

С. Д. Штовба, д. т. н., проф.; А. В. Галушак

ПОРІВНЯННЯ КРИТЕРІЇВ НАВЧАННЯ НЕЧІТКОГО КЛАСИФІКАТОРА З ГОЛОСУЮЧИМИ ПРАВИЛАМИ

У нечітких класифікаторах прийняття рішення відбувається за лінгвістичними правилами <Якщо – тоді>, антецеденти яких містять нечіткі терми “низький”, “середній”, “високий” тощо. Для підвищення безпомилковості нечіткий класифікатор навчають за експериментальними даними. Досліджують нечіткий класифікатор із голосуючими правилами, у якому результатом логічного виведення обирають клас із максимальною сумарною належністю за всіма правилами. Запропоновано нові критерії навчання нечіткого класифікатора, які враховують різницю належностей нечіткого висновку лише до головних конкурентів. За правильною класифікацією головним конкурентом прийнятого рішення є клас, що має другий за величиною ступінь належності. У випадку неправильної класифікації помилково прийняте рішення є головним конкурентом правильного класу. Комп'ютерні експерименти із настроювання нечіткого класифікатора для УСІ-задачі із розпізнавання італійських вин засвідчили суттєву перевагу нових критеріїв навчання.

Ключові слова: класифікація, нечітка база знань, навчання, голосуючі правила, критерії навчання, головні конкуренти.

Вступ

Задача класифікації полягає у віднесенні об'єкта за деякими ознаками до одного з класів. У нечітких класифікаторах прийняття рішень відбувається за лінгвістичними правилами <Якщо – тоді>, антецеденти яких містять нечіткі терми “низький”, “середній”, “високий” тощо [1]. Кожне правило задає область факторного простору, у межах якої об'єкти належать до одного класу. Границі цих областей нечіткі, тому один і той же об'єкт може одночасно належати декільком класам, але з різним ступенем.

У нечітких класифікаторів агрегування логічних висновків за всіма правилами бази знань здійснюють за двома схемами. За першою схемою з єдиним правилом-переможцем результатом логічного виведення обирають консеквент правила з максимальним ступенем виконання [2]. За другою схемою з голосуючими правилами результатом логічного виведення обирають клас із максимальною сумарною належністю за всіма правилами [3]. Перевагою схеми з єдиним правилом-переможцем є більш інтерпретабельний алгоритм логічного виведення, а схеми з голосуючими правилами – більш гладкі границі розділу класів у факторному просторі [4].

Для підвищення безпомилковості нечіткий класифікатор навчають за експериментальними даними. Для цього ітераційно змінюють його параметри, щоб мінімізувати відстань між експериментальними даними та результатами нечіткого виведення. Цю відстань, яку назвемо критерієм навчання, можна визначити в різний спосіб. Відповідно виникає зацікавленість у виборі такого критерію навчання, який забезпечує найкращу безпомилковість нечіткого класифікатора на тестовій вибірці.

У роботах [5 – 8] експериментально перевірено ефективність трьох критеріїв навчання нечіткого класифікатора з єдиним правилом-переможцем. Досліджували такі критерії: 1) частоту помилок; 2) квадратичну нев'язку між двома нечіткими множинами – бажаними та реальними результатами класифікації; 3) квадратичну нев'язку між нечіткими бажаними та реальними результатами класифікації з додатковим штрафом за помилкове рішення.

Для класифікатора з голосуючими правилами як критерій навчання використовують частоту помилок [4]. Метою статті є перевірка 5 критеріїв навчання нечітких класифікаторів із голосуючими правилами: трьох із [5 – 8] та двох нових. Нові критерії навчання нечіткого

класифікатора враховують різницю належностей нечіткого висновку лише до головних конкурентів. У випадку правильної класифікації головним конкурентом прийнятого рішення є клас із другим за величиною ступенем належності. Цю різницю слід максимізувати, щоб віддалити від класу, із яким найлегше можна переплутати правильне рішення. У випадку неправильної класифікації помилково прийняте рішення є головним конкурентом правильного класу, тому різницю між ступенями належностей до цих класів слід зменшувати під час навчання.

1. Нечіткий класифікатор із голосуючими правилами

Уведемо такі позначення:

$\mathbf{X} = (x_1, x_2, \dots, x_n)$ – вектор інформативних ознак об'єкта класифікації (вектор вхідних атрибутів);

l_1, l_2, \dots, l_m – класи рішень;

y – результат класифікації.

Нечіткий класифікатор являє собою відображення $\mathbf{X} = (x_1, x_2, \dots, x_n) \rightarrow y \in \{l_1, l_2, \dots, l_m\}$ на основі бази нечітких правил. Ґрунтуючись на [2], базу правил нечіткого класифікатора запишемо так:

Якщо $(x_1 = \tilde{a}_{1j}$ та $x_2 = \tilde{a}_{2j}$ та ... та $x_n = \tilde{a}_{nj}$ з вагою w_j), тоді $y = d_j$, $j = \overline{1, k}$, (1)

де k – кількість правил; $d_j \in \{l_1, l_2, \dots, l_m\}$ – категоріальне значення консеквента j -го правила; $w_j \in [0, 1]$ – ваговий коефіцієнт, який задає достовірність j -го правила, $j = \overline{1, k}$; \tilde{a}_{ij} – нечіткий терм, яким оцінюють ознаку x_i в j -му правилі, $i = \overline{1, n}$, $j = \overline{1, k}$.

