

**ОПТИМІЗАЦІЯ КОНТРОЛЬНИХ ДОПУСКІВ НА ОЗНАКИ
РОЗПІЗНАВАННЯ В ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНИХ МЕТОДАХ
АВТОМАТИЧНОЇ КЛАСИФІКАЦІЇ**

**А.С. Довбиш,
М.В. Козинець,
С.М. Котенко**

Сумський державний університет

Пропонується в рамках інформаційно-екстремальної інтелектуальної технології метод синтезу здатної навчатися системи керування, який дозволяє підвищити її функціональну ефективність навчання шляхом застосування паралельно-послідовного алгоритму оптимізації контрольних допусків на ознаки розпізнавання.

ВСТУП

Підвищення ефективності та оперативності керування виробничими процесами органічно пов'язано із розробленням та впровадженням інтелектуальних інформаційних технологій, що базуються на ідеях і методах машинного навчання. Застосування здатних навчатися (самонавчатися) систем керування (СК) у виробництві дозволяє здійснити перехід від суб'єктивних методів керування до інтелектуальних інформаційних технологій керування слабо формалізованими процесами, які функціонують за умов апріорної невизначеності. Основні перешкоди на шляху інтенсивного впровадження адаптивних СК, що навчаються, все ще обумовлені відставанням теорії машинного навчання від потреб практики. Так, основним недоліком відомих методів машинного навчання систем розпізнавання [1-3] є ігнорування в практичних задачах керування перетину класів розпізнавання у просторі ознак розпізнавання, що потребує попередньої нормалізації образів [4] з метою їх наближення до еталонів. На відміну від відомих методів нормалізація образів у рамках інформаційно-екстремальної інтелектуальної технології (ІЕІТ) аналізу та синтезу СК, що навчаються, [5] здійснюється безпосередньо в процесі навчання системи шляхом цілеспрямованої трансформації апріорного нечіткого розбиття простору ознак на класи розпізнавання в чітке розбиття еквівалентності, що дозволяє побудувати безпомилковий за навчальною матрицею класифікатор. Така трансформація здійснюється за допомогою допустимих перетворень у дискретному паракептуальному просторі, серед яких важливу роль відіграє оптимізація (тут і далі в інформаційному розумінні) системи контрольних допусків (СКД) на ознаки розпізнавання. У працях [6, 7] досліджувалась оптимізація контрольних допусків як за паралельним алгоритмом, коли поля допусків для всіх ознак змінювалися одночасно, так і за послідовним алгоритмом. Якщо паралельний алгоритм оптимізації дозволяє підвищити оперативність навчання, то він втрачає в точності обчислення глобального максимуму інформаційного критерію функціональної ефективності (КФЕ) навчання системи. Послідовний алгоритм оптимізації СКД, навпаки, втрачає в оперативності навчання, але дозволяє часто побудувати, наприклад, для образів 2D безпомилковий класифікатор навіть без оптимізації інших просторово-часових параметрів функціонування. Слабким місцем існуючих послідовних алгоритмів оптимізації СКД [7] є неформалізований вибір стартових допусків на ознаки розпізнавання. Невдалий вибір таких допусків може вивести систему на початку оптимізації за межі робочої (допустимої) області визначення функції КФЕ навчання, що призводить до збільшення часу оптимізації СКД.

Метою статті є розробка паралельно-послідовного алгоритму оптимізації СКД, який дозволяє підвищити оперативність навчання при забезпеченні високої точності пошуку глобального максимуму КФЕ навчання в робочій області визначення його функції.

ПОСТАВЛЕННЯ ЗАДАЧІ ДОСЛІДЖЕННЯ

За умови обґрунтування у загальному випадку нечіткої гіпотези компактності реалізацій образу оптимізацію СКД на ознаки розпізнавання розглянемо в рамках ІЕІТ для гіперсферичного класифікатора, в якому контейнери класів розпізнавання відновлюються на кожному кроці навчання в радіальному базисі дискретного простору Хеммінга. Нехай дано алфавіт класів розпізнавання $\{X_m^o \mid m = \overline{1, M}\}$, навчальна матриця типу “об’єкт – властивість” $\|y_{m,i}^{(j)}\|$, $i = \overline{1, N}$, $j = \overline{1, n}$, де N , n – кількість ознак розпізнавання та векторів-реалізацій образу відповідно. Задано структурований вектор параметрів функціонування системи, що навчається, $g = \langle x_1, d_1, \delta \rangle$, який складається з еталонного вектора-реалізації x_1 найбільш бажаного (базового) класу X_1^o , геометричного параметра d_m – кодової відстані гіперповерхні контейнера K_1^o класу X_1^o від вершини еталонного вектора $x_1 \in X_1^o$, який визначається у просторі Хеммінга за формулою

