

УДК 681.518.004.93

ОПТИМІЗАЦІЯ РІВНІВ СЕЛЕКЦІЇ ЕТАЛОННИХ ВЕКТОРІВ КЛАСІВ РОЗПІЗНАВАННЯ В РАМКАХ МЕТОДУ ФУНКЦІОНАЛЬНО-СТАТИСТИЧНИХ ВИПРОБУВАНЬ

А.С. Краснопоясовський, канд. техн. наук

Сумський державний університет

Розглядається математична модель і алгоритм оптимізації параметрів навчання за екстремально-інформаційним методом функціонально-статистичних випробувань, що ґрунтується на прямій оцінці інформаційної здатності інтелектуальної системи керування.

* * *

Рассматривается математическая модель и алгоритм оптимизации параметров обучения по экстремально-информационному методу функционально-статистических испытаний, основанному на прямой оценке информационной способности интеллектуальной системы управления.

* * *

The mathematical model and algorithm of optimization of learning parameters is considered within the frames of extreme-informational method of functional-statistic tests (MFST), which is based on a direct estimation of an information ability of the intelligent control system.

Вступ

Вирішення проблеми підвищення ефективності функціонування інтелектуальних систем керування (ІСК) пов'язано із наданням їм властивостей навчання (самонавчання). Основним недоліком відомих методів навчання розпізнаванню образів є їх модельність, яка обумовлена використанням статистично стійких і однорідних навчальних вибірок великих обсягів, утворення яких на практиці, як правило, ускладнено. При цьому побудова на етапі навчання ІСК "точних", але складних за формою замкнених роздільних гіперповерхонь – контейнерів класів розпізнавання [1,2] не гарантує за реальних умов отримання на екзамені вірогідності розпізнавання, наближеної до максимально асимптотичної, яка визначається ефективністю навчання. У рамках детерміновано-статистичного підходу виправданим є побудова оптимальних в інформаційному розумінні статистично усереднених контейнерів, які забезпечують максимальну міру різноманітності між реалізаціями найближчих сусідніх класів. На досягнення такої мети спрямовано екстремально-інформаційний метод функціонально-статистичних випробувань (МФСВ), який ґрунтується на прямій

оцінці інформаційної здатності ІСК, що навчається [3]. Поширення в рамках МФСВ принципу редукції [4] на форму контейнерів класів розпізнавання зумовило доцільність їх побудови в радіальному базисі простору ознак за умови оптимізації їх геометричних параметрів, які визначають фенотип об'єкта. Такими параметрами є центри контейнерів, які збігаються з вершинами еталонних векторів-реалізацій відповідних класів, і радіуси контейнерів. Якщо побудова оптимального контейнера у формі гіперсфери відповідає мінімально-дистанційному принципу розпізнавання образів [2], то для реалізації максимально-дистанційного принципу необхідно максимізувати середню міжцентрову відстань для класів із заданого алфавіту. Досягнення цієї мети в рамках МФСВ можливо шляхом оптимізації параметрів навчання, які впливають на розподіл реалізацій класів – генотип об'єкта. Такими параметрами в МФСВ є параметр поля контрольних допусків δ_i , $i = \overline{1, N}$, і рівень селекції координат еталонних векторів ρ_m , $m = \overline{1, M}$. Тут N, M – кількість ознак і класів розпізнавання відповідно.

Визначення. Рівнем селекції координат еталонного вектора будь-якого класу розпізнавання називається

вається рівень квантування дискрет полігона емпіричних частот попадання значень ознак розпізнавання у свої поля контрольних допусків.

Полігон будується для кожного класу так: по осі абсцис відкладаються ранги ознак розпізнавання, які відповідають їх номерам у двійковому векторі-реалізації, а по осі ординат – відносні частоти випробувань, при яких значення відповідної ознаки знаходиться в своєму полі контрольних допусків. За умовчанням приймається рівень селекції $\rho_m=0,5$.

Розглянемо вплив рівнів селекції координат еталонних векторів на ефективність навчання в рамках МФСВ.

