

категоріальну модель ФКА за МФСВ можна розглядати як удосконалення відомої моделі [2], яке полягає в урахуванні компоненти ОПР, що формалізована у вигляді множини запитів і операторів її формування. Відповідно у статті знайшла подальший розвиток методологія проектування СППР, що навчається, яка дозволяє розв'язувати широке коло задач автоматичної класифікації, включаючи прогнозичну класифікацію, і орієнтована на реалізацію етапів навчання та екзамену як окремо у часі (навчання за апріорно класифікованою навчальною матрицею), так і в режимі багато потокового виконання задачі (наприклад, при кластер-аналізі).

Таким чином, системологія проектування навчального СППР передбачає в рамках детерміновано-статистичного підходу розроблення методів аналізу і синтезу слабоформалізованих процесів за умов апріорної невизначеності, інформаційних і ресурсних обмежень, з метою оптимізації просторово-часових параметрів функціонування системи шляхом її оптимізації на етапі навчання, з метою побудови безпомилкового за навчальною матрицею класифікатора.

## SUMMARY

*The questions of classification of structures Decision Support System (DSS) are considered, the formalized model is made, problems of the analysis and synthesis of learning DSS are formulated and is shown, that they are interconnected, interdependent and are compelled sequence.*

## СПИСОК ЛІТЕРАТУРИ

1. Васильев В. И. Распознавающие системы: Справочник. - 2-е изд., перераб. и доп.- Киев: Наукова думка, 1983.- 422 с.
2. Краснопоясовський А.С. Інформаційний синтез інтелектуальних систем керування: підхід, що ґрунтуються на методі функціонально-статистичних випробувань.- Суми: Видавництво Сумського державного університету, 2004. – 261с.
3. Костюк В.И., Гаврик А.П., Ямпольский Л.С., Карлов А.Г. Промышленные роботы: Конструирование, управление, эксплуатация. – К.:Вища шк. Головное изд-во, 1985.- 359 с.
4. Фомин Я. А., Тарловский Г. Р. Статистическая теория распознавания образов.– М.: Радио и связь, 1986.- 264 с.
5. Турбович И. Т., Гитис В. Г., Маслов В. К. Опознание образов. Детерминир.-статист. подход.-М.: Наука, 1971.- 246 с.
6. Краснопоясовський А.С., Козинець М.В. Факторний класифікаційний аналіз за методом функціонально-статистичних випробувань // Радіоелектронні та комп’ютерні системи.- 2004. – №4. – С. 46-50.
7. Козинець М. В. Корекція функціональної ефективності системи підтримки прийняття рішень при збільшенні потужності ознак розпізнавання // Комп’ютерні системи та інформаційні технології. – 2005. – №3. – С. 57-61.
8. Буч Г. Объектно-ориентированное проектирование с примерами применения / Пер. с англ. /Под ред. А.Н. Артамошина. – Киев – Москва: Диалектика, И.В.К., 1992.- 519 с.

*Надійшла до редакції 3 березня 2006 р.*

УДК 681.518: 004.93.1

## ОПТИМІЗАЦІЯ ІНВЕСТИЦІЙНОГО ПОРТФЕЛЯ ЗА МЕТОДОМ ФУНКЦІОНАЛЬНО-СТАТИСТИЧНИХ ВИПРОБУВАНЬ

*А.С. Довбуш, д-р техн. наук, проф.; В.А. Тронь, студент  
Сумський державний університет*

### ВСТУП

Із розвитком комп’ютерних мереж і створенням великих комп’ютерних банків інформації склалися умови для формування

сучасної теорії портфеля цінних паперів у формі моделей оптимізації, що привело до прогресивних змін у процесі аналізу, особливо звичайних акцій. Але, з іншого боку, це вимагає застосування до розв'язання практичних задач теорії інвестування великої кількості висококваліфікованих і досвідчених експертів. Одним із шляхів виходу із такого стану є розроблення і впровадження здатних навчатися (самонавчатися) систем підтримки прийняття рішень (СППР), основним призначенням яких є введення людини-експерта в контур керування системи [1,2].