Класифікацію поточного об'єкта з атрибутами $\mathbf{X}^* = (x_1^*, x_2^*, \dots, x_n^*)$ здійснюють таким чином. Спочатку розраховують ступінь виконання j -го правила з бази (1):

$$\mu_j(X^*) = w_j \cdot (\mu_j(x_1^*) \wedge \mu_j(x_2^*) \wedge \dots \wedge \mu_j(x_n^*)), \quad j = \overline{1, k}, \quad (2)$$

де $\mu_j(x_i^*)$ – ступінь належності значення x_i^* нечіткому терму \tilde{a}_{ij} ; \wedge – t -норма, яку зазвичай реалізують операцією мінімуму або добутком.

Ступінь належності вхідного вектора \mathbf{X}^* до класів l_1, l_2, \dots, l_m розраховують так:

$$\mu_s(y^*) = \frac{\sum_{\forall j: d_j=l_s, j=\overline{1, k}} \mu_j(X^*)}{\max_{s=\overline{1, m}} \left(\sum_{\forall j: d_j=l_s, j=\overline{1, k}} \mu_j(X^*) \right)}, \quad s = \overline{1, m}. \quad (3)$$

Нечітким рішенням задачі класифікації буде нечітка множина

$$\tilde{y}^* = \left(\frac{\mu_{l_1}(y^*)}{l_1}, \frac{\mu_{l_2}(y^*)}{l_2}, \dots, \frac{\mu_{l_m}(y^*)}{l_m} \right). \quad (4)$$

Результатом виведення оберемо ядро нечіткої множини (4), тобто клас із максимальною сумою ступенів належності:

$$y^* = \underset{\{l_1, l_2, \dots, l_m\}}{\operatorname{arg\,max}} \left(\mu_{l_s}(y^*) \right).$$

Можлива ситуація, коли в ядро нечіткої множини (4) входять кілька елементів. Тоді об'єкт одночасно належить кільком класам з однаковими ступенями, значення яких дорівнює $\max_{s=1, m} (\mu_{l_s}(y^*))$. Для вибору одного з цих конкурентних класів застосуємо схему на основі єдиного правила-переможця. За нею серед правил, що стосуються цих конкурентних класів, виберемо правило з максимальним ступенем виконання.

2. Критерії навчання нечіткого класифікатора

Навчальну вибірку з M пар “входи – вихід” запишемо так:

$$(\mathbf{X}_r, y_r), \quad r = \overline{1, M}, \quad (5)$$

де $\mathbf{X}_r = (x_{r1}, x_{r2}, \dots, x_{rm})$ - вхідні атрибути r -го об'єкта; $y_r \in \{l_1, l_2, \dots, l_m\}$ - клас r -го об'єкта.

Уведемо такі позначення:

\mathbf{P} – вектор параметрів функцій належності термів з бази знань (1);

\mathbf{W} – вектор вагових коефіцієнтів правил бази знань (1);

$F(\mathbf{K}, \mathbf{X}_r) \in \{l_1, l_2, \dots, l_m\}$ – результат класифікації за базою знань із параметрами

$\mathbf{K} = (\mathbf{P}, \mathbf{W})$ для вхідного вектору \mathbf{X}_r з r -го рядка вибірки (5).

Навчання нечіткого класифікатора полягає в знаходженні такого вектора \mathbf{K} , який мінімізує частоту помилок класифікації на тестовій вибірці. При цьому для настроювання параметрів \mathbf{K} використовують лише навчальну вибірку (5). Навчання розглядають як задачу оптимізації. Вона полягає в знаходженні таких значень керованих змінних \mathbf{K} , які мінімізують відстань між результатами логічного виведення та експериментальними даними з вибірки (5). Цю відстань, яку назвемо критерієм навчання, можна визначити у різний спосіб.

Критерій 1 – частота помилок класифікації [4]:

$$Crit_1 = \frac{1}{M} \sum_{r=1, M} \Delta_r(\mathbf{K}), \quad (6)$$

$$\text{де } \Delta_r(\mathbf{K}) = \begin{cases} 1, & \text{якщо } y_r \neq F(\mathbf{K}, \mathbf{X}_r) \\ 0, & \text{якщо } y_r = F(\mathbf{K}, \mathbf{X}_r) \end{cases}$$

Переваги критерію полягають у його простоті та ясній змістовній інтерпретації. Але цільова функція в задачі оптимізації за цим критерієм приймає дискретні значення, що ускладнює застосування швидких градієнтних методів оптимізації, особливо за малих вибірок даних.

