

УДК 658.012

С. Д. Штовба, д. т. н., проф.; Е. В. Штовба, к. э. н.; О. Д. Панкевич, к. т. н., доц.

КРИТЕРИИ ТОЧНОСТИ И КОМПАКТНОСТИ ДЛЯ ОЦЕНКИ КАЧЕСТВА НЕЧЕТКИХ БАЗ ЗНАНИЙ В ЗАДАЧАХ ИДЕНТИФИКАЦИИ

Качество нечеткой базы знаний рассматривается как свойство модели исследуемой зависимости удовлетворить требования заказчика по многим критериям, среди которых наиболее популярными являются точность и компактность. Исследуются нечеткие базы знаний, моделирующие три типа зависимостей с выходом в виде четкого числа, нечеткого числа или класса решения. Для каждого типа зависимости систематизированы критерии точности соответствующих нечетких баз знаний. Для оценивания компактности нечеткой базы знаний описано 9 известных частных критериев и предложено 5 новых.

Ключевые слова: нечеткая база знаний, критерии качества, точность, компактность, нечеткая идентификация.

Введение

Предпосылкой успешной разработки теории формализованного проектирования нечетких баз знаний является определение термина «качество нечетких баз знаний». Проще всего качество отождествить с точностью, т. е. с отклонением результатов нечеткого вывода от экспериментальных данных. Этот подход, который доминирует в современной теории нечеткой идентификации, привел к ряду негативных результатов. С 1990-х годов в нечетком научном сообществе стартовала «гонка» за точностью, в результате которой разработан ряд методов проектирования высокоточных нечетких баз знаний. Однако полученные по этим методам нечеткие базы знаний потеряли важное конкурентное преимущество – способность описывать исследуемую зависимость буквально несколькими естественными высказываниями, понятными заказчику – специалистам прикладных областей без специальной математической квалификации. Такие высокоточные нечеткие базы знаний заказчики воспринимают как набор непонятных чисел, которым они не привыкли доверять при принятии важных решений. Таким образом, при решении прикладных задач нечеткой идентификации, кроме точности, следует учитывать и другие критерии качества нечетких баз знаний.

Вопрос о необходимости обеспечения баланса между точностью и количеством правил нечеткой базы знаний впервые поднят в [1]. В этой статье нечеткие базы знаний применяют для задач классификации. Позже появились работы о балансе между точностью и компактностью нечетких баз знаний других типов, а также о балансе между другой парой критериев – точностью и интерпретируемостью. За последние 2 года опубликовано несколько важных статей [2 – 9] по многокритериальной теории нечеткой идентификации.

В статьях [2, 3] с помощью компьютерных экспериментов показано, что для задачи выбора правил зависимость точности нечеткой базы знаний от ее компактности является квадратичной. Для задач параметрической идентификации с настройкой функций принадлежности термов нечеткой базы знаний наблюдалась экспоненциальная зависимость точности от компактности [4, 5]. В статье [6] разработан метод решения одной из задач структурной нечеткой идентификации, а именно: выбора правил нечеткой базы знаний с учетом точности и компактности. Новизна метода состоит в использовании вместо типовых пороговых уровней точности и компактности [1] линейного ограничения, задающего механизм компенсации между этими противоречивыми критериями. При новом ограничении удается существенно сократить область допустимых решений, сузив ее до окрестности парето-фронта.

В статье [7] предложен подход к идентификации на основе синглтонных нечетких баз знаний с учетом, кроме требований точности, еще и прозрачности, т. е. согласованности внутренней структуры модели с ее внешним поведением. В этой статье под согласованностью понимают возможность предсказания поведения модели в ключевых точках факторного пространства без осуществления нечеткого логического вывода. Такими ключевыми точками являются ядра нечетких антецедентов правил. Для обеспечения прозрачности введено ограничение на то, чтобы в каждой ключевой точке соответствующее правило базы знаний выполнялось с единичной степенью принадлежности, а другие правила вообще не активировались.

В статье [8] предложен подход к идентификации с учетом следующих трёх составляющих интерпретабельности нечеткой базы знаний: 1) нечеткое разбиение переменных должно соответствовать условиям семантической целостности; 2) база знаний должна быть компактной и достаточной; 3) в каждом правиле должны фигурировать только информативные признаки, т. е. правила могут быть неполными (короткими).

