

УДК 629.7.036.3

А. С. ГИШВАРОВ, В. С. ГАБДУЛЛИН, А. В. НЕСТЕРОВ

**ДИАГНОСТИКА СОСТОЯНИЯ АВИАЦИОННЫХ ГТД
С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ**

На данный момент в области авиадвигателестроения актуальным является создание единой методологии разработки алгоритмов конструирования и обучения различного вида нейронных сетей применительно к решению задач по диагностике состояния авиационных ГТД и сравнение эффективности нейросетевого метода с существующими методами параметрической диагностики. *Нейронные сети ; параметрическая диагностика*

В настоящее время нейросетевая технология является одной из наиболее динамично развивающихся областей искусственного интеллекта. Она успешно применяется в различных областях науки и техники, таких как распознавание образов, системы диагностики сложных технических объектов, экология и наука об окружающей среде (прогнозы погоды и различных катаклизмов), построение математических моделей, описывающих климатические характеристики, биомедицинские приложения и др. Применительно к области авиадвигателестроения актуальным является создание единой методологии разработки алгоритмов конструирования и обучения различного вида нейронных сетей для решения задач по параметрической диагностике состояния двигателей, включая: разработку алгоритмов и программного обеспечения нейросетевого метода параметрического диагностирования, обеспечивающего более высокую по сравнению с существующими методами вероятность выявления дефектов газотурбинных двигателей; проверку эффективности нейросетевого метода на примере конкретных авиационных ГТД; выявление архитектур нейронных сетей наиболее эффективных для параметрической диагностики состояния ГТД.

Известно, что среди неисправностей и отказов ГТД значительную часть составляют параметрические, заключающиеся в несоответствии значений контролируемых на двигателе параметров нормам технических условий. Для контроля и предотвращения подобных отказов используются параметрические методы диагностирования, базирующиеся на специальной обработке и анализе значений термогазодинами-

ческих и других параметров, измеряемых на работающем двигателе.

Оценка технического состояния двигателей как летного, так и наземного применения, в условиях эксплуатации проводится, как правило, по ограниченному объему информации, обусловленному малым количеством штатных контролируемых параметров. Это существенно ограничивает эффективность параметрических методов диагностики, основанных на идентификации математических моделей рабочих процессов двигателей. Поэтому актуальным является проведение исследований по повышению эффективности методов диагностики, включая метод нейронных сетей [3, 4].

В настоящее время известны несколько методов параметрической диагностики состояния двигателей, которые условно можно разделить на методы А, Б, В, Г и Д [1]:

А – метод диагностических матриц;

Б – метод, основанный на решении системы нормальных уравнений;

В – метод, основанный на нелинейной оптимизации критерия, характеризующего состояние двигателя;

Г – метод уравнивания по квадратной целевой функции;

Д – метод уравнивания по модульной целевой функции.

1. Диагностика методом диагностических матриц. Диагностические матрицы представляют собой таблицы, в которых изменения диагностических параметров состояния элементов газоздушного тракта двигателя (КПД компрессора и турбины, площади характерных проходных сечений, коэффициенты потерь давления и др.) представлены в виде функций от из-

менения контролируемых параметров (расход топлива, температура газа и др.).

В данном случае задача формулируется следующим образом: при контроле ряда параметров двигателя обнаружены отклонения параметров от их значений, измеренных в тех же условиях и на том же режиме, когда двигатель был заведомо исправен; зафиксированные отклонения свидетельствуют о возникновении одной или нескольких неисправностей в проточной части двигателя; требуется определить, в каком именно узле (узлах) двигателя появилась неисправность.

Для локализации неисправности необходимо, используя обнаруженные отклонения контролируемых параметров, определить с помощью диагностических матриц двигателя изменение параметров состояния его узлов.

Формирование диагностической матрицы проводится аналитической или численной линеаризацией математической модели рабочих процессов двигателя, представляющей собой систему трансцендентных уравнений.

