

А. С. ДОВБИШ, д-р техн. наук, професор СумДУ, Суми;
В. В. МОСКАЛЕНКО, аспірант СумДУ, Суми

ОПТИМІЗАЦІЯ СЛОВНИКА ОЗНАК РОЗПІЗНАВАННЯ ДЛЯ ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНОГО ГІПЕРЕЛІПСОЇДНОГО КЛАСИФІКАТОРА

Розглядається в рамках інформаційно-екстремальної інтелектуальної технології метод послідовно-спадної селекції словника ознак розпізнавання для класифікатора з гіпереліпсоїдними контейнерами класів розпізнавання. Як приклад розглянуто реалізацію алгоритму селекції словника ознак розпізнавання системи підтримки прийняття рішень для керування технологічним процесом вирощування скінтіляційних монокристалів з розплаву.

Рассматривается в рамках информационно-экстремальной интеллектуальной технологии метод последовательно-нисходящей селекции словаря признаков распознавания для классификатора с гиперэллипсоидными контейнерами классов распознавания. В качестве примера рассматривается реализация алгоритма селекции словаря признаков распознавания системы поддержки принятия решений для управления технологическим процессом выращивания скинтиляционных монокристаллов из расплава.

This paper considers sequential top-down feature selection method for hyper-ellipsoidal classifier within intellectual information-extreme technology. On the example of implementation the article considers sequential top-down feature selection method for Decision Support System for control of growing scintillate single crystals from the melt.

Вступ. Підвищення функціональної ефективності керування слабо формалізованими процесами, що функціонують за умов апіорної невизначеності, здійснюється шляхом впровадження інтелектуальних інформаційних технологій, що базуються на ідеях і методах машинного навчання та розпізнавання образів [1,2]. Більшість відомих методів навчання систем розпізнавання ігнорують перетин класів розпізнавання у просторі ознак розпізнавання (ОР), що має місце у практичних задачах керування. Ця проблеми вирішуються в рамках інформаційно-екстремальної інтелектуальної технології (ІЕІ-технологія) аналізу та синтезу здатних навчатися автоматизованих систем керування (АСК) [3,4]. Проте для здатних навчатися АСК існує проблема багатовимірності, оскільки ефективність функціонування системи залежить від кількості ОР. Тому важливого значення набуває задача селекції ОР, що полягає у формуванні оптимального в інформаційному розумінні словника ознак із початкового надлишкового, що дозволяє зменшити обчислювальну трудомісткість алгоритму і підвищити достовірність розпізнавання. У праці [6] запропонована оптимізація словника ознак розпізнавання для інформаційно-екстремального класифікатора з гіперсферичними контейнерами класів розпізнавання, але у випадку складного витягнутого розподілу реалізацій образу функціо-

нальна ефективність навчання АСК може бути збільшена за умови переходу до побудови гіпереліпсоїдних контейнерів класів розпізнавання [7,8].

У статті розглядається застосування методу послідовно-спадної селекції (ПСС) словника ОР для інформаційно-екстремального гіпереліпсоїдного класифікатора на прикладі реалізації інтелектуальної системи підтримки прийняття рішень (СППР) для автоматизованого керування технологічним процесом вирощування сцинтиляційних монокристалів із розплаву [9].

Постановка задачі. Розглянемо АСК, складовою частиною якої є здатна навчатися СППР. Нехай сформовано апіорно класифікований алфавіт класів розпізнавання $\{X_m^o \mid m = \overline{1, M}\}$, що характеризує відповідні функціональні стани АСК, і відповідну навчальну багатовимірну (векторну) матрицю типу «об'єкт-властивість» $\|y_{m,i}^j \mid i = \overline{1, N}, j = \overline{1, n}\|$, де N, n – кількість ознак розпізнавання і векторів-реалізацій образу відповідно. Базовий клас X_1^o характеризує максимальну функціональну ефективність здатної навчатися АСК, тобто є найбільш бажаним для особи, що приймає рішення. Відомий структурований вектор параметрів функціонування СППР

$$g = \langle \Sigma, \delta, c_m, x_m, x_{m,1}, x_{m,2}, d_m \rangle, \quad (1)$$

де Σ – словник ОР; δ – параметр поля контрольних допусків на ознаки розпізнавання; c_m – фокальна відстань гіпереліпсоїдного контейнера; x_m – двійковий еталонний вектор, що визначає геометричний центр контейнера класу X_m^o в бінарному просторі ознак Ω_B ; $x_{m,1}, x_{m,2}$ – двійкові вектори, що визначають координати першого та другого фокусів контейнера класу X_m^o ; d_m – велика піввісь контейнера класу X_m^o .

