

Глава 10

ДИАГНОСТИКА И ПРОГНОЗИРОВАНИЕ УСТАЛОСТНОГО РАЗРУШЕНИЯ АВИАЦИОННЫХ КОНСТРУКЦИЙ

1. МОДЕЛИ И МЕТОДЫ: ОБЩАЯ ХАРАКТЕРИСТИКА

1.1. ПОСТАНОВКА ЗАДАЧИ

Высокие уровни нагрузок в акустическом диапазоне частот являются причиной усталостных повреждений элементов авиационных конструкций и выхода из строя бортовой аппаратуры. Исследованиям в этой области стало уделяться большое внимание начиная 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. В последнее время интерес к этой проблеме вновь усилился в связи с разработкой нового поколения сверхзвуковых пассажирских самолетов и гиперзвуковых летательных аппаратов.

Наибольшее влияние акустические нагрузки оказывают на тонкостенные элементы конструкции летательного аппарата. Их основные источники – это пульсации давления в турбулентном пограничном слое, шум струй двигателей, шум винтов и пульсации давления при бафтинге. 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 главе рассматриваются способы диагностики усталостного разрушения акустически нагруженных тонкостенных конструкций с применением нейронных сетей. Решение этой задачи дает возможность снизить временные и материальные затраты на эксплуатацию летательных аппаратов, повысить надежность контроля за разрушением элементов конструкции, упростить регламентные работы.

Описываемый подход предполагает оценку степени разрушения по изменениям *распределенной жесткости*, распознаваемой, в свою очередь, по качественным изменениям нормированных *спектральных характеристик* параметров, измеряемых *тензодатчиками* или *акселерометрами* в контрольных точках. Нормировка позволяет анализировать только качественную форму реакции конструкции, не учитывая уровень нагрузки.

Такой подход, основанный на оценке усредненных свойств конструкции, представляется более перспективным, чем поиск отдельных трещин [14, 25], которые не всегда могут наблюдаться непосредственно и, имея большой разброс в динамике своего развития, труднопрогнозируемы. Использование в качестве контрольных параметров вторичных характеристик (спектров), а не исходных временных реализаций обусловлено тем, что

- они представительны, сохраняя достаточно много полезной информации об исследуемом процессе,
- требуют гораздо меньше памяти при цифровой форме представления,
- при современном уровне технологии легко и быстро вычисляются с контролируемой точностью.

1.2. ТЕХНОЛОГИЯ МОНИТОРИНГА

Компоненты используемой технологии мониторинга, обеспечивающей диагностику как известных ранее, так и впервые появляющихся видов усталостных разрушений, представлены на рис. 1.

Поскольку полагается, что заранее не всегда возможно предсказать ни все возможные виды разрушений, ни те изменения, которые они вызовут в спектральных характеристиках, использовать для диагностики только нейронные сети с *управляемым процессом обучения* невозможно. Поэтому в схеме предусмотрена возможность применения одной из разновидностей нейронных сетей с *неуправляемым процессом обучения* – *самоорганизующихся карт Кохонена (self-organizing feature maps)* [17, 18], обучающие данные для которых содержат значения только входных переменных.

