

О.В. Заговора, студент Institute for Web Science and Technologies (University of Koblenz-Landau, Germany), В.Г. Концевич, канд.техн.наук, доцент (Сумський Государственный Університет) г. Суми, Україна

# Информационно-экстремальная интеллектуальная технология анализа результатов исследований машин динамического действия

Для анализа результатов испытаний компрессора динамического действия и соответствующего тренд-прогнозирования предлагается метод синтеза прогностической системы, способной обучаться в рамках информационно-экстремальной интеллектуальной технологии. Предлагаемый метод путем применения порядковых статистик позволит повысить функциональную эффективность прогностического обучения и определить на этапе экзамена реперные точки переобучения.

**Ключевые слова:** информационно-экстремальная интеллектуальная технология, прогностическая система обучения.

Для аналізу результатів випробувань компресора динамічної дії та відповідного тренд-прогнозування пропонується метод синтезу прогностичної системи здатної навчатися в рамках інформаційно-екстремальної інтелектуальної технології. Пропонований метод шляхом застосування порядкових статистик дозволить підвищити функціональну ефективність прогностичного навчання та визначити на етапі іспиту реперні точки перенаочання.

**Ключові слова:** інформаційно-екстремальна інтелектуальна технологія, прогностична система навчання.

For the analysis of the test results of the dynamic action compressor and the corresponding trend-prediction, synthesis method of forecasting system able to train under extreme intellectual information technology is proposed. The proposed method will improve the functional efficiency of predictive learning and determined at the exam reference points retraining by applying the order statistics.

**Keywords:** information and extreme intelligent technology, prediction learning system.

Одним из перспективных подходов к увеличению функциональной эффективности обучающихся автоматизированных систем управления (АСУ) [1] является создание детерминировано-статистических методов классификационного прогнозирования на основе самообучения и распознавания образов [2].

Основными причинами отсутствия широкого применения классификационного прогнозирования работоспособности компрессорных машин являются:

- модельный характер известных методов, обусловленный тем, что пересечения гиперсферических контейнеров в практических задачах контроля не учитываются;

- отсутствие алгоритмов построения безшибочных решающих правил по многомерной учебной матрице, что обусловлено методологическими причинами.

Устранение этих недостатков может быть обеспечено применением методов классификационного прогнозирования, разработанных в рамках информационно-экстремальной интеллектуальной технологии (ИЭИТ), основанной на максимизации количества информации в процессе

обучения системы путем введения дополнительных информационных ограничений.

Далее рассматриваются в рамках ИЭИТ вопросы оптимизации параметров функционирования СППР, способной обучаться и являющейся составной частью АСУ [3].

## Постановка задачи в рамках ИЭИТ

Пусть даны  $\{x_m^0 \mid m = \overline{1, M}\}$  – алфавит  $M$  классов распознавания, которые в общем случае могут пересекаться, и матрицу данных технологического процесса  $\|y_{m,i}^{(j)}\|, i = \overline{1, N}, i = \overline{1, n}$ , где  $N, n$  – количество признаков распознавания и моментов считывания информации соответственно. Известен вектор-кортеж пространственно-временных параметров функционирования обучающейся АСУ,  $g_m = \langle g_{(m,1)}, \dots, g_{(m,6)}, \dots, g_{(m,n)} \rangle$  с соответствующими ограничениями  $R_\xi(g_1, \dots, g_n) \leq 0$ . Следует в процессе обучения АСУ оптимизировать такой параметр плана обучения, как система контрольных допусков  $D$ , и построить вариационный ряд экстремальных последовательных статистик (ЭПС) путем целенаправленной трансформации нечеткого разбиения  $R^{(M)}$  в четкое

разбиение эквивалентности при условиях, представленных в работе [4].

При этом оптимальные значения параметров плана обучения обеспечивают максимум информационного критерия функциональной эффективности (КФЭ) обучения

$$E^* = \langle \max_{\{G_\vartheta\}} \sum_{m=1}^M E_m^* \rangle, \quad (1)$$

где  $E_m^*$  – максимум КФЭ обучения распознавания реализаций класса  $X$ ;  $\{G_\vartheta\}$  – области допустимых значений параметров обучения.

Таким образом, процесс оптимизации параметров функционирования обучающейся АСУ, предполагает построение ЭПС и оптимизация системы контрольных допусков, что обеспечивает выполнение условия (1).

