

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

## СРАВНЕНИЕ КРИТЕРИЕВ ОБУЧЕНИЯ НЕЧЕТКОГО КЛАССИФИКАТОРА С ГОЛОСУЮЩИМИ ПРАВИЛАМИ

*В нечетких классификаторах принятие решения происходит по лингвистическим правилам <Если – то>, antecedentes которых содержат нечеткие термы "низкий", "средний", "высокий" и т. п. Для повышения безошибочности нечеткий классификатор обучают по экспериментальным данным. Исследуют нечеткий классификатор с голосующими правилами, в котором результатом логического вывода выбирают класс с максимальной суммарной принадлежностью по всем правилам. Предложены новые критерии обучения нечеткого классификатора, учитывающие разницу принадлежностей нечеткого вывода только к главным конкурентам. При правильной классификации главным конкурентом принятого решения является класс, имеющий вторую по величине степень принадлежности. В случае неправильной классификации ошибочно принятое решение является главным конкурентом правильного класса. Компьютерные эксперименты по настройке нечеткого классификатора для UCI-задачи по распознаванию итальянских вин показали существенное преимущество новых критериев обучения.*

**Ключевые слова:** классификация, нечеткая база знаний, обучение, голосующие правила, критерии обучения, главные конкуренты.

### Введение

Задача классификации заключается в отнесении объекта по некоторым признакам к одному из классов. В нечетких классификаторах принятие решений происходит по лингвистическим правилам <Если – то>, antecedentes которых содержат нечеткие термы "низкий", "средний", "высокий" и т. д. [1]. Каждое правило задает область факторного пространства, в пределах которой объекты принадлежат одному классу. Границы этих областей нечеткие, поэтому один и тот же объект может одновременно принадлежать нескольким классам, но с разной степенью.

В нечетких классификаторах агрегирование логических выводов по всем правилам базы знаний осуществляется по двум схемам. По первой схеме с единственным правилом-победителем результатом логического вывода выбирают консеквент правила с максимальной степенью выполнения [2]. По второй схеме с голосующими правилами результатом логического вывода выбирают класс с максимальной суммарной принадлежностью по всем правилам [3]. Преимуществом схемы с единственным правилом-победителем является более интерпретабельный алгоритм логического вывода, а схемы с голосующими правилами – более гладкие границы раздела классов в факторном пространстве [4].

Для повышения безошибочности нечеткий классификатор обучают по экспериментальным данным. Для этого итерационно изменяют его параметры, чтобы минимизировать расстояние между экспериментальными данными и результатами нечеткого вывода. Это расстояние, которое назовем критерием обучения, можно определить различными способами. Соответственно возникает заинтересованность в выборе такого критерия обучения, который обеспечивает лучшую безошибочность нечеткого классификатора на тестовой выборке.

В работах [5 – 8] экспериментально проверена эффективность трёх критериев обучения нечеткого классификатора с единственным правилом-победителем. Исследовали следующие критерии: 1) частоту ошибок; 2) квадратичную невязку между двумя нечеткими множествами – желаемыми и реальными результатами классификации; 3) квадратичную невязку между нечеткими желаемыми и реальными результатами классификации с

дополнительным штрафом за ошибочное решение.

Для классификатора с голосующими правилами как критерий обучения используют частоту ошибок [4]. Целью статьи является проверка 5 критериев обучения нечетких классификаторов с голосующими правилами: трех из [5 – 8] и двух новых. Новые критерии обучения нечеткого классификатора учитывают разницу принадлежностей нечеткого вывода только у главных конкурентов. В случае правильной классификации главным конкурентом принятого решения является класс со второй по величине степенью принадлежности. Эту разницу следует максимизировать, чтобы отдалить от класса, с которым легче всего перепутать правильное решение. В случае неправильной классификации ошибочно принятое решение является главным конкурентом правильного класса, поэтому разницу между степенями принадлежности к этим классам следует уменьшать во время учебы.

### 1. Нечеткий классификатор с голосующими правилами

Введем такие обозначения:

$\mathbf{X} = (x_1, x_2, \dots, x_n)$  – вектор информативных признаков объекта классификации (вектор входных атрибутов);

$l_1, l_2, \dots, l_m$  – классы решений;

$y$  – результат классификации.

