

УДК 681.518:004.93.1'



В.В. Москаленко

Сумський державний університет, м. Суми, Україна

ПРОГНОЗУВАННЯ МОМЕНТУ ПЕРЕНАВЧАННЯ ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНОГО УНІМОДАЛЬНОГО КЛАСИФІКАТОРА

Пропонується в рамках інформаційно-екстремальної інтелектуальної технології метод синтезу здатної навчатися прогностичної системи підтримки прийняття рішень (СППР), побудованої на базі унімодального класифікатора. Як прогностична функція розглядається одновимірна інваріантна до широкого сімейства законів розподілу ймовірностей порядкова статистика з розподілом χ^2 . Розроблено категорійні моделі та алгоритми навчання і екзамену прогностичної СППР. Як приклад розглянуто реалізацію прогностичної унімодальної СППР для керування технологічним процесом вирощування сцинтиляційних монокристалів.

УНІМОДАЛЬНИЙ КЛАСИФІКАТОР, СИСТЕМА ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ, РОЗПІЗНАВАННЯ, ПОРЯДКОВА СТАТИСТИКА, ПРОГНОЗУВАННЯ, СЦИНТИЛЯЦІЙНИЙ МОНОКРИСТАЛ

Вступ

У процесі експлуатації здатної навчатися системи підтримки прийняття рішень (СППР) відбувається дрейф векторів-реалізацій класів розпізнавання як у часі, так і у просторі. Це призводить до зменшення функціональної ефективності системи, оскільки побудовані на етапі навчання вирішальні правила залишаються незмінними. Таким чином, особливої актуальності в задачах прогностичної класифікації набуває вирішення двох проблем: визначення керуючого сигналу на горизонті прогнозування та визначення моменту часу перенавчання системи. Відомі прогностичні алгоритми, що базуються на ідеях і методах статистичної екстраполяції, характеризуються значною помилкою прогнозування, оскільки вони не враховують довільні початкові умови процесів, що прогножуються [1-3].

Одним із перспективних методів синтезу прогностичної СППР, що навчається, є інформаційно-екстремальна інтелектуальна технологія (ІЕІ-технологія), яка у порівнянні з відомими методами, враховує перетин гіперсферичних контейнерів класів розпізнавання та дозволяє побудувати безпомилкові за багатовимірною навчальною матрицею вирішальні правила [4,5]. У працях [6,7] розглядалися питання прогнозування функціональної ефективності здатної навчатися СППР для мультимодального класифікатора. Але у багатьох специфічних випадках перевагу слід віддавати унімодальним класифікаторам, що дозволяють будувати вирішальні правила для впорядкованих (структурованих) алфавітів класів розпізнавання [8,9].

У статті на прикладі автоматизації процесу вирощування сцинтиляційних монокристалів розглядається інформаційно-екстремальний метод прогностичного навчання інтелектуальної СППР, побудованої на базі унімодального класифікатора, що характеризується впорядкованим алфавітом класів з єдиним центром розсіювання векторів-реалізацій образу.

1. Постановка задачі

Ідея прогнозування моменту перенавчання унімодальної СППР в рамках ІЕІ-технології полягає у спостереженні за зменшенням ймовірності знаходження поточних значень ознак розпізнавання у своїх контрольних допусках. Дрейф статистичних властивостей реалізацій образу знижує достовірність розпізнавання функціональних станів АСК унаслідок утримування константними в пам'яті СППР геометричних параметрів контейнерів класів розпізнавання, які сформовано на попередньому етапі навчання. Для прогнозування зміни інформаційної спроможності СППР доцільно використати екстремальні порядкові статистики (ЕПС), що є чутливими до виходу значень ознак розпізнавання за межі своїх контрольних допусків та інваріантними до широкого сімейства законів розподілу ймовірностей [4]. При цьому для визначення моменту часу перенавчання СППР достатньо оцінити належність значення поточної порядкової статистики до варіаційного блоку відповідної ЕПС.

