

ИСПОЛЬЗОВАНИЕ ИНТЕЛЛЕКТУАЛЬНЫХ МЕТОДОВ ДЛЯ ВИБРОДИАГНОСТИКИ ТЕХНИЧЕСКОГО СОСТОЯНИЯ АВИАЦИОННЫХ ГАЗОТУРБИННЫХ ДВИГАТЕЛЕЙ

Карчин Иван Константинович

*студент 2 курса напр. «Промышленная электроника»,
УГАТУ г. Уфа*

Жернаков Сергей Владимирович

*д.т.н, профессор,
УГАТУ, г. Уфа*

Аннотация. В статье рассматриваются интеллектуальные методы вибродиагностики технического состояния авиационных газотурбинных двигателей. Большое место в работе занимает рассмотрение методов анализа диагностики авиационных изделий. Исследование ведется через рассмотрение таких проблем, как основные источники вибрации, влияние дефектов на вибрацию математическое и программное обеспечение для экспертной и автоматической вибродиагностики, системы вибромониторинга и диагностики машин и оборудования. Раскрывается метод анализа с использованием самоорганизующейся карты Кохонена. Описывается практическая реализация нейронной сети Кохонена.

Проблемная область исследований следующая:

- Основные источники вибрации [1];
- Влияние дефектов на вибрацию;
- Математическое и программное обеспечение для экспертной и автоматической вибродиагностики [2,3];
- Системы вибромониторинга и диагностики машин и оборудования.
- **Дано:** Вибросигнал авиационного газотурбинного двигателя

Постановка задач: Задачей работы является определение проблемной области исследования; выявление источников и причин возбуждения вибрации; рассмотрение методы анализа вибрации.

Решение задач:

Преобразование сигнала в цифровую форму

Цифровая обработка сигнала

Под цифровой обработкой сигналов принято в вычислительной технике называть арифметическую обработку последовательностей, равноотстоящих во времени отсчетов. Под цифровой обработкой понимают также обработку одномерных и многомерных массивов данных.

Данная обработка может быть выполнена и с помощью обычных вычислительных средств. Например, на современном персональном компьютере с процессором типа Pentium IV или AMD обработка не представляет никаких трудностей. Однако именно специфика последовательности предоставляет дополнительные возможности для достижения высокой эффективности при жестких ограничениях систем реального времени.

Системы и методы цифровой обработки разрабатывались в оборонных отраслях в первую очередь для решения задач радиолокации, обработки гидроакустических и тепловизионных сигналов.

Для обнаружения и уничтожения летательных аппаратов служили комплексы, состоящие из радиолокаторов, управляющих вычислительных машин и ракетных установок. В области военного морского приборостроения системы цифровой обработки использовались, в частности, для анализа гидроакустических сигналов, определения шумовых паспортов кораблей на основе спектральных характеристик, вычисления корреляционных зависимостей паспорта и реального гидроакустического сигнала.

Современное применение методов цифровой обработки лежит в области мультимедийных технологий, то есть обработки звука и изображений, включающей их сжатие, кодировку. В области цифровой связи цифровыми методами выполняется модуляция и демодуляция данных для передачи по каналам связи.

Цифровая обработка, в отличие от аналоговой, традиционно используемой во многих радиотехнических устройствах, является более дешевым способом достижения результата, обеспечивает более высокую точность, миниатюрность и технологичность устройства, температурную стабильность.

Наиболее жесткие требования к аппаратной части цифровой обработки предъявляют радиолокационные системы. Основным содержанием цифровой обработки здесь является фильтрация входных сигналов антенны, частоты сигналов от 10 МГц до 10 ГГц. Размеры преобразований могут достигать до 2^{14} комплексных точек, требования по быстродействию составляют 10^9 умножений в секунду.

В системах обработки звука цифровые процессоры обработки сигнала решают задачи анализа, распознавания и синтеза речи, сжатия речи в системах телекоммуникации. Для систем обработки изображений типовыми задачами являются улучшение изображений, сжатие информации для передачи и хранения, распознавание образов. При обработке цифровых звуковых сигналов используются алгоритмы цифровой фильтрации и спектрального анализа (вычисление ДПФ – дискретное преобразование Фурье и БПФ – быстрое преобразование Фурье), алгоритмы корреляционного анализа, обратной свертки, специальные алгоритмы линейного

предсказания. В большинстве случаев удовлетворительные результаты обеспечивает формат данных с фиксированной запятой, длина слова 16 бит, частоты сигналов от 4 до 20 кГц (до 40 кГц в случае обработки музыки), требуемая производительность – до $10 \cdot 10^6$ операций в секунду – 10 MIPS по компьютерной терминологии.