При цьому задано обмеження

$$\begin{cases} c_m < d_m, \\ d(x_{m,1} \oplus x_{c,1}) + d(x_{m,2} \oplus x_{c,1}) > 2 \cdot d_m, \\ d(x_{m,1} \oplus x_{c,2}) + d(x_{m,2} \oplus x_{c,2}) > 2 \cdot d_m, \\ d(x_{m,1} \oplus x_c) + d(x_{m,2} \oplus x_c) > 2 \cdot d_m, \\ \delta \in [0; \delta_H / 2], \end{cases} \quad (2)$$

де $d(x_{m,1} \oplus x_{c,1}), d(x_{m,2} \oplus x_{c,1})$ – кодова відстань від першого та другого фокусів контейнера класу X_m^o до першого фокусу контейнера іншого класу X_c ; $d(x_{m,1} \oplus x_{c,2}), d(x_{m,2} \oplus x_{c,2})$ – кодова відстань від першого та другого

фокусів контейнера класу X_m^o до другого фокусу контейнера іншого класу X_c ; $d(x_{m,1} \oplus x_c)$, $d(x_{m,2} \oplus x_c)$ – кодова відстань від першого та другого фокусів контейнера класу X_m^o до еталонного вектора контейнера іншого класу X_c ; δ_H – нормоване поле допусків, що визначає область значень параметра δ .

Необхідно в процесі навчання СППР визначити оптимальні значення координат вектора параметрів функціонування (1), що забезпечують максимальне значення усередненого за алфавітом класів розпізнавання критерію функціональної ефективності (КФЕ)

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{\{k\}} E_m, \quad (3)$$

де E_m – інформаційний КФЕ навчання СППР розпізнавати реалізації класу X_m^o ; $\{k\}$ – впорядкована множина кроків навчання (відновлення контейнерів класів розпізнавання).

Математична модель навчання. Діаграму процесу навчання гіпереліпсоїдної СППР з контуром оптимізації словника ОР в рамках ІЕІ-технології показано на рис.1.




Рис. 1– Категорійна модель навчання гіпереліпсоїдного класифікатора

Категорійна модель (рис.1) містить оператор формування вхідного математичного опису

$$\Phi: G \times T \times Z \times \Omega \rightarrow Y,$$

де G – простір вхідних сигналів (факторів), які діють на СППР; T – множина моментів часу зняття інформації; Z – простір можливих функціональних і технічних станів СППР; Ω – простір ОР; Y – вибіркова множина значень рецепторів (вхідна навчальна матриця).

Оператор $\theta_1 : Y \rightarrow X$ формує бінарну вибіркву множину X – вхідну бінарну навчальну матрицю $\|x_{m,i}^{(j)}\|$, а оператор $\theta_2 : X \rightarrow \mathfrak{R}^{|M|}$ відновлює на кожному кроці навчання оптимальне в інформаційному розумінні розбиття простору ознак на M класів розпізнавання. Оператор класифікації $\Psi_H : \mathfrak{R}^{|M|} \rightarrow I^{|I|}$ перевіряє основну статистичну гіпотезу $\gamma_1 : y_{m,i}^{(j)} \in X_m^o$, де $I^{|I|}$ – множина l статистичних гіпотез. Оператор γ формує множину точнісних характеристик $\mathfrak{Z}^{q|l}$, де $q = l^2$. Оператор φ обчислює терм-множину E значень інформаційного КФЕ, який є функціоналом точнісних характеристик. Оператори f_1 та f_2 корегують геометричні параметри розбиття $\mathfrak{R}^{|M|}$ шляхом формування множини пар фокусів F для різних фокальних відстаней і вибору серед них оптимальних. Оператори r_1 і r_2 корегують геометричні параметри розбиття $\mathfrak{R}^{|M|}$ шляхом цілеспрямованого перебору значень великої півосі гіпереліпсоїдних контейнерів, що є елементами терм-множини R . Оператори δ_1 і δ_2 цілеспрямовано змінюють СКД D на ОР, оцінюючи вплив параметра СКД на КФЕ СППР з метою його максимізації. Оператор $\sigma = \sigma_1 \circ \sigma_2 : E \rightarrow \Omega$ змінює простір ознак Ω згідно з алгоритмом оптимізації словника. При цьому σ_1 – оператор формування словника ознак Σ ; σ_2 – оператор формування нового простору ознак $\Omega' \subset \Omega$. Оператор $U_H : E \rightarrow G \times T \times \Omega \times Z$ регламентує процес навчання СППР.

