

# РЕШЕНИЕ ЗАДАЧ ПРОГНОЗИРОВАНИЯ СОСТОЯНИЯ И УПРАВЛЕНИЯ ЖИЗНЕННЫМ ЦИКЛОМ СЛОЖНЫХ ТЕХНИЧЕСКИХ КОМПЛЕКСОВ МЕТОДАМИ РАСПОЗНАВАНИЯ ОБРАЗОВ

УДК 681.3.06

**Геннадий Александрович Беркетов,**  
к.т.н., профессор, проф. каф. Автоматизированных систем обработки информации и управления Московского государственного университета экономики, статистики и информатики (МЭСИ)  
Тел.: (495) 442-61-11  
Эл. почта: GABerketov@mesu.ru

**Андрей Александрович Микрюков,**  
к.т.н., доцент, зав. каф. Автоматизированных систем обработки информации и управления Московского государственного университета экономики, статистики и информатики (МЭСИ)  
Тел.: (495) 442-61-11  
Эл. почта: AMikrukov@mesu.ru

**Анатолий Петрович Цуркин,**  
к.ф.м.н., доцент, проф. кафедры Автоматизированных систем обработки информации и управления Московского государственного университета экономики, статистики и информатики (МЭСИ)  
Тел.: (495) 442-61-11  
Эл. почта: APCurkin@mesu.ru

В статье рассматривается математическая модель оценивания и прогнозирования состояния сложной технической системы на основе использования методов распознавания образов. Предложены алгоритмы распознавания на основе сопоставления измеренного вектора признаков с априорным описанием классов состояний объектов, по результатам чего принимается решение о принадлежности текущего состояния объекта к одному из классов. Разработанные алгоритмы могут использоваться при решении задач управления жизненным циклом сложных технических комплексов.

**Ключевые слова:** прогнозирование состояния, классы технического состояния, вектор параметров объекта, логические методы распознавания образов, решающее правило.

**Gennady A. Berketov,**  
PhD in Technical Sciences, Professor, Department of Automated Control Systems, Moscow State University of Economics, Statistics and Informatics (MESI)  
Tel.: (495) 442-61-11  
E-mail: GABerketov@mesu.ru

**Andrei A. Mikrukov**  
PhD in Technical Sciences, Associate Professor, Head of Department, Department of Automated Control Systems, Moscow State University of Economics, Statistics and Informatics (MESI)  
Tel.: (495) 442-61-11  
E-mail: AMikrukov@mesu.ru

**Anatoly P. Tsurkin**  
PhD in Physical and Mathematical Science, Associate Professor, Professor, Department of Automated Control Systems, Moscow State University of Economics, Statistics and Informatics (MESI)  
Tel.: (495) 442-61-11  
E-mail: APCurkin@mesu.ru

In article the mathematical model of estimation and forecasting of a condition of difficult technical system based on the use of methods of images recognition is considered. Recognition algorithms based on comparison of the measured vector of signs to the aprioristic description of objects classes' conditions are offered. The decision on accessory of current object state to one of classes is made by results of recognition algorithms. The developed algorithms can be used as the solution of management problems of difficult technical complexes life cycle.

**Keywords:** prediction of the state, classes technical condition, the vector object parameters, logical methods of pattern recognition, the decision rule.

## 1. Введение

Задача прогнозирования состояния сложных технических комплексов (СТК) в настоящее время приобрела важное практическое значение, что обусловлено старением оборудования многих из действующих СТК и отсутствием достаточных средств для их замены или капитального ремонта. На основе оценки остаточного ресурса элементов СТК может быть организовано управление его техническим состоянием. В частности, могут быть организованы выборочные ремонтно-профилактические работы (РПР) в первую очередь на оборудовании, отказ которого может привести к возникновению аварийных или критических ситуаций.

Остаточный ресурс СТК определяется величиной наработки до его перехода в предельное состояние. При этом под предельным состоянием СТК понимается такое его состояние, при котором он не способен выполнять целевые задачи с заданным качеством. Наиболее часто в качестве признаков перехода СТК в предельное состояние используют:

- неустранимое снижение уровня безотказности функционирования;
- недопустимое возрастание эксплуатационных расходов на обеспечение функционирования.

При продлении сроков эксплуатации СТК необходимо уметь оценивать текущее состояние его элементов, то есть относить их к тому или иному классу возможных состояний и прогнозировать сроки их перехода в предельное состояние. Основные трудности при решении этой задачи обусловлены следующим.

