

4 Абрамов А.Д., Крупка А.В. Тест максимального правдоподобия для принятия решения о величинах параметров сигналов от протяженных объектов в пассивных радиосистемах. // *Авиационно-космическая техника и технология*. - Харьков: НАКУ «ХАИ», 2002. - с. 7 - 11.

5 Абрамов А.Д. Определение числа шумовых пространственно-временных сигналов методом проверки сложных гипотез по критерию отношения правдоподобия. *Авиационно-космическая техника и технология*. - Харьков: НАКУ «ХАИ», 1996. - с. 407 - 411.

УДК 681.518:004.93

КЛАСИФІКАЦІЙНЕ УПРАВЛІННЯ ТЕХНОЛОГІЧНИМ ПРОЦЕСОМ ВИРОБНИЦТВА СКЛАДНИХ МІНЕРАЛЬНИХ ДОБРІВ

О.М. Куй

У рамках інформаційно-екстремального методу функціонально-статистичних випробувань (МФСВ) розглянуто задачу інформаційного синтезу здатної навчатися інтелектуальної системи управління (ІСУ). Запропоновано математичні моделі процесів навчання і екзамену та алгоритм оптимізації параметрів навчання ІСУ за інформаційним критерієм. Реалізація алгоритму ілюструється на прикладі оптимізації параметрів функціонування АСУТП виробництва складних мінеральних добрив.

Заступник голови правління ВАТ „Сумихімпром” – директор з виробництва, вул. Харківська, ВАТ „Сумихімпром”, Суми, Україна.

Контактний тел.: +38(0542) 33-88-22

e-mail: admin@khimprom.org.ua

В.М. Волков

Начальник виробничо-технічного відділу ВАТ „Сумихімпром”, вул. Харківська, ВАТ „Сумихімпром”, Суми, Україна.

Контактний тел.: (0542) 33-82-71

e-mail: admin@khimprom.org.ua

**А.С. Красноясовський*

Кандидат технічних наук, доцент кафедри.

**М.В. Козинець*

Аспірант кафедри.

**І.В. Шелехов*

Аспірант кафедри.

**Кафедра інформатики Сумського державного університету, вул. Римського-Корсакова, 2, Суми, Україна, 40007.*

Контактний тел.: (0542) 21-40-84

e-mail: kras@kpm.sumdu.edu.ua

Вступ

Підвищення ефективності та оперативності управління виробничими процесами органічно пов'язано із розробкою та впровадженням інтелектуальних інформаційних технологій, що базуються на ідеях і методах машинного навчання, яке є важливим розділом теорії розпізнавання образів [1-7]. Застосування здатних навчатися (самонавчатися) інтелектуальних АСУТП у виробництві дозволяє здійснити перехід від застарілих суб'єктивних методів ручного управління до інтелектуальних інформаційних технологій управління слабо формалізованими процесами та об'єктами, які функціонують в умовах невизначеності. Основні перешкоди на шляху інтенсивного впровадження інтелектуальних АСУТП, що навчаються, все ще обумовлені відставанням теорії машинного навчання від потреб практики. Так, основними недоліками багатьох відомих методів навчання систем розпізнавання, які роблять неефективним їх застосування на практиці, є

ігнорування перетину класів розпізнавання у просторі ознак розпізнавання, що має місце у практичних задачах контролю та управління, і необхідність використання навчальних вибірок великих обсягів. На подолання цих недоліків спрямовано інформаційно-екстремальний метод функціонально-статистичних випробувань (МФСВ), який ґрунтується на прямій оцінці інформаційної спроможності ІСУ [8-10]. Розглянемо у рамках МФСВ основні етапи інформаційного синтезу інтелектуальної АСУТП, здатної навчатися.

1. Постановка задачі

Відомі алфавіт класів розпізнавання $\{X_m^o | m = \overline{1, M}\}$, який характеризує M функціональних станів технологічного процесу, і навчальна матриця типу «об'єкт-властивість» $\|y_{m,i}^{(j)}\|$, $i = \overline{1, N}$, $j = \overline{1, n}$, де N, n – кількість ознак розпізнавання і випробувань відповідно. Нехай клас X_1^o характеризує найбільш бажаний функціональний

стан технологічного процесу. Необхідно на етапі навчання побудувати оптимальне (тут і далі в інформаційному розумінні) нечітке розбиття $\tilde{\mathfrak{R}}^{M|}$, $M = Card\tilde{\mathfrak{R}}^{M|}$, бінарного простору ознак Ω_B на класи розпізнавання за таких умов:

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

$$(\exists \tilde{X}_k^o \in \tilde{\mathfrak{R}}^{M|}) (\exists \tilde{X}_l^o \in \tilde{\mathfrak{R}}^{M|}) [\tilde{X}_k^o \neq \tilde{X}_l^o \rightarrow \tilde{X}_k^o \cap \tilde{X}_l^o \neq \emptyset]; \quad (2)$$


$$(\forall \tilde{X}_k^o \in \tilde{\mathfrak{R}}^{M|}) (\forall \tilde{X}_l^o \in \tilde{\mathfrak{R}}^{M|}) [\tilde{X}_k^o \neq \tilde{X}_l^o \rightarrow Ker\tilde{X}_k^o \cap Ker\tilde{X}_l^o = \emptyset]; \quad (3)$$

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


і на етапі екзамєну (у робочому режимі) за максимальним значенням функції належності дефазифікувати функціональний стан АСУТП і у разі необхідності стабілізувати технологічний процес. Тут під функціональним станом розуміються основні характеристики системи у визначений момент або інтервал часу її функціонування у заданому режимі, які залежать як від технічного стану системи, так і від середовища, що впливає на неї через контрольовані і неконтрольовані фактори.

2. Математичні моделі


Математичні моделі розглянемо на рівні системного аналізу у вигляді діаграм відображення множин, що утворюються на етапах навчання і екзамєну АСУТП. Нехай універсум випробувань задається декартовим добутком множин $G \times T \times \Omega \times Z \times V$, де G – множина сигналів на вході АСУТП; T – множина моментів зчитування інформації; Ω – простір ознак розпізнавання; Z – множина можливих функціональних станів АСУТП; V – множина вирішальних правил, які застосовуються для досягнення поставленої мети. Оператор $F: G \times T \times \Omega \times Z \times V \rightarrow Y$ формує вхідний математичний опис – вибірккову множину Y , яка утворює у загальному випадку дійсну навчальну матрицю $\|y_{m,i}^{(j)}\|$ для заданого алфавіту $\{X_m^o\}$. Тоді у рамках МФСВ діаграма відображень множин на етапі навчання АСУТП має вигляд



Тут оператор $\theta_1: Y \rightarrow X$ формує бінарну навчальну матрицю X і оператор $\theta_2: X \rightarrow \tilde{\mathfrak{R}}^{M|}$ будує розбиття у просторі Ω_B . Оператор класифікації $\Psi: \tilde{\mathfrak{R}}^{M|} \rightarrow I^{|l|}$ перевіряє основну статистичну гіпотезу $\gamma_1: y_{m,i}^{(j)} \in X_m^o$, де $I^{|l|}$ – множина гіпотез. Оператор γ визначає множину точніших характеристик $\mathfrak{Z}^{|q|}$, де $q = l^2$, а оператор ϕ формує множину E значень інформаційного критерію функціональної ефективності (КФЕ) навчання. Оператор r корегує розбиття $\tilde{\mathfrak{R}}^{M|}$ залежно від значень критерію. За діаграмою (5) оператори контуру



реалізують базовий алгоритм LEARNING [8], який безпосередньо визначає екстремальні значення геометричних параметрів контейнерів шляхом пошуку максимуму критерію $E_m^* \subset E$. Оптимізація системи контрольних допусків на ознаки здійснюється так само за ітераційним алгоритмом, в якому застосовуються оператори контуру



де θ – композиція операторів θ_1 і θ_2 . Оптимізація рівнів селекції координат еталонних векторів здійснюється за алгоритмом, в якому задіяно оператори контуру




Оператор U регламентує процес навчання і дозволяє оптимізувати параметри його плану проведення.

Проблема формування інформативного словника ознак, яка розглядається як одна із задач загального інформаційного синтезу ІСУ, так само вирішується в рамках оптимізації процесу навчання за МФСВ. Для цього у діаграму (5) введено додатковий контур оптимізації словника ознак, який замикається оператором $\pi: E \rightarrow \Sigma^\Lambda$, де множина Σ^Λ – відкритий словник, що містить первинні та вторинні ознаки, і оператором $\omega: \Sigma^\Lambda \rightarrow \Omega$, котрий безпосередньо змінює розмірність простору ознак. Аналогічно розширення словника ознак розпізнавання може здійснюватися, наприклад, при оптимізації в процесі навчання параметрів впливу на образи зовнішнього середовища та інших параметрів функціонування ІСУ, які впливають на потужність простору станів Z , за допомогою оператора $h: \Sigma^\Lambda \rightarrow Z$. У діаграмі (5) оператор τ змінює крок дискретизації реалізації образу, що так само змінює потужність словника Σ^Λ .

