

Обучение нейро-нечеткой системы на основе метода разности площадей¹

Аннотация. Рассмотрен новый метод обучения нечетких MISO-систем, используемых в своей структуре нечетко-логический вывод с линейными функциями принадлежности. Особенностью данного способа является применение в качестве дефаззификации метода разности площадей. Синтезирована новая структурная схема разработанной нейро-нечеткой системы вывода. Приведены результаты численного моделирования, показывающие принцип работы предложенного метода и дан сравнительный анализ с традиционной моделью ANFIS. Представлен сравнительный анализ использования в нечетком выводе различных формул нахождения мягкого минимума и t-норм. Разработанный метод увеличивает точность нечетких систем, причем его работоспособность подтверждена рядом имитационных экспериментов.

Ключевые слова: нечетко-логический вывод, мягкие вычисления, дефаззификация, метод разности площадей, обучение, адаптивные нейро-нечеткие системы вывода, RMSE.

Введение

Модели приближенных рассуждений, основанные на нечетко-логическом выводе, зарекомендовали себя как эффективное средство интеллектуализации систем управления, принятия решений и распознавания образов [1]. Наряду с уменьшением вычислительной сложности и, как следствие, упрощением программной реализации, данный подход обеспечивает ряд дополнительных преимуществ, таких как работоспособность в условиях неполноты исходной информации, возможность разработки макета моделируемой системы с последующей ее настройкой.

В настоящее время известны подходы к построению моделей нечетко-логического вывода, основанные на схемах приближенных рассуждений Мамдани и Такаги-Сугэно [2]. При этом для обучения нечетких систем, как правило, используют адаптивные нейро-нечеткие системы вывода (ANFIS – adaptive neuro-fuzzy inference system) [3] и гибридные технологии, сочетающиеся с не-

четкими моделями: искусственные нейронные сети [4, 5], генетические алгоритмы [6, 7] и алгоритмы муравьиной колонии [8]. Известно, что проклятие размерности (curse of dimensionality), при которой наблюдается рост числа заключений нечеткого вывода в геометрической прогрессии при увеличении входных переменных системы и/или числа термов у входных переменных [9, 10], снижает точность обучения нечетких моделей. Данный недостаток объясняется использованием в традиционных алгоритмах нечеткого вывода жестких арифметических операций нахождения минимума и максимума [11]. При этом на точность нечетко-логических моделей влияют структура нечетких правил [12] и метод дефаззификации результирующего нечеткого множества. Одним из способов устранения данных недостатков является использование в нечетких моделях мягких арифметических операций [13], что позволяет обеспечить отклик результирующей переменной на любое изменение входных параметров, а также обучение нечеткой системы на основе метода разности площадей [14].

¹Работа выполнена при поддержке гранта Президента РФ МД-2983.2015.8.

1. Постановка задачи

Рассматривается нечеткая MISO-система, имеющая входные и выходные переменные, заданные треугольными функциями принадлежности (ФП), причем взаимосвязь между ними формируется на основе нечетких правил вида:

$$\text{Rule}_i: \text{Если } X_1 = x_{i1} \text{ И } X_2 = x_{i2} \text{ И } \dots \text{ И } X_n = x_{in} \\ \text{То } Y = y_i, \quad (1)$$

где X_n – входная переменная; n – количество входных переменных; x_{in} – лингвистический терм, описывающий входные ФП; i – количество термов у входной/выходной переменной; Y – выходная переменная; y_i – лингвистический терм, описывающий выходные ФП.

Нечеткая MISO-система осуществляет отображение на основе одного из традиционных методов дефазификации, к которым относятся: среднего максимума (Middle of Maxima – MM); первого максимума (First of Maxima – FM); последнего максимума (Last of Maxima – LM); центра тяжести (Center of Gravity – CG); центра сумм (Center of Sums – CS) и высот (Model of Height – MH). Например, при использовании метода центра тяжести отображение нечеткой MISO-системы имеет следующий вид:

$$y_{defuz} = \frac{\int_{\min}^{\max} y \cdot \mu'(y) dy}{\int_{\min}^{\max} \mu'(y) dy}, \quad (2)$$

где $\min$, $\max$ – пределы интегрирования нечеткого множества; $\mu'(y)$ – ФП выходной переменной после реализации на основе нечетких правил (1) процедуры нечеткого вывода.

Задача оценки нечеткой MISO-системы сводится к поиску такого решения, при котором среднеквадратическое отклонение (RMSE – root mean square error) минимально [15, 16]:

$$RMSE = \frac{1}{M} \sqrt{\sum_{i=1}^n (y_{экс} - y_{defuz})^2} \rightarrow \min, \quad (3)$$

где $y_{экс}$ – множество обучаемых данных; M – количество точек в обучаемой выборке.