Нечеткий классификатор представляет собой отображение  $\mathbf{X} = (x_1, x_2, \dots, x_n) \rightarrow y \in \{l_1, l_2, \dots, l_m\}$  на основе базы нечетких правил. Основываясь на [2], базу правил нечеткого классификатора запишем так:

$$\text{Если } (x_1 = \tilde{a}_{1j} \text{ и } x_2 = \tilde{a}_{2j} \text{ и } \dots \text{ и } x_n = \tilde{a}_{nj} \text{ с весом } w_j), \text{ тогда } y = d_j, \quad j = \overline{1, k}, \quad (1)$$

где  $k$  – количество правил;  $d_j \in \{l_1, l_2, \dots, l_m\}$  – значение консеквента  $j$ -го правила;  $w_j \in [0, 1]$  – весовой коэффициент, задающий достоверность  $j$ -го правила,  $j = \overline{1, k}$ ;  $\tilde{a}_{ij}$  – нечеткий терм, оценивающий атрибут  $x_i$  в  $j$ -ом правиле,  $i = \overline{1, n}$ ,  $j = \overline{1, k}$ .

Классификацию текущего объекта, заданного вектором  $\mathbf{X}^* = (x_1^*, x_2^*, \dots, x_n^*)$ , осуществляют следующим образом. Сначала рассчитывают степень выполнения  $j$ -го правила из базы (1):

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

где  $\mu_j(x_i^*)$  – степень принадлежности значения  $x_i^*$  нечеткому терму  $\tilde{a}_{ij}$ ;  $\wedge$  – t-норма, которую обычно реализуют операцией минимума или умножением.

Степени принадлежности входного вектора  $\mathbf{X}^*$  классам  $l_1, l_2, \dots, l_m$  рассчитывают так:

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

Нечетким решением задачи классификации будет нечеткое множество

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

Результатом логического вывода выберем ядро нечеткого множества (4), то есть класс с максимальной степенью принадлежности:

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

Возможна ситуация, когда в ядро нечеткого множества (4) входят несколько элементов. Тогда объект одновременно принадлежит нескольким классам с одинаковыми степенями, значение которых равно  $\max_{s=1, m} \left( \mu_{l_s}(y^*) \right)$ . Для выбора одного из этих конкурентных классов

применим схему на основе единственного правила-победителя. По этой схеме среди правил конкурентных классов выбираем правило с максимальной степенью выполнения.

## 2. Критерии обучения нечеткого классификатора

Обучающую выборку из  $M$  пар “входы – выход” запишем так:

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

где  $\mathbf{X}_r = (x_{r1}, x_{r2}, \dots, x_{rm})$  - входные атрибуты  $r$ -го объекта;  $y_r \in \{l_1, l_2, \dots, l_m\}$  - класс  $r$ -го объекта.

Введем следующие обозначения:

$\mathbf{P}$  – вектор параметров функций принадлежности нечетких термов из базы правил (1);

$\mathbf{W}$  – вектор весовых коэффициентов правил из базы (1);

$F(\mathbf{K}, \mathbf{X}_r) \in \{l_1, l_2, \dots, l_m\}$  – результат классификации по базе нечетких правил (1) с параметрами  $\mathbf{K} = (\mathbf{P}, \mathbf{W})$  для входного вектора  $\mathbf{X}_r$  из  $r$ -ой строки выборки (5).

Обучение нечеткого классификатора состоит в нахождении вектора  $\mathbf{K}$ , минимизирующего частоту ошибок классификации на тестовой выборке. При этом для настройки параметров используют только обучающую выборку (5). Обучение рассматривают как задачу оптимизации. Она заключается в нахождении таких значений управляемых переменных  $\mathbf{K}$ , которые минимизируют расстояние между результатами логического вывода и экспериментальными данными из выборки (5). Это расстояние, которое назовем критерием обучения, можно определить различными способами.

**Критерий 1** – частота ошибок классификации [4]:

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

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

Преимущества критерия заключаются в его простоте и ясной содержательной интерпретации. Целевая функция в задачи оптимизации по этому критерию принимает дискретные значения, что затрудняет использование быстрых градиентных методов оптимизации, особенно для малых обучающих выборок.

**Критерий 2** – квадратичная невязка между двумя нечеткими множествами – желаемыми и реальными результатами классификации [2]. Для ее расчета значения выходной переменной  $y$  в обучающей выборке фазсифицируют следующим образом:

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

Критерий обучения учитывает расстояние между логическим выводом в форме нечеткого множества (4) и желаемого нечеткого значения выходной переменной (7):

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

где  $D_r(\mathbf{K}) = \sum_{s=1, m} (\mu_{l_s}(y_r) - \mu_{l_s}(\mathbf{K}, \mathbf{X}_r))^2$  – расстояние между желаемым и действительным выходными нечеткими множествами при классификации  $r$ -го объекта из обучающей выборки (5).