Критерій 2 – квадратична нев'язка між двома нечіткими множинами – бажаними та реальними результатами класифікації [2]. Для її розрахунку значення вихідної змінної y у навчальній вибірці фазифікують так:

$$\left. \begin{aligned} \tilde{y} &= \left(\frac{1}{l_1}, \frac{0}{l_2}, \dots, \frac{0}{l_m} \right), & \text{якщо } y = l_1 \\ \tilde{y} &= \left(\frac{0}{l_1}, \frac{1}{l_2}, \dots, \frac{0}{l_m} \right), & \text{якщо } y = l_2 \\ &\vdots \\ \tilde{y} &= \left(\frac{0}{l_1}, \frac{0}{l_2}, \dots, \frac{1}{l_m} \right), & \text{якщо } y = l_m \end{aligned} \right\} \quad (7)$$

Критерій навчання враховує відстань між логічним висновком у формі нечіткої множини (4) та бажаним нечітким значенням вихідної змінної (7):

$$Crit_2 = \sum_{r=1, M} D_r(\mathbf{K}), \quad (8)$$

де $D_r(\mathbf{K})$ – відстань між бажаною та дійсною вихідними нечіткими множинами під час класифікації r -го об'єкта з навчальної вибірки (5).

Для розрахунку $D_r(\mathbf{K})$ використовують евклідову метрику:

$$D_r(\mathbf{K}) = \sum_{s=1, m} (\mu_{l_s}(y_r) - \mu_{l_s}(\mathbf{K}, \mathbf{X}_r))^2, \quad (9)$$

де $\mu_{l_s}(y_r)$ – ступінь належності r -го об'єкта навчальної вибірки до класу l_s згідно з (7); $\mu_{l_s}(\mathbf{K}, \mathbf{X}_r)$ – розрахований за формулою (3) ступінь належності висновку за нечіткою моделлю з параметрами \mathbf{K} до класу l_s для вхідного вектору \mathbf{X}_r .

Перевага критерію $Crit_2$ полягає в урахуванні міри впевненості в прийнятому рішенні на основі ступенів належності об'єкта різним класам. У критерії $Crit_1$ вважають, що результат класифікації об'єкта є абсолютно достовірним, тобто неважливо наскільки ступінь належності в рішення більший, ніж в інших альтернатив: на 0.0001 або на 1. Крім того, цільова функція в задачі навчання за критерієм (8) не має довгих плато, тому вона придатна до оптимізації градієнтними методами. Але близькі до границь класів об'єкти вносять майже однаковий внесок у критерій навчання (8) як за правильної, так і за помилкової класифікації, тому навчання може бути нерезультативним.

Критерій 3 – квадратична нев'язка між нечіткими бажаними та реальними результатами класифікації з додатковим штрафом за помилкове рішення [5 - 8]. Цей критерій успадковує переваги двох попередніх критеріїв. Ідея полягає в збільшенні відстані D для помилково класифікованих об'єктів:

$$Crit_3 = \sum_{r=1, M} (\Delta_r(\mathbf{K}) \cdot p + 1) \cdot D_r(\mathbf{K}), \quad (10)$$

де $p > 0$ – штрафний коефіцієнт.

Критерій 4 – відстань між головними конкурентами зі штрафом за помилкове рішення. Це новий критерій навчання. Ідея цього критерію полягає у врахуванні різниці належностей нечіткого висновку лише до головних конкурентів. За алгоритмом логічного виведення рішенням обирають клас із максимальним ступенем належності. Позначимо цей клас-переможець через win та присвоїмо йому перший ранг. У випадку правильної класифікації головним конкурентом прийнятого рішення є $vicewin$ – клас із другим рангом, тобто клас із другим за величиною ступенем належності (рис. 1а). Чим більша різниця між ступенями належності до класів win та $vicewin$, тим більша впевненість у логічному висновку і тим далі об'єкт розташований від границі розділу класів. Позначимо через $smax$ операцію

знаходження другого за величиною елемента множини. Тоді для r -го об'єкта з вибірки (5) $\mu_{win}(\mathbf{X}_r) = \max_{s=1, m}(\mu_{l_s}(\mathbf{X}_r))$ та $\mu_{vicewin}(\mathbf{X}_r) = \text{smax}_{s=1, m}(\mu_{l_s}(\mathbf{X}_r))$. Відповідно різниця між головними конкурентами становить $\mu_{win}(\mathbf{X}_r) - \mu_{vicewin}(\mathbf{X}_r)$.

За неправильної класифікації помилково прийняте рішення буде головним конкурентом правильного класу (рис. 1б). Відповідно бажано зменшити різницю між ступенями належності до помилкового рішення та до правильного класу. Різницю між головними конкурентами в цьому випадку запишемо так: $\mu_{win}(\mathbf{X}_r) - \mu_{y_r}(\mathbf{X}_r)$.




Рис. 1. Головні конкуренти:
а) правильна класифікація; б) помилкова класифікація

У критерії навчання враховуватимемо відносні показники, розділивши різницю на ступінь належності класу-переможцю. За правильної класифікації відносна різниця дорівнює $D_r^1 = \frac{\mu_{win}(\mathbf{X}_r) - \mu_{vicewin}(\mathbf{X}_r)}{\mu_{win}(\mathbf{X}_r)}$, а за неправильної – $D_r^0 = \frac{\mu_{win}(\mathbf{X}_r) - \mu_{y_r}(\mathbf{X}_r)}{\mu_{win}(\mathbf{X}_r)}$. Крім того, аналогічно до критерія 3, за помилкової класифікації зважимо різницю штрафним коефіцієнтом. Математично критерій навчання запишемо так:

$$Crit_4 = p \cdot \sum_{\substack{y_r \neq F(\mathbf{K}, \mathbf{X}_r) \\ r=1, M}} D_r^0(\mathbf{K}) - \sum_{y_r = F(\mathbf{K}, \mathbf{X}_r)} D_r^1(\mathbf{K}), \quad (11)$$

де $p \geq 1$ – штрафний коефіцієнт.