На відміну від «атомістичних» традиційних підходів центральною проблемою сучасної інвестиційної теорії є формування портфеля, тобто набору активів. При цьому в аналізі як окремих активів, так і їх портфелів враховуються обидва найважливіші фактори: дохідність і ризик, який так само повинен оцінюватися кількісно. Оскільки в теоретичних моделях основну увагу приділяють аналізу фактора невизначеності, тобто ризику інвестицій, то доцільно часові характеристики в першому наближенні не розглядати особливо при короткостроковому прогнозуванні курсів акцій, що є характерним для сучасного нестабільного українського фондового ринку.

Відомо, що успіх інвестицій в основному залежить від правильного розподілення коштів за типом активів. Проведені спостереження показали, що прибуток складається з таких складових [3]:

- на 94% - вибором типу інвестиційних інструментів (акції великих компаній, короткотермінові казначейські векселі, довготермінові облігації тощо);
- на 4% - вибором конкретних цінних паперів даного типу;
- на 2% - оцінкою моменту закупки цінних паперів.

Даний феномен пояснюється тим, що папери одного типу сильно корелюють, тобто якщо якась галузь зазнає спаду, то збитки інвестора не дуже залежать від того, чи переважають у його портфелі папери тієї чи іншої компанії. Визнаним фактом є те, що інвестор може зменшити ризик при збереженні доходів, розміщуючи в портфелі папери з низькою чи від'ємною кореляцією. Так, дослідження показали, що коли портфель складається з 10-20 різних видів цінних паперів, включених за допомогою випадкової вибірки з існуючого на ринку паперів набору, то несистематичний ризик може бути зведений до мінімуму. Таким чином, диверсифікація портфеля дає можливість знизити невизначеність в отриманні доходів.

У статті розглядається задача інформаційного синтезу здатної навчатися СППР для оптимального формування інвестиційного портфеля в рамках інформаційно-екстремального методу функціонально-статистичних випробувань (МФСВ), що ґрунтуються на прямій оцінці інформаційної спроможності системи за умов априорної невизначеності, нечітких даних, інформаційних і ресурсних обмежень [4].

#### ПОСТАВЛЕННЯ ЗАДАЧІ

Розглянемо поставлення задачі оптимізації інвестиційного портфеля за МФСВ.

Нехай дано алфавіт класів розпізнавання  $\{X_m^o \mid m = \overline{1, M}\}$ , де  $M$  — кількість класів (портфелів), навчальна матриця  $\|y_{m,i}^{(j)} \mid i = 1, N, j = 1, n\|$ , де  $N$ ,  $n$  — кількість ознак розпізнавання (нормовані показники) і реалізацій образу відповідно і відомий вектор параметрів функціонування СППР, який у загальному випадку має 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 СППР, які впливають на параметри розподілу реалізації образу;

$\langle f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle$  – фенотипні параметри функціонування СППР, які впливають на геометрію контейнера класу розпізнавання, побудованого в радіальному базисі простору ознак розпізнавання.

При цьому відомі обмеження на відповідні параметри функціонування:

$$R_{\xi_1}(g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}) \leq 0; R_{\xi_2}(f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2}) \leq 0.$$

На етапі навчання треба побудувати оптимальне в інформаційному розумінні розбиття простору ознак на класи за умов:

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

де  $d_k^*, d_l^*$  – оптимальні радіуси контейнерів класів розпізнавання  $K_k^o \in X_k^o$  і  $K_l^o \in X_l^o$  відповідно. При цьому інформаційний критерій функціональної ефективності (КФЕ) набуває максимуму в робочій області визначення його функції:

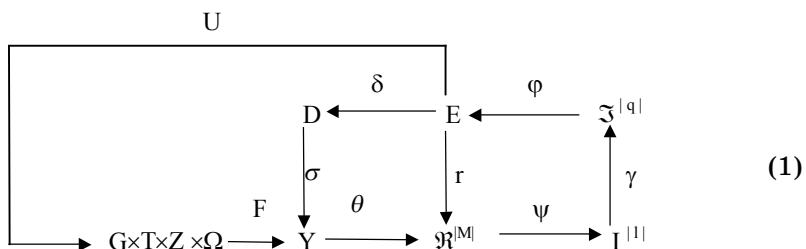
$$E^* = \max_G E_m,$$

де  $E_m$  – критерій функціональної ефективності навчання системи розпізнавати реалізації класу  $X_m^0$ ;  $G$  – робоча область визначення функції КФЕ.

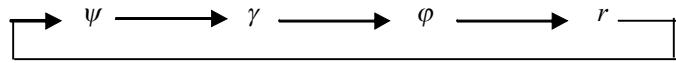
На етапі екзамену треба за побудованим на етапі навчання СППР вирішальним правилом визначити належність реалізації образу, що розпізнається, до відповідного класу розпізнавання із заданого алфавіту.

#### МАТЕМАТИЧНІ МОДЕЛІ СППР, ЩО НАВЧАЄТЬСЯ

Категорійну модель процесу навчання СППР за МФСВ подамо у вигляді діаграми відображені множин, які застосовуються на етапі навчання:



Тут універсум випробувань задається декартовим добутком  $G \times T \times Z \times \Omega$ , де  $G$  – множина факторів, що впливають на СППР;  $T$  – множина моментів котирування акцій;  $Z$  – множина функціональних станів СППР;  $\Omega$  – простір ознак розпізнавання. Оператор виходу  $F : G \times T \times Z \times \Omega \rightarrow Y$  формує на вході системи прийняття рішень (класифікатора) вибіркову множину  $Y$ , навчальну матрицю  $\|y_{m,i}^{(j)}\|$  для абетки класів розпізнавання  $\{X_m^o\}$ . Оператор  $\theta : Y \rightarrow \Re^{|M|}$  буде чітке розбиття  $\Re^{|M|}$ , яке допускає у загальному випадку перетин класів розпізнавання. Оператор  $\Psi : \Re^{|M|} \rightarrow I^{|l|}$  перевіряє основну статистичну гіпотезу  $\gamma_1 : y_{m,i}^{(j)} \in X_m^o$ , де  $I^{|l|}$  – множина гіпотез, яка для  $M = 2$ , крім основної, містить альтернативну гіпотезу  $\gamma_2 : y_{m,i}^{(j)} \notin X_m^o$ . Оператор  $\gamma$  визначає множину точнісних характеристик  $\Im^{|q|}$ , де  $q = l^2$ , а оператор  $\varphi$  обчислює терм-множину  $E$  значень інформаційного критерію оптимізації. Оператор  $r$  корегує розбиття  $\Re^{|M|}$  залежно від значень критерію. За діаграмою (1) оператори контуру



реалізують базовий алгоритм навчання TEACHING, який безпосередньо визначає екстремальні значення геометричних параметрів контейнерів шляхом пошуку максимуму КФЕ навчання СППР  $E_m^*$ . Оптимізація системи контрольних допусків на ознаки розпізнавання здійснюється за ітераційною процедурою, в якій задіяні оператори контуру

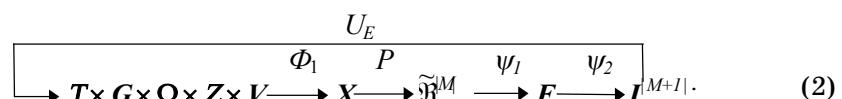


Оператор  $U$  в діаграмі (1) регламентує процес навчання і дозволяє оптимізувати параметри плану навчання, наприклад послідовність представлення класів розпізнавання.

