

Исследование устойчивости нейро-нечёткой системы вывода, основанной на методе отношения площадей

Н. А. Милостная¹ ✉

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: nat_mil@mail.ru

Резюме

Цель исследования: исследование гипотезы о возможности изменения вида переходного процесса во время обучения нейро-нечёткой системы вывода, основанной на методе соотношения площадей, и изучения свойств влияния весового коэффициента на её устойчивость.

Методы. Для разработки нейро-нечёткой системы вывода в статье используется аппарат нечёткой логики. При этом входные и выходные переменные описываются треугольными функциями принадлежности, в композиционном правиле использовалась модель импликации Мамдани. При дефаззификации применялась линейная модель отношения площадей. Во время обучения использовался метод обратного распространения ошибки.

Результаты. В ходе экспериментальных исследований было установлено, что предложенная нейро-нечёткая модель, основанная на методе отношения площадей, позволяет изменять вид переходного процесса, а именно преобразовать колебательный процесс в апериодический (монотонный) процесс. Также в ходе экспериментальных исследований было установлено, что на устойчивость нейро-нечёткой системы вывода в большей степени влияет весовой коэффициент, определяемый при расчете общей площади выходных функций принадлежности. Таким образом, полученные результаты доказывают: во-первых, что предложенная нейро-нечёткая система вывода обеспечивает трансформацию передаточных характеристик, а во-вторых, обеспечивает её устойчивость в заданном диапазоне характеристик весового коэффициента.

Заключение. В статье представлена архитектура адаптивной нейро-нечёткой системы вывода, основанной на линейном методе отношения площадей. Отличительной особенностью предлагаемой архитектуры является использование на входах и выходе нечёткой системы треугольных функций принадлежности. Анализ имитационного процесса её обучения показал, что при обучении с целью обеспечения устойчивости необходимо устанавливать допустимые значения весового коэффициента, численные значения которого, в свою очередь, влияют на трансформацию передаточных характеристик нейро-нечёткой системы вывода.

Ключевые слова: адаптивная нейро-нечёткая система вывода; метод отношения площадей; обучение; устойчивость.

Конфликт интересов: Автор декларирует отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Финансирование: Работа выполнена в рамках государственного задания ГЗ № 0851-2020-0032.

Для цитирования: Милостная Н. А. Исследование устойчивости нейро-нечёткой системы вывода, основанной на методе отношения площадей // Известия Юго-Западного государственного университета. 2021; 25(3): 70-85. <https://doi.org/10.21869/2223-1560-2021-25-3-70-85>.

Поступила в редакцию 26.08.2021

Подписана в печать 14.09.2021

Опубликована 21.10.2021

Stability Study of a Neuro-Fuzzy Output System Based on Ratio Area Method

Natalya A. Milostnaya ¹ ✉

¹ Southwest State University
50 Let Oktyabrya str. 94, Kursk 305040, Russian Federation

✉ e-mail: tanygin@yandex.com

Abstract

Purpose of research is to study the hypothesis about the possibility of changing the type of transition process during training in a neuro-fuzzy inference system based on area ratio method, and to study the properties of weight coefficient influence on its stability.

Methods. An apparatus of fuzzy logic is used for the development of a neuro-fuzzy output system. At the same time, input and output variables are described by triangular membership functions. Mamdani implication model was used in the compositional rule. A linear model of area ratio was used in defasification. The reverse error propagation method was used during training.

Results. In experimental studies, it was found that the proposed neuro-fuzzy model based on area ratio method allows to change the type of transition process, namely, to transform oscillatory process into an aperiodic (monotonic) process. In experimental studies, it was also found that the stability of neuro-fuzzy output system is more influenced by the weight coefficient determined in calculating the total area of membership output functions. Thus, the obtained results prove: first, that the proposed neuro-odd output system ensures the transformation of transfer characteristics, and second, ensures its stability in a given range of weight coefficient characteristics.

Conclusion: The architecture of an adaptive neuro-fuzzy output system based on a linear method of area ratio is described. A distinctive feature of the proposed architecture is the use of an odd system of triangular accessory functions at inputs and outputs. Analysis of the simulation process of its training showed that it is important to ensure stability during training. It is also necessary to establish permissible values of the weight coefficient, numerical values of which in its turn affect the transformation of transfer characteristics of a neuro-fuzzy output system.

Keywords: adaptive neuro-fuzzy output system; area ratio method; training; sustainability.

Conflict of interest. The author declare the absence of obvious and potential conflicts of interest related to the publication of this article.

Funding: Work carried out within the framework of the state law № 0851-2020-0032.

For citation: Milostnaya N. A. Stability Study of a Neuro-Fuzzy Output System Based on Ratio Area Method. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta* = *Proceedings of the Southwest State University*. 2021; 25(3): 70-85 (In Russ.). <https://doi.org/10.21869/2223-1560-2021-25-3-70-85>.

Received 26.08.2021

Accepted 14.09.2021

Published 21.10.2021

Введение

Модели рассуждений, основанные на нечётком выводе, являются эффективным инструментом для создания систем с искусственным интеллектом. Подобные системы часто используются в задачах распознавания образов [1], высокоскоростной обработки деталей [2], прогнозирования различных ситуаций [3, 4] и моделирования сложных систем управления [5]. Для улучшения численных характеристик интеллектуальных систем используются гибридные модели, например ANFIS-NARX. Эта модель включает адаптивную нейро-нечёткую систему вывода (ANFIS – adaptive neuro-fuzzy inference system) и нелинейную авторегрессивную модель с экзогенным входом (NARX – nonlinear autoregressive with exogenous input). В статье [6] авторы показали, что точность оценки предложенного метода ANFIS-NARX намного лучше, чем динамический метод NARX, основанный на искусственной нейронной сети.

В другой гибридной сети (ANN-FL) алгоритм Такаги-Сугено используется для разработки адаптивных нейро-нечётких систем логического вывода, который представляет собой сочетание двух технологий: искусственных нейронных сетей (ANN) и нечёткой логики (FL) [7]. В данной модели – нечёткий вывод используется для получения выходной переменной, при этом если она не совпадает с требуемым значением,

то искусственная нейронная сеть обучает её веса ANFIS [8].

