

УДК 681.51

А.Г. КОНЦЕВИЧ¹, С.В. ЕПИФАНОВ²¹ГП НПКГ «Зоря»-«Машпроект», Николаев, Украина²Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», Украина

УЧЕТ ФАКТОРА ВРЕМЕНИ ПРИ ИДЕНТИФИКАЦИИ МОДЕЛИ ГТД ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТЬЮ

Рассмотрены проблемы идентификации модели нормального состояния ГТД во время эксплуатации двигателя. Предложен оригинальный подход введения в модель временного фактора. Задача идентификации решена с помощью нейросетевой технологии. Приведены методики формирования нейросети, обучающих шаблонов, результаты идентификации модели ГТД.

идентификация модели нормального состояния, временной фактор, время, искусственная нейронная сеть, подготовка данных, обучающие шаблоны, нормализация данных

Введение

Идентификация модели нормального состояния газотурбинного двигателя в условиях эксплуатации является сложной технологической задачей. Данный вопрос, неоднократно решенный с применением различных математических аппаратов, и имеющий многочисленные формализованные и методологически обоснованные решения, легко реализуемый для модельных данных, значительно усложняется в реальных эксплуатационных условиях.

Данный факт связан с тем, что на параметры проточной части газотурбинного двигателя влияет множество рабочих факторов и внешних условий: температура и давление воздуха на входе в ГТД, влажность воздуха, теплотворная способность топлива (может периодически изменяться, например, на газоперекачивающей станции), режима работы двигателя и всей установки в целом (нагнетатель, генератор, винт изменяемого шага и пр.). В процессе эксплуатации все эти параметры изменяются в очень широком диапазоне значений. Для построения работоспособной модели в алгоритм идентификации необходимо ввести данные, собранные в широком диапазоне значений параметров внешних условий и режима.

Испытание двигателя, а тем более серийного, на

климатическом стенде - очень сложная и дорогостоящая задача. Поэтому зафиксировать значения параметров газового тракта при изменении климатических условий, особенно температуры наружного воздуха, в рабочем диапазоне значений можно только в разные времена года. Сбор информации при различных значениях режимных параметров тоже представляет собой сложную задачу. Это связано с тем, что наземные газотурбинные установки в основном работают на расчетных режимах, близких к номинальному. Однако допусковый контроль двигателя необходимо производить во всем диапазоне рабочих характеристик и внешних условий. Поэтому сбор соответствующей информации, необходимой для идентификации, может продолжаться до 6 и более месяцев, что для двигателя соответствует наработке от 1000 до 2500 часов. Совершенно очевидно, что за это время двигатель подвергается естественному износу, загрязнению, его характеристики, и, следовательно, соответствующая им идентификационная модель изменяются.

Формулирование проблемы. Перечисленные выше проблемы влекут необходимость корректировки модели с течением времени, поэтому возникает проблема создания методики построения идентификационной модели и проведения допускового контроля.

Подобную методику можно было бы также применить при тренд-анализе параметров ГТД, который широко используется в автоматизированных средствах диагностирования и является эффективным средством раннего обнаружения неисправностей.

Во многих случаях данный анализ ограничивается графическим представлением параметрической информации об объекте; заключение о наличии или отсутствии тренда формирует эксперт. Широкое использование алгоритмических методов сдерживается отсутствием рекомендаций по их выбору для различных условий применения, которые, в частности, определяются характером и интенсивностью тренда, необходимостью его выявления на фоне естественного изменения анализируемых параметров по времени наработки и скачкообразного смещения значений параметров при соответствующих эксплуатационных воздействиях, периодичностью наблюдений и параметрами распределения случайных погрешностей измерений [1].

Известно, что параметры ГТД существенно изменяются в процессе наработки вследствие постепенного ухудшения характеристик проточной части (изнашивания, изменения зазоров и т. п.). Это изменение присуще всем двигателям и поэтому в различных работах называется нормальным или естественным старением.

Очевидно, вследствие этого изменения, применение обычных методов тренд-анализа, которые по сути являются проверкой стационарности случайного процесса результатов регистрации параметров ГТД, к обработке результатов регистрации параметров ГТД может привести к появлению сигналов о наличии тренда. Однако эти сигналы свидетельствуют не об изменении в характеристиках процесса относительно исходных, а о том, что характеристики исходного процесса (результаты регистрации параметров исправного двигателя), не являются постоянными.