Постановка задачі

Оптимізацію рівнів селекції ρ_m будемо здійснювати в рамках алгоритму навчання за МФСВ. Нехай дано $\{X_m^o \mid m = \overline{1, M}\}$ – алфавіт M класів розпізнавання, які можуть перетинатися, і навчальну матрицю $\|y_{m,j}^{(j)}\|$, $i = \overline{1, N}$, $j = \overline{1, n}$, де N, n – кількість ознак розпізнавання і реалізацій образу відповідно. Відомий структурований вектор параметрів навчання $g_m = \langle g_{m,1}, \dots, g_{m,\xi}, \dots, g_{m,\Xi} \rangle$ з обмеженнями $R_\xi(g_1, \dots, g_\Xi) \leq 0$. Треба на етапі навчання побудувати в бінарному просторі ознак оптимальне (тут і далі в інформаційному розумінні) нечітке розбиття $\tilde{\mathfrak{R}}^{|M|}$ і при цьому визначити оптимальні значення параметрів, які забезпечують максимум критерію функціональної ефективності (КФЕ) навчання

$$E^* = \max_{\{G_\xi\}} \bar{E},$$

де $\bar{E} = \frac{1}{M} \sum_{m=1}^M E_m^*$ – усереднений КФЕ навчання розпізнаванню реалізацій образів; $\{G_\xi\}$ – області допустимих значень параметрів навчання; і на етапі екзамени прийняти рішення про належність реаліза-


цій, що розпізнаються, одному із класів алфавіту $\{X_m^o\}$. Тут E_m^* – максимум КФЕ навчання розпізнаванню реалізацій класу X_m^o . Тоді оптимальне значення рівня селекції визначається як розв’язок часткової задачі інформаційного синтезу ІСК, що навчається:

$$\rho_m^* = \arg_{G_\rho} E_m^*,$$

де $G_\rho \in [0;1]$ – область допустимих значень параметра ρ_m .


Математична модель оптимізації параметрів навчання за МФСВ

Математичну модель процесу навчання ІСК за МФСВ подамо у вигляді діаграми відображень множин, які застосовуються на етапі навчання при оптимізації рівнів селекції:




Тут універсум випробувань задається декартовим добутком $G \times T \times Z \times \Omega$, де G – множина сигналів на вході ІСК; T – множина моментів зняття інформації з рецепторів; Z – множина станів ІСК; Ω – простір ознак розпізнавання. Оператор виходу $\Phi : G \times T \times Z \times \Omega \rightarrow Y$ формує на вході системи прийняття рішень вибірку множини Y – дійсну або цілу навчальну матрицю $\|y_{m,i}^{(j)}\|$ для абетки класів розпізнавання $\{X_m^o\}$, $m = \overline{1, M}$. Оператор $\theta : Y \rightarrow \tilde{\mathfrak{R}}^{|M|}$ будує нечітке розбиття $\tilde{\mathfrak{R}}^{|M|}$, яке допускає у загальному випадку перетин класів розпізнавання, що є характерним для практичних задач контролю та управління. Оператор θ є композицією двох операторів: оператор $\theta_1 : Y \rightarrow X$, де X –

двійкова вибіркова множина – навчальна матриця $\|x_{m,i}^{(j)}\|$, і оператор $\theta_2 : X \rightarrow \tilde{\mathfrak{R}}^{|\mathbf{M}|}$. Оператор $\Psi : \tilde{\mathfrak{R}}^{|\mathbf{M}|} \rightarrow \mathbf{I}^{|\mathbf{I}|}$ перевіряє основну статистичну гіпотезу $\gamma_1 : x_{m,i}^{(j)} \in X_m^o$. Тут $\mathbf{I}^{|\mathbf{I}|}$ – множина альтернативних гіпотез. Оператор γ визначає множину точнісних характеристик $\mathfrak{S}^{|\mathbf{q}|}$, де $q = l^2$ – кількість точнісних характеристик. Оператор ϕ обчислює множину \mathbf{E} значень інформаційного КФЕ навчання, який є функціоналом точнісних характеристик. Оператор r корегує розбиття $\tilde{\mathfrak{R}}^{|\mathbf{M}|}$ залежно від значень КФЕ. За діаграмою (1) оператори контуру