Как правило, точность моделей ANFIS оценивается с помощью коэффициента корня из среднеквадратической ошибки (RMSE – root mean square error). Например, в статье [8] оценивалось моделирование и обучение процесса одновременной адсорбции красителя и иона металла с помощью ANN и ANFIS. Все имитационные эксперименты доказывают, что точность ANFIS выше, чем ANN в 2 и более раза. Алгоритмы обучения ANFIS подразделяются на популяционные алгоритмы (PBA – population-based algorithms) и производные (DBC – derivative-based calculations). Основанные на PBA алгоритмы обучения ANFIS используют гибридные технологии, такие как генетические алгоритмы (GA – genetic algorithms) [9], алгоритмы оптимизации роя частиц (PSO – particle swarm optimization algorithms), алгоритмы искусственных пчелиных семей (ABS – artificial bee colony algorithms) и алгоритмы имитации отжига (SA – simulated annealing algorithms) [10, 11, 12, 13]. Экспериментальные результаты, представленные в этих статьях, показывают, что точность ANFIS в 2 раза выше, чем у алгоритмов GA и в 2 раза ниже, чем у алгоритмов PSO. Алгоритмы GA, PSO и ABS являются популяционными алгоритмами. Общим недостатком этих алгоритмов является

длительное вычислительное время для поиска оптимального решения. Производные алгоритмы DBC с использованием моделей наименьших квадратов (LS – Least Squares) и градиентного спуска (GD – Gradient Descent) рассмотрены в работах [14, 15]. Для их обучения используются следующие машины вывода: машины опорных векторов наименьших квадратов (LS-SVM – least squares support vector machines) и машину, основанную на многоядерных алгоритмах регрессии опорных векторов наименьших квадратов (TS-LSSVR – Takagi–Sugeno system based on multi-kernel least squares support vector regression). В научных исследованиях было установлено, что алгоритм TS-LSSVR имеет лучшие характеристики по сравнению с моделями ANFIS и LS-SVM примерно в 3 раза. Существующие и модифицированные модели ANFIS имеют ряд недостатков, в том числе «проклятие измерения» [16], которое приводит к увеличению времени обучения нейро-нечёткой сети и снижения её точности. Проклятие размерности увеличивает число выводов нечёткого вывода в геометрической прогрессии с увеличением количества входных переменных или их функций принадлежности. Следовательно, время принятия решения в ANFIS увеличивается. Эту ошибку можно исправить, комбинируя нечёткие импликации в композиционном слое ANFIS [17–19]. Следует отметить, что точность нейро-нечётких си-

стем вывода зависит от модели дефаззификации, используемой в ANFIS. В статье [20] представлен подробный анализ традиционных и нетрадиционных моделей дефаззификации.

Таким образом основная цель ANFIS – оптимизировать параметры системы нечёткого вывода, используя один из алгоритмов обучения. Минимальное значение ошибки между целевым выходным значением и фактическим выходным значением является параметром оптимизации, оцененным, например, с использованием значения RMSE.

Материалы и методы

Математическая модель нейро-нечёткой системы вывода реализуется с помощью следующих математических операций.

Шаг 1. Фаззификация входных переменных. На этом этапе формируются входные и выходные функции принадлежности (ФП). Пусть вход нейро-нечёткой системы вывода имеет две входные переменные и одну выходную. Тогда для её построения рассмотрим следующую MISO-модель:

$$X_1 = \{x_{11}\} + \{x_{12}\} + \{x_{13}\}, \quad (1)$$

$$X_2 = \{x_{21}\} + \{x_{22}\} + \{x_{23}\}, \quad (2)$$

$$Y = \{y_1\} + \{y_2\} + \{y_3\} + \{y_4\} + \{y_5\}, \quad (3)$$

где X_1 , X_2 – входы нечёткой системы; Y – выход нечёткой системы.

Входные и выходные нечёткие переменные для нейро-нечёткой системы вывода представлены на рис. 1.

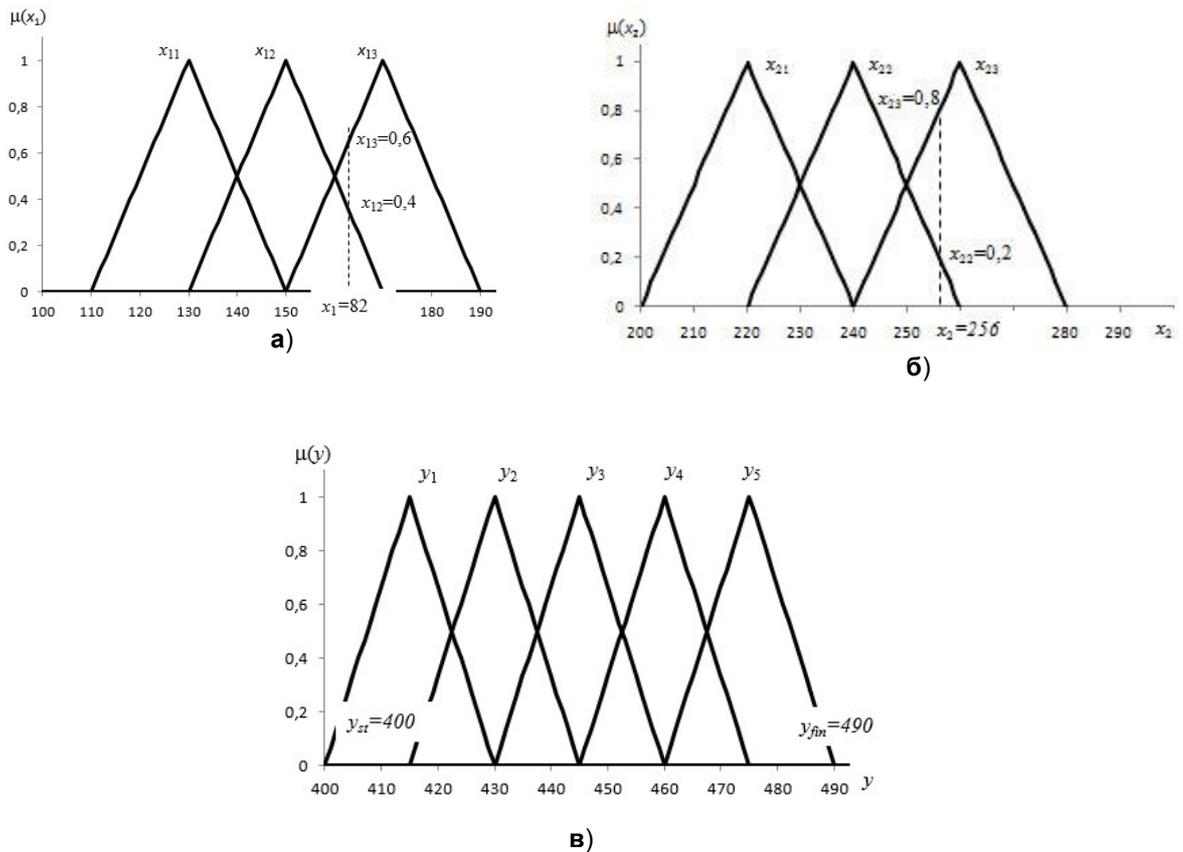


Рис.1. Функции принадлежности: а – первая ФП; б – вторая ФП; в – выходная ФП

Fig. 1. Membership function: а – first MF; б – second MF; в – output MF

В случае использования колоколообразных (Гауссовских) функций принадлежности, время вычисления площадей усеченных ФП в методе отношения площадей увеличивается, поэтому в

статье используются треугольные ФП, что в значительной степени позволяет сократить время их обучения.

Шаг 2. Расчёт степени активации функций принадлежности по формуле

$$\mu_{x_i}(x_{ij}) = trimf(x_{ij}; a, b, c) = \begin{cases} 0, & x_{ij} \leq a; \\ \frac{x_{ij} - a}{b - a}, & a \leq x_{ij} \leq b; \\ \frac{c - x_{ij}}{c - b}, & b \leq x_{ij} \leq c; \\ 0, & c \leq x_{ij}, \end{cases} \quad (4)$$

где a, b, c, d – лингвистические метки треугольных ФП; x_{ij} – четкое значение ядра нечёткого множества.