Предположения о свойствах модели отказов оборудования, принимаемые при расчетах надежности оборудования в пределах гарантийного ресурса, оказываются слишком упрощенными и даже неприемлемыми за его пределами. Различные параметры оборудования при его длительной эксплуатации могут влиять друг на друга, и тогда причиной отказа может оказаться не только недопустимое отклонение некоторого параметра, но и неблагоприятное сочетание значений нескольких параметров, при том условии, что каждый из параметров находится в пределах допусков. При этом отказ одного элемента оборудования может привести к цепочке отказов других (кратный отказ). Заметим, что возможность возникновения таких ситуаций редко учитывается при проектировании средств диагностики, рассчитанных на использование в пределах гарантийных сроков эксплуатации СТК.

Обычно традиционные программы поддержания работоспособности СТК недостаточно полно учитывают конкретные условия эксплуатации его компонент, но, как показывает практика, именно они могут стать причиной отказов. Многие факторы внешней среды имеют кумулятивный характер, то есть их воздействие на работоспособность определяется суммарной экспозицией (суммарной длительностью воздействий). Примерами вредных воздействий кумулятивного характера могут быть:

- изменение характеристик электронной аппаратуры под влиянием повышенной или пониженной влажности;
- возникновение трещин и механических повреждений в результате изменения температуры и воздействия длительной вибрации и многое другое.

Для большинства элементов СТК исходная информация о закономерностях изменения их параметров в процессе эксплуатации чрезвычайно мала. Вследствие этого известные методы прогнозирования, использующие классический аппарат математической статистики и теории случайных процессов, в практике прогнозирования состояния СТК за пределами гарантийных сроков могут найти лишь ограниченное применение.

Для более надежного прогнозирования остаточного ресурса СТК после длительной эксплуатации необходимо следующее:

- расширение исходной информационной базы за счет проведения комплексного обследования подсистем СТК;
- проведение мониторинга последующей эксплуатации СТК;
- разработка новых методов прогнозирования, дополняющих уже известные.

Возможности для расширения информационной базы в настоящее время существенно увеличились: разработаны новые методы неразрушающего контроля, программно-технические средства реализации которых выпускает промышленность; достижения микроэлектроники позволяют встраивать в оборудование малогабаритные устройства, которые могут записывать и хранить большие объемы информации об условиях работы оборудования и его параметрах на длительном интервале времени; компьютерные сетевые технологии дают возможность производить быстрый обмен и анализ информации.

Ведутся также и исследования, направленные на разработку новых методов прогнозирования. Одним из перспективных направлений решения задач оценивания и прогнозирования технического состояния СТК является использование моделей и методов распознавания образов. В статье рассматриваются методы оценивания и прогнозирования технического состояния СТК, основанные на указанном подходе.

## 2. Модель распознавания состояний СТК и методы формирования решающего правила

В начале (с целью иллюстрации основных понятий) приведем общее описание модели распознавания технического состояния (ТС) объектов.

Под классом технического состояния понимается подмножество множества возможных значений вектора параметров объекта, которое соотносится с некоторой содержательной интерпретацией условий, при которых объект еще может использоваться по своему назначению. Например, пространство состояний некоторой подсистемы или компоненты оборудования СТК могут разделяться на

следующие классы, соотнесенные с условиями возможного использования:

- подсистема исправна и работоспособна;
- подсистема работоспособна, но содержит неисправности;
- подсистема неработоспособна, но ее работоспособность может быть восстановлена при выполнении ремонтно-профилактических работ;
- подсистема неработоспособна, ее работоспособность может быть восстановлена только при выполнении капитального ремонта;
- подсистема работоспособна, но ее дальнейшая эксплуатация нецелесообразна из-за низкого качества функционирования и больших эксплуатационных затрат;
- подсистема работоспособна, но ее дальнейшая эксплуатация нецелесообразна по соображениям безопасности.

Множество классов состояний диагностируемого объекта будем обозначать через  $Q = \{q_1, q_2, \dots, q_m\}$ .

При распознавании ТС объекта его физические характеристики преобразуются в вектор признаков  $X = (x_1, x_2, \dots, x_n)'$ , которые характеризуют данное состояние (штрихом здесь обозначена операция транспонирования). Переменные  $x_i$  называют также диагностическими параметрами объекта. Множество возможных значений вектора  $X$  называется пространством признаков.

Система распознавания на основании сопоставления измеренного вектора признаков с априорным описанием классов состояний объекта принимает решение о принадлежности текущего состояния этого объекта к одному из классов.

Правило, которое каждому вектору признаков ставит в соответствие определенное наименование класса, называют решающим правилом.