Нехай дано $\{X_m^o | m = \overline{1, M}\}$ – впорядкований алфавіт M класів розпізнавання, що характеризують відповідні функціональні стани АСК, і відповідну навчальну багатовимірну (векторну) матрицю типу «об'єкт-властивість» $\|y_{m,i}^j, | i = \overline{1, N}, j = \overline{1, n}\|$, де N, n – кількість ознак розпізнавання і векторів-реалізацій образу відповідно.

Відомий структурований вектор параметрів функціонування СППР $g = \langle d_m, \delta \rangle$, де d_m – радіус контейнера класу X_m^o , що відновлюється в радіальному базисі дискретного простору ознак розпізнавання з центром розсіювання, який визначається вершиною еталонного вектора x_m ; δ – параметр поля системи контрольних допусків (СКД) на ознаки розпізнавання. При цьому задано такі обмеження: вершина вектора x_m , що визначає геометричний центр розсіювання векторів-реалізацій всіх класів в бінарному просторі ознак розпізна-

вання Ω_B , має одиничні координати; $d_m > d_{m-1}$, при цьому радіус класу X_M^o дорівнює $d_M = N$ і $\delta \in [0; \delta_H / 2]$, де δ_H – нормоване поле допусків, що визначає область значень параметра δ .

Необхідно в процесі навчання СППР визначити оптимальні значення координат вектора g та побудувати варіаційний ряд ЕПС. При цьому оптимальні значення параметрів функціонування повинні забезпечувати максимум усередненого за алфавітом інформаційного критерію функціональної ефективності (КФЕ) навчання СППР:

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

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

У режимі прогностичного екзамону визначити поточний функціональний стан АСК, обчислити його порядкову статистику і зіставит її із сформованими на етапі навчання ЕПС з метою прийняття рішення про необхідність перенавчання СППР.

2. Математична модель інформаційно-екстремального унімодального прогностичного класифікатора

Розглянемо особливості математичних моделей прогностичної автоматичної класифікації для унімодальної СППР в рамках ІЕІ-технології. У цьому випадку обов'язковим етапом процесу навчання є відображення вибіркової множини X на множину вільних статистик S , яка обчислюється, на кожному кроці навчання:

$$\mu: X \rightarrow S.$$

Вільна статистика $S \in S$ повинна бути однаковою статистичною характеристикою вибіркової множини, інваріантною до широкого сімейства ймовірнісних мір і чутливою до зміни функціонального стану АСК. Такою статистикою є нормована статистика числа успіхів за n випробувань:

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

де $k_{m,j}$ – число успіхів при j -му випробуванні; $\bar{k}_{m,n}$ – вибіркоче середнє числа успіхів після n випробувань; $S_{m,n}^2$ – вибіркоче незміщена дисперсія за n випробувань.

Відомо, що статистика (2) має розподіл χ^2 із степенем свободи $k = n-1$ і не залежить ні від математичного сподівання, ні від дисперсії, а залежить тільки від обсягу випробувань n [4]. Вільна статистика $S_{m,n}$ є членом варіаційного ряду – порядковою статистикою, ранг якої визначається номером випробування.

На етапі прогностичного навчання здійснюється визначення як оптимальних параметрів навчання,

так і значень ЕПС з подальшим формуванням збільшенням їх варіаційного ряду $\langle \{S_{m,n}^*\} \rangle$.

Статистика $S_{m,n}^*$ є випадковою величиною і блоки варіаційного ряду розділяються довірчим коридором. При цьому квантілі функції розподілу χ^2 визначають відповідно нижню та верхню граничні межі варіаційного блоку статистики $S_{m,n}$, що покривають значення статистик $\{S_{m,n}^*\}$ з довірчою ймовірністю $1-Q$:

$$P\{K_{Q/2}^{(m)}(n-1) < S_{m,n}^* < K_{1-Q/2}^{(m)}(n-1)\} = 1-Q, \quad (3)$$

де $K_{Q/2}^{(m)}(n-1)$, $K_{1-Q/2}^{(m)}(n-1)$, – квантілі функції розподілу χ^2 з $n-1$ степенями свободи [4]; Q – рівень значущості (звичайно вибирають одне із значень 0,05; 0,01; 0,005; 0,001).

