

# НЕЙРОСЕТЕВОЙ АЛГОРИТМ КЛАССИФИКАЦИИ В УСЛОВИЯХ МАЛОЙ ВЫБОРКИ В ЗАДАЧЕ КОНТРОЛЯ УСТАЛОСТНОГО РАЗРУШЕНИЯ ТОНКОСТЕННЫХ КОНСТРУКЦИЙ

Кацин А.С., Коробкова С.В., Куравский Л.С.

Научный Центр Нейрокомпьютеров,  
ООО РусАвиа

Высокие уровни нагрузок в акустическом диапазоне частот являются причиной усталостных повреждений элементов авиационных конструкций и выхода из строя бортовой аппаратуры. Наибольшее влияние акустические нагрузки оказывают на тонкостенные элементы конструкции летательного аппарата. Нагрузки носят случайный характер, их уровни в разных точках поверхности летательного аппарата могут составлять 145-170 дБ, при широком частотном диапазоне (до 5000 Гц).

В данной работе осуществляется постановка задачи, описание методики решения и приводятся результаты экспериментов распознавания состояний виброакустической системы с помощью нейронных сетей в случае малой обучающей выборки, используя в качестве входных данных нормированные оценки спектральных плотностей напряжений в контрольных точках конструкции.

## ФИЗИЧЕСКАЯ ПОСТАНОВКА ЗАДАЧИ

Исследования в области контроля усталостного разрушения тонкостенных конструкций стало уделяться большое внимание с середины 50-х годов, что было связано с массовым характером усталостных повреждений авиационных конструкций от акустических нагрузок, обусловленным ростом скоростей полета и переходом от поршневых к турбореактивным и турбовинтовым двигателям.

При описании реакции конструкции на указанные нагрузки часто применяется термин «акустические вибрации», который относится как к пульсациям акустического происхождения, связанным с распространением звука, так и к пульсациям, не вызывающим существенного звукового излучения.

В последнее время интерес к акустическим вибрациям усилился в связи с разработкой нового поколения пассажирских самолетов и гиперзвуковых летательных аппаратов. Экспериментальные исследования акустических вибраций, проводимые на специальных стендах и в процессе наземных и летных испытаний как правило отличаются высокой стоимостью, трудоемкостью и продолжительностью. Кроме того, сложности воспроизведения акустических вибраций в условиях эксперимента побуждают применять компьютерные методы моделирования и обработки информации. Одним из подходов является сравнение результатов моделирования и натурных испытаний, для чего часто оказывается вполне достаточно тех неполных данных, которые получаются в результате измерений, проведенных при натурных испытаниях.

В этой работе описывается алгоритм классификации неисправностей конструкции по значениям признаков, полученным при измерениях.

Исходными данными для обработки является вектор из 10 признаков, который должен быть отнесен к одному из 7 классов:

1. ОК – неповрежденная конструкция.
2. CENTER
3. LEFT
4. RIGHT
5. BOUND
6. R\_C
7. L\_C

Первое из указанных состояний соответствует нормальному режиму работы, а последующие 6 – рассматриваются как варианты конструкции с неисправностями.

## МАТЕМАТИЧЕСКАЯ ПОСТАНОВКА ЗАДАЧИ

Дана совокупность числовых характеристик  $X$  (параметры, характеризующие объект исследования), влияющих на набор значений функций  $F_i(X)$  (функции  $F_i(X)$  - принадлежность состояния объекта исследования классу  $i$ ).  $M$  - количество векторов характеристик исследуемого объекта.  $X$  представляет собой множество векторов характеристик  $X = \{X^n, n = 1..M\}$ . Размерность каждого вектора  $X^n$  равна  $N$ .

Функция  $F_i(X)$  может принимать значения 1 или 0 в зависимости от того, принадлежит ли данный вектор фиксированному в данный момент классу  $i$  ( $i = 1..k$ ).

В этой работе построение нейросетевого алгоритма и исследование его эффективности проводилось при  $k = 7$ ,  $N = 10$ ,  $M = 7 \cdot 24$ .

Требуется для произвольного вектора  $X^*$  вычислить функции  $F_i(X^*)$  для каждого из семи классов.

### АЛГОРИТМ РЕШЕНИЯ ЗАДАЧИ НА НЕЙРОННОЙ СЕТИ

На входе мы имеем выборку в десятимерном пространстве признаков ( $N = 10$ ), состоящую из 7-ми классов по 24 образа в каждом. Такого количества образов явно недостаточно для правильной работы нейронной сети. Идея состоит в том, чтобы “размыть” каждый образ до необходимого размера. Для этого распределим нормально, к примеру, 500 образов с заданными распределением и математическим ожиданием  $\sigma$  и  $m$  соответственно, равным исходному образу.