Таким чином, категорійна модель навчання (рис.1) являє собою композицію контурів оптимізації параметрів функціонування в процесі навчання СППР.

Алгоритм навчання. Відповідно категорійної моделі (рис. 1) оптимізація словника ОР здійснюється шляхом багато циклічної ітераційної процедури

$$\Sigma^* = \arg \max_{\Sigma \in \Omega} \{ \max_{G_S} \{ \max_{\{k\}} \bar{E}_k \} \}, \quad (4)$$

де \bar{E}_k – усереднене значення КФЕ навчання СППР, обчислене на k -му кроці навчання; G_S – область допустимих значень контрольних допусків; $\{k\}$ – множина кроків навчання.

Вхідними даними для алгоритму навчання являються в загальному випадку дійсний масив векторів-реалізацій класів розпізнавання (навчальна матриця) $\{y_{m,i}^{(j)} | m = \overline{1, M}; i = \overline{1, N}; j = \overline{1, n}\}$ і система нормованих допусків на

ознаки розпізнавання $\{\delta_{H,i} | i = \overline{1, N}\}$, що задає область значень відповідних контрольних допусків.

У процедурі (4) внутрішній цикл реалізує базовий алгоритм навчання, основними задачами якого є пошук глобального максимуму інформаційного КФЕ навчання СППР в робочій (допустимій) області визначення його функції та оптимізація геометричних параметрів контейнерів класів розпізнавання. При цьому специфіка базового алгоритму навчання гіпереліпсоїдної СППР полягає у побудові гіпереліпсоїдних контейнерів класів розпізнавання та в перевірці на непоглинання контейнером одного класу фокусів та еталонних векторів контейнерів інших класів. Розглянемо основні етапи базового алгоритму побудови гіпереліпсоїдних вирішальних правил:

1. Ініціалізація максимальної фокальної відстані c_{\max} , $0 \leq c_{\max} \leq \frac{N}{2}$.
2. Обчислення нижнього $A_{KH,i}$ та верхнього $A_{KB,i}$ контрольних допусків для кожної ознаки розпізнавання за формулами:

$$A_{KH,i} = y_{1,i} - \delta; \quad A_{KB,i} = y_{1,i} + \delta,$$

де $y_{1,i}$ – вибіркове середнє значення i -ї ОР у векторах-реалізаціях базового класу X_1^o , відносно якого будується СКД.

3. Формування бінарної навчальної матриці $\|x_{m,i}^{(j)}\|$ за правилом

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } A_{KH,i} \leq y_{m,i}^{(j)} \leq A_{KB,i}. \\ 0, & \text{if } \textit{else}. \end{cases}$$

4. Обчислення для класу X_m^o двійкового еталонного вектора x_m за правилом

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

де ρ_m – рівень селекції координат вектора x_m ($\rho_m = 0,5$).

5. Ініціалізація двійкових координат фокусів контейнера класу X_m^o : $x_{m,1} = x_{m,2} = x_m$.
6. Обнуління лічильника кількості класів: $m = 0$.
7. $m = m + 1$.