$$d_1 = \sum_{i=1}^N (x_{1,i} \oplus \lambda_i), \quad (1)$$

де $x_{1,i}$ – i -та координата вектора x_1 ; λ_i – i -та координата деякого вектора λ , вершина якого знаходиться на гіперповерхні контейнера $K_1^o \in X_1^o$, і параметр симетричного поля допусків δ . Надалі кодову відстань (1) між векторами x_1 і λ будемо умовно називати радіусом псевдосфери і позначати з метою спрощення у вигляді $d_m = d(x_m \oplus \lambda)$. Задано допустимі області значень відповідних параметрів $x_1 \in \Omega_B^{|N|}$, де $\Omega_B^{|N|}$ – бінарний простір ознак потужності N ; $d_1 \in [0; d(x_1 \oplus x_c) - 1]$, де x_c – еталонний вектор-реалізація сусіднього (найближчого) класу X_c^o і параметра $\delta \in [0; \delta_H / 2]$, де δ_H – нормоване (експлуатаційне) поле допусків на ознаки розпізнавання.

Треба на етапі навчання за априорно класифікованими реалізаціями нечітких образів побудувати оптимальне в інформаційному розумінні чітке розбиття $\Re^{|M|}$ дискретного простору ознак Ω_B на M класів розпізнавання шляхом ітераційної максимізації усередненого за алфавітом $\{X_m^o\}$ значення інформаційного КФЕ навчання СК:

$$\bar{E}^* = \frac{1}{M+1} \sum_{m=1}^{M+1} \max_{\{d\}} E_m, \quad (2)$$

де E_m – інформаційний КФЕ навчання системи розпізнавати реалізації класу X_m^o ; $\{d\}$ – множина кроків навчання.

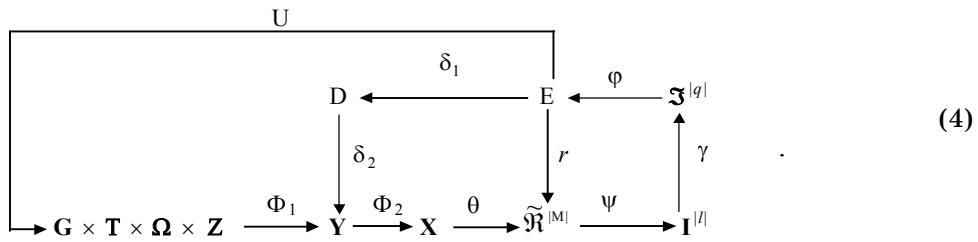
МАТЕМАТИЧНА МОДЕЛЬ

Нехай вхідний математичний опис СК, що навчається, має структуру

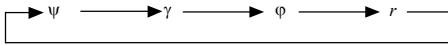
$$\Delta_B = \langle G, T, \Omega, Z, Y, X; \Phi_1, \Phi_2 \rangle, \quad (3)$$

де G – простір вхідних сигналів (факторів), які діють на СК; T – множина моментів часу зняття інформації; Ω – простір ознак розпізнавання; Z – простір можливих функціональних станів СК; Y – вибіркова множина в евклідовому просторі; X – вибіркова множина в бінарному просторі Хеммінга, яка утворює вхідну бінарну навчальну матрицю; Φ_1, Φ_2 – оператори формування множин Y і X відповідно.