В традиционных нечетких MISO-системах основными факторами, приводящими к увеличению RMSE, являются:

- несовершенство моделей дефазификации результирующего нечеткого множества, более подробно рассмотрены в работе [14];
- использование в структуре нечеткого вывода жестких формул нахождения минимума и максимума [11], что снижает аддитивность нечетких моделей и приводит к негладкой поверхности отклика результирующей переменной;
- большое число заключений нечетко-логического вывода, что приводит к снижению оперативности принятия управляющего решения при работе нечеткого вывода, так при реализации формулы (2) число заключений в нечетком выводе всегда равняется количеству нечетких правил [8], поэтому сокращение числа заключений позволит увеличить оперативность и минимизировать RMSE.

Как правило, поверхность отклика в обучаемой выборке имеет сложный рельеф, тогда модели поиска, основанные на традиционных моделях ANFIS, не всегда позволяют достигать оптимальных решений. Для решения проблемы, связанной с минимизацией функции (3), предлагается использовать мягкий алгоритм нечетко-логического вывода [17], в качестве метода дефазификации использовать модель разности площадей, приведенную в работе [14], для обучения использовать метод распространения обратной ошибки [18, 19].

2. Метод обучения нечеткой MISO-системы

Метод обучения нечеткой MISO-системы реализован в виде ниже следующей последовательности шагов. Необходимо отметить, что ограничением данного метода является то, что термы ФП должны иметь либо треугольный, либо трапециевидный вид.

Шаг 1. Фазификация входных переменных. Пусть нечеткая MISO-система состоит из двух входных переменных, имеющих по три терма $X_1 = \{x_{11}\} + \{x_{12}\} + \{x_{13}\}$ и $X_2 = \{x_{21}\} + \{x_{22}\} + \{x_{23}\}$ и выходную переменную, имеющую пять термов, $y \in Y = \{y_1\} + \{y_2\} + \{y_3\} + \{y_4\} + \{y_5\}$. При этом термы описываются:

Треугольные ФП

$$f(x; a, b, c) = \begin{cases} 0, & x \leq a; \\ \frac{x-a}{b-a}, & a \leq x \leq b; \\ \frac{c-x}{c-b}, & b \leq x \leq c; \\ 0, & c \leq x. \end{cases}$$

Трапецевидная ФП

$$f(x; a, b, c, d) = \begin{cases} 0, & x \leq a; \\ \frac{x-a}{b-a}, & a \leq x \leq b; \\ 1, & b \leq x \leq c; \\ \frac{d-x}{d-c}, & c \leq x \leq d; \\ 0, & d \leq x. \end{cases} \quad (4)$$

где a, b, c, d – параметры ФП; x – количественное значение входного параметра.

ФП, имеющие треугольный вид для нечеткой MISO-системы, представлены на Рис. 1.

Шаг 2. Определение степеней принадлежности для каждой предпосылки на основе информации, поступающей от сенсоров систем активного контроля, например при $x_1=82$ и $x_2=256$:

$$X_1 = (x_{11}, x_{12}, x_{13},) = (0; 0,4; 0,6),$$

$$X_2 = (x_{21}, x_{22}, x_{23},) = (0; 0,2; 0,8).$$

Шаг 3. Синтез базы знаний, содержащих нечеткие правила вида (1), сведены в Табл. 1.

Шаг 4. Построение матрицы нечетких отношений. При составлении матрицы нечетких отношений был учтен подход, предложенный в работе [12]. Следует отметить, что в традиционных моделях Мамдани и Сугэно для реали-

зации композиционного правила в нечетко-логическом выводе используются операции нахождения жесткого минимума и максимума. Вследствие этого традиционные алгоритмы нечетко-логического вывода не обладают свойством аддитивности, под которым понимается отсутствие реакции на выходе нечеткой MISO-системы при изменении значений на ее входе [20]. Использование мягких арифметических операций нахождения минимума (soft-min) и максимума (soft-max) позволяет устранять данный недостаток. Формулы нахождения мягкого минимума и максимума типа I имеют вид:

Жесткий минимум: $\min(x_1, x_2) = \frac{x_1 + x_2 - (x_1 - x_2) \cdot \text{sgn}(x_1 - x_2)}{2},$ $\text{sgn}(x_1 - x_2) = \begin{cases} -1, & \text{if } x_1 - x_2 < 0; \\ 0, & \text{if } x_1 - x_2 = 0; \\ 1, & \text{if } x_1 - x_2 > 0. \end{cases}$	(5)
Мягкий минимум: $\min(x_1, x_2)_\delta = \frac{x_1 + x_2 + \delta^2 + \sqrt{(x_1 - x_2)^2 + \delta^2}}{2}.$	
Мягкий максимум: $\text{soft-max}(x_1, x_2) = \gamma \cdot \max(x_1, x_2) + 0,5(1 - \gamma)(x_1 + x_2) , \text{ где } \gamma = 0,9$	