Быстрое преобразование Фурье и расчет его быстродействия

Разработка преобразований Фурье сыграла огромную роль в появлении и развитии ряда новых областей науки и техники. Достаточно отметить, что электротехника переменного тока, электрическая связь и радиосвязь базируются на спектральном представлении сигналов. Прямое преобразование Фурье переводит описание сигнала (функции времени) из временной области в частотную область, а обратное преобразование Фурье переводит описание сигнала из частотной области во временную [4].

Быстрое преобразование Фурье (БПФ) - это не еще одна разновидность преобразования Фурье, а название целого ряда эффективных алгоритмов, предназначенных для быстрого вычисления дискретно-временного ряда Фурье. Основная идея быстрого преобразования Фурье - деление N-точечного дискретно-временного ряда Фурье на два и более ряда меньшей длины, каждый из которых можно вычислить отдельно, а затем линейно просуммировать с остальными, с тем, чтобы получить дискретно-временной ряд Фурье исходной N-точечной последовательности.

Базовой операцией, выполняемой над последовательностями отсчетов, является прямое и обратное преобразования Фурье, которое позволяет осуществить перенос сигнала из амплитудно-временной области в представление амплитуда-частота и обратно.

Цифровыми методами данную операцию можно выполнить на основе прямого преобразования Фурье, позволяющего произвольную периодическую непрерывную функцию $x(t)$ представить в виде.

Прямое преобразование Фурье:

$$X(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt \quad (1)$$

Обратное преобразование Фурье:

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\omega)e^{j\omega t} d\omega \quad (2)$$

При использовании ряда Фурье в цифровой обработке сигнала (ЦОС) необходимо его преобразование для того, чтобы его можно было применить к дискретизированному аналоговому входному сигналу. Преобразование выполняется простой заменой непрерывной переменной времени t на дискретное время $n \cdot T_s$, где T_s – период дискретизации, а n – номер отсчета. Частотный спектр дискретного сигнала имеет период $1/T_s$. Другими словами, спектр сигнала повторяется с периодом, равным частоте дискретизации ω . В результате можно получить дискретное преобразование Фурье, произведя небольшой ряд вычислений и подставив их в формулу преобразования Фурье [4].

Прямое дискретное преобразование Фурье:

$$X_N(k) = \sum_{n=0}^{N-1} x(n)W_N^{kn} \quad (3)$$

где W_N^{kn} – поворачивающий множитель;

N – Число отсчетов для описания входного сигнала;

k – Целочисленное значение (0, 1, 2...).

Обратное дискретное преобразование Фурье:

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X_N(k)W_N^{-kn} \quad (4)$$

Проблема, возникающая при практической реализации ДПФ, заключена в большом количестве вычислительных операций, пропорциональном N^2 . Для решения этой проблемы были разработаны алгоритмы для уменьшения арифметических операций, получившие название быстрого преобразования Фурье.

Существует множество разнообразных методов уменьшения сложности (алгоритм по основанию 2 наиболее распространен). Многие другие преобразования еще больше сокращают необходимое количество умножений, но ценой дополнительных сложений. Раньше это было полезным, потому что умножение выполнялось дольше, чем сложение. Однако большинство цифровых процессоров обработки сигналов выполняют и умножение, и сложение за один цикл, так что всякое увеличение количества сложений равнозначно снижает производительность.

Довольно простая структура БПФ позволяет быстро и легко выполнить преобразование на кристалле ЦПОС,

специально предназначенном для реализации БПФ. Поскольку алгоритмы реализуются аппаратно, такие кристаллы успешно выполняют быстрые БПФ. Основной недостаток подобных реализаций состоит в том, что они непрограммируемые и не способны выполнять другие функции обработки сигналов. Однако ЦПОС общего назначения могут выполнять разнообразные операции с входным сигналом, включая БПФ.

Проанализировав отсчеты БПФ, даст результат того, что они располагаются не в том порядке, как выходные. Чтобы выполнить БПФ быстро, необходим алгоритм перестановки входных отсчетов относительно их естественного порядка. Это можно сделать путем размещения в обратном (реверсивном) порядке бит, которыми кодируется номер отсчета, или путем сложения по модулю. Большинство ЦПОС имеют специальный режим адресации, позволяющий автоматически производить перестановку отсчетов как фоновую операцию. С помощью алгоритмов БПФ современные процессоры легко могут вычислять 1024-точечное ДПФ менее чем за 1 мс.

