

ПРОГНОСТИЧНЕ НАВЧАННЯ АВТОМАТИЗОВАНОЇ СИСТЕМИ КЕРУВАННЯ ВИРОБНИЦТВОМ ФОСФОРНОЇ КИСЛОТИ

А.С. Довбиш, д-р техн. наук;

В.А. Тронь, аспірант

Сумський державний університет, м. Суми

Предлагается в рамках информационно-экстремальной интеллектуальной технологии метод синтеза способной обучаться прогностической системы, который позволяет повысить её функциональную эффективность прогностического обучения и определения момента переобучения на этапе экзамена путём применения порядковых статистик.

Пропонується в рамках інформаційно-екстремальної інтелектуальної технології метод синтезу здатної навчатися прогностичної системи керування, який дозволяє підвищити її функціональну ефективність прогностичного навчання та визначення моменту перенавчання на етапі екзамену шляхом застосування порядкових статистик.

ВСТУП

Створення детерміновано-статистичних методів класифікаційного прогнозування на основі самонавчання та розпізнавання образів є одним із перспективних підходів до збільшення функціональної ефективності адаптивних автоматизованих систем керування (АСК), що навчаються [1-3]. Основними причинами відсутності широкого застосування класифікаційного прогнозування на практиці є такі:

- відомі методи [4-9] мають модельний характер, спричинений нехтуванням перетину гіперсферичних контейнерів, що є у практичних задачах контролю;
- відсутність алгоритмів побудови безпомилкових за багатовимірною навчальною матрицею вирішальних правил, що зумовлено методологічними причинами.

На усунення цих недоліків спрямовані методи класифікаційного прогнозування, розроблені у рамках інформаційно-екстремальної інтелектуальної технології (ІЕІТ), в основу якої покладено максимізацію кількості інформації шляхом введення додаткових інформаційних обмежень в процесі навчання АСК [12].

Концепція класифікаційного прогнозування функціонального стану АСК, що навчається, в рамках ІЕІТ така. У процесі зміни функціонального стану системи відбувається дрейф вершин еталонних векторів-реалізацій образу в просторі ознак розпізнавання, що призводить до зниження достовірності розпізнавання функціональних станів унаслідок утримування константними в пам'яті АСК геометричних параметрів контейнерів класів розпізнавання, які сформовано на попередньому етапі навчання. Крім того, внаслідок переміщення в часі вершин векторів-реалізацій зменшується ймовірність знаходження поточних значень ознак розпізнавання у своїх контрольних допусках. При цьому також змінюються статистичні властивості реалізацій образу, що впливають на значення екстремальних порядкових статистик (ЕПС), інваріантних до широкого сімейства законів розподілу ймовірностей [11]. Таким чином, у процесі прогнозування система повинна стежити за зміною як детермінованої складової переміщення вершин еталонних векторів-реалізацій образу, так і статистичної складової, що спричиняє зміну значень ЕПС. Для підтримки належної ефективності функціонування АСК здійснюється її перенавчання. Таким чином,

достатньо оцінити ступінь наближення значення поточної ЕПС до межі відповідного довірчого коридора для визначення моменту перенавчання АСК. Коли будь-яка статистика виходить за межі свого коридора, то це призводить до статистичної однаковості вибірових послідовностей, що робить необхідним перенавчання АСК. У статті розглядається інформаційно-екстремальний метод прогностичного навчання на прикладі АСК виробництвом фосфорної кислоти.

ПОСТАНОВКА ЗАДАЧІ

Розглянемо таку постановку задачі оптимізації параметрів плану навчання у рамках ІЕІТ. Нехай дано $\{X_m^o \mid m = \overline{1, M}\}$ – алфавіт M класів розпізнавання, які у загальному випадку можуть перетинатися, і матрицю даних технологічного процесу $\|y_{m,i}^{(j)}\|$, $i = \overline{1, N}$, $j = \overline{1, n}$, де N , n – кількість ознак розпізнавання і моментів зчитування інформації відповідно. Відомо вектор-кортеж просторово-часових параметрів функціонування АСК, що навчається, $g_m = \langle g_{m,1}, \dots, g_{m,\xi}, \dots, g_{m,\Xi} \rangle$ з відповідними обмеженнями $R_\xi(g_1, \dots, g_\Xi) \leq 0$. Слід у процесі навчання АСК оптимізувати такий параметр плану навчання, як система контрольних допусків D , та побудувати варіаційний ряд ЕПС шляхом цілеспрямованої трансформації нечіткого розбиття $\tilde{\mathfrak{R}}^{|M|}$ в чітке розбиття еквівалентності за умов:

- 1) $(\forall X_m^o \in \tilde{\mathfrak{R}}^{|M|}) [X_m^o \neq \emptyset]$;
- 2) $(\exists X_k^o \in \tilde{\mathfrak{R}}^{|M|}) (\exists X_l^o \in \tilde{\mathfrak{R}}^{|M|}) [X_k^o \neq X_l^o \rightarrow X_k^o \cap X_l^o \neq \emptyset]$;
- 3) $(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|}) (\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}) [X_k^o \neq X_l^o \rightarrow \text{Ker} X_k^o \cap \text{Ker} X_l^o = \emptyset]$;
- 4) $(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|}) (\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}) [X_k^o \neq X_l^o \rightarrow (x_k \oplus x_l) \& (d_l^* < d(x_k \oplus x_l))]$;
- 5) $\bigcup_{X_m^o \in \tilde{\mathfrak{R}}^{|M|}} X_m^o \subseteq \Omega_B$, $k \neq l$, $k, l, m = \overline{1, M}$,

де $\text{Ker} X_k^o$, $\text{Ker} X_l^o$ – ядра класів X_k^o і X_l^o відповідно; d_k^* , d_l^* – оптимальні радіуси контейнерів $K_k^o \in X_k^o$ і $K_l^o \in X_l^o$ відповідно, що відновлюються в радіальному базисі простору ознак Ω_B ; x_k , x_l – еталонні двійкові вектори реалізації класів X_k^o і X_l^o відповідно. При цьому оптимальні значення параметрів плану навчання забезпечують максимум інформаційного критерію функціональної ефективності (КФЕ) навчання

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

де E_m^* – максимум КФЕ навчання розпізнавання реалізацій класу X_m^o ; $\{G_\xi\}$ – області допустимих значень параметрів навчання.

Таким чином, процес оптимізації параметрів функціонування АСК, що навчається, передбачає побудову ЕПС та оптимізацію системи контрольних допусків, що забезпечує виконання умови (1).

МАТЕМАТИЧНА МОДЕЛЬ ПРОГНОСТИЧНОГО НАВЧАННЯ

Математичні моделі прогностичної автоматичної класифікації в рамках ІЕІТ мають певні особливості. У цьому випадку обов'язковим етапом процесу навчання є відображення вибіркової множини X на множину вільних статистик S , яка обчислюється, на кожному кроці навчання:

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

Статистика $S \in S$ має задовольняти такі вимоги:

- бути одновимірною статистичною характеристикою вибіркової множини;

- бути інваріантною до широкого сімейства ймовірнісних мір;

- бути чутливою до зміни функціонального стану АСК, що навчається

Для такої статистики будемо вважати „успіхом” знаходження при випробуванні значення ознаки в своєму полі контрольних допусків. Нехай у процесі проведення випробувань виконується умова рівності ймовірностей знаходження N ознак у межах своїх контрольних допусків, тобто $p_1 = p_2 = \dots = p_N = p$. Тоді ймовірність одержання k успіхів – числа ознак, що містяться в допуску, визначається за біноміальним розподілом

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

де $q = 1 - p$ – ймовірність виходу значення ознаки за межі поля допусків;

$$C_N^k = \frac{N!}{k! (N-k)!} - \text{біноміальні коефіцієнти.}$$

Введемо вільну статистику, інваріантну щодо групи всіх $N!$ перестановок координат N -вимірного вектора-реалізації $x_m^{(j)} \subset X_m^o$, $j = 1, n$, яка залежить тільки від обсягу навчальної вибірки. У процесі реалізації багатоциклічного ітераційного алгоритму оптимізації параметрів навчання за ІЕІТ формується екстремальна порядкова статистика (ЕПС), яка може розглядатися як одновимірна статистична прогноуюча функція відповідного стану АСК:

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

де $k_{m,j}$ – число успіхів при j -му випробуванні; $\bar{k}_{m,n}$ – вибіркве середнє значення числа успіхів після n ипробувань; $s_{m,n}^2$ – вибіркве середнє квадратичне числа успіхів після n випробувань відповідно.