Как показано в работе [13], формула (5), используемая для нахождения мягкого минимума, при значениях входных переменных равных 0 дает отрицательный результат, так например




Рис. 1. Графики функций ФП

а) – первая входная переменная x_1 ; б) – вторая входная переменная x_2 ; в) – выходная переменная y

Табл. 1. Нечеткая база знаний

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

при $x_1=0$ и $x_2=0$ ответ на выходе будет равняться $-0,02375$. Отрицательные ответы будут получаться до значений входных переменных, равных $x_1=0,01$ и $x_2=0,05$, в этом случае ответ, полученный с помощью формулы (5), будет равен $-0,00077$, при $x_2=0,06$, ответ станет положительным и будет равняться $0,000895$. Однако данное обстоятельство является положительным свойством данной формулы. При использовании известных [2] формул нахождения минимума при входных значениях равных 0, т.е. $x_1=0$ и $x_2=0$, ответ будет равен 0. На следующих операциях нечеткого вывода, ответ также будет равен нулю, а сама нечеткая система станет не аддитивной. Поэтому при исследовании нечетких систем у них получается большое значение среднеквадратического отклонения (RMSE).

В литературе [13] приведены формулы нахождения мягкого минимума типа II, причем в этой работе показано, что формулы (6) дают идентичный результат:

Мягкий минимум: $\min_{\delta}(x_1, x_2)_{II_1} = \frac{x_1 + x_2 - \frac{(x_1 - x_2) \cdot (x_1 - x_2)}{\sqrt{(x_1 - x_2)^2 + \delta^2}}}{2} =$ $= \frac{x_1 + x_2}{2} - \frac{(x_1 - x_2)^2}{2 \cdot \sqrt{(x_1 - x_2)^2 + \delta^2}}.$	(6)
Мягкий минимум: $\min_{\delta}(x_1, x_2)_{II_2} =$ $0,5 \cdot \left[x_1 + x_2 + \frac{\delta^2}{\sqrt{(x_1 - x_2)^2 + \delta^2}} - \sqrt{(x_1 - x_2)^2 + \delta^2} \right].$	

Также необходимо отметить, что в работе [2] в формуле нахождения мягкого минимума существует ошибка. При рассмотрении английского варианта данной работы видно, что в формуле (5) для нахождения мягкого минимума используется сумма степеней принадлежности:

Мягкий максимум: $\max_{\delta}(x_1, x_2)_I = \frac{x_1 + x_2 + \delta^2 + \sqrt{(x_1 - x_2)^2 + \delta^2}}{2}.$	(7)
---	-----

В русской версии данной работы используется разность степеней принадлежности, формула (5).

Проведенные исследования формулы (7) показали, что данная формула может использоваться как формула мягкого максимума. Также следует отметить, что для реализации операций мягкого минимума могут использоваться так называемые t-нормы [2], например формулы:

Произведение PROD: $\min_t(x_1, x_2)_I = x_1 \times x_2.$ Произведение Эйнштейна: $\min_t(x_1, x_2)_I = \frac{x_1 \times x_2}{2 - (x_1 + x_2 - x_1 \times x_2)}.$	(8)
---	-----

За счет рационального расположения элементов в матрице нечетких отношений, количество заключений в нечетком выводе равно числу термов у выходной ФП, в данном случае – 5 (Табл. 2). В то время как в традиционных нечетко-логических моделях число заключений с учетом рекомендаций [2, 12] равнялось бы количеству нечетких правил и находилось бы в пределах от 9 до 15. Результаты моделирования матрицы нечетких отношений приведены в Табл. 3.

Шаг 5. Дефазификация выходного результата, основана на использовании метода разности площадей, предложенного в работе [14]. Данный метод определяет площади треугольных и/или трапециевидных термов ФП с помощью универсальной формулы (Рис. 2):

$$S = \frac{h}{6}(b_1 + 4b_2 + b_3), \quad (9)$$

где h – высота геометрической фигуры; b_1 , b_2 , b_3 – длина нижнего, среднего и верхнего основания геометрической фигуры.

