

ОПТИМІЗАЦІЯ ПАРАМЕТРІВ ПЛАНУ НАВЧАННЯ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ

А.С. Довбиш, В.А. Тронь
Сумський державний університет

Розглядається у рамках інформаційно-екстремальної інтелектуальної технології оптимізація рецепторного поля зображень та формування ієрархічної структури вхідних образів, що дозволило підвищити у режимі екзамену системи підтримки прийняття рішень достовірність та оперативність розпізнавання.

Незважаючи на те що параметри плану навчання системи прийняття рішень впливають на функціональну ефективність системи, питання їх оптимізації ще недостатньо висвітлюється в науково-технічній літературі. Одну з перших постановок оптимізації параметрів плану навчання подано у праці [1], де розв'язання задачі здійснюється шляхом пошуку оптимального шляху в орієнтованому графі за методом дерева рішень. Застосування такого підходу до розв'язання задачі оптимізації параметрів плану навчання для систем розпізнавання образів ускладнене значним впливом суб'єктивного фактору, пов'язаним з формуванням трафіка мережі в методах, що використовують дерево рішень. Для розв'язання цієї задачі перспективним є використання ідей та методів інформаційно-екстремальної інтелектуальної технології (ІЕІТ) аналізу та синтезу систем прийняття рішень, що навчаються [2]. Основною перевагою методів оптимізації параметрів плану навчання у рамках ІЕІТ є можливість кількісного оцінювання впливу структури та потужності вхідного математичного опису на функціональну ефективність системи, що навчається.

У статті розглядаються питання оптимізації рецепторного поля зображень та формування ієрархічної структури вхідних образів, що визначає послідовність оброблення образів у процесі навчання.

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, що у загальному випадку можуть перетинатися, і стаціонарну матрицю яскравості $\|y_{m,i}^{(j)}\|$, $i = \overline{1, N}$, $j = \overline{1, n}$, де N , n – кількість ознак розпізнавання і реалізацій образу відповідно. Відомо вектор-кортеж просторово-часових параметрів функціонування системи підтримки прийняття рішень (СППР), 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 СППР оптимізувати такі параметри плану навчання, як крок квантування τ вектора реалізації зображення, структурованість s та узгодженість u ієрархічної структури 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 $(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|}) (\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}) [X_k^o \neq X_l^o \rightarrow (d_k^* < d(x_k \oplus x_l)) \& (d_l^* < d(x_k \oplus x_l))]$,
- 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 плану навчання СППР передбачає побудову ієрархічної структури класів розпізнавання та оптимізацію рецепторного поля зображень, що забезпечує виконання умови (1)

МАТЕМАТИЧНА МОДЕЛЬ

Розглянемо категорійну модель оптимізації параметрів плану навчання СППР, що передбачає вхідний математичний опис:

$$\Delta_B = \langle G, T, Z, \Omega, Y; F \rangle,$$

де G – простір факторів, що впливають на СППР; T – множина моментів часу зняття інформації; Z – простір можливих станів системи контролю; Ω – простір ознак розпізнавання; Y – множина сигналів, що знімаються з виходу блока первинної обробки інформації СППР і утворюють вхідну навчальну матрицю; $F: G \times T \times Z \times \Omega \rightarrow Y$ – оператор формування вибіркової множини Y ;

Категорійна модель оптимізації параметрів плану навчання у вигляді діаграми відображення множин наведена на рис.1.





Рисунок 1 – Категорійна модель оптимізації параметрів плану навчання

Показаний на рис. 1 оператор $\theta: X \rightarrow \tilde{\mathfrak{R}}^{|M|}$ відновлює на кожному кроці навчання у загальному випадку нечітке розбиття $\tilde{\mathfrak{R}}^{|M|}$. Базовий алгоритм навчання LEARNING реалізується послідовно оператором класифікації $\Psi: \tilde{\mathfrak{R}}^{|M|} \rightarrow I^{|l|}$, що перевіряє основну статистичну гіпотезу $\gamma_1: y_{m,i}^{(j)} \in X_m^o$, де $I^{|l|}$ – множина статистичних гіпотез, оператором γ , що визначає множину точнісних характеристик процесу навчання $\mathfrak{S}^{|q|}$, де

