

УДК 681.518 004.93.1

І.В. ШЕЛЕХОВ

Сумський державний університет, Україна

ПІДВИЩЕННЯ ОПЕРАТИВНОСТІ НАВЧАННЯ СИСТЕМИ КЕРУВАННЯ ЗА МЕТОДОМ ФУНКЦІОНАЛЬНО-СТАТИСТИЧНИХ ВИПРОБУВАНЬ

Проведено аналіз шляхів підвищення оперативності етапу навчання системи керування за методом функціонально статистичних випробувань. Досліджено тенденцію зміни параметрів навчання в процесі оптимізації при різних модифікаціях методу та вплив просторових обмежень на кількість ітерацій оптимізації. Підвищення оперативності алгоритму ілюструється на прикладі автофокусування електронного мікроскопа за зображеннями зразка, що досліджується.

навчання, оптимізація, оперативність, параметри функціонування, метод функціонально-статистичних випробувань, критерій функціональної ефективності

Важливе питання релевантності знань систем керування (СК), що навчається, часто недооцінюється при створенні даних систем. Найбільшою проблемою, яка пов'язана з цим, є врахування характеристик, що змінюються з часом. Вимоги до характеристик найбільш бажаного класу стають суворішими, змінюються повністю чи частково, зменшуючи ефективність функціонування СК в цілому. Для багатьох СК єдиним способом вирішення даної проблеми є періодичне перенавчання на основі нової інформації [1 – 4]. При цьому мають місце суттєві витрати, пов'язані із залученням експертів на час перенавчання та зупинкою технологічного керованого процесу.

Одним з перспективних методів автоматичної класифікації є інформаційно-екстремальний метод функціонально-статистичних випробувань (МФСВ), який дозволяє оптимізувати за інформаційним критерієм функціональної ефективності (КФЕ) просторово-часові параметри функціонування СК, що навчаються, за умов апріорної невизначеності, інформаційних і ресурсних обмежень [5]. Якщо реалізація алгоритму екзамену за МФСВ здійснюється в реальному темпі часу, завдяки використанню в радіальному базисі відносно простих функцій належності для формування чітких керуючих висловлювань,

то оперативність алгоритмів навчання змінюється у відносно широкому інтервалі часу залежно від повноти структури параметрів навчання, способу реалізації та типів самих алгоритмів навчання. Розглянуті в працях [5 – 7] алгоритми навчання в рамках МФСВ орієнтовані на реалізацію прямого методу пошуку глобального максимуму інформаційного КФЕ в робочій області визначення його функції, що може на практиці не відповідати існуючим для СК часовим обмеженням. Тому підвищення оперативності реалізації алгоритмів навчання в рамках МФСВ є актуальною задачею, дослідженню якої присвячена дана стаття.

Розв'язання цієї задачі щодо алгоритмів навчання в рамках МФСВ досягається двома шляхами:

- пошук меж робочої області визначення функції інформаційного КФЕ навчання СК шляхом застосування алгоритмів оптимізації параметрів навчання із змінним кроком ітерації;
- застосування оперативних алгоритмів пошуку глобального максимуму функції інформаційного КФЕ навчання безпосередньо в робочій області її визначення.

Задача підвищення оперативності навчання (перенавчання) в рамках МФСВ зводиться до мінімізації кількості ітерацій оптимізації параметрів навчання.

ня. Найбільшу кількість ітерацій мають алгоритми навчання, що реалізують, крім базового алгоритму, оптимізацію системи контрольних допусків (СКД) на ознаки розпізнавання (ОР) за послідовним алгоритмом [7].

Кількість ітерацій N_s для даного випадку можна оцінити так:

$$N_s = N_{SKD} \cdot N_D \cdot m \cdot \sum_{i=1}^N \frac{VD_i - ND_i}{2 \cdot st_i},$$

де N_D – кількість кроків оптимізації радіуса контейнера класу;

N – потужність словника ОР;

m – кількість класів;

VD_i, ND_i – верхній і нижній допуск на i -ту ОР;

st_i – крок оптимізації верхнього і нижнього допуску на i -ту ОР;

N_{SKD} – кількість проходів при оптимізації СКД в цілому.