Для расчета  $D_r(\mathbf{K})$  используют евклидову метрику:

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

где  $\mu_{l_s}(y_r)$  – степень принадлежности  $r$ -го объекта из обучающей выборки классу  $l_s$  согласно (7);  $\mu_{l_s}(\mathbf{K}, \mathbf{X}_r)$  – рассчитанная по (3) степень принадлежности классу  $l_s$  выхода нечеткой модели с параметрами  $\mathbf{K}$  в случае входного вектора  $\mathbf{X}_r$ .

Преимущество критерия  $Crit_2$  состоит в учете меры уверенности в принятом решении на основе степеней принадлежности объекта разным классам. В критерии  $Crit_1$  эту информацию игнорируют, т. е. неважно насколько степень принадлежности у решения больше, чем у других альтернатив: на 0.0001 или на 1. Другими словами, в случае  $Crit_1$  считают, что результат классификации объекта является абсолютно достоверным. Кроме того, целевая функция для задачи оптимизации по критерию  $Crit_2$  не содержит протяженных плато, поэтому обучать нечеткий классификатор можно с помощью быстрых градиентных методов. Близкие к границам классов объекты вносят почти одинаковый вклад в критерий обучения (8) как при правильной, так и при ошибочной классификации, поэтому обучение может быть нерезультативным.

**Критерий 3** – квадратичная невязка между нечеткими желаемыми и реальными результатами классификации с дополнительным штрафом за ошибочно принятое решение [5 - 8]. Этот критерий наследует преимущества двух предыдущих критериев. Идея состоит в увеличении расстояния  $D$  для ошибочно классифицированных объектов:

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

где  $p > 0$  – штрафной коэффициент.

**Критерий 4** – расстояние между главными конкурентами со штрафом за ошибочное решение. Это новый критерий обучения. Идея этого критерия заключается в учете разницы принадлежностей нечеткого вывода только к главным конкурентам. По алгоритму логического вывода решением выбирают класс с максимальной степенью принадлежности. Обозначим этот класс-победитель как *win* и присвоим ему первый ранг.

В случае правильной классификации главным конкурентом принятого решения является *vicewin* – класс со вторым рангом, то есть класс со второй по величине степенью принадлежности (рис. 1а). Чем больше разница между степенями принадлежности к классам *win* и *vicewin*, тем больше уверенность в логическом выводе и тем дальше объект находится от границы раздела классов.

Обозначим через  $\text{smax}$  операцию нахождения второго по величине элемента множества. Тогда для  $r$ -го объекта выборки (5)  $\mu_{win}(\mathbf{X}_r) = \max_{s=1, m} (\mu_{l_s}(\mathbf{X}_r))$  и  $\mu_{vicewin}(\mathbf{X}_r) = \text{smax}_{s=1, m} (\mu_{l_s}(\mathbf{X}_r))$ .

Соответственно разница между главными конкурентами составляет  $\mu_{win}(\mathbf{X}_r) - \mu_{vicewin}(\mathbf{X}_r)$ .

При неправильной классификации ошибочно принятое решение будет главным конкурентом правильного класса (рис. 1б). Следовательно желательно уменьшить разницу между степенями принадлежности к ошибочному решению и к правильному классу. Разницу между главными конкурентами в этом случае запишем так:  $\mu_{win}(\mathbf{X}_r) - \mu_{y_r}(\mathbf{X}_r)$ .




Рис. 1. Главные конкуренты:  
а) правильная классификация; б) ошибочная классификация

В критерии обучения будем учитывать относительные показатели, разделив разницу на степень принадлежности класса-победителя. При правильной классификации относительная разница равна  $D_r^1 = \frac{\mu_{win}(\mathbf{X}_r) - \mu_{vicewin}(\mathbf{X}_r)}{\mu_{win}(\mathbf{X}_r)}$ , а при неправильной –  $D_r^0 = \frac{\mu_{win}(\mathbf{X}_r) - \mu_{y_r}(\mathbf{X}_r)}{\mu_{win}(\mathbf{X}_r)}$ .

Кроме того, аналогично критерию 3, при ошибочной классификации взвесим разницу штрафным коэффициентом. Математически критерий обучения запишем следующим образом:

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

где  $p \geq 1$  – штрафной коэффициент.

