

О настройке и возможностях обучения нейро-нечеткой сети на основе байесовской логико-вероятностной модели

Г. А. Хамчиев¹, Г. И. Кожомбердиева²

Петербургский государственный университет путей сообщения Императора Александра I

¹gyqn@yandex.ru, ²kgi-liizht@yandex.ru

Аннотация. В докладе приводятся примеры настройки нейро-нечеткой сети на основе байесовской логико-вероятностной модели для решения задачи нечеткого вывода. Показано, как параметры сети могут использоваться для ее обучения. Обсуждаются возможности обучения нейро-нечеткой сети предложенной структуры, в том числе с использованием гибридного алгоритма, известного по применению для сети ANFIS.

Ключевые слова: нейро-нечеткая сеть; байесовская логико-вероятностная модель нечеткого вывода; настройка параметров нейро-нечеткой сети; машинное обучение; обучение нейро-нечеткой сети; гибридный алгоритм обучения

I. ВВЕДЕНИЕ

Данный доклад является продолжением доклада Кожомбердиевой Г. И., Буракова Д. П. и Хамчиева Г. А. «О нейросетевой интерпретации байесовской логико-вероятностной модели нечеткого вывода», представленного в настоящем сборнике, поэтому в тексте, естественно, делаются отсылки к содержанию, рисунку и формулам первого доклада.

В докладе приводится демонстрационный пример решения задачи нечеткого вывода с использованием предложенной структуры нейро-нечеткой сети на основе байесовской логико-вероятностной модели (БЛВ-модели). На примере показывается, как параметры, расположенные в параметрических слоях сети, могут использоваться для ее обучения. Обсуждаются возможности обучения нейро-нечеткой сети предложенной структуры.

Так как, по мнению авторов, предложенная сетевая структура сопоставима с известными нейро-нечеткими сетями Такаги–Сугено–Канга и Ванга–Менделя [1–3],

для ее обучения можно применять гибридный алгоритм, использующийся при обучении известной нейро-нечеткой сети ANFIS, основанной на модели Такаги–Сугено–Канга.

II. ПРИМЕР СОЗДАНИЯ И НАСТРОЙКИ НЕЙРО-НЕЧЕТКОЙ СЕТИ НА ОСНОВЕ БЛВ-МОДЕЛИ

В качестве поясняющего примера используем известную демонстрационную задачу «Ужин в ресторане», которая, несмотря на простоту решения, вполне позволяет продемонстрировать возможности использования нейро-нечеткой сети на основе БЛВ-модели как универсального аппроксиматора непрерывной функциональной зависимости на основе ее обучения.

Пусть необходимо разработать экспертную систему для определения суммы чаевых, которые нужно оставить официанту заведения в зависимости от уровня обслуживания и качества приготовления заказанных блюд. Сервис и качество еды посетитель оценивает по 10-балльной шкале, а величину выплачиваемых чаевых – в процентах (от 0 до 25 % от стоимости ужина). Данная нечеткая модель входит в число демонстрационных примеров MATLAB [4], но здесь представлена в редакции, использованной ранее авторами работ [5–7].

В системе нечеткого вывода сформулированы соответствующие лингвистические переменные (ЛП) для оцениваемых показателей *Сервис* (уровень обслуживания) и *Еда* (качество блюд), на шкалах показателей определены функции принадлежности их термов и сформирована система нечетких правил, использующих в посылках и заключениях высказывания о значениях ЛП. Графики функций принадлежности входных ЛП приведены на рис. 1.