2. Диагностика методом, основанном на решении системы нормальных уравнений. В данном случае диагностика проводится за счет уточнения параметров состояния двигателя решением системы нормальных уравнений, формируемых из условия минимума суммарной квадратичной «невязки» между значениями контролируемых параметров и их расчетными значениями, определенными по модели:

$$\Phi = \min \left\{ \sum_{j=1}^m b_j \frac{1}{p_j^3(\mathbf{X})} [p_j^p(\mathbf{X}) - p_j^3(\mathbf{X})]^2 \right\} \quad (1)$$

$$\frac{\partial}{\partial x_i} \left[\sum_{j=1}^m \frac{[p_j^p(\mathbf{X}) - p_j^3(\mathbf{X})]^2}{p_j^3(\mathbf{X})} \right] = 0,$$

где b_j – коэффициент, учитывающий погрешность контроля параметра P_j ($b_j = T/\sigma$, T – константа; σ_j – среднеквадратичное отклонение погрешности контроля параметра p_j^3); p_j^p – расчетное значение параметра p_j , определенное по модели; p_j^3 – замеренное при контроле значение параметра p_j ; $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$ – вектор параметров состояния; m – число контролируемых параметров.

В матричном виде решение определяется исходя из соотношения:

$$(\mathbf{C}^T \cdot \mathbf{B} \cdot \mathbf{C}) \cdot \mathbf{X} = \mathbf{C}^T \cdot \mathbf{B} \cdot \mathbf{P}^3, \quad (2)$$

откуда

$$\mathbf{X} = (\mathbf{C}^T \cdot \mathbf{B} \cdot \mathbf{C})^{-1} \cdot (\mathbf{C}^T \cdot \mathbf{B} \cdot \mathbf{P}^3),$$

где \mathbf{C} – матрица коэффициентов линеаризованной модели двигателя; \mathbf{B} – матрица коэффициентов, учитывающих погрешности контроля параметров; \mathbf{X} – вектор поправок к параметрам состояния узлов двигателя; \mathbf{P}^3 – вектор-столбец замеренных параметров.

3. Диагностика методом нелинейной оптимизации критерия, характеризующего состояние двигателя. В данном случае экстремум функционала (1) определяется методом нелинейной оптимизации в области параметров состояния, задаваемой системой двусторонних ограничений:

$$\min x_i \leq x_i \leq \max x_i; \quad i = \overline{1, n}, \quad (3)$$

где $\min x_i$, $\max x_i$ – соответственно нижняя и верхняя границы параметров состояния двигателя.

4. Диагностика методом уравнивания по квадратичной целевой функции. Метод уравнивания основан на детерминированной связи контролируемых параметров двигателя между собой. Наличие такой связи является одним из условий определения параметров состояния. Для двигателя в качестве такой взаимосвязи выступают уравнения рабочих процессов. Диагностика проводится минимизацией квадратичной целевой функции вида:

$$\Phi = \min \left\{ \sum_{j=1}^m \gamma_j \frac{1}{p_j^3} (p_j^p(\mathbf{X}) - p_j^3(\mathbf{X}))^2 + \sum_{i=1}^n \gamma_i \frac{1}{x_i^o} (x_i - x_i^o)^2 \right\}. \quad (4)$$

Минимум данной функции определяется при выполнении системы равенств:

$$p_j^p(\mathbf{X}) + \Delta_{jp} = p_j^3(\mathbf{X}) + \Delta_{j3}, \quad (5)$$

где $p_j^p(\mathbf{X})$ – оценка j -го контролируемого параметра по модели; $p_j^3(\mathbf{X})$ – измеренное при контроле значение параметра p_j ; \mathbf{X} – вектор параметров состояния; x_i – оценка i -го параметра состояния; x_i^o – исходное значение i -го параметра состояния; γ_j, γ_i – соответственно статистические веса величин p_j^3 и x_i ; Δ_{jp}, Δ_{j3} – соответственно суммарные погрешности определения $p_j^p(\mathbf{X})$ и $p_j^3(\mathbf{X})$.