Для примера рассчитаем расстояние (11) по результатам логического вывода из рис. 1. При правильной классификации (рис. 1а) расстояние равно:  $D_a^1 = \frac{0.8 - 0.5}{0.8} = 0.375$ . В случае ошибочной классификации (рис. 1б) при штрафном коэффициенте  $p = 3$  расстояние равно:  $D_b^0 = 3 \cdot \frac{0.8 - 0.2}{0.8} = 2.25$ .

**Критерий 5** – квадратичное расстояние между главными конкурентами с штрафом за ошибочное решение. Этот критерий является модификацией предыдущего. Отличие заключается в использовании не абсолютных расстояний, а их квадратов:

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

Возведение в квадрат в  $Crit_5$  позволяет увеличить вклад в критерии обучения больших отклонений и нивелировать вклад малых отклонений.

#### 4. Компьютерные эксперименты

Целью экспериментов является выявление критерия, обучение по которому обеспечивает наилучшую безошибочность. Рассматриваем тестовую задачу Wine Dataset из UCI Machine Learning Repository. Она заключается в выявлении сорта винограда ( $y$ ), из которого изготовлено вино. База данных содержит результаты лабораторных анализов по 13-ти показателям 178 образцов итальянских вин, изготовленных в одном регионе. Для каждого образца указан один из трех сортов винограда, из которого изготовлено вино.

Обучающую выборку сформируем из строк базы данных с предельными значениями каждого из 13 атрибутов. Дополнительно в обучающую выборку включим все нечетные строки базы данных. Все остальные данные занесем в тестовую выборку. В результате получим обучающую выборку из 100 строк и тестовую – из 78. Спроектируем нечеткий классификатор вин по трем признакам:  $x_7$  – flavanoids,  $x_{10}$  – color intensity и  $x_{13}$  – proline. По распределению экспериментальных данных (рис. 2) сформируем нечеткую базу знаний (табл. 1) с пятью правилами. Нечеткие термы зададим гауссовой функцией принадлежности:

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

где  $b$  – координата максимума и  $c > 0$  – коэффициент концентрации.

Параметры функций принадлежности начального нечеткого классификатора приведены в табл. 2.

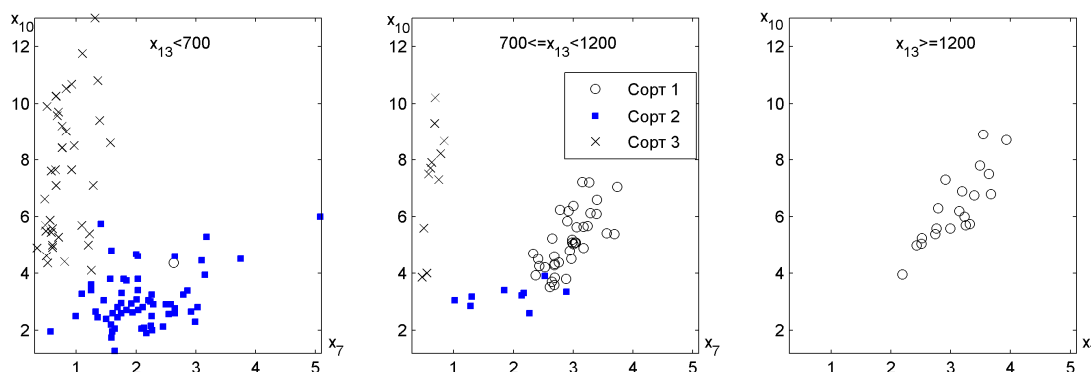


Рис. 2. Распределение данных в Wine Database

Таблица 1

№	$x_7$	$x_{10}$	$x_{13}$	$y$
1	–	–	Высокий	Сорт 1
2	Высокий	Высокий	Средний	Сорт 1
3	–	Низкий	Низкий	Сорт 2
4	Низкий	Низкий	Средний	Сорт 2
5	Низкий	Высокий	–	Сорт 3

Таблица 2

Параметры функций принадлежности термов нечеткого классификатора вина

Входная переменная	Терм	Параметры	
		$b$	$c$
$x_7$	Низкий	2	0.34
	Высокий	2	5.08
$x_{10}$	Низкий	6	1.28
	Высокий	6	13
$x_{13}$	Низкий	3	2.78
	Средний	3	10
	Высокий	3	16.8