Параметры (признаки) состояния объектов обычно имеют стохастический характер, их значения могут с некоторой вероятностью распределяться по нескольким классам состояния, поэтому в процессе распознавания возможны случайные ошибки.

Считается, что система распознавания допускает ошибку в том случае, если она относит к классу  $q_i$  состояние, на самом деле принадлежащее другому классу  $q_j$ .

Признаки, используемые при оценке технического состояния СТК, могут измеряться в различных шкалах: коли-

чественной (числовой), ordinalной (порядковой) и номинальной. В теории измерений номинальные шкалы считаются простейшими и самыми «бедными» (их называют также шкалами наименований или классификационными шкалами). Если обозначить числами возможные значения номинального признака, то эти числа будут иметь смысл только абстрактных символов, обозначающих вариант реализации признака, и никакие другие отношения между указанными числами, кроме их равенства, значения не имеют. При сравнении двух значений признака, измеряемого в номинальной шкале, можно сделать лишь вывод о совпадении или несовпадении значений. Поэтому при анализе таких признаков каждую отметку номинальной шкалы считают отдельным самостоятельным признаком. Он принимает всего два значения  $A$  и  $B$ . Чаще всего полагают, что  $A = 0$  и  $B = 1$ . Такие признаки называют дихотомическими, бинарными или булевыми (логическими). После проведения дихотомизации номинальные признаки становятся доступными для применения различных методов количественного многомерного анализа, учитывающих их специфику.

Для ординарных признаков существенен лишь порядок градаций на шкале, и для них считаются допустимыми любые монотонные преобразования, не нарушающие этот порядок.

Описанные выше особенности способов формирования признаков следует учитывать при выборе диагностической модели и методов эмпирико-статистической оценки ее параметров.

Рассмотрим модель распознавания состояний СТК и методы формирования решающего правила для случая, когда все признаки измеряются в непрерывной числовой шкале. Более общий случай будет рассмотрен позже.

Основой статистического подхода к задаче классификации образов в числовом признаковом пространстве является статистическая теория принятия решений. Этот подход основан на предположении, что задача выбора решения формулируется в терминах теории вероятностей и известны все представляющие интерес вероятностные величины.

Пусть  $Q = \{q_1, q_2, \dots, q_m\}$  – множество рассматриваемых классов ТС оцениваемого объекта;  $\lambda_{ij}$  – потери, связанные с ошибочным отнесением

состояния класса  $q_i$  к классу  $q_j$ . Каждому классу  $q_i$  в пространстве признаков  $R^n$  соответствует множество  $D_i$  – образ класса. Вектор признаков  $X = (x_1, x_2, \dots, x_n)'$  является многомерной случайной величиной. Заданы условные плотности  $p(X/q_i)$  распределения вероятностей вектора  $X$  в предположении его принадлежности к классу  $q_i$ . Пусть также заданы априорные вероятности  $P(q_i)$  принадлежности объекта к соответствующим классам  $q_i$ . Тогда апостериорная (после измерения параметров и вычисления вектора признаков  $X$ ) вероятность принадлежности состояния объекта к классу  $q_i$  может быть вычислена с помощью байесовского правила

$$P(q_i/X) = P(q_i)p(X/q_i)/p(X), \quad (1)$$

где

$$p(X) = \sum_{i=1}^m p(X/q_i). \quad (2)$$

Предположим, что вектор  $X$  был классифицирован как образ состояния, принадлежащего классу  $q_j$ . Так как  $X$  на самом деле может принадлежать любому из  $m$  рассматриваемых классов, то математическое ожидание потерь, связанных с отнесением образа  $X$  к классу  $q_j$ , определяется следующим выражением:

$$r_j(X) = \sum_{i=1}^m \lambda_{ij} P(q_i/X). \quad (3)$$

В теории статистических решений эту величину называют *условным средним риском или условными средними потерями*.

С учетом (1) выражение (3) преобразуется к виду

$$r_j(X) = \frac{1}{p(X)} \sum_{i=1}^m \lambda_{ij} P(q_i) p(X/q_i). \quad (4)$$

В целом качество классификации можно оценить *общим средним риском*

$$r(X) = \frac{1}{p(X)} \sum_{j=1}^m \sum_{i=1}^m \lambda_{ij} P(q_i) p(X/q_i) \quad (5)$$

При распознавании каждого образа решающее правило (классификатор) может отнести его к одной из  $m$  возможных категорий. Если для каждого образа  $X$  вычисляются значения условных средних потерь  $r_j(X)$ ,  $j = 1, m$ , и классификатор причисляет его к классу, которому соответствуют минимальные условные средние потери, то очевидно, что и математическое ожидание полных потерь на множестве всех решений также будет минимизировано. Решающее правило, минимизирующее математическое ожидание

общих потерь, называется *байесовским решающим правилом (байесовским классификатором)*.