Нижня SN_m та верхня SV_m довірчі межі m -го блоку варіаційного ряду можна розрахувати, наприклад, поділивши варіаційні блоки на рівні частини:

$$SN_m = \frac{S_{m,n}^* + S_{m-1,n}^*}{2}; \quad SV_m = \frac{S_{m+1,n}^* + S_{m,n}^*}{2}. \quad (4)$$

Діаграма процесу прогностичного навчання унімодальної СППР в рамках ІЕІ-технології показана на рис. 1.




Рис. 1. Категорійна модель прогностичного навчання унімодальної СППР

Категорійна модель (рис. 1) містить оператор формування вхідного математичного опису (багатовимірної навчальної матриці типу «об'єкт-властивість»):

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

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 ознак розпізнавання; Y – вибіркоче множина значень рецепторів (вхідна навчальна матриця). Оператор $\theta_1: Y \rightarrow X$ формує вибіркоче бінарну множину X – вхідну у загальному випадку дійсну бінарну навчальну матрицю $\|x_{m,i}^{(j)}\|$ типу “процес-властивість”.

Оператор $\theta_2: X \rightarrow \tilde{R}^{|M|}$ відновлює в процесі навчання СППР оптимальне розбиття простору ознак на класи еквівалентності (M класів розпізнавання).

Оператор ν_1 відображає розбиття $\tilde{R}^{|M|}$ на впорядковану множину вирішальних правил V . Оператор d корегує геометричні параметри розбиття $\tilde{R}^{|M|}$, змінюючи радіус контейнера для кожного

класу відносно центру розсіювання x_m . Оператор v_2 забезпечує перехід до наступного вирішального правила після оптимізації радіуса контейнера попереднього класу розпізнавання.

Оператор класифікації $\Psi: \mathfrak{R}^{|M|} \rightarrow I^{|I|}$, де $I^{|I|}$ – множина I статистичних гіпотез, розглядається як композиція операторів $\Psi = v_1 \circ \Psi_H$, де Ψ_H перевіряє основну статистичну гіпотезу за відповідним вирішальним правилом. Оператор $\gamma: I^{|I|} \rightarrow \mathfrak{S}^{|q|}$ формує за результатами перевірки основної статистичної гіпотези множину точнісних характеристик $\mathfrak{S}^{|q|}$, де $q = l^2$. Оператор ϕ обчислює терм-множину E значень інформаційного КФЕ, який є функціоналом точнісних характеристик.

Оператори δ_1 і δ_2 змінюють систему контрольних допусків (СКД) D на ознаки розпізнавання. Ці оператори оцінюють вплив параметра СКД на КФЕ СППР і регламентують ітераційний процес оптимізації. Оператор μ обчислює множину ЕПС S^* . Оператор s впорядковує за збільшенням ЕПС, розраховані при максимальному усередненому КФЕ, та ставить у відповідність довірчі коридори для кожного класу розпізнавання. Оператор $U_H: E \rightarrow G \times T \times \Omega \times Z$ регламентує процес навчання СППР.

Діаграму процесу прогностичного екзамену в рамках ІЕІ-технології показано на рис. 2.




Рис. 2. Категорійна модель прогностичного екзамену унімодальної СППР

У діаграмі (рис. 2) оператор Φ_1 відображає універсум випробувань на вибіркочну множину X , яка утворює екзаменаційну матрицю $\|x_i^{(j)} \mid i = 1, N; j = 1, n\|$, аналогічну навчальній матриці за структурою, параметрами та процедурою формування.

Оператор P відображає бінарну вибіркочну множину X , що розпізнається, на побудоване на етапі навчання чітке розбиття $\mathfrak{R}^{|M|}$. Оператор класифікації Ψ утворює композицію двох операторів: оператор обчислення функції належності $\Psi_1: \mathfrak{R}^{|M|} \rightarrow F$, де F – множина функцій належності, і оператор дефазифікації $\Psi_2: F \rightarrow I^{|M+1|}$, який вибирає відповідну гіпотезу за максимальним значенням функції належності.