Відомо, що статистика (3) має розподіл χ^2 із ступенем свободи $k = n - 1$ і не залежить ні від математичного сподівання, ні від дисперсії, а залежить тільки від обсягу випробувань n . Як показує аналіз виразу (3), при збільшенні n вибіркво дисперсія збігається до нуля, а функція $S_{m,n}$, маючи тенденцію до збільшення, набуде якого завгодно великого значення. Таким чином, вільна статистика $S_{m,n}$ є членом варіаційного ряду – порядковою статистикою, ранг якої визначається номером випробування.

Позначимо через $\Pi(E_m) \subset E$ частково впорядковану підмножину значень КФЕ, обчислених у процесі навчання розпізнавання реалізацій

класу X_m^o . При цьому E_m^* – найбільший елемент підмножини $\Pi(E_m)$. Тоді множина E має впорядковану структуру $\mathbf{E} = \langle \{\Pi(E_m)\} \rangle$. Аналогічну структуру має і множина \mathbf{S} : $\mathbf{S} = \langle \{\Pi(S_m)\} \rangle$, де $\Pi(S_m)$ – підмножина статистик, обчислених при навчанні розпізнавання реалізації класу X_m^o , найбільшим елементом якої є екстремальна статистика S_m^* . Таким чином, елементи терм-множин \mathbf{E} і \mathbf{S} перебувають у взаємно-однозначній відповідності і визначення елементів підмножини $\Pi(S_m^*) \subset \mathbf{S}$ здійснюється в результаті бієктивного відображення

$$s : \mathbf{E} \mapsto \mathbf{S}. \quad (4)$$

Тоді діаграма процесу базового алгоритму прогностичного навчання в рамках ІЕІ-технології з урахуванням виразів (2) і (4) має вигляд:



Обчислення порядкових статистик $S_{m,n}$ для кожного класу здійснюється за формулою (3) на кожному кроці оптимізації параметрів навчання СК. Статистика $S_{m,n}$ набуде екстремального значення при випробуванні n^* , при якому КФЕ навчання системи розпізнавати реалізації класу X_m^o набуває максимального значення в робочій області визначення його функції. Після закінчення навчання СК формується варіаційний ряд ЕПС S_m^* за збільшенням з метою організації процедури їх зіставлення з поточною статистикою S_n , що обчислюється в режимі прогностичного екзамену.

КРИТЕРІЙ ФУНКЦІОНАЛЬНОЇ ЕФЕКТИВНОСТІ

У роботі [12] для двохальтернативної системи оцінок та рівноймовірних гіпотез одержано таку модифікацію інформаційної міри Кульбака:

$$E = 0,5 \log_2 \left(\frac{D_1 + D_2}{\alpha + \beta} \right) * [(D_1 + D_2) - (\alpha + \beta)] = \log_2 \left(\frac{2 - (\alpha + \beta)}{\alpha + \beta} \right) * [1 - (\alpha + \beta)], \quad (6)$$

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

Таким чином, функція критерію (6) є нелінійним функціоналом від точнісних характеристик процесу навчання. Крім того, його функція не є взаємодозначною, що потребує визначення в процесі навчання робочої області для його значень. Оскільки навчальна вибірка є обмеженою за

обсягом, то надалі замість точнісних характеристик будемо оперувати їх оцінками (емпіричними частотами):

$$D_1 = \frac{K_1}{n}; \alpha = \frac{K_2}{n}; \beta = \frac{K_3}{n}; D_2 = \frac{K_4}{n}, \quad (7)$$

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

Тоді робоча модифікація критерію Кульбака після відповідної підстановки оцінок (7) у вираз (6) набуває вигляду

$$E = \frac{1}{n} \log_2 \left\{ \frac{2n + 10^{-r} - [K_2^{(k)} + K_3^{(k)}]}{[K_2^{(k)} + K_3^{(k)}] + 10^{-r}} \right\} * [n - (K_2^{(k)} + K_3^{(k)})], \quad (8)$$

де $K_2^{(k)}$ – число реалізацій класу X_m^0 , які не знаходяться в k -й області цього класу.

Нормовану модифікацію критерію Кульбака можна подати у такому вигляді:

$$E_K = \frac{E}{E_{\max}},$$

де E_{\max} – максимальне значення критерію (6) при $D_1 = 1$ і $D_2 = 1$.

