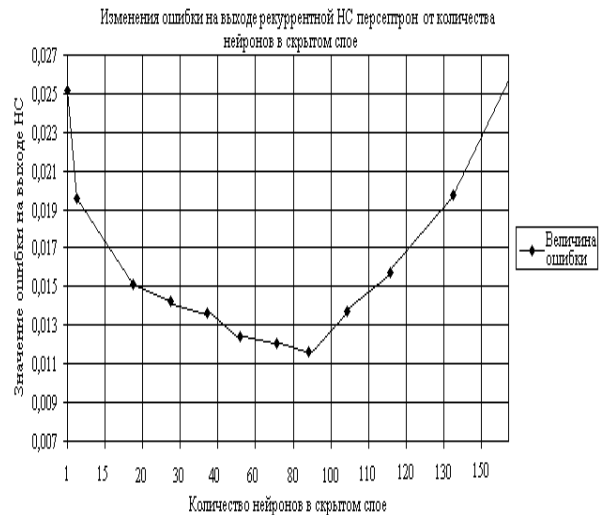


Рис. 14. Выбор оптимальной по сложности структуры рекуррентной НС

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

1. Алгоритм обратного распространения ошибки (Back Propagation)

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

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

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

где η – величина, задающая скорость сходимости;

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

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

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

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

2. Алгоритм быстрого распространения (Quick Propagation):

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

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

3. Алгоритм сопряженных градиентов (Conjugate Gradients):

$$\Delta W(t) = \eta \cdot p(t) + \alpha \cdot (W(t) - W(t-1));$$

$$p(t) = -[H(W(t))]^{-1} \cdot g(W(t));$$

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

4. Алгоритм Quasi Newton:

$$W(t+1) = W(t) + \Delta W;$$

$$\Delta W = \eta p(W).$$

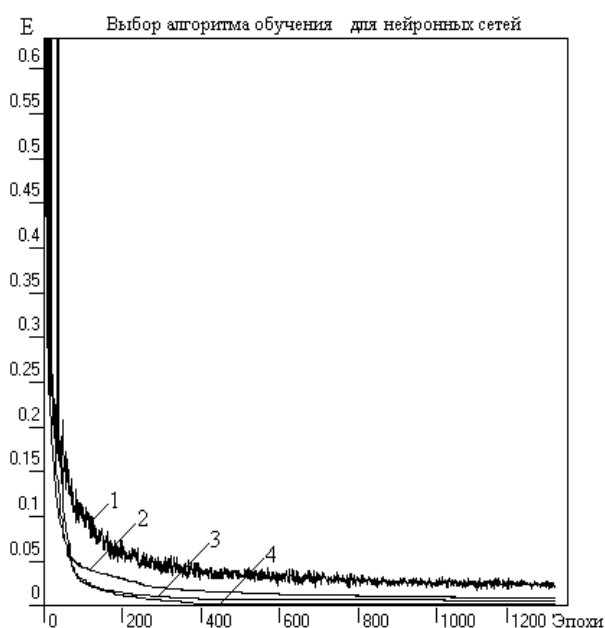


Рис. 15. Зависимость ошибки обучения НС от числа циклов: 1 – Back Propagation; 2 – Quick Propagation; 3 – Conjugate Gradients; 4 – Quasi Newton

График зависимости ошибки обучения НС от числа циклов (для различных алгоритмов обучения) приведен на рис. 15. Как видно из этого рисунка, наибольшей скоростью сходимости обладают алгоритмы (4) и (5). Требуемое число циклов обучения составляет 600÷1000.

Как уже отмечалось выше, после процесса обучения НС на интервале обучения (33% выборки), необходимо проверить эффективность ее работы на тестовой выборке, составляющей 67% объема всей выборки. Известно, что эталонные значения выходов НС принимают значения 0 или 1, а фактические сигналы на выходе НС (в силу инерционности процесса перемещения временного («окна»)) могут принимать непрерывные значения в интервале [0; 1]. Поэтому необходимо округлять вычисленные значения ξ_1 , ξ_2 и ξ_3 до ближайшего целого числа:

$$\bar{\xi}_i = \begin{cases} 0, & \text{если } \xi_i \leq 0,5; \\ 1, & \text{если } \xi_i \geq 0,5 (i = 1, 2, 3). \end{cases} \quad (6)$$

При этом могут иметь место ошибки I и II рода, т. е. отнесение состояния исправного ГТД и регулятора к классу неисправных состояний и наоборот.

Для определения достоверности классификации технического состояния авиационного двигателя и регулятора можно воспользоваться следующей формулой (7), где $K_{\text{ош}}$ – коэффициент ошибочной классификации:

$$K_{\text{ош}} = \frac{T_{\text{ош}}}{T_0} \cdot 100\%; \quad (7)$$

где $T_{\text{ош}}$ – суммарное количество состояний ГТД и регулятора, соответствующих ошибочной классификации; T_0 – величина тестовой выборки (в нашем случае 534 значения).