## Математическая модель прогностического обучения

Математические модели прогностической автоматической классификации в рамках ИЭИТ имеют определенные особенности. В этом случае обязательным этапом процесса обучения является отражение избирательной множества  $X$  на множество свободных

статистик  $S$ , которое вычисляется на каждом шаге обучения:

$$\mu : X \rightarrow S. \quad (2)$$

Статистика  $S \in S$  должна удовлетворять следующим требованиям:

- являться одномерной статистической характеристикой избирательной множества;
- обладать инвариантностью к широкому семейству вероятностных мер;
- быть чувствительной к изменению функционального состояния обучающейся АСУ.

Для такой статистики можно считать "успехом" попадание значения признака в свое поле контрольных допусков.

Пусть в процессе проведения испытаний выполняется условие равенства вероятностей нахождения  $N$  признаков своих контрольных допусков, то  $p_1=p_2=\dots=p_N=p$ . Тогда вероятность получения успехов - числа признаков, содержащихся в допуске, определяется по биномиальному распределению

$$P(k, N, p) = C_N^k p^k q^{N-k},$$

где  $q=1-p$  – вероятность выхода значения признака за пределы поля допусков;  $C_N^k$  – биномиальные коэффициенты.

Введем свободную статистику, инвариантную относительно группы всех  $N!$  перестановок координат  $N$  – мерного вектора-реализации  $x_{m,i}^{(j)} \subset X_m^0, j=1, n$ , которая зависит только от объема обучающей выборки. В процессе реализации многоциклического итерационного алгоритма оптимизации параметров обучения по ИЭИТ формируется экстремальная порядковая статистика (ЭПС), которая может рассматриваться как одномерная статистическая прогнозирующая функция соответствующего состояния АСУ:

$$S_{m,n} = \sum_{j=1}^n \left( \frac{k_{m,j} - \bar{k}_{m,n}}{S_{m,n}} \right)^2, m = 1, M, \quad (3)$$

где  $k_{m,j}$  – число успехов при  $j$ -ом испытании;  $\bar{k}_{m,n}$  – выборочное среднее значение числа успехов после  $n$  испытаний;  $S_{m,n}^2$  – выборочное среднее квадратическое числа успехов после  $n$  испытаний соответственно.

Известно, что статистика (3) имеет распределение  $\chi^2$  со степенью свободы  $k=n-1$  и не зависит ни от математического ожидания, ни от дисперсии, а зависит только от объема испытаний  $n$ . Как пока-

зывает анализ выражения (3), при увеличении  $n$  выборочная дисперсия совпадает с нулем, а функция  $S_{m,n}$  имея тенденцию к увеличению, достигнет какого угодно большого значения. Таким образом, свободная статистика  $S_{m,n}$  является членом вариационного ряда – порядковой статистике, ранг которой определяется номером испытания.

Обозначим  $E$  через  $\Pi(E_m) \subset E_m$  частично упорядоченное подмножество значений КФЕ, вычисленных в процессе обучения распознавания реализаций класса  $X_m^0$ . При этом  $E_m^*$  – наибольший элемент подмножества  $\Pi(E_m)$ . Тогда множество  $E$  имеет упорядоченную структуру  $E = \langle \Pi(S_m) \rangle$ . Аналогичную структуру имеет и множество  $S$ :  $S = \langle \Pi(S_m) \rangle$ , где  $\Pi(S_m)$  – подмножество статистик, вычисленных при обучении распознавания реализации класса  $X_m^0$ , крупнейшим элементом которого является экстремальная статистика  $S_m^*$ . Таким образом, элементы терм-множеств  $E$  и  $S$  находятся во взаимно-однозначном соответствии, и определение элементов подмножества  $\Pi(S_m^*) \subset S$  осуществляется в результате биективного отображения

$$S: E \rightarrow S. \quad (4)$$

Вычисление порядковых статистик  $S_{m,n}$  для каждого класса осуществляется по формуле (3) на каждом шагу оптимизации параметров обучения АСУ. Статистика  $S_{m,n}$  достигнет экстремального значения при испытании  $n^*$ , при котором КФЭ обучения системы распознавать реализации класса  $X_m^0$  принимает максимальное значение в рабочей области определения его функции. После окончания обучения АСУ формируется вариационный ряд ЭПС  $S_m^*$  за увеличением с целью организации процедуры их сопоставления с текущей статистикой  $S_n$ , который исчисляется в режиме прогностического экзамена.