Заметим, что при фиксированном  $X$  величина  $1/p(X)$  является константой и поэтому её можно устранить из соотношений (4) и (5), что позволяет упростить вычисления.

Модифицированные формулы для вычисления условного риска имеют вид

$$R_j(X) = \sum_{i=1}^m \lambda_{ij} P(q_i) p(X/q_i), \quad (6)$$

$$R(X) = \sum_{j=1}^m \sum_{i=1}^m \lambda_{ij} P(q_i) p(X/q_i). \quad (7)$$

Важным частным случаем рассмотренной модели является модель дихотомической классификации, когда множество  $Q$  состоит всего из двух классов  $q_1$  и  $q_2$ . Такие модели, например, широко используются при диагностике сложных технических систем. Подобные модели используются также и при решении некоторых задач оценки и прогнозирования технического состояния СТК.

Дихотомические модели имеют сравнительно простую структуру и легче поддаются количественному анализу. Отметим также, что решение многоальтернативных задач распознавания часто сводится к схемам, в которых используются двухальтернативные решающие правила.

Пусть  $Q = \{q_1, q_2\}$ . Тогда при анализе образа  $X$  возможны два следующих решения:  $X$  относится к классу  $q_1$  или  $X$  относится к классу  $q_2$ . При выборе первого решения

$$R_1(X) = \lambda_{11} p(X/q_1) P(q_1) + \lambda_{21} p(X/q_2) P(q_2), \quad (8)$$

а при выборе второго

$$R_2(X) = \lambda_{12} p(X/q_1) P(q_1) + \lambda_{22} p(X/q_2) P(q_2). \quad (9)$$

Как отмечалось выше, байесовское решающее правило относит образ  $X$  к классу с наименьшим значением средних потерь. Поэтому образ  $X$  зачисляется в класс  $q_1$ , если выполняется условие  $R_1(X) < R_2(X)$ ; это означает, что

$$\begin{aligned} & \lambda_{11} p(X/q_1) P(q_1) + \\ & + \lambda_{21} p(X/q_2) P(q_2) < \\ & < \lambda_{12} p(X/q_1) P(q_1) + \\ & + \lambda_{22} p(X/q_2) P(q_2), \end{aligned} \quad (10)$$

или, что то же самое,

$$\begin{aligned} & (\lambda_{12} - \lambda_{11}) p(X/q_1) P(q_1) > \\ & > (\lambda_{21} - \lambda_{22}) p(X/q_2) P(q_2). \end{aligned} \quad (11)$$

Обычно считается, что  $\lambda_{ij} > \lambda_{ii}$  (иногда дополнительно полагают  $\lambda_{ii} = 0$ ). При этом допущении выражение (11) приводит к условию

$$\frac{p(X/q_1)}{p(X/q_2)} > \frac{P(q_2)(\lambda_{21} - \lambda_{22})}{P(q_1)(\lambda_{12} - \lambda_{11})}, \quad (12)$$

выполнение, которого определяет отнесение образа  $X$  к классу  $q_1$ . Левую часть неравенства (12) называют отношением правдоподобия или коэффициентом правдоподобия:

$$l(X) = \frac{p(X/q_1)}{p(X/q_2)}. \quad (13)$$

Правая часть неравенства

$$h = \frac{P(q_2)(\lambda_{21} - \lambda_{22})}{P(q_1)(\lambda_{12} - \lambda_{11})} \quad (14)$$

называется пороговым значением.

Байесовское решающее правило формулируется следующим образом:

- состояние диагностируемого объекта относится к классу  $q_1$ , если выполняется условие  $l(X) > h$ ;
- состояние диагностируемого объекта относится к классу  $q_2$ , если выполняется условие  $l(X) < h$ ;
- решение выбирается произвольным образом или привлекается дополнительная информация, если имеет место равенство  $l(X) = h$ .

Использование штрафных коэффициентов  $\lambda_{ij}$  имеет важное практическое значение.

Правильно подобранные коэффициенты штрафа позволяют минимизировать в первую очередь вероятности принятия неверных решений, которые могут привести к невыполнению объектом своих функциональных задач или к значительным экономическим потерям. Например, при тестировании технической системы с целью подтверждения безопасности её дальнейшей эксплуатации штраф за принятие решения, ведущего к продлению эксплуатации неисправной системы, должен быть выше, чем штраф за принятие неверного решения о приостановке её функционирования.