В случае когда ошибки измерения и ошибки определения параметров модели распределены по нормальному закону, то условие обеспечения минимума суммы квадратов поправок к пара-

метрам p_j^3 и x_i^o фактически отвечает принципу максимального правдоподобия. Оптимальность квадратичной формы функции цели, кроме того, еще тесно связана и с точностью задания характеристик этих законов. Нарушение нормальности распределения погрешностей и отсутствие точных характеристик законов распределения приводит к получению оценок, отличающихся от истинных значений.

5. Диагностика методом уравнивания по модульной целевой функции. Диагностика проводится при наличии аномальных результатов измерений и ошибок в задании характеристик их распределения, минимизацией по модульной целевой функции:

$$\Phi = \min \left\{ \sum_{j=1}^m \gamma_j \frac{1}{p_j^3(\mathbf{X})} \left| p_j^p(\mathbf{X}) - p_j^3(\mathbf{X}) \right| + \sum_{i=1}^n \gamma_i \frac{1}{x_i^o} \left| x_i - x_i^o \right| \right\}; \quad (6)$$

$$p_j^p(\mathbf{X}) + \Delta_{jp} = p_j^3(\mathbf{X}) + \Delta_{j3}.$$

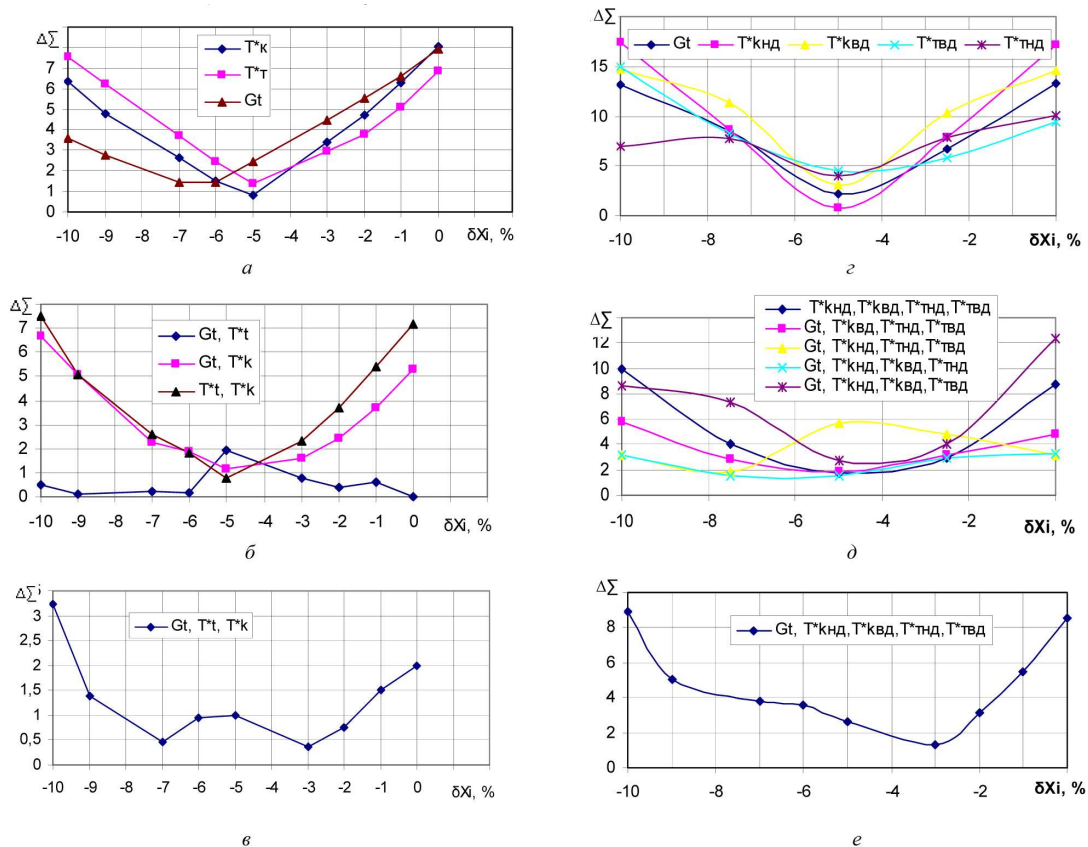