Тоді категорійна модель у вигляді діаграми відображення множин, що застосовуються при оптимізації СКД на ознаки розпізнавання в процесі навчання СК, має такий вигляд:



За ІЕІТ на етапі навчання оператор $\theta : X \rightarrow \tilde{\mathcal{R}}^{|M|}$ відновлює на кожному кроці навчання у загальному випадку нечітке розбиття $\tilde{\mathcal{R}}^{|M|}$. Оператор класифікації $\Psi : \tilde{\mathcal{R}}^{|M|} \rightarrow I^{|l|}$ перевіряє основну статистичну гіпотезу $\gamma_1 : y_m^{(j)}, i \in X_m^o$, де $I^{|l|}$ – множина статистичних гіпотез. Оператор γ визначає множину точнісних характеристик процесу навчання $\Sigma^{|q|}$, де $q = l^2$, а оператор φ обчислює терм-множину E значень інформаційного критерію оптимізації. Оператор r корегує розбиття $\tilde{\mathcal{R}}^{|M|}$ шляхом ітераційного пошуку глобального максимуму критерію (1) у робочій області визначення його функції. У діаграмі (4) контур операторів



реалізує базовий алгоритм навчання, який на кожному кроці навчання обчислює значення критерію $E_m \in E$, здійснюючи пошук глобального максимуму його функції в робочій області її визначення і оптимізує геометричні параметри розбиття. Оператор $U : E \rightarrow G \times T \times \Omega \times Z$ регламентує процес навчання і дозволяє оптимізувати параметри його плану. Контур оптимізації СКД, яка утворює терм-множину D , замикається послідовно оператором $\delta_1 : E \mapsto D$ і оператором $\delta_2 : D \mapsto Y$, який змінює реалізації образу в процесі максимізації критерію $E_m \in E$.

КРИТЕРІЙ ОПТИМІЗАЦІЇ

У праці [4] для двохальтернативної системи оцінок та рівноміровірних гіпотез одержано таку модифікацію інформаційної міри Кульбака:

$$E = 0,5 \log_2 \left(\frac{D_1 + D_2}{\alpha + \beta} \right) * [(D_1 + D_2) - (\alpha + \beta)] = \log_2 \left(\frac{2 - (\alpha + \beta)}{\alpha + \beta} \right) * [1 - (\alpha + \beta)], \quad (5)$$

де α , β , D_1 , D_2 – точнісні характеристики: помилки першого та другого родів, перша та друга достовірності відповідно.

Оскільки навчальна вибірка є обмеженою за обсягом, то надалі замість точнісних характеристик будемо оперувати їх оцінками (емпіричними частотами):

$$D_1 = \frac{K_1}{n}; \alpha = \frac{K_2}{n}; \beta = \frac{K_3}{n}; D_2 = \frac{K_4}{n}, \quad (6)$$

де K_1 , K_2 – кількість подій, які означають відповідно належність або неналежність реалізації класу X_m^0 , якщо $\{x_m^n\} \in X_m^0$; K_3 , K_4 – кількість подій, які означають відповідно належність або неналежність реалізації класу X_m^0 , якщо вони дійсно не належать класу X_m^0 ; n – обсяг вибірки.

Тоді робоча модифікація критерію Кульбака після відповідної підстановки оцінок (6) у вираз (5) набуває вигляду

$$E = \frac{1}{n} \log_2 \left\{ \frac{2n + 10^{-r} - [K_2^{(k)} + K_3^{(k)}]}{[K_2^{(k)} + K_3^{(k)}] + 10^{-r}} \right\} * [n - (K_2^{(k)} + K_3^{(k)})], \quad (7)$$

де 10^{-r} – достатньо мале число.

Тестовий алгоритм обчислення коефіцієнтів $K_2^{(k)}$ і $K_3^{(k)}$ у формулі (7) має вигляд

```
If   x_m^{(j)} ∉ X_m^o      then   K_2^{(k)}[j] := K_2^{(k)}[j-1] + 1      else   K_2^{(k)}[j] := K_2^{(k)}[j-1] ;
if   x_c^{(j)} ∈ X_m^o     then   K_3^{(k)}[j] := K_3^{(k)}[j-1] + 1      else   K_3^{(k)}[j] := K_3^{(k)}[j-1] .
```

АЛГОРИТМ ОПТИМІЗАЦІЇ КОНТРОЛЬНИХ ДОПУСКІВ

Розглянемо підхід до оптимізації СКД на ознаки розпізнавання в рамках ІЕГТ. На рис. 1 показано симетричне (двообічне) поле допусків на значення i -ї ознаки $y_{m,i}^{(j)}$, $i = \overline{1, N}$.