Діаграма відображень множин на екзамєні має такі відмінності від діаграм оптимізаційного навчання за МФСВ:

- зворотний зв'язок у діаграмі не містить контурів оптимізації параметрів функціонування системи, а оператор замкнення діаграми U_E регламентує процес прийняття рішень на екзамєні;
- замість оператора θ вводиться оператор p проєкціонування вибіркової множини X – екзамєнаційної матриці, що розпізнається, на розбиття $\tilde{\mathfrak{R}}^{M|}$, яке побудовано на етапі навчання;
- оператор класифікації Ψ утворює композицію двох операторів: $\Psi_1: \tilde{\mathfrak{R}}^{M|} \rightarrow \Phi$, де Φ – множина функцій належності, і оператор $\Psi_2: \Phi \rightarrow I^{M+1}$, який вибирає гіпотезу за максимальним значенням значення функції належності. З урахуванням наведених відмінностей діаграма відображень множин на екзамєні набуває вигляду



У діаграмі (6) оператор f відображає універсум випробувань на бінарну вибірккову множину X , яка утворює екзамєнаційну матрицю $\|x_i^{(j)}\|, i = \overline{1, N}, j = \overline{1, n}$, аналогічну за структурою та параметрами формування навчальної матриці $\|y_{m,i}^{(j)}\|$.

Перевагою категорійних моделей у вигляді діаграм відображень множин є те, що вони дозволяють на етапі системного аналізу не тільки встановлювати відношення між елементами інформаційного забезпечення та інформаційними потоками оброблення інформації, але і безпосередньо розробляти структуру алгоритмів режимів функціонування інтелектуальних систем.

3. Критерії оптимізації

Як критерії оптимізації параметрів функціонування інтелектуальної АСУТП у рамках МФСВ можуть застосовуватися статистичні інформаційні критерії, які є функціоналами від точнісних характеристик класифікатора. Наприклад, модифікація критерію Кульбака для двохальтернативної системи оцінок процесу навчання розпізнаванню реалізацій класу X_m^o за МФСВ і при рівніймовірних апріорних гіпотезах має вигляд [11]

$$E_m = 0,5 \log_2 \left(\frac{D_1^{(k)} + D_2^{(k)}}{\alpha^{(k)} + \beta^{(k)}} \right) * [(D_1^{(k)} + D_2^{(k)}) - (\alpha^{(k)} + \beta^{(k)})] = \log_2 \left(\frac{2 - (\alpha^{(k)} + \beta^{(k)})}{\alpha^{(k)} + \beta^{(k)}} \right) * [1 - (\alpha^{(k)} + \beta^{(k)})], \quad (7)$$

де $D_1^{(k)}, D_2^{(k)}, \alpha^{(k)}, \beta^{(k)}$ – точнісні характеристики процесу навчання: перша та друга достовірності, помилки першого та другого роду відповідно, отримані на k -му кроці навчання.

Нормовану модифікацію критерію (7) можна подати у вигляді

$$J = \frac{E_m}{J_{\max}}$$

де J_{\max} – значення критерію (7) при $D_1^{(k)} = D_2^{(k)} = 1$ і $\alpha^{(k)} = \beta^{(k)} = 0$.

4. Алгоритм навчання АСУТП

У загальному випадку ($M > 2$) алгоритм навчання полягає в реалізації багатоциклічної ітераційної процедури оптимізації структурованих параметрів функціонування АСУТП шляхом пошуку глобального максимуму усередненого за всім алфавітом класів значення КФЕ навчання, тобто

$$g_{\xi}^* = \langle \mathbf{arg} \{ \max_{G_{\xi}} \{ \dots \{ \max_{G_2} \{ \max_{G_1} \frac{1}{M} \sum_{m=1}^M E_m \} \} \} \} \rangle \quad (8)$$

де g_{ξ}^* – оптимальне значення параметра навчання, яке визначається у зовнішньому циклі ітераційної процедури оптимізації, $\xi = \overline{1, M}$; G_1, G_2, \dots, G_{ξ} – області допустимих значень відповідних параметрів навчання; E_m – інформаційний КФЕ навчання розпізнаванню реалізацій класу X_m^o .