На практике наряду с вышеописанным правилом принятия решения часто используют так называемое правило максимума апостериорной вероятности. При заданном  $X$  апостериорная вероятность  $p(q_i/X)$  принадлежности состояния объекта к классу  $q_i$  вычисляется следующим образом:

$$P(q_i / X) = \frac{P(X / q_i)P(q_i)}{P(X)}, \quad (15)$$

где  $P(X) = \sum_{i=1}^m P(q_i)P(X / q_i)$  совместная плотность распределения вектора признаков.

Решение о принадлежности состояния к классу  $q_i$  принимается при выполнении условия, обеспечивающего минимум средней вероятности ошибки классификации.

Если рассматриваются два диагностических класса  $q_1$  и  $q_2$ , то решение  $q_1$  принимается при  $P(q_1 / X) < P(q_2 / X)$  и  $q_2$  при  $P(q_1 / X) > P(q_2 / X)$ . Это и есть правило максимума апостериорной вероятности.

Отношение правдоподобия имеет прежний вид

$$l(X) = P(X / q_1) / P(X / q_2),$$

а величина порога вычисляется по формуле

$$h = P(q_2) / P(q_1). \quad (16)$$

При практических вычислениях удобно использовать логарифм отношения правдоподобия, полагая

$$l(X) = \log \frac{P(q_1 / X)}{P(q_2 / X)}, h = \log \frac{P(q_2)}{P(q_1)}.$$

В формулы вычисления пороговых значений (14) и (16) входят величины априорных вероятностей  $P(q_i)$ . Обычно  $P(q_i)$  заранее не известны. При решении практических задач эти величины часто задаются на основании субъективных оценок исследователя. Более объективным следует считать подход, когда  $P(q_i)$  полагают пропорциональными объемам обучающих выборок из рассматриваемых классов. При полной неопределенности, в соответствии с принципом Бернулли, можно положить  $P(q_1) = P(q_2) = 1/2$ , т.е. принять порог равным единице ( $h = 1$ ). В этом случае мы приходим к правилу максимального правдоподобия.

В теории распознавания образов широко используется геометрическое представление о разделении диагностических классов в пространстве признаков. Считается, что для успешной классификации необходимо, чтобы образы состояний  $X$ , соответствующие классу  $q_i$ , концентрировались в некоторой области  $D_i$  пространства  $R^n$ . Дополнительно требуется, чтобы в каждую область  $D_i$  попадала лишь незначительная часть образов из других классов.

Построение решающего правила можно рассматривать как задачу поиска  $m$  непересекающихся областей  $D_i$  ( $i = \overline{1, m}$ ), удовлетворяющих вышеуказанным условиям. Если образ состояния  $X$  попадает в область  $D_i$ , то принимается решение о принадлежности состояния к классу  $q_i$ .

Нет необходимости в полном построении точных границ областей  $D_i$ ; для целей классификации достаточно указать лишь гиперповерхности, которые разделят эти области в пространстве признаков. Примеры подобного разбиения пространства для двумерного вектора  $X$  приведены на рис. 1 и 2. Для разделения разделяющих гиперповерхностей вводится понятие дискриминантных (разделяющих) функций (ДФ).

Предполагается, что в случае разбиения на два класса разделяющая функция  $f(X)$  обладает следующим свойством:

$$\begin{aligned} f(X) &> 0, \text{ если } X \in D_1, \\ f(X) &< 0, \text{ если } X \in D_2, \end{aligned} \quad (17)$$

Тогда уравнение разделяющей гиперповерхности запишется в виде

$$f(X) = 0. \quad (18)$$

Этот случай иллюстрируется на рис. 1.

При разбиении пространства состояний на несколько классов каждая область  $D_i$  отделяется от остальных одной разделяющей поверхностью. В этом случае существует  $m$  разделяющих функций, обладающих следующим свойством: для  $i = \overline{1, m}$  выполняется

$$\begin{aligned} f_i(X) &> 0, \text{ если } X \in D_i, \\ f_i(X) &< 0, \text{ если } X \notin D_i, \end{aligned} \quad (19)$$

Поверхность, отделяющая область  $D_i$  от остальных, определяется значениями  $X$ , при которых  $f_i(X) = 0$ . Данный случай иллюстрируется на рис. 2.

Установим связь между подходом, основанным на теории статистических решений и геометрическим подходом.