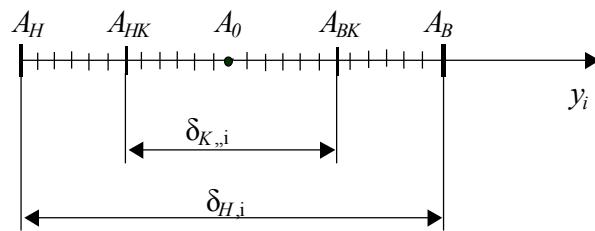


Рисунок 2– Симетричне поле допусків на значення ознаки розпізнавання

На рис. 2 взято такі позначення: A_0 –номінальне значення ознаки y_i ; A_H , A_B – нижній і верхній нормовані допуски відповідно; A_{HK} , A_{BK} – нижній і верхній контрольні допуски відповідно; $\delta_{H,i}$ – нормоване поле допусків; $\delta_{K,i}$ – контрольне поле допусків.

Існує декілька можливих стратегій зміни поля допусків $\delta_{K,i}$, серед яких відмітимо дві основні:

- симетрична стратегія $S_1(\varleftarrow \text{ var } A_{HK}, \varrightarrow \text{ var } A_{BK})$, яка є виправданою, наприклад, за умови підтвердження розвідувальним аналізом збігу номінального значення A_0 з теоретичним центром розсіювання значень навчальної вибірки $\{y_{m,i}^{(j)} \mid j = \overline{1, n}\}$;
- асиметрична стратегія $S_2(\varleftarrow \text{ var } A_{HK}, \varrightarrow \text{ var } A_{BK})$, яка має місце при відхиленні значення A_0 від центра розсіювання значень вибірки $\{y_{m,i}^{(j)} \mid j = \overline{1, n}\}$.

Задача оптимізації контрольних допусків на ознаки розпізнавання є частинною задачею інформаційного синтезу, в якій необхідно визначити екстремальні значення параметра поля допусків

$$\delta^* = \arg \max_{G_\delta} \max_{G_\Omega} \{ \max_{G_d} \bar{E} \},$$

де G_δ, G_Ω, G_d – дозволі обсягі значень параметрів δ, x_1 і d_1 відповідно.

Алгоритм оптимізації контрольних допусків, як і інших параметрів навчання СК у рамках IEIT, полягає у наближенні глобального максимуму інформаційного критерію оптимізації до граничного його значення в обсягі значень функції критерію. У праці [4] доведено збіжність алгоритму послідовної оптимізації контрольних допусків на ознаки розпізнавання, який має таку структуру ітераційної процедури оптимізації:

$$\{\delta_{K,i}^*\} = \arg \{ \max_{G_{\delta_i}} \{ \max_{G_E} \left[\bigotimes_{l=1}^L \max_{G_{d_l}} E_1^{(l)} \right] \} \}, \quad i = \overline{1, N}, \quad (8)$$

де $G_{\delta_i}, G_E, G_{d_l}$ – обсягі дозволі значень поля контрольних допусків для i -ї ознаки, критерію оптимізації і кодової відстані d_1 відповідно; \otimes – символ операції повтору; L – кількість прогонів ітераційної процедури послідовної оптимізації контрольних допусків; $E_1^{(l)}$ – значення критерію (3) при оптимізації контрольного поля допусків для i -ї ознаки розпізнавання на l -му прогоні процедури оптимізації.

Розглянемо алгоритм послідовної оптимізації контрольних допусків на ознаки розпізнавання за процедурою (8). Вхідні дані: масив реалізацій образу $\{y_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n}\}$; стартова система контрольних допусків $\{\delta_{K,i}\}$ і система нормованих допусків $\{\delta_{H,i}\}$, яка визначає обсягі значень відповідних контрольних допусків. Попередньо для кожної ознаки визначається ціна градації Δ_i , на яку змінюється i -та ознака. Схема алгоритму послідовної оптимізації контрольних допусків така:

- 1 Обнулення лічильника прогонів процедури оптимізації параметрів навчання $l:=0$.
- 2 Для стартової системи допусків обчислюється за базовим алгоритмом навчання (4) значення функції $E_{\max,1}^{(l)}$.
- 3 Формування лічильника прогонів: $l: l+1$.

