

**Информационно-экстремальная интеллектуальная технология проектирования корпоративной системы управления для региональной администрации**

Главной целью проектирования корпоративной системы управления (КИСУ) является обеспечение ее максимальной функциональной эффективности при принятии решений в процессе выполнения поставленной задачи. Для достижения поставленной цели КИСУ должна предоставлять лицу, принимающему решение, (ЛПР) информацию о текущем функциональном состоянии управляемого процесса и осуществлять многомерный статистический анализ данных с выдачей оптимальных (здесь и далее в информационном смысле) управленческих решений.

Для анализа накопленной корпоративной информации и выдачи рекомендаций ЛПР в задачах информационного менеджмента широко используются системы поддержки принятия решений (СППР, Decision Support Systems). Аналитический обзор известных методов проектирования СППР позволяет сделать вывод, что, несмотря на достаточный уровень их технического и программного обеспечения, они не в полной мере отвечают главной цели проектирования по таким основным причинам:

- полное или частичное отсутствие в их информационном обеспечении интеллектуальной составляющей, моделирующей когнитивные процессы, свойственные человеку при принятии решений;
- отсутствие образного (семантического) представления информации, что усложняет принятие решений ЛПР;
- отсутствие свойства адаптивности КИСУ;
- методологические проблемы, связанные с разработкой обобщенного критерия функциональной эффективности КИСУ;
- расплывчатое представление ЛПР цели и возможностей КИСУ.

Одним из перспективных путей устранения этих недостатков является переход к новому поколению СППР, работающих в режиме классификационного управления и основанных на идеях и методах машинного обучения (самообучения) и распознавания образов [1-5]. Сдерживающим фактором широкого внедрения известных КИСУ, работающих в режиме классификационного управления, является наличие следующих их основных недостатков:

- не учитывается влияние неконтролируемых входных факторов, вызывающих произвольные начальные условия управляемого процесса;
- игнорирование пересечения классов распознавания, что имеет место в практических задачах управления.

Основным перспективным путем устранения этих недостатков является придание КИСУ свойства адаптивности путем машинного (алгоритмического) обучения системы. С этой целью в Сумском государственном университете разработана информационно-экстремальная интеллектуальная технология (ИЭИ – технология), анализа и синтеза обучающихся (самообучающихся) КИСУ, основанная на максимизации информационной способности системы

путем введения в процессе обучения дополнительных информационных ограничений [6,7]. Практическое использование в Украине ИЭИ – технологии в различных областях социально-экономической сферы подтвердило возможность построения безошибочных решающих правил как для обучающей, так и проверочной многомерных матриц данных, полученных в результате мониторинга управляемых слабо формализованных процессов, что гарантирует высокую достоверность принятия решений в рабочем режиме КИСУ.

### Научно-методологические положения ИЭИ-технологии

Основная идея машинного обучения КИСУ в рамках ИЭИ-технологии состоит в трансформации априорного в общем случае нечёткого разбиения пространства признакою в чёткое разбиение классов эквивалентности путём итерационной оптимизации пространственно-временных параметров функционирования КИСУ. При этом осуществляется целенаправленный поиск глобального максимума многоэкстремальной функции статистического информационного критерия оптимизации в рабочей (допустимой) области её определения и одновременного восстановления в радиальном базисе бинарного пространства признаков распознавания оптимальных разделяющих гиперповерхностей. – контейнеров классов распознавания. Отличием методов ИЭИ-технологии от известных является трансформация в процессе обучения системы входного нечёткого распределения реализаций образов в чёткое путём целенаправленного изменения значений признаков распознавания, что позволяет строить безошибочные по обучающей и проверочной многомерным матрицам решающие правила.

Таким образом, в ИЭИ-технологии в рамках алгоритма обучения удалось совместить процедуры нормализации образов, состоящей в исправлении их априорной деформации относительно эталонного образа, и построения решающих правил путём оптимизации параметров функционирования СППР.