Рис. 1. Эффективность работы НС по распознаванию дефектов одновального (а, б, в) и двухвального двухконтурного (г, д, е) ГТД: T_k – температура воздуха за компрессорами; T_t – температура газ за турбиной; G_t – расход топлива; $T_{кнд}, T_{квд}$ – температура за компрессором низкого и высокого давлений; $T_{тнд}, T_{твд}$ – температура газа за турбиной низкого и высокого давлений; а, г – диагностика по значению одного контролируемого параметра; б, в, д, е – диагностика по соответственно значениям двух, трех, четырех и пяти контролируемых параметров

Очевидно, что оценка возможности применения метода нейронных сетей [2, 3, 4] должна проводится сравнением данного метода с перечисленными методами А, Б, В, Г и Д.

Эффективность работы метода нейронных сетей (НС) проверялась на примере одновального ГТД с отбором воздуха за компрессором и программой регулирования $n = idem$ и двухвального двухконтурного двигателя. В первом случае обучение проводилось по выборке, которая включала 216 возможных состояний двигателя. Во втором случае обучение проводилось по выборке, включающей 3125 возможных состояний двигателя.

Эффективность распознавания оценивалась суммарной «невязкой» по параметрам состояния узлов двигателя:

$$\Delta\Sigma = \sum_{i=1}^m \delta x_i = |\delta x_1| + |\delta x_2| + \dots + |\delta x_m|. \quad (7)$$