Для прикладу розрахуємо відстань (11) за результатами логічного виведення з рис. 1. За правильної класифікації (рис. 1а) відстань дорівнює: $D_a^1 = \frac{0.8 - 0.5}{0.8} = 0.375$. У випадку помилкової класифікації (рис. 1б) за штрафного коефіцієнта $p = 3$ відстань дорівнює: $D_b^1 = 3 \cdot \frac{0.8 - 0.2}{0.8} = 2.25$.

Критерій 5 – квадратична відстань між головними конкурентами зі штрафом за помилкове рішення. Цей критерій є модифікацією попереднього. Відмінність полягає у використанні не абсолютних відстаней, а їх квадратів:

$$Crit_5 = p \cdot \sum_{\substack{y_r \neq F(\mathbf{K}, \mathbf{X}_r) \\ r=1, M}} D_r^0(\mathbf{K})^2 - \sum_{y_r = F(\mathbf{K}, \mathbf{X}_r)} D_r^1(\mathbf{K})^2.$$

Піднесення до квадрату в $Crit_5$ дозволяє збільшити внесок у критерії навчання великих відхилень та знівелювати внесок малих відхилень.

4. Комп'ютерні експерименти

Метою експериментів є виявлення критерію, навчання за яким забезпечує найкращу безпомилковість. Розглядаємо тестову задачу Wine Dataset з UCI Machine Learning Repository. Вона полягає у виявленні сорту винограду (y), із якого виготовлено вино. База даних містить результати лабораторних аналізів за 13-ти показниками 178 зразків італійських вин, виготовлених в одному регіоні. Для кожного зразка вказаний один із трьох сортів винограду, із якого виготовлено вино.

Навчальну вибірку сформуємо з рядків бази даних із граничними значеннями кожного із 13 атрибутів. Додатково в навчальну вибірку внесемо всі непарні рядки бази даних. Усі інші дані занесемо в тестову вибірку. У результаті отримаємо навчальну вибірку зі 100 рядків і тестову – із 78. Спроекуємо нечіткий класифікатор вин за трьома ознаками: x_7 – flavanoids, x_{10} – color intensity та x_{13} – proline. За розподілом експериментальних даних (рис. 2) сформуємо нечітку базу знань (табл. 1) із п'ятьма правилами. Нечіткі терми задамо гаусовою функцією належності:

$$\mu(x) = \exp\left(-\frac{(x-b)^2}{2c^2}\right),$$

де b – координата максимуму та $c > 0$ – коефіцієнт концентрації.

Параметри функцій належностей початкового нечіткого класифікатора наведено в табл. 2.

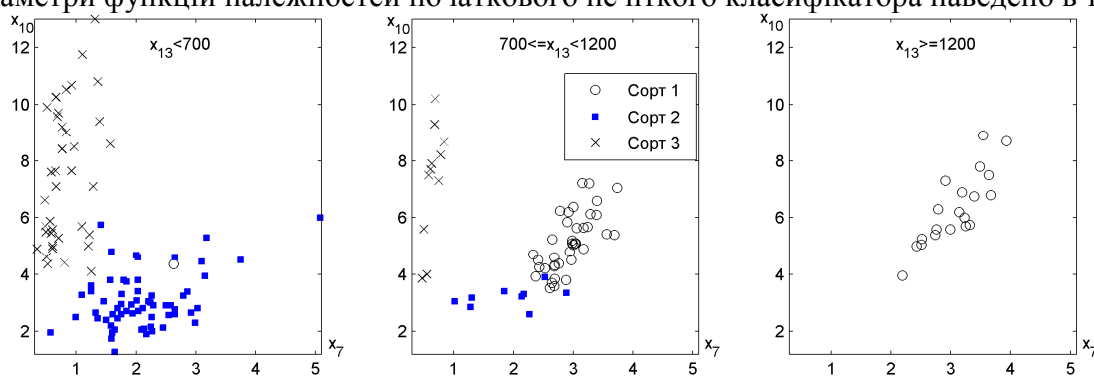


Рис. 2. Розподіл даних у Wine Database

Таблиця 1

Нечітка база знань класифікатора вин

№	x_7	x_{10}	x_{13}	y
1	–	–	Високий	Сорт 1
2	Високий	Високий	Середній	Сорт 1
3	–	Низький	Низький	Сорт 2
4	Низький	Низький	Середній	Сорт 2
5	Низький	Високий	–	Сорт 3

Таблиця 2

Параметри функцій належності термів нечіткого класифікатора вина

Вхідна змінна	Терм	Параметри	
		b	c
x_7	Низький	2	0.34
	Високий	2	5.08
x_{10}	Низький	6	1.28
	Високий	6	13
x_{13}	Низький	3	2.78
	Середній	3	10
	Високий	3	16.8