Якщо на підготовчому етапі використовувати паралельний алгоритм оптимізації СКД, то кількість ітерацій N_{s+p} дорівнює:

$$N_{s+p} = N_s + N_D \cdot m \cdot \frac{VD_g - ND_g}{2 \cdot st_g},$$

де N_D – кількість кроків оптимізації радіуса контейнера класу;

N – потужність словника ОР;

m – кількість класів;

VD_g, ND_g – верхній і нижній допуск на ОР по зведеної шкалі;

st_g – крок оптимізації верхнього і нижнього допуску ОР за зведеною шкалою.

Оцінку кількості ітерацій оптимізації розглянемо на прикладі автофокусування електронного мікроскопа за зображеннями зразка, що досліджується. Процес автофокусування здійснюється шляхом побудови контейнерів класів розпізнавання, навчальні матриці яких подані у вигляді зображень, наприклад, розміром 100×100 і обчислення значень КФЕ, що є мірою різноманітності цих зображень. Виходячи з припущення, що яскравість кожного пікселя зображення може приймати значення від 0 до 255, крок оптимізації дорівнює 1, а кількість кроків оптимізації радіуса контейнера класу максимальна ($N_D = N$), верхня межа кількості ітерацій дорівнює $N_s = N_{SKD} \cdot 2 \cdot 560 \cdot 000$.

З метою зниження кількості ітерацій оптимізації вводяться такі умови нечіткого розбиття простору ОР:

$$\left(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|} \right) \left(\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|} \right) [X_k^o \neq X_l^o \rightarrow (d_k^* < d(x_k \oplus x_l)) \& (d_l^* < d(x_k \oplus x_l))], \quad (1)$$

де $\tilde{\mathfrak{R}}^{|M|}$ – розбиття простору ОР;

X_k^o, X_l^o – класи розпізнавання;

d_k^*, d_l^* – радіуси контейнерів відповідних класів розпізнавання;

$d(x_k \oplus x_l)$ – кодова відстань між центрами відповідних класів;

x_k, x_l – еталонні вектори – реалізації класів, вершини яких визначають центри відповідних контейнерів.

У цьому випадку кількість кроків оптимізації радіуса контейнера зменшується з максимально можливою до кількості, що обмежується міжцентровою відстанню:

$$N_D = d(x_k \oplus x_l) \leq N.$$

Зрозуміло, що дане обмеження є досить умовним і може вважатися суттєвим тільки для випадку, коли міжцентрова кодова відстань набагато менша за кількість ознак N .

Проаналізуємо процес навчання на прикладі побудови оптимальних контейнерів в процесі автофокусування електронного мікроскопа за стаціонарними за яскравістю зображеннями зразку типу «Гратка», наведених на рис. 1. На рис. 1 а показано початкове зображення (клас X_1^o), а на рис. 1, б – поточне зображення (клас X_2^o).




Рис. 1. Навчальні матриці двох класів розпізнавання:
а – початкове (розфокусоване) зображення;
б – поточне зображення

Як КФЕ розглянемо ентропійний критерій Шеннона для двохальтернативного рішення при рівномірних гіпотезах [5]:

$$E_m^{(k)} = 1 + \frac{1}{2} \left(\frac{\alpha_m^{(k)}}{\alpha_m^{(k)} + D_{2,m}^{(k)}} \log_2 \frac{\alpha_m^{(k)}}{\alpha_m^{(k)} + D_{2,m}^{(k)}} + \frac{D_{1,m}^{(k)}}{D_{1,m}^{(k)} + \beta_m^{(k)}} \log_2 \frac{D_{1,m}^{(k)}}{D_{1,m}^{(k)} + \beta_m^{(k)}} + \frac{\beta_m^{(k)}}{D_{1,m}^{(k)} + \beta_m^{(k)}} \log_2 \frac{\beta_m^{(k)}}{D_{1,m}^{(k)} + \beta_m^{(k)}} + \frac{D_{2,m}^{(k)}}{\alpha_m^{(k)} + D_{2,m}^{(k)}} \log_2 \frac{D_{2,m}^{(k)}}{\alpha_m^{(k)} + D_{2,m}^{(k)}} \right), \quad (2)$$

де $D_{1,m}^{(k)}, D_{2,m}^{(k)}, \alpha_m^{(k)}, \beta_m^{(k)}$ – одержані на k -у кроці навчання точнісні характеристики: перша та друга достовірності, помилки першого та другого роду відповідно.