Оператор μ обчислює поточну порядкову статистику $S_n \in S$. Оператор співставлення $c: S \rightarrow S^*$, де S^* – множина впорядкованих за збільшенням ЕПС, визначає належність поточної ЕПС $S_n \in S$ одному із блоків варіаційного ряду екстремальних статистик $\langle \{S_m^*\} \rangle \in S^*$, отриманих у процесі прогностичного навчання.

Оператор ω перевіряє відповідність поточного класу, визначеного за максимумом усередне-

ної функції належності, блоку варіаційного ряду ЕПС, в якому знаходиться поточна статистика. У випадку невідповідності приймається рішення про перенавчання системи.

Оператора U_E утворює зворотний зв'язок у діаграмі і призначений для регламентації процесу екзамену.

3. Алгоритм інформаційно-екстремального унімодального прогностичного класифікатора

Алгоритм навчання унімодальної прогностичної СППР з оптимізацією СКД на ознаки розпізнавання, полягає у реалізації структурованої двоцикличованої ітераційної процедури пошуку глобального максимуму інформаційного КФЕ (1) в робочій області визначення його функції. Для інформаційно-екстремального алгоритму паралельної оптимізації СКД, при якому параметр поля контрольних допусків δ_K змінюється одночасно для всіх ознак розпізнавання, така процедура має вигляд:

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

де G_δ – область допустимих значень відповідних контрольних допусків на ознаки розпізнавання; G_E – область допустимих значень інформаційного КФЕ (1) навчання СППР.

У процедурі (5) внутрішній цикл реалізує базовий алгоритм навчання, основними задачами якого є обчислення інформаційного КФЕ навчання СППР; пошук глобального максимуму КФЕ в робочій (допустимій) області визначення його функції; оптимізація геометричних параметрів контейнерів класів розпізнавання [3, 5].

При цьому специфіка базового алгоритму навчання унімодальної СППР полягає у відсутності процедури визначення для кожного класу найближчого сусіда, оскільки класи розпізнавання апріорно є впорядкованими, що суттєво підвищує оперативність навчання.

Оптимізацію контрольних допусків на ознаки 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 у рамках ІЕІ-технології алгоритм навчання унімодальної СППР на етапі паралельної оптимізації контрольних допусків на ознаки розпізнавання (5). Вхідні дані: масив реалізацій класів розпізнавання $\{y_{m,i}^{(j)} \mid m = \overline{1, M}; i = \overline{1, N}; j = \overline{1, n}\}$; система нормованих допусків $\{\delta_{H,i} \mid i = \overline{1, N}\}$, що визначає область значень відповідних контрольних допусків. Попередньо для кожної ознаки визначається ціна градації її шкали виміру, що дозволяє обчислювати на кожному кроці навчання нижній і верхній контрольні допуски відповідно:

$$A_{KH,i} = y_{1,i} - \delta; A_{KB,i} = y_{1,i} + \delta, \quad (6)$$

де $y_{1,i}$ – вибіркове середнє значення i -ї ознаки розпізнавання у векторах-реалізаціях базового класу X_1^o .

Реалізація алгоритму навчання унімодальної СППР з паралельною оптимізацією контрольних допусків на ознаки розпізнавання здійснюється за такою схемою:

1) обнулюється лічильник кроків зміни параметра δ поля контрольних допусків на ознаки розпізнавання, який одночасно визначає і кількість кроків навчання: $l:=0$;

2) інкремент лічильник кроків зміни параметра δ : $l:=l+1$;

3) на кожному кроці навчання за формулами (6) обчислюються нижній $A_{HK,i}[l]$ і верхній $A_{BK,i}[l]$ контрольні допуски для всіх ознак розпізнавання;

4) реалізується базовий алгоритм навчання і визначається поточний глобальний максимум усередненого за алфавітом класів розпізнавання інформаційного критерію $\bar{E}[l]$ в робочій області визначення його функції;

5) якщо в робочій області визначення функції інформаційного критерію має місце $\bar{E}[l] \leq \text{extr max } \bar{E}$, де $\text{extr max } \bar{E}$ – граничний максимум усередненого за алфавітом класів розпізнавання інформаційного критерію (1), то виконується пункт 6, інакше – пункт 7 ($\bar{E}[0]=0$);

6) якщо $\delta \leq \delta_H / 2$, то виконується пункт 2, інакше – пункт 7;

7) $\text{extr max } \bar{E} := \max_{\{l\}} \bar{E}^*[l]$; $\delta^* := \arg \text{extr max } \bar{E}$;

8) для визначеного оптимального параметра δ^* поля контрольних допусків обчислюються за формулою (6) оптимальні нижні $\{A_{HK,i}^*\}$ і верхні $\{A_{BK,i}^*\}$ контрольні допуски на ознаки розпізнавання;

9) ЗУПИН.