Для кожного критерію проведемо 1000 експериментів із навчання нечіткої бази знань на основі квазіньютонівського алгоритму. Після навчання кожний класифікатор перевіримо на тестовій вибірці за частотою помилок (критерій $Crit_1$). Під час навчання налаштуємо вагові коефіцієнти перших чотирьох правил. Достовірність п'ятого правила не викликає сумнівів, тому, згідно з [9], його ваговий коефіцієнт не налаштуватимемо. Налаштуємо також коефіцієнти концентрації (c) функції належності кожного нечіткого терма. Для збереження інтерпретованості бази знань відповідно до [10] налаштуватимемо координати максимумів (b) функцій належності лише некрайніх термів. У базі знань лише один некрайній терм – “середній”, координату максимуму якого й будемо змінювати. Отже, загальна кількість параметрів, які налаштовують, становить $4 + 7 + 1 = 12$. Початкові точки для навчання оберемо випадково: для вагових коефіцієнтів правил з діапазону $[0, 1]$, а для параметрів функцій належності – в межах $\pm 30\%$ від значень із табл. 2.

Проведемо дві серії експериментів. Першу серію для нечіткого класифікатора з реалізацією t-норми операцією мінімуму (\min), а другу – із реалізацією t-норми операцією добутку (prod). В експериментах із навчання за критеріями $Crit_3$, $Crit_4$ та $Crit_5$ спочатку визначимо прийнятний рівень штрафного коефіцієнта. Для цього проведемо по 200 експериментів для $p = 1, 3, \dots, 9$. Результати експериментів (рис. 3 та 4, табл. 3) показали, що навчання відбувається значно краще, якщо для критерію $Crit_3$ $p = 1$. За критеріїв $Crit_3$ та $Crit_5$ якість навчання не так чутлива до штрафного коефіцієнта. Коли t-норму реалізовано операцією мінімуму, найкращої безпомилковості досягають, якщо $p = 3$ для $Crit_4$ та $p = 5$ для $Crit_5$. Коли t-норму реалізовано добутком, найкращої безпомилковості досягають, якщо $p = 5$ для $Crit_4$ та $p = 3$ для $Crit_5$. Саме за таких значень штрафного коефіцієнта проведемо решту 800 експериментів.

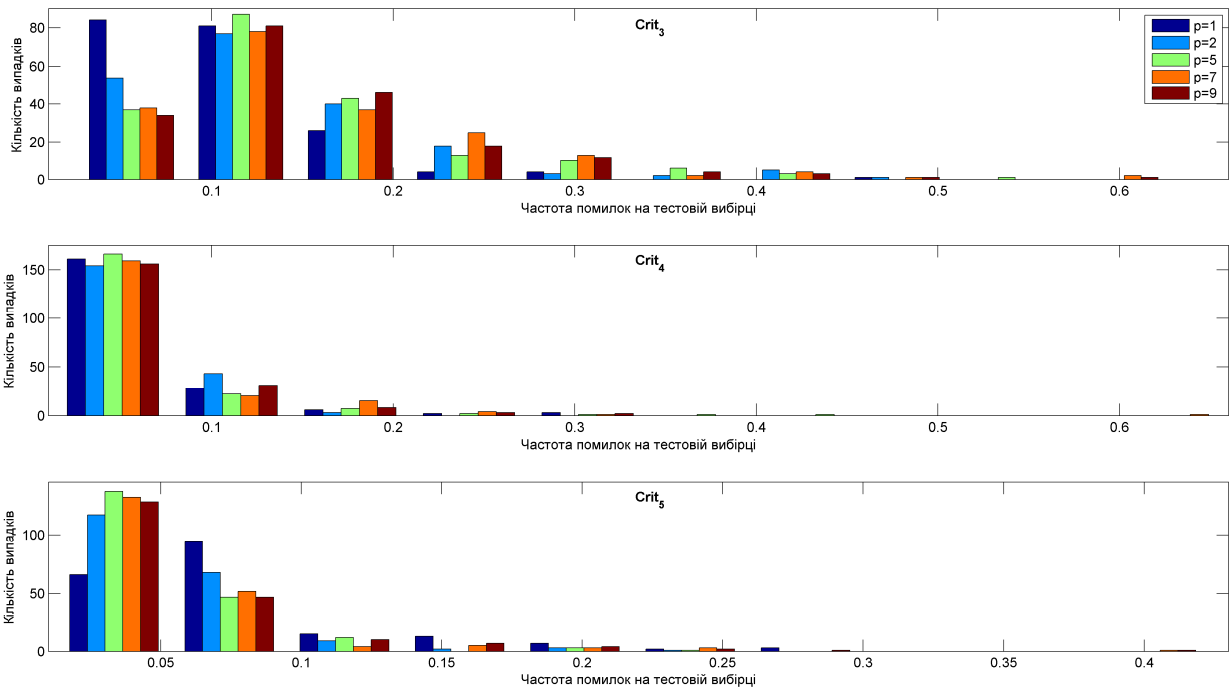


Рис. 3. Уплив штрафного коефіцієнта на безпомилковість класифікатора, в якому t-норму реалізовано операцією мінімуму