Оценим требуемую производительность устройства обработки. Для вычисления БПФ 256 точек по основанию 2 с комплексными входными данными требуется примерно 3 тыс. умножений действительных операндов и 5,5 тыс. сложений действительных операндов, для 1024 — точечного БПФ по основанию 2 — примерно 16 тыс. умножений и 28,5 тыс. сложений. В разрабатываемой МПС время опроса датчиков составляет 10 мкс, что дает частоту опроса в 100 кГц. Оценку быстродействия БПФ проведем с помощью следующего выражения:

$$N_{\text{MAC}} = \frac{N_{\text{умн}} \cdot f_{\text{отсч}}}{N_{\text{точ}}} = \frac{16000 \cdot 100000}{1024} = 1562500 \text{ операций,} \quad (5)$$

где N_{MAC} — число операций типа умножения-накопления, с^{-1} ;

$N_{\text{умн}}$ — число умножений, необходимых для вычисления преобразования;

$f_{\text{отсч}}$ — частота поступления входных данных, Гц;

$N_{\text{точ}}$ — размер преобразования.

Процессор TMS320VC5509A имеет быстродействие 400 млн. операций в секунду. Число логических операций для 1024-точечного БПФ удовлетворяет быстродействию процессора.

Обоснование выбора центрального процессора

Основным элементом системы является DSP процессор, и он должен удовлетворять следующим требованиям и ограничениям:

- обладать достаточным быстродействием (порядка 2 млн. инструкций в секунду), для решения круга задач, возложенных на него;
- достаточный объем ПЗУ программ, для реализации необходимых алгоритмов;
- наличие достаточного количества портов ввода/вывода для реализации базовых функций вычислителя.

Все вышеперечисленные требования легко обеспечат процессоры американской фирмы Texas Instruments. Процессоры этой компании обладают высокоскоростными интерфейсными подсистемами и поэтому их предпочтительнее использовать для тех задач, в которых требуется выполнение интенсивного обмена с внешними устройствами (микропроцессорные системы, различного рода контроллеры). На рисунке 1 представлено иерархическое дерево процессоров TI (Texas Instruments) [5].




Рисунок 1 – Иерархическое дерево микропроцессоров фирмы Texas Instruments

Проанализировав данные семейства DSP процессоров компании можно сделать вывод, что для реализации МПС для вибродиагностики ГТД наиболее подходящим будет процессор семейства C55x.

В данном семействе был выбран 16-разрядный процессор TMS320VC5509A. Отличительные особенности: высокопроизводительный ЦСП TMS320C55TM с фиксированной запятой с низким энергопотреблением: длительность однократной команды 9.26 / 6.95 / 5 нс, тактовая частота 108 / 144 / 200 МГц, выполнение

одной/двух команд за один такт, два умножителя (производительность до 400 миллионов умножений с накоплением в секунду (ММАСС)), два арифметическо-логических устройства (АЛУ), три внутренних шины чтения данных/операндов, две внутренних шины записи данных/операндов, встроенное ОЗУ 128К x 16 бит (8 блоков по 4К x 16 бит ОЗУ с двойным доступом (DARAM) (всего 64 КБайт); 24 блоков по 4К x 16 бит ОЗУ с одноканальным доступом (SARAM) (всего 192 КБайт)), встроенное ПЗУ 32К x 16 бит (64 КБайт) с одним тактом ожидания, общий объем адресуемой памяти 8М x 16 бит (синхронной DRAM), 16-битная внешняя параллельная шина, используемая как интерфейс внешней памяти (EMIF) с возможностью использования портов ввода-вывода общего назначения (GPIO) или подключения памяти типов (асинхронное статическое ОЗУ (SRAM), асинхронное EEPROM, синхронное динамическое ОЗУ (SDRAM)), 16-битный параллельный порт управляющего контроллера (EHPI) с возможностью использования портов ввода-вывода общего назначения (GPIO), программный контроль энергопотребления шести функциональных блоков внутренних устройств, встроенные периферийные устройства (два 20-битных таймера, сторожевой таймер (watchdog), шестиканальный контроллер доступа к памяти (DMA), три последовательных порта (до трёх многоканальных буферизованных последовательных порта (McBSP); до двух портов для подключения карт памяти типа MMC/SD)), программируемый тактовый генератор с ФАПЧ, слейв (Slave) порт интерфейса Full Speed USB (скорость передачи данных до 12 Мбит/с) поддерживающий режимы передачи данных Bulk, Isochronous и Interrupt, интерфейс Inter-Integrated Circuit (I2C), Слейв (Slave) и Мастер (Multi-Master) режимы, часы реального времени (RTC) с отдельным резонатором, генератором и источником питания, 2 (для устройств в корпусе LQFP) или 4 (для устройств в корпусе BGA) канала 10-битного АЦП последовательного приближения, встроенный эмулятор, поддержка JTAG. Варианты корпусов: 144-выводный корпус LQFP (PGE), 179-выводный корпус MicroStar BGA (GHN), 179-выводный корпус MicroStar BGA (ZHN) без содержания свинца (Pb-free). Питание ядра 1,2 В (для устройств с тактовой частотой 108 МГц), питание портов ввода-вывода в диапазоне 2,7 – 3,6 В; питание ядра 1,35 В (для устройств с тактовой частотой 144 МГц), питание портов ввода-вывода в диапазоне 2,7 – 3,6 В; питание ядра 1,6 В (для устройств с тактовой частотой 200 МГц), питание портов ввода-вывода в диапазоне 2,7 – 3,6 В.