В статье [9] предложен подход к идентификации зависимостей в задачах классификации с учетом безошибочности и интерпретабельности нечеткой базы знаний. Интерпретабельность предлагается оценивать посредством согласованности явной и скрытой семантики нечеткой базы знаний.

В статье [10] дается обзор подходов к определению термина «интерпретабельность нечеткой базы знаний» и предложена их таксономия. Таксономия осуществляется по сложности и семантической модели на 2 уровнях: на уровне правил базы знаний и на уровне нечеткого разбиения лингвистических переменных. Показано, что термин «интерпретабельность нечеткой базы знаний» и ее метрики еще не общеприняты, поэтому требуют дальнейшей формализации и обобщения. Обзор [10] написан по 75 работам.

Таким образом, возникла необходимость в формализованном определении качества нечеткой базы знаний как свойства модели удовлетворить требования заказчика по многим критериям, такими как: точность, компактность, прозрачность, интерпретабельность и т. д. Следующим шагом станет разработка алгоритмов расчета указанных частных критериев качества для любой нечеткой базы знаний. И наконец, следует разработать методы обеспечения желаемого качества с учетом многих критериев на основе системного подхода к нечеткому моделированию. **Целью** статьи является разработка критериев точности и компактности нечетких баз знаний, которые используют для моделирования зависимостей с непрерывным, дискретным и нечетким выходом.

1. Классификация задач нечеткой идентификации

Рассмотрим объект идентификации типа MISO с n входами $\mathbf{X} = (x_1, x_2, \dots, x_n)$ и одним выходом y . Предлагаем задачи идентификации классифицировать по типу выходной переменной y (рис. 1).

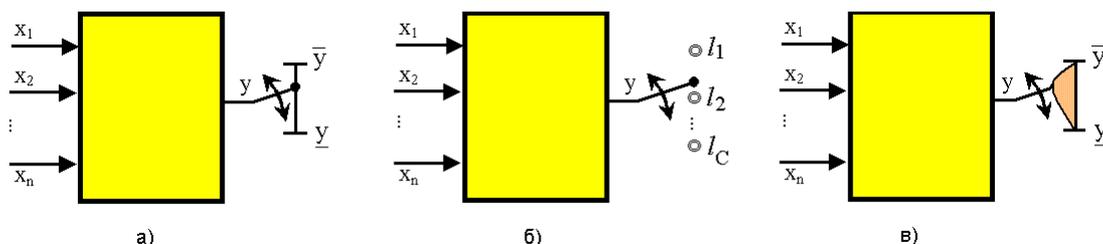


Рис. 1. Классификация задач нечеткой идентификации
а) непрерывный выход; б) дискретный выход; в) нечеткий выход

При непрерывном выходе (рис. 1а) значением выходной переменной y будет обычное

действительное число из диапазона $[\underline{y}, \bar{y}]$. Идентификацию таких зависимостей чаще всего осуществляют с помощью нечетких баз знаний Сугено и Мамдани [11 – 13].

При дискретном выходе (рис. 1б) значением выходной переменной y будет элемент из счетного множества $\{l_1, l_2, \dots, l_C\}$, который содержательно интерпретируется как класс решения. Идентификацию таких зависимостей целесообразно проводить с помощью нечетких классификационных баз знаний [1, 11, 14].

При нечетком выходе (рис. 1в) значением выходной переменной будет нечеткое число. Соответственно, отображение $\mathbf{X} = (x_1, x_2, \dots, x_n) \rightarrow \tilde{y}$ можно рассматривать как нечеткую функцию. Для идентификации таких зависимостей применяют три подхода.

В первом подходе [15, 16] используют нечеткую базу знаний, консеквенты правил которой заданы нечеткими множествами. Общей ключевой чертой логического вывода по таким базам знаний является продуцирование на выходе нечеткого множества

$$\tilde{y} = \int_{y \in [\underline{y}, \bar{y}]} \mu_{\tilde{y}}(y) / y, \tag{1}$$

где $\mu_{\tilde{y}}(y)$ – степень принадлежности числа $y \in [\underline{y}, \bar{y}]$ выходному нечеткому множеству \tilde{y} .