- 4 Обнулення лічильника ознак розпізнавання: $i:=0$.
- 5 Формування лічильника ознак розпізнавання: $i: i+1$.
- 6 Визначення екстремального значення параметра поля допусків $\delta_{K,i}^{(l)}$ за процедурою (8), в якій внутрішній цикл оптимізації реалізує базовий алгоритм навчання.

$$7 \quad \delta_{K,i}^{(l)} := \max_{\delta_{K,i} \in \delta_{H,i}} \delta_{K,i}^{(l)}.$$

8 Якщо $i \leq N$, то виконується пункт 5, інакше – пункт 9.

- 9 Якщо $|E_{\max,1}^{(l-1)} - E_{\max,1}^{(l)}| \leq \varepsilon$, де ε – будь-яке мале позитивне число, то виконується пункт 10, інакше – пункт 3.

10 $\{\delta_{K,i}^*\} := \{\delta_{K,i}^{(l)}\}$ і “ЗУПИН”.

Для формування стартової системи контрольних допусків застосуємо паралельний алгоритм їх оптимізації, що оптимізує контрольні допуски на всі ознаки одночасно. Вхідні дані такі самі, як і для алгоритму послідовної оптимізації, але за область значень параметра δ береться інтервал $[1 ; \delta_H / 2]$, де δ_H – ширина нормованого поля допусків.

Розглянемо кроки реалізації алгоритму паралельної оптимізації:

1 Обнуляється лічильник кроків зміни параметра δ : $l:=0$.

- 2 Запускається лічильник: $l:=l+1$ і обчислюються нижні та верхні контрольні допуски для всіх ознак:

$$\{A_{HK,i}[l] := y_{m,i} - \delta[l]\} \quad i \quad \{A_{BK,i}[l] = y_{m,i} + \delta[l]\},$$

$i = \overline{1, N}$ відповідно.

3 Реалізується базовий алгоритм навчання.

4 Якщо $E_1^*[l] \geq E_1^*[l-1]$, то виконується пункт 5, інакше – пункт 6.

5 Якщо $\delta \leq \delta_H / 2$, то виконується пункт 2, інакше – пункт 6.

6 $\{A_{HK,i}^* := A_{HK,i}[l-1]\}; \{A_{BK,i}^* := A_{BK,i}[l-1]\}, i = \overline{1, N}$;

$E_1^* := E_1^*[l-1]$ і “ЗУПИН”.

ПРИКЛАД РЕАЛІЗАЦІЇ АЛГОРИТМУ ПАРАЛЕЛЬНО-ПОСЛІДОВНОЇ ОПТИМІЗАЦІЇ

Розглянемо реалізацію алгоритму оптимізації СКД у рамках ІЕІТ на прикладі навчання СППР, яка є складовою частиною АСКТП виробництва складного мінерального добрива НКР (азот – калій – фосфор) у ВАТ «Суміхімпром». Для наочності розглянемо оптимізацію апріорного нечіткого розбиття для трьох класів: X_1^o , X_2^o і X_3^o , які відрізнялися один від одного вмістом хімічних компонентів. Тут клас X_1^o характеризує найкращий технологічний режим, що забезпечує відповідність кінцевого продукту заданому стандарту, а інші класи характеризують порушення технологічного процесу, що привело до відхилення вмісту азоту і фосфору від норми. Навчальна матриця складалась із 40 векторів-реалізацій для кожного класу. Структуровані вектори-реалізації класів мали 41 ознаку розпізнавання (із них 28 – технологічні параметри, значення яких візуально відображалися на моніторі, і 13 – результати поточного хімічного аналізу, які за графіком вводилися в систему оператором).