8. Обнуління лічильника кроків зміни фокального радіусу: $c_m = 0$.
9. Формування для еталонного вектора x_m множини $\{x_{m,v} \mid v = \overline{1, V}\}$, що складається з V оточуючих його двійкових векторів з кодовою відстанню $d(x_m \oplus x_{m,v}) = c_m$.
10. Розбиття множини векторів $\{x_{m,v} \mid v = \overline{1, V}\}$ на P пар фокусів $\{X_{m,p}^{[2]} \mid p = \overline{1, P}\}$. При цьому для кожної пари $X_{m,p}^{[2]} \Leftarrow x_{m,1}^{(p)}, x_{m,2}^{(p)} >$ повинна виконуватись умова $d(x_{m,1}^{(p)} \oplus x_{m,2}^{(p)}) = 2c_m$.
11. Обнуління лічильника пар фокусів $p = \overline{1, P}$: $p = 0$.
12. $p = p+1$.
13. Ініціалізація фокусів координатами пари векторів $\langle x_{m,1}^{(p)}, x_{m,2}^{(p)} \rangle$.
14. Обнуління лічильника кроків зміни великої півосі гіпереліпсоїдного контейнера: $d_m = 0$.
15. $d_m = d_m + 1$.
16. Обчислення інформаційного КФЕ E_m навчання СППР розпізнавати реалізації класу X_m^o .
17. Якщо виконуються умови (2), то здійснюється перехід до пункту 15, інакше – до пункту 18.
18. Визначається оптимальне значення великої півосі $d_m^* = \arg \max_{\{d_m\}} E_m^*$.
19. Якщо $p < P$, то виконується пункт 12, інакше – пункт 20.
20. Визначення оптимальної пари фокусів контейнера класу X_m^o :

$$\langle x_{m,1}, x_{m,2} \rangle^* = \arg \max_{\{p\}} E_m^* (\langle x_{m,1}^{(p)}, x_{m,2}^{(p)} \rangle).$$
21. $c_m = c_m + 1$.
22. Якщо $c_m \leq c_{\max}$, то виконується пункт 9, інакше – пункт 23.
23. Визначення оптимального значення фокальної відстані:

$$c_m^* = \arg \max_{\{c_m\}} E_m^*.$$
24. Якщо $m < M$, то виконується пункт 7, інакше – пункт 25.
25. ЗУПИН.

Оптимізацію контрольних допусків на ОР доцільно здійснювати за паралельно-последовним алгоритмом, що забезпечує прийнятну оперативність та високу точність обчислення КФЕ. При цьому за алгоритмом паралельної оптимізації СКД на ознаки визначаються квазіоптимальні контрольні допуски, які для последовного алгоритму приймаються як стартові.

Розглянемо основні етапи реалізації алгоритму ПСС словника ознак згідно категорійної моделі, наведеної на рис.1:

1. Для початкового надлишкового словника реалізується процедура паралельної оптимізації СКД на ОР при гіперсферичних контейнерах класів розпізнавання ($c_{\max} = 0$) [4]

$$\delta^* = \arg \max_{G_\delta} \{ \max_{G_E} \bar{E} \}, \quad (5)$$

де \bar{E} – уусереднений за алфавітом класів КФЕ навчання СППР; G_δ – область допустимих значень контрольних допусків на ОР; G_E – область допустимих значень інформаційного КФЕ (1).

2. Одержані за процедурою (5) квазіоптимальні допуски приймаються як стартові для процедури послідовної оптимізації контрольних допусків на ОР.
3. Реалізується ітераційна процедура послідовної оптимізації поля контрольних допусків на ОР при гіперсферичних контейнерах класів розпізнавання ($c_{\max} = 0$)

$$\{ \delta_{K,i}^* \} = \arg \{ \max_{G_{\delta_i}} \{ \max_{G_E} \left[\bigotimes_{s=1}^S \max_{G_d} \bar{E}^{(s)} \right] \} \}, \quad i = \overline{1, N}, \quad (6)$$

де $\bar{E}^{(s)}$ – усереднений за алфавітом класів КФЕ навчання СППР на s -му прогоні послідовної процедури оптимізації; G_{δ_i} – область допустимих значень поля контрольних допусків для i -ї ознаки; G_E – область допустимих значень критерію оптимізації; G_d – область допустимих значень радіусів контейнерів; \otimes – символ операції повтoreння.