Результат получим в форме нечеткого множества (1) после логического вывода по базе знаний Мамдани [12], по реляционной базе знаний Педрича [17] и по нечеткой базе знаний с нечеткими регрессионными уравнениями [18]. Вывод по этим нечетким базам знаний проводим без дефаззификации. После этого иногда необходимы дополнительные процедуры по нормализации и исправлению невыпуклости выходного нечеткого множества (рис. 2).

Преобразование невыпуклых нечетких множеств в нечеткие числа осуществляется аппроксимацией параметрическими функциями принадлежности. При этом для расчета невязки между двумя нечеткими множествами $\tilde{A} = \int_{y \in [\underline{y}, \bar{y}]} \mu_{\tilde{A}}(y) / y$ и $\tilde{B} = \int_{y \in [\underline{y}, \bar{y}]} \mu_{\tilde{B}}(y) / y$

применяют формулу:

$$RMSE(\tilde{A}, \tilde{B}) = \sqrt{\frac{\int_{\underline{y}}^{\bar{y}} (\mu_{\tilde{A}}(y) - \mu_{\tilde{B}}(y))^2 dy}{\bar{y} - \underline{y}}}. \tag{2}$$



Рис. 2. Невыпуклые нечеткие множества, полученные по алгоритму Мамдани

Во втором подходе используют нечеткую базу знаний с четкими консеквентами, например, синглтонную нечеткую базу знаний или базу знаний Сугено. Последнюю процедуру логического вывода – дефаззификацию – не проводим. Соответственно, на выходе получаем нечеткое множество на дискретном носителе, которое преобразуем в нечеткое число \tilde{y} , аппроксимируя непрерывной параметрической функцией принадлежности. Параметры этой функции принадлежности подбираем таким образом, чтобы минимизировать среднеквадратичную невязку между степенями принадлежности

двух нечетких множеств. При этом результаты дефаззификации дискретного и непрерывного нечетких множеств должны совпадать. На рис. 3 приведены примеры такой аппроксимации с помощью типовых и специальных функций принадлежности из статьи [16].