Для аналізу ефективності алгоритму оптимізації СКД на ознаки розпізнавання спочатку було реалізовано базовий алгоритм навчання за ІЕІТ, який оптимізував контейнери класів без оптимізації контрольних

допусків. На рис. 3–5 показано графіки залежності функції КФЕ (7) від радіусів контейнерів відповідних класів

E

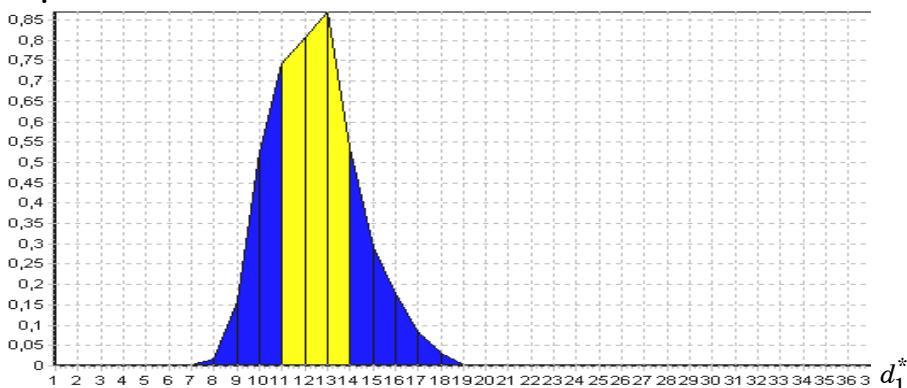


Рисунок 3–Оптимізація контейнера класу X_1^o за базовим алгоритмом навчання

E

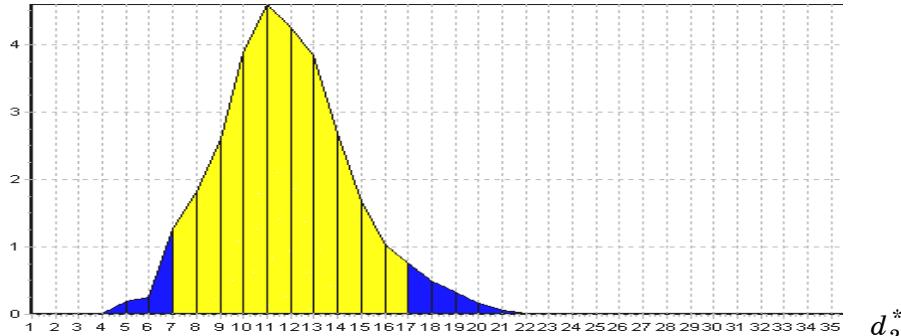


Рисунок 4–Оптимізація контейнера класу X_2^o за базовим алгоритмом навчання

E

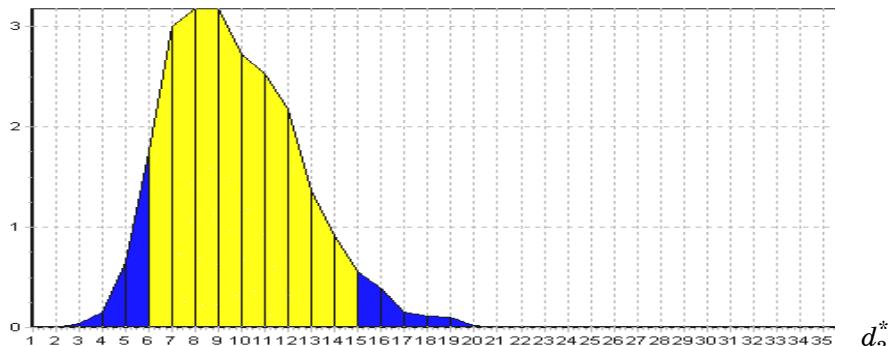


Рисунок 5–Оптимізація контейнера класу X_3^o за базовим алгоритмом навчання

Тут і далі світла область графіка означає робочу область визначення інформаційного КФЕ навчання системи. Аналіз рис. 3–5 показує, що оптимальні радіуси контейнерів у кодових одиницях дорівнюють відповідно $d_1^* = 13$, $d_2^* = 11$ і $d_3^* = 9$.

Для визначення стартових допусків на ознаки розпізнавання було запущено алгоритм паралельної оптимізації допусків. На рис. 6 показано динаміку зміни КФЕ навчання системи в процесі оптимізації параметра поля допусків δ за паралельним алгоритмом.