4. При оптимальному полі СКД на ОР $\{ \delta_{K,i}^* \mid i = \overline{1, N} \}$ здійснюється запуск базового алгоритму з метою гіпереліпсоїдної корекції вирішального правила ($c_{\max} = \frac{N}{2}$).
5. Формується лічильник кількості ОР у поточному словнику, $i = N$.
6. Формується множина варіантів словників, потужність яких на 1 менша від поточного, $\{ \Sigma_{i,h} \mid h = \overline{1, i} \}$.
7. За алгоритмами паралельно-послідовної оптимізації СКД (5) і (6) та гіпереліпсоїдної корекції вирішальних правил визначаються опти-

мальні параметри навчання та максимальне усереднене значення КФЕ для кожного варіанту словника $\bar{E}_{\Sigma_i, h}$.

8. Визначаємо оптимальний словник ознак Σ_i^* , для якого $\bar{E}_{\Sigma_i^*} = \max_h \bar{E}_{\Sigma_i, h}$.

9. $i=i-1$.

10. Якщо $i > 0$, виконуємо пункт 6, інакше – пункт 11.

11. Визначаємо Σ^* , для якого $\bar{E}_{\Sigma^*} = \max_i \bar{E}_{\Sigma_i^*}$.

12. ЗУПИН.

Як КФЕ навчання використовуємо модифіковану інформаційну міру Кульбака, в якій розглядається відношення повної ймовірності правильного прийняття рішень P_i до повної ймовірності помилкового прийняття рішень P_f . Для двохальтернативних гіпотез модифікований критерій Кульбака має вигляд

$$E_m^{(k)} = [P_{t,m}^{(k)} - P_{f,m}^{(k)}] \cdot \log_2 \frac{P_{t,m}^{(k)}}{P_{f,m}^{(k)}} = \left[\begin{array}{l} P_{t,m}^{(k)} = p(\mu_1) \cdot D_{1,m} + p(\mu_2) \cdot D_{2,m} \\ P_{f,m}^{(k)} = p(\mu_1) \cdot \alpha_m + p(\mu_2) \cdot \beta_m \\ p(\mu_1) = \frac{n_1}{n_1 + n_2}; p(\mu_2) = \frac{n_2}{n_1 + n_2} \end{array} \right] =$$

$$= \frac{[(n_1 \cdot D_{1,m}^{(k)} + n_2 \cdot D_{2,m}^{(k)}) - (n_1 \cdot \alpha_m^{(k)} + n_2 \cdot \beta_m^{(k)})]}{n_1 + n_2} \cdot \log_2 \left(\frac{n_1 \cdot D_{1,m}^{(k)} + n_2 \cdot D_{2,m}^{(k)}}{n_1 \cdot \alpha_m^{(k)} + n_2 \cdot \beta_m^{(k)}} \right) =$$

$$= \frac{[n_2 - n_1 + 2 \cdot (n_1 \cdot D_{1,m}^{(k)} - n_2 \cdot \beta_m^{(k)})]}{n_1 + n_2} \cdot \log_2 \left(\frac{n_2 + (n_1 \cdot D_{1,m}^{(k)} - n_2 \cdot \beta_m^{(k)})}{n_1 - (n_1 \cdot D_{1,m}^{(k)} - n_2 \cdot \beta_m^{(k)})} \right), \quad (7)$$

де $D_{1,m}^{(k)}$ – перша достовірність, обчислена на k -му кроці навчання для m -го класу; $D_{2,m}^{(k)}$ – друга достовірність; $\alpha_m^{(k)}$ – помилка першого роду; $\beta_m^{(k)}$ – помилка другого роду; n_1, n_2 – кількість реалізацій, що розмежовуються гіперповерхнею контейнера класу X_m^o .

Оскільки навчальна вибірка є обмеженою за обсягом, то замість точнісних характеристик на практиці використовуються їх оцінки у вигляді емпіричних частот

$$D_{1,m}^{(k)} = \frac{K_{1,m}^{(k)}}{n_1}; \beta_m^{(k)} = \frac{K_{2,m}^{(k)}}{n_2}, \quad (8)$$

де $K_{1,m}^{(k)}$ – кількість подій, що характеризують належність реалізацій образу до контейнера класу X_m^o , якщо вони дійсно є реалізаціями цього класу; $K_{2,m}^{(k)}$ – кількість подій, що характеризують належність реалізацій до контейнера класу X_m^o , якщо вони насправді належать іншому класу.