#### Алгоритм прогностического обучения

Рассмотрим базовый алгоритм прогностического обучения системы управления. Алгоритм имеет следующие входные данные:  $\{Y[J,I,K]\}$  – массив обучающих выборок,  $J=1\dots NM$  – переменная количества испытаний, где  $NM$  – минимальный объем презентативной обучающей выборки,  $I=1\dots N$  – переменная числа признаков распознавания,  $K=1\dots M$  – переменная количества классов распознавания  $\{NDK[I]\}, \{VDK[I]\}$  – массивы нижних и верхних контрольных допусков

на признаки соответственно. Результатом реализации алгоритма являются:  $\{DOPT[K]\}$  – целый массив оптимальных значений радиусов контейнеров классов распознавания в кодовой расстояния Хемминга;  $\{EV[K]\}$  – массив эталонных двоичных векторов классов распознавания  $\{EM[K]\}$  – настоящий массив максимальных значений информационного КФЕ процесса обучения  $\{S[K]\}$  – настоящий массив ЭПС классов распознавания  $\{D1[K]\}, \{A[K]\}, \{B[K]\}, \{D2[K]\}$  – настоящие массивы оценок экстремальных значений точностных характеристик процесса обучения для соответствующих классов распознавания: первая вероятность, ошибки первого и второго рода и вторая вероятность соответственно. Переменная  $D$  является рабочей переменной шагов обучения, на которых последовательно увеличивается значение радиуса контейнера класса распознавания.

Структурная схема базового алгоритма обучения LEARNING приведена на рисунке. В структурной схеме алгоритма блок 3 формирует массив учебных двоичных выборок  $\{X[J,I,K]\}$  путем сравнения значений элементов массива  $\{Y[J,I,K]\}$  с соответствующими контрольными допусками на признаки распознавания по правилу

$$x_{m,i} = \begin{cases} 1, & \text{if } y_{m,i}^{(j)} \in \delta_{K,i}, \\ 0, & \text{if } y_{m,i}^{(j)} \notin \delta_{K,i}. \end{cases}$$

Блок 3 также формирует вариационный ряд порядковых статистик  $\{S[K]\}$  по правилу (3) и формирует массив эталонных двоичных векторов  $\{EV[K]\}$  путем статистического усреднения столбцов массива  $\{X[J,I,K]\}$  по правилу

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{2} \sum_{j=1}^n x_{m,i}^{(j)} > \rho_m, \\ 0, & \text{if } \frac{1}{2} \sum_{j=1}^n x_{m,i}^{(j)} < \rho_m \end{cases},$$

при соответствующем уровне селекции, который по умолчанию равен  $\rho_m = 0,5$ . Блок 4 осуществляет разбиение множества эталонных векторов на пары "ближайших соседей". Блок 11 вычисляет на каждом шаге обучения значение информационного КФЭ и оценки точностных характеристик процесса обучения. При невыполнении условия блока сравнения 12 блок 13 оценивает принадлежность текущего значения критерия  $E[D]$  рабочей области  $G_E$  определения его функции и при

положительном решении блока 13 это значение запоминается блоком 14.

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{2} \sum_{j=1}^n x_{m,i}^{(j)} > \rho_m, \\ 0, & \text{if } \frac{1}{2} \sum_{j=1}^n x_{m,i}^{(j)} < \rho_m \end{cases}$$

Таким образом, процесс обучения СППР заключается в реализации процедуры поиска глобального максимума функции информационного критерия в рабочей области ее определения и итерационного приближения этого максимума к его предельному максимальному значению с целью построения безошибочных по учебной матрице решающих правил, которые геометрически характеризуются восстановленными в процессе обучения оптимальными контейнерами параметрических классов распознавания.