Як показано на рис. 6, оптимальне значення параметра δ стартового поля допусків, яке гарантує знаходження системи в робочій області визначення функції критерію (5), дорівнює $\delta^* = \pm 36$ відносних одиниць для всіх ознак розпізнавання. Крім того, усереднене значення КФЕ навчання для трьох класів є значно більшим ($\bar{E} = 11,32$) у порівнянні з базовим алгоритмом навчання (рис.3-5), але воно не досягає граничного значення критерію ($\bar{E}^* = 13,96$ при $n=40$ і $r = 2$).

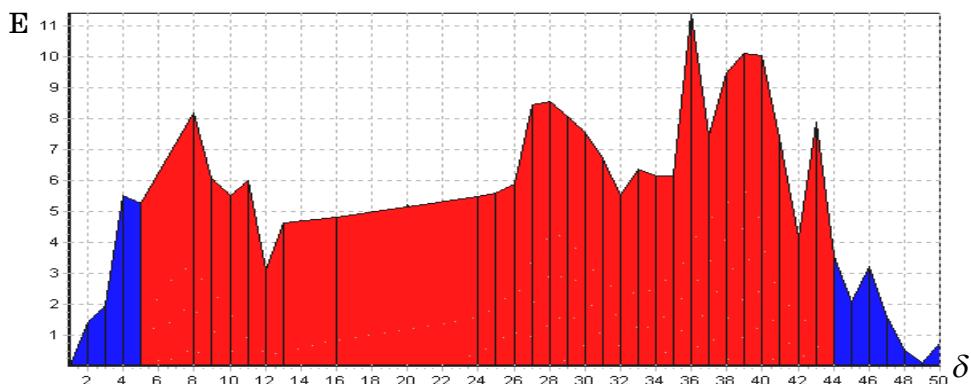


Рисунок 6 – Оптимізація параметра δ за паралельним алгоритмом

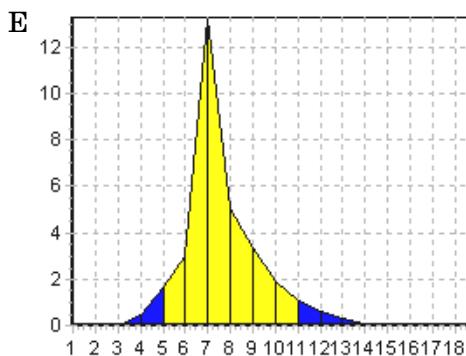


Рисунок 7–Оптимізація контейнера класу X_1^o за послідовним алгоритмом

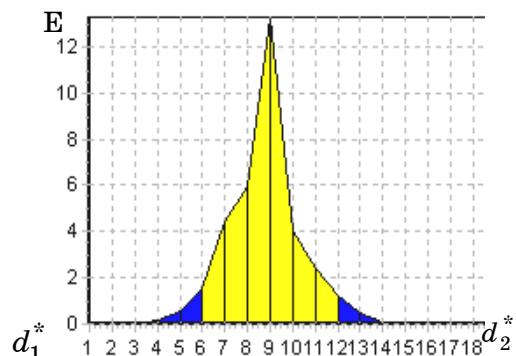


Рисунок 8–Оптимізація контейнера класу X_2^o за послідовним алгоритмом

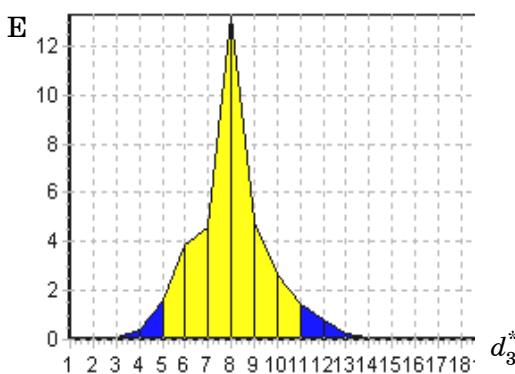


Рисунок 9–Оптимізація контейнера класу X_3^o за послідовним алгоритмом

Після визначення стартової СКД запускається алгоритм послідовної оптимізації (8) за тим самим критерієм (7). На рис. 7–9 наведено графіки залежності КФЕ від радіусів контейнерів відповідних класів після оптимізації контрольних допусків за послідовним алгоритмом.