Существует множество методов получения набора чисел, распределенных по нормальному закону ( $m = 0, \sigma = 1$ ) на основании данных значений  $U_i$ , распределенных равномерно. Воспользуемся формулой Бокса-Мюллера. К примеру, зададим один образ для  $N = 2$ . Для этого нужно произвольным образом выбрать числа  $U_1, U_2, U_3, U_4$  из интервала  $(0,1]$ . Тогда:

$$X1 = \sqrt{-2 \log U_1} \cos(2\pi U_2)$$

$$X2 = \sqrt{-2 \log U_3} \cos(2\pi U_4)$$

(где  $X1, X2$  – координаты образа.)

Необходимо выполнить процесс для каждого из исходных образов. На рис. 1 изображён пример “размытия” 10-ти образов в  $N = 2$  с  $\sigma = 0.25$ .

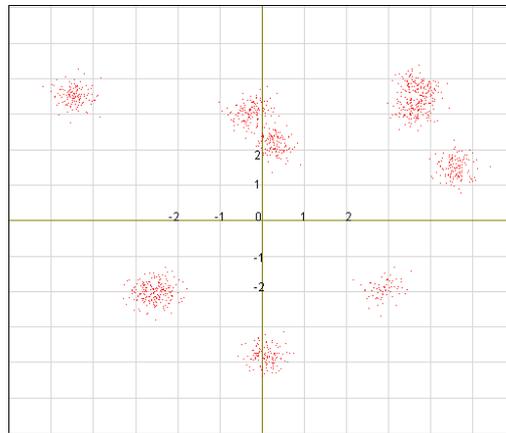


Рис. 1. Размытие 10 образов

### ОБУЧЕНИЕ ПЕРВОГО СЛОЯ НЕЙРОННОЙ СЕТИ С ПЕРЕМЕННОЙ СТРУКТУРОЙ

После того, как мы получили обучающую выборку необходимых размеров, приступим к обучению нейронной сети. Воспользуемся алгоритмом обучения для нейронной сети с переменной структурой. В нашем случае достаточно будет архитектуры нейронной сети с одним первым слоем с переменным числом нейронов. Для описания алгоритма воспользуемся рис. 2.

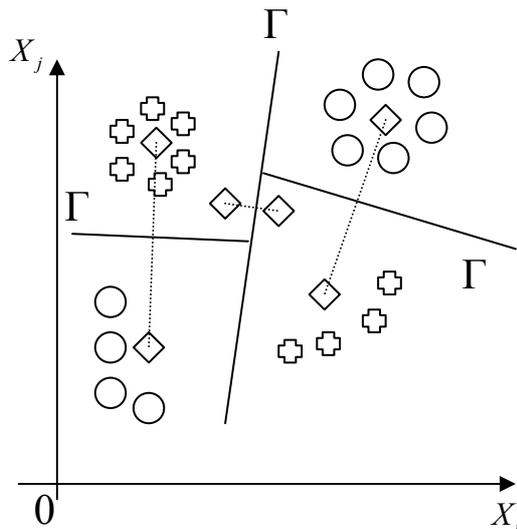


Рис. 2. Разделение классов гиперплоскостями

На рис. 2 изображена проекция  $N$ -мерного пространства признаков на оси  $X_i, X_j$ .

Итак, мы имеем 2 класса точек: “Крестики” и “Нолики”. Найдём геометрический центр точек 1-го класса и отдельно геометрический центр точек 2-го класса. На рисунке они показаны наиболее близкими друг к другу “ромбиками”. Далее проведём отрезок, соединяющий “ромбики”. Теперь через его центр проводим гиперплоскость [Г1] перпендикулярно отрезку.

Все точки, лежащие выше [Г1], относятся к первому классу, ниже – ко второму.

Соответственно у нас возникают неправильно определённые точки как выше, так и ниже гиперплоскости. Находим максимальную ошибку, и работаем далее в той части пространства, в которой она обнаружена. В данном случае - выше [Г1].

Находим геометрические центры образов разных классов, теперь уже только тех, которые лежат в заданной области (на рисунке они показаны 2-мя ромбиками выше [Г1]). Далее проводим ещё одну гиперплоскость [Г2] и считаем, что подобласть выше [Г2] относится к 1-му классу, ниже – 2-му. Следовательно все точки находящиеся выше [Г1] определены без ошибок. Остаётся только аналогично [Г2] провести недостающую гиперплоскость [Г3].

Итак, пространство разделено без ошибок. Для наглядного представления удобно параллельно делению создавать так называемое “Логическое дерево” (рис.3).