Использование нейронной сети в решении практических задач

Общие вопросы функционирования нейронной сети

Применение аппарата нейронных сетей для решения различных задач науки и техники обусловлено огромными потенциальными возможностями, этих технологий. Существуют задачи, решение которых просто невозможно аналитическими методами, а нейросети успешно с ними справляются. Даже в том случае, если можно найти решение при помощи уже изученных алгоритмов, нейронные сети порой позволяют сделать то же самое быстрее и более эффективно [6].

Искусственные нейронные сети (НС) — совокупность моделей биологических нейронных сетей. Представляют собой сеть элементов — искусственных нейронов — связанных между собой синаптическими соединениями.

подавляющее большинство моделей НС требуют обучения. Обучение — это такой выбор параметров сети, при котором сеть лучше всего справляется с поставленной проблемой. Обучение — это задача многомерной оптимизации, и для ее решения существует множество алгоритмов.

Основу каждой нейронной сети (НС) составляют относительно простые, в большинстве случаев — однотипные, элементы (ячейки), имитирующие работу нейронов мозга. Каждый нейрон характеризуется своим текущим состоянием по аналогии с нервными клетками головного мозга, которые могут быть возбуждены или заторможены.

Текущее состояние нейрона определяется, как взвешенная сумма его входов:

$$s = \sum_{i=1}^n x_i \cdot w_{i..} \quad (6)$$

Выход нейрона есть функция его состояния:

$$y = f(s).$$

Нелинейная функция f называется активационной и может иметь различный вид. Одной из наиболее распространенных является нелинейная функция с насыщением, так называемая логистическая функция или сигмоид:

$$f(x) = \frac{1}{1+e^{-ax}}.$$

Одно из ценных свойств сигмоидной функции — простое выражение для ее производной.

Следует отметить, что сигмоидная функция дифференцируема на всей оси абсцисс, что используется в некоторых алгоритмах обучения. Кроме того, она обладает свойством усиливать слабые сигналы лучше, чем большие, и предотвращает насыщение от больших сигналов, так как они соответствуют областям аргументов, где сигмоид имеет пологий наклон.

Возвращаясь к общим чертам, присущим всем НС, отметим, что принцип параллельной обработки сигналов, который достигается путем объединения большого числа нейронов в так называемые слои и соединения определенным образом нейронов различных слоев, а также, в некоторых конфигурациях, и нейронов одного слоя между собой, причем обработка взаимодействия всех нейронов ведется послойно. Примеры активационных функций представлены в таблице 1.

ТАБЛИЦА 1

РАЗНОВИДНОСТИ ФУНКЦИЙ АКТИВАЦИИ

Название	Формула	Область значений
Пороговая	$f(s) = \begin{cases} 0, & s < T, \\ 1, & s \geq T \end{cases}$	(0; 1)
Знаковая (сигнатурная)	$f(s) = \begin{cases} 1, & s > 0, \\ -1, & s \leq 0 \end{cases}$	(-1; 1)
Сигмоидальная (логистическая)	$f(x) = \frac{1}{1 + e^{-s}}$	(0; 1)
Полулинейная	$f(s) = \begin{cases} s, & s > 0, \\ 0, & s \leq 0 \end{cases}$	(0; ∞)
Линейная	$f(s) = s$	(-∞; ∞)
Радиальная базисная	$f(s) = \exp(-s^2)$	(0; 1)
Полулинейная с насыщением	$f(s) = \begin{cases} 0, & s \leq 0, \\ s, & 0 < s < 1, \\ 1, & s \geq 1 \end{cases}$	(0; 1)
Линейная с насыщением	$f(s) = \begin{cases} -1, & s \leq -1, \\ s, & -1 < s < 1, \\ 1, & s \geq 1 \end{cases}$	(-1; 1)
Гиперболический тангенс	$f(s) = \frac{e^s - e^{-s}}{e^s + e^{-s}}$	(-1; 1)

