

УДК 629.735(045)

А.Г. КУЧЕР, А.С. ЯКУШЕНКО, А.Ю. СУХОРУКОВ

Национальный авиационный университет, Украина

ОПТИМИЗАЦИЯ МЕТОДА ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ ДЛЯ РАСПОЗНАВАНИЯ КЛАССА ТЕХНИЧЕСКОГО СОСТОЯНИЯ ГТД

В статье рассмотрены проблемы выбора метода обучения нейронной сети, оптимального с точки зрения стабильности работы, скорости обучения и качества распознавания класса технического состояния ГТД по параметрам его функционирования. Приведены результаты исследования различных методов.

диагностирование, техническое состояние, нейронные сети, обучение, математическое моделирование, газотурбинный двигатель

Введение

Одним из приоритетных направлений развития авиационной техники и, прежде всего, авиационных ГТД на протяжении последних десятилетий является повышение уровня контролепригодности, что, в первую очередь, характеризуется резким увеличением объемов регистрируемой информации. Это, с одной стороны, позволяет выполнять диагностирование с глубиной распознавания дефекта до узла, а, иногда, и глубже. С другой стороны наличие больших объемов информации значительно усложняет алгоритмы обработки информации, требует высокой квалификации эксперта, увеличивает время, необходимое на ее анализ и повышает вероятность ошибки. Это связано с общепринятым при диагностировании ГТД подходом, суть которого состоит в ручном или полуавтоматизированном анализе изменения значений диагностических параметров и их отклонений во времени.

1. Формулирование проблемы

Для уменьшения нагрузки эксперта, повышения качества и оперативности определения технического состояния ГТД необходимо выполнять предварительный автоматизированный анализ информации. Результатом такого анализа является классификация технического состояния (ТС) ГТД – отнесение двигателя к одному из классов (простейший случай – к дефектным или бездефектным двигателям). После

такой классификации эксперт должен проанализировать только отселектированные данные.

Перспективным направлением автоматизированного определения класса ТС ГТД является использование нейронных сетей. Одной из особенностей работы такой сети является необходимость ее обучения, в ходе которого происходит настройка параметров ее элементов (нейронов). В настоящее время разработано значительное число методов обучения, различающихся, с точки зрения пользователя, точностью обучения, объемом вычислений (временем обучения), устойчивостью получения результатов и требованиями, предъявляемыми к компьютеру. При этом отсутствуют рекомендации по выбору оптимального алгоритма. В виду этого метод выбора оптимального метода обучения нейронной сети является объектом этой работы.

2. Решение проблемы. Выбор алгоритма обучения нейронной сети

В качестве объекта исследований выбраны статические нейронные сети, которые учитывают только текущие значения параметров рабочего процесса ГТД. Для такой классификации наиболее часто используются так называемые LVQ-сети (Learning Vector Quantization) и сети с прямым распространением сигнала [1]. В работе [2] приведены характеристики качества распознавания класса технического состояния ГТД для LVQ-

сети. Из этих характеристик следует, что такие сети имеют неудовлетворительно высокий уровень ошибок даже для относительно простых входных данных. Это предопределяет необходимость использования нейронных сетей более сложной структуры – многослойных сетей с прямым распространением сигнала.

Для того, чтобы сеть начала работать, необходимо провести ее обучение. Для этого на вход сети подаются векторы диагностических параметров и с помощью одной из существующих процедур обучения параметры нейронов (весовые коэффициенты входов и сдвиги) изменяются таким образом, чтобы минимизировать разность между откликом сети (вектор, составленный из сигналов нейронов выходного слоя) и вектором целей обучения. Как вектор целей может использоваться, например, набор, составленный из нулей и единиц. В этом наборе положение единиц презентует номер класса, к которому принадлежит ГТД с параметрами текущего вектора входных данных. Учитывая, что для значительной части нейронов (с сигмоидальной функцией активации) выходной сигнал не превышает единицу, для кодирования номера класса ТС вместо единицы лучше использовать меньшее значение (например из диапазона 0,5 – 0,9).