Пусть задано алфавит классов распознавания  $\{X_m^o \mid m = \overline{1, M}\}$ . В общем случае при принятии гипотезы нечёткой компактности реализаций образа имеет место нечёткое разбиение  $\tilde{\mathfrak{R}}^{|M|}$  пространства признаков на классы распознавания, для которого выполняются условия

$$\left(\forall X_m^o \in \tilde{\mathfrak{R}}^{|M|}\right) \left[X_m^o \neq \emptyset\right]; \quad (1)$$

$$\left(\exists X_k^o \in \tilde{\mathfrak{R}}^{|M|}\right) \left(\exists X_l^o \in \tilde{\mathfrak{R}}^{|M|}\right) \left[X_k^o \neq X_l^o \rightarrow X_k^o \cap X_l^o \neq \emptyset\right]; \quad (2)$$

$$\left(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|}\right) \left(\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}\right) \left[X_k^o \neq X_l^o \rightarrow KerX_k^o \cap KerX_l^o = \emptyset\right]; \quad (3)$$

$$\bigcup_{X_m^o \in \tilde{\mathfrak{R}}} X_m^o \subseteq \Omega_B; \quad k \neq l; \quad k, l, m = \overline{1, M}. \quad (4)$$

При этом элементы разбиения  $\tilde{\mathfrak{R}}^{|M|}$  являются нечёткими классами распознавания.

В бинарном пространстве признаков  $\Omega$  для унимодальных распределений реализаций образов оптимальные контейнеры классов распознавания восстанавливаются в форме равносторонних единичных гиперпараллелепипедов. С целью обобщения и удобства построения такого контейнера вводится понятие “псевдогиперсферы”, которая описывает гиперпараллелепипед и содержит все его вершины. Это позволяет рассматривать такие параметры оптимизации контейнера в радиальном

базисе пространства признаков  $\Omega$ , как эталонный вектор-реализация образа  $x_m \in X_m^o$ , вершина которого определяет геометрический центр контейнера  $K_m^o \subset X_m^o$ , и радиус псевдосферического контейнера, определяемый в пространстве Хемминга:

$$d_m = \sum_{i=1}^N (x_{m,i} \oplus \lambda_i), \quad (5)$$

где  $x_{m,i}$  –  $i$ -ая координата эталонного вектора  $x_m$ ;  $\lambda_i$  –  $i$ -ая координата некоторого вектора-реализации  $\lambda$ , вершина которого находится на поверхности контейнера  $K_m^o \in X_m^o$ .

Далее, с целью упрощения, кодовое расстояние (5), например, между векторами  $x_m$  и  $\lambda$  обозначается как  $d_m = d(x_m \oplus \lambda)$ .

Восстановление оптимальных контейнеров с центрами в вершинах соответствующих эталонных векторов осуществляется на каждом шаге обучения путём целенаправленного изменения радиуса  $d_m$  по рекуррентной процедуре

$$d_m(k) = [d_m(k-1) + h \mid d_m(k) \in G_m^d], \quad (6)$$

где  $k$  – переменная числа увеличений радиуса контейнера  $K_m^o$  (числа шагов обучения);  $h$  – шаг увеличения радиуса;  $G_m^d$  – область допустимых значений радиуса  $d_m$ .

Пусть классы  $X_k^o$  и  $X_l^o$  являются ближайшими соседями, то есть имеют среди всех классов наименьшее межцентровое расстояние  $d(x_k \oplus x_l)$ , где  $x_k, x_l$  – эталонные вектора соответствующих классов. Тогда с целью недопущения “поглощения” одним классом ядра ближайшего соседа условия (1)-(4) дополняются предикатным выражением

$$\left( \forall X_k^o \in \tilde{\mathfrak{R}}^{|\mathcal{M}|} \right) \left( \forall X_l^o \in \tilde{\mathfrak{R}}^{|\mathcal{M}|} \right) [X_k^o \neq X_l^o \rightarrow (d_k^* < d(x_k \oplus x_l)) \& \& (d_l^* < d(x_k \oplus x_l))], \quad (7)$$

где  $d_k^*, d_l^*$  – оптимальные радиусы контейнеров  $K_k^o$  и  $K_l^o$  соответственно.

Таким образом, в ИЭИ-технологии в соответствии с принципом отложенных решений процесс построения решающих правил состоит в итерационном приближении глобального значения информационного критерия функциональной эффективности (КФЭ) обучения КИСУ к его граничному значению

### Алгоритм обучения КИСУ

Алгоритм обучения СППР в рамках ИЭИ-технологии состоит в реализации многоциклической итерационной процедуры оптимизации структурированных пространственно-временных параметров функционирования КИСУ путём поиска глобального максимума усреднённого по алфавиту  $\{X_m^o\}$  значения информационного КФЭ обучения.