Табл. 2. Матрица нечетких отношений

Выходной терм	Композиция			Максимум
y'_5	$b_1 = \text{soft-min}(x_{11}, x_{21})$			b_1
y'_4	$b_2 = \text{soft-min}(x_{11}, x_{22})$	$b_4 = \text{soft-min}(x_{12}, x_{21})$		$\text{soft-max}(b_2, b_4)$
y'_3	$b_3 = \text{soft-min}(x_{11}, x_{23})$	$b_5 = \text{soft-min}(x_{12}, x_{22})$	$b_7 = \text{soft-min}(x_{13}, x_{21})$	$\text{soft-MAX}(b_3, b_5, b_7)$
y'_2	$b_6 = \text{soft-min}(x_{12}, x_{23})$	$b_8 = \text{soft-min}(x_{13}, x_{22})$		$\text{soft-max}(b_6, b_8)$
y'_1	$b_9 = \text{soft-min}(x_{13}, x_{23})$			b_9

Табл. 3. Расчет матрицы нечетких отношений для мягких и жестких операций

Терм	Жесткие формулы				Мягкие формулы			
	Композиция			Максимум	Композиция			Максимум
y'_5	0			0	-0,02375			-0,02375
y'_4	0	0		0	-0,00183	-0,00031		-0,00038
y'_3	0	0,2	0	0,2	0,00047	0,198172	0,00021	0,178883
y'_2	0,2	0,4		0,4	0,199694	0,399694		0,389694
y'_1	0,6			0,6	0,598172			0,598172




Рис. 2. Площади геометрических фигур
(формулы (6) для расчета площадей приведены при $h=1$)




Рис. 3. Определение высот усеченных термов выходной ФП

При использовании данного метода отпадает необходимость в операциях усечения термов выходной ФП и последующего их объединения, используемых в традиционных нечетких моделях.

Шаг 5.1. Определение общей площади фигуры с учетом формулы (9), описывающей выходную переменную y (Рис.1, в), состоящую из пяти треугольных термов:

$$S_{\text{общ}} = n \cdot \frac{b_1}{2} = \frac{5 \cdot (530 - 500)}{2} = 75, \quad (10)$$

где n – количество термов выходной лингвистической переменной ($n=5$).

Шаг 5.2. Усечение термов выходной ФП. Данная операция выполняется:

$$\mu(y)'_i = \text{soft} \frac{n}{i=1} \min(y'_i; \mu(y_i)). \quad (11)$$

Результат реализации данной операции в графическом виде представлен на Рис. 3.

Шаг 5.3. Нахождение высоты усеченных термов выходной функции принадлежности. Так на Рис.3 высота усеченных термов $h(y_1)=0.598172$, $h(y_2)=0.389694$, $h(y_3)=0.178883$, $h(y_4)=0$, $h(y_5)=0$.

Шаг 5.4. В зависимости от высоты усеченного терма определить площадь для каждого из них выходной ФП:

$$S_n = \begin{cases} S_n = 0, & \text{если } h = 0; \\ S_n = \frac{b_1}{2}, & \text{если } h = 1; \\ S_n = \frac{h}{2}(b_1 + b_3), & \text{если } h \in (0, 1). \end{cases} \quad (12)$$

Учитывая формулу (12), рассчитаем площади усеченных термов:

$$S_1 = \frac{h \cdot (b_1 + b_3)}{2} = \frac{0,598172 \cdot [(530 - 500) + 13]}{2} = 12,86,$$

$$S_2 = \frac{h \cdot (b_1 + b_3)}{2} = \frac{0,389694 \cdot [(545 - 515) + 19]}{2} = 8,38,$$

$$S_3 = \frac{h \cdot (b_1 + b_3)}{2} = \frac{0,178883 \cdot [(560 - 530) + 25]}{2} = 3,85,$$

$$S_4 = 0,$$

$$S_5 = 0.$$

Шаг 5.5. Определить общую суммарную площадь усеченных термов выходной переменной:

$$S_{\text{усеч}} = \sum_{i=1}^n S_i = 12,86 + 8,38 + 3,85 + 0 + 0 = 25,09. \quad (13)$$

Шаг 5.6. Расчет отношения общей площади и площади усеченной фигуры:

$$D = \frac{S_{\text{усеч}}}{S_{\text{общ}}} = \frac{25,09}{75} = 0,335. \quad (14)$$

Шаг 5.7. Найти пропорциональное отношение:

$$\begin{aligned} y_{\text{defuz}} &= [D \cdot (y_{\text{кон}} - y_{\text{нач}})] + y_{\text{нач}} = \\ &= [0,335 \cdot (590 - 500)] + 500 = 530,15. \end{aligned} \quad (15)$$

где $y_{\text{кон}}$, $y_{\text{нач}}$ – конечное и начальное значение (Рис.1, в) диапазона величин выходной переменной.