Одержана в процесі паралельної оптимізації квазіоптимальна система контрольних допусків використовувалася як стартова для алгоритму послідовної оптимізації контрольних допусків на ознаки розпізнавання. Це дозволяє суттєво підвищити оперативність алгоритму навчання, оскільки обчислення в процесі навчання КФЕ здійснювалося тільки в робочій (допустимій) області визначення його функції.

Алгоритм послідовної оптимізації поля контрольних допусків на ознаки розпізнавання здійснювався за такою ітераційною процедурою:

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

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 повторення.

При оптимальних параметрах навчання розраховується варіаційний ряд порядкових статистик $\langle \{S_{m,n}^*\} \rangle$. за формулою (2) та розраховуються відповідні довірчі межі за формулами (3) та (4).

Як КФЕ навчання використано модифіковану інформаційну міру Кульбака, в якій розглядається відношення правдоподібності у вигляді відношення повної ймовірності правильного прийняття рішень P_i до повної ймовірності помилкового прийняття рішень P_f [3, 6]. Для рівноймовірних двоальтернативних гіпотез, що характеризує найбільш складний у статистичному розумінні випадок прийняття рішень, міру Кульбака подамо у вигляді:

$$\begin{aligned} E_m^{(k)} &= \left[P_{t,m}^{(k)} - P_{f,m}^{(k)} \right] \cdot \log_2 \frac{P_{t,m}^{(k)}}{P_{f,m}^{(k)}} = \\ &= \left[\begin{array}{l} P_{t,m}^{(k)} = 0,5 \cdot D_{1,m} + 0,5 \cdot D_{2,m} \\ P_{f,m}^{(k)} = 0,5 \cdot \alpha_m + 0,5 \cdot \beta_m \end{array} \right] = \quad (7) \\ &= 0,5 \cdot \left[(D_{1,m}^{(k)} + D_{2,m}^{(k)}) - (\alpha_m^{(k)} + \beta_m^{(k)}) \right] \cdot \log_2 \left(\frac{D_{1,m}^{(k)} + D_{2,m}^{(k)}}{\alpha_m^{(k)} + \beta_m^{(k)}} \right), \end{aligned}$$

де $D_{1,m}^{(k)}$ – перша достовірність, обчислена на k -му кроці навчання розпізнавати реалізації класу X_m^o ; $D_{2,m}^{(k)}$ – друга достовірність; $\alpha_m^{(k)}$ – помилка першого роду; $\beta_m^{(k)}$ – помилка другого роду.

Оцінками точнісних характеристик при прийнятті рішень в процесі навчання є емпіричні частоти:

$$D_{1,m}^{(k)} = \frac{K_{1,m}^{(k)}}{n_{\min}}; \alpha_m^{(k)} = \frac{K_{2,m}^{(k)}}{n_{\min}}; \beta_m^{(k)} = \frac{K_{3,m}^{(k)}}{n_{\min}}; D_{2,m}^{(k)} = \frac{K_{4,m}^{(k)}}{n_{\min}}, \quad (8)$$

де $K_{1,m}^{(k)}$, $K_{2,m}^{(k)}$ – кількість подій, які означають відповідно належність та неналежність реалізацій образу контейнеру класу X_m^o , якщо насправді вони є реалізаціями цього класу; $K_{3,m}^{(k)}$, $K_{4,m}^{(k)}$ – кількість подій, які означають відповідно належність і неналежність реалізацій контейнеру класу X_m^o , якщо насправді вони належать до сусіднього (зовнішнього); n_{\min} – мінімальний обсяг репрезентативної навчальної вибірки [3].