Результаты сравнительного анализа ошибок классификации технического состояния ГТД и регулятора для различных классов архитектур НС, а также классического метода наименьших квадратов (МНК) показывают, что рекуррентные сети наиболее эффективно и качественно осуществляют процесс распознавания технического состояния ГТД и регулятора (ошибка распознавания дефектов не превысила 1% даже в условиях аддитивной помехи); временные НС, НС Элмана и классический метод наименьших квадратов данную задачу решают с большей погрешностью, которая в ряде случаев достигает 6% и более, что в условиях бортовой реализации может негативно отразиться на процессе принятия решения о техническом состоянии авиационного двигателя и его регулятора.

Для проверки качества работы нейросетевого классификатора (НС2) необходимо провести его тестирование, т. е. предъявлять на вход сети данные, не входящие в состав обучающей выборки. В данном случае тестирование проводилось на основе данных, не вошедших в обучающую выборку и учитывающих следующие случаи:

- уменьшение КПД турбины низкого давления на 5%;
- уменьшение Fd регулятора на 5%;
- двойной дефект (одновременное уменьшение КПД компрессора низкого давления на 5% и КПД турбины низкого давления на 5%).

Результаты тестирования нейросетевого классификатора, реализованного на основе рекуррентной НС, с учетом перечисленных выше случаев, показали высокое качество диагностирования технического состояния авиационного ГТД и его регулятора.

В общем случае, процесс принятия решения о техническом состоянии ГТД и его регулятора осуществляется как и ранее на основании значений на выходе нейроклассификатора НС2 с использованием решающего правила (6), с последующим сравнением вектора $\bar{\zeta} = (\bar{\zeta}_1, \bar{\zeta}_2, \bar{\zeta}_3)^T$ с векторами эталонных состояний. Более подробно особенности реализации процесса принятия решения будут рассмотрены ниже.




Рис. 16. Графическая интерпретация процесса диагностирования технического состояния ГТД и его регулятора

Как уже отмечалось, завершающим этапом реализации FDI -метода является принятие решения о типе отказа в ГТД и его регуляторе на основе анализа числового вектора ζ . Графическая интерпретация принятия решения для рекуррентной НС персептрон и МНК показана

на рис. 16, где вершины куба соответствуют центрам кластеров (эталонных состояний ГТД и регулятора). Фактический вектор состояния двигателя S может принимать значения в любой точке внутри данного куба:

S_1 – центр кластера (прецедент), соответствующий исправному (эталонному состоянию ГТД и его регулятора);

S_2 – центр кластера, соответствующий дефекту в компрессоре;

S_3 – центр кластера, соответствующий дефекту в турбине;

S_4 – центр кластера, соответствующий дефекту в камере сгорания;

S_5 – центр кластера, соответствующий дефекту в fI регулятора;

S_6 – центр кластера, соответствующий дефекту в Fd регулятора;

S_7 – центр кластера, соответствующий дефекту в Fu регулятора;

S_8 – центр кластера, соответствующий дефекту в $P0$ регулятора.

Определение технического состояния ГТД осуществляются по правилу «ближайшего соседа» [15, 16], 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:

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

где d – расстояние до центра ближайшего (p -го) кластера (прецедента).

При этом расстояние d вычисляется, например, с использованием евклидовой метрики:

$$d = \sqrt{\sum_{i=1}^n (y_i - y_i^{эТ})^2}, \quad (8)$$

где y_i – измеренное значение i -го параметра ГТД; $y_i^{эТ}$ – эталонное значение этого параметра, вычисленное с помощью НС.

Рассмотрим данную процедуру на примере задачи диагностирования двойного дефекта, связанного с уменьшением КПД компрессора и турбины низкого давления на 5%. Величина вектора на выходе НС2 персептрон в данном случае равна $R = (0,54; 0,02; 0,484)^T$. Тогда, учитывая эталонные состояния $S_1 \div S_8$ авиационного двигателя и используя формулу (8), можно вычислить расстояние d от соответствующего прецедента до центров кластеров:

$$d(S, S_1) = 0,725; \quad d(S, S_5) = 1,186;$$

$$d(S, S_2) = 0,668; \quad d(S, S_6) = 1,199;$$

$$d(S, S_3) = 0,692; \quad d(S, S_7) = 1,232;$$

$$d(S, S_4) = 0,747; \quad d(S, S_8) = 1,219.$$

Анализ полученных значений $d(S, S_i)$ показывает, что результатом решения данной задачи будет: $S \in S_2 \cup S_3$, т. е. предъявляемый нейронной сети прецедент примерно равноудален от следующих состояний: дефект в компрессоре (S_2) и дефект в турбине (S_3). Таким образом, диагноз сети – «умеренный» по интенсивности дефект в двух узлах авиационного двигателя (компрессоре и турбине низкого давления).

ВЫВОДЫ

На основании приведенных выше результатов, можно сформулировать следующие выводы:

1. Решение задачи классификации технического состояния авиационного двигателя и его регулятора в нейросетевом базисе позволяет более эффективно и качественно решить данную задачу.