Діаграма відображення множин на екзамені має такі відмінності:

- зворотний зв'язок у діаграмі не містить контурів оптимізації параметрів функціонування СППР, а призначенням оператора  $U_E$  є регламентація екзамену;
- замість оператора  $\theta$  вводиться оператор  $P$  відображення вибіркової множини  $X \subset \Omega_B$ , що розпізнається, на побудоване на етапі навчання оптимальне чітке розбиття  $\Re^{|M|}$ ;
- оператор класифікації  $\Psi$  утворює композицію двох операторів:  $\Psi_1 : \Re^{|M|} \rightarrow F$ , де  $F$  – множина функцій належності, і оператор дефазифікації  $\Psi_2 : F \rightarrow I^{|M+1|}$ , який вибирає гіпотезу за максимальним значенням функції належності.

З урахуванням наведених відмінностей діаграма відображення множин на екзамені набуває вигляду



У діаграмі (2) оператор  $\Phi_1$  утворює екзаменаційну матрицю  $\|x_i^{(j)} | i = \overline{1, N}, j = \overline{1, n}\|$ , аналогічну за структурою, параметрами та процедурою формування до навчальної матриці.

### КРИТЕРІЙ ОПТИМІЗАЦІЇ

Як критерій оптимізації параметрів навчання СППР може розглядатися будь-яка статистична інформаційна міра, яка є функціоналом від точнісних характеристик СППР. Так, широкого використання в алгоритмах навчання за МФСВ набула модифікація інформаційної міри Кульбака [4], в якій розглядається відношення правдоподібності у вигляді логарифмічного відношення повної ймовірності правильного прийняття рішень  $P_t$  до повної ймовірності помилкового прийняття рішень  $P_f$ :

$$\Lambda = \log_2 \frac{P_t}{P_f} = \log_2 \frac{p(\mu_1)p(\gamma_1 / \mu_1) + p(\mu_2)p(\gamma_2 / \mu_2)}{p(\mu_1)p(\gamma_2 / \mu_1) + p(\mu_2)p(\gamma_1 / \mu_2)},$$

де  $p(\mu_1)$ ,  $p(\mu_2)$  – безумовні ймовірності появи реалізацій класів  $X_1^o$  і  $X_2^o$  відповідно, а умовні ймовірності – точнісні характеристики: перша достовірність  $D_1 = p(\gamma_1 / \mu_1)$ , помилка першого роду  $\alpha = p(\gamma_2 / \mu_1)$ , помилка другого роду  $\beta = p(\gamma_1 / \mu_2)$  і друга достовірність  $D_2 = p(\gamma_2 / \mu_2)$ . Для рівномовірних гіпотез, що характеризує найбільш важкий у статистичному розумінні випадок прийняття рішень, міра Кульбака має вигляд

$$E_m = \frac{1}{2} \log_2 \left( \frac{D_1 + D_2}{\alpha + \beta} \right) [(D_1 + D_2) - (\alpha + \beta)] = \log_2 \left( \frac{2 - (\alpha + \beta)}{\alpha + \beta} \right) [2 - (\alpha + \beta)]. \quad (3)$$

Таким чином, критерій (3) є нелінійним функціоналом від точнісних характеристик процесу навчання і не є взаємо-однозначною функцією, що потребує знання робочої області її визначення. Оскільки навчальна вибірка є обмеженою за обсягом, то замість, наприклад, помилок першого та другого роду розглянемо їх оцінки:  $\alpha = K_1 / n$ ,  $\beta = K_2 / n$ , де  $K_1$  – кількість реалізацій класу  $X_1^o$ , які не належать контейнеру  $K_1^o$ ;  $K_2$  – кількість реалізацій класу  $X_2^o$ , які належать контейнеру  $K_1^o$ . Після підстановки цих оцінок у (3) отримаємо робочу формулу КФЕ за Кульбаком для  $k$ -го контейнера  $K_1^o$ , що відновлюється в радіальному базисі:

$$E_1 = \frac{1}{n} \log_2 \left\{ \frac{2n + 10^{-r} - [K_2^{(k)} + K_3^{(k)}]}{[K_2^{(k)} + K_3^{(k)}] + 10^{-r}} \right\} * [n - (K_2^{(k)} + K_3^{(k)})], \quad (4)$$