Суми $K_{1,m}^{(k)}$, $K_{2,m}^{(k)}$, $K_{3,m}^{(k)}$, $K_{4,m}^{(k)}$ обчислюються на k -му кроці навчання СППР за алгоритмом:

$$K_{1,m}^{(k)}[0] = 0; K_{2,m}^{(k)}[0] = 0; K_{3,m}^{(k)}[0] = 0; K_{4,m}^{(k)}[0] = 0;$$

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

$$\text{else } K_{2,m}^{(k)}[j] := K_{2,m}^{(k)}[j-1] + 1;$$

$$\text{if } x_c^{(j)} \in X_m^o \text{ then } K_{3,m}^{(k)}[j] := K_{3,m}^{(k)}[j-1] + 1$$

$$\text{else } K_{4,m}^{(k)}[j] := K_{4,m}^{(k)}[j-1] + 1,$$

де $x_c^{(j)}$ – j -та реалізація сусіднього (зовнішнього) класу X_c^o .

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

if $d_{m-1} < d[x_m \oplus x^{(j)}] < d_m$ then $x^{(j)} \in X_m^o$ else $x^{(j)} \notin X_m^o$,

де d_{m-1} – визначений в процесі навчання оптимальний радіус контейнера внутрішнього (вкладеного) класу, для першого(базового) класу $d_{m-1} = 0$; $d[x_m \oplus x^{(j)}]$ – кодова відстань вектора $x^{(j)}$ до центра розсіювання реалізацій x_m ; \oplus – символ операції складання за модулем два; d_m – поточний радіус контейнера класу X_m^o , що відновлюється в бінарному просторі ознак розпізнавання.

Робоча модифікація критерію Кульбака після відповідної підстановки оцінок (8) у вираз (7) набуває вигляду:

$$E_m^{(k)} = \frac{[K_1^{(k)} + K_4^{(k)} - K_2^{(k)} - K_3^{(k)}]}{2 \cdot n_{\min}} \cdot \log_2 \left(\frac{K_1^{(k)} + K_4^{(k)} + 10^{-r}}{K_2^{(k)} + K_3^{(k)} + 10^{-r}} \right), \quad (9)$$

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

Нормовану модифікацію критерію (9) можна подати у вигляді:

$$E_m^{*(k)} = \frac{E_m^{(k)}}{E_{\max}^{(k)}}, \quad (10)$$

де $E_{\max}^{(k)}$ – значення критерію при $D_{1,m}^{(k)} = 1$ і $\beta_m^{(k)} = 0$ ($K_1^{(k)} = n_{\min}$ і $K_2^{(k)} = 0$).

Алгоритм екзамену за ІЕІ-технологією базується на аналізі значень функції належності, яка обчислюється для кожної реалізації, що розпізнається, визначаючи належність до контейнеру класу X_m^o , і для унімодального класифікатора має такий простий вигляд:

$$\mu_{m,j} = \begin{cases} 1, & \text{if } d_{m-1}^* < d[x_m \oplus x^{(j)}] < d_m^*; \\ 0, & \text{if } \text{else.} \end{cases} \quad (11)$$

де $d(x_m \oplus x^{(j)})$ – кодова відстань між еталонним вектором x_m і реалізацією класу, що розпізнається; d_{m-1}^* , d_m^* – оптимальні радіуси контейнерів класів X_{m-1}^o і X_m^o відповідно.

Алгоритм екзамену має такі вхідні дані: M – кількість класів, які СППР навчена розпізнавати; $\{d_m^*\}$ – масиви оптимальних радіусів контейнерів, та $\{\delta_{k,i}^* | i = \overline{1, N}\}$ – масив контрольних допусків на ознаки розпізнавання, визначенні на етапі навчання; $\{x^{(j)}\}$ – масив двійкових векторів-реалізацій образу, що розпізнається.