$q = l^2$, оператором φ , що обчислює терм-множину E значень інформаційного критерію оптимізації, і оператором r , що корегує розбиття $\tilde{\mathfrak{A}}^{|M|}$ шляхом ітераційного пошуку глобального максимуму критерію (1) у робочій області визначення його функції. Контур оптимізації контрольних допусків мистить множину D – систему контрольних допусків на ознаки розпізнавання. У діаграмі оператори контура



оптимізують рецепторне поле зображення, що характеризується множиною ознак R . Оператор $U: E \rightarrow G \times T \times \Omega \times Z \times V$ регламентує процес навчання і дозволяє оптимізувати параметри його плану, що визначають обсяг і структуру випробовувань, черговість розгляду класів розпізнавання та інше.

КРИТЕРІЙ ОПТИМІЗАЦІЇ

Як критерій оптимізації параметрів плану навчання СППР розглянемо модифікацію ентропійного інформаційного КФЕ за Шенноном для двохальтернативного розв'язання при рівноймовірних гіпотезах за формулою [2]

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

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

При обмеженому обсязі навчальних вибірок слід користуватися оцінками точнісних характеристик, що обчислюються на k -му кроці відновлення контейнерів класів розпізнавання:

$$D_1^{(k)} = \frac{K_1^{(k)}}{n_{\min}}; \quad \alpha^{(k)} = \frac{K_2^{(k)}}{n_{\min}}; \quad \beta^{(k)} = \frac{K_3^{(k)}}{n_{\min}}; \quad D_2^{(k)} = \frac{K_4^{(k)}}{n_{\min}}, \quad (3)$$

де $K_1^{(k)}$, $K_2^{(k)}$ – кількість подій, що означають відповідно належність та неналежність реалізацій образу контейнера $K_{1,k}^o$, якщо дійсно $\{x_1^{(j)}\} \in X_1^o$; $K_3^{(k)}$, $K_4^{(k)}$ – кількість подій, що означають відповідно належність і неналежність реалізацій контейнеру $K_{1,k}^o$, якщо вони дійсно належать класу X_2^o ; n_{\min} – мінімальний обсяг репрезентативної навчальної вибірки.

Після підстановки відповідних позначень (3) в (2) робоча формула для обчислення ентропійного КФЕ навчання СППР розпізнавання реалізацій, наприклад, класу X_1^o набуває вигляду

$$E_1^{(k)} = 1 + \frac{1}{2} \left(\frac{K_1^{(k)}}{K_1^{(k)} + K_3^{(k)}} \log_2 \frac{K_1^{(k)}}{K_1^{(k)} + K_3^{(k)}} + \frac{K_2^{(k)}}{K_2^{(k)} + K_4^{(k)}} \log_2 \frac{K_2^{(k)}}{K_2^{(k)} + K_4^{(k)}} + \frac{K_3^{(k)}}{K_1^{(k)} + K_3^{(k)}} \log_2 \frac{K_3}{K_1^{(k)} + K_3^{(k)}} + \frac{K_4^{(k)}}{K_2^{(k)} + K_4^{(k)}} \log_2 \frac{K_4^{(k)}}{K_2^{(k)} + K_4^{(k)}} \right). \quad (4)$$

Таким чином, оцінка функціональної ефективності навчання СППР зводиться до визначення на кожному кроці навчання коефіцієнтів $K_1^{(k)}$, $K_2^{(k)}$, $K_3^{(k)}$ і $K_4^{(k)}$ і обчислення КФЕ за формулою (4) при забезпеченні репрезентативності навчальної вибірки ($n = n_{\min}$).

АЛГОРИТМ ОПТИМІЗАЦІЇ ПАРАМЕТРІВ ПЛАНУ НАВЧАННЯ

Оптимізацію параметрів плану навчання СППР обмежимо розв'язанням двох задач:

- побудова ієрархічної структури образів, що визначає послідовність їх подання для навчання;
- оптимізація рецепторного поля морфологічних зображень тканин, що визначає потужність словника ознак.