В работе [2] как параметр адекватности сети входным данным предложено использовать величину процента ошибок распознавания Δ . В случае, если рассматривается возможность одновременного возникновения дефектов в двух, или более, узлах ГТД, как характеристика адекватности может быть использован процент грубых ошибок распознавания Δ_r , если неверно определены все дефекты или ГТД отнесен к классу бездефектных.

В работе [2] приведен пример создания LVQ-сети для распознавания технического состояния двигателя ПС-90А [3]. При этом использованы наборы данных, которые описывают случай, когда

классы технического состояния ГТД в пространстве признаков состояния (диагностических отклонений) довольно сильно разнесены, а функция (см. зависимость (2) в [2]) принята нормальной. Это обеспечивает малое представление данных по каждому классу на границах между классами. Более сложным для распознавания является случай, когда имеет место равномерный закон распределения и когда классы плотно граничат между собой.

Кроме того, использованные в работе [2] наборы представляют только основные классы ТС (основной класс описывает случай изменения функциональных характеристик только одного элемента проточной части). Для нормальной работы сеть должна быть в состоянии распознавать не только основные, но и, по крайней мере, вторичные классы, которые являются попарными комбинациями основных классов (двойные дефекты).

Для проведения исследований получены такие наборы данных. Метод получения соответствует приведенному в работе [2] с учетом сделанных в данной работе уточнений. Был получен учебный набор данных, в котором каждый класс представлен 20 точками. Первые 20 точек представляют бездефектный ГТД (1 класс), с 21 по 120 – первичные классы (деградация одного из узлов – внешний контур вентилятора (2 класс), компрессор высокого давления (3), камера сгорания (4), турбины высокого (5) и низкого давления (6)), с 121 по 320 – вторичные классы (комбинации первичных): комбинация классов 2 + 3 (7 класс), 2 + 4 (8), 2 + 5 (9), 2 + 6 (10), 3 + 4 (11), 3 + 5 (12), 3 + 6 (13), 4 + 5 (14), 4 + 6 (15), 5 + 6 (16). При расчете было принято, что $\overline{\Delta a_i^\Gamma} = 0,4$, диапазон $\overline{\Delta a_i^{\text{MIN}}} \dots \overline{\Delta a_i^{\text{MIN}}}$ для бездефектного двигателя составлял $-0,1 \dots \overline{\Delta a_i^\Gamma}$, для дефектных $\overline{\Delta a_i^\Gamma} \dots 1$. Полученный таким образом набор данных использован в дальнейшей работе.

Наиболее целесообразно с нашей точки зре-

ния начать построение сети с выбора алгоритма обучения. Наиболее известны следующие методы обучения сети: алгоритмы сопряженных градиентов: Флетчера-Ривса (сокращенное название CGF), Полака-Рибейры (CGP), Биеля-Пауэлла (CGB); квазиньютоновские алгоритмы: Левенберга-Марквардта (LM), Бройдена-Флетчера (BFG), Батитти (OSS); градиентный пороговый алгоритм обратного распространения ошибки (Rprop). Детальная характеристика этих методов приведена в [1].

В качестве тестовой использована сеть, имеющая 3 слоя: входной слой состоит из 7 нейронов, промежуточный из 11, выходной – 16 (по числу классов). Функция активации нейрона – гиперболический тангенс. Схема сети приведена на рис. 1. Учитывая, что на выходе сети стоят не перцептроны, а нейроны, значение на выходе которых изменяется плавно, для формирования на выходе программы номера класса ТС, отклик сети подается на вход процедуры выбора наибольшего значения. Номер нейрона выходного слоя, имеющий наибольшее значение, соответствует номеру распознанного сетью класса.

Обучение сети проводилось при использовании представления точности обучения по критерию суммы квадратов отклонений целей обучения от отклика сети: sse – представление ошибки (Sum squared error).

Обучение сети по всем алгоритмам проводилось в течение одинакового промежутка времени (500 секунд). Процесс обучения был повторен несколько раз.