Розглянемо основні етапи реалізації алгоритму екзамену:

- 1) обнуління лічильника класів розпізнавання: $m := 0$;
- 2) інкремент лічильника класів розпізнавання: $m := m + 1$;
- 3) обнуління лічильника числа реалізацій, що розпізнаються: $j := 0$;
- 4) інкремент лічильника числа реалізацій, що розпізнаються: $j := j + 1$;

5) обчислення кодової відстані $d(x_1 \oplus x^{(j)})$;

6) обчислення функції належності (11);

7) порівняння: якщо $j \leq n$, то виконується крок 4, інакше – крок 8;

8) порівняння: якщо $m \leq M$, то виконується крок 2, інакше – крок 9;

9) визначення класу X_m^o , до якого належить реалізація образу, наприклад, за умови

$$\bar{\mu}_m^* = \max_{\{m\}} \bar{\mu}_m,$$

де $\bar{\mu}_m = \frac{1}{n} \sum_{j=1}^n \mu_{m,j}$ – усереднене значення функцій

належності для реалізацій класу X_m^o , або видача повідомлення: «Клас не визначено», якщо $\bar{\mu}_m \leq c$. Тут c – порогове значення;

10) розраховується поточна порядкова статистика S_n за формулою (2) і перевіряється її належність блоку варіаційного ряду, що відповідає номеру класу, визначеному на кроці 7. У випадку невідповідності формується повідомлення про необхідність перенавчання СППР.

Таким чином, алгоритми екзамену у рамках ІЕІ-технології є детермінованим і відрізняються відносно малою обчислювальною трудомісткістю, що дозволяє реалізовувати його у реальному темпі часу.

4. Приклад реалізації інформаційно-екстремального унімодального прогностичного класифікатора

Розроблені алгоритми були застосовані для прогнозування зміни функціональної ефективності автоматизованої системи керування вирощування сцинтиляційних монокристалів на установці типу «РОСТ» [7,8] за методом Чохральського (НТК «Інститут монокристалів», м. Харків). Алфавіт класів характеризував функціональні стани АСК технологічним процесом вирощування великогабаритних монокристалів, визначені згідно з технологічним режимом за трьохальтернативною системою оцінок: клас X_1^o – «Норма», клас X_2^o – «Менше норми» і клас X_3^o – «Більше норми».

На рис. 3 показано одержані на етапі навчання унімодальної СППР порядкові статистики (2) для упорядкованого алфавіту з трьох класів і словника із 35 ознак розпізнавання, які характеризували як технологічні параметри процесу вирощування монокристалу, так і їх різниці першого та другого порядку. При цьому обсяг навчальної вибірки дорівнював $n = 40$.

Аналіз рис. 3 показує що клас X_1^o із найбільшою ймовірністю «успіхів» має найменше значення ЕПС $S_1^* = 30$, для інших класів кінцеві значення варіаційних рядів зростають обернено пропорційно ймовірності „успіху” і відповідно порядку вкладеності контейнерів, $S_2^* = 47$; $S_3^* = 60$. Таким чином, ЕПС утворюють варіаційний ряд за збільшенням їх значень.

У режимі прогностичного екзамену за максимальним значенням функції належності (11) визначався клас поточного функціонального стану технологічного процесу, а для визначення моменту

часу перенавчання СППР оцінювалась належність поточної екзаменаційної порядкової статистики, обчисленої за формулою (2), до відповідного блоку варіаційного ряду.




Рис. 3. Графік залежності ЕПС від кількості випробувань при оптимальних параметрах навчання СППР

На рис.4 показано зміну в часі екзаменаційних порядкових статистик у своїх варіаційних блоках на часовому інтервалі t , який дорівнює кількості періодів аналізу (екзамену) інформації в робочому режимі СППР.




Рис. 4. Тренди екзаменаційних порядкових статистик

Аналіз рис. 4 показує, що після 80 реалізацій екзамену поточна порядкова статистика $S_2(t)$, яка є одновимірною статистичною характеристикою реалізацій класу X_2^o , переходить у варіаційний блок іншого класу, що створює статистичну невизначеність і тому потребує перенавчання СППР.

Таким чином, аналіз графіків ЕПС, сформованих на етапі навчання, показує чітку залежність між висотою тренду ЕПС та порядком вкладеності контейнерів класів розпізнавання при побудові унімодального класифікатора.