Для каждого критерия проведем 1 000 экспериментов по обучению нечеткой базы знаний на основе квазиньютоновского алгоритма. После обучения каждый классификатор проверим на тестовой выборке по частоте ошибок (критерий  $Crit_1$ ). Во время обучения настроим весовые коэффициенты первых четырех правил. Достоверность пятого правила не вызывает сомнений, поэтому, в соответствии с [9], его весовой коэффициент настраивать не будем. Настроим коэффициенты концентрации ( $c$ ) функции принадлежности каждого нечеткого термина. Для сохранения интерпретируемости базы знаний согласно [10] будем настраивать координаты максимумов ( $b$ ) функций принадлежности только некрайних термов. В базе знаний лишь один некрайний терм – "средний", координату максимума которого и будем менять. Таким образом, общее количество настраиваемых параметров составляет  $4 + 7 + 1 = 12$ . Начальные точки для обучения выберем случайно: для весовых коэффициентов правил с диапазона  $[0, 1]$ , а для параметров функций принадлежности – в пределах  $\pm 30\%$  от значений табл. 2.

Проведем две серии экспериментов. Первую серию для нечеткого классификатора с реализацией t-нормы операцией минимума ( $\min$ ), а вторую – с реализацией t-нормы операцией произведения ( $\text{prod}$ ). В экспериментах по обучению по критериям  $Crit_3$ ,  $Crit_4$  и  $Crit_5$  сначала определим приемлемый уровень штрафного коэффициента. Для этого проведем по 200 экспериментов для  $p = 1, 3, \dots, 9$ . Результаты экспериментов (рис. 3 и 4, табл. 3) показали, что обучение происходит существенно лучше, если для критерия  $Crit_3$   $p = 1$ . Для критериев  $Crit_3$  и  $Crit_5$  качество обучения не так чувствительно к штрафному коэффициенту. Когда t-норма реализована операцией минимума, лучшей безошибочности достигают, если  $p = 3$  для  $Crit_4$  и  $p = 5$  для  $Crit_5$ . Когда t-норма реализована произведением, лучшей безошибочности достигают, если  $p = 5$  для  $Crit_4$  и  $p = 3$  для  $Crit_5$ . Именно при таких значениях штрафного коэффициента проведем остальные 800 экспериментов.

