

СИНТЕЗ И ОПТИМИЗАЦИЯ НЕЛОКАЛЬНЫХ ИНТЕРПРЕТИРУЕМЫХ ЛИНГВИСТИЧЕСКИХ НЕЙРО-НЕЧЕТКИХ МОДЕЛЕЙ

Кукса П.П.

Московский государственный технический университет им. Н.Э. Баумана

Кафедра “Компьютерные системы и сети”

E-mail: pkouxa@yahoo.com

www.geocities.com/pkouxa

Аннотация

Рассматриваются вопросы построения интерпретируемых лингвистических нечетких моделей. Формирование нечетких моделей реализуется на основе гибридных стратегий обучения с использованием нейросетевых представлений. Рассматривается оптимизация (обучение на уровне изменения информационных параметров функций) и синтез на уровне изменения размерности и структуры связей для нейро-нечетких моделей. Предлагается процедура построения интерпретируемых адаптивных моделей и их оптимизации.

В последние годы наблюдается повышение научного и практического интереса к методам интеллектуальной обработки информации, таким как: модели на основе нечеткой логики, искусственные нейронные сети, гибридные модели искусственного интеллекта.

Современные тенденции развития теории и практики интеллектуальных систем напрямую связаны с развитием нового научного направления мягких вычислений и вычислительного интеллекта, сформировавшегося как новая парадигма проектирования и разработки интеллектуальных систем в результате синтеза методов теории нечетких систем, нейронных сетей, эволюционных и генетических алгоритмов.

Появление нового класса гибридных адаптивных моделей диктует необходимость развития методической и алгоритмической базы их построения. В связи с этим видится актуальной тема по созданию и совершенствованию методов построения и обучения интегрированных моделей.

При проектировании адаптивных систем управления, а также в процессе их функционирования широко используются методы обучения. Обучение осуществляется на основе данных различного характера: входо-выходной информации, локальных данных, полученных из результатов управления. Наличие этапа обучения или оптимизации в процедуре построения нечетких моделей позволяет повысить достоверность результатов синтеза и одновременно уменьшить затраты времени на проектирование.

Методами структурной идентификации [2,6] осуществляется формирование набора нечетких правил, описывающего поведение исследуемой системы или алгоритм действия регулятора. Полученная модель оптимизируется в процессе параметрического обучения с целью повышения ее точности и качества.

Существующие методы обучения с использованием нейросетевых алгоритмов [2, 6] имеют существенные недостатки: формируемые в результате нечеткие модели практически не поддаются интерпретации. Проблема интерпретируемости снижает ценность результатов обучения и в определенной степени разрывает цепочку итерационного проектирования. Возникающие трудности интерпретации обусловлены тем, что в нейросетевых алгоритмах обучения при осуществлении адаптации информационных параметров узлов и связей не учитываются семантические ограничения на значения соответствующих параметров нечеткой модели. В силу указанных причин для построения интерпретируемых моделей нейросетевые алгоритмы требуют существенной доработки и модификации: необходима их адаптация применительно к нечетким системам. В настоящей работе рассматриваются вопросы построения интерпретируемых нечетких моделей на основе методов обучения. Под обучением нечеткой системы будем понимать процесс формирования базы правил и настройки параметров модели на основе имеющегося набора данных.

Постановка задачи. При наличии системы данных, соответствующих исходному объекту, правила можно получить методом обучения. Предполагается, что при разработке модели исследуемого объекта (конструктивной основы построения) исходная информация об объекте содержит набор данных в форме вход-выход, и, возможно, априорно известные правила поведения. Для формализации системы на основе комплекса данных в совокупности с известными правилами используется аппарат теории нечетких систем и искусственных нейронных сетей.

Процедура построения и оптимизации нечетких моделей. В процедуре построения нечеткой модели условно можно выделить два этапа [2]:

- 1) этап формирования базы нечетких правил;
- 2) этап адаптации параметров правил, составляющих сформированную базу правил.

Первый этап является этапом структурной идентификации и оптимизации. На этом этапе осуществляется генерация набора правил и оптимизация структуры модели (индуцированного набора нечетких правил).

Второй этап является этапом параметрической оптимизации набора правил и сводится к нахождению оптимальных значений параметров в соответствии с принятым критерием и имеющимися данными.