Для упрощения выкладок будем рассматривать случай с двумя разделяемыми классами  $q_1$  и  $q_2$ .




Рис. 1. Пример линейной дискриминантной функции для случая разделения образов на два класса




Рис. 2. Иллюстрация к случаю разделения на несколько классов

Положим  $\lambda_{11} = \lambda_{22} = 0$ ,  $\lambda_{12} = \lambda_1$ ,  $\lambda_{21} = \lambda_2$ . При осуществлении события  $X$  условные вероятности ошибок первого рода и второго рода равны

$$\alpha = \int \dots \int_{D_2} P(X/q_1) dx_1 \dots dx_n;$$

$$\beta = \int \dots \int_{D_1} P(X/q_2) dx_1 \dots dx_n; \quad (20)$$

Средний риск определяется по формуле

$$R = \lambda_1 P(q_1) \alpha + \lambda_2 P(q_2) \beta \quad (21)$$

Так как интеграл от плотности вероятности по области  $D_1 \cup D_2$  равен единице, то

$$\alpha = 1 - \int \dots \int_{D_1} P(X/q_2) dx_1 \dots dx_n,$$

откуда

$$R = \alpha_1 P(q_1) + \int \dots \int_{D_1} \left[ \lambda_2 P(q_2) P(X/q_2) - \lambda_1 P(q_1) P(X/q_1) \right] dx_1 \dots dx_n \quad (22)$$

Для минимизации среднего риска необходимо так выбрать области  $D_1$  и  $D_2$ , чтобы интеграл в (22) принял отрицательное и наибольшее по модулю значение. Это достигается тогда, когда подынтегральное выражение принимает наибольшее по модулю отрицательное значение, и вне области  $D_1$  не существует такой области, в которой подынтегральное выражение отрицательно, т.е. выполняется

$$\lambda_2 P(q_2) P(X/q_2) - \lambda_1 P(q_1) P(X/q_1) < 0. \quad (23)$$

Отсюда следует ранее рассмотренное байесовское решающее правило.

Распознаваемое состояние, для которого установлен вектор признаков  $X$ , относится к классу  $q_1$ , если

$$\frac{P(X/q_1)}{P(X/q_2)} > \frac{\lambda_2 P(q_1)}{\lambda_1 P(q_2)}, \quad (24)$$

где  $\frac{\lambda_1 P(q_1)}{\lambda_2 P(q_2)} = h$  – пороговое значение коэффициента правдоподобия.

Отсюда следует, что разделяющая функция для байесовского правила имеет вид

$$f(X) = \lambda_1 P(q_1) P(X/q_1) - \lambda_2 P(q_2) P(X/q_2) \quad (25)$$

Итак, если для объекта известны априорные вероятности классов состояний  $P(q_i)$  и условные плотности вероятности  $P(X/q_i)$ , то можно определить решающее правило или дискриминантные функции для классификации состояний по результатам диагностических измерений.

Для сложных технических систем аналитическое определение плотностей  $P(X/q_i)$  является исключительно сложной задачей, поэтому на практике обычно пользуются моделью объекта в форме выборки экспериментальных данных. Экспериментальные данные обычно представляются в виде таблицы. Строки этой таблицы отождествляются с состояниями объекта, а столбцы – с диагностическими признаками. Таблицу такого вида принято называть таблицей типа «состояние-признак». Такой набор данных также является моделью состояний СТК, однако связи между диагностическими параметрами (признаками) здесь выражены в неявной форме. В общем случае используемые данные могут включать в себя:

- доступные для измерения параметры объекта;
- данные по некоторым параметрам условий эксплуатации, включая данные по экспозициям факторов кумулятивного характера;
- данные по выходным параметрам объекта;
- оценки технического состояния объекта для каждого набора экспериментальных данных.

Экспериментальные данные формируются на основе наблюдений за объектами однородной статистической совокупности.

### 3. Обучение модели распознавания состояний СТК

Таблица данных используется в качестве обучающей выборки для построения системы распознавания состояний. Процесс обучения заключается в построении аппроксимаций для разделяющих функций.

Рассмотрим процесс обучения критерию Байеса применительно к ситуации, когда число классов равно двум ( $m = 2$ ).

Принадлежность состояния к классу  $q_1$  или классу  $q_2$  определяется знаком функции

$$f(X) = (\lambda_{11} - \lambda_{12}) P(X/q_1) + (\lambda_{21} - \lambda_{22}) P(X/q_2). \quad (26)$$

Сложность аппроксимирующей функции зависит от взаимного расположения образов классов в пространстве признаков. Иногда разделение образов можно осуществить с помощью линейной ДФ, но в общем случае необходимо использовать нелинейную аппроксимацию. Ниже рассматривает-

ся общий случай построения нелинейной аппроксимации.