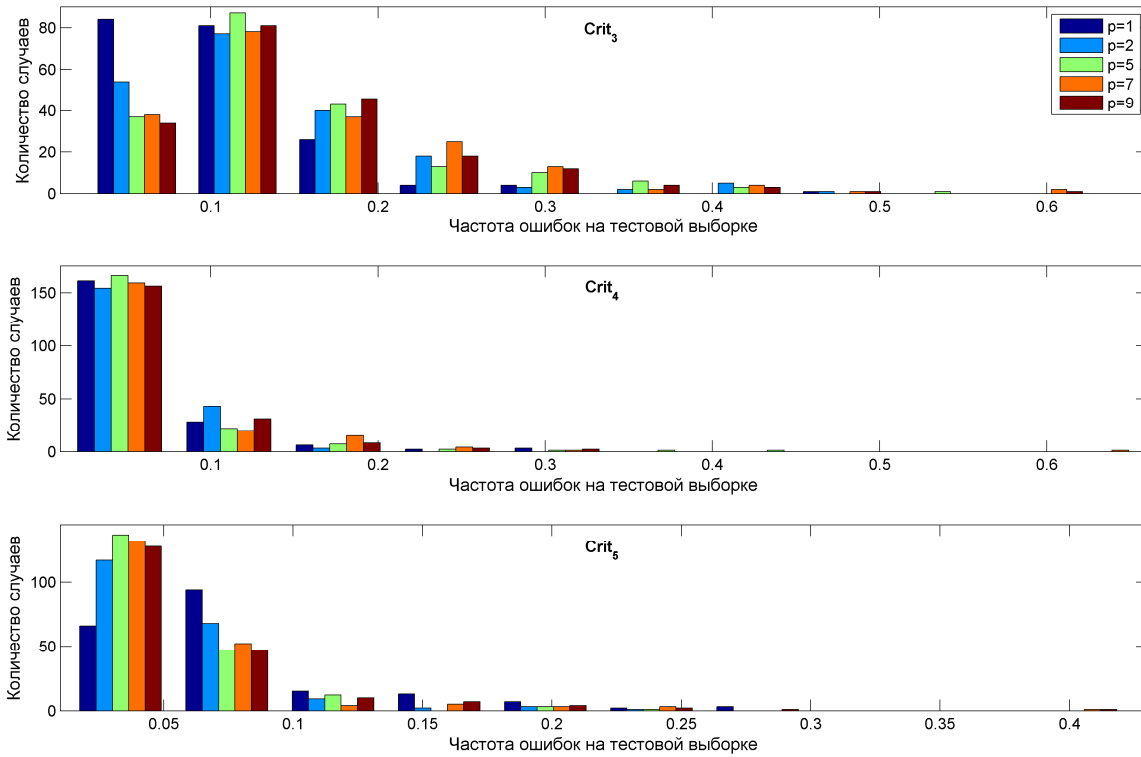


Рис. 3. Влияние штрафного коэффициента на безошибочность классификатора, в котором t-норма реализована операцией минимума

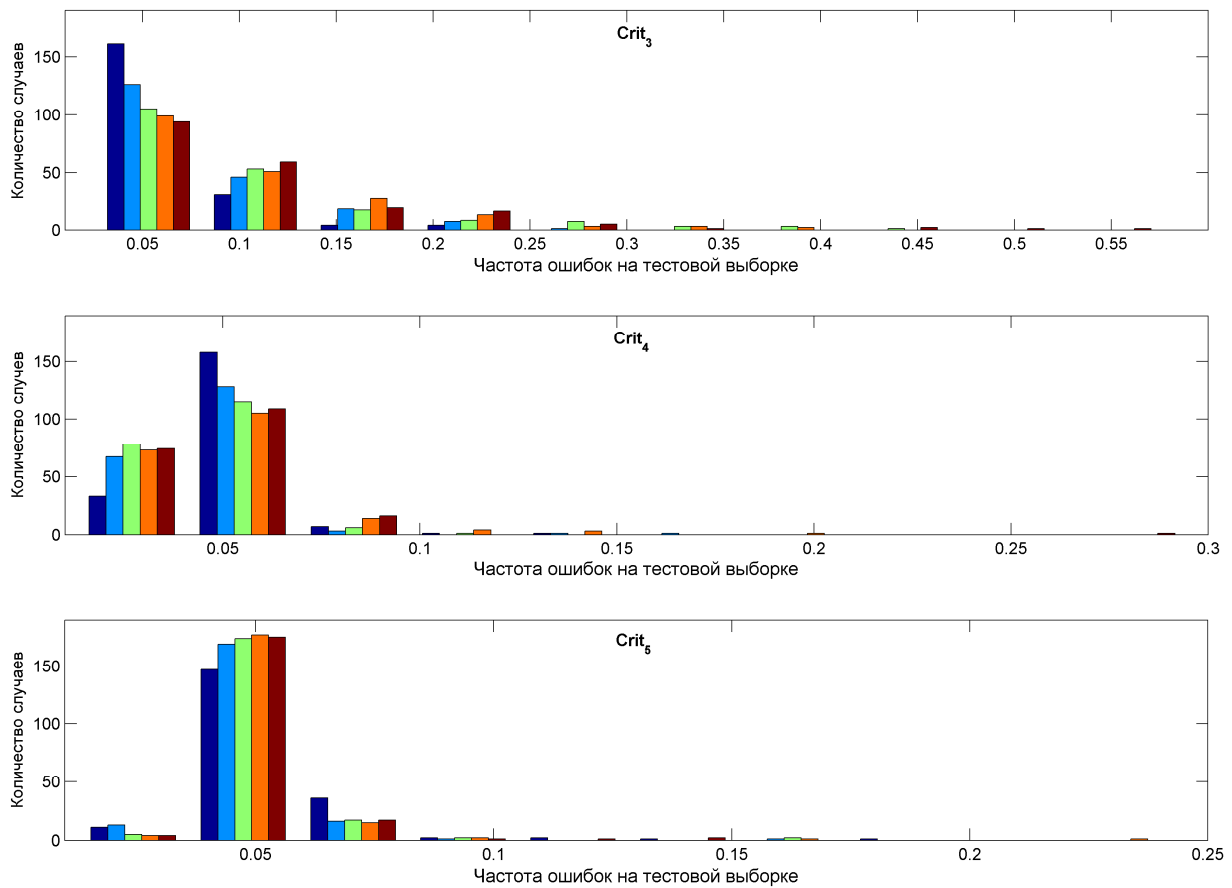


Рис. 4. Влияние штрафного коэффициента на безошибочность классификатора, в котором t-норма реализована операцией произведения