Выделим следующие характерные черты нейросетей как универсального средства обработки информации:

- средство прогнозирования во времени для процессов, зависящих от многих переменных: применение на производстве (изучение и прогнозирование свойств исследуемых материалов, и синтез новых материалов с заданными свойствами); прогнозирование развития циклонов и других природных процессов, прогнозирование изменений курсов валют и других финансовых процессов;
- классификатор по многим признакам, дающий разбиение входного пространства на области. Например, создание антивирусной системы на основе модели нейронной сети с элементами распознавания и классификации;
- средство распознавания зрительных, слуховых образов; огромная область применения: от распознавания текста и целей на экране радара до систем голосового управления, а также распознавание движущихся объектов, и анализа динамики их перемещения;
- инструмент управления и регулирования с предсказанием; управление роботами, другими сложными устройствами;
- инструмент для принятия решений и диагностики, исключающий логический вывод; особенно в областях, где отсутствуют четкие математические модели: в медицине, например, прогнозирование сердечно-сосудистых заболеваний, криминалистике, финансовой сфере.

В данном проекте основной задачей, на которую направлено внедрение нейросетевых алгоритмов является задача классификации.

Разновидности нейронных сетей

Выбор иерархии нейронной сети осуществляется в соответствии с особенностями и сложностью задачи, поэтому рассмотрим основные виды нейронных сетей.

Персептрон представляет собой модель обучаемой распознающей системы. По сути, персептрон состоит из одного слоя искусственных нейронов, соединенных с помощью весовых коэффициентов с множеством входов. Архитектура многослойной нейронной сети состоит из последовательно соединённых слоёв, где нейрон каждого слоя своими входами связан со всеми нейронами предыдущего слоя, а выходами – следующего [7].

Самоорганизующиеся нейронные сети Кохонена обеспечивают топологическое упорядочивание входного пространства образов. Они позволяют топологически непрерывно отображать входное n-мерное пространство в выходное m-мерное, $m \ll n$. Входной образ проецируется на некоторую позицию в сети, кодируемую как положение активированного узла. В отличие от большинства других методов классификации и кластеризации, топологическое упорядочивание классов сохраняет на выходе подобие во входных образах, что является особенно полезным при классификации данных, имеющих большое количество классов.

Сети Хопфилда однослойные и полносвязные (связи нейронов на самих себя отсутствуют), выходы связаны с входами. В отличие от многослойной нейронной сети, является релаксационной – т.е. будучи, установленной в

начальное состояние, функционирует до тех пор, пока не достигнет стабильного состояния, которое и будет являться её выходным значением. Нейронные сети Хопфилда применяются в качестве ассоциативной памяти и для решения оптимизационных задач. Нейронные сети Хопфилда бывают синхронными, когда одновременно пересчитываются все нейроны и асинхронными, когда пересчитывается случайно выбранный нейрон. Применение нейронных сетей Хопфилда в качестве ассоциативной памяти позволяет точно восстанавливать образы, которым сеть обучена, при подаче на вход искажённого образа. При этом сеть “вспомнит” наиболее близкий образ, и таким образом распознает его.

Когнитрон имеет иерархическую многослойную организацию, в которой нейроны между слоями связаны только локально. Входной слой чувствителен к простым образам, таким, как линии, и их ориентации в определенных областях визуальной области, в то время как реакция других слоев является более сложной, абстрактной и независимой от позиции образа.

Многослойные сети – нейроны объединяются в слои. Слой содержит совокупность нейронов с едиными входными сигналами. Число нейронов в каждом слое может быть любым и никак заранее не связано с количеством нейронов в других слоях.

Для реализации нашей задачи наиболее подходящими являются самоорганизующиеся нейронные сети Кохонена, так называемые карты Кохонена.

Самоорганизующая нейронная сеть Кохонена

Существует метод, позволяющий автоматизировать действия по поиску закономерностей – метод анализа с использованием самоорганизующейся карты Кохонена – один из разновидностей нейросетевых алгоритмов. Основным отличием является то, что при обучении используется метод обучения без учителя, то есть результат обучения зависит только от структуры входных данных. В этом методе искусственная сеть из связанных нейронов пытается самостоятельно понять сосредоточение входных объектов и визуально отобразить результаты на карте [8].

Алгоритм функционирования самообучающихся карт (Self Organizing Maps – SOM) представляет собой один из вариантов кластеризации многомерных векторов. Важным отличием алгоритма SOM является то, что в нём все нейроны упорядочены в некоторую структуру (обычно двумерную сетку). При этом в ходе обучения модифицируется не только нейрон-победитель, но и, в меньшей степени, соседи. За счёт этого SOM можно считать одним из методов проецирования многомерного пространства в пространство с более низкой размерностью. При использовании этого алгоритма векторы, схожие в исходном пространстве, оказываются рядом и на полученной карте.