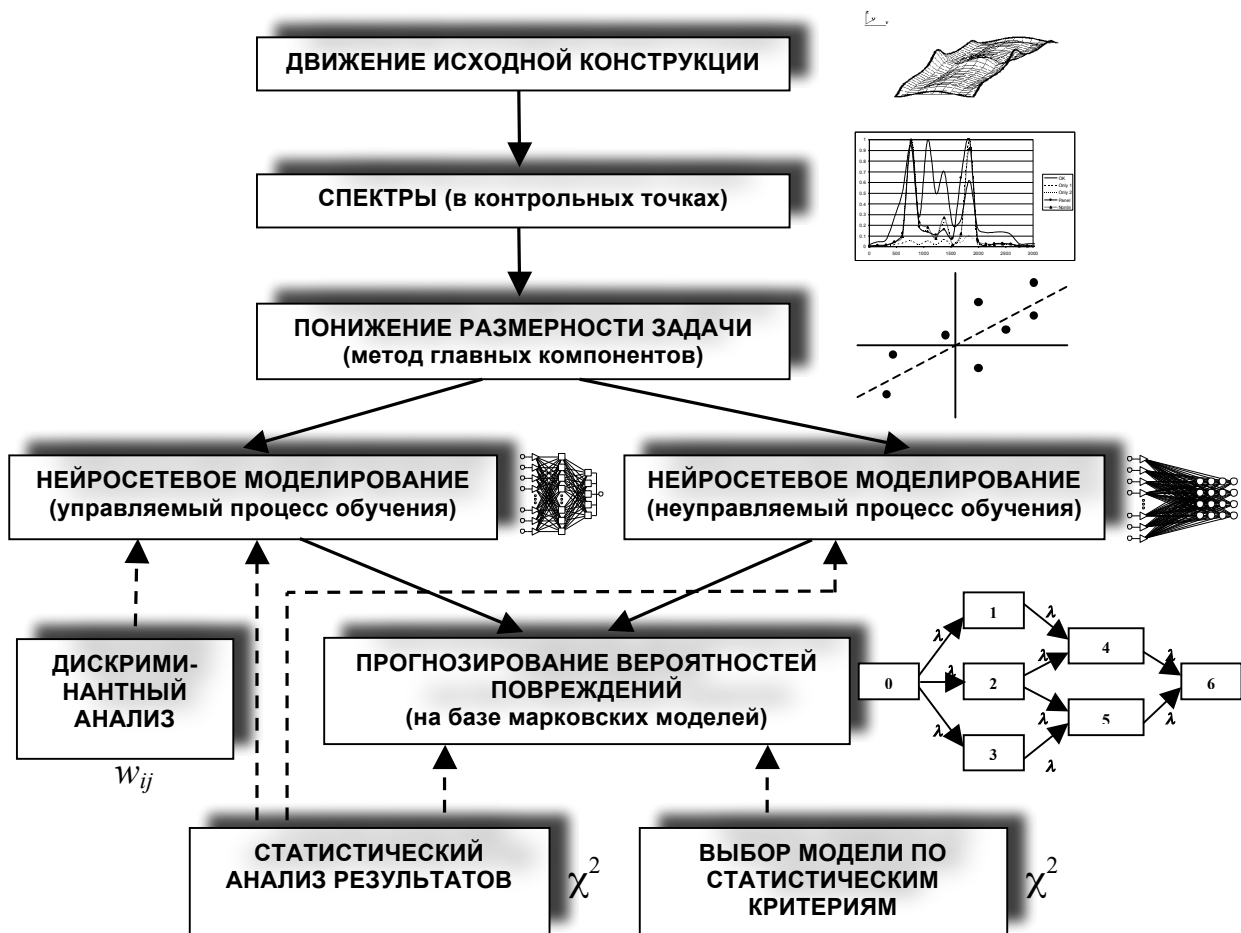


Рис. 1. Компоненты технологии мониторинга.

1.3. САМООРГАНИЗУЮЩИЕСЯ КАРТЫ КОХОНЕНА

Карты Кохонена являются одним из видов нейронных сетей с конкурентным обучением (*competitive learning*). Они имеют два слоя - входной и выходной. Входной слой выполняет распределительные функции. Выходной слой этих сетей, называемый также слоем *топологической карты*, образует прямоугольную матрицу, составленную из *радиальных элементов* (тип нейронов).