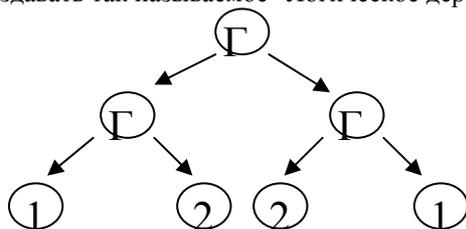


Рис. 3. Логическое дерево

Возьмём, к примеру, узел “Г2”. Из него выходит две ветви. Область выше [Г2] проходит по правой ветви, ниже – по левой.

Процесс деления заканчивается когда суммарная ошибка обучения равна 0.

Мы разобрались, как решить задачу с двумя классами образов. Для применения этого алгоритма к нашей задаче достаточно каждый из семи классов отделять от оставшихся шести, то есть за первый класс взять фиксированный класс, а за второй – все оставшиеся.

Теперь нам остается определить процесс задания  $\sigma$  для размытия исходной выборки. Для начала определим минимальное расстояние между образами фиксированного класса и образами остальных классов ( $L_{\min}$ ). Далее будем задавать  $\sigma$  в процентах от  $L_{\min}/2$ . Для экспериментов выбраны значения  $\sigma$ : 30%, 50%, 70%.

### РЕЗУЛЬТАТЫ

Вышеописанный алгоритм был реализован в виде программы на VB. Каждая точка была размыта, так что из исходных 24 векторов, или точек в 10-мерном пространстве, в каждом из 7 классов была получена выборка из  $7 \cdot 24 \cdot 500 = 84000$  векторов.

Для классификации была выбрана шестислойная нейронная сеть переменной структуры. Количество нейронов первого слоя изменяется в процессе обучения, количество нейронов в остальных слоях постоянно.

Критерием обученности нейронной сети является равенство нулю ошибки распознавания.

Построим зависимости ошибки распознавания на обучающей выборке от количества нейронов первого слоя для различных  $\sigma$  для двух классов – ОК, LEFT.

Сплошная линия - 70%;

Длинный пунктир - 50%;

Короткий пунктир - 30%.

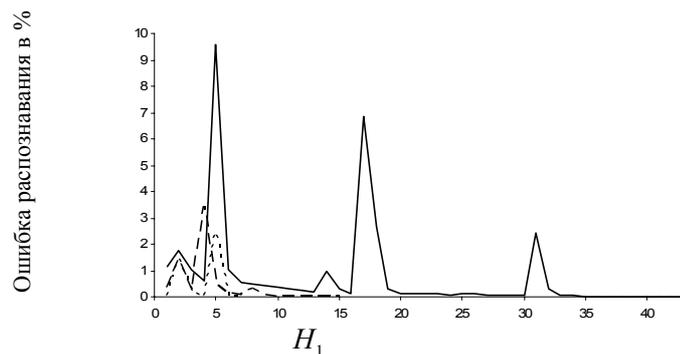


Рис. 4. График ошибки распознавания в процентах в зависимости от количества нейронов первого слоя  $H_1$  для класса ОК

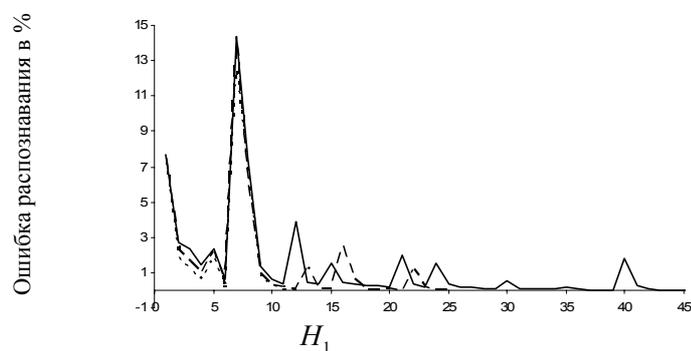


Рис. 5. График ошибки распознавания в процентах в зависимости от количества нейронов первого слоя  $H_1$  для класса LEFT

При этом на тестовой выборке, которая составляет 30% от обучающей выборки, было правильно распознано 100% точек.

#### ВЫВОДЫ

Данная методика позволяет получить параметры обученной нейронной сети объективно более адекватные для решения задачи распознавания, нежели полученные при обучении нейронной сети на малой выборке.

Оптимальный уровень размытия, то есть  $\sigma$ , должен выбираться отдельно для каждой конкретной задачи.

#### ЛИТЕРАТУРА

1. Галушкин А.И. Синтез многослойных систем распознавания образов. Энергия, Москва, 1974.
2. Баранов С.Н., Куравский Л.С. Акустические вибрации тонкостенных конструкции: моделирование, оптимизация и диагностика. ООО РусАвиа, 2001.
3. Галушкин А.И. Нейронные сети и проблема малой выборки. V Всероссийская конференция «Нейрокомпьютеры и их применение», 1999.