Кількість циклів оптимізації визначається кількістю контурів оптимізації в діаграмі (5). При цьому внутрішні цикли оптимізують фенотипні параметри навчання, які безпосередньо визначають геометричну форму контейнерів. Такими параметрами, наприклад, для гіперсферичних контейнерів є їх радіуси, а для еліпсоїдних – повздовжня та поперечна напіввісі за умови, що центри контейнерів збігаються із центрами розсіювання реалізацій образів. До генотипних віднесемо параметри навчання, які прямо або непрямо впливають на розподіл реалізацій

класу. Це, в першу чергу, система контрольних допусків на ознаки розпізнавання, рівні селекції координат еталонних векторів, параметри оптимізації словника ознак, плану навчання, параметри впливу середовища та інше. Послідовна оптимізація кожного із цих параметрів дозволяє збільшувати значення максимуму КФЕ навчання, що підвищує повну вірогідність прийняття рішень на екзаміні. Обов'язковою процедурою алгоритму навчання за МФСВ є оптимізація контрольних допусків на ознаки розпізнавання. У праці [9] досліджено алгоритм паралельної оптимізації контрольних допусків на ознаки, що є виправданим при розпізнаванні зображень. При класифікаційному управлінні технологічними процесами словник складається із груп і окремих ознак, які, як правило, мають різні шкали виміру. Тому тут доцільно застосовувати алгоритми послідовної або послідовно-паралельної оптимізації контрольних допусків на ознаки розпізнавання.

Алгоритм оптимізації контрольних допусків за МФСВ полягає у наближенні глобального максимуму інформаційного критерію оптимізації до найбільшого його значення в області значень функції. Тому важливого значення набуває дослідження збіжності такого алгоритму. Розглянемо збіжність алгоритму послідовної оптимізації контрольних допусків на ознаки розпізнавання. Введемо такі позначення:

$x = \langle x_1, \dots, x_i, \dots, x_N \rangle$ – структурований вектор ознак розпізнавання;

$\delta_k = \langle \delta_{k,1}, \dots, \delta_{k,i}, \dots, \delta_{k,N} \rangle$ – структурований вектор стартових параметрів контрольних допусків на ознаки розпізнавання;

l – кількість прогонів ітераційної процедури послідовної оптимізації контрольних допусків;

$E_{1\max}^{(l)}(x, \delta)$ – максимальне значення КФЕ в робочій області його визначення при l -му прогоні ітераційної процедури;

E_1^* – найбільший глобальний максимум КФЕ в області його значень;

$\delta_{k,i}^{(l)}$ – значення параметра поля контрольних допусків для i -ої ознаки, яке отримано при l -му прогоні ітераційної процедури та дорівнює половині інтервалу $[y_{1,i}^{(l)} \pm \delta_{k,i}^{(l)}]$;

$\hat{\delta}_{k,i}^{(l)}$ – екстремальне значення параметра поля контрольних допусків для i -ої ознаки;

$\delta_{k,i}^*$ – оптимальне значення поля контрольних допусків: $\delta_{k,i}^* = \mathbf{arg} \max_{G_E} E_1^*$.

З урахуванням (8) і введених позначень алгоритм послідовної оптимізації поля контрольних допусків на ознаки розпізнавання приймає вигляд

$$\{\delta_{k,i}^*\} = \langle \mathbf{arg} \{ \max_{G_{\delta_i}} \{ \max_{G_E} \left[\bigotimes_{l=1}^L \max_{G_{d_1}} E_1^{(l)} \right] \} \} \rangle, i = \overline{1, N}, \quad (9)$$

де $G_{\delta_i}, G_E, G_{d_1}$ – області допустимих значень поля контрольних допусків для i -ої ознаки, критерію оптимізації і кодової відстані d_1 відповідно; \bigotimes – символ операції повторення.

Для оптимальних контейнерів, побудованих у радіальному базисі за МФСВ, з метою недопущення “поглинання” одним класом ядра іншого додатково накладається таке обмеження

$$\left(\forall X_k^o \in \tilde{X}^{(M)} \right) \left(\forall X_l^o \in \tilde{X}^{(M)} \right) \left[X_k^o \neq X_l^o \rightarrow (d_k^* < d(x_k \oplus x_l)) \& (d_l^* < d(x_k \oplus x_l)) \right], \quad (10)$$

де d_k^* , d_l^* – оптимальні радіуси контейнерів класів X_k^o і X_l^o ; $d(x_k \oplus x_l)$ – кодова відстань між центрами класів X_k^o і X_l^o .

Розглянемо послідовність $u_N^{(l)} = \langle u_1^{(l)}, \dots, u_i^{(l)}, \dots, u_N^{(l)} \rangle$, де

$$u_i^{(l)} = E_{1\max}^{(l)}(x, \hat{\delta}_{k,1}, \dots, \hat{\delta}_{k,i}, \delta_{k,i+1}, \dots, \delta_{k,N}) - E_{1\max}^{(l)}(x, \hat{\delta}_{k,1}, \dots, \hat{\delta}_{k,i-1}, \delta_{k,i}, \dots, \delta_{k,N})$$

Т в е р д ж е н н я. Послідовність $u_N^{(l)}$ монотонно спадає і обмежена знизу.