Пусть вектор параметров функционирования КИСУ в общем случае имеет следующую структуру:

$$g = \langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}, f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle, \quad \Xi_1 + \Xi_2 = \Xi, \quad (8)$$

где  $\langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1} \rangle$  – генотипные параметры функционирования КИСУ, влияющие на параметры распределения реализаций образа;  $\langle f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle$  – фенотипные параметры функционирования КИСУ, которые прямо влияют на геометрию контейнеров классов распознавания. При этом известны ограничения на параметры функционирования

$$R_{\xi_1}(g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}) \leq 0; \quad R_{\xi_2}(f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2}) \leq 0.$$

Тестовый алгоритм обучения для общего случая ( $M > 2$ ) представим в виде итерационной процедуры оптимизации структурированных пространственно-временных параметров функционирования (8)

$$\begin{aligned} & (\forall g_{\xi_1} \in g) (\forall f_{\xi_2} \in g) (\exists g_{\xi_1} \in G_{\xi_1}) \{ \text{if } E^* = \max_{G_E} \bar{E} \text{ then} \\ & g_{\xi_1}^* = \arg \langle [\max_{G_{\xi_1}} \dots [\max_{G_1} [\max_{F_{\xi_2}} [\dots [\max_{F_1} \bar{E} ] \dots]]]] \rangle \text{ else} \quad (9) \\ & (\text{if } \xi_1 \leq \Xi_1 \text{ then } \xi_1 = \xi_1 + 1 \text{ else } STOP \text{ )}, \quad \xi_1 = \overline{1, \Xi_1}, \quad \xi_2 = \overline{1, \Xi_2}, \end{aligned}$$

где  $G_{\xi_1}, \dots, G_1$  – области допустимых значений соответствующих генотипных параметров обучения;

$$\bar{E} = \frac{1}{M} \sum_{m=1}^M E_m \quad (10)$$

усреднённое значение КФЭ обучения КИСУ;  $G_E$  – область значений функции информационного КФЭ;  $g_{\xi_1}^*$  – оптимальное значение параметра обучения, определяемого во внешнем цикле итерационной процедуры оптимизации;  $F_{\xi_2}, \dots, F_1$  – области допустимых значений соответствующих фенотипных параметров обучения. В формуле (10)  $E_m$  – информационный КФЭ обучения КИСУ распознавать реализации класса  $X_m^o$ .

В многоциклической итерационной процедуре оптимизации параметров функционирования КИСУ базовый информационно-экстремальный алгоритм реализуется во внутреннем цикле алгоритма обучения. Назначением базового алгоритма обучения является:


- вычисление информационного КФЭ обучения системы;
- поиск глобального максимума КФЭ в рабочей (допустимой) области определения его функции;
- оптимизация геометрических параметров контейнеров классов распознавания.

Входное математическое описание обучающейся КИСУ представим в виде теоретико-множественной структуры

$$\Delta_B = \langle \mathbf{G}, \mathbf{T}, \mathbf{\Omega}, \mathbf{Z}, \mathbf{Y}; \Phi \rangle,$$

где  $\mathbf{G}$  – пространство входных сигналов (факторов), действующих на систему распознавания;  $\mathbf{T}$  – множество моментов времени считывания информации;  $\mathbf{\Omega}$  – пространство признаков распознавания;  $\mathbf{Z}$  – пространство состояний системы распознавания;  $\mathbf{Y}$  – множество сигналов на выходе блока первичной обработки информации;  $\Phi: \mathbf{G} \times \mathbf{T} \times \mathbf{\Omega} \times \mathbf{Z} \rightarrow \mathbf{Y}$  – оператор формирования выборочного множества (обучающей матрицы)  $\mathbf{Y}$  на входе КИСУ. Тогда категорийную модель

процесса обучения КИСУ по базовому алгоритму представим в виде диаграммы отображения множеств