Множество параметров нечеткой модели включает в себя следующие группы: множество параметров условий; множество параметров заключений, элементами которых являются параметры функций принадлежности (ФП) термов переменных; параметры нечетких операций, используемых в алгоритме нечеткого логического вывода (t- и s- норм, операции дефазификации).

Общая процедура построения нечетких моделей на основе информации об исследуемом объекте в форме данных вида вход-выход может выглядеть следующим образом:

- Шаг 1: Определение входных и выходных величин.
- Шаг 2: Определение типа и числа лингвистических термов для каждой из переменных системы.
- Шаг 3: Формирование функций принадлежности выбранного типа.
- Шаг 4: Генерирование правил логического вывода.
- Шаг 5: Анализ сформированной базы правил и ее оптимизация.
- Шаг 6: Оптимизация нечетких подмножеств входных и выходных переменных.
- Шаг 7: Вычисление оценки качества функционирования, если результат неудовлетворительный, то переход к шагу 2.

Далее раскрывается содержание основных этапов построения и оптимизации нечетких моделей и предлагаются принципы организации обучения в контексте решаемой задачи построения интерпретируемых моделей.

Интерпретируемость нечетких систем. Нечеткая система как согласованное множество отдельных нечетких правил описывающих рассматриваемый объект, систему или процесс является его математической моделью, которая в общем случае допускает содержательную интерпретацию (является логически прозрачной) и обладают свойством наглядности, что упрощает использование и модификацию модели, позволяет ориентировочно предвидеть результаты вычислительного эксперимента с моделью и облегчает контроль их правильности. Обеспечение интерпретируемости при построении модели методом обучения требует специальной организации алгоритмов структурно-параметрической идентификации и обучения.

Предлагается рассматривать свойство интерпретируемости в следующих аспектах:

-семантический аспект интерпретируемости: различимость термов, нормализация подмножеств (существование элемента с единичной степенью принадлежности), покрытие доменов переменных, минимальная мощность терм-множеств;

-синтаксический аспект интерпретируемости: целостность (непротиворечивость) системы правил, минимальная сложность правил, полнота системы правил, минимальное количество правил.

Для того чтобы система правил и модель в целом были интерпретируемыми необходимо выполнение ряда требований и условий, основные из которых приведены в таблице 1. Приведенные критерии интерпретируемости охватывают оба указанных аспекта интерпретируемости.

Таблица 1.

Требования и условия интерпретируемости	
<i>Требования к структуре разбиения доменов переменных</i>	
1)	Различимость нечетких подмножеств нечеткого разбиения
2)	Достаточная величина покрытия доменов (больше пороговой ε) $\forall x \in X_i \exists \tilde{A} \in PX_i : \mu_{\tilde{A}}(x) > \varepsilon, \quad \forall i$
3)	Высота области пересечения соседних нечетких подмножеств не выше пороговой (допустимый диапазон перекрытия min 25%- max 75%) $\forall \tilde{A}, \tilde{B} \in PX_i : \sup_{x \in X_i} \min \{ \mu_{\tilde{A}}(x), \mu_{\tilde{B}}(x) \} < \theta, \quad \forall i$
4)	Должны существовать граничные нечеткие множества $\forall i \exists \tilde{A}, \tilde{B} \in PX_i : \mu_{\tilde{A}}(m_i) = 1 \wedge \mu_{\tilde{B}}(M_i) = 1$
<i>Требования к свойствам нечетких подмножеств</i>	
5)	Нормальность, выпуклость, (унимодалность) нечетких подмножеств Выпуклость: $\forall \tilde{A} \in PX_i \forall x, y, z \in X_i : x < y < z \rightarrow \mu_{\tilde{A}}(y) \geq \min \{ \mu_{\tilde{A}}(x), \mu_{\tilde{A}}(z) \}, \forall i$
<i>Требования компактности</i>	
6)	Небольшое количество нечетких подмножеств в каждом из доменов N_T
7)	Относительно небольшое количество правил N_R
<i>Основное требование интерпретируемости</i>	
8)	Единственность представления лингвистических термов $\forall i (LT(A_i^{(r)}) = LT(A_i^{(r')})) \rightarrow \mu_{A_i^{(r)}} = \mu_{A_i^{(r')}}, \quad \forall r \neq r' \quad r, r' = \overline{1, N_R}$

Примечание: В табл. 1 использованы следующие обозначения:

X_i, m_i, M_i - i -й домен, его левая и правая граница, соответственно;

PX_i - семейство нечетких подмножеств i -го домена;

\tilde{A}, \tilde{B} - нечеткие подмножества, $\mu_{\tilde{A}}, \mu_{\tilde{B}}$ - функции принадлежности \tilde{A} и \tilde{B} ;

$A_i^{(r)}$ - нечеткое подмножество i -го домена в r -том правиле;

$LT(A_i^{(r)})$ - наименование нечеткого подмножества.