Доведення. Покажемо, що $u_{i-1}^{(l)} \geq u_i^{(l)}$. Це легко доводитися за індукцією. Нехай для першої ознаки знайдено $\hat{\delta}_{k,1}$, а значення контрольних допусків для інших ознак залишаються стартовими. Тоді має місце

$$E_{1\max}^{(l)}(x, \hat{\delta}_{k,1}, \delta_{k,2}, \dots, \delta_{k,i}, \dots, \delta_{k,N}) \geq E_{1\max}^{(l)}(x, \delta_{k,1}, \dots, \delta_{k,i}, \dots, \delta_{k,N}).$$

Оскільки за властивістю інформаційного критерію $E_{1\max}^{(l)} \geq 0$, то відношення рівності може бути тільки за умови, що стартове значення $\delta_{k,i}$ дорівнює екстремальному. Так само справедливо для всіх N екстремальних значень $\hat{\delta}_{k,i}$, $i = \overline{1, N}$:

$$E_{1\max}^{(l)}(x, \hat{\delta}_{k,1}, \dots, \hat{\delta}_{k,i}, \dots, \hat{\delta}_{k,N}) \geq E_{1\max}^{(l)}(x, \hat{\delta}_{k,1}, \dots, \hat{\delta}_{k,i}, \dots, \hat{\delta}_{k,N-1}, \delta_{k,N}).$$

Таким чином, послідовність $u_i^{(l)}$, $i = \overline{1, N}$, є спадною і обмеженою знизу, оскільки її члени позитивні. Але не ясно, чи є послідовність $u_N^{(l)}$ стаціонарною, тобто чи існує таке L , що для будь-якого $l > L$ $u_{i-1}^{(l)} = u_i^{(l)}$. Відповідь на це запитання дає така теорема.

Т е о р е м а. Ітераційний алгоритм послідовної оптимізації контрольних допусків на ознаки розпізнавання (9) збігається з імовірністю одиниця.

Доведення. Для доведення теореми необхідно та достатньо показати, що екстремальні поля контрольних допусків $\{\hat{\delta}_{k,i}^{(l)}\}$ збігаються відповідно до оптимальних $\{\delta_{k,i}^*\}$, $i = \overline{1, N}$. Припустимо, що послідовність $u_N^{(l)}$, яка за твердженням спадає і обмежена знизу, збігається на L -му прогоні ітераційної процедури і вона є стаціонарною, тобто $u_N^{(L+1)} = u_N^{(L)}$. Тоді маємо $E_{1\max}^{(L+1)}(x, \hat{\delta}_k) = E_{1\max}^{(L)}(x, \hat{\delta}_k)$. Але звідси не обов'язково витікає, що $\{\hat{\delta}_{k,i}^{(l)}\} = \{\delta_{k,i}^*\}$, оскільки функція $E_1(x, \delta)$ не є взаємо-однозначною. Покажемо концептуально, що все-таки існує $\hat{\delta}_{k,i}^{(l)} = \delta_{k,i}^*$, $i = \overline{1, N}$, для будь-якого $l \geq L$.

У силу максимально-дистанційного принципу розпізнавання образів у процесі оптимізації розбиття \mathfrak{R}^{2l} для найближчих сусідніх класів X_1^o і X_2^o повинна виконуватися умова $d(x_1 \oplus x_2) \rightarrow \max_{G_d}$, яка не суперечить умовам (1-4) і (10). Нехай існує для функції $E_{1\max}^{(l)}(x, \delta)$ множина екстремальних параметрів:

$$\langle \hat{\delta}_{k,i=\min}^{(l)}, \hat{\delta}_{k,i=\min+1}^{(l)}, \dots, \hat{\delta}_{k,i=\max-1}^{(l)}, \hat{\delta}_{k,i=\max}^{(l)} \rangle.$$

Оскільки збільшення параметра $\hat{\delta}_{k,i}^{(l)}$ збільшує ймовірність переходу i -ої координати еталонного вектора $x_2 \in X_2^o$ в одиницю, то за умови, що еталонний вектор $x_1 \in X_1^o$ є одиничним, має місце

$$d[(x_1 \oplus x_2) / \hat{\delta}_{k,i=\min}^{(l)}] \geq d[(x_1 \oplus x_2) / \hat{\delta}_{k,i=\min+1}^{(l)}].$$

Таким чином, можна стверджувати, що припущення про стаціонарність послідовності $u_N^{(l)}$ є справедливим, оскільки в силу максимально-дистанційного принципу розпізнавання образів існує за умови $E_{1\max}^{(L+1)}(x, \hat{\delta}_k) = E_{1\max}^{(L)}(x, \hat{\delta}_k)$ оптимальне значення параметру поля контрольних допусків $\delta_{k,i}^* = \hat{\delta}_{k,i=\min}^{(L)}$.