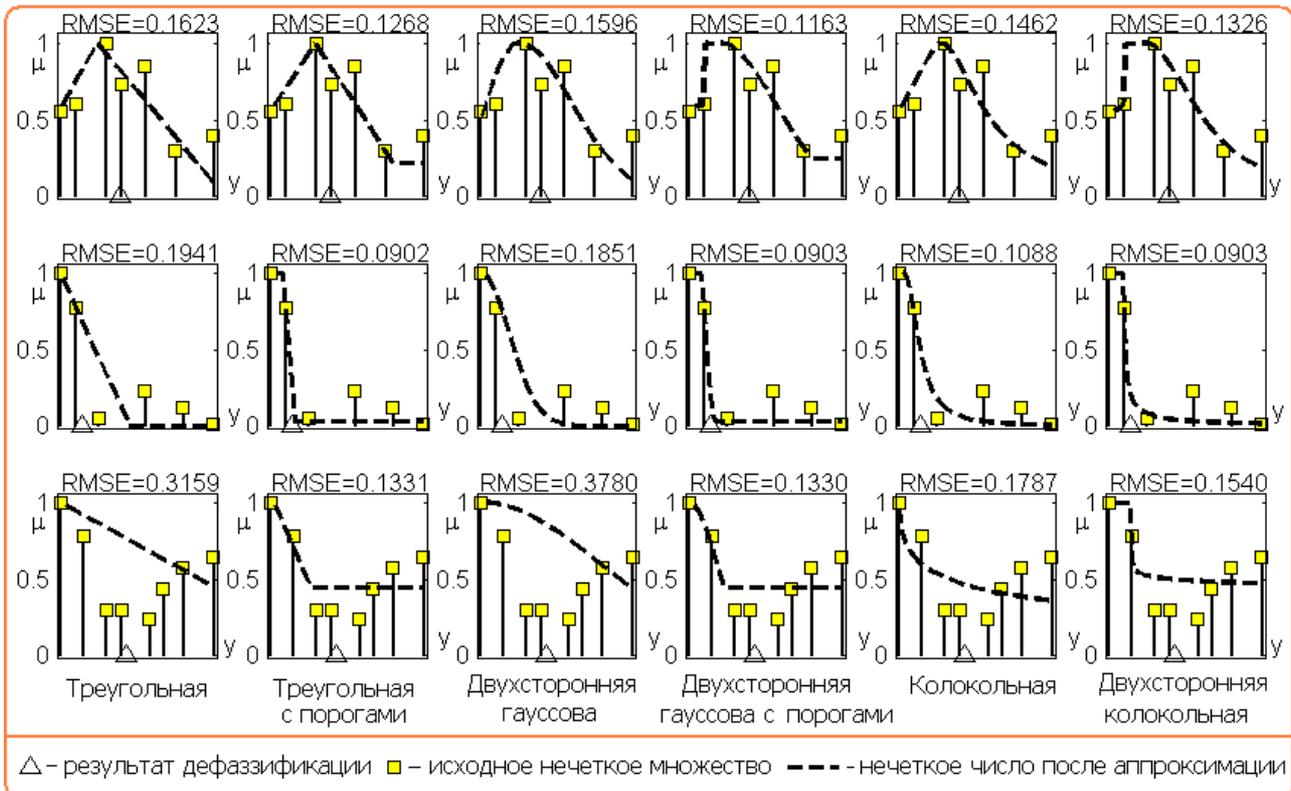


Рис. 3. Аппроксимация невыпуклых дискретных нечетких множеств параметрическими функциями принадлежности

В третьем подходе [15, 16] предполагается, что для каждой точки факторного пространства соответствующее нечеткое число \tilde{y} задается параметрической функцией принадлежности одного и того же типа. Для описания зависимости параметров этой функции принадлежности от (x_1, x_2, \dots, x_n) используется нечеткая база знаний типа ММО, которая имеет несколько входных и несколько выходных переменных. Входные переменные тождественны входам (x_1, x_2, \dots, x_n) исследуемой зависимости. Каждая выходная переменная базы знаний задает один из параметров функции принадлежности нечеткого числа \tilde{y} . Для описания таких зависимостей подходят различные нечеткие базы знаний, в результате логического вывода по которым получаем четкие числа. Например, нечеткая база знаний Мамдани будет состоять из правил типа:

Если x_1 ="Низкий" и x_2 ="Высокий", то y_1 ="Средний" и y_2 ="Малый",

где y_1 и y_2 – параметры функции принадлежности выходного нечеткого числа \tilde{y} , например, коэффициент концентрации и координата максимума колокольной функции принадлежности.

2. Критерии точности для задач с непрерывным выходом

Для оценивания точности считаем, что известна следующая выборка данных:

$$(\mathbf{X}_r, y_r), y_r \in [y, \bar{y}], r = \overline{1, M}, \quad (3)$$

где \mathbf{X}_r и y_r – пара данных «входы – выход» в r -ой строчке выборки; M – объем выборки.

Обозначим через $y = F(\mathbf{X})$ модель на основе нечеткой базы знаний, связывающей входы \mathbf{X} с выходом y исследуемой зависимости. Для задачи с непрерывным выходом точность идентификации на выборке (3) по методу наименьших квадратов определяется так:

$$RMSE = \sqrt{\frac{1}{M} \sum_{r=1, M} (y_r - F(\mathbf{X}_r))^2} .$$

Популярность критерия точности $RMSE$ обусловлена гладкостью целевой функции на этапе параметрической идентификации, что позволяет применять быстрые градиентные методы оптимизации. Недостатком является то, что невязку минимизируют в среднем, а это не исключает больших ошибок в отдельных зонах факторного пространства. Для защиты от таких выбросов критерием точности можно выбрать максимальную абсолютную невязку [19]:

$$MaxErr = \max_{r=1, M} |y_r - F(\mathbf{X}_r)| .$$

Критерии $RMSE$ и $MaxErr$ коррелированы, но обычно нечеткая база знаний, минимизирующая невязку по одному из них, не является наилучшей и по другому критерию.

3. Критерии точности для задач с дискретным выходом

Предположим, что известна следующая выборка данных:

$$(\mathbf{X}_r, y_r), \quad y_r \in \{l_1, l_2, \dots, l_C\}, \quad r = \overline{1, M}, \quad (4)$$

где $\{l_1, l_2, \dots, l_C\}$ – классы решений.