Поэтому для учета естественного изменения параметров двигателя по наработке применяются мо-

дифицированные методы: в [1], например, применяется модифицированный S-критерий для обработки результатов регистрации параметров ГТД. Тем не менее в существующей литературе данный вопрос малоисследован и проработан явно недостаточно.

1. Решение проблемы. Построение идентификационной модели

Для решения поставленной задачи построения математической модели исходного процесса или модели нормального состояния ГТД с учетом естественного изменения параметров двигателя по наработке. Необходимо ввести время как влияющий фактор в состав аргументов модели.

В качестве математического аппарата для создания модели будем использовать искусственные нейронные сети (ИНС). Для построения ИНС не важен физический смысл входных и выходных параметров, она «пытается» аппроксимировать функциональную связь между входом и выходом, если она есть. Для обучения ИНС необходима лишь обучающая выборка в виде экспериментальных пар «вход»-«выход».

В отличие от идентификации, рассмотренной в [2], решение данной задачи требует дополнительного внесения наработки, соответствующей времени регистрации параметров, в обучающие шаблоны данных. Тогда задача ИНС – найти функциональную зависимость между набором входных векторов \vec{Y}_i и соответствующих им выходным, где $i = \overline{1, n}$; n – количество обучающих шаблонов, где Y – вектор контролируемых параметров (давления, температуры, обороты, расход топлива и т.д.); R – параметры режима (π_k, n_2, p_2); Θ – внешние условия (барометрическое давление, температура, влажность).

1.1. Замечания относительно подготовки данных для идентификации модели ГТД с помощью ИНС. Для решения поставленной задачи, как и в [2], был выбран многослойный пересептрон с одним скрытым слоем. Проблема выбора архитектуры сети обсуждалась ранее в [2]. Однако необходимо обра-

тратить внимание на выбор активационной функции и нормализации экспериментальных данных для обучения. В абсолютном большинстве литературных источников авторы советуют приводить данные к диапазону $[0; 1]$. Однако такой подход резко снижает точность, зачастую приводит к некорректной работе сети и совершенно лишает ее способности к экстраполяции функциональной зависимости за пределы области исходных данных измерений параметров. Данный факт обусловлен следующим обстоятельством.

Как упоминалось в [2], выбор активационной функции нейронов не оказывает принципиального влияния на работу ИНС. Для задач моделирования физических процессов часто используются следующие активационные функции слоев нейронов:

1) сигмоида $f_{act} = \frac{1}{1+e^{-x}}$ (рис. 1);

2) функция гиперболического тангенса

$$f_{act} = h \operatorname{tg} x = \frac{e^x - e^{-x}}{e^x + e^{-x}};$$

3) радиально-базисные функции

$$f_{акм}(x) = \frac{1}{\sqrt{2 \cdot \pi} \cdot \sigma} \cdot e^{-\frac{1}{2} \left(\frac{x - \mu}{\sigma} \right)^2};$$

4) экспоненциальная $f_{акм}(x) = e^{-\frac{1}{2} \cdot x^2}$ и др.




Рис. 1. Сигмоидальная активационная функция

Хотя выбор активационной функции нейронов не

носит принципиального характера, в литературе по ИНС не рассматривается вопрос о взаимном расположении нормированных данных, используемых для обучения ИНС, и активационной функции. В данной статье предлагается размещать активационную функцию симметрично в диапазоне входных-выходных данных. Этого можно добиться либо соответствующим нормированием параметров (как будет показано ниже), либо путем смещения активационной функции. Как будет показано в дальнейшем, такое нормирование обучающих данных (смещение активационной функции) обеспечивает существенное уменьшение ошибки аппроксимации на различных задачах по идентификации моделей ГТД и их систем.

Для сети с сигмоидальной активационной функцией входному обучающему набору данных, нормализованному к диапазону $[0; 1]$, соответствуют значения выходного набора, лежащие в диапазоне $[0,5; 0,731059]$ ($f_{act}(0) = 0,5$, $f_{act}(1) = 0,731059$). Можно увидеть, что такая же нормализация выходного обучающего набора приведет к несоответствию выходным значениям активационной функции и некорректной работе при экстраполяции. На первый взгляд это противоречит представлениям о том, что промежуточный слой или слои ИНС, а также смещение аргумента активационной функции w_0 могут смещать и масштабировать выходной диапазон в широких пределах:

$$OUT = f_{act} \left(\sum_j w_j \cdot x_j + w_0 \right),$$

где y – выход нейрона; w_j – весовые коэффициенты; x_j – входные сигналы нейрона.