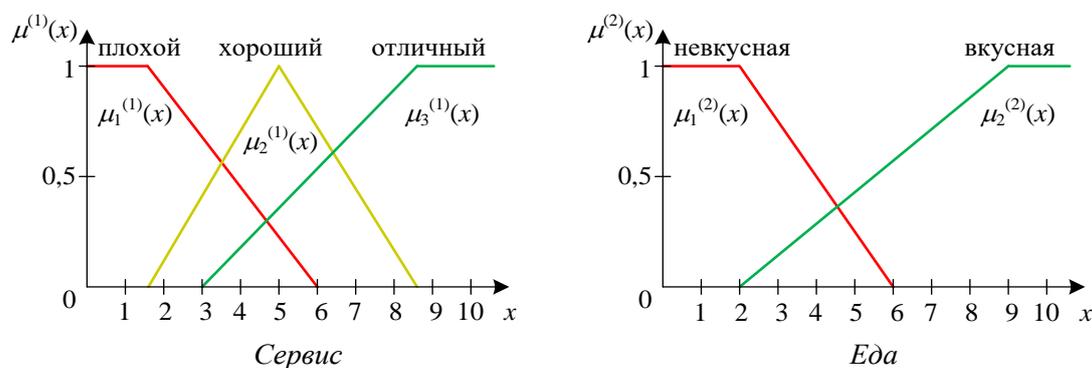


Рис. 1. Функции принадлежности $\mu_j^{(1)}(x_1)$, $j = 1, 2, 3$, и $\mu_j^{(2)}(x_2)$, $j = 1, 2$, термов входных лингвистических переменных *Сервис* и *Еда*

Шкала выходной переменной *Чаевые* в соответствии с условиями задачи разбита на три непересекающихся интервала [0; 5], [5; 20] и [20, 25], соответствующих лингвистическим значениям «Маленькие», «Средние» и «Большие» соответственно.

Отметим, что определение функций принадлежности для термов выходной ЛП в нейро-нечеткой сети на основе БЛВ-модели не предусмотрено.

Используются следующие нечеткие правила:

- 1) ЕСЛИ *Сервис* = «Плохой» ИЛИ *Еда* = «Невкусная» ТО *Чаевые* = «Маленькие»;
- 2) ЕСЛИ *Сервис* = «Хороший» ТО *Чаевые* = «Средние»;
- 3) ЕСЛИ *Сервис* = «Отличный» И *Еда* = «Вкусная» ТО *Чаевые* = «Большие».

Данные правила представляются в виде функций алгебры логики, задаваемых в ДСНФ, и далее трансформируются в набор функций вероятностной логики (ФВЛ). Вероятностные функции используются для вычисления условных вероятностей, оценивающих степени соответствия набора значений входных переменных x_1 и x_2 («четких» свидетельств) предположениям об истинности байесовских гипотез о значении («Маленькие», «Средние» или «Большие») выходной ЛП *Чаевые*:

$$P(e|H_1) = \mu_1^{(1)}(x_1) + \mu_1^{(2)}(x_2) - \mu_1^{(1)}(x_1) \cdot \mu_1^{(2)}(x_2),$$

$$P(e|H_2) = \mu_2^{(1)}(x_1),$$

$$P(e|H_3) = \mu_3^{(1)}(x_1) \cdot \mu_2^{(2)}(x_2).$$

Используем, например, при расчетах входные значения оценок качества сервиса и еды $x_1 = x_2 = 5$. Установим веса нечетких правил w_1, w_2, w_3 равными 1, а в качестве характерных значений термов выходной ЛП примем по умолчанию среднее значение граничных точек, соответствующих термам интервалов y_k^{start} и y_k^{end} на шкале выходной переменной. Тогда при заданных функциях принадлежности (см. рис. 1) апостериорное байесовское распределение вероятностей $\{P(H_k | e)\}$ примет вид {0,26; 0,64; 0,10}, а искомый размер чаевых составит $y = 11\%$. (Для вычислений использованы формулы (1) и (2) из предшествующего доклада Кожомбердиевой Г. И., Буракова Д. П. и Хамчиева Г. А. «О нейросетевой интерпретации байесовской логико-вероятностной модели нечеткого вывода».)

Преобразуем построенную для решения задачи «Ужин в ресторане» систему нечеткого вывода, использующую БЛВ-модель, в нейро-нечеткую сеть, структура которой соответствует рис. 1, приведенному в упомянутом выше докладе. Напомним, что обучение сети осуществляется путем изменения параметров на параметрических слоях, и уточним, какие параметры для этого используются:

1. Функции принадлежности $\mu_j^{(i)}(x_i)$ термов входных ЛП представляют собой трапеции, описываемые четырьмя параметрами $a_j^{(i)}, b_j^{(i)}, c_j^{(i)}, d_j^{(i)}$, которые соответствуют абсциссам вершин трапеций на графиках функций принадлежности (треугольная функция принадлежности рассматривается как частный случай трапециевидной при $b_j^{(i)} = c_j^{(i)}$;

2. Весовые коэффициенты нечетких правил $w_k \in [0; 1]$ (по умолчанию принимаются равными 1);

3. Граничные точки соответствующих термам выходной ЛП интервалов y_k^{start} и y_k^{end} на шкале выходной переменной, а также коэффициенты смещения характерного значения для каждого терма $\alpha_k \in [0; 1]$ (по умолчанию принимаются равными 0,5). Характерное значение терма \tilde{y}_k вычисляется как выпуклая комбинация граничных точек: $\tilde{y}_k = (1 - \alpha_k) \cdot y_k^{start} + \alpha_k \cdot y_k^{end}$.