АЛГОРИТМ ПРОГНОСТИЧНОГО НАВЧАННЯ

Розглянемо базовий алгоритм прогностичного навчання системи керування. Алгоритм має такі вхідні дані: $\{Y[J,I,K]\}$ – масив навчальних вибірок, $J=1 \dots NM$ – змінна кількості випробувань, де NM – мінімальний обсяг репрезентативної навчальної вибірки, $I=1 \dots N$ – змінна кількості ознак розпізнавання, $K=1 \dots M$ – змінна кількості класів розпізнавання; $\{NDK[I]\}$, $\{VDK[I]\}$ – масиви нижніх і верхніх контрольних допусків на ознаки відповідно. Результатом реалізації алгоритму є: $\{DOP[K]\}$ – цілий масив оптимальних значень радіусів контейнерів класів розпізнавання у кодовій відстані Хеммінга; $\{EV[K]\}$ – масив еталонних двійкових векторів класів розпізнавання; $\{EM[K]\}$ – дійсний масив максимальних значень інформаційного КФЕ процесу навчання; $\{S[K]\}$ – дійсний масив ЕПС класів розпізнавання; $\{D1[K]\}$, $\{A[K]\}$, $\{B[K]\}$, $\{D2[K]\}$ – дійсні масиви оцінок екстремальних значень точнісних характеристик процесу навчання для відповідних класів розпізнавання: перша вірогідність, помилки першого та другого роду і друга вірогідність відповідно. Змінна D є робочою змінною кроків навчання, на яких послідовно збільшується значення радіуса контейнера класу розпізнавання.

У структурній схемі алгоритму блок 3 формує масив навчальних двійкових вибірок $\{X[J,I,K]\}$ шляхом порівняння значень елементів масиву $\{Y[J,I,K]\}$ з відповідними контрольними допусками на ознаки розпізнавання за правилом

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

Блок 3 також формує варіаційний ряд порядкових статистик $\{S[K]\}$ за правилом (3) і формує масив еталонних двійкових векторів $\{EV[K]\}$ шляхом статистичного усереднення стовпців масиву $\{X[J,I,K]\}$ за правилом

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

при відповідному рівні селекції, який за умовчанням дорівнює $\rho_m = 0,5$. Блок 4 здійснює розбиття множини еталонних векторів на пари “найближчих сусідів”. Блок 11 обчислює на кожному кроці навчання значення інформаційного КФЕ і оцінки точнісних характеристик процесу навчання. При невиконанні умови блока порівняння 12 блок 13 оцінює належність поточного значення критерію $E [D]$ робочій області G_E визначення його функції і при позитивному рішенні блока 13 це значення запам’ятовується блоком 14. Структурну схему базового алгоритму навчання LEARNING наведено на рис. 1.