Так само, виходячи із концепції методу автоматичної класифікації (у даному випадку МФСВ), що є найбільш ефективним методом евристичного виведення, можна довести, що алгоритм паралельної оптимізації контрольних допусків на ознаки розпізнавання збігається за ймовірністю, тобто $E_1^* = E_{1\max}^{(L)} + \epsilon$, де ϵ – будь-яке мале позитивне число. Таким чином, послідовність $u_N^{(l)}$, $l = \overline{1, L}$, не є стаціонарною. Тут l – кількість кроків одночасного збільшення контрольних допусків для всіх N ознак розпізнавання. Підкреслимо, що вибір алгоритму паралельної оптимізації контрольних допусків, перш за все, визначається вимогами його оперативності, які є достатньо жорсткими при розпізнаванні зображень.

Отримані в процесі навчання за МФСВ оптимальні контейнери класів у вигляді гіперсфер дозволяють здійснювати на екзаміні дефазифікацію за простою функцією належності:

$$\mu_m = \left[1 - \frac{d(x_m \oplus x^{(j)})}{d_m^*} \right]^+ \quad (11)$$

де $[\dots]^+$ – позитивна частина функції; $x^{(j)}$ – реалізація, що розпізнається.

5. Приклад оптимізації параметрів навчання АСУТП

Розглянемо реалізацію алгоритму навчання на прикладі АСУТП виробництва складного мінерального добрива NPK (азот, фосфор і калій) у ВАТ «Суміхімпром». На рис.1 наведено схему технологічного процесу нейтралізації при виробництві NPK.

Суть процесу нейтралізації така. Розбавлені фосфорна та сірчана кислоти поступають відповідно із ємностей 1-5 і 1-1 в ємності 3-1 і 3-2, де вони змішуються. Із ємності 3-1 суміш поступає послідовно у сатуратори 4-1 і 4-2, а із ємності 3-2 – у сатуратори 4-6 і 4-5. У цих сатураторах відбувається перша стадія нейтралізації кислот (амонізація). Утворена в процесі нейтралізації пульпа поступає в ємність 3-1, де здійснюється її лабораторний хімічний аналіз. Потім пульпа із позиції 3-1 поступає послідовно у сатуратори 4-4 і 4-5, де відбувається друга стадія нейтралізації з метою доведення азоту до заданого рівня концентрації в пульпі. Після завершення другої стадії нейтралізації пульпа поступає в ємність 5-2, де так само здійснюється її лабораторний хімічний аналіз. Після корегування змісту в пульпі фосфору та калію, вона поступає в барабанний гранулятор, де набуває кінцевих показників якості.

Структурована реалізація функціонального стану технологічного процесу складалася із значень 34 ознак розпізнавання, із яких 12 становили результати хімічного аналізу (вхідний і міжопераційний контроль), а інші – значення відповідних датчиків інформації (температури, рівнів, витрати, рН-метрів та електричних параметрів технологічного обладнання). Априорний алфавіт класів розпізнавання складався із п'яти класів. При цьому базовий клас X_1^o відповідав функціональному стану АСУТП, який забезпечував вихід продукту NPK із заданими хімічним складом і показниками гранульованості. Інші класи характеризувалися різними відхиленнями від заданих показників якості.

Як параметр навчання, що оптимізується у зовнішньому циклі, розглядалось поле контрольних допусків $\delta_{k,i}$ на ознаки розпізнавання, а як параметр навчання внутрішнього циклу оптимізації – радіус d_m гіперсферичного