Однако часть аппроксимирующей и обобщающей способностей сети будет «расходоваться» на эти преобразования. Кроме того, практика показала, что использование для входного и выходного наборов данных диапазонов $[-1; 1]$ и $[0,268941; 0,731059]$ существенно улучшает работу сети и приводит к уменьшению средней и максимальной ошибки аппроксимации в несколько раз. Такая нормализация позволяет также обойтись меньшим количеством нейронов в

скрытом слое (слоях) сети.

1.2. Формирование шаблонов для обучения ИНС и получение идентификационной модели.

Для обучения ИНС были составлены набор входных векторов $\vec{X}_i = (\text{time}, x_1, x_2, \dots, x_k)_i$ и соответствующий им набор выходных – $\vec{Y}_i = (y_1, y_2, \dots, y_m)_i$, где $k + 1$ – количество аргументов (входов нейросети); m – количество контролируемых параметров (выходов нейросети). Алгоритм обучения ИНС автоматически воспринимает структуру данных: нейросеть обучается по матрице измеренных параметров таким образом, что при подаче на ее вход векторов X на выходе она с заданной точностью выдает соответствующий вектор параметров Y .

Обучение ИНС проводилось по данным, зарегистрированным во время штатной работы двухкаскадного газотурбинного двигателя компрессорной станции. В качестве аргументов идентификационной функции были выбраны: наработка (*optime*),

частота вращения турбокомпрессора высокого давления (NHP), частота вращения силовой турбины (NPT), температура и давление наружного воздуха (T_0, P_0). Контролируемые параметры – выход ИНС: расход топлива (GT), температура воздуха за компрессором низкого давления (TLPC), давление воздуха за компрессором высокого давления (PHPC), температура уходящих газов (EGT) – за турбиной низкого давления.

После обучения ИНС была получена модель двигателя $f_{\text{ИНС}}$. Затем для визуализации результатов идентификации модели были рассчитаны относительные отклонения значений модельных параметров от замеренных Y_i и построены в виде временных трендов (рис. 2 – 5):

- 1) $Y_i - f_{\text{ИНС}}(\text{optime}, \text{NHP}, \text{NPT}, T_0, P_0) / Y_i$;
- 2) $Y_i - f_{\text{ИНС}}(0 \text{ часов}, \text{NHP}, \text{NPT}, T_0, P_0) / Y_i$;
- 3) $Y_i - f_{\text{ИНС}}(1000 \text{ часов}, \text{NHP}, \text{NPT}, T_0, P_0) / Y_i$;
- 4) $Y_i - f_{\text{ИНС}}(2000 \text{ часов}, \text{NHP}, \text{NPT}, T_0, P_0) / Y_i$.




Рис. 2. Относительные отклонения нейросетевой модели от зарегистрированных параметров

Первый случай, по сути, демонстрирует погрешность метода: по рис. 2 видно, что максимальная ошибка аппроксимации не превышает 3 – 4 %, что приблизительно соответствует погрешности каналов измерения, а расчет средней ошибки дал

около 0,5 %. Во втором случае в течение первых 300 часов отклонения приблизительно постоянны и находятся в коридоре $[-3; 3\%]$, а затем растут до 6 – 8% на отметке в 2000 часов.

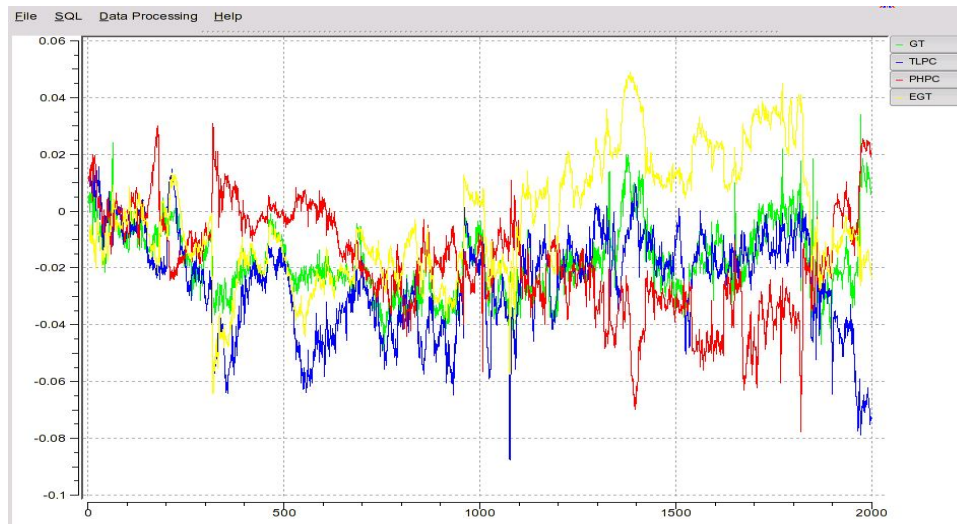


Рис. 3. Относительные отклонения ИИС-модели (при $ortime = 0$ часов) от зарегистрированных параметров