SOM подразумевает использование упорядоченной структуры нейронов. Обычно нейроны располагаются в узлах двумерной сетки с прямоугольными или шестиугольными ячейками. При этом нейроны взаимодействуют друг с другом. Величина этого взаимодействия определяется расстоянием между нейронами на карте. Применение двумерных сеток связано с тем, что возникают проблемы при отображении пространственных структур большей размерности. Количество нейронов в сетке определяет степень детализации результата работы алгоритма и, в конечном счёте, от этого зависит точность обобщающей способности карты.

Для решения задач вибродиагностирования при реализации алгоритма SOM заранее задается конфигурация сети и количество нейронов в ней. В случае, когда количество узлов карты превышает количество примеров в обучающей выборке, то успех использования алгоритма в большой степени зависит от подходящего выбора начального радиуса обучения. Перед началом обучения карты необходимо проинициализировать весовые коэффициенты нейронов. Удачно выбранный способ инициализации позволит существенно ускорить обучение и приведёт к получению более качественных результатов.

Обучение состоит из последовательности коррекций векторов, представляющих собой нейроны. На каждом шаге обучения из исходного набора данных случайно выбирается один из векторов и затем производится поиск наиболее похожего близкого к нему вектора коэффициентов нейронов – так выбирается нейрон-победитель. Под похожестью в данной задаче понимается расстояние между векторами, обычно вычисляемое в евклидовом пространстве.

После того, как найден такой нейрон, производится корректировка весов нейросети. При этом векторы, описывающие нейрон и его соседей в сетке, перемещаются в направлении входного вектора. Часто эту величину называют радиусом обучения, который выбирается достаточно большим на начальном этапе обучения и постепенно уменьшается так, что в конечном итоге обучается один единственный нейрон.

Обучение состоит из двух основных фаз: на первоначальном этапе выбирается достаточно большое значение скорости и радиуса обучения, что позволяет расположить векторы нейронов в соответствии с распределением примеров в выборке, а затем производится точная подстройка весов, когда значения параметров скорости обучения значительно меньше начальных.

В разрабатываемой МПС вибрация замеряется по шести каналам, каждый из которых характеризуется набором различных спектров вибрации, которые описывают состояние ГТД. Сигналы имеют цифровую форму в результате БПФ- преобразования. Как правило, каждый сигнал имеет свою амплитуду и частоту и соответственно их параметры можно представить в виде координат в многомерном пространстве. Каждую несущую спектра

сигнала можно представить в виде точки в этом пространстве. Но так как значения несущих вибрации различное, то необходимо их про нормировать, что в результате нам дает попадание всех точек в куб единичного размера (см. рисунок 2).




Рисунок 2 – Расположение спектров в пространстве

Из рисунка 2 можно увидеть, как расположены спектры в пространстве. Причём легко заметить участки, где они группируются, то есть у них схожи параметры, значит и сами эти спектры, скорее всего, принадлежат одной группе.

Далее трехмерная система преобразуется в простую для восприятия двумерную систему так, чтобы соседние в искомом пространстве спектры оказались рядом на полученной картинке. Для этого естественно используем самоорганизующуюся карту Кохонена, которую можно представить в виде сети (см. рисунок 3).

Теперь набросим эту сеть на пространство признаков и поступим следующим образом: выберем один объект и найдём ближайший к нему узел сети. Далее, в процессе обучения, этот узел подтягивается к объекту и, вместе с этим узлом также, но с меньшей силой, подтягиваются и соседние узлы. Потом выбирается новый объект, и процедура повторяется. В результате получается карта, расположение узлов которой совпадает с расположением основных скоплений объектов в исходном пространстве (см. рисунок 4).

Полученная карта обладает следующим замечательным свойством – её узлы расположились таким образом, что объектам, похожим между собой соответствуют соседние узлы карты. Теперь можно определить, какие объекты попали в конкретные узлы карты. В результате всех этих операций объекты со схожими параметрами попадут в один узел или в соседние узлы.




Рисунок 3 – Карта Кохонена




Рисунок 4 – Вид пространства после наложения карты

Итогом работы нейронных карт Кохонена является кластер. Кластером будет являться группа векторов, расстояние между которыми внутри этой группы меньше, чем расстояние до соседних групп. Структура кластеров при использовании алгоритма SOM может быть отображена путем визуализации расстояния между опорными векторами (весовыми коэффициентами нейронов). Здесь чаще всего используется унифицированная матрица расстояний, вычисляется расстояние между вектором весов нейрона в сетке и его ближайшими соседями.