#### Выводы

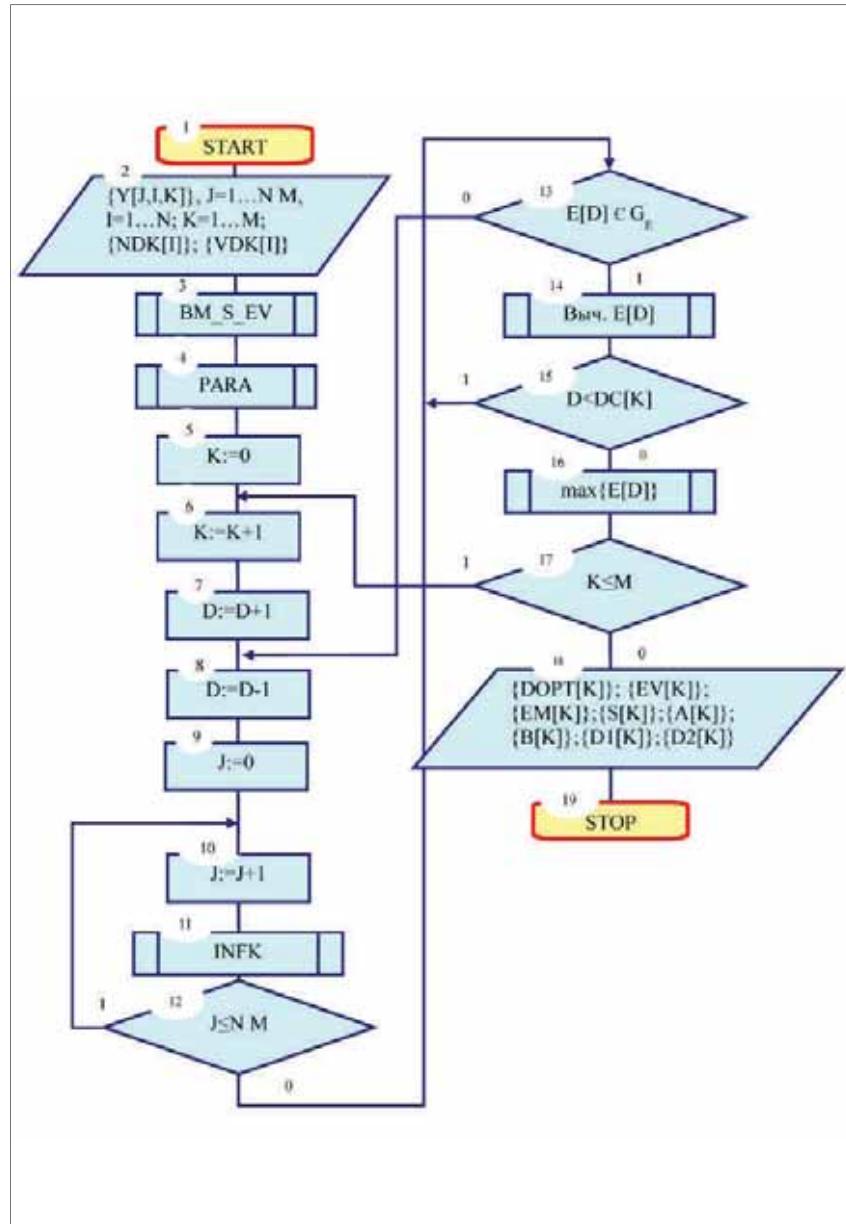
1. В качестве перспективного подхода повышающего функциональную эффективность обучающихся АСУ предлагается модель детерминировано-статистических методов классификационного прогнозирования на основе самообучения и распознавания образов.

2. Математическая модель детерминировано-статистического метода классификационного прогнозирования разработана с учётом особенностей прогностической автоматической классификации в рамках ИЭИТ.

3. Дополнение предложенной модели сформулированными информационными ограничениями позволит повысить эффективность методов классификационного прогнозирования.

4. Разработанный алгоритм прогностического обучения интеллектуальной СППР позволит провести релевантный анализ и обеспечить адекватное прогнозирование результатов исследований машин динамического действия.

5. Реализация предложенной процедуры поиска глобального максимума функции информационного критерия в рабочей области ее определения и итерационное приближение этого максимума к его предельному максимальному значению обеспечивает эффективный процесс обучения СППР.



**Рисунок. Структурная схема базового алгоритма прогностического обучения**

#### Список литературы:

1. Концевич В.Г. Проблемы создания единого информационного пространства при внедрении CALS-идеологии на предприятиях компрессоростроительной отрасли / В.Г.Концевич / Сборник трудов II Всероссийской студенческой науч.-прак. конф. «Вакуумная и компрессорная техника и пневмоагрегаты» / М.: МГТУ, 2010. С.7-16.

2. Довбши А.С. Анализ алгоритмов оптимизации контрольных допусков по признакам распознавания / А.С.Довбши, О.О.Дзюба // Адаптивные системы управления, 2010.- №16.- С. 11-15.

3. Заговора О.В. Формализация выходов процесса управления изменениями в жизненном цикле информационной системы управления как источника новых знаний / О.В. Заговора, В.Г. Концевич / Материалы конф. «Информационные процессы и технологии. Информатика – 2011» / Севастопольский нац. технический университет, 2011.- С. 234.

4. Мухамедиев Р.И. Ограниченност одноранговых аддитивных моделей оценивания / Вестник Сумского государственного университета. Серия Технические науки, 2006.- № 4.- С. 17-23.