Вхідними даними для розв'язання першої задачі є сформовані за результатами гістологічного аналізу бінарні навчальні матриці типу «об'єкт – властивість» для класів розпізнавання двох типів, що характеризують відповідно вісім доброякісних патологій та п'ять злоякісних. На рис. 2 показано ієрархічну структуру образів, що складається з двох рівнів. На першому рівні ієрархічної структури розміщують два класи $X_1^{(1)}$ і $X_2^{(1)}$, які є найближчими серед класів різних типів. Нехай клас $X_1^{(1)}$ характеризує доброякісну пухлину, а клас $X_2^{(1)}$ характеризує злоякісну пухлину. Визначення таких найближчих класів здійснювалося за критерієм мінімальної кодової відстані між класами різних типів. Класи другого рівня поділяють на дві страти (групи) – доброякісні та злоякісні. Класи другого рівня ранжуються за збільшенням кодової відстані від еталонного вектора-реалізації контрольного класу $X_{1,1}^{(2)}$, що характеризує здорову тканину. Таким чином, клас верхнього рівня $X_1^{(1)}$ збігається з класом $X_{1,8}^{(2)}$, а клас $X_2^{(1)}$ – з класом $X_{2,5}^{(2)}$.




Рисунок 2 – Ієрархічна структура алфавіту класів навчання

Показані на рис. 2 класи характеризують такі патології:
 1) мезоплазію, 2) фіброаденому перинакалікулярну проліферативну,
 3) фіброаденому інтраканікулярну, 4) фіброаденому філоїдну,

5) фібroadеному перинакалікулярну непроліферативну, 6) фібroadематоз протоковий; 7) фібroadеноматоз непроліферативний; 8) фібroadеноматоз фіброїдний.

Злоякісні пухлини 1) інфільтруюча протокова карцинома I ступеня злоякості; 2) інфільтруюча протокова карцинома II ступеня злоякості; 3) інфільтруюча протокова карцинома III ступеня злоякості; 4) інфільтруючий протоковий рак комедокарцинома; 5) папілярний рак.

Таким чином, алгоритм навчання починається з навчання СППР розпізнавати класи першого рівня, а потім класи, що входять в кожну із страт нижнього рівня. Якщо класи другого рівня мають підкласи, що утворюють відносно нього страти нижнього рівня, то план навчання аналогічно продовжується далі.

Для підвищення достовірності розпізнавання реалізацій образу в СППР режим екзамену здійснюється у два етапи. На першому етапі розпізнається клас за гістологічною навчальною матрицею, а на другому етапі оцінюється належність морфологічного зображення тканини пацієнта, одержаної за методом біопсії, до еталонного зображення діагностованого класу. Якщо така належність морфологічного зображення тканини підтверджується, то встановлюється остаточний діагноз. Якщо не підтверджується, то проводиться додаткове обстеження пацієнта. При цьому актуальною є задача вибору розміру рецепторного поля зображення, що впливає на достовірність рішень на екзамені.

За початкове рецепторне поле вибирався розмір екрана монітора 1024x768 пікселів. У процесі оптимізації його розміру здійснювалося послідовне стискання зображення, а відповідно і його навчальної матриці яскравості, з кроком у один, два і три пікселі.

Розглянемо кроки реалізації алгоритму:

- 1 Надаємо значенню рецепторного поля початкового значення $T:=0$.
- 2 Збільшуємо значення лічильника: $T:=T+1$.
- 3 Запускаємо базовий алгоритм навчання LEARNING [3], який на виході дасть значення КФЕ.
- 4 Виконуємо порівняння: якщо $T<3$, то виконуємо крок 2, інакше – крок 5.
- 5 Знаходимо максимальне значення КФЕ в робочій області визначення його функції.
- 6 Повертаємо результат: максимальне значення КФЕ і значення T , при якому воно знайдене.