де  $10^{-r}$  – будь-яке мале додатне число, яке дозволяє уникнути появи нуля в знаменнику дробу. На практиці доцільно брати  $r$  таким, що дорівнює кількості знаків у мантисі значення критерію.

Нормований критерій Кульбака можна подати у вигляді

$$E = E_m / E_{\max},$$

де  $E_{\max}$  - максимальне значення критерію  $E_m$  при  $D_1 = D_2 = 1,0$  і  $\alpha = \beta = 0$ .

### СХЕМА АЛГОРИТМУ НАВЧАННЯ СППР

Оптимізація контрольних допусків на ознаки розпізнавання за МФСВ може здійснюватися за послідовним або паралельним алгоритмами. Використання послідовного алгоритму доцільно в загальному випадку, коли ознаки розпізнавання мають різні шкали виміру, а оперативність реалізації алгоритму навчання не є критичною. Паралельний алгоритм доцільно використовувати за умови, що ознаки розпізнавання мають однакову шкалу виміру, а на оперативність реалізації алгоритму навчання накладаються жорсткі часові обмеження.

При класифікаційному керуванні об'єктами, для яких словник складається із окремих ознак з різними шкалами виміру, доцільно застосовувати алгоритми послідовної оптимізації контрольних допусків.

Оптимальне значення параметра поля контрольних допусків для  $i$ -ї ознаки розпізнавання  $\delta_{K,i}^*$  визначається як

$$\delta_{K,i}^* = \arg \max_{\{d\}} E_1^*, \quad (5)$$

де  $E_1^*$  - найбільший глобальний максимум функції КФЕ в області її визначення;  $\{d\}$  - множина кроків навчання.

З урахуванням (5) і введених позначень алгоритм послідовної оптимізації поля контрольних допусків на ознаки розпізнавання набуває вигляду:

$$\{\delta_{K,i}^*\} = \arg \max_{G_{\delta_i}} \left\{ \max_{G_E} \left[ \bigotimes_{l=1}^L \max_{G_{d_l}} E_1^{(l)} \right] \right\}, \quad i = \overline{1, N}, \quad (6)$$

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

При цьому центрування контейнерів здійснюється в процесі навчання шляхом знаходження еталонних векторів, вершини яких визначають центри класів розпізнавання. Вхідною інформацією є навчальна матриця  $\|y_{m,i}^{(j)}\|$  системи полів нормованих допусків  $\{\delta_{H,i}\}$ , яка задає область визначення контрольних допусків  $\{\delta_{K,i}\}$  на значення ознак та рівні селекції координат двійкових еталонних векторів-реалізацій  $\{\rho_m\}$ , які за замовчуванням дорівнюють 0,5 для всіх класів розпізнавання.

Розглянемо кроки реалізації послідовного алгоритму (6).

- 1 Формується лічильник класів розпізнавання  $k := k + 1$ ;
- 2 Якщо  $k = 1$ , то виконується пункт 3, інакше – пункт 17.
- 3 Формується лічильник напрямків зміни контрольного поля допусків  $\delta_{K,i}$  для всіх ознак розпізнавання одночасно  $l : l + 1$ ,  $l = 0, 1$ .
- 4 При  $s = 0$ , де  $s$  – змінна кроків зміни параметра поля допусків  $\delta$  в одному напрямку, задається початкова СКД на ОР:  $\{NK[s,i]\}, \{VK[s,i]\}$  – нижні і верхні контрольні допуски.