Суми $K_{1,m}^{(k)}$ і $K_{2,m}^{(k)}$ обчислюються на k -му кроці навчання СППР за правилом

$$K_{1,m}^{(k)}[0] = 0; K_{2,m}^{(k)}[0] = 0;$$

$$\text{if } x_m^{(j)} \in X_m^o \text{ then } K_{1,m}^{(k)}[j] := K_{1,m}^{(k)}[j-1] + 1;$$

$$\text{if } x_c^{(j)} \in X_m^o \text{ then } K_{2,m}^{(k)}[j] := K_{2,m}^{(k)}[j-1] + 1,$$

де $x_c^{(j)}$ – j -та реалізація “чужого” класу X_c^o .

Визначення належності реалізації $x^{(j)}$, наприклад, класу X_m^o , для класифікатора з гіпереліпсоїдними контейнерами здійснюється за правилом

$$\text{if } d(x_{m,1} \oplus x^{(j)}) + d(x_{m,2} \oplus x^{(j)}) \leq 2d_m \text{ then } x^{(j)} \in X_m^o \text{ else } x^{(j)} \notin X_m^o,$$

де $d(x_{m,1} \oplus x^{(j)})$, $d(x_{m,2} \oplus x^{(j)})$ – кодові відстані між вектором $x^{(j)}$ і першим та другим фокусами контейнера класу X_m^o відповідно; d_m – значення великої півосі контейнера класу X_m^o ; \oplus – символ операції складання за модулем два.

Модифікація критерію Кульбака після відповідної підстановки оцінок (8) у вираз (7) набуває вигляду

$$E_m^{(k)} = \frac{[n_2 - n_1 + 2 \cdot (K_1^{(k)} - K_2^{(k)})]}{n_2 + n_1} \cdot \log_2 \left(\frac{n_2 + (K_1^{(k)} - K_2^{(k)}) + 10^{-r}}{n_1 - (K_1^{(k)} - K_2^{(k)}) + 10^{-r}} \right), \quad (9)$$

де 10^{-r} – константа, що введена для виключення нескінченних піків у випадках нульових емпіричних частот при обчисленні критерію.

При обчисленні інформаційного КФЕ для m -го класу всю багатовимірну навчальну матрицю зручно розбити на дві частини з обсягами $n_1 = n_{\min}$ та $n_2 = n_{\min}(M-1)$, де n_{\min} – мінімальний обсяг репрезентативної навчальної вибірки для кожного класу. Після підстановки значень n_1 та n_2 у вираз (9) робоча формула модифікованого критерію Кульбака набуває вигляду

$$E_m^{(k)} = \frac{[n_{\min} \cdot (M-2) + 2 \cdot (K_1^{(k)} - K_2^{(k)})]}{n_{\min} \cdot M} \cdot \log_2 \left(\frac{n_{\min} \cdot (M-1) + (K_1^{(k)} - K_2^{(k)}) + 10^{-r}}{n_{\min} - (K_1^{(k)} - K_2^{(k)}) + 10^{-r}} \right). \quad (10)$$

Нормовану модифікацію критерію (10) представимо у вигляді

$$\hat{E}_m^{(k)} = \frac{E_m^{(k)}}{E_{\max}}, \quad (11)$$

де E_{\max} – значення критерію при $K_1^{(k)} = n_1 = n_{\min}$ та $K_2^{(k)} = 0$.

При цьому робоча область визначення функції інформаційного КФЕ обмежена як умовами (2), так і нерівностями $D_1 \geq 0,5$ і $D_2 \geq 0,5$.

Таким чином, алгоритм навчання СППР полягає в ітераційній процедурі наближення глобального максимуму інформаційного КФЕ (3) до його граничного значення шляхом оптимізації словника ознак, системи контрольних допусків та геометричних параметрів контейнерів.

Приклад реалізації алгоритму навчання. Реалізація запропонованого алгоритму здійснювалася в НТК “Інститут монокристалів” (м. Харків) при вирощуванні монокристалів на установці типу “РОСТ” за методом Кіропулоса [9]. За архівною історією вирощувань та даними кінцевого лабораторного контролю якості оптичних характеристик та діаметру монокристала було сформовано вхідну апіорно класифіковану нечітку навчальну матрицю для трьох класів, що характеризували якість монокристалу. При цьому кількість ознак розпізнавання дорівнювала $N=30$. Динаміку зміни максимуму усередненого нормованого інформаційного критерію Кульбака (11) при оптимізації СКД за паралельно-послідовним алгоритмом з повним словником ознак при відновленні в радіальному базисі простору ознак гіперсферичних контейнерів класів розпізнавання показано на рис. 2. Тут і далі штрихована ділянка графіка позначає робочу область визначення інформаційного КФЕ.