ПРИКЛАД РЕАЛІЗАЦІЇ АЛГОРИТМУ ОПТИМІЗАЦІЇ ПАРАМЕТРІВ ПЛАНУ НАВЧАННЯ

Як приклад реалізації вищевказаного алгоритму оптимізації параметрів плану навчання у рамках ІЕІТ розглядалася оптимізація за критерієм (4) рецепторного поля морфологічних зображень тканин при діагностуванні раку молочної залози, одержаних за методом біопсії на кафедрі патанатомії медичного інституту Сумського державного університету (завідувач кафедри д-р мед. наук, професор А.М. Романюк). Як параметр оптимізації рецепторного поля τ розглядався крок стиснення двох зображень, що характеризували класи $X_1^{(1)}$ і $X_2^{(1)}$ першого рівня ієрархічної структури заданого алфавіту класів розпізнавання (рис. 2). На рис. 3 і рис. 4 показано графіки залежності ентропійного критерію (4) від радіусів контейнерів відповідних класів при реалізації базового алгоритму навчання LEARNING для початкового рецепторного поля ($\tau=0$ пікселів). На цих рисунках подвійним штрихуванням позначено робочу область визначення функції КФЕ (4), в якій здійснюється за алгоритмом LEARNING пошук його глобального максимуму.




Рисунок 3 – Графік залежності КФЕ від радіуса контейнера класу $X_1^{(1)}$ ($\tau = 0$)

Аналіз рис. 3 показує, що оптимальне значення радіуса контейнера класу $X_1^{(1)}$ дорівнює $d_1^* = 108$ (у кодівих одиницях) при максимальному значенні критерію $E_1^* = 0,58$




Рисунок 4 – Графік залежності КФЕ від радіуса контейнера класу $X_2^{(1)}$ ($\tau = 0$)

На рис. 4 оптимальне значення радіуса контейнера класу $X_2^{(1)}$ дорівнює $d_2^* = 77$ при максимальному значенні критерію $E_2^* = 0,64$. Таким чином, середнє значення максимумів КФЕ для цих класів дорівнює $\bar{E}^* = 0,61$.

На рис. 5 і рис. 6 наведено графіки залежності критерію (4) від радіусів контейнерів класів $X_1^{(1)}$ і $X_2^{(1)}$ при реалізації базового алгоритму навчання LEARNING для рецепторного поля з кроком стиснення $\tau = 1$ піксель.




Рисунок 5 – Графік залежності КФЕ від радіуса контейнера класу $X_1^{(1)}$ ($\tau = 1$)

Аналіз рис. 5 показує, що при стисненні рецепторного поля через один піксель оптимальне значення радіуса контейнера $X_1^{(1)}$ дорівнює $d_1^* = 42$, а максимальне значення критерію оптимізації – $E_1^* = 0,75$.




Рисунок 6 – Графік залежності КФЕ від радіуса контейнера класу $X_2^{(1)}$ ($\tau = 1$)

Як бачимо з рис. 6, оптимальне значення радіуса контейнера класу $X_2^{(1)}$ при $\tau = 1$ дорівнює $d_2^* = 56$ при $E_2^* = 0,79$. При цьому середнє значення КФЕ при $\tau = 1$ дорівнює $\bar{E}^* = 0,77$.

На рис.7 і рис. 8. показано графіки залежності ентропійного критерію (4) від радіусів контейнерів класів $X_1^{(1)}$ і $X_2^{(1)}$, одержані при наступному кроці стиснення рецепторного поля ($\tau = 2$).




Рисунок 7 – Графік залежності KФЕ від радіуса контейнера класу $X_1^{(1)}$ ($\tau = 2$)

Аналіз рис. 7 показує, що при стисненні рецепторного поля через два пікселі оптимальне значення радіуса контейнера $X_1^{(1)}$ дорівнює $d_1^* = 34$, а значення критерію оптимізації – $E_1^* = 0,55$.