Для демонстрации возможностей настройки нейро-нечеткой сети на основе БЛВ-модели в табл. 1 приводятся значения параметров и результат расчета значения выходной функции $y = f(x_1, x_2)$ для рассмотренного выше примера с набором ФВЛ (1), а в табл. 2 – для примера с тем же набором ФВЛ, но измененными параметрами сети.

ПРИМЕР НАСТРОЙКИ СЕТИ С НАБОРОМ ПРАВИЛ В ВИДЕ ФВЛ (1) И ИСХОДНЫМИ ЗНАЧЕНИЯМИ ПАРАМЕТРОВ

Входная ЛП		Сервис			Еда	
Термы	Плох.	Хор.	Отл.	Невк.	Вкус.	
Значения параметров функций принадлежности						
$ak^{(i)}$	0	1,5	3	0	2	
$bk^{(i)}$	0	5	8,5	0	9	
$ck^{(i)}$	1,5	5	10	2	10	
$dk^{(i)}$	6	8,5	10	6	10	
Веса нечетких правил						
w_k	1	1	1			
Выходная ЛП		Чаевые				
Термы	Мал.	Сред.	Больш.			
Параметры термов выходной ЛП						
y_k^{start}	0	5	20			
α_k	0,5	0,5	0,5			
y_k^{end}	5	20	25			
$y = f(5, 5) = 11\%$						

ПРИМЕР ИЗМЕНЕНИЯ ПАРАМЕТРОВ НАСТРОЙКИ СЕТИ С НАБОРОМ ПРАВИЛ В ВИДЕ ФВЛ (1)

Входная ЛП		Сервис			Еда	
Термы	Плох.	Хор.	Отл.	Невк.	Вкус.	
Значения параметров функций принадлежности						
$ak^{(i)}$	0	1	7	0	2	
$bk^{(i)}$	0	4	9	0	9	
$ck^{(i)}$	1	4	10	5	10	
$dk^{(i)}$	4	9	10	9	10	
Веса нечетких правил						
w_k	0,75	1	0,5			
Выходная ЛП		Чаевые				
Термы	Мал.	Сред.	Больш.			
Параметры термов выходной ЛП						
y_k^{start}	0	5	20			
α_k	0	0,5	1			
y_k^{end}	5	20	25			
$y = f(5, 5) = 6,5\%$						

На рис. 2a и 2b представлены графики результирующих поверхностей, заметно отличающиеся друг от друга.

Следует особо отметить, что наибольшее влияние на вид поверхности выходной функции $y = f(x_1, x_2)$ оказывает используемый в третьем непараметрическом слое сети набор нечетких правил, выбираемый на этапе построения сети. Продемонстрируем это, изменив второе и третье правила из набора (1), представленного в виде

ФВЛ. Рассмотрим два примера изменения нечетких правил, вполне соответствующих возможному

расхождению во мнениях разных экспертов:

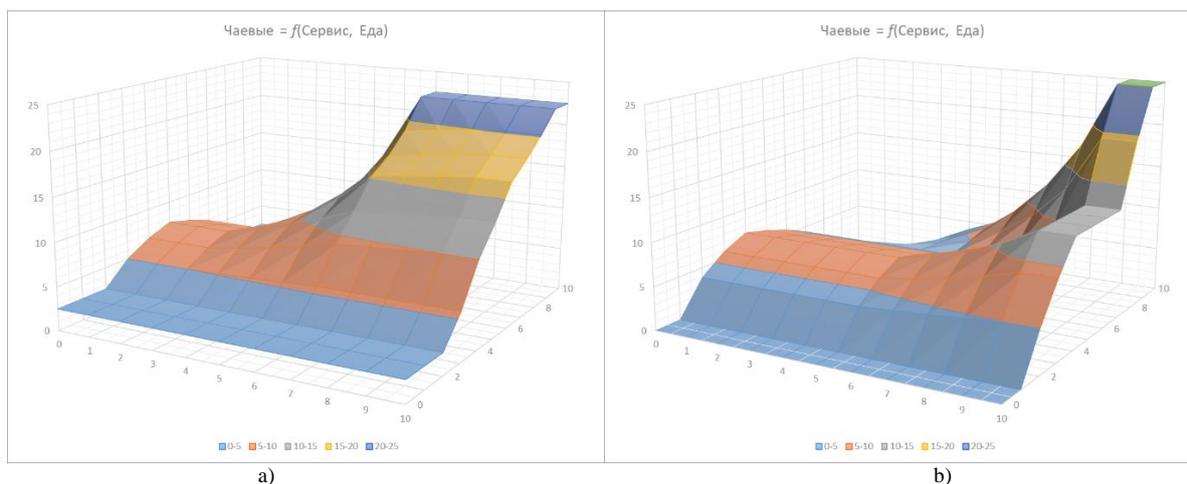


Рис. 2. Графики поверхности выходной функции $y=f(x_1, x_2)$ для нейро-нечеткой сети с набором правил (1)

а) – значения параметров, представленные в табл. 1, б) – значения параметров, представленные в табл. 2.

$$\begin{aligned}
 P(e|H_1) &= \mu_1^{(1)}(x_1) + \mu_1^{(2)}(x_2) - \mu_1^{(1)}(x_1) \cdot \mu_1^{(2)}(x_2), \\
 P(e|H_2) &= \mu_2^{(1)}(x_1) + \mu_2^{(2)}(x_2) - \mu_2^{(1)}(x_1) \cdot \mu_2^{(2)}(x_2), \\
 P(e|H_3) &= \mu_3^{(1)}(x_1).
 \end{aligned} \quad (2)$$

$$\begin{aligned}
 P(e|H_1) &= \mu_1^{(1)}(x_1) + \mu_1^{(2)}(x_2) - \mu_1^{(1)}(x_1) \cdot \mu_1^{(2)}(x_2), \\
 P(e|H_2) &= \mu_2^{(1)}(x_1) \cdot \mu_2^{(2)}(x_2), \\
 P(e|H_3) &= \mu_3^{(1)}(x_1).
 \end{aligned} \quad (3)$$

Графики результирующих поверхностей для обоих вариантов (2) и (3) изменения набора нечетких правил для нейро-нечеткой сети с параметрами, представленными в табл. 1, показаны на рис. 3а и рис. 3б. При этом, хотя эти графики резко отличаются от представленного на рис. 2а, полученные сетью размеры чаевых (12,2 % и 12,1 % соответственно) лишь незначительно расходятся с приведенным в табл. 1 значением 11 %, что, впрочем, вполне ожидаемо, учитывая сохранение общей семантики правил при их изменении.

III. АЛГОРИТМЫ ГЕНЕРАЦИИ НЕЧЕТКИХ ПРАВИЛ

Кратко остановимся на проблеме, которая возникает при необходимости спроектировать нейро-нечеткую систему, когда в наличии у разработчика имеются только численные данные и построены базы правил требует длительного процесса итеративного обучения. Таким образом, задачу формирования базы нечетких правил можно рассматривать в общем контексте обучения нейро-нечетких сетей. С 90-х годов прошлого века активно ведется разработка различных алгоритмов генерации нечетких правил. Алгоритмы, используемые для генерации нечетких правил, можно разделить на несколько групп. (Существуют также алгоритмы, сочетающие в себе различные особенности алгоритмов из разных групп.)

Первая группа, *алгоритмы кластеризации*, включает следующие алгоритмы [2, 8]: Густафсона–Кесселя, нечетких С-средних, вероятностных С-средних, горной кластеризации и другие.

Вторая группа – *алгоритмы сеточного разбиения* (Grid Partitioning). К этой группе относятся, например, алгоритмы Ванга–Менделя [9], Абе–Лэна [10] и пикового группирования (DPC) [1].

К алгоритмам третьей группы, *эволюционным алгоритмам*, относятся нечеткие деревья решений, различные генетические алгоритмы, а также алгоритмы, основанные на моделировании социального поведения живых организмов, например, алгоритмы роя частиц, пчелиной колонии и криля рыб [1, 2, 11].

IV. ВОЗМОЖНОСТИ ОБУЧЕНИЯ НЕЙРО-НЕЧЕТКИХ СЕТЕЙ

Наиболее популярным алгоритмом обучения нейронных сетей, в том числе нейро-нечетких и нечетких, является алгоритм обратного распространения ошибки. Его суть состоит в обновлении параметров сети с использованием математических методов, основанных на вычислении производных функции ошибки (градиентный спуск). Помимо алгоритма обратного распространения ошибки, при обучении нейро-нечетких сетей используются также генетические и эволюционные алгоритмы, алгоритмы онлайн-обучения, алгоритмы с использованием различных методов кластеризации данных и прочие [2, 12]. Рассмотрим некоторые из них.