Рис. 1. Общая структура сети, использованной при выборе алгоритма обучения

При проведении обучения с использованием алгоритма BFG программное обеспечение в ряде попыток выдало предупреждение о возможной некорректности полученного результата. Это указывает на то, что алгоритм BFG нецелесообразно использовать для распознавания класса ТС.

Метод LM требует меньшего числа циклов обучения (в 100 – 1000 раз), но за временем их выполнения даже на компьютере, который имеет 400 мегабайт оперативной памяти (метод критичен к этому параметру), достигнутая ошибка распознавания достаточно высока. Кроме того, при выполнении ряда попыток (в двух из трех), было выявлено, что метод имеет склонность к "зависанию" при котором процесс обучения практически останавливается. Можно высказать предположение, что нестабильность работы указывает на чувствительность метода к начальному состоянию сети.

Для минимизации влияния начального состояния выполнена попытка объединения двух методов обучения – BFG и LM в один алгоритм. При этом обучение сети начиналось из алгоритма BFG и после частичного (предварительного) обучения окончательное обучение было выполнено по методу LM. Полученный комбинированный метод также проявил склонность к "зависанию" при выполнении метода LM и довольно высоком уровне ошибок распознавания в случае удачного проведения обучения.

Для каждого алгоритма после удачного окончания обучения проведено распознавание обученной сетью учебного набора. На базе сравнения полученного отклика сети (номера класса ТС) с заданными значениями определено наличие ошибки (код 0 – для случая частичного распознавания класса и 0,5 – для грубой ошибки).

На рис. 2 приведены характеристики процесса обучения сети и результаты распознавания учебного набора данных при использовании рассмотренных методов обучения.

Как видно из рис. 2, с точки зрения точности обучения (минимальные значения параметров Δ и Δ^r) наилучшие показатели имеет метод Rprop, по которому и будет проведена дальнейшая работа. Кроме того, следует выделить метод CGP, показавший стабильную работу. Данный метод позволяет также проводить многоэтапное прерывистое обучение, обеспечивая продолжение обучения с места, на котором оно было прервано. Данное свойство особенно важно для определения переучивания сети. На рис. 3 приведены параметры точности обучения сети по методам Rprop и CGP до и после прерывания на 20 цикле обучения. Из приведенных данных видно, что метод Rprop после остановки начинает обучение сети заново, тогда как CGP продолжает обучение.

Для проверки надежности работы алгоритма CGP было проведено обучение сети с 20 нейронами в промежуточном слое. Ход обучения и результаты распознавания учебных данных приведены на рис. 4 – 5. Как можно видеть, выбранный алгоритм работает устойчиво и обеспечивает высокую точность распознавания учебного набора данных ($\Delta = 6,5\%$, $\Delta^r = 5\%$). При этом сеть продолжала обучаться до последнего цикла обучения. Это означает, что, в случае необходимости, путем увеличения времени обучения можно повысить точность распознавания. В этом случае момент прерывания обучения необходимо определять по возникновению эффекта переобучения сети [1].

В заключение проведено обучение сети при использовании критерия среднего значения отклонений целей обучения от отклика: *mae*-представление ошибки (Mean absolute error). В результате использования критерия не удалось получить сеть, адекватно описывающую исходные данные.

В представленной работе постановка задачи выбора оптимального с точки зрения качества классификации ТС ГТД метода обучения сети и разработан метод решения поставленной задачи. Проведено опробование предложенных методов.