При цьому структурований алгоритм послідовної оптимізації СКД подається у вигляді:

$$\{\delta_{K,i}^*\} = \left\langle \arg \left\{ \max_{G_{\delta_i}} \left[\max_{G_E} \left[\bigotimes_{l=1}^{N_{SKD}} \max_{G_{d_1}} E_1^{(l)} \right] \right] \right\} \right\rangle, \quad (3)$$

$i = \overline{1, N}$,

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

\otimes – символ операції повторення;

N_{SKD} – кількість проходів процедури оптимізації СКД.

Якщо вектор g параметрів функціонування, у загальному випадку, має таку структуру:

$$g = \langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}, f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle, \quad \Xi_1 + \Xi_2 = \Xi,$$

де $\langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1} \rangle$ – генотипні параметри функціонування нечіткого регулятора, які впливають на параметри розподілу реалізацій образу;

$\langle f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle$ – фенотипні параметри функціонування нечіткого регулятора, які прямо впливають на геометрію контейнера класу розпізнавання, і відомі обмеження на відповідні параметри функціонування:

$$R_{\xi_1}(g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}) \leq 0;$$

$$R_{\xi_2}(f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2}) \leq 0,$$

то, у загальному випадку ($M > 2$), алгоритм навчання за МФСВ полягає в реалізації багатоциклічної ітераційної процедури оптимізації структурованих параметрів функціонування СК шляхом пошуку глобального максимуму усередненого для всіх класів розпізнавання значення КФЕ навчання в робочій області визначення його функції. Подамо його у такій тестовій формі:

$$\begin{aligned} & (\forall g_{\xi_1} \in g) (\forall f_{\xi_2} \in g) (\exists g_{\xi_1} \in G_{\xi_1}) \{ \text{if } \bar{E} = \max_{G_E} E^* \\ & \text{then } g_{\xi_1}^* = \arg \left\langle \left[\max_{G_{\xi_1}} \left[\left[\max_{G_1} \left[\left[\max_{F_{\xi_2}} \left[\left[\max_{F_1} \bar{E} \right] \dots \right] \right] \right] \right] \right] \right] \right\rangle \quad (4) \\ & \text{else (if } \xi_1 \leq \Xi_1 \text{ then } \xi_1 = \xi_1 + 1 \text{ else STOP) \}, \\ & \xi_1 = \overline{1, \Xi_1}, \xi_2 = \overline{1, \Xi_2}, \end{aligned}$$

де G_E – область значень функції інформаційного КФЕ навчання;

$$\bar{E} = \frac{1}{M} \sum_{m=1}^M E_m$$

– усереднене значення КФЕ навчання СК;

$g_{\xi_1}^*$ – оптимальне значення параметра навчання,

яке визначається у зовнішньому циклі ітераційної процедури оптимізації;

$G_{\xi_1}, \dots, G_1; F_{\xi_2}, \dots, F_1$ – області допустимих значень генотипних і фенотипних параметрів навчання.

Тут E_m – інформаційний КФЕ навчання СК розпізнавати реалізації класу X_m^o .

Критерієм припинення ітераційного процесу за послідовним алгоритмом оптимізації є збіг параметрів навчання систем керування після послідовних проходів оптимізації системи контрольних допусків в цілому.

У табл. 1 подано динаміку зміни параметрів навчання СК. Нульовою ітерацією ($k_{SKD} = 0$) є знаходження стартової СКД за паралельним алгоритмом, при якому контрольні допуски змінюються для ОР одночасно на однакове значення.


Таблиця 1

Значення параметрів навчання СК після відповідного проходу при оптимізації СКД в цілому