Шаг 3. Синтез нечётких правил (НП). Чтобы сформировать базу правил, которая определяет исходное соотно-

шение между входными и выходными переменными системы нечёткого вывода, необходимо создать базу нечётких правила вида «Если... То ...»:

FR_p : Если x_1 есть $\mu_{x1}(x_{ij}) \Theta_t$ x_2 есть $\mu_{x2}(x_{ij}) \Theta_t \dots$

$$\Theta_t x_i \text{ есть } \mu_{x_n}(x_{nm}) \quad (5)$$

Then y is y_k ,

где Θ_t – знак, обозначающий операцию t-норм (табл. 1); p – количество нечётких правил.

Шаг 4. Расчет степеней активации предпосылок нечётких правил по формуле:

$$\alpha_p = \mu_{x_1}(x_{1j}) \Theta_t \mu_{x_2}(x_{2j}) \Theta_t \dots \Theta_t \mu_{x_n}(x_{nm}). \quad (6)$$

Если несколько нечётких правил ссылаются на один и тот же выходной термин, то нечеткое правило активиру-

ется, и оно имеет максимальную степень вывода нечётких правил, используя формулу:

$$h_k = \alpha_1 \Theta_s \alpha_2 \Theta_s \dots \Theta_s \alpha_p, \quad (7)$$

где Θ_s – знак, обозначающий операцию s-норм (см. табл. 1).

Шаг 5. Формирование базы нечётких правил. Пусть MISO-система нейро-нечёткого контроллера имеет девять нечётких правил, которые сведены в табл. 2.

Таблица 1. Формулы t и s-норм

Table 1. Equations t and s-norm

t-норма (Θ_t) / t-norm (Θ_t)		s-норма (Θ_s) / s-norm (Θ_s)	
Мамдани I_M	$\min(x_{1j}; x_{2j});$ <i>if</i> $I = I_M$	Мамдани I_M	$\max_1^p(\alpha_p);$ <i>if</i> $I = I_M$
Произведение I_{PROD}	$x_{1j} \times x_{2j};$ <i>if</i> $I = I_{PROD}$	Произведение I_{PROD}	$\prod_1^p \alpha_p;$ <i>if</i> $I = I_{PROD}$
Лукашевича I_L	$\min(1, 1 - x_{1j} + x_{2j});$ <i>if</i> $I = I_L$	Алгебраическая сумма I_{AS}	$\alpha_p + \alpha_{p+1} - \alpha_p \times \alpha_{p+1};$ <i>if</i> $I = I_{AS}$
Разности границ I_{BD}	$\max(0, x_{1j} + x_{2j} - 1);$ <i>if</i> $I = I_{BD}$	Суммы границ I_L	$\min(1, \alpha_p + \alpha_{p+1});$ <i>if</i> $I = I_{BS}$
Мягкая I_{SOFT}	$\frac{x_{1j} + x_{2j} + \delta^2 - \sqrt{[x_{1j} - x_{2j}]^2 + \delta^2}}{2},$ $\delta = 0.05$ <i>if</i> $I = I_{SOFT}$	Мягкая I_{SOFT}	$\frac{\alpha_p + \alpha_{p+1} + \delta^2 + \sqrt{[\alpha_p - \alpha_{p+1}]^2 + \delta^2}}{2},$ $\delta = 0.05$ <i>if</i> $I = I_{SOFT}$

Таблица 2. База нечётких правил

Table 2. Base of fuzzy rules

НП	ЕСЛИ		ТО	НП	ЕСЛИ		ТО	НП	ЕСЛИ		ТО
НП ₁	x_{11}	x_{21}	y_5	НП ₄	x_{12}	x_{21}	y_4	НП ₇	x_{13}	x_{21}	y_3
НП ₂	x_{11}	x_{22}	y_4	НП ₅	x_{12}	x_{22}	y_3	НП ₈	x_{13}	x_{22}	y_2
НП ₃	x_{11}	x_{23}	y_3	НП ₆	x_{12}	x_{23}	y_2	НП ₉	x_{13}	x_{23}	y_1

Шаг 6. Дефаззификация методом отношения площадей [20]. На этом шаге необходимо определить общую площадь формы выходной переменной:

$$S_1 = k \cdot w \cdot \frac{d_1}{2}, \quad (8)$$

где k – количество термов выходной ФП ($k = 5$); w – весовой коэффициент; d_1 – ширина основания треугольной функции принадлежности.

Шаг 7. Вычисление площади преобразованных функций принадлежности, которые зависят от значений высоты предпосылок нечётких правил:

$$S_{1i} = \begin{cases} S_{1i} = 0, & \text{if } h = 0; \\ S_{1i} = \frac{d_1}{2}, & \text{if } h = 1; \\ S_{1i} = \frac{h}{2}(d_1 + d_3), & \text{if } h \in (0, 1). \end{cases} \quad (9)$$

Шаг 8. Определение общей площади фигуры с преобразованными функциями принадлежности следующим образом:

$$S_2 = \sum_{i=1}^k S_{1i}. \quad (10)$$

Шаг 9. Расчет отношения общей площади выходной переменной (см. Уравнение (8)) и общей площади с преобразованными функциями принадлежности (см. уравнение (10)) следующим образом:

$$D = \frac{S_2}{S_1}. \quad (11)$$

Переменная D всегда находится в диапазоне значений от 0 до 1. Чтобы

получить чёткое значение на выходе нечёткой системы, необходимо масштабировать значение переменной D в ядро выходной нечёткой переменной.

Шаг 10. Рассчитать чёткое значение на выходе нечёткой системы с линейной функцией следующим образом:

$$y_{defuz} = [D \cdot (y_{fin} - y_{st})] + y_{st} = \left[\frac{S_2}{S_1} \cdot (y_{fin} - y_{st}) \right] + y_{st}, \quad (12)$$

где y_{st} , y_{fin} – начальное и конечное значения ядра нечёткой ФП (см. рис.1в).

Шаг 11. Обучение нейро-нечёткой системы вывода. На этом этапе предлагаемая модель обучается с использованием метода ошибки обратного распространения по формуле

$$w_{output} = w_{output} + \sigma(y_{defuz} - y_{exp}), \quad \partial |y_{defuz} - y_{exp}| \leq T, \quad (13)$$

где w_{output} – весовой коэффициент; σ – скорость обучения нейро-нечёткого контроллера (по умолчанию равен 0,07); T – порог (по умолчанию равен 0,01).

Структурная схема нейро-нечёткой системы вывода показана на рис. 2.

Структурная схема нейро-нечёткой системы вывода, основанная на линейном методе отношения площадей и представленная на рис. 2, работает следующим образом. В блоке «Input» формируется входной сигнал для нечётких сигналов, описанных уравнениями (1)÷(3). В блоках «Degrees X1» и «Degrees X2» по формуле (4) осуществляется расчет степеней активации входных функций принадлежности.