2. Решение задачи сводится к использованию рекуррентной НС, где входами ее являются текущие и задержанные параметры, причем оптимальный размер временного окна выбирается $8 \div 12$, а количество нейронов в скрытом слое $75 \div 90$.

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

4. Анализ качества классификации технического состояния авиационного ГТД и его регулятора с помощью рекуррентной нейронной сети в рассматриваемом примере не превысил 1% на тестовой выборке.

5. Нейросетевые технологии можно эффективно применять для решения задач диагностирования технического состояния авиационного ГТД и его регулятора. Они позволяют работать как с реальными данными, полученными для индивидуального и эталонного (среднестатистического) авиационного двигателя и регулятора, 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.

6. В отличие от классических методов диагностирования, основанных на расчете термодинамических параметров ГТД с помощью нелинейных поэлементных моделей двигателя, реализация нейросетевого метода диагностиро-

вания базируется на обучении нейронной сети по данным малой обучающей выборки, с проверкой качества полученной нейросетевой модели на специальном образом организованной тестовой выборке.

7. Проведенный сравнительный анализ показал возможность решения поставленных задач диагностирования состояния ГТД и регулятора с помощью различных архитектур нейронных сетей (рекуррентных, временных и НС Элмана), а также метода наименьших квадратов, обеспечивающих высокую достоверность распознавания дефектов, включая двойные дефекты, в различных узлах авиационного двигателя.

8. Проверка эффективности работы нейронных сетей в условиях аддитивной (случайной) помехи показала сохранение высокого качества диагностирования ГТД и его регулятора, т. е. робастность этого метода по отношению к искажению входных данных.

9. Принятие решений о месте и характере дефекта в реальном ГТД и его регуляторе может производиться на основе сравнения выхода нейроклассификатора, построенного на базе рекуррентного персептрона, 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. **Бурков В. Н., Новиков Д. А.** Теория активных систем: состояние и перспективы. М.: СИНТЕГ, 1999. 127 с.
2. **Новиков Д. А., Петраков С. Н.** Курс теории активных систем. М.: СИНТЕГ, 1999. 105 с.
3. **Попов Э. В., Фомин И. Б., Шапот М. Д.** Статические и динамические экспертные системы. М.: Финансы и статистика, 1996. 315 с.
4. **Васильев В. И., Ильясов Б. Г.** Интеллектуальные системы. Теория и практика. М.: Радиотехника, 2009. 392 с.
5. **Боев Б. В., Бугровский В. В.** Идентификация и диагностика в информационно-управляющих системах авиакосмической энергетики. М.: Наука, 1988. 325 с.
6. **Кеба И. В.** Диагностика авиационных газотурбинных двигателей. М.: Транспорт, 1980. 356 с.
7. **Кусимов С. Т., Васильев В. И., Ильясов Б. Г.** Управление динамическими системами в условиях неопределенности. М.: Наука, 1998. 625 с.
8. **Кусимов С. Т., Васильев В. И., Ильясов Б. Г.** Проблемы проектирования и развития сис-

тем автоматического управления и контроля ГТД. М.: Машиностроение, 1999. 685 с.

9. **Черняховская Л. Р., Старцева Е. Б., Максимов П. В.** Поддержка принятия решений при стратегическом управлении предприятием на основе инженерии знаний. Уфа: Гилем, 2010. 128 с.

10. **Галушкин А. И.** Теория нейронных сетей. М.: ИПРЖР, 2000. 416 с.

11. **Рутковская Д., Рутковский Л.** Нейронные сети, генетические алгоритмы и нечеткие системы. М.: Горячая линия, 2008. 355 с.

12. **Ярушкина Н. Г.** Основы теории нечетких и гибридных систем. М.: Финансы и статистика, 2007. 347 с.

13. **Ясницкий Л. Н.** Введение в искусственный интеллект. М.: Академия, 2010. 176 с.

14. **Бывайков М. Е.** Алгоритм обнаружения изменения вида модели при текущем оценивании // Автоматика и телемеханика. 1993. № 5. С. 82–93.

15. **Жернаков С. В.** Контроль и диагностика комплексных отказов САУ ГТД с использованием рекуррентных нейронных сетей // Авиакосмическое приборостроение. 2009. № 2. С. 33-49.

16. **Жернаков С. В.** Идентификация характеристик ГТД на основе технологии нейронных сетей // Информационные технологии. 2010. № 3. С. 39–47.

ОБ АВТОРАХ

Жернаков Сергей Владимирович, зав. каф. информац.-измерительн. техники и технологий. Дипл. инженер по промышленной электронике (УГАТУ, 1984). Д-р техн. наук по системному анализу, управлению и обработке информации (УГАТУ, 2005). Иссл. в обл. интеллектуальных систем.

Кобылев Сергей Вадимович, асп. каф. вычислительн. техники и защиты информации. Дипл. инженер по вычислительн. машинам, комплексам и сетям (УГАТУ, 2010). Готовит диссертацию в области контроля и диагностики бортовых систем авиационных двигателей.