В диаграмме (11) для нечёткого разбиения  $\tilde{\mathfrak{R}}^{|M|} \subset \Omega$ , отвечающего условиям (1)-(4) и (7), введены оператор нечёткой факторизации пространства признаков:  $\theta: Y \rightarrow \tilde{\mathfrak{R}}^{|M|}$  и оператор  $\psi: \tilde{\mathfrak{R}}^{|M|} \rightarrow I^{|l|}$  проверки основной статистической гипотезы о принадлежности реализаций  $\{x_m^{(j)} | j = \overline{1, n}\}$  классу  $X_m^o$ . Здесь  $l$  – количество статистических гипотез. Оператор  $\gamma: I^{|l|} \rightarrow \mathfrak{F}^{|q|}$  по результатам оценки статистических гипотез формирует множество точностных характеристик  $\mathfrak{F}^{|q|}$ , где  $q=l^2$  – количество точностных характеристик. Оператор  $\phi: \mathfrak{F}^{|q|} \rightarrow E$  вычисляет множество значений информационного КФЭ, являющегося функционалом точностных характеристик. Контур оптимизации геометрических параметров разбиения  $\tilde{\mathfrak{R}}^{|M|}$  замыкается оператором  $r: E \rightarrow \tilde{\mathfrak{R}}^{|M|}$ . Оператор  $U: E \rightarrow G \times T \times \Omega \times Z$  регламентирует процесс обучения.

Входной информацией для обучения по базовому алгоритму является в общем случае вещественная обучающая матрица  $\|y_m^{(j)} | m = \overline{1, M}; j = \overline{1, n}\|$ ; система полей контрольных допусков  $\{\delta_{k,i}\}$  на признаки распознавания и уровни селекции (квантования)  $\{\rho_m\}$  координат эталонных векторов-реализаций, которые по умолчанию принимаются равными 0,5 для всех классов распознавания.

Рассмотрим обобщённые этапы реализации базового алгоритма обучения:

1. Формирование бинарной обучающей матрицы  $\|x_{m,i}^{(j)}\|$  по правилу

$$x_1^{(j)} = \begin{cases} 1, & \text{if } y_{1,i} - \delta \leq y_{1,i}^{(j)} \leq y_{1,i} + \delta, \\ 0, & \text{if else.} \end{cases}$$

2. Формирование массива двоичных эталонных векторов  $\{x_{m,i} | m = \overline{1, M}, i = \overline{1, N}\}$ , элементы которых определяются по правилу

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

где  $\rho_m$  – уровень селекции координат вектора  $x_m \in X_m^o$ .

3. Разбиение множества эталонных векторов на пары ближайших "соседей" за схемой:

а) структурируется множество эталонных векторов, начиная с вектора  $x_1$  базового класса  $X_1^o$ , характеризующего наибольшую функциональную эффективность КИСУ;

- б) строится матрица размерности  $M \times M$  кодовых расстояний между эталонными векторами;
- в) для каждой строки матрицы кодовых расстояний находится минимальный элемент;
- г) определяется ближайший вектор, столбчик которого включает минимальный элемент соответствующей строки.
- д) для заданного алфавита классов строится структурированное множество попарных разбиений  $\{\mathfrak{R}_m^{[2]} \mid m = \overline{1, M}\}$ , задающее план обучения;

4. Оптимизация кодового расстояния  $d_m$  осуществляется в рамках процедуры (9) по энтропийному критерию в следующей модификации [5]

$$E_m^{(k)} = 1 + \frac{1}{2} \left( \frac{\alpha_m^{(d)}}{\alpha_m^{(d)} + D_{2,m}^{(d)}} \log_2 \frac{\alpha_m^{(d)}}{\alpha_m^{(d)} + D_{2,m}^{(d)}} + \frac{\beta_m^{(d)}}{D_{1,m}^{(d)} + \beta_m^{(d)}} \log_2 \frac{\beta_m^{(d)}}{D_{1,m}^{(d)} + \beta_m^{(d)}} + \frac{D_{1,m}^{(d)}}{D_{1,m}^{(d)} + \beta_m^{(k)}(d)} \log_2 \frac{D_{1,m}^{(d)}}{D_{1,m}^{(d)} + \beta_m^{(d)}} + \frac{D_{2,m}^{(d)}}{\alpha_m^{(d)} + D_{2,m}^{(d)}} \log_2 \frac{D_{2,m}^{(d)}}{\alpha_m^{(d)} + D_{2,m}^{(d)}} \right), \quad (12)$$

где  $\alpha_m^{(d)}$ ,  $\beta_m^{(d)}$  – ошибки первого и второго рода принятия решений на  $d$ -ом шаге обучения соответственно;  $D_{1,m}^{(d)}$ ,  $D_{2,m}^{(d)}$  – первая и вторая достоверности соответственно.


5. Обучение КИСУ распознавать реализации класса  $X_m^o$  заканчивается при нахождении максимума КФЭ (12) в рабочей области его определения.