Для задачи с дискретным выходом критерием точности обычно выбирают частоту ошибок классификации на выборке (4):

$$MCR = \frac{\sum_{r=1, M} \Delta_r}{M}, \quad (5)$$

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

Преимущества критерия (5) заключаются в его простоте и наглядной интерпретации. Недостаток критерия (5) связан с тем, что не учитываются степени принадлежности выбранной и конкурентных альтернатив, т. е. остается без внимания «уверенность» нечеткого классификатора при выборе одного решения из множества $\{l_1, l_2, \dots, l_C\}$. Это происходит потому, что в результате вывода для текущего входного вектора \mathbf{X}^* из полученного нечеткого класса

$$\tilde{y}(\mathbf{X}^*) = \left(\frac{\mu_{l_1}(\mathbf{X}^*)}{l_1}, \frac{\mu_{l_2}(\mathbf{X}^*)}{l_2}, \dots, \frac{\mu_{l_C}(\mathbf{X}^*)}{l_C} \right) \quad (6)$$

выбирают одну альтернативу с максимальной степенью принадлежности. Сомнения относительно правильности выбранного решения возникают, когда альтернативы имеют приблизительно равные степени принадлежности.

Для учета уровня уверенности при принятии решений в [14] предложен критерий точности в форме расстояния между экспериментальными данными и результатами нечеткой классификации. Для этого значение выходной переменной в выборке (4) фазифицируют следующим образом:

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

Далее для каждого объекта рассчитывают расстояние между результатами нечеткой классификации (6) и желанными нечеткими значениями выходной переменной (7). Соответственно критерий точности на всей выборке (4) записывают следующим образом [14]:

$$FD = \sqrt{\frac{1}{M} \sum_{r=1, M} D_r}, \quad (8)$$

где $D_r = \sum_{j=1, C} (\mu_{l_j}(y_r) - \mu_{l_j}(X_r))^2$ – расстояние между желаемым и полученным выходными нечеткими множествами при классификации r -го объекта;

$\mu_{l_j}(y_r)$ – степень принадлежности значения переменной из r -й строки выборки данных (4) классу l_j согласно (7);

$\mu_{l_j}(X_r)$ – степень принадлежности входного вектора X_r классу l_j , рассчитанная в результате нечеткого вывода.

Проведенные в [11, 20, 21] компьютерные эксперименты свидетельствуют, что в некоторых случаях минимизирующая (8) нечеткая база знаний не обеспечивает близкую к минимальной частоту ошибок классификации (5). Это объясняется тем, что близкие к границам раздела классов объекты вносят почти одинаковый вклад в критерий точности (8) как при правильной, так и при ошибочной классификации. Поэтому в [20] предложен новый критерий, наследующий преимущества предыдущих. Идея заключается в увеличении расстояния D_r для ошибочно классифицированных объектов. В результате критерий точности становится таким:

$$PFD = \sqrt{\frac{1}{M} \sum_{r=1, M} (\Delta_r \cdot penalty + 1) \cdot D_r}, \quad (9)$$

где $penalty > 0$ – штрафной коэффициент.

При известных ценах на ошибки классификации разных типов значения Δ_r в (5) и (9) определяют по платежной матрице.

4. Критерий точности для задач с нечетким выходом

Будем считать известной следующую выборку данных:

$$(X_r, \tilde{y}_r), \text{ supp}(\tilde{y}_r) \in [y, \bar{y}], r = \overline{1, M}, \quad (10)$$

где \tilde{y}_r – выходное значение в r -й строке выборки, заданное нечетким числом на носителе $\text{supp}(\tilde{y}_r)$.

Для задачи с нечетким выходом критерий точности на выборке (10) определен таким образом [15, 16]:

$$RMSE = \sqrt{\frac{1}{M} \sum_{r=1, M} RMSE(\tilde{y}_r, \tilde{F}(X_r))^2},$$

где $\tilde{F}(X_r)$ – нечеткое число, полученное в результате логического вывода по нечеткой базе

знаний для входного вектора \mathbf{X}_r ; $RMSE(\tilde{y}_r, \tilde{F}(\mathbf{X}_r))$ – невязка (2) между двумя нечеткими числами, соответствующими желаемому и полученному результатам логического вывода.