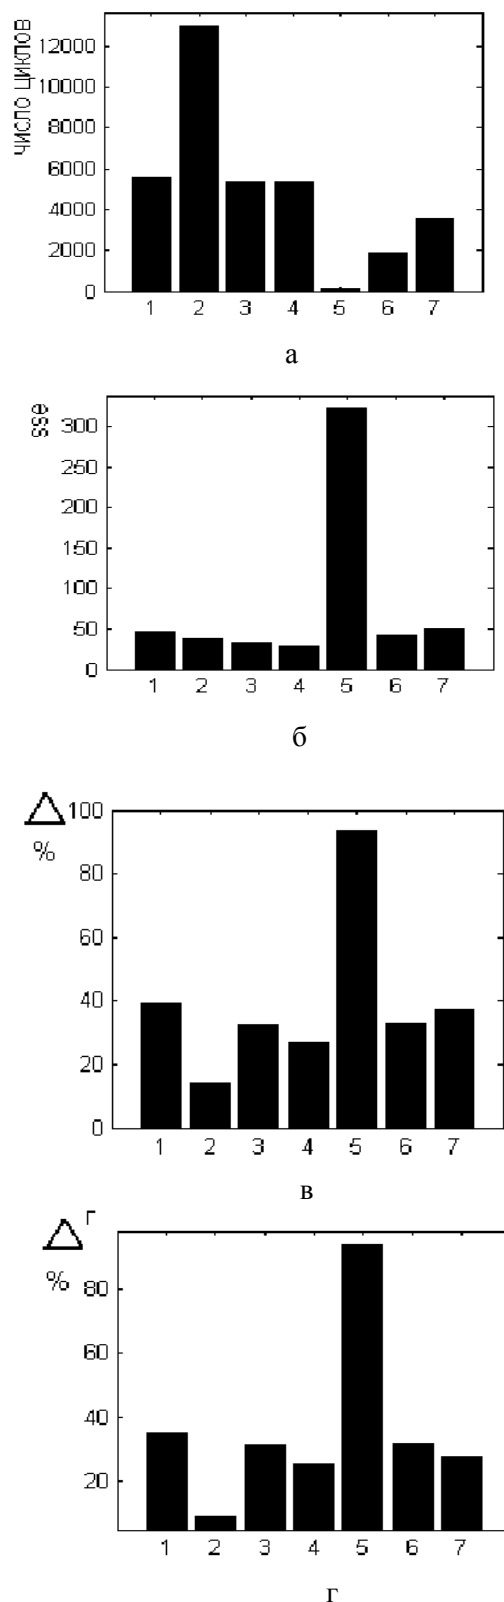


Рис. 2. Характеристики процесса обучения сети и результаты распознавание учебного набора данных при использовании алгоритмов: 1 – CGF, 2 – Rprop, 3 – CGP, 4 – CGB, 5 – LM, 6 – BFG, 7 – OSS, а – число циклов обучения; б – параметр точности обучения sse; в – процент ошибок распознавания; г – процент грубых ошибок распознавания




Рис. 3. Изменение параметра sse для метода Rprop (а, б) и CGP (в, г) при прерывании процесса обучения на 20 цикле




Рис. 4. Ход процесса обучения (зависимость параметра точности обучения sse от числа циклов) при использовании алгоритма обучения CGP после выполнения 12 000 циклов

Заключение

Представленный алгоритм обеспечивает выбор оптимального метода обучения нейронной сети распознаванию класса технического состояния двигателя. Для окончательного формирования архитектуры нейронной сети необходимо провести следующие исследования: выбор типа нейронов каждого слоя; определение количества слоев; окончательное обучение сети с учетом возможности эффекта переобучения сети.




Рис. 5. Результаты распознавания учебного набора (рис.3, б) при использовании алгоритма обучения CGP после выполнения 12 000 циклов

Литература

1. Медведев В.С., Потемкин В.Г. Нейронные сети. Matlab 6 / Под общ. ред. В.Г. Потемкина. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.
2. Кучер О.Г., Якушенко О.С., Сухоруков В.Ю. Розпізнавання технічного стану авіаційних ГТД з використанням нейронних мереж // Запоріжжя: ЗНТУ, ХАІ, Мотор-Січ. – № 1. – 2002. – С. 101 – 106.
3. Двигатель ПС-90А. Руководство по технической эксплуатации. В 3-х книгах. – Пермь: ПНПО "Авиадвигатель", 1990.

Поступила в редакцию 31.05.2004

Рецензент: д-р техн. наук, проф. С.Р. Игнатович, Национальный авиационный университет, Киев.