Шаг 6. Процедура обучения. На данном шаге с помощью метода распространения обратной ошибки происходит обучение ANFIS, т.е. корректировка усеченных площадей термов выходной переменной до тех пор, пока полученное значение y_{defuz} с помощью формулы (15) не станет максимально приближено к заранее известному эталонному значению $y_{\text{этл}}$ в соответствии с соотношением:

$$y_{\text{вых}} = (w)_i + \delta(y_{\text{defuz}} - y_{\text{этл}}), \quad (16)$$

где δ – шаг обучения нейро-нечеткой системы вывода (по умолчанию $\delta=0,01$).

Как было показано в работе [14], в качестве весового параметра w , рекомендуется использовать соотношение $n/2$, используемое в формуле (10) для определения общей площади. На первом шаге обучения $w = n/2 = 2,5$.

3. Нейро-нечеткая система вывода

Рассмотрим нейро-нечеткую систему вывода, в которой слои соответствуют шагам приведенного в пункте 2 метода ее обучения (Рис. 4).

Слой 1. Формируется вектор входных переменных $U_{\text{вх}} = f(X_1, X_2)$, характеризующий зна-

чения, например, полученные от датчиков системы активного контроля сложных систем управления.

Слой 1'. Задается вектор выходной величины $U_{\text{вых}} = f(Y)$.

Слой 2. Фаззификация входных переменных. Каждая из входных переменных задается в виде трех параметризованных термов $X_1 = \{x_{11}\} + \{x_{12}\} + \{x_{13}\}$, $X_2 = \{x_{21}\} + \{x_{22}\} + \{x_{23}\}$ [21] (Рис.1).

Слой 2'. Фаззификация выходной переменной, которая задается в виде пяти параметризованных термов: $Y = \{y_1\} + \{y_2\} + \{y_3\} + \{y_4\} + \{y_5\}$ (Рис.1).

Слой 3. Рассчитываются b параметры матрицы нечетких отношений (Табл. 3).

Слой 4. Расчет выходных параметров y'_i матрицы нечетких отношений.

Слой 5. Определение высоты, по которой в зависимости от нечетких правил (Табл. 3) происходит усечение термов выходной переменной, формула (11).

Слой 6. Нахождение площадей усеченных термов выходной переменной, формула (9).

Слой 6'. Формирование весового коэффициента w , формула (16).

Слой 7. Нахождение суммарной площади усеченных термов выходной переменной, формула (13).

Слой 7'. Расчет общей площади фигуры, формула (10).

Слой 8. Расчет отношения общей площади и суммарной площади усеченных термов выходной переменной, формула (14).

Слой 9. Дефаззификация результирующей переменной, формула (15).

Слой 9. Обучение нейро-нечеткой системы вывода с помощью формулы (16), т. е. подбор для каждой обучаемой точки весового коэффициента до тех пор, пока разность между заданным значением и дефаззифицируемым результатом не будет минимальна.

4. Численное моделирование работы адаптивной нейро-нечеткой системы вывода

Рассмотрим процедуру моделирования. Нечеткая MISO-система сформирована на основе треугольных ФП (Рис. 1). Исследование разработанного метода обучения нечеткой системы




Рис. 4. Структура адаптивной нейро-нечеткой системы вывода

проводилось при решении задачи минимизации коэффициента RMSE. В качестве тестовых функций использовалась таблица наблюдений, состоящая из 441 точки (Рис. 5), полученных случайным образом в диапазоне значений, соответствующих распределению выходной ФП. Критерием качества аппроксимации является ошибка вывода, определяемая с помощью RMSE.

В процессе работы метода обучения нейро-нечеткой системы вывода изменялись следующие параметры: весовой коэффициент w ; ошибка обучения $\text{error} = 0,01$; количество итераций обучения $it = 50$.

В начале эксперимента был произведен расчет отклика результирующей переменной при использовании модели Мамдани с применением жестких и мягких арифметических операций в структуре нечеткого вывода (Рис. 6).




Рис. 5. Графическое представление 441 точки в таблице наблюдения




Рис. 6. Моделирование работы нечеткого вывода для модели Мамдани без использования процедуры обучения

- а) – с использованием жестких арифметических операций
б) – с использованием мягких арифметических операций




Рис. 7. Моделирование работы нечеткого вывода с использованием метода разности площадей без использования процедуры обучения

- а) – с использованием жестких арифметических операций
б) – с использованием мягких арифметических операций

Затем был произведен расчет отклика результирующей переменной при использовании в качестве дефазификации метода разности площадей с применением жестких и мягких арифметических операций в структуре нечеткого вывода (Рис. 7).