реалізують базовий алгоритм TEACHING [3], який безпосередньо визначає оптимальні значення геометричних параметрів контейнерів шляхом пошуку максимуму КФЕ. Оптимізація контрольних допусків на ознаки розпізнавання здійснюється за ітераційною процедурою, в якій задіяно оператори контуру



а оптимізація рівнів селекції – операторами контуру



Оператор U регламентує процес навчання.

Обчислювальний аспект оптимізації параметрів навчання за МФСВ

Центральною процедурою алгоритму навчання за МФСВ є обчислення інформаційного критерію оптимізації контейнерів класів розпізнавання в ра-

діальному базисі простору ознак. Як критерій оптимізації параметрів навчання може використовуватися одна із статистичних інформаційних мір. Розглянемо як КФЕ навчання, наприклад, модифікацію інформаційної міри за Шенноном [5]:

$$E = 1 + \frac{1}{2} \left(\frac{\alpha}{\alpha + D_2} \log_2 \frac{\alpha}{\alpha + D_2} + \frac{\beta}{D_1 + \beta} \log_2 \frac{\beta}{D_1 + \beta} + \frac{D_1}{D_1 + \beta} \log_2 \frac{D_1}{D_1 + \beta} + \frac{D_2}{\alpha + D_2} \log_2 \frac{D_2}{\alpha + D_2} \right), \quad (2)$$

де D_1, D_2, α, β – точнісні характеристики процесу навчання при двохальтернативній системі оцінок рішень: перша і друга вірогідності, помилки першого та другого роду відповідно.

Обчислення критерію (2) на кожному кроці навчання здійснюється шляхом оцінки відповідних точнісних характеристик: $D_1 = K_1/n$; $\alpha = K_2/n$; $\beta = K_3/n$; $D_2 = K_4/n$, де коефіцієнти K_1, K_2, K_3, K_4 , наприклад, при навчанні розпізнаванню реалізацій класу X_1^o обчислюються за алгоритмом

$$\begin{aligned} & \text{if } x_1^{(j)} \in X_1^o \text{ then } K_1(j) := K_1(j-1) + 1 \\ & \text{else } K_2(j) := K_2(j-1) + 1; \\ & \text{if } x_2^{(j)} \in X_1 \text{ then } K_3(j) := K_3(j-1) + 1 \\ & \text{else } K_4(j) := K_4(j-1) + 1. \end{aligned} \quad (3)$$

Тут $x_2^{(j)}$ – j -а реалізація класу X_2^o , що є сусіднім до класу X_1^o .

За МФСВ оптимізація параметрів навчання здійснюється шляхом багаточиклічної структурованої ітераційної процедури пошуку максимуму інформаційного КФЕ навчання ІСК. При цьому внутрішній цикл оптимізує параметри, які впливають безпосередньо на фенотип класу – геометричні параметри контейнера, а інші цикли оптимізують параметри, які впливають на генотип класу – розподіл реалізацій образу.

Нехай d_1, δ, ρ_1 – параметри оптимізації радіуса контейнера K_1^o класу X_1^o , поля контрольних допусків на ознаки розпізнавання і рівнів селекції координат еталонного вектора класу X_1^o відповідно. Тоді структурований алгоритм оптимізації рівня селекції для класу X_1^o має вигляд

$$\rho_1^* = \langle \mathbf{arg}\{\max_{G_p} \{\max_{G_\delta} \{\max_{G_d} E_1\}\}\} \rangle, \quad (3)$$

де E_1 – значення КФЕ навчання системи розпізнавати реалізації класу X_1^o ; G_p, G_δ, G_d – області допустимих значень відповідних параметрів навчання. Тут параметр поля контрольних допусків δ вибрано однаковим для всіх ознак розпізнавання. Згідно з виразом (3) зовнішній цикл ітераційної процедури оптимізує рівень селекції ρ_1 , а внутрішній цикл – радіус контейнера K_1^o . Отже, за МФСВ редукція, наприклад, гіпотетичного контейнера K_m^o здійснюється шляхом цілеспрямованої трансформації вихідного розподілу реалізацій класу X_m^o і вписування його у сферичний габарит, радіус d_m і центр якого при цьому так само змінюються.