Пусть задана система линейно независимых функций  $\phi_1(X)$ ,  $\phi_2(X)$ , ...,  $\phi_k(X)$ . Тогда  $f(X)$  можно аппроксимировать линейной комбинацией

$$\hat{f}(X, W) = W \phi(X) = w_1 \phi_1(X) + w_2 \phi_2(X) + \dots + w_k \phi_k(X). \quad (27)$$

Выражение (27) представляет собой скалярное произведение вектор-строки коэффициентов  $W = (w_1, w_2, \dots, w_k)$  и вектор-столбца  $\phi(X)$ , для которого

$$\phi'(X) = [\phi_1(X), \phi_2(X), \dots, \phi_k(X)].$$

Коэффициенты  $w_1, w_2, \dots, w_k$  определяются в результате статистической обработки обучающей выборки.

Ошибка аппроксимации определяется функционалом

$$J(W) = \int \dots \int_{(X)} [f(X) - W \phi(X)]^2 dX, \quad (28)$$

где  $(X)$  – пространство признаков  $[(X) \subseteq R^n]$ ,  $dX = dx_1 dx_2 \dots dx_n$ .

Условие минимума функционала имеет вид

$$\nabla J(W) = -2 \int \dots \int_{(X)} [f(X) - W \phi(X)] \phi(X) dX = 0. \quad (29)$$

Введем матрицу

$$H = \int \dots \int_{(X)} \phi(X) \phi'(X) dX,$$

размер которой равен  $S \times S$ . Тогда условие (29) перепишется в виде

$$HW - \int \dots \int_{(X)} f(X) \phi(X) dX = 0. \quad (30)$$

Подставив в (30) соотношение (26), получим

$$HW - \int \dots \int_{(X)} [(\lambda_{11} - \lambda_{12}) P(q_1) p(x/q_1) + (\lambda_{21} - \lambda_{22}) P(q_2) p(x/q_2)] \phi(X) dX = 0 \quad (31)$$

Обозначим через  $q(X)$  класс состояния ассоциируемого с вектором признаков  $X$ .

Положим

$$\Phi(X) = \begin{cases} (\lambda_{11} - \lambda_{12}) \phi(X), & \text{если } q(X) = q_1; \\ (\lambda_{21} - \lambda_{22}) \phi(X), & \text{если } q(X) = q_2. \end{cases}$$

Тогда равенство (31) представляется в виде

$$HW = M_X[\Phi(X)]. \quad (32)$$

Символом  $M$  здесь обозначена операция вычисления математического ожидания.

Пусть система функций  $\{\varphi_i(X)\}_1^S$  является ортонормированной. В этом случае

$$HW = IW = W$$

и, следовательно, будет выполняться равенство

$$W = M_X[\Phi(X)] \quad (33)$$

Тогда итерационный алгоритм обучения критерию Байеса может быть записан следующим образом:

$$\left. \begin{aligned} W_K &= W_{K-1} - \\ &-(1/K)\{W_{K-1} - (\lambda_{11} - \lambda_{12})\varphi(X_n)\}, \\ &\text{если } q(X_n) = q_1; \\ W_K &= W_{K-1} - \\ &-(1/K)\{W_{K-1} - (\lambda_{21} - \lambda_{22})\varphi(X_n)\}, \\ &\text{если } q(X_n) = q_2. \end{aligned} \right\} \quad (34)$$

$K = 1, 2, \dots, N$ , где  $N$  – объем обучающей последовательности.

Алгоритм (34) реализует метод стохастического градиента.

#### 4. Логические методы распознавания состояний технической системы.

Рассмотрим теперь общий случай, когда признаки ТС подсистем СТК измеряются в различных шкалах.

Пусть задано множество классов состояний  $Q = \{q_1, q_2, \dots, q_m\}$ .

Тогда каждому классу из  $Q$  должно соответствовать некоторое присущее ему свойство-предикат.

Под свойством-предикатом на совокупности классов  $Q$  понимается такая функция состояния  $x(S)$ , которая принимает только два значения: «истинно» или «ложно». Обычно логические значения обозначаются соответственно 1 и 0.

Для параметров, измеряемых в непрерывной числовой шкале предикат может быть определен, например, следующим образом. На множестве значений параметра  $\xi$  выделяют интервал  $(\alpha, \beta)$  и полагают

$$x(\xi) = \begin{cases} 1, & \text{если } \xi \in (\alpha, \beta); \\ 0, & \text{если } \xi \notin (\alpha, \beta). \end{cases}$$

Аналогично определяют предикаты для параметров, измеряемых в порядковой шкале.