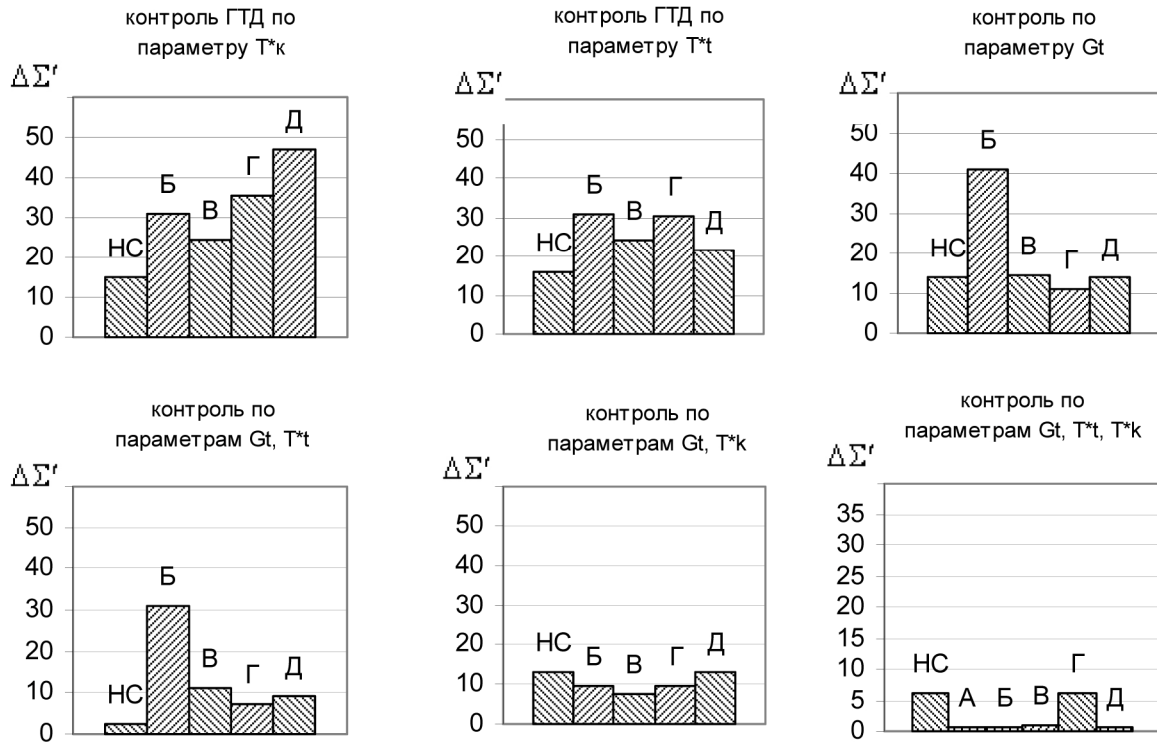


Рис. 2. Сравнительная оценка эффективности метода диагностики состояния НС и методов А, Б, В, Г и Д (для одновального двигателя)

Здесь $\delta x_i = x_i^* - x_i$; δx_1 – отклонение состояния (величина дефекта) узла компрессора ($\delta \eta_K^*$), δx_2 – отклонение состояния (величина дефекта) узла турбины ($\delta \eta_T^*$), δx_m – отклонение состояния (величина дефекта) узла камеры сгорания ($\delta \sigma_{k/c}$) и т. д.

Было установлено (рис. 1), что по мере увеличения глубины дефектов узлов δx_i в интервале обучения 0... – 10 % эффективность распознавания вначале увеличивается (значение $\Delta \Sigma$ уменьшается), достигая своего максимума (минимума значения $\Delta \Sigma$), а затем убывает.

Данную особенность зависимости $\Delta \Sigma = f(\delta x_i)$ можно использовать в практических целях, например, границы интервала обучения выбирать из условия получения наибольшей эффективности распознавания дефектного состояния двигателя (для узла компрессора двигателя это может быть граничное значение $\delta \eta_{к.лр}^*$, при котором требуется промывка двигателя и т. д).

В качестве примера в таблице приведены результаты оценки эффективности методов диагностики состояния двухвального двухконтурного двигателя (в столбце «КП» приведены сочетания параметров состояния: 1 – расход топ-

лива, Gt ; 2 – температура воздуха за компрессором низкого давления, $T_{кнд}^*$; 3 – температура воздуха за компрессором высокого давления, $T_{квд}^*$; 4 – температура газа за турбиной низкого давления, $T_{тнд}^*$, 5 – температура газа за турбиной высокого давления, $T_{твд}^*$).

Исследование показало, что наиболее приемлемы для распознавания состояния ГТД:

- линейная сеть (Linear);
- многослойный перцептрон (MLP);
- нейронная сеть типа радиальной базисной функции (RBF);
- обобщенно-регрессионная нейронная сеть (GRNN).

Сеть Linear является самой простой моделью, в которой подгоночная функция определяется гиперплоскостью. В задаче классификации гиперплоскость размещается таким образом, чтобы она разделяла собой два класса (линейная и дискриминантная функция); в задаче регрессии гиперплоскость должна проходить через заданные точки. Линейная модель представляется сетью без промежуточных слоев, которая в выходном слое содержит только линейные элементы (т. е. элементы с линейной функцией активизации).