5 Визначаються за базовим алгоритмом навчання TEACHING [4] максимум критерію  $E_1^*$  і екстремальні параметри контейнера класу  $X_1^o$ .

6  $s := s + 1$ .

7 Формується лічильник ознак розпізнавання:  $i := i + 1$ .

8 Для  $i$ -ої ознаки розпізнавання змінюються контрольні допуски за алгоритмом  $NK[s, i] = NK[s - 1, i] + C * H$  і  $VK[s, i] = VK[s - 1, i] - C * H$ , де  $C$  – символ Кронокера;  $H$  – крок збільшення радіуса контейнера  $K_1^o$ .

9 Якщо  $i \leq N$ , то виконується пункт 7, інакше пункт 10.

10 Визначаються за базовим алгоритмом TEACHING максимум інформаційного критерію  $E_1^*(s)$  і оптимальні параметри контейнера  $K_1^*$ .

11 Якщо  $E_1[s] \geq E_1[s - 1]$ , то виконується пункт 6, інакше – пункт 12.

12 Якщо  $s = 1$ , то виконується пункт 13, інакше – пункт 15. Якщо  $L < 2$ , то зміна параметра  $\delta$  здійснюється у протилежному напрямку ( $C := -1$ ) і виконується пункт 3, інакше –punkt 14.

13 За оптимальні беруться контрольні допуски, які визначено в пункті 4.

14 За оптимальні беруться контрольні допуски:  $\{ANK[i]\} := \{NK[s - 1, i]\}$  і  $\{AVK[i]\} := \{VK[s - 1, i]\}$  та параметри контейнера класу  $X_1^o$ , які є екстремальними значеннями критерію  $E_1^* = E[s - 1]$ .

15 Якщо  $k \leq M$ , то виконується пункт 1, реалізується базовий алгоритм TEACHING ( $k \neq 1$ ) і визначаються оптимальні геометричні параметри контейнерів інших класів при незмінних оптимальних контрольних допусках, знайдених для базового класу  $X_1^o$ , інакше – зупин реалізації алгоритму.

#### ПРИКЛАД ОПТИМІЗАЦІЇ ІНВЕСТИЦІЙНОГО ПОРТФЕЛЯ

Нехай портфель інвестицій складається з п'яти типів активів [1]: акції підприємств, облігації підприємств, ощадні сертифікати, кредитний договір, облігації державних позик.

Кожен актив має дві ознаки: дохідність і ризик. Таким чином, маємо 10 ознак об'єкта. В інвестиційній теорії існує три типи портфелів: найкращим вважається ринковий (середня дохідність і середній ризик) – клас  $X_1^o$ , агресивний (висока дохідність і високий ризик) – клас  $X_2^o$ , консервативний (низька дохідність і низький ризик) – клас  $X_3^o$ . Реалізації образу, що утворюють навчальну матрицю для заданого алфавіту, складалися із 10 структурованих ознак:  $X_1 \in [15; 19]$  – дохідність акцій підприємств,  $X_2 \in [7; 11]$  – ризик акцій підприємств,  $X_3 \in [12; 16]$  – дохідність облігацій підприємств,  $X_4 \in [5; 7]$  – ризик облігацій підприємств,  $X_5 \in [13; 17]$  – дохідність ощадних сертифікатів,  $X_6 \in [4; 8]$  – ризик ощадних сертифікатів,  $X_7 \in [13; 17]$  – дохідність кредитних договорів,  $X_8 \in [6; 8]$  – ризик кредитних договорів,  $X_9 \in [9; 12]$  – дохідність облігацій державних позик,  $X_{10} \in [3; 5]$  – ризик облігацій державних позик.