Основным преимуществом сети Кохонена перед другими нейронными сетями, к примеру, перед сетью ART Гроссберга, является то, что сеть способна функционировать в условиях помех, а так как число классов фиксировано, веса модифицируются медленно, настройка весов заканчивается после обучения (в сети ART настройка продолжается непрерывно).

Практическая реализация нейронной сети Кохонена

Одной из наиболее ответственных деталей авиадвигателей являются лопатки. Трещины, сколы, забоины в лопатках, возникающие в процессе эксплуатации, являются одним из наиболее характерных и распространенных дефектов. Эти дефекты, как правило, появляются и развиваются в течение определенного временного промежутка в процессе выработки двигателем его ресурса. Это дает реальную возможность осуществлять диагностические мероприятия для своевременного выявления дефектных лопаток.

Работа нейронной сети Кохонена в виде самоорганизующихся карт рассмотрена на примере лопаток первой ступени рабочего колеса компрессора низкого давления (РКНД). Анализу подвергается спектр виброскорости с диапазоном частот от 200 до 300 Гц в режиме малого газа (см. рисунок 5). Этот сигнал снят непосредственно с датчиков вибрации, и, прежде чем произвести его обработку на нейронной сети, его подвергаем быстрому преобразованию Фурье, чтобы получить необходимые несущие частоты [9].

После того как произвели БПФ можно проводить обработку данных нейронной сетью, но предварительно про нормировать их. Все амплитуды сигнала нормируются относительно критической амплитуды в 14,7 мм/с в диапазоне от 0 до 1, которая возможна в данном режиме. Это значение рассчитано с учетом допуска +5% от максимального значения. Значения частот нормируются относительно максимальной частоты 300 Гц в диапазоне от 0,6 до 1. Все это необходимо для того, чтобы правильно разметить границы входных векторов в нейронную сеть и, соответственно, правильно заставить ее работать [10].




Рисунок 5 – Спектр лопаток 1-й ступени РККНД в режиме малого газа

После нормирования амплитуды и частоты создается нейронная сеть Кохонена в виде самоорганизующейся карты размером 4x2, то есть в карте участвуют 8 нейронов. Такой размер карты выбран исходя из того, что количество нейронов равно количеству классов на выходе сети, а за каждым классом закреплено определенное состояние лопаток 1-й ступени РККНД, то есть сеть будет решать формализованную задачу.

После создания сети необходимо ее обучить. Для этого на вход сети подается массив в виде двухэлементных векторов, полученных в результате нормирования. Перед обучением также задается несколько параметров, а именно: количество циклов обучения 5000; количество циклов на этапе упорядочения 2000; параметр скорости обучения на этапе упорядочения 0,9; параметр скорости обучения на этапе подстройки 0,02; размер окрестности на этапе подстройки 0,1. После задания параметров происходит непосредственное обучение сети.

В процессе построения карты Кохонена изменяются 2 параметра: размер окрестности и параметр скорости обучения. Параметр скорости обучения продолжает уменьшаться, но очень медленно, и именно этот этап именуется подстройкой. Малое значение окрестности и медленное уменьшение параметра скорости обучения хорошо настраивают сеть при сохранении размещения, найденного на предыдущем этапе. Число шагов на этапе подстройки значительно превышает число шагов на этапе размещения. На этом этапе происходит тонкая настройка весов нейронов по отношению к набору векторов входа.

На рисунке 6 изображена топографическая карта начального расположения нейронов карты Кохонена и вершины векторов входа. Топология карты Кохонена представлена на рисунке 7, соединение соседних нейронов и дистанции между ними представлено на рисунке 8, а на рисунке 9 показаны плоскости для векторов входа.