Таким образом, исходный вектор признаков  $\tilde{X}$  преобразуется в новый вектор  $X$ , компоненты которого принимают только логические значения. В дальнейшем будем предполагать, что

соответствующее преобразование уже выполнено и все признаки представляются логическими переменными.

Логические методы распознавания образов базируются на аппарате алгебры логики и позволяют оперировать информацией, заключенной не только в отдельных признаках, но и в сочетаниях значений признаков. В самом общем виде логические методы можно охарактеризовать как поиск по обучающей выборке логических закономерностей и формирование некоторой системы логических решающих правил (например, в виде конъюнкций признаков). Группа логических методов отличается разнообразием и включает методы различной сложности и глубины анализа [6]. В качестве примера логических методов распознавания рассмотрим алгоритм «Кора», эффективность которого подтверждается в ряде прикладных областей. Ниже приводится модифицированный вариант этого алгоритма.

В этом методе значение какого-либо признака  $x_i$  рассматривается как элементарное событие  $T$ . Например, для признаков, измеряемых в номинальных шкалах, элементарными событиями  $T$  называют события  $x_i = a$  или  $x_i \neq a$ , где  $a$  – одно из возможных значений признака. Если же шкала порядковая или числовая, то элементарными событиями могут называться события вида  $a < x_i < b$ . В алгоритме «Кора» анализируются все возможные конъюнкции вида

$$T_{i_1} \cap T_{i_2} \cap \dots \cap T_{i_l} \quad (l \leq l_0), \quad (35)$$

где  $l_0$  – некоторое наперед заданное число.

Среди конъюнкций выделяются те, которые характерны (верны на обучающей выборке чаще, чем некоторый порог  $1 - \varepsilon_1$ ) для одного из классов и не характерны для другого (верны реже, чем в заданной доле случаев  $\varepsilon_2$ ).

Если коэффициент корреляции между какими-либо двумя выделенными конъюнкциями по модулю более  $1 - \varepsilon_3$ , то оставляется «наилучшая» из них с точки зрения различения классов, а если конъюнкции эквивалентны, то более короткая (имеющая в представлении (35) меньшее  $l$ ) или просто отобранная ранее. Параметры  $\varepsilon_1, \varepsilon_2$  и  $\varepsilon_3$  подбираются так, чтобы общее число отобранных (информативных) конъюнкций не превосходило некоторого

числа  $N$ . При распознавании образа состояния  $X$  подсчитывается  $N_i$  – число характерных для  $i$ -го класса отобранных конъюнкций, которые верны для  $X$ . Если  $N_i$  является наибольшим из всех, то принимается решение о принадлежности состояния  $i$ -му классу.

Алгоритм «Кора» отличается простотой и легко программируется; его трудоемкость определяется заданными параметрами  $\varepsilon_1, \varepsilon_2, \varepsilon_3, N$ , а также размерностью пространства признаков.

#### Заключение

В статье рассмотрены методы оценивания и прогнозирования технического состояния СТК, основанные на методах распознавания образов. Указанные методы являются перспективными и позволяют эффективно решать задачи управления жизненным циклом сложных технических комплексов.

#### Литература

1. Надёжность и эффективность в технике. Эффективность технических систем. Т. 3. – М.: Машиностроение, 1988.
2. Беркетов Г. А. Прогнозирование остаточного ресурса технических систем методами распознавания образов. // Математические методы решения инженерных задач. 2002. №1. с. 17-31.
3. Справочник по прикладной статистике. Т. 1. /Под ред. Э. Ллойда, У. Лидермана, М.: Финансы и статистика, 1989. 510 с.
4. Горелик А.Л., Скрипка В.А. Методы распознавания. Уч. пособ. для вузов. М.: Высшая школа, 2008.

#### References

1. The reliability and the effectiveness of the technique. Effectiveness of technical systems. V.3. – M.: Mechanical Engineering, 1988.
2. G. A. Berketov. Prediction of residual life of technical systems using pattern recognition. // Mathematical methods for solving engineering problems., №1, p. 17-31, 2002.
3. Reference book on Applied Statistics. V.1.// Edited by A. Lloyd, W. Liderman, Moscow: The Finance and Statistics, p. 510, 1989.
4. A. L. Gorelik, V.A. Scripka. Recognition methods. // Manual for universities. Moscow: High School, 2008.