При формуванні навчальної матриці бралися показники 20 найкращих компаній, що становлять 60% ринку цінних паперів України протягом трьох років, які характеризували середні дохідності активів та середні ризики (середньоквадратичні відхилення). Оптимізація параметрів навчання (параметр  $\delta$  і радіуси контейнерів класів  $X_1^o - X_3^o$ ) у процесі побудови гіперсферичного класифікатора в рамках МФСВ здійснювалася за послідовним алгоритмом (6) шляхом пошуку глобального максимуму критерію (4) в робочій області визначення його функції.

На рис. 1 наведено графік зміни критерію  $E_1$  на кожному кроці оптимізації параметра  $\delta$ . Тут штриховою позначено робочу область для паралельної оптимізації параметра  $\delta$ , в якій перша та друга достовірності перебільшують відповідно помилки першого та другого роду.

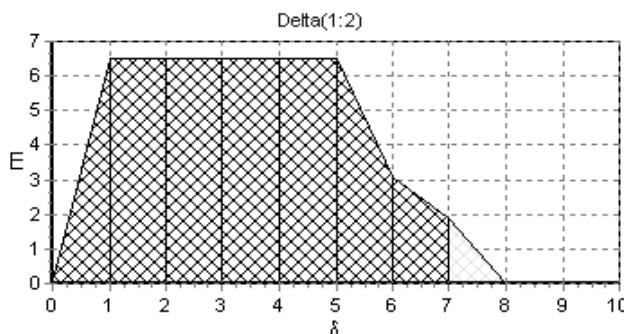


Рисунок 1

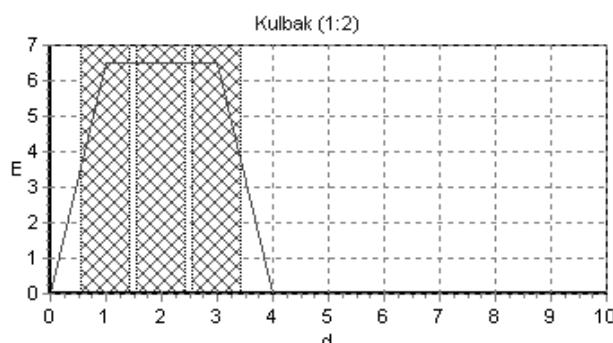


Рисунок 2

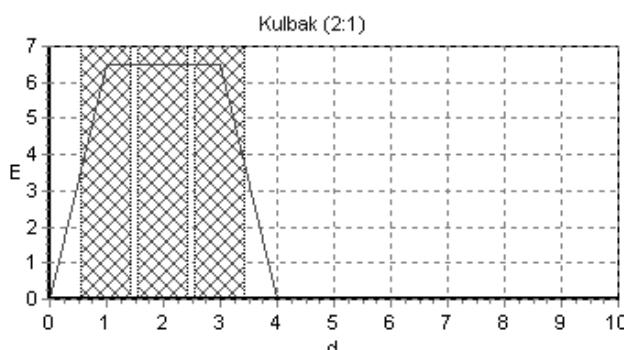


Рисунок 3

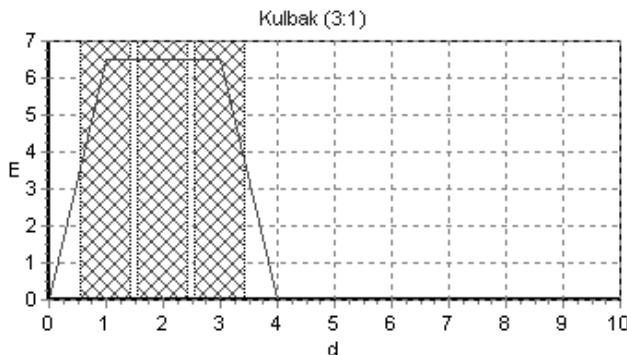


Рисунок 4

Як показано на рис. 1-4, оптимальне значення параметра  $\delta$  дорівнює 2, оптимальні значення радіусів відповідних контейнерів у кодових одиницях дорівнюють:  $d_1^* = 1$ ,  $d_2^* = 2$  і  $d_3^* = 2$ . У табл. 1 наведено результати оптимізації контейнера класу  $X_1^o$ .