| k_{SKD} | Клас X_1^o | | | | Клас X_2^o | | | | $d(x_1 \oplus x_2)$ |
|-----------|--------------|---------|------|---------|--------------|---------|------|---------|---------------------|
| | E_1^* | d_1^* | D1 | β | E_2^* | d_2^* | D1 | β | |
| 0 | 0,62106 | 30 | 0,72 | 0 | 0,68785 | 44 | 0,89 | 0,02 | 61 |
| 1 | 0,68325 | 32 | 0,81 | 0 | 0,88240 | 40 | 0,96 | 0 | 57 |
| 2 | 0,70102 | 28 | 0,83 | 0 | 0,90500 | 32 | 0,97 | 0 | 47 |
| 3 | 0,70102 | 27 | 0,83 | 0 | 0,93038 | 31 | 0,98 | 0 | 46 |
| 4 | 0,72069 | 23 | 0,85 | 0 | 1 | 27 | 1 | 0 | 40 |
| 5 | 0,79442 | 22 | 0,91 | 0 | 1 | 21 | 1 | 0 | 33 |
| 6 | 0,84309 | 22 | 0,94 | 0 | 1 | 21 | 1 | 0 | 34 |
| 7 | 0,88240 | 22 | 0,96 | 0 | 1 | 21 | 1 | 0 | 34 |
| 8 | 1 | 21 | 1 | 0 | 1 | 20 | 1 | 0 | 34 |
| 9 | 1 | 18 | 1 | 0 | 1 | 16 | 1 | 0 | 30 |
| 10 | 1 | 16 | 1 | 0 | 1 | 14 | 1 | 0 | 27 |
| 11 | 1 | 16 | 1 | 0 | 1 | 14 | 1 | 0 | 27 |

У результаті оптимізації були отримані параметри навчання, що дозволяють безпомилково визнача-

ти належність невідомих реалізацій на етапі екзаме- ну, що ілюструється рис. 2.



а



б

Рис. 2. Оптимізація радіуса контейнера класу X_1^o із зазначенням міжцентрової кодової відстані: а – після паралельної оптимізації СКД; б – після послідовної оптимізації СКД

Аналіз рис. 2 показує, що при проведенні паралельної оптимізації системи контрольних допусків глобальний максимум нормованого КФЕ не досягає

максимального значення в робочій області визначення його функції (на рисунках робочу область виділено штриховкою).

Як видно з табл. 1 за 11 кроків навчання за послідовним алгоритмом оптимізації СКД (3) досягається максимальне граничне значення КФЕ, що свідчить про досягнення мети навчання СК – побудову чіткого розбиття класів.

Оперативність знаходження даного результату можна оцінити через кількість ітерацій N_{s+p} , яка дорівнює 22 183 524 при $N_D = N$ та скорочується до 8 387 344 при використанні обмеження (1). Це досить суттєве зменшення можна пояснити специфікою даних навчальної матриці, які були сформовані з зображень одного об'єкту для випадків різних ступенів сфокусованості електронного мікроскопу. Тому вже після нульової ітерації центри контейнерів класів розпізнавання (табл. 1) знаходяться на кодовій відстані 61 один від одного, тоді як максимальна можлива відстань дорівнює 100. Крім того в процесі оптимізації міжцентрова відстань зменшується до 27.

Слід зазначити що, крім зменшення міжцентрової відстані зменшується так само і робоча (заштрихована) область, що показано на рис. 3. Назаль межі робочої області визначаються в процесі оптимізації на кожній ітерації, що не дозволяє обчислити міні-

мальну кількість кроків обчислення КФЕ. Але аналіз тенденції зміни її параметрів дозволяє встановити такі додаткові обмеження на область пошуку оптимальних параметрів контейнерів класів навчання:

1) оскільки верхня межа робочої області не зростає в процесі оптимізації параметрів навчання, то її значення на попередній ітерації можна використовувати як кінцеве значення на наступній ітерації при оптимізації радіусів контейнерів класів навчання замість міжцентрової відстані;

2) на початку оптимізації кількість ітерацій, що відповідають області від центру контейнера поточного класу до нижньої межі, складає досить вагому частину від загальної кількості ітерацій. Це вказує на необхідність зміни напрямку ітераційного процесу: замість збільшення значення радіуса від нуля до верхньої межі, слід зменшувати його значення від верхньої межі до моменту виходу з робочої області.

Введення наведених вище обмежень дозволило скоротити кількість ітерацій до 3 306 229, що відповідає приблизно кількості ітерацій, які виконуються під час одного-двох проходів при оптимізації СКД без врахування цих обмежень.