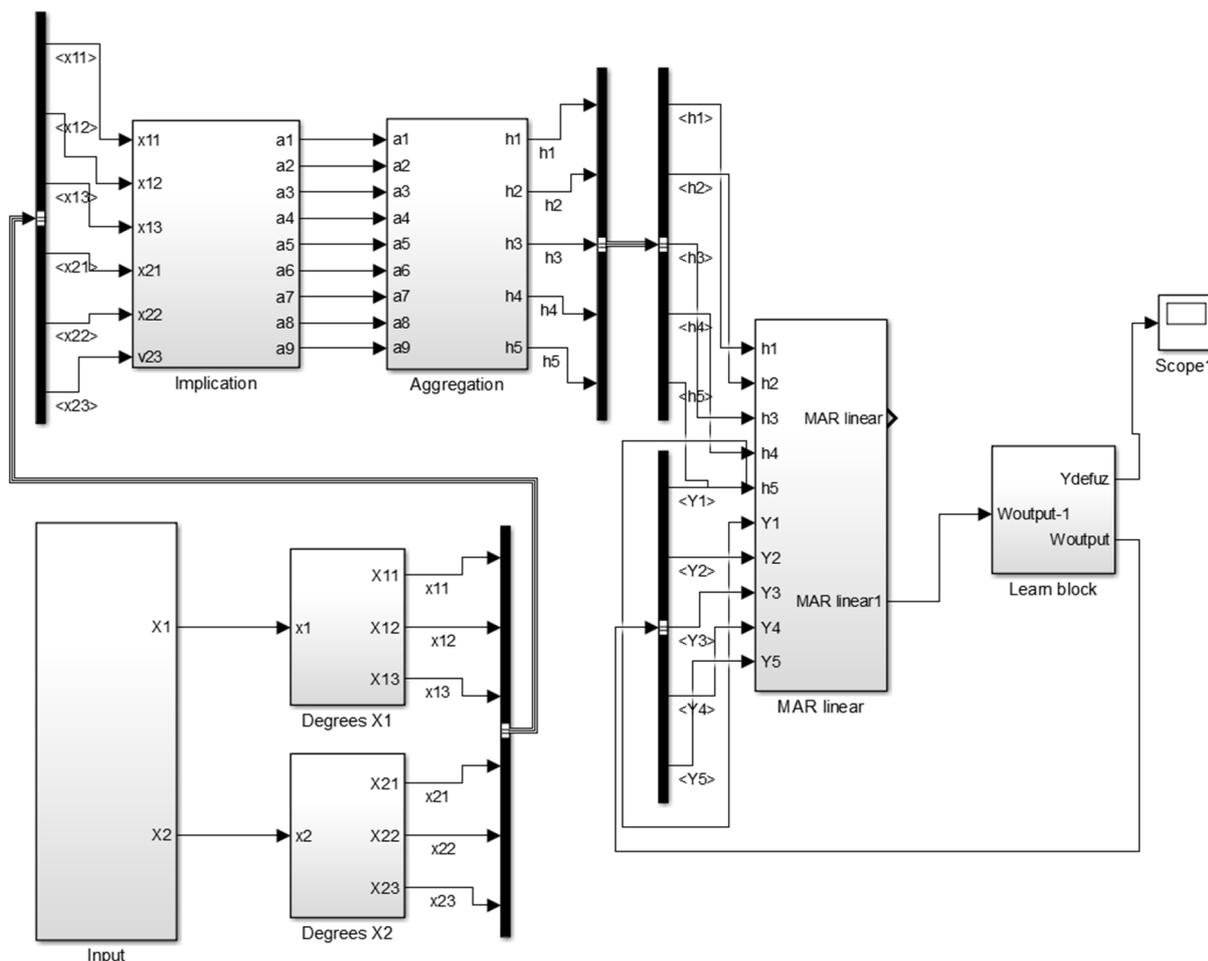


Рис. 2. Структурная схема нейро-нечёткой системы вывода

Fig. 2. Structural schime of neuro-fuzzy inference system

В блоке «Implication» по формуле (6) с помощью одной из t-норм (см. табл. 1) осуществляется расчёт степеней заключений нечёткого вывода. В случае, если несколько заключений ссылаются на одно и то же выходное нечёткое правило (см. табл. 2, например, НП₂ и НП₄), то в блоке «Aggregation» по формуле (7) с использованием одной из s-норм (см. табл. 1) осуществляется выбор наибольшего значения. В блоке «MAR linear» осуществляется по формулам (8)÷(12) дефазификация результирующей переменной на основе метода отношения площадей. В блоке

«Learn block» по уравнению (13) осуществляется обучение нейро-нечёткой системы вывода.

В следующем разделе рассмотрим исследование свойств устойчивости нейро-нечёткой системы вывода.

Результаты и их обсуждение

Во время экспериментальных исследований проводилось моделирование и исследование устойчивости нейро-нечёткой системы вывода, представленной на рис. 2 [21-25].

Следует отметить, что в большинстве нечётких систем для обеспечения ус-

тойчивости используется следующий метод. Управляющий регулятор наблюдает состояние входного объекта. Если состояние выходит за некоторые установленные границы, то управляющий регулятор запускает режим стабилизации, чтобы вернуть входной объект в область заданных условий его функционирования. Если сигнал стабилизации не позволяет перевести управляемый объект в область допустимых значений, то осуществляется отключение системы. На-

пример, структуры системы, представленной на рис. 2, при стабилизации входного сигнала, например, к значению 460 из ядра выходной нечёткой переменной (см. рис. 1в), при весовом коэффициенте $w = 0,07$ (см. фор. (8)) наблюдается неустойчивое состояние системы, которое представлено на рис. 3. Видно, что нейро-нечёткая система вывода не может обучить систему, находится в диапазоне значений [478; 442] и не может перейти к заданному значению 460.

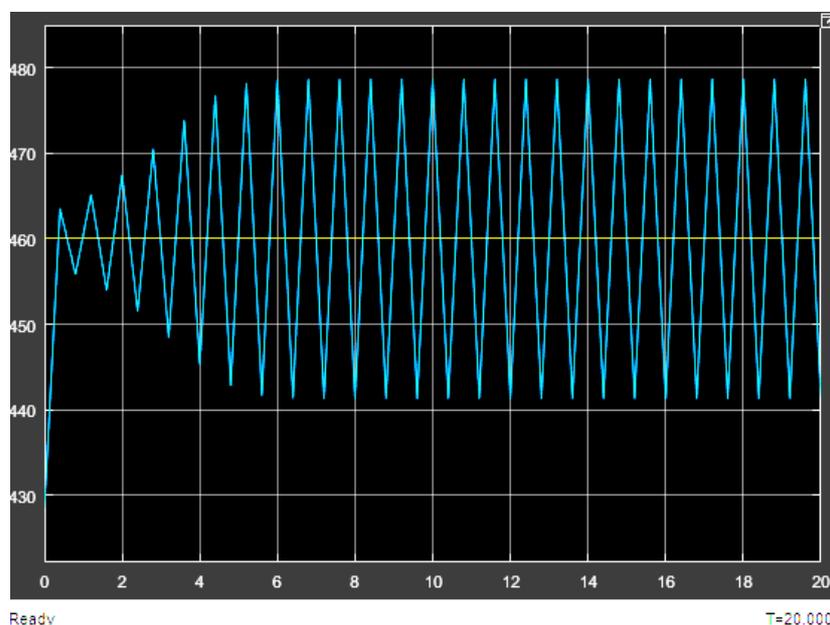


Рис. 3. Неустойчивое состояние нейро-нечёткой системы вывода

Fig. 3. Unstable condition of neuro-fuzzy inference system

На представленном рис. 3 под устойчивостью понимается состояние нейро-нечёткой системы вывода, если она обучает модель и состояние системы не выходит за заданные границы, установленные лицом, принимающим решение.