Таблица 3

**Влияние штрафного коэффициента в критерии обучения на безошибочность классификатора на тестовой выборке (полу жирным выделены лучшие результаты)**

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

Результаты экспериментов показали корреляцию значений критериев  $Crit_1 - Crit_5$  на обучающей выборке с частотой ошибок на тестовой выборке (рис. 5). Соответственно эти критерии можно применять для обучения нечеткого классификатора с голосующими правилами. Качество обучения (табл. 4 и рис. 6, 7) существенно лучше при использовании новых критериев  $Crit_4$  и  $Crit_5$ . Новые критерии обеспечивают лучшую безошибочность как в среднем (табл. 4), так и по количеству лучших случаев обучения. Среди новых критериев незначительное преимущество имеет  $Crit_5$ .

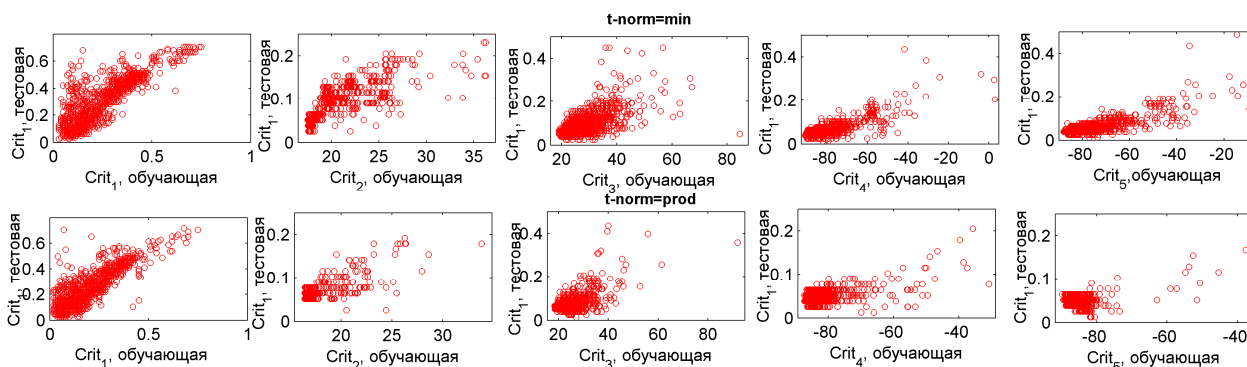


Рис. 5. Распределение результатов обучения нечеткого классификатора

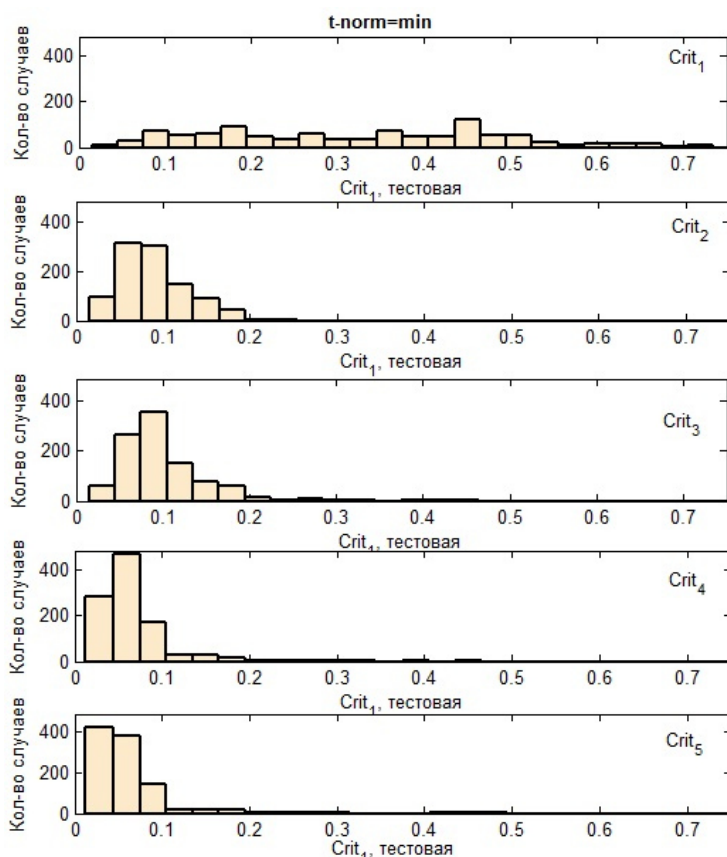


Рис. 6. Распределение качества обучения классификатора, t-норму которого реализовано минимумом