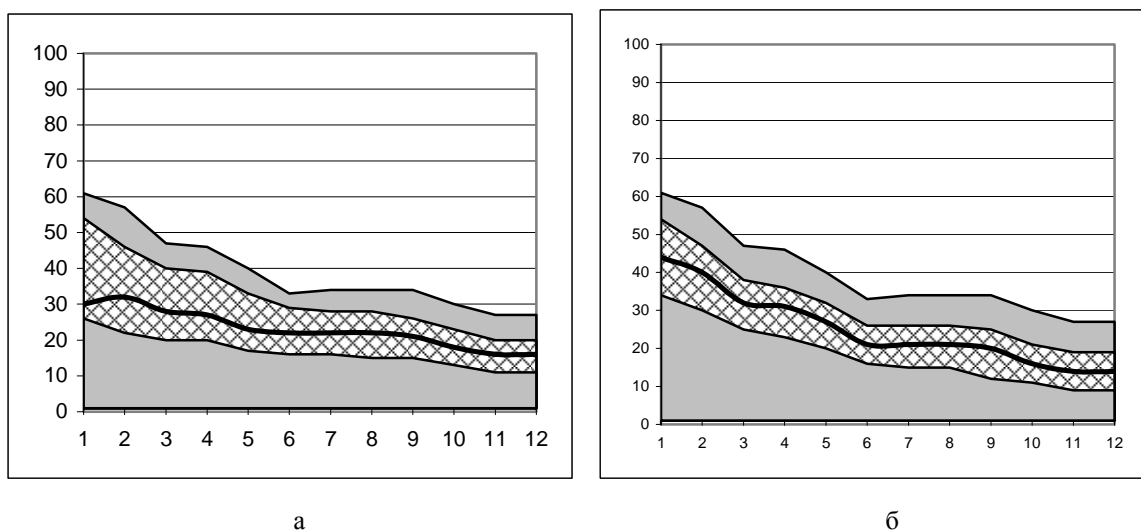


Рис. 3. Динаміка зміни радіусів контейнерів класів навчання та параметрів робочої області після кожного проходу при оптимізації СКД: а – для класу X_1^0 ; б – для класу X_2^0

Висновки

1. Запропонований у статті підхід до підвищення оперативності алгоритму навчання в рамках МФСВ дозволяє суттєво зменшити кількість кроків ітерації, наприклад, при оптимізації контрольних допусків на ознаки розпізнавання шляхом введення на них відповідних обмежень, що враховують виявлені тенденції зміни значень параметрів навчання системи.

2. Рекомендується з метою підвищення загальної оперативності процесу навчання перед реалізацією послідовного алгоритму запускати паралельний алгоритм, який хоч і не забезпечує побудови безпомилкових за навчальною вибіркою вирішальних правил, але дозволяє визначити стартові значення контрольних допусків.

Застосування одержаних результатів може бути перспективним при розробці інформаційного та алгоритмічного забезпечення інтелектуальних систем керування різними технологічними процесами, наприклад, в нафтохімічній і металургійній промисловості, що дозволить підвищити точність і оперативність керування при одночасному збереженні енергоресурсів.

Література

1. William Donald Smart. Making Reinforcement Learning Work on Real Robots. – 2002. – 165 p.

2. Shakhrovich G., Viola P.A., Moghaddam B. A unified learning framework for real-time face detection and classification // Automatic Face and Gesture Recognition, 2002. Proceedings. Fifth IEEE International Conference on 20-21 May 2002., – P. 14-21.

3. Anil K. Jain. Real-Time Object Measurement and Classification. – Springer-Verlag, 1988. – 407 p.

4. Alexios Chouchoulas Incremental Feature Selection Based on Rough Set Theory, 2001. – 51 p.

5. Краснопоясовський А.С. Інформаційний синтез інтелектуальних систем керування: Підхід, що ґрунтується на методі функціонально-статистичних випробувань. – Суми: Видавництво СумДУ, 2004. – 261 с.

6. Краснопоясовський А.С. Оптимізація контрольних допусків на ознаки розпізнавання за методом функціонально-статистичних випробувань // Штучний інтелект. – 2003. – № 1. – С. 53-61.

7. Краснопоясовський А.С., Кий О.М., Волков В.М., Козинець М.В., Шелехов І.В. Класифікаційне управління технологічним процесом виробництва складних мінеральних добрив // Східно-Європейський журнал передових технологій. – 2003. – № 6. – С. 12-17.

Надійшла до редакції 7.06.2006

Рецензент: д-р техн. наук, проф. О.Ю. Соколов, Національний аерокосмічний університет ім. М.С. Жуковського «ХАІ», Харків.