Таким образом, рассматриваемая нейро-нечёткая система вывода, используя круговой критерий устойчивости,

является глобально и асимптотически устойчивой, если круг с центром на вещественной оси в целевой точке

$$O = -0.5 \times \left(\frac{1}{\kappa_1} + \frac{1}{\kappa_2} \right)$$

и радиусом

$$r = 0.5 \times \left(\frac{1}{\kappa_1} - \frac{1}{\kappa_2} \right)$$

размещается целиком в области, прилегающей к левой части частотной характеристики линейной части системы, и не соприкасается с ней (рис. 4). При этом $k_1 \geq 0$ и $k_2 \geq 0$.

Рассмотрим передаточные характеристики процесса обучения нейро-не-

чёткой системы вывода. Так же, как и в предыдущем случае оставим центр обучения равным 460, но исследуем процесс влияния весового коэффициента w (см. фор. (8)) на устойчивость нейро-нечёткой системы вывода для двух центров 460 и 425.

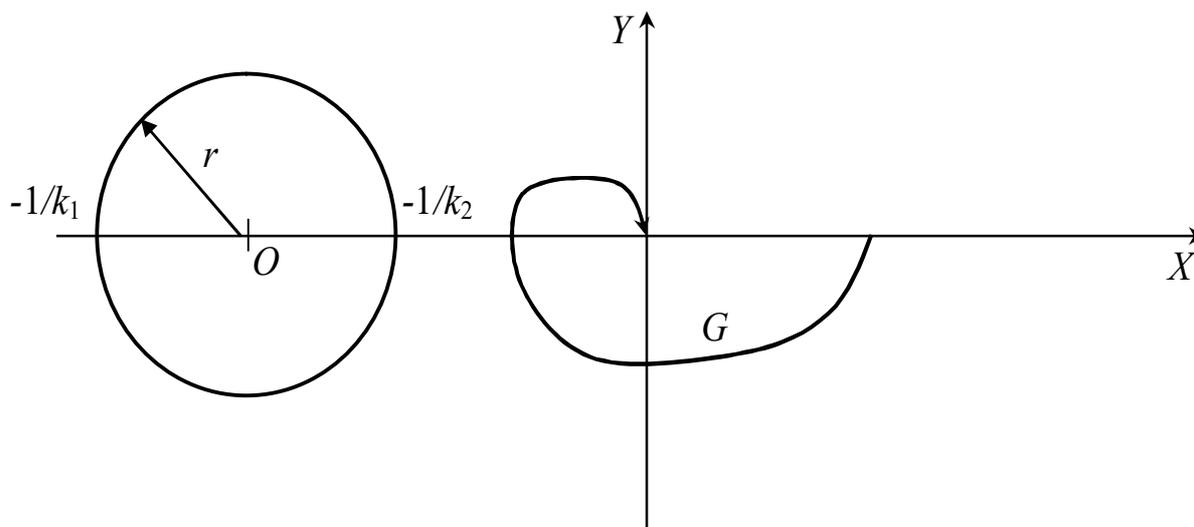


Рис. 4. Круговой критерий устойчивости нейро-нечёткой системы вывода

Fig. 4. Circular criterion for the stability of the neuro-fuzzy inference system

На основании полученных результатов, представленных на рис. 5 и рис. 6, подтверждена гипотеза о том, что нейро-нечёткая система, основанная на методе отношения площадей, позволяет изменять вид переходного процесса, то есть трансформировать его из колебательного в аperiodический (монотонный) процесс. В первом случае ($O=460$), на рис. 5в и 5г видно, что при значении весового коэффициента, равном $w=0,03$, осуществляется преобразование из одного вида переходной характеристики в другой. Во втором случае ($O=425$), на

рис. 6б и 6в видно, что при значении весового коэффициента, равном $w=0,1$, осуществляется преобразование из одного вида переходной характеристики в другой.

Также в ходе имитационного моделирования было установлено, что на устойчивость нейро-нечёткой системы вывода влияет диапазон числовых величин весового коэффициента, и были установлены допустимые границы весового коэффициента, необходимые для обеспечения устойчивости нейро-нечёткой системы вывода.