При последовательной обработке каждого обучающего примера выбирается расположенный ближе всего к нему нейрон (*выигравший нейрон*). Затем, взяв взвешенную сумму прежнего центра соответствующего радиального элемента и обучающего примера, параметры выигравшего нейрона и нейронов из его окрестности корректируются так, чтобы они стали в большей степени похожи на

входной пример. Результатом последовательности таких корректировок является то, что определенные участки сети «перетягиваются» в сторону обучающих примеров и похожие наблюдения активируют группы близко лежащих нейронов на топологической карте. Таким образом, сеть учится «понимать» структуру входных данных. Ее идея появилась по аналогии с ассоциативными свойствами человеческого мозга.

Формально процедуру обучения можно представить в виде следующей последовательности шагов:

1. Координатам центров радиальных элементов W_p приписываются случайные начальные значения.
2. Задаются начальные значения радиуса окрестности корректировки (S), номера входного примера ($k=1$) и номера эпохи ($t=1$).
3. Для текущего входного примера X_k в заданной метрике вычисляются расстояния $D_{k,p}(X_k, W_p)$ между ним и каждым из элементов сети.
4. Выбирается нейрон с минимальным расстоянием $D_k = \min_p D_{k,p}$ (нейрон-победитель).
5. Производится модификация весовых коэффициентов:

$$W_p(t+1) = W_p(t) + \gamma(t)h(t, k, p, s)(X_k - W_p(t)),$$
 где невозрастающая функция $\gamma(t)$ характеризует скорость обучения в момент времени t (иногда полагают $\gamma(t)=1/t$); функция $h(t, k, p, s)$ равна единице для всех нейронов из окрестности радиуса S нейрона-победителя k и равна нулю в противном случае.
6. Номер входного примера k увеличивается на единицу. Если $k \leq K$, где K - общее число обучающих примеров, то переход к шагу 3, иначе переход к шагу 7.
7. Номер эпохи t увеличивается на единицу. Радиус окрестности корректировки S уменьшается. Если значение t не превысило заданного числа эпох обучения, то переход к шагу 3, иначе окончание обучения.

Если разбиение входных данных на классы полностью или частично известно, части нейронов топологической карты могут быть приписаны соответствующие метки.

При решении задачи классификации в карте Кохонена задается так называемый *порог доступа*. Он определяет наибольшее расстояние, на котором происходит распознавание. Если расстояние от выигравшего нейрона до наблюдения на входе превышает этот порог, то считается, что сеть не приняла никакого решения. Когда нейроны помечены, а пороги установлены на нужном уровне, сеть может служить детектором новых явлений: она сообщает о непринятии решения только в том случае, если параметры поданного на вход наблюдения значительно отличаются от параметров всех помеченных ранее радиальных элементов. Таким образом, обеспечивается диагностика как известных ранее, так и впервые появляющихся видов неисправностей.

Пример, иллюстрирующий процесс обучения и диагностики виброакустических систем на базе карт Кохонена, представлен на рис. 2 - 4. Наблюдаемая система представляла собой панель воздухозаборника маневренного самолета с двумя динамическими гасителями колебаний. Ее состояние оценивалось по спектрам ускорений в контрольных точках. Распознавались следующие состояния: **OK** – работают оба гасителя, **Only1** – гаситель 2 неисправен, **Only2** – гаситель 1 неисправен, **Panel** – оба гасителя неисправны, **Nonlin** – нелинейная реакция гасителя (удар подвижной части об ограничитель). Первое из указанных состояний соответствовало нормальному режиму работы, а последующие четыре - рассматривались как варианты работы системы с неисправностями.

Для повышения качества распознавания одновременно применялись дублирующие друг друга сети разной структуры. Исходные варианты карт Кохонена с размерностями выходных слоев 3×3, 4×4 и 7×7 обучались для распознавания состояний **OK** и **Only1**. Далее последовательно возникали неисправности **Only2**, **Panel** и **Nonlin**. После обнаружения нового вида неисправностей обучение проводилось заново с присвоением элементам топологических карт соответствующих меток (рис. 3). На рис. 4 представлен график, показывающий характерную динамику изменения среднеквадратических ошибок обучения и верификации.