Как видно из анализа Рис. 6 и Рис. 7, коэффициент RMSE будет иметь наименьшее значение для предложенного метода дефазификации на основе метода разности площадей, так как у исследуемых моделей отклик результирующей переменной наблюдается при любом изменении одной из входных переменных, в то время как для моделей, использующих жесткие арифметические операции, имеются зоны нечувствительности, в которых отклик результирующей переменной не происходит. Так, для диапазона $X_1 \in [0, 20]$ и $[90, 100]$ (Рис. 7, а), а переменная $X_2 \in [280, 300]$ отклик результирующей величины не наблюдается.

Далее было осуществлено моделирование метода обучений нейро-нечеткой сети для метода

разности площадей с использованием жестких и мягких арифметических операций и расчет коэффициента RMSE (Рис. 8). При этом коэффициент RMSE для жесткой MISO-системы составил $RMSE_{hard}=1.4945$, а для мягкой MISO-системы $RMSE_{soft}=0.01232$. Оценка временных параметров процедуры работы нечетко-логического вывода приведена в работе [22].

С целью более детального исследования работы, предложенной в статье адаптивной нейро-нечеткой системы вывода (Рис. 4), проведем расчет RMSE при использовании на шаге 4 в структуре нечеткого вывода различных формул нахождения мягкого минимума и t-нормы.

Рассмотрим моделирование адаптивной нейро-нечеткой системы с использованием в ней формулы (5) мягкого минимума типа I; формулы (6) мягкого минимума типа II; формул (8) t-норм произведения PROD и произведения Эйнштейна. Результаты моделирования сведены в Табл. 4. Графическое представление полученных результатов приведено на Рис. 9




Рис. 8. Обучение нейро-нечеткой сети с использованием метода

- а) – для жестких арифметических операций
б) – для мягких арифметических операций

Табл. 4. Расчет RMSE для различных формул, используемых в структуре нечеткого вывода

Расчет RMSE			
Мягкий минимум тип I (формула 5)	Мягкий минимум тип II (формула 6)	t-норма произведение PROD (формула 8)	t-норма произведение Эйнштейна (формула 8)
0,01232	0,01415	0,02344	0,02548




Рис. 9. Обучение нейро-нечеткой сети с использованием метода разности площадей

- а) – мягкой формулы минимума типа II
б) – t-норма произведение PROD
в) – t-норма произведение Эйнштейна

Расчеты, приведенные в Табл. 4, показывают, что при использовании формулы (5) нахождения мягкого минимума типа I значение RMSE минимально. Данная формула имеет преимущество перед формулой (6) мягкого минимума типа II в 1,15 раза, перед t-нормой произведения PROD (8) в 1,9 раза, и перед t-нормой произведения Эйнштейна (9) в 2,1 раза.

Для сравнения разработанного метода обучения с существующими моделями ANFIS было проведено исследование результатов обучения нечетких систем в системе математического программирования MatLAB (модуль ANFIS-редактор). Следует отметить, что данная система позволяет обучать нейро-нечеткую сеть только на основе модели Сугэно. В ANFIS-редакторе была


сформирована нечеткая MISO-система, имеющая две входные переменные с тремя термами в каждой (Рис. 10). В автоматическом режиме были сгенерированы 9 нечетких правил.

При обучении по данным значениям, представленным на Рис. 5, ошибка обучения составила $RMSE_{matlab}=8,2588$ (Рис. 11).


Как показал анализ Рис. 11 и Рис. 8, точность предложенного метода обучения при аналогичных показателях в $8,5288/0,01232=692,3$ раз выше.

С целью минимизации коэффициента RMSE в среде MatLab увеличим число термов входных переменных. Расчет сведен в Табл. 5.

При наилучшем результате обучения (опыт № 6) поверхность отклика результирующей переменной представлена на Рис. 12.



а)




б)


Рис. 10. ANFIS-редактор

а) – структура нейро-нечеткой сети

б) – наблюдаемая выборка



а)



б)

Рис. 11. Ошибка обучения в ANFIS при 50 итераций а) и поверхность отклика результирующей переменной б)

Табл. 5. Расчет коэффициента RMSE

Номер опыта	Число термов у входных переменных	Число нечетких правил	RMSE
1	$x_1=5, x_2=5$	25	8,1701
2	$x_1=8, x_2=8$	64	7,8784
3	$x_1=12, x_2=12$	144	7,1358
4	$x_1=16, x_2=16$	256	5,2218
5	$x_1=20, x_2=20$	400	2,7919
6	$x_1=21, x_2=21$	441	0,001




Рис. 12. Отклик результирующей переменной при RMSE=0.001

5. Обсуждение результатов моделирования

Как и следовало ожидать, минимальное значение RMSE при моделировании в среде MatLAB получено в режиме, когда количество нечетких правил равняется числу обучаемых точек. Так, рекомендуемое минимальное число нечетких правил с учетом рекомендаций [2] определяется по формуле $x = l^z = 21^2 = 441$, где l – число термов, z – количество входных переменных. Анализ Табл. 5, показал, что в опыте № 6 при числе нечетких правил, равном 441, и 21 терму у каждой из входных переменных значение RMSE минимально. Следует отметить, что такое большое количество заключений снижает оперативность принятия управляющих решений механизма нечетко-логического вывода и приводит нечеткую MISO-систему к появлению «проклятия размерности». Так, если количество обучаемых точек будет равно 1500, то для получения минимального значения RMSE необходимо будет, чтобы количество термов у входных переменных равнялось 39 единицам.