Рис. 2 – Графік зміни максимумів КФЕ при оптимізації СКД при повному словнику ОР для гіперсферичного класифікатора

Аналіз рис. 2 показує, що оптимальний вектор СКД на ОР був одержаний на 3217 кроці навчання, на якому досягнуто глобальний максимум усередненого інформаційного КФЕ $\bar{E}^* = 0,718$.

З метою підвищення значення КФЕ запускався алгоритм оптимізації словника ознак. На рис. 3 показана гістограма залежності значення максимального усередненого нормованого КФЕ (11) від варіантів словників сформованих в процесі оптимізації за алгоритмом ПСС при використанні гіперсферичних контейнерів класів розпізнавання. Затемнені стовпчики відповідають вибору словника на конкретному кроці його оптимізації. Горизонтальна лінія показує значення КФЕ, для початкового словника ознак.




Рис. 3 – Гістограма залежності максимального усередненого значення нормованого КФЕ від варіантів словників ОР при гіперсферичних контейнерах класів розпізнавання

Аналіз рис. 3 показує, що на третьому кроці оптимізації усереднений нормований КФЕ досягає свого максимального значення $\bar{E}_{\Sigma_{28,26}} = 1,0$, що свідчить про побудову безпомилкових за навчальною матрицею вирішальних правил. При цьому було перебрано 86 словників та видалено з початкового словника 2-гу, 7-му та 28-му ознаки розпізнавання.

З метою підвищення ефективності навчання після паралельно послідовної оптимізації СКД додатково запускається алгоритм гіпереліпсоїдної корекції вирішальних правил. На рис. 4 показана гістограма залежності значення максимального усередненого нормованого КФЕ (11) від варіантів словників, сформованих в процесі оптимізації за алгоритмом ПСС при використанні гіпереліпсоїдних контейнерів класів розпізнавання.

Аналіз рис. 4 показує, що вже на першому кроці оптимізації усереднений нормований КФЕ досягає свого максимального значення $\bar{E}_{\Sigma_{30,7}} = 1,0$. При цьому було перебрано 7 словників та видалено з початкового словника одну 7-у ознаку, яка виявилася максимально заважаючою.

Після видалення заважаючої ознаки в процесі гіпереліпсоїдної корекції вирішальних правил були визначені для всіх класів розпізнавання оптимальні значення фокальних відстаней, які відповідно дорівнювали $c_1^* = 0$, $c_2^* = 4$ і

$c_3^* = 0$ (у кодових одиницях). Це свідчить, що контейнери класів X_1^o та X_3^o залишилися гіперсферичними, а контейнер X_2^o деформувався у гіпереліпсоїд обертання з ексцентриситетом твірного еліпсу $e_2^* = \frac{c_2^*}{d_2^*}$, де d_2^* – оптимальна довжина великої півосі твірного еліпсу. Графік залежності нормованого інформаційного КФЕ (11) від фокальної відстані контейнера класу X_2^o показано на рис. 5.

Аналіз рис. 5 показує, що значення фокальної відстані контейнера класу X_2^o від 2 до 4 кодових одиниць забезпечує граничне значення КФЕ, проте виходячи з умови максимальної компактності реалізацій образу обираємо значення рівне $c_2^* = 4$.



Рис. 4 – Гістограма залежності максимального усередненого значення нормованого КФЕ від варіантів словників ОР при гіпереліпсоїдній корекції вирішальних правил





Рис. 5 – Залежність нормованого інформаційного КФЕ для X_2^o від фокальної відстані його контейнера при оптимальному словнику ОР

На рис. 6 наведено графіки залежності нормованого КФЕ (8) від довжини великої півосі гіпереліпсоїдних контейнерів класів X_1^o , X_2^o та X_3^o , що відновлюються в бінарному просторі ознак при оптимальному словнику. Для класів X_1^o та X_3^o довжина великої півосі є радіусом їхніх гіперсферичних контейнерів.