Приклад оптимізації рівнів селекції

Розглянемо задачу оптимізації геометричних параметрів контейнера класу розпізнавання за МФСВ на прикладі автофокусування растрового електронного мікроскопа РЕМ-103 за зображенням зразка, що досліджується. На рис.1,а показано початкове розфокусоване зображення об'єкта «Гратка» (клас X_1^o), а на рис.1,б – зображення цього об'єкта, отриманого після першого кроку настроювання (клас X_2^o).




Рис.1. Зображення об'єкта «Гратка»: а–початкове розфокусоване зображення; б – поточне зображення

У процесі реалізації алгоритму навчання за діаграмою (1) було побудовано оптимальний контейнер K_1^o , який забезпечує максимальну асимптотичну достовірність розпізнавання в режимі екзамену реалізацій класу X_1^o . Результати оптимізації контейнера K_1^o за алгоритмом (3) обчислення КФЕ навчання наведено у таблиці. Тут ρ_1 – значення рівня селекції координат вектора $x_1 \in X_1^o$; δ – параметр контрольного поля допусків; $d_c = d(x_1 \oplus x_2)$ – міжцентрова кодова відстань класів X_1^o і X_2^o ; d_1 – радіус контейнера K_1^o ; E_1 – значення критерію (2). Аналіз таблиці показує, що максимальному значенню критерію E_1 відповідають декілька рівнів селекції. За оптимальне приймається значення $\rho_1^* = 0,48$, яке забезпечує згідно з максимально-дистанційним принципом розпізнавання образів у радіальному базисі максимальну міжцентрову відстань d_c для класів X_1^o і X_2^o . У таблиці при $\rho = 0,4$ робоча область визначення критерію оптимізації відсутня і тому значення величин не наводяться.

Залежність КФЕ (2) від радіуса контейнера класу X_1^o при оптимальному значенні рівня селекції $\rho_1^* = 0,48$ показано на рис. 2, де подвійною штриховкою позначено робочу область визначення інфор-

маційного критерію, в якій вірогідності $D_1, D_2 > 0,5$.

Параметри оптимізації контейнера K_1^o

ρ_1	δ	dc	d_1	E_1	D_1	β
0,40	-	-	-	-	-	-
0,42	13	57	38	0,645	0,76	0,00
0,44	13	60	37	0,645	0,76	0,00
0,46	13	59	35	0,645	0,76	0,00
0,48	13	64	34	0,645	0,76	0,00
0,50	13	58	49	0,605	1,00	0,31
0,52	13	62	48	0,615	1,00	0,29
0,54	14	44	25	0,645	0,76	0,00
0,56	13	66	47	0,621	1,00	0,28
0,58	14	54	25	0,645	0,76	0,00
0,60	13	65	41	0,643	0,99	0,18

При цьому зліва від робочої області перша вірогідність має значення $D_1 \leq 0,5$, а справа – друга вірогід-

ність дорівнює $D_2 \leq 0,5$. Оптимальний радіус d_1^* контейнера K_1^o , як видно з таблиці і рис. 2, дорівнює 34 кодівим одиницям відстані при значенні КФЕ $E_1 = 0,645$.

Особливість модифікації КФЕ за Шенноном полягає в тому, що за відсутності в контейнері K_1^o реалізацій як “свого”, так і “чужого” класів значення критерію $E_1 = 0,5$.

Це має місце, як показано на рис. 2, при $d_1 = 0$, тобто ні одна реалізація класів не збігається з еталонним вектором класу X_1^o , і в контейнерах з малими значеннями радіусів, в яких відсутні реалізації образів. Так само $E_1 = 0,5$ при значеннях $d_1 > d_c$, коли контейнер K_1^o може охоплювати всі реалізації класів X_1^o і X_2^o .