Рис. 4. Относительные отклонения ИИС-модели (при $ortime = 1000$ часов) от зарегистрированных параметров

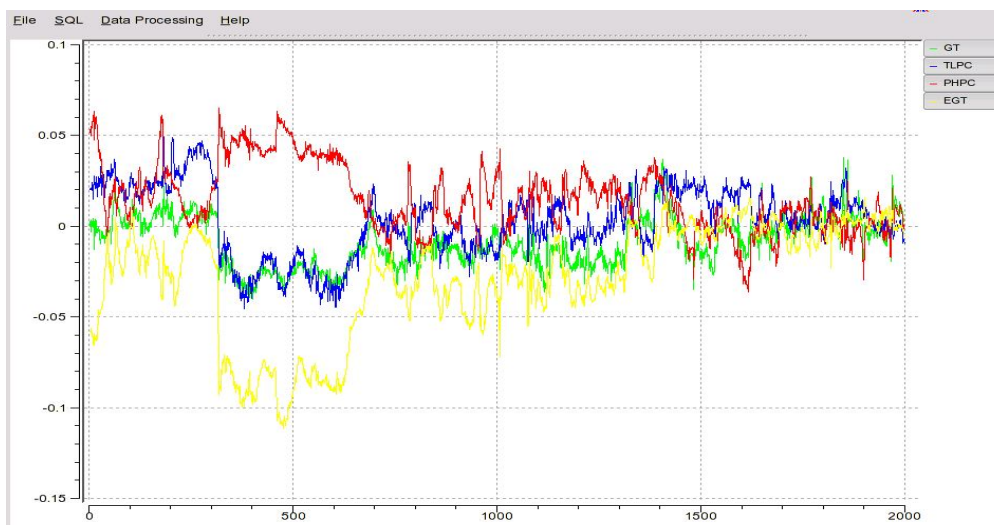


Рис. 5. Относительные отклонения ИИС-модели (при $ortime = 2000$ часов) от зарегистрированных параметров




Рис. 6. ИНС зависимость EGT от NHP при $optime = 0...2000$ ч,
 $NPT = 5000$ об/мин, $T_0 = 15$ °C, $P_0 = 100$ кПа

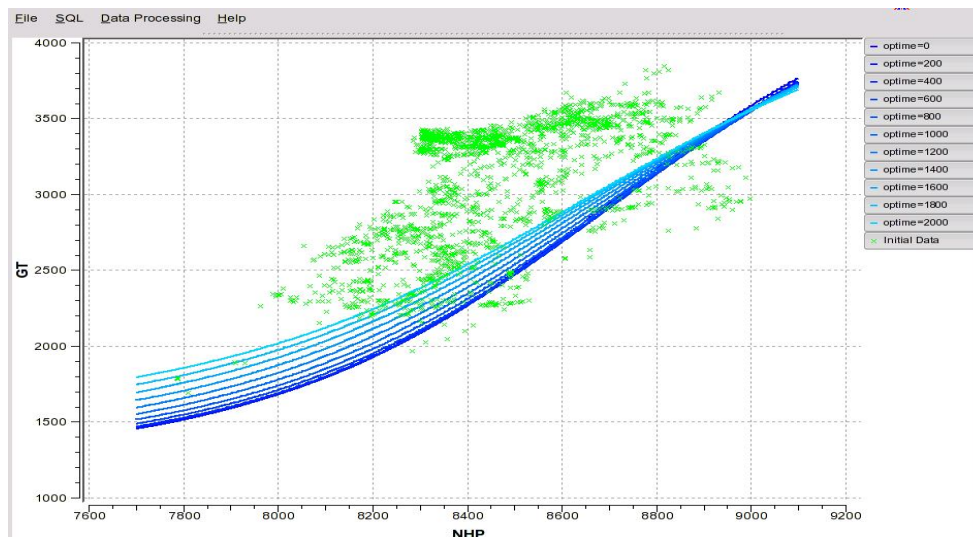


Рис. 7. ИНС зависимость GT от NHP при $optime = 0...2000$ ч,
 $NPT = 5000$ об/мин, $T_0 = 15$ °C, $P_0 = 100$ кПа