Из полученных результатов моделирования сделан следующий вывод. В случае, когда в нечеткой MISO-системе для реализации нечетко-логического вывода используются жесткие арифметические операции нахождения минимума и максимума, то отклик результирующей переменной имеет зоны нечувствительности (Рис. 7, а и Рис. 8, а). Так, в областях, где переменная X_1 принадлежит диапазону $[0,20]$ и $[90,100]$, а переменная $X_2 \in [280,300]$, возникает зона нечувствительности, в которой отклик результирующей переменной не зависит от изменения входных переменных. Появление зон нечувствительности характерно для всех нечетко-логических систем, использующих в своей структуре жесткие арифметические операции нахождения минимума и максимума. Следовательно, в нечетких MISO-системах, в которых при моделировании возникают зоны нечувствительности, обучение невозможно. Поэтому получение малых коэффициентов $RMSE < 1$ для систем, использующих жесткие арифметические операции, маловероятно. Получение коэффициента $RMSE$ меньше 1 возможно только в том случае, если нечеткая система не имеет зон нечувствительности, например, как показано на Рис.7, б и 8, б. Для того, чтобы отклик ре-

зультирующей нечеткой MISO-системы изменялся во всей области допустимых значений, в структуре нечетко-логического вывода необходимо использовать либо мягкие арифметические операции нахождения минимума или максимума, либо использовать так называемые s- и t- нормы.

Приведенный анализ использования в структуре адаптивной нейро-нечеткой системы вывода различных формул нахождения мягкого минимума и t-, s- норм, показал преимущество формулы нахождения мягкого минимума типа I. Она имеет преимущество перед формулой (6) мягкого минимума типа II в 1,15 раза, перед t-нормой произведения PROD (8) в 1,9 раза, и перед t-нормой произведения Эйнштейна (9) в 2,1 раза.

Предложенный метод обучения нечетких MISO-систем имеет отклик результирующей переменной во всей области определения входных и выходных параметров. Поэтому по сравнению с традиционной моделью ANFIS он имеет преимущество по коэффициенту $RMSE$ в 692,3.

Литература

1. Панкова Л.А., Пронина В.А. Семантический текстовый поиск, основанный на теории нечетких множеств // Искусственный интеллект и принятие решений. 2013. № 3. С. 19-23.
2. Пегат А. Нечеткое моделирование и управление / А. Пегат, пер. с англ. – М.: БИНОМ. Лаборатория знаний. 2012. 798 с.
3. Mousavi S.J., Ponnambalam K., Karray F. Inferring operating rules for reservoir operations using fuzzy regression and ANFIS // Fuzzy set and system. 2007. Vol. 158. Issue 10. p. 1064-1082.
4. Емалетдинова Л.Ю., Струнkin Д.Ю. Моделирование диагностической деятельности врача на основе нечеткой нейронной сети // Искусственный интеллект и принятие решений. 2010. № 3. С. 73-78.
5. Amirkhani S., Nasirivatan Sh., Kasaeian A.B., Hajinezhad A. ANN and ANFIS models to predict the performance of solar chimney power plants // Renewable Energy. 2015. Vol. 83. p. 597-607.
6. Sarkheyli A., Zain A.M., Sharif S. Robust optimization of ANFIS based on a new modified GA // Neurocomputing. 2015. Vol. 166. p. 357-366.
7. Бобырь М.В., Милостная Н.А. Механизм адаптации нечеткой системы вывода на основе генетического алгоритма // Промышленные АСУ и контроллеры. 2015. № 3. С. 27-32.
8. Ходашинский И.А., Дудин П.А. Идентификация нечетких систем на основе прямого алгоритма муравьиной колонии // Искусственный интеллект и принятие решений. 2011. № 3. С. 26-33.
9. Li S., Qiu J., Yang X., Liu H., Wan D., Zhu Y. A novel approach to hyperspectral band selection based on spectral