Некоторые из перечисленных требований хотя и носят качественный характер, но могут быть оценены количественно, что позволяет учитывать их в алгоритмах идентификации и оптимизации. Условия 6, 7 реализуются в алгоритмах структурно-параметрической идентификации как ограничения, задаваемые разработчиком и определяющие максимально возможную сложность генерируемой модели. Требование 5 обеспечивается при использовании большинства стандартных типов функций принадлежности (треугольные, гауссовы и ряд других). Условия 1-4 должны, прежде всего, обеспечиваться в алгоритмах начальной инициализации в части конструирования нечетких множеств. Условие 8 обеспечивается организацией *нелокальных* (связанных) нейро-нечетких моделей и *связанной адаптацией* параметров в процессе оптимизации [2].

Структурный синтез и оптимизация. В настоящее время предложено большое число разнообразных методов решения проблемы структурной и параметрической идентификации

нечетких систем. Обзор основных существующих методов структурного синтеза для лингвистических нечетких моделей приведен в [2, 6]. Для построения *интерпретируемых* моделей процедуру структурного синтеза предлагается выполнять в два этапа. На первом этапе целесообразно использовать метод субтрактивной кластеризации [3], не относящийся к классу оптимизационных методов, поскольку для начальной инициализации структуры модели и ее параметров использование оптимизационных методов представляется излишним. Методом субтрактивной кластеризации находятся естественные группировки данных, на их основе определяются нечеткие разбиения базовых доменов и формируются нечеткие правила. Проекции найденных в результате кластеризации центров определяют положение нечетких подмножеств на интервалах определения. На втором этапе для удовлетворения требованиям интерпретируемости конструирование нечетких подмножеств необходимо осуществлять исходя из заданных значений покрытия доменов, уровней перекрытия и количества N_T подмножеств. При превышении фактического числа термов заданного количества, объединяются отдельные близкие нечеткие подмножества с образованием нового подмножества со средневзвешенными параметрами (1).

$$p_C = \frac{n_A p_A + n_B p_B}{n_A + n_B}, \quad (1)$$

где p_A , p_B и p_C – параметры объединяемых и результирующего множеств; n_A и n_B – количество множеств, в результате объединения которых получены \tilde{A} и \tilde{B} .

Оптимизация параметров. Параметрическое обучение заключается в нахождение оптимальных значений конкретного множества параметров модели. Алгоритмически параметрическое обучение означает подстройку внутренних параметров модели (параметров формы и положения функций принадлежности, параметров нечетких операций), направленную на улучшение качества модели в смысле принятого критерия. Задача обучения может рассматриваться как задача аппроксимации функциональной зависимости, частично определенной имеющейся выборкой данных. Способность к *обобщению* принципиально имеется у нечетких систем, благодаря свойству универсальной аппроксимации [5]. Под универсальными аппроксимирующими способностями нечетких систем понимается возможность приближения ими произвольной функциональной зависимости с любой заданной точностью. Согласно обобщенной аппроксимационной теореме [5], для любой функции g на компактном множестве U и любой $e > 0$, существует нечеткая система $f : U \rightarrow \mathfrak{R}$, такая что $\sup_{x \in U} |f(x) - g(x)| \leq e$. Указанное свойство нечетких систем обуславливает потенциальную возможность построения модели, аппроксимирующей поведение исследуемого объекта.