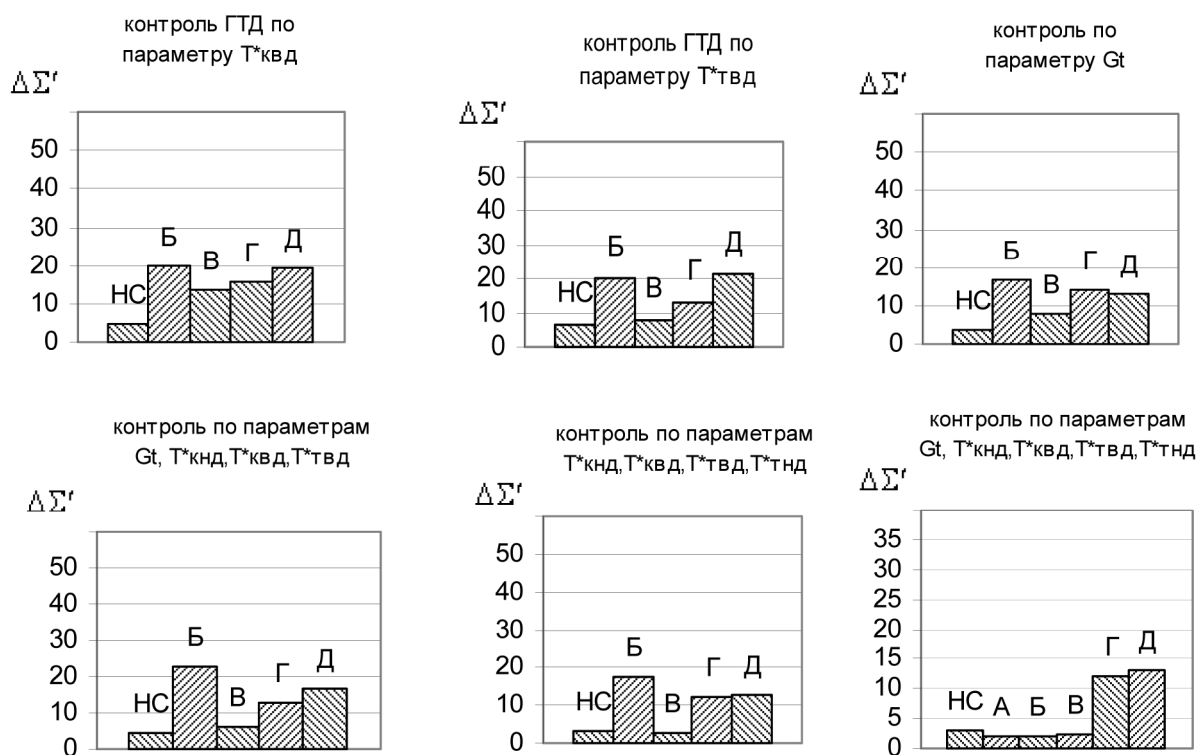


Рис. 3. Сравнительная оценка эффективности методов диагностики состояния НС и методов А, Б, В, Г и Д (для двухвального двухконтурного двигателя)

В сети MLP каждый элемент сети строит взвешенную сумму своих входов с поправкой в виде слагаемого, затем пропускает эту величину активации через передаточную функцию, и таким образом получается выходное значение этого элемента. Элементы организованы в полойную топологию с прямой передачей сигнала. Такая сеть интерпретируется как модель вход-выход, в которой свободными параметрами являются веса и пороговые значения (смещения). Сети подобной структуры моделируют функцию практически любой сложности.

Сеть типа RBF имеет промежуточный слой из радиальных элементов, каждый из которых воспроизводит гауссову поверхность отклика. Сети RBF имеют ряд преимуществ перед сетями MLP. Во-первых, они моделируют произвольную нелинейную функцию с помощью всего одного промежуточного слоя и тем самым избавляют от необходимости решать вопрос о числе слоев. Во-вторых, параметры линейной комбинации в выходном слое можно полностью оптимизировать с помощью хорошо известных методов линейного моделирования, которые работают быстро и не испытывают трудности с локальными

минимумами, так мешающими при обучении многослойного персептрона. Поэтому сети RBF обучаются очень быстро (на порядок быстрее многослойного персептрона).

В сети GRNN в точку расположения каждого обучающего наблюдения помещается гауссовская ядерная функция. GRNN-сеть копирует внутрь себя все обучающие наблюдения и использует их для оценки отклика в произвольной точке. Окончательная выходная оценка сети получается как средне взвешенная выходов по всем обучающим наблюдениям, где величина весов отражают расстояние от этих наблюдений до той точки, в которой проводится оценивание (и таким образом, более близкие точки вносят больший вклад в оценку).