Кластеризация. Кластеризация является одной из задач обучения без учителя. Она подразумевает группировку точек данных в кластеры на основе их характеристик, которые затем можно использовать для формирования нечетких правил и функций принадлежности. Кластеризация помогает определять основные закономерности и отношения в данных, позволяя ускорить процесс обучения нейро-нечетких сетей путем определения начальных значений параметров, адаптация которых осуществляется в процессе обучения [3].

Гибридный алгоритм. Этот алгоритм используется для обучения известной нейро-нечеткой сети ANFIS [13], его реализация присутствует в пакете Fuzzy Logic Toolbox платформы MATLAB [14]. Гибридный алгоритм поэтому является одним из наиболее распространенных алгоритмов, использующихся при обучении нейро-

нечетких сетей, включающим в себя комбинацию методов обучения с учителем и без учителя, которые используются для нахождения нечетких правил и настройки параметров нейронной сети [2].

Первым шагом гибридного алгоритма является идентификация нечетких правил с использованием кластеризации для группировки похожих точек данных в кластеры.

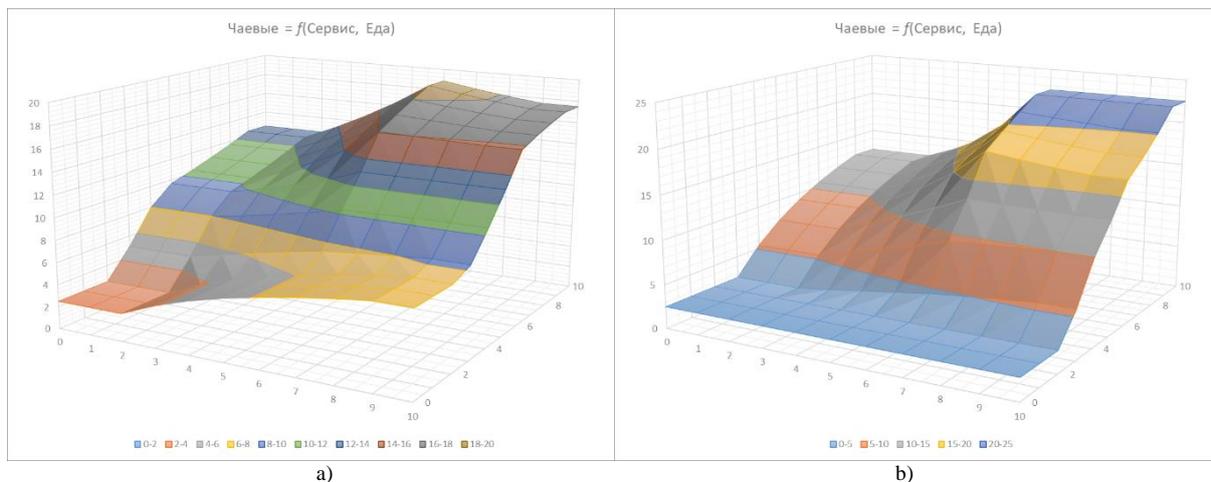


Рис. 3. Графики поверхности выходной функции $y=f(x_1, x_2)$ для нейро-нечеткой сети с параметрами, представленными в табл. 1
а) – набор нечетких правил (2), б) – набор нечетких правил (3).

Затем эти кластеры используются для генерации нечетких правил, описывающих взаимосвязь между входными и выходными переменными. Количество правил равно количеству кластеров. Кластеризация не является обязательной, но благодаря ее использованию гибридный алгоритм быстро сходится к искомому решению.

Следующим шагом является настройка линейных параметров модели. Затем настраиваются параметры нелинейных функций принадлежности [2].