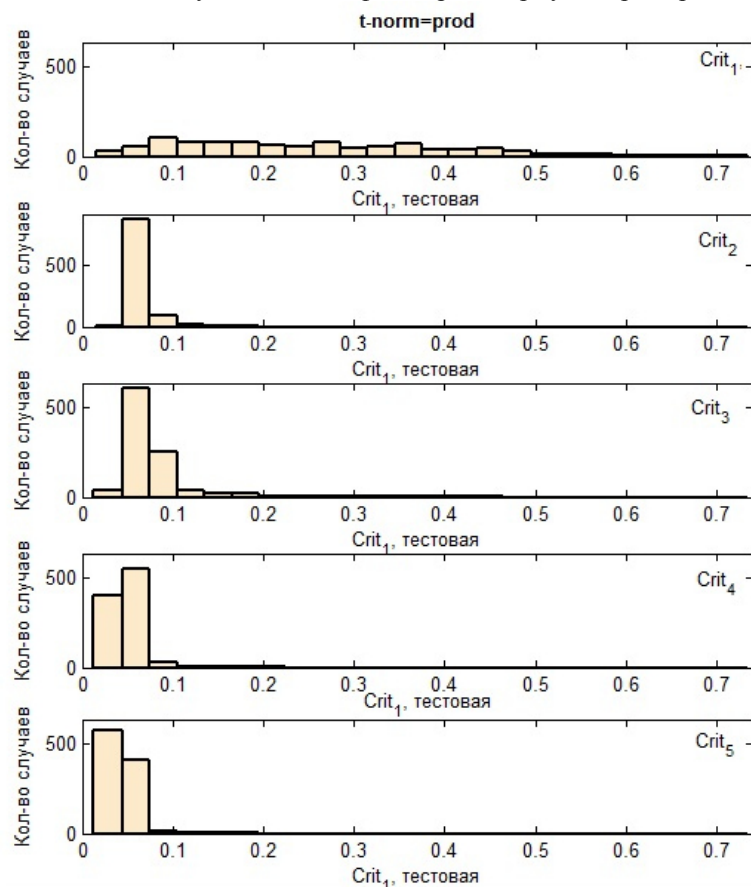


Рис. 7. Распределение качества обучения классификатора, t-норму которого реализовано произведением

Статистика обучения нечетких классификаторов (полу жирным выделены лучшие результаты)

t-норма	Критерий обучения	Частота ошибок ( $Crit_1$ ) на тестовой выборке			
		минимальное	среднее	медианное	максимальное
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	<b>0.0598</b>	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	<b>0.0451</b>	0.0385	0.1667

### Выводы

Впервые реализовано обучение нечеткого классификатора с голосующими правилами не только по частоте ошибок, но и по другим критериям обучения. Это такие критерии как: квадратичная невязка между двумя нечеткими множествами – желаемыми и реальными результатами классификации; квадратичная невязка между нечеткими желаемыми и реальными результатами классификации с дополнительным штрафом за ошибочное решение; расстояние между главными конкурентами со штрафом за ошибочное решение; квадратичное расстояние между главными конкурентами со штрафом за ошибочное решение. Критерии на основе расстояния между главными конкурентами являются новыми, а остальные применяли для обучения нечеткого классификатора по схеме вывода на основе единственного правила победителя.

Проведенные компьютерные эксперименты по настройке нечеткого классификатора для УС-задачи по распознаванию итальянских вин показали существенное преимущество новых критериев обучения. Среди новых критериев обучения небольшое преимущество имеет критерий в форме квадратичного расстояния между главными конкурентами со штрафом за ошибочное решение.

*Публикация содержит результаты исследований, проведенных при грантовой поддержке Государственного фонда фундаментальных исследований по конкурсному проекту №62 / 201-2015.*

### СПИСОК ЛИТЕРАТУРЫ

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 Наукові праці ВНТУ, 2015, № 4

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 Сергей Дмитриевич** – д. т. н., профессор, профессор кафедры компьютерных систем управления, Email: shtovba@ksu.vntu.edu.ua.

**Галуцак Анастасия Владимировна** – ассистент кафедры компьютерных систем управления, Email: nastya.nahorna@gmail.com.

Винницкий национальный технический университет.