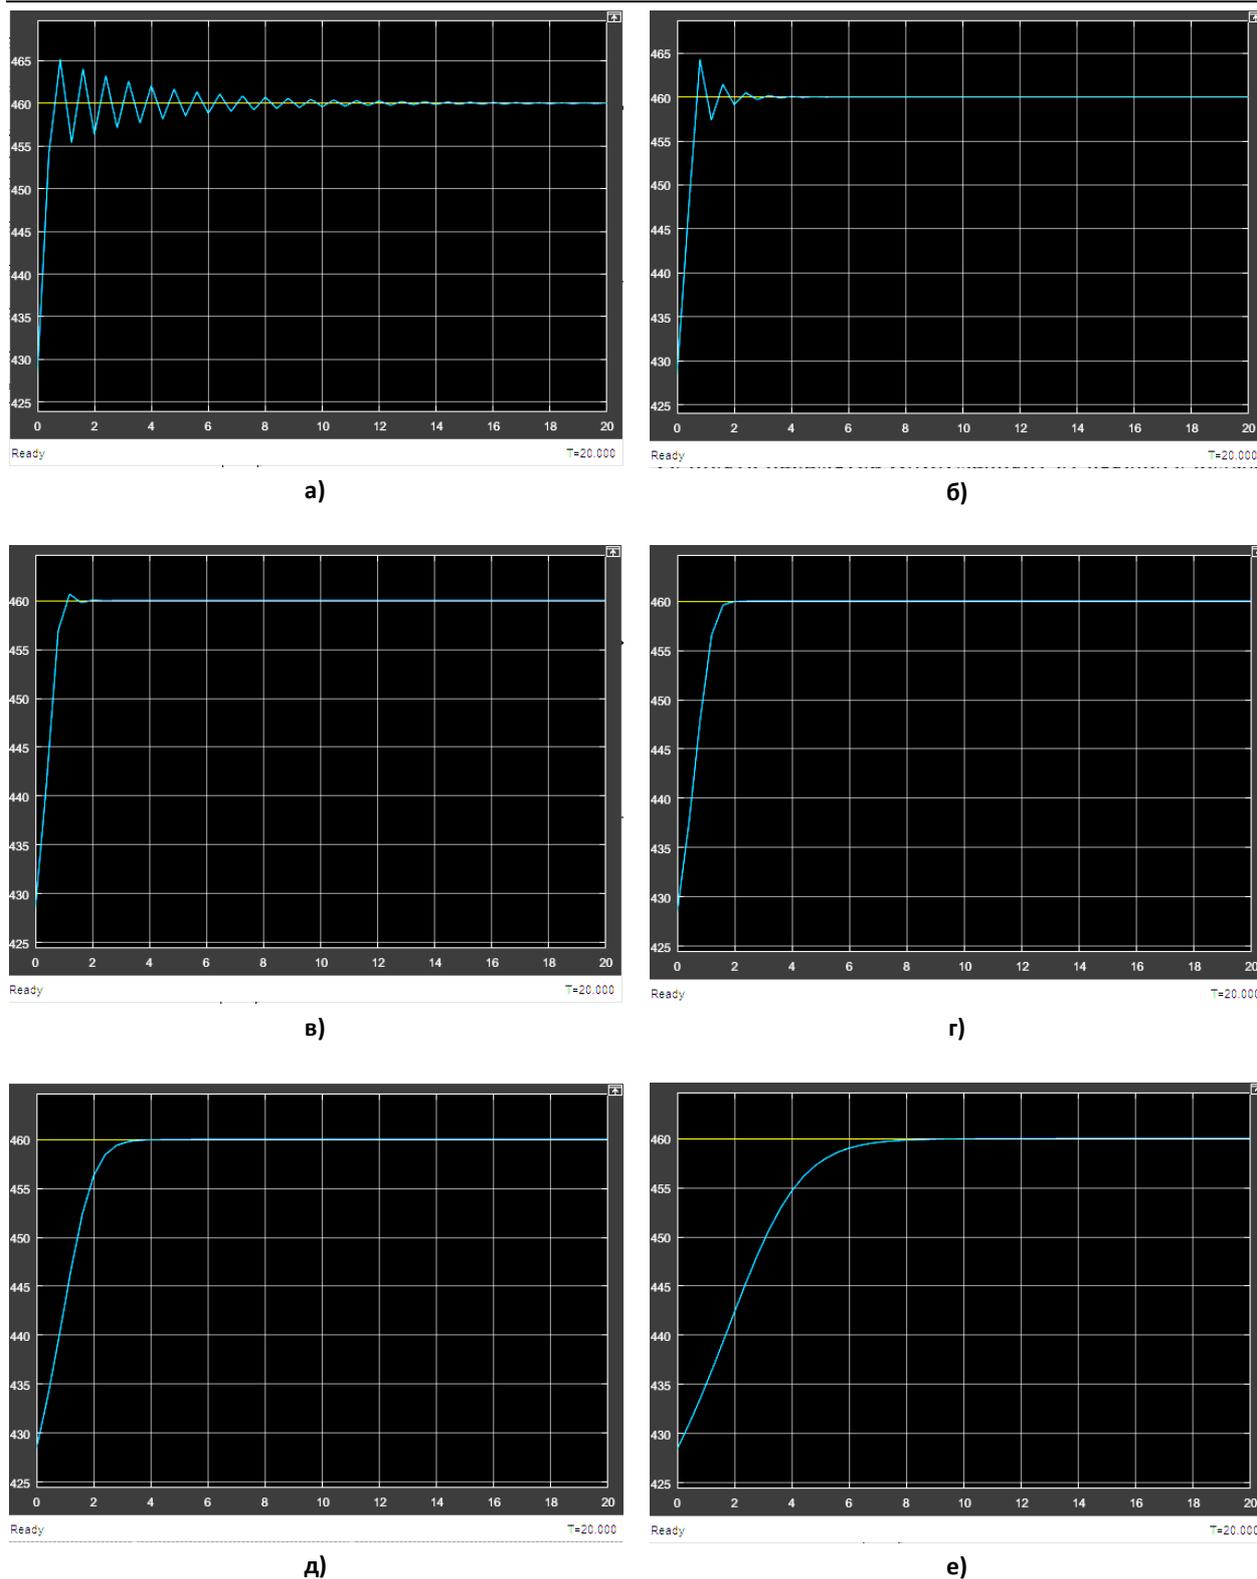


Рис. 5. Переходный процесс в целевой точке 460: **а** – $w = 0.06$; **б** – $w = 0.05$; **в** – $w = 0.04$; **г** – $w = 0.03$; **д** – $w = 0.02$; **е** – $w = 0.01$

Fig. 5. Transient process at the target point 460: **а** – $w = 0.06$; **б** – $w = 0.05$; **в** – $w = 0.04$; **г** – $w = 0.03$; **д** – $w = 0.02$; **е** – $w = 0.01$