Таблиця 1 – Результати оптимізації контейнера класу  $X_1^o$

| $\delta$ | $E_k$           | $D_1$           | $\beta$         | $d_1$    | $d_c$    | $l_\delta$  |
|----------|-----------------|-----------------|-----------------|----------|----------|-------------|
| 0        | 0.074289        | 0.700000        | 0.475000        | 4        | 5        | 0,8         |
| 1        | 6.482982        | 1.000000        | 0.000000        | 3        | 4        | 0,75        |
| <b>2</b> | <b>6.482982</b> | <b>1.000000</b> | <b>0.000000</b> | <b>1</b> | <b>4</b> | <b>0,25</b> |
| 3        | 6.482982        | 1.000000        | 0.000000        | 1        | 4        | 0,25        |
| 4        | 6.482982        | 1.000000        | 0.000000        | 1        | 4        | 0,25        |
| 5        | 6.482982        | 1.000000        | 0.000000        | 1        | 4        | 0,25        |
| 6        | 3.066184        | 1.000000        | 0.025000        | 1        | 4        | 0,25        |
| 7        | 1.539470        | 1.000000        | 0.150000        | 1        | 4        | 0,25        |
| 8        | 0.000000        | 0.000000        | 1.000000        | 0        | 0        | ---         |
| 9        | 0.000000        | 0.000000        | 1.000000        | 0        | 0        | ---         |
| 10       | 0.000000        | 0.000000        | 1.000000        | 0        | 0        | ---         |

У табл. 1 показано динаміку зміни у процесі оптимізації параметра  $\delta$  значень критерію  $E_1$ , першої достовірності  $D_1$ , помилки другого роду  $\beta$ , радіуса  $d_1$  контейнера класу  $X_1^o$ , міжцентральної відстані  $d_c = d(x_1 \oplus x_c)$ , де  $x_c$  – еталонний вектор-реалізація сусіднього (до  $X_1^o$ ) класу  $X_c^o$  і відносний коефіцієнт нечіткої компактності реалізації образу  $X_1^o$ :

$$l_\delta = \frac{d_1^*}{d(x_1 \oplus x_c)}.$$

#### ВИСНОВОК

1 У процесі навчання за МФСВ побудовано оптимальний в інформаційному розумінні гіперсферичний класифікатор, який в режимі екзамену забезпечує повну ймовірність правильного прийняття рішень, наближену до асимптотичної ймовірності, що характеризує функціональну ефективність навчання СППР.

2 Вперше розроблено інформаційне та програмне забезпечення здатної навчатися СППР формування інвестиційного портфеля, яке дозволяє оперативно і з високою достовірністю в режимі екзамену приймати рішення на ринку цінних паперів.

## SUMMARY

*In this article the problem of application decision support system (DSS) for optimal forming of investment portfolio is considered. The DSS is synthesized by information-extreme method of automatic classification in frameset of the method of functional statistical tests.*

## СПИСОК ЛІТЕРАТУРИ

1. Закон України про цінні папери і фондову біржу // Відомості Верховної Ради. - 1991. - № 38. – С. 1-3.
2. Петрушенко Ю.М. Використання сучасних методів інвестиційного аналізу на ринку акцій України // Вісник Сумського державного аграрного університету. Серія Фінанси та кредит. – 1999. – №1.
3. Лукашин Ю.П. Оптимизация структуры портфеля ценных бумаг //Экономика и математические методы. – М., 1995. – Т. 31, Вып. 1.
4. Краснопоясовський А. С. Інформаційний синтез інтелектуальних систем керування: Підхід, що ґрунтується на методі функціонально-статистичних випробувань.– Суми: Видавництво СумДУ, 2004. – 261 с.

*Надійшла до редакції 12 травня 2006 р.*