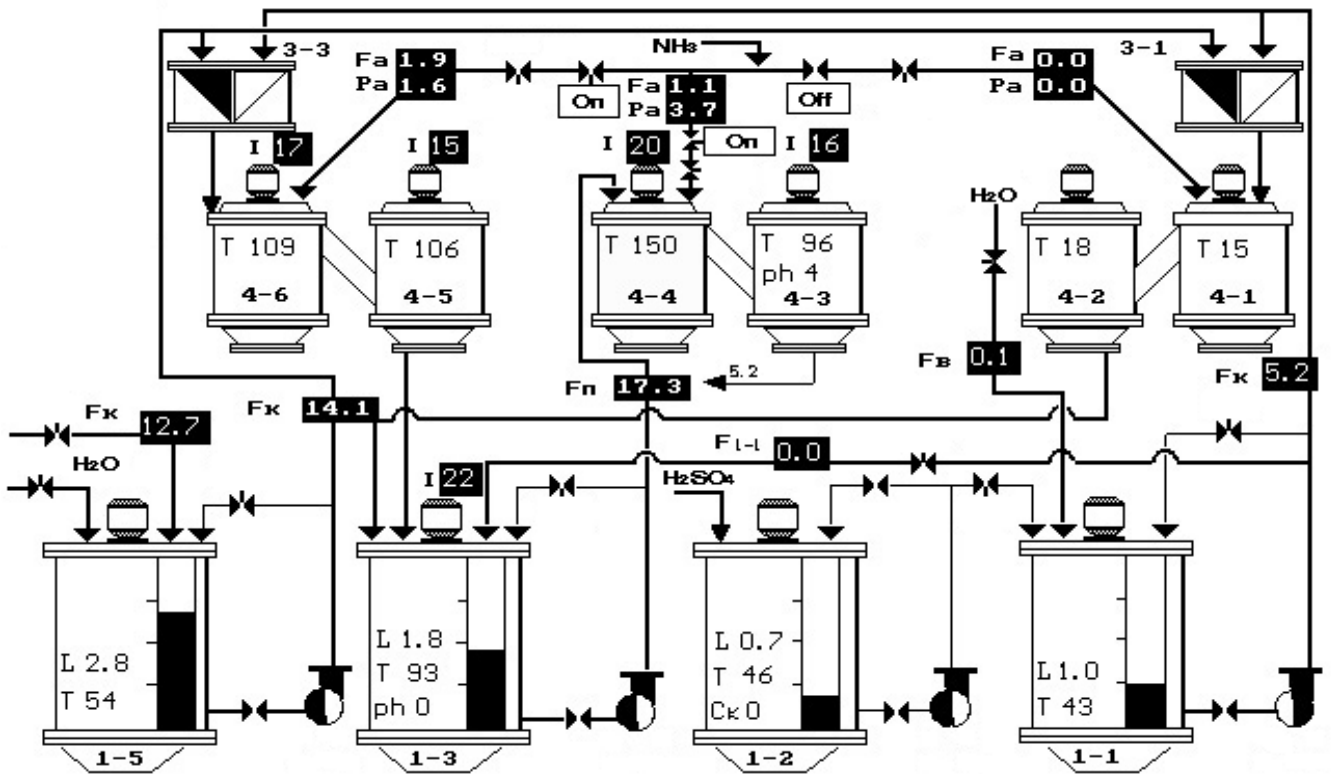


Рисунок 1. Мнемосхема технологического процесса нейтрализации продукта NPK

контейнера $K_m \subset X_m^o$. Оскільки ознаки склали різнофакторні групи, тобто вони є результатом впливу на функціональну ефективність АСУТП різних факторів і мають різні шкали виміру, то оптимізація контрольних допусків здійснювалася за послідовним алгоритмом (9), що є прийнятним для технологічних процесів з малою швидкістю. У процесі експлуатації за алгоритмом факторного класифікаційного аналізу у рамках МФСВ АСУТП формувала нові класи і оптимізувала параметри навчання для нового розбиття.

З метою експериментального дослідження збіжності алгоритму навчання на рис. 2а наведено динаміку зміни контрольних допусків у процесі їх оптимізації для восьмої у структурі реалізації образу ознаки (зміст фосфору в пульпі після першої стадії нормалізації) при першому прогоні ітераційної процедури ($l=1$). На рис. 2б наведено залежність інформаційного критерію (7) від радіуса контейнера класу X_1^o .




Рисунок 2. Оптимізація контрольних допусків на значення змісту фосфору в пульпі при $l=1$

Тут і далі область значень контрольних допусків задається градаціями шкали виміру ознаки, а значення радіусів подаються як кодові відстані від геометричного центра контейнера. Аналіз рис. 2 показує, що глобальний максимум критерію (7) при оптимізації контрольних допусків на значення даної ознаки при $l=1$ дорівнює $E_{\max}^{(1)}=3,00$. Оскільки функція критерію (7) не взаємодозначна, то оптимальні значення контрольних допусків знаходяться в інтервалі 9-13. Як екстремальний параметр контрольного поля допусків на ознаку алгоритм згідно наведеної вище теореми вибирає мінімальне значення: $\hat{\delta}_{k,8}^{(1)} = \pm 9$, при якому екстремальний радіус дорівнює $\hat{d}_1^{(1)} = 9$. Аналіз залежності критерію (7) від параметра поля допусків для такої самої ознаки (рис.3а) і від радіуса контейнера класу X_1^o (рис.3б), отриманих при $l=2$, показує збільшення значення критерію ($E_{\max}^{(2)}=7,65$) і при цьому екстремальні параметри навчання відповідно приймають значення $\hat{\delta}_{k,8}^{(2)} = \pm 15$ і $\hat{d}_1^{(2)} = 8$.