Аналіз рис. 6 показує, що оптимальні значення великих півосей контейнерів класів розпізнавання відповідно дорівнюють $d_1^* = 5$, $d_2^* = 14$ і $d_3^* = 5$.

Таким чином, порівняльний аналіз рис. 3 і рис. 4 показує, що оптимізація словника ОР за алгоритмом ПСС при застосуванні гіпереліпсоїдних контейнерів класів розпізнавання підвищила оперативність побудови безпомилкових за навчальною матрицею вирішальних правил. При цьому заважаючих ознак виявилось менше в порівнянні з гіперсферичним класифікатором.

Висновки. У рамках ІЕІ-технології розроблено інформаційне, алгоритмічне та програмне забезпечення гіпереліпсоїдного класифікатора з оптимізацією словника ОР для СППР, що є складовою частиною АСК процесу вирощування скінтіляційних монокристалів. Фізичне моделювання за даними архівної історії вирощування скінтіляційних монокристалів показало, що використання гіпереліпсоїдних вирішальних правил при оптимізації словника ОР за алгоритмом ПСС дозволило підвищити ефективність навчання за рахунок збільшення оперативності оптимізації. Гіпереліпсоїдні вирішальні правила є більш завадозахищеними в порівнянні з гіперсферичними, оскільки вони видаляють меншу кількість заважаючих ознак при побудові безпомилкових за навчальною матрицею вирішальних правил. Такий ефект може бути корисним при функціонуванні СППР у режимі факторного кластер-аналізу, де існує непередбачуваність цінності інформації, що міститься в ознаках розпізнавання.



а



б




Рис. 6 – Графіки залежності КФЕ від значень великих півосей гіпереліпсоїдних контейнерів при оптимальному словнику ОР:

a – клас X_1^0 ; b – клас X_2^0 ; v – клас X_3^0

Список литературы: 1. *Евменов В. П.* Интеллектуальные системы управления / В. П. Евменов. – М. : Книжный дом «ЛИБРОКОМ». – 2009. – 304 с. 2. *Симанков В. С.* Адаптивное управление сложными системами на основе теории распознавания образов / В. С. Симанков, Е. В. Луценко. – Краснодар : Техн. ун-т Кубан. гос. технол. ун-та. –1999. – 318 с. 3. *Довбиш А. С.* Основы проектирования интеллектуальных систем: Навчальний посібник / А. С. Довбиш. – Суми : Видавництво Сум ДУ. – 2009. – 171 с. 4. *Довбиш А. С.* Интеллектуальная система поддержки принятия решений для керування вирощуванням монокристалів / А. С. Довбиш, В. С. Суздаль, В. В. Москаленко // Вісник СумДУ. Серія технічні науки. – 2011. – № 2. – С. 39–47. 5. *Korn F.* On the 'Dimensionality Curse' and the 'Self-Similarity Blessing' / F. Korn, B. Pagel, C. Faloutsos. – IEEE Trans. on Knowledge and Data Engineering, 1, 13, January, 2001. – P. 96–111. 6. *Шелехов І. В.* Оптимізація словника ознак розпізнавання за методом послідовної спадної селекції / І. В. Шелехов // Современные методы кодирования в электронных системах: междунар. науч. конф., 26-27 окт. 2004 г.: тезисы докл. – 2004. – С. 42–43. 7. *Хьюбер Дж. П.* Робастность в статистике / Дж. П. Хьюбер. – М. : Мир. – 2007. – 300 с. 8. *Василенко Ю. А.* Аппроксимация обучающей выборки гиперпараллелепипедами / Ю. А. Василенко, Ф. Г. Ващук, С. И. Коновалов // Науковий вісник УжДПУП. Природничі науки. – Ужгород : Вид-во УжДШЕП, 1998. – № 2. – С. 9–17. 9. *Суздаль В. С.* Сцинтилляционные монокристаллы: автоматизированное выращивание / В. С. Суздаль, П. Е. Стадник, Л. И. Герасимчук, Ю. М. Епифанов. – Х. : ИСМА, 2009. – 260 с.

Надійшла до редколегії 25.04.2012