5. Критерии компактности нечеткой базы знаний

Для оценки компактности нечетких баз знаний используют такие частные критерии [1 – 5, 8, 10]:

n – количество входных переменных модели;

N_{rules} – количество правил в базе знаний;

N_{r1} – количество правил в базе знаний, в antecedенте которых только одна переменная, т. е. количество правил с antecedентами длиной в один элемент;

N_{r2} – количество правил в базе знаний с antecedентами длиной в два элемента;

N_{r3} – количество правил в базе знаний с antecedентами длиной в три элемента;

N_{vr} – суммарная длина antecedентов всех правил базы знаний;

N_{x_i} – мощность терм-множества входной переменной x_i , $i = \overline{1, n}$;

$N_x^{total} = \sum_{i=1, n} N_{x_i}$ – суммарное количество термов входных переменных;

$RF = \frac{N_{rules}}{N_{max}}$ – уровень наполненности базы знаний правилами, где $N_{max} = \prod_{i=1, n} N_{x_i}$ –

максимально возможное количество правил.

Дополнительно к этим критериям предлагаем следующие:

RF_a – средний уровень наполненности правилами иерархической базы знаний;

$AF = \frac{N_{vr}}{n \cdot N_{max}}$ – уровень наполненности antecedентов правил базы знаний;

AF_a – средний уровень наполненности antecedентов иерархической базы знаний;

N_H – суммарное количество настраиваемых параметров базы знаний;

N_{infer} – количество логических выводов по иерархической базе знаний.

Интегральный критерий компактности можно определить сверткой некоторого подмножества приведенных выше частных критериев. Целесообразность включения тех или иных частных критериев в интегральный определяется спецификой соответствующей задачи идентификации.

Выводы и прогноз будущих исследований

Качество нечеткой базы знаний следует рассматривать как свойство модели исследуемой зависимости удовлетворить требования заказчика по многим критериям, таким как: точность, компактность, прозрачность, интерпретабельность и т. д. Нами рассмотрены нечеткие базы знаний трех типов, в результате логического вывода по которым на выходе получаем четкое число, нечеткое число или класс решения. Для каждого типа базы знаний систематизированы критерии точности. Для оценивания компактности описано 9 известных частных критериев и предложено 5 новых. Эти критерии учитывают количество входных переменных модели, количество правил в базе знаний, количество коротких правил в базе знаний, суммарную длину antecedентов всех правил базы знаний, мощности терм-множеств входных переменных, уровень наполненности базы знаний правилами, количество настраиваемых параметров базы знаний и т. п. Новые критерии преимущественно касаются иерархических нечетких баз знаний. Будущие исследования будут направлены на формализацию прозрачности и интерпретабельности нечетких баз знаний с последующей разработкой многокритериальных методов обеспечения желаемого качества нечеткой

ідентифікації багатофакторних залежностей.