При оценке состояния ГТД по одному контролируемому параметру более эффективны сети MLP и Linear; по двум параметрам – сети Linear и RBF; по трем параметрам – сети Linear и GRNN.

| КП | НС | А | Б | В | Г | Д | Оптимальный вид НС модели |
|-----------|---------|-------|--------|-------|-------|-------|---------------------------|
| 1,2,3,4,5 | 2,99127 | 1,950 | 1,9497 | 2,425 | 11,97 | 12,97 | Linear, GRNN |
| 1,3,4,5 | 3,66219 | – | 22,82 | 9,105 | 12,02 | 16,39 | GRNN, GRNN |
| 2,3,4,5 | 3,33128 | – | 17,476 | 2,731 | 11,99 | 12,66 | Linear, GRNN |
| 3,4,5 | 3,1287 | – | 19,82 | 12,75 | 11,94 | 20,32 | GRNN, GRNN |
| 1,4,5 | 7,18009 | – | 19,91 | 19,53 | 12,07 | 19,14 | RBF, RBF |
| 2,4,5 | 6,0977 | – | 16,82 | 5,38 | 12,09 | 19,46 | GRNN, Linear |
| 1,2,4,5 | 5,56507 | – | 10,67 | 17,78 | 12,04 | 14,31 | GRNN, GRNN |
| 4,5 | 9,13681 | – | 16,82 | 12,51 | 12,01 | 19,51 | RBF, RBF |
| 1,3,5 | 3,31004 | – | 19,82 | 8,701 | 12,05 | 13,39 | RBF, RBF |
| 2,3,5 | 2,49714 | – | 19,91 | 10,72 | 12,07 | 13,92 | GRNN, GRNN |
| 1,2,3,5 | 2,58191 | – | 20,865 | 7,31 | 11,98 | 13,12 | GRNN, GRNN |
| 3,5 | 3,25405 | – | 16,82 | 17,26 | 12,07 | 13,97 | GRNN, GRNN |
| 1,5 | 3,57203 | – | 19,82 | 17 | 12,09 | 18,56 | RBF, RBF |
| 2,5 | 6,81419 | – | 16,91 | 9,938 | 12,16 | 21,42 | GRNN, GRNN |
| 1,2,5 | 5,72964 | – | 19,82 | 11,13 | 12,06 | 19,47 | GRNN, GRNN |
| 5 | 5,40735 | – | 19,82 | 17,04 | 12,1 | 21,31 | GRNN, GRNN |
| 1,3,4 | 4,02097 | – | 22,82 | 11,04 | 12,57 | 12,43 | RBF, RBF |
| 2,3,4 | 3,10292 | – | 19,91 | 8,421 | 12,72 | 13,25 | RBF, RBF |
| 1,2,3,4 | 4,42893 | – | 22,82 | 6,135 | 12,54 | 16,54 | GRNN, GRNN |
| 3,4 | 2,51797 | – | 16,91 | 12,4 | 12,76 | 12,44 | RBF, RBF |
| 1,4 | 6,39405 | – | 19,82 | 24,33 | 12,62 | 21,45 | RBF, RBF |
| 2,4 | 3,57721 | – | 22,82 | 20,23 | 12,77 | 19,08 | GRNN, GRNN |
| 1,2,4 | 3,18521 | – | 19,82 | 7,444 | 12,6 | 13,36 | GRNN, GRNN |
| 4 | 6,13273 | – | 19,91 | 7,647 | 12,82 | 21,16 | RBF, RBF |
| 1,3 | 4,85953 | – | 22,82 | 11,62 | 13,54 | 12,51 | RBF, RBF |
| 2,3 | 4,33176 | – | 19,91 | 17,86 | 14,72 | 13,24 | RBF, RBF |
| 1,2,3 | 4,46666 | – | 22,91 | 4,129 | 13,55 | 19,6 | GRNN, GRNN |
| 3 | 4,56321 | – | 19,91 | 13,76 | 15,56 | 19,54 | GRNN, GRNN |
| 1 | 3,66439 | – | 16,82 | 7,907 | 13,92 | 13 | RBF, RBF |
| 2 | 2,2845 | – | 19,82 | 9,559 | 17,43 | 21,79 | Linear, RBF |
| 1,2 | 2,99679 | – | 19,82 | 9,035 | 13,76 | 19,32 | GRNN, GRNN |