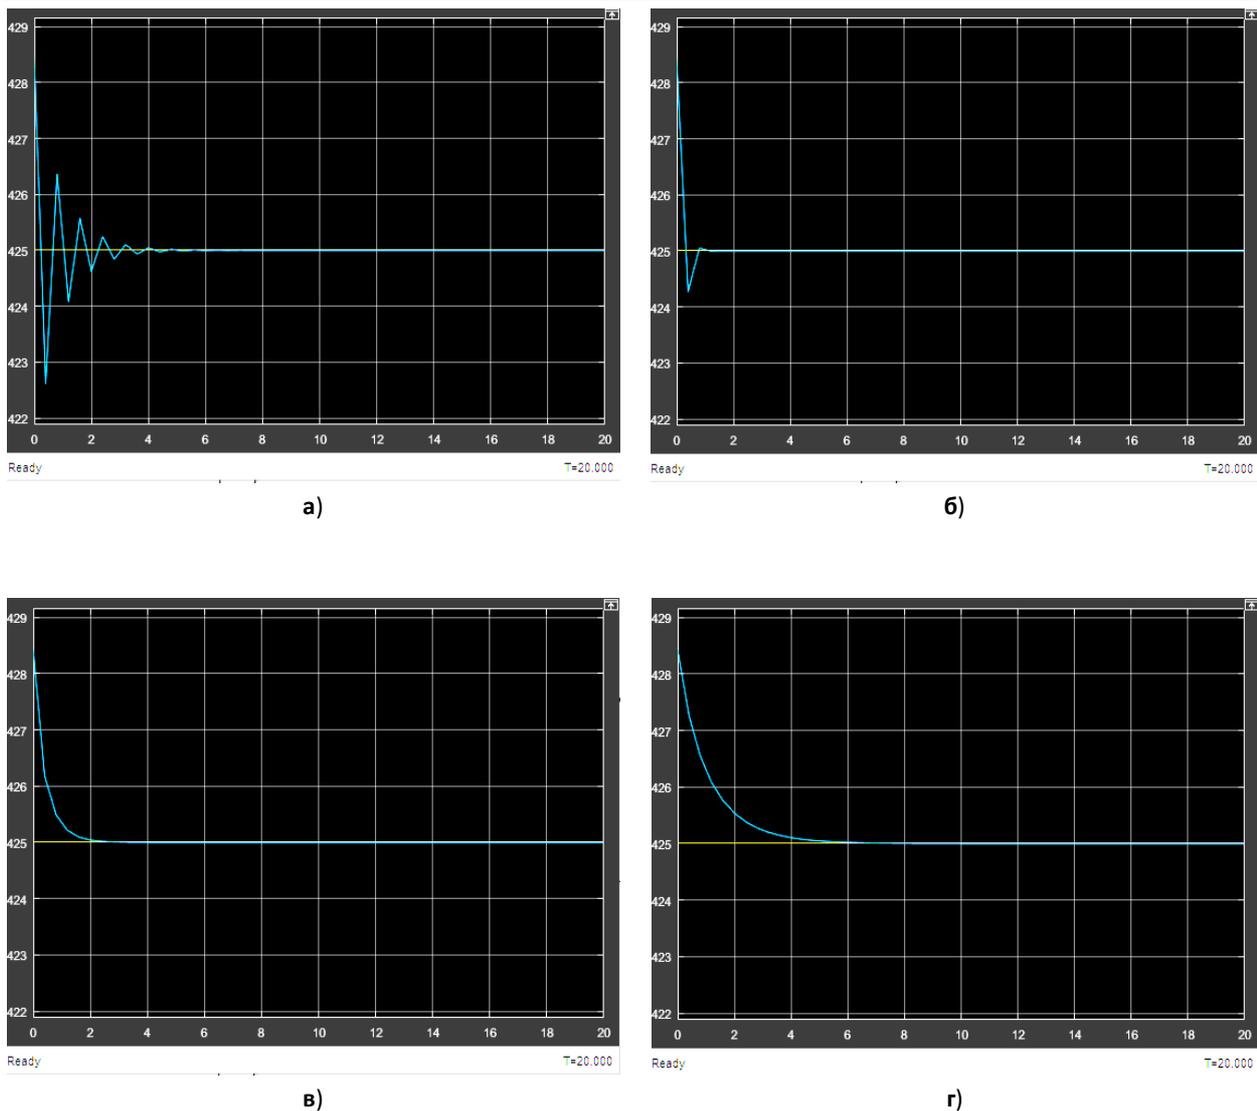


Рис. 6. Переходный процесс в целевой точке 425: **а** – $w = 0.3$; **б** – $w = 0.2$; **в** – $w = 0.1$;
г – $w = 0.05$

Fig. 6. Transient process at the target point 425: **a** – $w = 0.3$; **б** – $w = 0.2$; **в** – $w = 0.1$; **г** – $w = 0.05$

Выводы

В данной статье представлена структурно-функциональная организация нейро-нечёткой системы вывода, основанной на методе отношения площадей. Проведено имитационное моделирование нейро-нечёткой системы вывода в среде Simulink. В ходе экспери-

ментальных исследований подтверждено, что разработанная нейро-нечёткая система вывода позволяет трансформировать вид переходного процесса из колебательного в апериодический (монотонный) процесс. В статье определены параметры, влияющие на устойчивость нейро-нечёткой системы вывода и даны рекомендации по их подбору.

Список литературы

1. Shahmoradi S., Shouraki S.B. Evaluation of a novel fuzzy sequential pattern recognition tool (fuzzy elastic matching machine) and its applications in speech and handwriting recognition // *Applied Soft Computing*. 2018. N62. P. 315-327.
2. Титов В.С., Бобырь М.В., Анциферов А.В. Адаптивный мультисетевой алгоритм нечетко-логического вывода в задачах управления оборудованием с ЧПУ // *Мехатроника, автоматизация, управление*. 2013. № 5. С. 18-23.
3. Hodgett R.E., Siraj S. SURE: A method for decision-making under uncertainty // *Expert Systems with Applications*. 2019. N 115. P. 684-694.
4. Temur G.T. A novel multi attribute decision making approach for location decision under high uncertainty // *Applied Soft Computing*. 2016. N 40. P. 674-682.
5. Бобырь М.В., Титов В.С., Акульшин Г.Ю. Моделирование нечетко-логических систем управления на основе мягких арифметических операций // *Вестник компьютерных и информационных технологий*. 2013. № 3 (105). С. 29-35.
6. Annabestani, M., Naghavi, N. Nonlinear identification of IPMC actuators based on ANFIS-NARX paradigm // *Sensors and Actuators, A: Physical*. 2014. N209. P. 140–148.
7. A. Piegat *Fuzzy Modelling and Control*. Physica-Verlag, Heidelberg. 2001.
8. Modeling of simultaneous adsorption of dye and metal ion by sawdust from aqueous solution using of ANN and ANFIS / M. Dolatabadi, M. Mehrabpour, M. Esfandyari, H. Alidadi, M. Davoudi // *Chemometrics and Intelligent Laboratory Systems*. 2018. N 181. P. 72-78.
9. Бобырь М.В., Милостная Н.А. Механизм адаптации нечеткой системы вывода на основе генетического алгоритма // *Промышленные АСУ и контроллеры*. 2015. № 3. С. 27-32.
10. Rezakazemi M., Dashti A., Asghari M., Shirazian S. H₂-selective mixed matrix membranes modeling using ANFIS, PSO-ANFIS, GA-ANFIS // *International Journal of Hydrogen Energy*. 2017. N42. P. 15211-15225.
11. Mottahedi A., Sereshki F., Ataei M. Overbreak prediction in underground excavations using hybrid ANFIS-PSO model // *Bioresource Technology*. 2018. N267. P. 634-641.
12. Karaboga D., Kaya E. An adaptive and hybrid artificial bee colony algorithm (ABC) for ANFIS training // *Applied Soft Computing*. 2016. N49. P. 423-436.
13. Haznedar B., Kalinli A. Training ANFIS structure using simulated annealing algorithm for dynamic systems identification // *Neurocomputing*. 2018. N 302. P. 66-74.
14. Boulkaibet I., Belarbi K., Bououden S., Chadli M., Marwala T. An adaptive fuzzy predictive control of nonlinear processes based on Multi-Kernel least squares support vector regression // *Applied Soft Computing*. 2018. N 73. P. 572-590.
15. Li L.J., Su H.Y., Chu J., Generalized predictive control with online least squares support vector machines // *Acta Automatica Sinica*. 2007. N 33. P.1182–1188.

16. An ANFIS model of quality of experience prediction in education / T. Vasileva-Stojanovska, M. Vasileva, T. Malinovski, V. Trajkovik // *Applied Soft Computing*. 2015. N 34. P. 129-138.
17. Vemuri N.R. Mutually exchangeable fuzzy implications // *Information Sciences*. 2015. N317. P. 1-24.
18. Laha A. Building contextual classifiers by integrating fuzzy rule based classification technique and k-nn method for credit scoring // *Adv. Eng. Inf.*, 2007. N21. P. 281-291.
19. Casale G., Pérez J.F., Wang W. QD-AMVA: Evaluating systems with queue-dependent service requirements // *Perform. Eval.* 2015. N 91. P. 80-98.
20. Bobyr M.V., Milostnaya N.A., Kulabuhov S.A. A method of defuzzification based on the approach of areas ratio // *Applied Soft Computing*. 2017. N59. P. 19-32.
21. Бобырь М.В., Милостная Н.А. Анализ использования мягких арифметических операций в структуре нечетко-логического вывода // *Вестник компьютерных и информационных технологий*. 2015. № 7 (133). С. 7-15.
22. Bobyr M.V., Emelyanov S.G. A nonlinear method of learning neuro-fuzzy models for dynamic control systems // *Applied Soft Computing*. 2020. Т. 88. P. 106030.
23. Bobyr M.V., Yakushev A.S., Dorodnykh A.A. Fuzzy devices for cooling the cutting tool of the cnc machine implemented on FPGA // *Measurement*. 2020. Т. 152. P. 107378.
24. Титов В.С., Бобырь М.В., Анциферов А.В. Адаптивный мультисетевой алгоритм нечетко-логического вывода в задачах управления оборудованием С ЧПУ // *Мехатроника, автоматизация, управление*. 2013. № 5. С. 18-23.
25. Бобырь М.В. Методы построения функций принадлежности для нечетких баз знаний // *Промышленные АСУ и контроллеры*. 2011. № 2. С. 27-32.