Рис. 2. Залежність КФЕ від радіуса контейнера K_1^o

Перспективи подальших досліджень

Оптимізація рівнів селекції координат еталонних векторів класів розпізнавання при побудові оптимальних контейнерів у радіальному базисі простору ознак поряд з максимізацією середньої міжкласової відстані для заданого алфавіту класів розпізнавання

дозволяє вирішувати проблему центрування контейнерів, яка в рамках МФСВ має як теоретичний, так і методологічний аспекти. Теоретичний аспект цієї проблеми пов'язаний з використанням на практиці навчальних вибірок відносно малого обсягу ($n < 1000$), що обумовлює появу статистичної похибки між емпіричною частотою $\omega_i = n_i/n$ та ймовір-

ністю p_i знаходження значення i -ї ознаки в своєму полі контрольних допусків. Це призводить до того, що вершина еталонного вектора x_m , координати якого визначаються шляхом статистичного усереднення стовпців двійкової навчальної матриці $\|x_{m,i}^{(j)}\|$, не збігається з теоретичним центром розсіювання реалізацій класу X_m^o . Так само перспективним є застосування процедури оптимізації рівнів селекції при формуванні інформативного словника ознак розпізнавання, необхідність якого впливає із принципу редукції [4]. При цьому, якщо в процесі навчання буде визначено оптимальне значення $\rho_m^* < 0,5$, то це може свідчити про виявлення, принаймні, однієї інформативної ознаки, латентність якої полягала саме в низькій частоті її появи. Якщо буде знайдено $\rho_m^* > 0,5$, то це свідчить про негативний вплив на прийняття рішень, по крайній мірі, однієї "заважаючої" ознаки розпізнавання, яка виключається із розгляду. Отже, оптимізація рівнів селекції координат еталонних векторів повинна здійснюватися як обов'язкова процедура розв'язання задачі загального інформаційного синтезу здатних навчатися ІСК.

Підсумок

Застосування МФСВ для розв'язання задачі інформаційного синтезу здатних навчатися ІСК дозволяє оптимізувати в інформаційному розумінні просторово-часові параметри функціонування системи, які забезпечують максимальну асимптотичну достовірність класифікатора за умови перетину класів розпізнавання. У результаті фізичного моделювання процесу багатопараметричної оптимізації параметрів навчання досліджено вплив рівня селекції координат еталонних векторів класів розпізнавання на функціональну ефективність навчання ІСК. При цьому за оптимальне приймається значення

рівня селекції, яке забезпечує глобальний максимум інформаційного КФЕ навчання в робочій області його визначення і максимальну в радіальному базисі міжцентрову відстань сусідніх класів у заданому алфавіті.

Література

1. Турбович И.Т., Гитис В.Г., Маслов В.К. Опознавание образов. Детерминир.-статист. подход.–М.: Наука, 1971.–246 с.
2. Анисимов Б.В., Курганов В.Д., Злобин В.К. Распознавание и цифровая обработка изображений.– М.: Высш. шк. 1983.–256 с.
3. Красноясовський А.С. Оптимізація контейнерів класів розпізнавання за методом функціонально-статистичних випробувань // Автоматизированные системы управления и приборы автоматики.– 2002.–Вып.119.– С. 69–76.
4. Васильев В.И., Суровцев И.В. Индуктивные методы обнаружения закономерностей // Управляющие системы и машины. – 1998.– №5.–С.3–13.
5. Красноясовський А. С., Черниш А. В., Слассушевський О.Ю. Про вибір критерію функціональної ефективності системи розпізнавання, що навчається // Радиоэлектроника и информатика.– 2001.– №4.–С. 121–124.

Надійшла до редакції 18.03.03

Рецензенти: д-р техн. наук, професор Кулик А.С., Національний аерокосмічний університет ім. М.С. Жуковського "ХАІ", м. Харків; канд. техн. наук, доцент Боровик В.О., Сумський Державний університет, м. Суми.