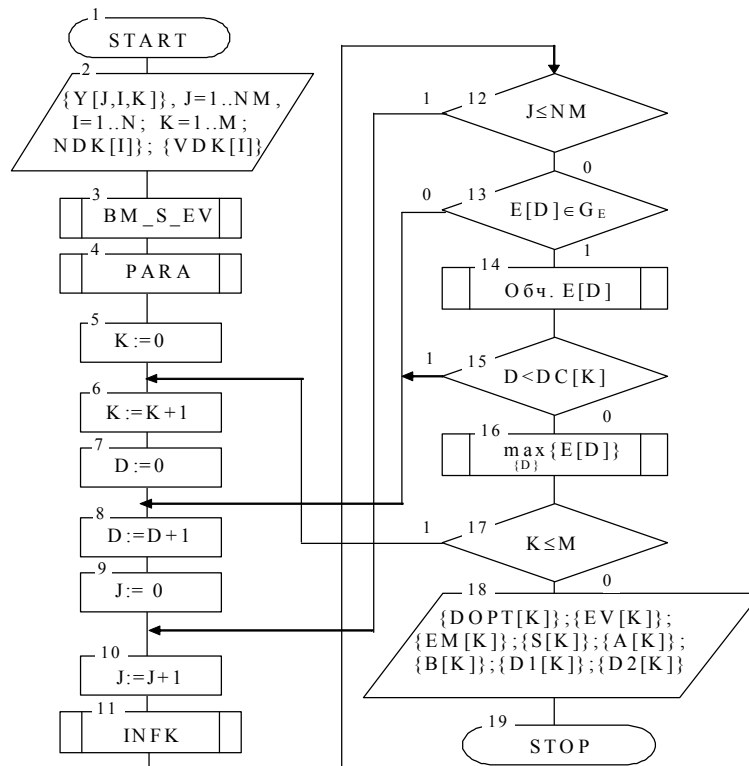


Рисунок 1 – Структурна схема базового алгоритму прогностичного навчання

ПРИКЛАД РЕАЛІЗАЦІЇ АЛГОРИТМУ ПРОГНОСТИЧНОГО НАВЧАННЯ

Одержані результати знайшли експериментальне підтвердження при прогнозуванні функціональної ефективності системи керування хімічним технологічним процесом у ВАТ „Сумихімпром”. На рис. 2 показано одержані на етапі навчання порядкові статистики (3) для чотирьох класів, сформованих залежно від змісту концентрації P_2O_5 у сировині, при контрольних допусках, за яких КФЕ системи керування технологічним процесом досягає глобального максимуму в робочій області визначення його функції.




Рисунок 2 – Графік залежності ЕПС від кількості випробувань

Аналіз рис. 2 показує відповідність всім вищенаведеним вимогам до ЕПС, а також чітку залежність між трендом ЕПС і еталонним вектором відповідного класу, зокрема клас X_1^o із найбільшою ймовірністю „успіхів” має найнижче кінцеве значення ЕПС, для інших класів кінцеві значення варіаційних рядів зростають обернено пропорційно ймовірності „успіху”.

SUMMARY

FORECASTING LEARNING OF AUTOMATED CONTROL SYSTEM OF PHOSPHORIC ACID PRODUCTION

A.S. Dovbysh, V.A. Tron
Sumy State University

The method of learnable forecasting control system synthesis in frameset of information-extreme intellectual technology is offered. Method allows to raise functional efficiency of control system forecasting learning and determination of relearning moment during examination stage with using serial statistics.

СПИСОК ЛІТЕРАТУРИ

1. Силин В.Б., Заковряшин А.И. Автоматическое прогнозирование состояния аппаратуры управления и наблюдения. – М.: Энергия, 1973. – 336 с.
2. Костюк В.И., Гаврик А.П., Ямпольский Л.С., Карлов А.Г. Промышленные роботы: Конструирование, управление, эксплуатация. – К.: Вища шк., 1985. – 359 с.
3. Браверман Э.М., Мучник И.Б. Структурные методы обработки эмпирических данных. – М.: Наука, 1983. – 464 с.

4. Розенблат Ф. Принципы нейродинамики. Перцептроны и теория механизмов мозга.– М.: Мир, 1965. –480 с.
5. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика. – М.: Мир, 1992. – 240 с.
6. Зайченко Ю.П., Моамед Мухамед, Шаповаленко Н.В. Нечіткі нейронні мережі і генетичні алгоритми в задачах макроекономічного прогнозування // Наукові вісті НТУУ «КПІ». – 2002. – С. 20 –30
7. Краснопоясовський А.С., Марченко В.В. Статистична оцінка вибіркової послідовності в задачах автоматичної класифікації // Современные технологии машиностроения: Тематический сборник научных статей. - Отв. ред. Н.В.Захаров. - Киев: ИСМО, Сумы: СумГУ,1997. - Вып.1. - С.141-145.
8. Анисимов Б. В., Курганов В. Д., Злобин В. К. Распознавание и цифровая обработка изображений. - М.: Высшая школа, 1983.–256 с.
9. Краснопоясовський (Довбиш) А.С. Інформаційний синтез інтелектуальних систем керування. Підхід, що ґрунтується на методі функціонально-статистичних випробувань. – Суми: Видавництво СумДУ, 2004. – 261 с.
10. Барра Д. Математическая статистика.– М.: Мир, 1983.– 342 с.
11. Соле Ж. Л. Основные структуры математической статистики.– М.: Мир, 1972. – 127 с.
12. Краснопоясовський А.С. Оптимізація контрольних допусків на ознаки розпізнавання за методом функціонально-статистичних випробувань // Штучний інтелект. – 2003. – №1. – С. 53 – 61.

Надійшла до редакції 16 лютого 2009 р.