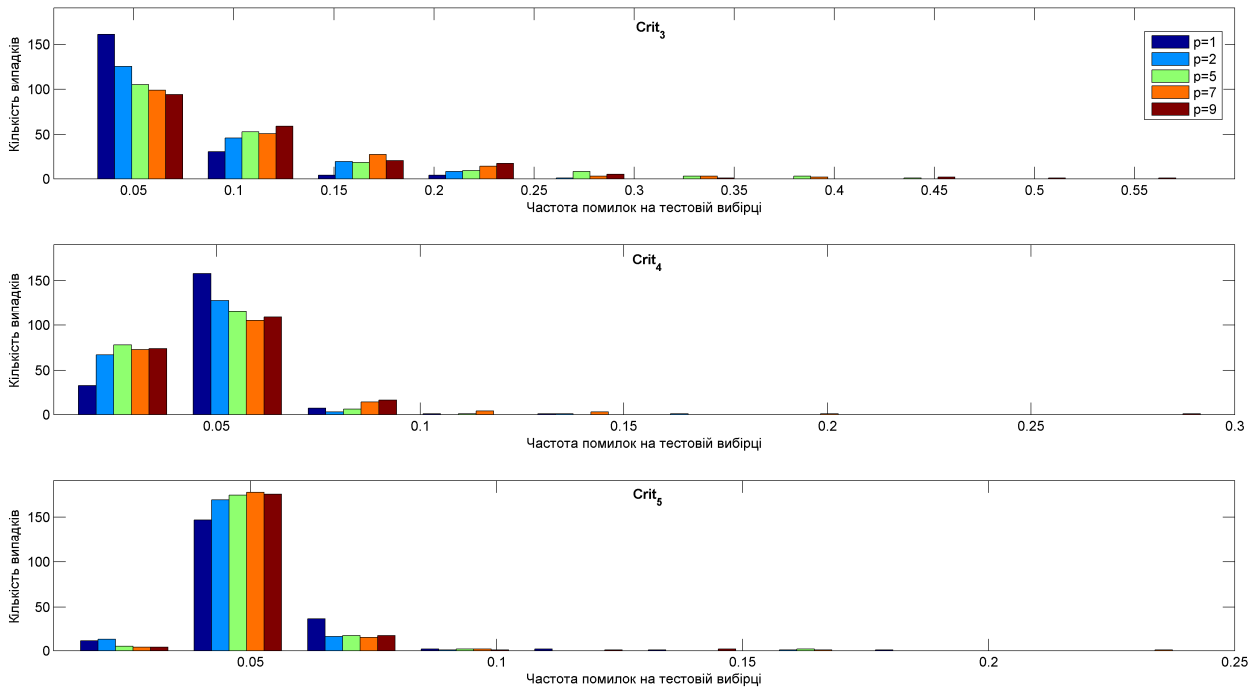


Рис. 4. Уплив штрафного коефіцієнта на безпомилковість класифікатора, в якому t-норму реалізовано добутком

Уплив штрафного коефіцієнта в критерії навчання на безпомилковість класифікатора на тестовій вибірці (напівжирним виділено найкращі результати)

t-норма	Критерій	Середня безпомилковість				
		$p = 1$	$p = 3$	$p = 5$	$p = 7$	$p = 9$
min	$Crit_3$	0.1050	0.1356	0.1469	0.1560	0.1553
	$Crit_4$	0.0712	0.0645	0.0696	0.0757	0.0721
	$Crit_5$	0.0812	0.0595	0.0572	0.0608	0.0631
prod	$Crit_3$	0.0715	0.0879	0.1091	0.1061	0.1133
	$Crit_4$	0.0546	0.0506	0.0496	0.0528	0.0517
	$Crit_5$	0.0510	0.0446	0.0448	0.0461	0.0460

Результати експериментів показали кореляцію значень критеріїв $Crit_1 - Crit_5$ на навчальній вибірці із частотою помилок на тестовій вибірці (рис. 5). Відповідно ці критерії можна застосовувати для навчання нечіткого класифікатора з голосуючими правилами. Якість навчання (табл. 4 та рис. 6, 7) суттєво краща за використання нових критеріїв $Crit_4$ та $Crit_5$. Нові критерії забезпечують кращу безпомилковість як в середньому (табл. 4), так і за кількістю найкращих випадків навчання. Серед нових критеріїв незначну перевагу має $Crit_5$.