- shape similarity analysis and fast branch and bound search // *Engineering Applications of Artificial Intelligence*. 2014. Vol. 27. p. 241-250.
10. Lee M.-L., Chung H.-Y., Yu F.-M. Modeling of hierarchical fuzzy systems // *Fuzzy Sets and Systems*. 2003. Vol. 138. Issue 2. p. 343-361.
 11. Denga X., Wang X. Incremental learning of dynamic fuzzy neural networks for accurate system modeling // *Fuzzy Sets and Systems*. 2009. Vol. 160. Issue 7. p. 972-987.
 12. Бобырь М.В. Влияние числа правил на обучение нечетко-логической системы // *Вестник компьютерных и информационных технологий*. 2014. № 11 (125). С. 28-35.
 13. Бобырь М.В., Милостная Н.А. Анализ использования мягких арифметических операций в структуре нечетко-логического вывода // *Вестник компьютерных и информационных технологий*. 2015. № 7. С. 7-14.
 14. Бобырь М.В., Кулабухов С.А. Дефаззификация вывода из базы нечетких правил на основе метода разности площадей // *Вестник компьютерных и информационных технологий*. 2015. № 9 (135). С. 32-41.
 15. Ротштейн А.П., Штовба С.Д. Моделирование надежности человека-оператора с помощью нечеткой базы знаний Сугено // *Автоматика и телемеханика*. 2009. № 1. С. 180-187.
 16. Бобырь М.В., Титов В.С. Метод коррекции параметров режима резания в системах с ЧПУ // *Мехатроника, автоматизация, управление*. 2010. № 7. С. 49-53.
 17. 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.
 18. Емельянов С.Г., Бобырь М.В., Анциферов А.В. Алгоритм самообучения адаптивных нейро-нечетких систем на основе мягких вычислений // *Информационно-измерительные и управляющие системы*. 2013. Т. 11. № 8. С. 3-9.
 19. Бобырь М.В., Титов В.С., Червяков Л.М. Адаптация сложных систем управления с учётом прогнозирования возможных состояний // *Автоматизация. Современные технологии*. 2012. № 5. С. 3-10.
 20. Бобырь М.В., Кулабухов С.А., Титов Д.В. Оценка влияния числа обучаемых точек на аддитивность нечетких систем // *Промышленные АСУ и контроллеры*. 2014. № 10. С. 30-35.
 21. Бобырь М.В., Емельянов С.Г., Милостная Н.А. О некоторых свойствах моделирования адаптивных нейро-нечетких систем на основе упрощенного нечетко-логического вывода // *Информационно-измерительные и управляющие системы*. 2014. Т. 12. № 5. С. 4-12.
 22. Бобырь М.В., Титов Д.В., Кулабухов С.А. Оценка прогнозирования принятия управляющих решений в условиях неопределенности // *Телекоммуникации*. 2015. № 11. С. 39-44.

Бобырь Максим Владимирович. Профессор кафедры «Вычислительная техника» ФГБОУ ВО «Юго-Западный государственный университет». Доктор технических наук. E-mail: fregat_mn@rambler.ru max_b@mail333.com

Милостная Наталья Анатольевна. Преподаватель кафедры «Вычислительная техника» ФГБОУ ВО «Юго-Западный государственный университет». Кандидат технических наук. E-mail: nat_mil@mail.ru

Кулабухов Сергей Алексеевич. Аспирант кафедры «Вычислительная техника» ФГБОУ ВО «Юго-Западный государственный университет». E-mail: 79513146681@ya.ru

Teaching of neuro-fuzzy system on the basis of the method of difference areas

M.V. Bobyr, S.A. Kulabuchov, N.A. Milostnaya

Abstract: A new method of teaching MISO-fuzzy systems is reviewed and it uses in its structure fuzzy inference with linear membership functions. The peculiarity of this method is the usage of the difference of areas in the quality of defuzzification. The structural scheme of the worked out the neuro-fuzzy inference system was synthesized. The results of numerical modeling are shown and demonstrate the principle of the work of the suggested method and the comparative analysis with the traditional model of ANFIS is given. The worked out method increases accuracy of the fuzzy systems, and besides it is proved with the number of imitative experiments.

Keywords: fuzzy inference, soft computing, defuzzification, method of difference areas, teaching, adaptive neuro-fuzzy inference system, RMSE.

Bobyr Maxim Vladimirovich. Professor South-West state university Computer Science dept. Full doctor of science. E-mail: maxbobyr@gmail.com fregat_mn@rambler.ru

Milostnaya Nataliya Anatolievna. Researcher South-West state university Science dept. Candidate of Sciences. E-mail: nat_mil@mail.ru

Kulabukhov Sergey Alekseevich. Aspirant South-West state university Computer Science dept. E-mail: Kulabuhov.Sergei@yandex.ru