Таким образом, базовый алгоритм обучения является итерационной процедурой поиска глобального максимума информационного КФЭ (12) в рабочей области определения его функции:

$$d_m^* = \arg \max_{\{d\}} E_m^*.$$

Оптимальные параметры обучения – кодовые расстояния  $\{d_m^*\}$  и двоичные эталонные векторы  $\{x_m^*\}$  для заданного алфавита  $\{X_m^o\}$  являются входными данными для функционирования КИСУ в режиме экзамена, то есть непосредственного принятия решений.

На рис.1 показан график изменения критерия (12) в процессе восстановления оптимальных контейнеров двух соседних классов  $X_1^o$  и  $X_2^o$  при обучении работающей в режиме мониторинга КИСУ трудовыми ресурсами Сумской области






Рис.1. Графики зависимости КФЭ (12) от радиусов контейнеров: а) класс  $X_1^o$ ; б) класс  $X_2^o$

На рис.1 штриховкой обозначены рабочие области определения функции критерия (12), в которой осуществляется поиск её глобального максимума. Анализ рис. 1 показывает, что радиусы оптимальных контейнеров классов  $X_1^o$  и  $X_2^o$  равняются  $d_1^* = 8$  кодовых единиц и  $d_2^* = 11$  кодовых единиц, а максимальные значения КФЭ –  $E_1^* = 0,9$  и  $E_2^* = 0,7$  соответственно. при максимальном граничном значении  $E_{гран} = 1,0$  критерия (12). Таким образом, реализация базового алгоритма обучения в общем случае не приводит к построению безошибочных решающих правил, что в соответствии с принципом отложенных решений требует оптимизации других пространственно-временных параметров функционирования КИСУ.

### **Перспективы развития и внедрения ИЭИ-технологии при проектировании обучающихся КИСУ**

Дальнейшее развитие ИЭИ-технологии связано с оптимизацией генотипных параметров функционирования системы, влияющих на распределение векторов реализаций образов и позволяющих трансформировать априорное нечёткое распределение в чёткое. Такими параметрами функционирования являются, например, система контрольных допусков на признаки распознавания, уровни селекции координат двоичных эталонных векторов-реализаций образов, параметры словаря признакою, плана обучения, внешней среды и другие. Кроме того, основными вопросами, требующими дальнейшей разработки, являются повышение оперативности алгоритма обучения, исследование влияния мощности словаря признаков и алфавита классов на достоверность принятия решений и внедрение интеллектуальных КИСУ в органах регионального самоуправления.

### **Выводы**

1. Основным путём повышения функциональной эффективности КИСУ, функционирующих в условиях априорной неопределённости, является придание ей свойства адаптивности путём обучения.
2. Информационно-экстремальная интеллектуальная технология (ИЭИ – технология) анализа и синтеза обучающихся (самообучающихся) КИСУ, основанная на максимизации информационной способности системы путем введения в процессе обучения дополнительных информационных

ограничений, позволяет в условиях априорной неопределённости строить безошибочные как по обучающей, так и по проверочной матрицам решающие правила.

### Литература

1. Васильев В. И. Распознающие системы. Справочник. 2-е изд., перераб. и доп.–Киев: Наукова думка, 1983.– 422 с.
2. Методы анализа данных: Подход, основанный на методе динамических сгущений: Пер. с фр. / Кол. авт. под рук. Э. Дидэ / Под ред. и с предисл. С. А. Айвазяна и В. М. Бухштабера. – М.: Финансы и статистика, 1985. – 375 с.
3. Прикладная статистика: Классификация и снижение размерности. Справ. изд./ С. А. Айвазян, В. М. Бухштабер, И. С. Енюков, Л. Д. Мешалкин / Под ред. С. А. Айвазяна. – М.: Финансы и статистика, 1989.– 607 с.
4. Зайченко Ю.П. Основи проектування інтелектуальних систем. Навчальний посібник.– К.:Видавничий Дім “Слово”, 2004.–352с
5. Краснополюсовський А.С. Інформаційний синтез інтелектуальних систем керування: Підхід, що ґрунтується на методі функціонально-статистичних випробувань.– Суми: Видавництво СумДУ, 2004. – 261 с.
6. Довбиш А.С. Основи проектування інтелектуальних систем: Навчальний посібник. – Суми: Видавництво СумДУ, 2009. – 171с.