Полагаем, что гибридный алгоритм может быть применен для обучения нейро-нечеткой сети на основе БЛВ-модели, поскольку структура этой сети сходна со структурой сети Такаги–Сугено–Канга, на которой основана сеть ANFIS. Опишем возможный вариант его применения. Для генерации правил и нахождения начальных значений параметров функций принадлежности входных ЛП можно использовать алгоритм кластеризации с применением нечетких С-средних [2]. На следующем шаге производится настройка линейных параметров модели (параметров шестого слоя), а именно коэффициентов α_k , использующихся при вычислении характерных значений термов выходной ЛП \tilde{y} с помощью метода наименьших квадратов. После проведения достаточного количества итераций выполняется настройка параметров функций принадлежности $\mu_j^{(i)}(x_i)$ (параметров первого слоя) с использованием метода градиентного спуска, после чего процесс обучения завершается.

V. ЗАКЛЮЧЕНИЕ

В докладе продемонстрирован процесс изменения функции, которую реализует сеть, описанная в предшествующем докладе Г. И. Кожомбердиевой, Д. П. Буракова и Г. А. Хамчичева «О нейросетевой интерпретации байесовской логико-вероятностной модели нечеткого вывода», представленном в настоящем

сборнике. Изменение реализуемой функции обеспечивается путем изменения параметров сети.

Параметры, использованные при настройке сети, планируется использовать при ее обучении. Выделены перспективные методы обучения и сделан предварительный вывод о возможности применения гибридного алгоритма, поскольку он активно используется при обучении сети ANFIS, основанной на сети Такаги–Сугено–Канга, имеющей сходную структуру с предложенной авторами докладов сетью.

В настоящее время с целью продолжения исследований ведется работа по программной реализации нейро-нечеткой сети на основе БЛВ-модели.

СПИСОК ЛИТЕРАТУРЫ

- [1] Борисов В.В., Круглов В.В., Федулов А.С. Нечеткие модели и сети. 2-е изд., стереотип. М.: Горячая линия – Телеком, 2018. 284 с.
- [2] Осовский С. Нейронные сети для обработки информации; [пер. с польск. И.Д. Рудинского]. 2-е изд., перераб. и доп. М.: Горячая линия – Телеком, 2018. 448 с.
- [3] Рутковская Д., Пилиньский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы; [пер. с польск. И.Д. Рудинского]. 2-е изд. М.: Горячая линия – Телеком, 2013. 384 с.
- [4] Fuzzy Inference Process [Электронный ресурс]. URL: <https://www.mathworks.com/help/fuzzy/fuzzy-inference-process.html> (дата обращения 09.03.2023).
- [5] Кожомбердиева Г.И. Байесовская логико-вероятностная модель нечеткого вывода // Международная конференция по мягким вычислениям и измерениям. 2019. Т. 1. С. 35–38.
- [6] Кожомбердиева Г.И., Бураков Д.П. Байесовская логико-вероятностная модель нечеткого вывода: этапы вывода заключений и дефазификации // Нечеткие системы и мягкие вычисления. 2019. Т. 14. № 2. С. 92–110.
- [7] Kozhombardieva G.I., Burakov D.P. Combining Bayesian and logical-probabilistic approaches for fuzzy inference systems implementation. Journal of Physics: Conference Series. 2020. vol. 1703. 012042.
- [8] Yager R.R., Filev D.P. Generation of Fuzzy Rules by Mountain Clustering // Journal of Intelligent and Fuzzy Systems. 1994. 2(3):209–219.

- [9] Wang L. X., Mendel J. M. Generating Fuzzy Rules by Learning from Examples. *IEEE Transactions on Systems, Man, and Cybernetics*. November/December 1992. 22(6):1414–1427.
- [10] Abe S., Lan M. S. Fuzzy rules extraction directly from numerical data and its application to pattern classification // *IEEE Trans. On Fuzzy Systems*. 1995. V. 3. P.18–28.
- [11] Ходашинский И.А., Сарин К.С., Филимоненко И.В. Алгоритмы «стадо криля» и кусочно-линейной инициализации для построения систем типа Такаги – Сугено // *Автометрия*. 2017. № 4(53). С. 84–94.
- [12] Souza P.V.C. Fuzzy neural networks and neuro-fuzzy networks: A review the main techniques and applications used in the literature // *Appl. Soft Comput.* 2020. vol. 92. 106275.
- [13] Jang J.S.R. ANFIS: Adaptive-Network-Based Fuzzy Inference System // *IEEE Transactions on Systems Man & Cybernetics*. 1993. 23:665–685.
- [14] Neuro-Adaptive Learning and ANFIS [Электронный ресурс]. URL: <https://www.mathworks.com/help/fuzzy/neuro-adaptive-learning-and-anfis.html> (дата обращения 09.03.2023).