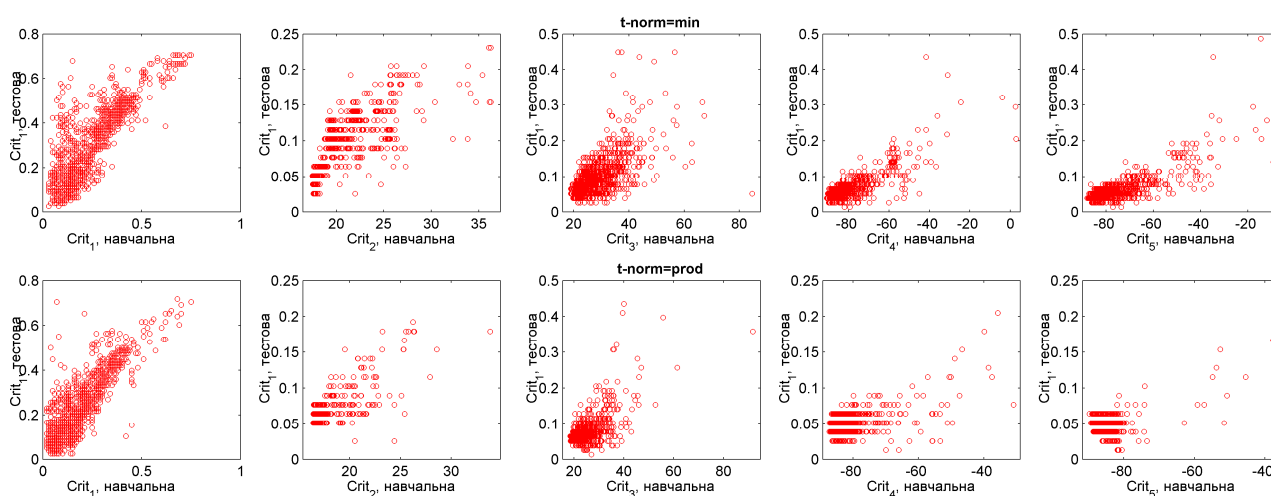


Рис. 5. Розподіл результатів навчання нечіткого класифікатора

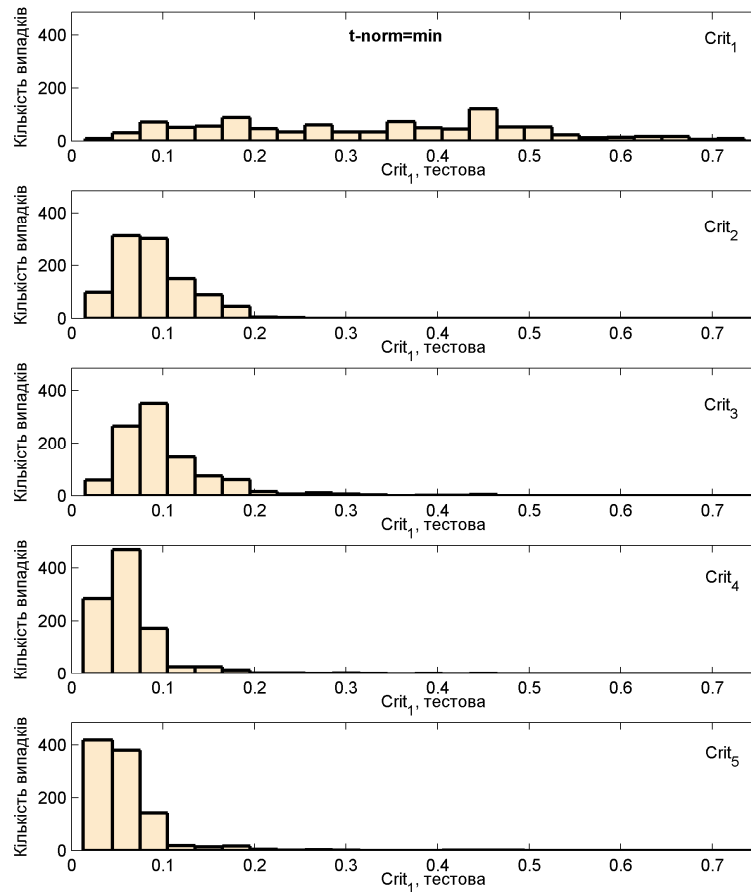


Рис. 6. Розподіл якості навчання класифікатора, t-норму якого реалізовано мінімумом

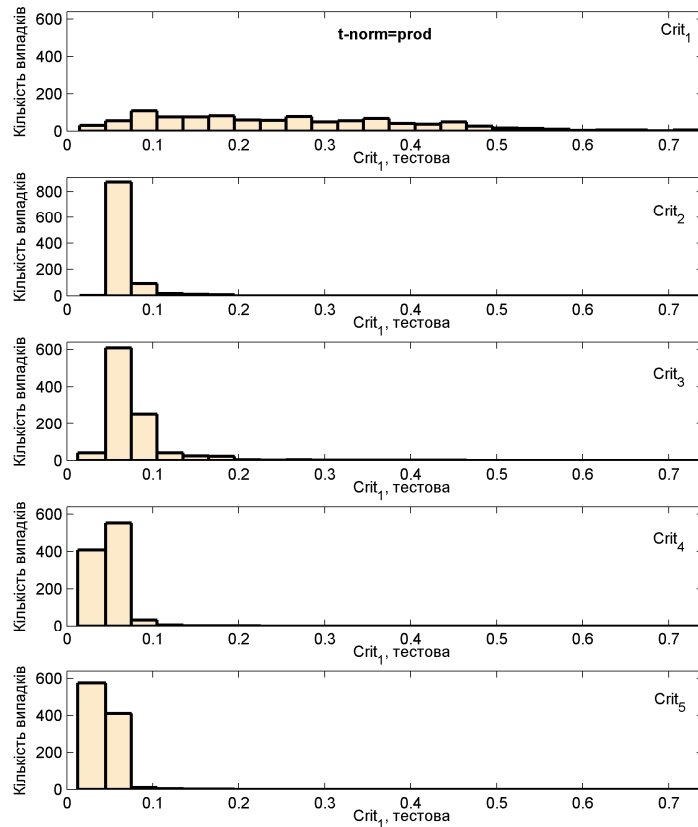


Рис. 7. Розподіл якості навчання класифікатора, t-норму якого реалізовано добутком