Висновки

1. У рамках ІЕІ-технології розроблено інформаційне, алгоритмічне та програмне забезпечення унімодального прогностичного класифікатора для прогнозування зміни функціональної ефективності АСК в процесі вирощування скінтіляційних монокристалів. Це дозволяє запобігти зниженню функціональної ефективності АСК шляхом вчасного

проведення профілактичних робіт та перенавчання СППР, яка є інтелектуальною складовою АСК.

2. Фізичне моделювання за даними архівної історії вирощування скінтіляційних монокристалів показало, що ЕПС для унімодального класифікатора можуть розглядатися як прогностичні функції.

Список літератури: 1. Силин, В.Б. Автоматическое прогнозирование состояния аппаратуры управления и наблюдения [Текст] / В.Б. Силин, А.И. Заковряшин. – М., «Энергия». – 1973. – 336 с. 2. Абрамов, О.В. Прогнозирование состояния технических систем [Текст] / О.В. Абрамов, А.Н. Розенбаум. – М.: Наука. – 1990. – 126 с. 3. Довбиш, А.С. Основы проектирования интеллектуальных систем: Навчальний посібник [Текст] / А.С. Довбиш. – Суми: Видавництво Сум ДУ. – 2009. – 171 с. 4. Соле, Ж. Л. Основные структуры математической статистики [Текст] / Ж. Л. Соле. – М.: Мир. – 1972. – 127 с. 5. Довбиш, А.С. Интеллектуальная система поддержки принятия решений для керування вирощування монокристалів [Текст] / А.С. Довбиш, В.С. Суздаль, В.В. Москаленко // Вісник СумДУ. Серія технічні науки. – 2011. – №2. – С. 39-47. 6. Кульбак, С. Теория информации и статистика [Текст]: Пер. с англ./ С. Кульбак. – М.: Наука. – 1967. – 408 с. 7. Горилецкий, В.И. Рост кристаллов [Текст] / В.И. Горилецкий, Б.В. Гринёв, Б.Г. Заславский, Н.Н. Смирнов, В.С. Суздаль. –Харків: Акта. – 2002. – 536 с. 8. Суздаль, В.С. Скінтіляційні монокристалли: автоматизированное выращивание [Текст] / В.С. Суздаль, П.Е. Стадник, Л.И. Герасимчук, Ю.М. Епифанов. – Харьков «ИСМА», 2009. – 260 с. 9. Довбиш, А.С. Класифікаційне прогностичне керування вирощуванням скінтіляційних монокристалів [Текст] / А.С. Довбиш, В.В. Москаленко // Современные направления теоретических и прикладных исследований '2011: междунар. науч.-практ. конф., 15-28 марта 2011 г.: тез. докл. – Одесса: Чорноморье. – 2011. – Т.3. – С. 12-14.

Надійшла до редколегії 29.06.2012

УДК 681.518:004.93.1'

Прогнозирование момента переобучения информационно-экстремального унимодального классификатора / В.В. Москаленко // Бионика интеллекта: науч.-техн. журнал. – 2012. – № 2 (79). – С. 47–52.

Предлагается информационно-экстремальный метод анализа и синтеза прогностической системы поддержки принятия решений (СППР), функционирующей в режимах обучения и экзамена. При этом СППР построено на базе унимодального классификатора, характеризующегося структурированным алфавитом классов распознавания и общим центром рассеивания векторов-реализаций классов распознавания. В качестве примера реализации такой СППР рассмотрена интеллектуальная система управления технологическим процессом выращивания скінтіляційних монокристаллов.

Ил. 4. Библиогр.: 9 назв.

UDC 681.518:004.93.1'

Forecasting of time moment of re-learning for information-extreme unimodal classifier / V.V. Moskalenko // Bionics of Intelligense: Sci. Mag. – 2012. – № 2 (79). – P. 47–52.

This paper propose information-extreme method of analysis and synthesis of forecasting decision support system (DSS) with learning and exam mode. The DSS based on unimodal classifier characterized by structured alphabet of recognition classes and single center of pattern vector-realizations distribution. On the example of implementation of such DSS the article considers intelligent control of growing scintillate single crystals.

Fig.: 4. Ref.: 9 items.