Аналіз рис. 7–9 показує, що оптимальні радіуси відповідних контейнерів класів розпізнавання дорівнюють $d_1^* = 7$, $d_2^* = 9$, $d_3^* = 8$. При цьому середнє значення радіусів контейнерів дорівнює 5,33, що значно менше відповідного середнього значення для базового алгоритму навчання (11). Це свідчить про зменшення ступеня перетину класів у процесі оптимізації контрольних допусків на ознаки розпізнавання. Аналіз зміни величини середніх значень КФЕ в процесі оптимізації СКД показав, що при реалізації базового алгоритму навчання $\bar{E} = 2,90$, при оптимізації за паралельним алгоритмом $\bar{E} = 11,32$, а при оптимізації за послідовним алгоритмом $\bar{E} = 13,07$. Таким чином, застосування алгоритму послідовної оптимізації СКД забезпечує найближення значення КФЕ до граничного (13,96).

ПЕРСПЕКТИВИ РОЗШИРЕННЯ ДОСЛІДЖЕННЯ

Подальший розвиток запропонованого в рамках ІЕІТ методу навчання СК з метою побудови безпомилкового за навчальною матрицею класифікатора образів високого порядку доцільно здійснювати шляхом оптимізації інших просторово-часових параметрів функціонування СК, наприклад, таких, як:

- рівні селекції координат двійкових еталонних векторів-реалізацій образу, що дозволить збільшити середню міжцентрну кодову відстань для заданого алфавіту класів;
- параметри словника, що впливають на інформативність ознак розпізнавання;
- параметри впливу на керований процес зовнішнього середовища та інші.

Перспективною сферою впровадження одержаних результатів є керовані слабо формалізовані процеси в різних галузях соціально-економічної сфери суспільства: нафто-хімічна та металургійна промисловість, мікро- та нано-технології, медичне діагностування та інше.

ВИСНОВКИ

1 Запропонований алгоритм паралельно-послідовної оптимізації контрольних допусків на ознаки розпізнавання дозволяє побудувати вирішальні правила, достовірність яких наближається до асимптотичної (граничної) достовірності).

2 Реалізація алгоритму паралельної оптимізації контрольних допусків дозволяє вибрати стартову систему допусків, що забезпечує знаходження СК, що навчається, в робочій області визначення функції визначення інформаційного КФЕ навчання системи.

3 Поєднання паралельного і послідовного алгоритму в оптимізації дозволяє підвищити оперативність навчання та забезпечити наближену до асимптотичної достовірність прийняття рішень на етапі екзамену.

SUMMARY

Proposing informational-extremal intellectual technology's method synthesis learning system of control, which promote functional effectiveness of learning by way of using parallel-consecutive algorithm of the optimization control permits on the identification signs.

СПИСОК ЛІТЕРАТУРИ

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. Дида / 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. Гиренко А.В., Ляшенко В.В., Машталир В.П., Путятин Е.П. Методы корреляционного обнаружения объектов. – Харьков: АО “БизнесИнформ”, 1996. – 112 с.
5. Краснопоясовский А. С. Інформаційний синтез інтелектуальних систем керування: Підхід, що ґрунтуються на методі функціонально-статистичних випробувань. – Суми: Видавництво СумДУ, 2004. – 261 с.
6. Краснопоясовський А.С. Оптимізація контрольних допусків на ознаки розпізнавання за методом функціонально-статистичних випробувань // Штучний інтелект. – 2003. – №1. – С. 53 – 61.
7. Краснопоясовський А.С., Кий О.М., Волков В.М., Козинець М.В., Шелехов І.В. Класифікаційне управління технологічним процесом виробництва складних мінеральних добив // Східно-Європейський журнал передових технологій.–2003.–№ 6.–С.12–17.

A.C. Довбшиш, д-р техн. наук, доцент
Сумський державний університет

M.B. Козинець, асистент
Сумський державний університет

C.M. Котенко, студент
Сумський державний університет

Надійшла до редакції 20 березня 2007 р.