References

1. Shahmoradi S., Shouraki S.B. Evaluation of a novel fuzzy sequential pattern recognition tool (fuzzy elastic matching machine) and its applications in speech and handwriting recognition. *Applied Soft Computing*, 2018, no. 62, pp. 315-327.
2. Titov V.S., Bobyr M.V., Antsiferov A.V. Adaptivnyi mul'tisetevoi algoritm nechetko-logicheskogo vyvoda v zadachakh upravleniya oborudovaniem s ChPU [Adaptive multi-network fuzzy inference algorithm in problems of control of equipment with CNC]. *Mekhatronika, avtomatizatsiya, upravlenie = Mechatronics, Automation, Control*. 2013, no. 5, pp. 18-23.
3. Hodgett R.E., Siraj S. SURE: A method for decision-making under uncertainty. *Expert Systems with Applications*, 2019, no. 115, pp. 684-694.
4. Temur G.T. A novel multi attribute decision making approach for location decision under high uncertainty. *Applied Soft Computing*, 2016, no. 40, pp. 674-682.

5. Bobyr M.V., Titov V.S., Akulshin G.Yu. Modelirovanie nechetko-logicheskikh sistem upravleniya na osnove myagkikh arifmeticheskikh operatsii [Modeling of fuzzy-logical control systems based on soft arithmetic operations]. *Vestnik komp'yuternykh i informatsionnykh tekhnologii = Bulletin of Computer and Information Technologies*, 2013, no. 3 (105), pp. 29-35.

6. Annabestani M., Naghavi N. Nonlinear identification of IPMC actuators based on ANFIS-NARX paradigm. *Sensors and Actuators, A: Physical*, 2014, no. 209, pp. 140-148.

7. A. Piegat Fuzzy Modeling and Control. Physica-Verlag, Heidelberg, 2001.

8. Dolatabadi M., Mehrabpour M., Esfandyari M., Alidadi H., Davoudi M. Modeling of simultaneous adsorption of dye and metal ion by sawdust from aqueous solution using of ANN and ANFIS. *Chemometrics and Intelligent Laboratory Systems*, 2018, no. 181, pp. 72-78.

9. Bobyr M.V., Milostnaya N.A. Mekhanizm adaptatsii nechetkoi sistemy vyvoda na osnove geneticheskogo algoritma [Adaptation mechanism of a fuzzy inference system based on a genetic algorithm]. *Promyshlennye ASU i kontrolyery = Industrial ACS and Controllers*, 2015, no. 3, pp. 27-32.

10. Rezakazemi M., Dashti A., Asghari M., Shirazian S. H₂-selective mixed matrix membranes modeling using ANFIS, PSO-ANFIS, GA-ANFIS. *International Journal of Hydrogen Energy*, 2017, no. 42, pp. 15211-15225.

11. Mottahedi A., Sereshki F., Ataei M. Overbreak prediction in underground excavations using hybrid ANFIS-PSO model. *Bioresource Technology*, 2018, no. 267, pp. 634-641.

12. Karaboga D., Kaya E. An adaptive and hybrid artificial bee colony algorithm (ABC) for ANFIS training. *Applied Soft Computing*, 2016, no. 49, pp. 423-436.

13. Haznedar B., Kalinli A. Training ANFIS structure using simulated annealing algorithm for dynamic systems identification. *Neurocomputing*, 2018, no. 302, pp. 66-74.

14. Boulkaibet I., Belarbi K., Bououden S., Chadli M., Marwala T. An adaptive fuzzy predictive control of nonlinear processes based on Multi-Kernel least squares support vector regression. *Applied Soft Computing*, 2018, no. 73, pp. 572-590.

15. Li L.J., Su H.Y., Chu J. Generalized predictive control with online least squares support vector machines. *Acta Automatica Sinica*, 2007, no. 33, pp. 1182-1188.

16. Vasileva-Stojanovska T., Vasileva M., Malinovski T., Trajkovik V. An ANFIS model of quality of experience prediction in education. *Applied Soft Computing*, 2015, no. 34, pp. 129-138.

17. Vemuri N.R. Mutually exchangeable fuzzy implications. *Information Sciences*, 2015, no. 317, pp. 1-24.

18. Laha A. Building contextual classifiers by integrating fuzzy rule based classification technique and k-nn method for credit scoring. *Adv. Eng. Inf.*, 2007, no. 21, pp. 281-291.

19. Casale G., Pérez J.F., Wang W. QD-AMVA: Evaluating systems with queue-dependent service requirements. *Perform. Eval.*, 2015, no.91, pp. 80-98.

20. Bobyr, M.V., Milostnaya, N.A., Kulabuhov, S.A. A method of defuzzification based on the approach of areas ratio. *Applied Soft Computing*, 2017, no. 59, pp.19-32.
21. Bobyr M.V., Milostnaya N.A. Analiz ispol'zovaniya myagkikh arifmeticheskikh operatsii v strukture nechetko-logicheskogo vyvoda [Analysis of the use of soft arithmetic operations in the structure of fuzzy inference]. *Vestnik komp'yuternykh i informatsionnykh tekhnologii = Bulletin of Computer and Information Technologies*, 2015, no. 7 (133), pp. 7-15.
22. Bobyr M.V., Emelyanov S.G. A nonlinear method of learning neuro-fuzzy models for dynamic control systems. *Applied Soft Computing*, 2020, vol. 88, p. 106030.
23. Bobyr M.V., Yakushev A.S., Dorodnykh A.A. Fuzzy devices for cooling the cutting tool of the cnc machine implemented on FPGA. *Measurement*, 2020, vol. 152, p. 107378.
24. Titov V.S., Bobyr M.V., Antsiferov A.V. Adaptivnyi mul'tisetevoi algo-ritm nechetko-logicheskogo vyvoda v zadachakh upravleniya oborudovaniem S ChPU [Adaptive multi-network fuzzy inference algorithm in control problems for CNC equipment]. *Mekhatronika, avtomatizatsiya, upravlenie = Mechatronics, Automation, Control*. 2013, no. 5, pp. 18-23.
25. Bobyr M.V. Metody postroeniya funktsii prinadlezhnostoni dlya nechetkikh baz znaniy [Methods for constructing accessory functions for fuzzy knowledge bases]. *Promyshlennyye ASU i kontrolyery = Industrial ACS and Controllers*, 2011, no. 2, pp. 27-32.

Информация об авторе / Information about the Author

Милостная Наталья Анатольевна,
кандидат технических наук, Юго-Западный
государственный университет,
г. Курск, Российская Федерация,
e-mail: nat_mil@mail.ru,
ORCID: <https://orcid.org/0000-0002-3779-9165>

Natalya A. Milostnaya, Cand. of Sci.
(Engineering), Southwest State University,
Kursk, Russian Federation,
e-mail: nat_mil@mail.ru,
ORCID: <https://orcid.org/0000-0002-3779-9165>