Рис. 8. ИНС зависимость GT от NHP при $NPT = 3600...5000$ об/мин,
 $optime = 1500$ ч, $T_0 = 15$ °C, $P_0 = 100$ кПа




Рис. 9. ИНС зависимость РНРС от NHP при NPT = 3600...5000 об/мин, optime = 1500 ч, T0 = 15 °С, P0 = 100 кПа




Рис. 10. Отклонения полиномиальной идентификационной модели ГТД от исходного процесса

В 4-м случае наблюдаем картину обратную 2-му – «снижение» отклонений с 6 – 10 % при optime = 0 до 3 – 4% в диапазоне optime = 1500...2000 часов. В 3-м случае отклонения минимальны в диапазоне от 500 до 1500 часов и возрастают в начале и в конце рассматриваемого участка. Данный пример говорит о том, что нейросеть способна «улавливать» зависимость изменения модели ГТД, обусловленную разви-

тием дефектов, естественным износом или загрязнением, от времени.

2. Результаты идентификации модели ГТД с учетом временного фактора

Полученные выше модели можно рассматривать как поверхности в пространстве (Y_i , optime, NHP, NPT, T0, P0). На рис. 6 – 9 показаны примеры дроссельных характеристик ГТД для параметров EGT

(температура исходящих газов или температура за ТНД), GT (расход топливного газа) и РНРС (давление за КВД), полученные как проекции на плоскость (Y , ННР) сечений этих поверхностей, соответствующих различным значениям времени ($optime$), частоте вращения СТ и фиксированным значениям температуры наружного воздуха (T_0 , °C) и атмосферного давления (P_0 , кПа). На этой же плоскости отображено исходное множество точек.

Для сравнения на рис. 10 изображены отклонения соответствующие полиномиальной модели нормального состояния.

Рассчитанные максимальные ошибки аппроксимации, для отдельных контролируемых параметров, находятся в пределах 5 – 8%, а расчет средней погрешности выдал значения порядка 0,7 – 1,6%. Как видно из сравнения графиков нейросетевая модель не уступает по точности полиномиальной, но как было показано в [2], превосходит ее по гибкости описания зависимостей.

Необходимо отметить, что отказ от частоты вращения силовой турбины в качестве одного из аргументов идентификационной функции в рассматриваемом примере лишь незначительно повысил среднюю (с 0,533 до 0,599%) и максимальную (с 3,735 до 3,876%) ошибки аппроксимации. (осредненные данные соответствуют 10 тестируемым нейросетям). Влияние аргумента NPT на контролируемые параметры в рассмотренном примере не столь велико, как ННР, однако как следует из рис. 8 и 9 может быть существенным, что может стать объектом дальнейших исследований.

На этом примере четко видно, как ИНС аппроксимирует физические взаимосвязи между парамет-

рами, обусловленные рабочим процессом, протекающим в газовом тракте ГТД.

Заключение

Таким образом, путем использования новых информационных интеллектуальных технологий удалось получить эффективную проверенную на практике методику учета временного фактора при идентификации модели ГТД и тренд-анализе.

В заключение считаем необходимым сказать, что вопрос методики применения и обновления идентификационной модели, учитывающей временной фактор, для допускового контроля ГТД, остается открытым. Как видно из графиков допусковый контроль ГТД проводимый на основе ИНС-модели взятой при фиксированном значении времени (500, 1000, 2000 часов, например), позволяет уменьшить ошибку аппроксимации модели ГТД на 2 – 4%.

Литература

1. Епифанов С.В. Оптимальный синтез систем диагностирования технического состояния авиационных ГТД с целью обеспечения их надежности: Дисс. д-ра техн. наук: 05.07.05. – Х., 2001. – 360 с.
2. Концевич А.Г. Аппроксимация модели нормального состояния ГТД искусственной нейронной сетью // Авиационно-космическая техника и технология: Сб. научн. тр. – Х. – 2002. – Вып. 31. Двигатели и энергоустановки. – С. 202-205.

Поступил в редакцию 10.06.2006

Рецензент: д-р техн. наук, проф. М.Л. Угрюмов, Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Харьков.