СПИСОК ЛІТЕРАТУРИ

1. Ishibuchi H. Single-objective and two-objective genetic algorithms for selecting linguistic rules for pattern classification problems / H. Ishibuchi, T. Murata, I. B. Turksen // *Fuzzy Sets and Systems*. – 1997. – Vol. 89, No. 2 – P. 135 – 50.
2. Штовба С. Д. Вплив кількості нечітких правил на точність бази знань Мамдані / С. Д. Штовба, В. В. Мазуренко, О. Д. Панкевич // *Вісник Хмельницького національного університету. Технічні науки*. – 2011. – № 2. – С. 185 – 188.
3. Штовба С. Д. Залежність точності ідентифікації від обсягу нечіткої синглтоної бази знань / С. Д. Штовба, О. Д. Панкевич, В. В. Мазуренко // *Інформаційні технології та комп'ютерна інженерія*. – 2011. – № 1. – С. 73 – 78.
4. Штовба С. Д. Дослідження навчання компактних нечітких баз знань типу Мамдані / С. Д. Штовба, В. В. Мазуренко // *Штучний інтелект*. – 2011. – № 4. – С. 521 – 529.
5. Штовба С. Д. Дослідження навчання компактних нечітких синглтонних баз знань / С. Д. Штовба, В. В. Мазуренко // *Вимірювальна та обчислювальна техніка в технологічних процесах*. – 2011. – № 1. – С. 133 – 139.
6. Генетический алгоритм выбора правил нечеткой базы знаний, сбалансированной по критериям точности и компактности [Электронный ресурс] / С. Д. Штовба, В. В. Мазуренко, Д. А. Савчук // *Наукові праці Вінницького національного технічного університету*. – 2012. – №3. Режим доступу до журн.: http://www.nbu.gov.ua/e-journals/vntu/2012_3/2012-3_ru.files/ru/12sdsacc_ru.pdf.
7. Riid A. Identification of Transparent, Compact, Accurate and Reliable Linguistic Fuzzy Models / A. Riid, E. Rüstern // *Information Sciences*. – 2011. – Vol. 181, № 20. – P. 4378 – 4393.
8. Guillaume S. Learning interpretable fuzzy inference systems with FisPro // *Information Sciences* / S. Guillaume, B. Charnomordic // *Information Sciences*. – 2011. – Vol. 181, № 20. – P. 4409 – 4427.
9. Mencar C. Design of fuzzy rule-based classifiers with semantic cointension / C. Mencar, C. Castiello, R. Cannone, A. M. Fanelli // *Information Sciences*. – 2011. – Vol. 181, № 20. – P. 4361 – 4377.
10. Gacto M. J. Interpretability of linguistic fuzzy rule-based systems: An overview of interpretability measures / M. J. Gacto, R. Alcalá, F. Herrera // *Information Sciences*. – 2011. – Vol. 181, № 20. – P. 4340 – 4360.
11. Штовба С. Д. Проектирование нечетких систем средствами MATLAB / С. Д. Штовба. – М.: Горячая линия. – Телеком, 2007. – 288 с.
12. Mamdani E. H. An Experiment in Linguistic Synthesis with Fuzzy Logic Controller / E. H. Mamdani, S. Assilian // *Int. J. Man-Machine Studies*. – 1975. – Vol. 7, № 1. – P. 1 - 13.
13. Takagi T. Fuzzy Identification of Systems and Its Applications to Modeling and Control / T. Takagi, M. Sugeno // *IEEE Trans. on Systems, Man, and Cybernetics*. – 1985. Vol. 15, № 1. – P. 116 - 132.
14. Ротштейн А. П. Интеллектуальные технологии идентификации: нечеткая логика, генетические алгоритмы, нейронные сети / А. П. Ротштейн. – Вінниця: УНІВЕРСУМ–Вінниця, 1999. – 320 с.
15. Штовба С. Д. Настройка нечеткой модели по обучающей выборке с нечетким выходом / С. Д. Штовба // *Кибернетика и системный анализ*. – 2007. – № 3. – С. 26 – 32.
16. Штовба С. Д. Навчання нечіткої бази знань за вибіркою нечітких даних / С. Д. Штовба // *Штучний інтелект*. – 2006. – № 4. – С. 560 – 570.
17. Pedrycz W. An Identification Algorithm in Fuzzy Relational Systems / W. Pedrycz // *Fuzzy Sets and Systems*. – 1984. – № 13. – P. 153 – 167.
18. Штовба С. Д. Моделювання залежностей за допомогою нечіткої бази знань з нечіткими регресійними рівняннями / С. Д. Штовба // *Вісник Вінницького політехнічного інституту*. – 2011. – № 3. – С. 195 – 199.
19. Ротштейн А. П. Моделирование надежности человека-оператора с помощью нечеткой базы знаний Сугено / А. П. Ротштейн, С. Д. Штовба // *Автоматика и телемеханика*. – 2009. – № 1. – С. 180 – 187.
20. Shtovba S. Tuning the Fuzzy Classification Models with Various Learning Criteria: the Case of Credit Data Classification / S. Shtovba, O. Pankevich, G. Dounias // *Fuzzy Sets and Soft Computing in Economics and Finance : intern. conference, 17 – 20 June 2004 : proc.*, Vol. 1. – St. Petersburg (Russia), 2004. – P. 103 – 110.
21. Штовба С. Д. Порівняння критеріїв навчання нечіткого класифікатора / С. Д. Штовба // *Вісник Вінницького політехнічного інституту*. – 2007. – № 6. – С. 84 – 91.

Штовба Сергей Дмитриевич – профессор, д. т. н., профессор кафедры компьютерных систем управления.

Штовба Елена Валериевна – к. э. н., доцент кафедры менеджмента и моделирования в экономике.

Панкевич Ольга Дмитриевна – доцент, к. т. н., доцент кафедры теплогазоснабжения.

Винницкий национальный технический университет.