**Статистика навчання нечітких класифікаторів
(напівжирним виділено найкращі результати)**

t-норма	Критерій навчання	Частота помилок ($Crit_1$) на тестовій вибірці			
		мінімальне	середнє	медіанне	максимальне
min	$Crit_1$	0.0256	0.3222	0.3333	0.7051
	$Crit_2$	0.0256	0.0901	0.0897	0.2308
	$Crit_3$	0.0256	0.1003	0.0897	0.4487
	$Crit_4$	0.0128	0.0638	0.0513	0.4359
	$Crit_5$	0.0128	0.0598	0.0513	0.4872
prod	$Crit_1$	0.0256	0.2518	0.2308	0.7179
	$Crit_2$	0.0256	0.0601	0.0513	0.1923
	$Crit_3$	0.0128	0.0747	0.0641	0.4359
	$Crit_4$	0.0128	0.0496	0.0513	0.2051
	$Crit_5$	0.0128	0.0451	0.0385	0.1667

Висновки

Уперше реалізовано навчання нечіткого класифікатора з голосуючими правилами не лише за частотою помилок, але й за іншими критеріями навчання. Це такі критерії як: квадратична нев'язка між двома нечіткими множинами – бажаними та реальними результатами класифікації; квадратична нев'язка між нечіткими бажаними та реальними результатами класифікації з додатковим штрафом за помилкове рішення; відстань між головними конкурентами зі штрафом за помилкове рішення; квадратична відстань між головними конкурентами зі штрафом за помилкове рішення. Критерії на основі відстані між головними конкурентами є новими, а решту застосовували для навчання нечіткого класифікатора зі схемою виведення на основі єдиного правила переможця.

Проведені комп'ютерні експерименти з налаштування нечіткого класифікатора для UCI-задачі із розпізнавання італійських вин засвідчили суттєву перевагу нових критеріїв навчання. Серед нових критеріїв навчання невелику перевагу має критерій у формі квадратичної відстані між головними конкурентами зі штрафом за помилкове рішення.

Публікація містить результати досліджень, проведених за грантової підтримки Державного фонду фундаментальних досліджень за конкурсним проектом №62/201-2015.

СПИСОК ЛІТЕРАТУРИ

1. Kuncheva L. I. Fuzzy classifier design, Studies in Fuzziness and Soft Computing / L. I. Kuncheva . – Vol. 49. – Berlin – Heidelberg: Springer-Verlag, 2000. – 314 p.
2. Rotshtein A. N. Design and tuning of fuzzy rule-based system for medical diagnosis / A. N. Rotshtein, N. H. Teodorescu, , A. Kandel, L. C. Jain // Fuzzy and Neuro-Fuzzy Systems in Medicine. – Boca-Raton : CRC-Press, 1998. - P. 243 – 289.
3. Ishibuchi H. Voting in fuzzy rule-based systems for pattern classification problems / H. Ishibuchi, T. Nakashima, T. Morisawa // Fuzzy Sets and Systems. – 1999. – Vol. 103, №2. – P. 223 – 238.
4. Ishibuchi H. Classification and modeling with linguistic information granules: advanced approaches advanced approaches to linguistic data mining / H. Ishibuchi, T. Nakashima, M. Nii. – Berlin – Heidelberg: Springer-Verlag, 2005. – 307 p.
5. Shtovba S. Tuning the fuzzy classification models with various learning criteria: the case of credit data classification / S. Shtovba, O. Pankevich, G. Dounias // Proc. of Inter. Conference on Fuzzy Sets and Soft Computing in Economics and Finance. St. Petersburg (Russia). St. Petersburg: Russian Fuzzy Systems Association. – 2004. – Vol. 1. – P. 103 – 110.

6. Штовба С. Д. Проектирование нечетких систем средствами MATLAB / С. Д. Штовба. – М. : Горячая линия – Телеком, 2007. – 288 с.
7. Штовба С. Д. Порівняння критеріїв навчання нечіткого класифікатора / С. Д. Штовба // Вісник Вінницького політехнічного інституту. – 2007. – № 6. – С. 84 – 91.
8. Штовба С. Д. Анализ критериев обучения нечеткого классификатора / С. Д. Штовба, О. Д. Панкевич, А. В. Нагорна // Автоматика и вычислительная техника. - 2015. - № 3. - С. 5 - 16.
9. Панкевич О. Д. Діагностування тріщин будівельних конструкцій за допомогою нечітких баз знань. Монографія / О. Д. Панкевич, С. Д. Штовба. – Вінниця: УНІВЕРСУМ – Вінниця, 2005. – 108 с.
10. Штовба С. Д. Обеспечение точности и прозрачности нечеткой модели Мамдани при обучении по экспериментальным данным / С. Д. Штовба // Проблемы управления и информатики. – 2007. – № 4. – С. 102 – 114.

Штовба Сергій Дмитрович – д. т. н., професор, професор кафедри комп'ютерних систем управління, Email: shtovba@ksu.vntu.edu.ua.

Галуцак Анастасія Володимирівна – асистент кафедри комп'ютерних систем управління, Email: nastya.nahorna@gmail.com.

Вінницький національний технічний університет.