Рисунок 3. Оптимізація контрольних допусків на зміст фосфору в пульпі при $l=2$

На рис. 4 наведено такі самі залежності, отримані на цьому прогоні ($l=2$) при оптимізації контрольних допусків на значення 24-ої ознаки – щільності пульпи на вході у барабанний гранулятор.




Рисунок 4. Оптимізація контрольних допусків на значення 24-ої ознаки (щільності пульпи в позиції 5-2) при $l=2$

Аналіз рис. 4 показує, що значення критерію $E_8^{(2)}$ збігається із значенням $E_{24}^{(2)} = 7,65$, що свідчить про збігання ітераційної процедури оптимізації параметрів навчання за послідовним алгоритмом вже після другого її прогону. При цьому для 24-ої ознаки отримано такі оптимальні параметри навчання: $\delta_{24}^{*(2)} = 12$ і $d_1^{*(2)} = 8$.

Підсумок

Застосування МФСВ як інформаційно-екстремального методу автоматичної класифікації дозволяє оптимізувати в інформаційному розумінні процес навчання інтелектуальної системи управління слабо формалізованими процесами, функціональні стани яких на практиці можуть перетинатися. Перевагою використання на рівні системного аналізу математичних моделей у вигляді діаграм відображення множин, що застосовуються при автоматичній класифікації в рамках МФСВ, є спрощення синтезу алгоритмів навчання та екзамену. Так, алгоритм навчання подається як багатоциклічна ітераційна процедура пошуку глобального екстремуму інформаційного критерію функціональної ефективності у робочій області його визначення. При цьому кількість циклів визначається кількістю контурів оптимізації параметрів навчання у відповідній діаграмі відображення множин. У задачах контролю та управління побудова контейнерів класів розпізнавання у радіальному базисі є виправданою, оскільки, по-перше, на практиці має місце гіпотеза компактності (як чіткої, так і нечіткої) реалізацій образу і, по-

друге, значно спрощується обчислювальна трудомісткість алгоритму навчання через редукцію форми контейнерів класів розпізнавання.

Таким чином, МФСВ належить до методів непараметричної автоматичної класифікації, які дозволяють дійсновати корегування вхідного математичного опису здатної навчатися інтелектуальної системи з метою більшення асимптотичної достовірності класифікації на екзамені. Застосування здатних навчатися (самонавчатися) інтелектуальних АСУТП у виробництві дозволяє значно підвищити відсоток конденційного продукту, який повинен відповідати світовим стандартам, продуктивність праці та зменшити виробничі втрати при переналадженні технологічних ліній.

Література

1. Ивахненко А. Г. О принципах построения обучающихся систем управления сложными процессами. - М.: Наука, 1970. - 252 с.
2. Васильев В.И., Шевченко А.И. Формирование и опознавание образов. - Донецк: ДонГИИИ, 2000. - 360 с.
3. Сироджа И.Б. Квантовые модели и методы искусственного интеллекта для принятия решений и управления. - Киев: Наукова думка, 2002. - 490 с.
4. Скурихин В.И., Павлов А.А., Путилов Э.П., Гриша С.Н. Автоматизированные системы управления гибкими технологиями. - К.: Техніка, 1987. - 165 с.
5. 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.
6. Анисимов Б.В., Курганов В.Д., Злобин В.К. Распознавание и цифровая обработка изображений. - М.: Высшая школа, 1983. - 256 с.
7. Duda R.O., Hart P.E., Stork D.G. Pattern Classification, second ed. John Wiley & Sons, New York, 2000. - 425 p.
8. Краснопоясовський А.С. Оптимізація контейнерів класів розпізнавання за методом функціонально-статистичних випробувань // Автоматизированные системы управления и приборы автоматики, 2002.-Вып.119.- С. 69-76.
9. Краснопоясовський А.С. Оптимізація контрольних допусків на ознаки розпізнавання за МФСВ // Штучний інтелект.- 2003.- №1. - С. 53 - 62.
10. Краснопоясовский А.С. Классификационная настройка сложной системы // Управляющие системы и машины.-2002.-№1.-С. 9-15.
11. Краснопоясовський А. С., Черниш А. В., Сластувський О.Ю. Про вибір критерію функціональної ефективності системи розпізнавання, що навчається // Радиодіелектроніка и информатика, 2001.- №4.-С. 121-124.