Рисунок 6 – Начальное расположение весов и векторов входа

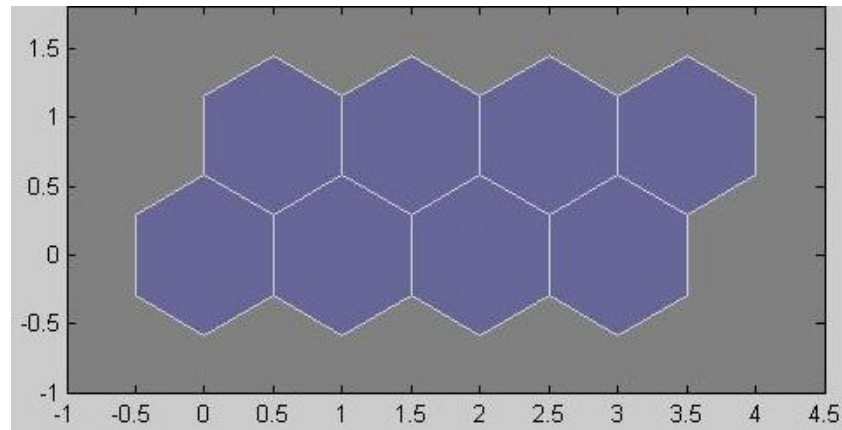


Рисунок 7 – Топология карты Кохонена




Рисунок 8 – Соединение соседних нейронов и дистанции между ними




Рисунок 9 – Плоскости для векторов входа

Векторы входа, как правило, распределяются неравномерно в силу того, что решаемая задача имеет нелинейный характер, а нейроны на карте Кохонена будут иметь тенденцию распределяться в соответствии с плотностью размещения векторов входа. Таким образом, при обучении карты Кохонена решается не только задача кластеризации входных векторов, но и выполняется их классификация. Результат обучения приведен на рисунке 10.




Рисунок 10 – Результат обучения карты Кохонена

Из рисунка 10 видно, что обучение карты дало четкое разбиение входных векторов на соответствующие кластеры и достаточно точно выявлены центры классов. В классах расположено различное число входных векторов, то есть каждый нейрон сети победил определенное число раз исходя из всего массива входных векторов. Частота выигрышей нейронов приведена на рисунке 11. Нумерация нейронов читается, слева направо, начиная с нижнего ряда.

В итоге вся сеть сконфигурирована, построена и обучена, но для окончательного убеждения в работоспособности сети необходимо ее протестировать на входных векторах, не относящихся к векторам обучения. Зададим сети несколько векторов и посмотрим, правильно ли она будет разбивать их по классам: $[0,8; 0,5] \rightarrow 5$; $[0,9; 0,9] \rightarrow 1$; $[0,85; 0,28] \rightarrow 4$; $[0,6; 0,01] \rightarrow 6$; $[0,95; 0,4] \rightarrow 4$; $[1,0; 1,0] \rightarrow 1$. Сеть распределила вектора по классам верно, следовательно, карта Кохонена работает правильно.

РЕЗУЛЬТАТЫ ДИАГНОСТИРОВАНИЯ ЛОПАТОК 1-Й СТУПЕНИ РККНД

Выходные классы (нейроны)	1	2	3	4	5	6	7	8
Частота выигрышей нейронов	1	2	6	1	2	4	1	3
Состояние вибрации	a	b	c	d	e	f	g	h




Рисунок 11 – Частота выигрышей нейронов карты Кохонена

При обработке данных нейронная сеть не знает, что она обрабатывает, она просто разбивает их на классы. Теперь нам необходимо распределить эти классы по состояниям, которые будут отвечать за различные дефекты или же исправное состояние ГТД. Это осуществляется на основании экспертных оценок, которые представляют собой систему принятия решения. Система принятия решения жестко связана с классами нейронной сети Кохонена.

Как уже было сказано выше, работа нейронной сети рассматривается на примере лопаток 1-й ступени РККНД и результаты диагностирования приведены в таблице 2.

Вывод: в данной работе были выявлены проблемные области исследования диагностики авиационной техники (АТ), рассмотрены источники и причины возбуждения изделий, а также определены методы анализа вибрации.

Список литературы

- 1 Сидоренко М.К. Виброметрия газотурбинных двигателей. - М.: Машиностроение, 1978.
- 2 <http://www.vibrocenter.ru/atlant8.htm>
- 3 Многоканальный синхронный регистратор Атлант. Руководство пользователя. Пермь, «Вибро-Центр», 2007.
- 4 Быстрое преобразование Фурье и алгоритмы вычисления свертки: Пер. с англ. – М.: Радио и связь, 1985. – 248 с., ил.
- 5 Продукция компании Texas Instruments. [Электронный ресурс]. Режим доступа: <http://www.ti.com>
- 6 Медведев В.С., Потемкин В.Г. Нейронные сети. Matlab 6/Под общ. ред. к.т.н. В.Г. Потемкина. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.
- 7 Миркес Е.М. Нейрокомпьютер. Проект стандарта. – Новосибирск: Наука, Сибирская издательская фирма РАН, 1998. – 189 с.
- 8 Статья Самоорганизующиеся нейронные сети. [Электронный ресурс]. Режим доступа: http://www.dall-analytika.ru/articles/articles_5.html
- 9 ГОСТ Р ИСО 10816-4-99. Контроль состояния машин по результатам измерения вибраций на не вращающихся частях. Часть 4. Газотурбинные установки. Госстандарт России. Москва. ИПК. Издательство стандартов, 2000. – 16 с.