В сети MLP каждый элемент сети строит взвешенную сумму своих входов с поправкой в виде слагаемого, затем пропускает эту величину активации через передаточную функцию, и таким образом получается выходное значение этого элемента. Элементы организованы в послойную топологию с прямой передачей сигнала. Такая сеть интерпретируется как модель вход-выход, в которой свободными параметрами являются веса и пороговые значения (сме-

щения). Сети подобной структуры моделируют функцию практически любой сложности.

Сеть типа RBF имеет промежуточный слой из радиальных элементов, каждый из которых воспроизводит гауссову поверхность отклика. Сети RBF имеют ряд преимуществ перед сетями MLP. Во-первых, они моделируют произвольную нелинейную функцию с помощью всего одного промежуточного слоя и тем самым избавляют от необходимости решать вопрос о числе слоев. Во-вторых, параметры линейной

комбинации в выходном слое можно полностью оптимизировать с помощью хорошо известных методов линейного моделирования, которые работают быстро и не испытывают трудности с локальными минимумами, так мешающими при обучении многослойного персептрона. Поэтому сети RBF обучаются очень быстро (на порядок быстрее многослойного персептрона).

В сети GRNN в точку расположения каждого обучающего наблюдения помещается гауссовская ядерная функция. GRNN-сеть копирует внутрь себя все обучающие наблюдения и использует их для оценки отклика в произвольной точке. Окончательная выходная оценка сети получается как средневзвешенная выходов по всем обучающим наблюдениям, где величина весов отражают расстояние от этих наблюдений до той точки, в которой проводится оценивание (и таким образом, более близкие точки вносят больший вклад в оценку).

При оценке состояния ГТД по одному контролируемому параметру более эффективны сети MLP и Linear; по двум параметрам – сети Linear и RBF; по трем параметрам – сети Linear и GRNN.

Результаты сравнения эффективности нейросетевого подхода с методами А, Б, В, Г и Д показывают (рис. 2, 3), что преимущество НС перед другими методами возрастает по мере уменьшения информации о контролируемых параметрах двигателя.

Поскольку в различных ситуациях эффективность рассмотренных методов диагностики состояния ГТД различна, то очевидно, что оптимальным является комбинированный метод.

СПИСОК ЛИТЕРАТУРЫ

1. **Ахмедзянов, А. М.** Диагностика состояния ВРД по термогазодинамическим параметрам / А. М. Ахмедзянов, Н. Г. Дубравский, А. П. Тунаков. М. : Машиностроение, 1983. 206 с.
2. **Гишваров, А. С.** Повышение эффективности параметрического диагностирования состояния авиационных ГТД с применением нейронных сетей / А. С. Гишваров, В. С. Габдуллин. Казань, 2008.
3. **Хайкин, С.** Нейронные сети : полный курс / С. Хайкин. М. : Изд. дом «Вильямс», 2006. 1104 с.
4. **Калан, Р.** Основные концепции нейронных сетей / Р. Калан. 2001.

ОБ АВТОРАХ



Гишваров Анас Саидович, проф., зав. каф. авиац. двигателей. Дипл. инж.-мех. по авиац. двигателям (УАИ, 1973). Д-р техн. наук по тепловым двигателям ЛА (УГАТУ, 1993). Теор. и эксперим. иссл. в обл. надежности, ресурса и испытаний техн. систем.



Габдуллин Владислав Салаватович, аспирант каф. авиац. двигателей. Дипл. инж.-мех. по авиац. двигателям (УГАТУ, 2005). Иссл. в обл. надежности и диагностики авиац. ГТД.



Нестеров Андрей Викторович, дипл. инж.-мех. по авиац. двигателям (УГАТУ, 2008). Иссл. в обл. надежности, ресурса и диагностики авиац. ГТД.