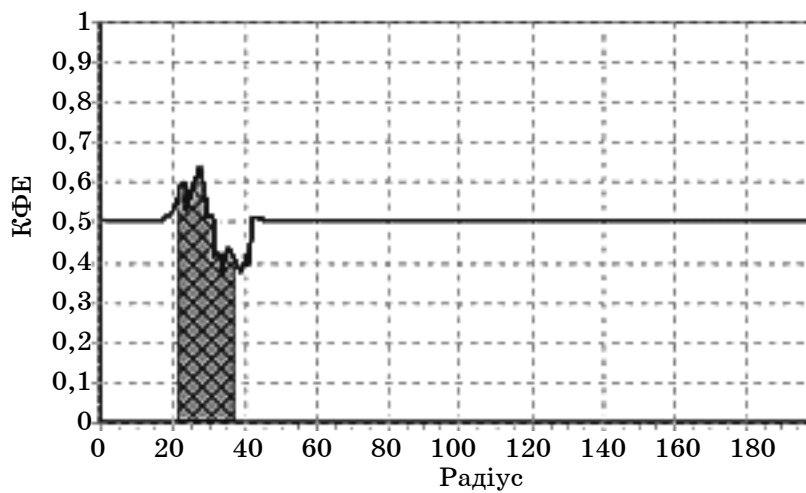


Рисунок 8 – Графік залежності KФЕ від радіуса контейнера класу $X_2^{(1)}$ ($\tau = 2$)

Як показано на рис. 8, при стисненні рецепторного поля через два пікселі оптимальне значення радіуса контейнера $X_2^{(1)}$ дорівнює $d_2^* = 28$,

а значення критерію оптимізації – $E_2^* = 0,65$. При цьому усереднене значення критерію дорівнює $\bar{E} = 0,6$.

Таким чином, аналізуючи вищенаведені графіки, можна зробити висновок, що максимальне значення КФЕ досягається на другому кроці оптимізації рецепторного поля, тобто при зчитуванні матриці яскравості через один піксель ($\tau^* = 1$). Пояснення цього феномена полягає в тому, що саме на цьому кроці оптимізації рецепторного поля вилучається найбільша кількість неінформативних і “заважаючих” ознак розпізнавання. Це призвело до збільшення інформаційного КФЕ навчання СППР, що є мірою різноманітності класів $X_1^{(1)}$ і $X_2^{(1)}$. При цьому за теоремою Шеннона-Котельникова [4] повинна виконуватися умова $\tau^* \leq \left(\Delta t = \frac{\pi}{\omega_{zp}} \right)$, де ω_{zp} – гранична частота спектра сигналу.

ВИСНОВКИ

2 Розроблене інформаційне і програмне забезпечення системи розпізнавання за апріорно класифікованою навчальною матрицею в рамках ІЕІТ дозволяє визначити оптимальне в інформаційному розумінні рецепторне поле зображень, що забезпечує підвищення достовірності та оперативності розпізнавання зображень через вилучення неінформативних та “заважаючих” ознак розпізнавання.

3 Використання ієрархічної структури образів, побудованої за дистанційним критерієм міжцентрової кодової відстані для класів розпізнавання, дозволяє значною мірою вирішити проблему багатовимірності алфавіту класів.

4 Для збільшення критерію функціональної ефективності з метою побудови безпомилкових за навчальною вибіркою вирішальних правил необхідно у рамках ІЕІТ здійснювати оптимізацію генотипних параметрів функціонування системи, що прямо впливають на розподіл реалізацій образу.

SUMMARY

OPTIMIZATION OF LEARNING PLAN PARAMETERS OF DECISION SUPPORT SYSTEM

A.S. Dovbysh, V.A. Tron

The article describes the receptor field optimization and forming of hierarchical structure of entering patterns in context of information-extreme intellectual technology, what allowed to increase the recognition validity and efficiency in examination mode of decision support system.

СПИСОК ЛІТЕРАТУРИ

1. Краснопоясовський А.С. Інформаційний синтез інтелектуальних систем керування. – Суми: Видавництво СумДУ, 2004. – 261 с.
2. Краснопоясовський А.С. Оптимізація контейнерів класів розпізнавання за методом функціонально-статистичних випробувань //Автоматизированные системы управления и приборы автоматики. – Харьков: Харьк. нац. ун-т радиоелектр., 2002.–Вып.119.– С. 69–76.
3. Краснопоясовський А.С. Теория информации и кодирования. – Харьков : Харьк. авиац. институт, 1976.– 91 с.

А.С. Довбиш, д-р. тех. наук, СумДУ,
м. Суми;

В.А. Тронь, аспірант, СумДУ, м. Суми

Надійшла до редакції 10 жовтня 2007р.