Независимая и связанная параметрическая оптимизация. Нечеткому правилу $R^{(j)}$ соответствует набор нечетких подмножеств $L^j = \{A_{ij}\}$, $i = 1 \dots n$ (n - число входных переменных; $j \in \{1, 2, \dots, N_R\}$; N_R - число правил), определенных на соответствующих универсальных множествах X_i . Параметрическая оптимизация может осуществляться либо в предположении (2) уникальности нечетких подмножеств, либо в предположении связанности наборов L^j .

$$L^j \cap L^i = \emptyset, i \neq j. \quad (2)$$

Соответственно, можно выделить два подхода к реализации параметрического обучения: первый ориентирован на систему правил (3), в которой каждое правило создается на основе своего набора нечетких множеств (вариант IMF-FLS):

$$R^{(j)}: \text{IF } x_1 \text{ is } A_{1j} \text{ AND } x_2 \text{ is } A_{2j} \text{ AND } \dots \text{ AND } x_n \text{ is } A_{nj} \text{ THEN } y \text{ is } B_j, \quad (3)$$

где A_{ij}, B_j - лингвистические значения соответствующих входных и выходных переменных в составе j -го правила.

Второй подход ориентирован на систему правил (4), в которой одним и тем же лингвистическим значениям, содержащимся в нескольких правилах, соответствует одно и тоже нечеткое множество (вариант FLS).

$$R^{(j)}: IF x_1 \text{ is } A_{1k(1,j)} \text{ AND } x_2 \text{ is } A_{2k(2,j)} \text{ AND } \dots \text{ AND } x_n \text{ is } A_{nk(n,j)} \text{ THEN } y \text{ is } B_{h(j)}, \quad (4)$$

где $k(i, j) : \{1, 2, \dots, n\} \times \{1, 2, \dots, R\} \rightarrow \{1, 2, \dots, n_i\}$; $h(j) : \{1, 2, \dots, R\} \rightarrow \{1, \dots, H\}$; n - число входных переменных; R - количество правил n_i - число подмножеств в разбиении домена X_i ; H - количество лингвистических значений выходной переменной.

Второй вариант задания системы правил является более общим: вариант IMF-FLS является частным случаем FLS при $k(i, j) = j$, $h(j) = j$, $n_i = R$, $H = R \forall i \in \{1, 2, \dots, n\} \forall j \in \{1, 2, \dots, R\}$.

Модель, построенную на базе правил в форме (4), будем называть *нелокальной нечеткой моделью* (рис. 1), в отличие от локальной нечеткой модели, построенной на основе правил в форме (3).

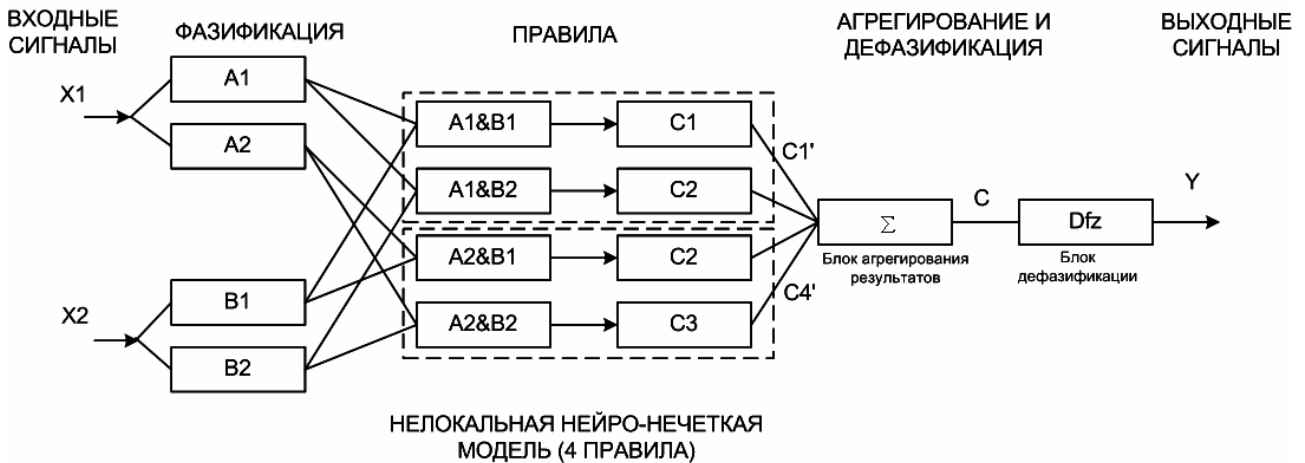


Рис. 1. Структура нелокальной нейро-нечеткой модели

Примечание:

- * значениями лингвистических переменных x_1, x_2 являются нечеткие подмножества A_1, A_2 и B_1, B_2 соответственно;
- * выходная переменная y принимает три различных лингвистических значения C_1, C_2, C_3 ;
- * $C_1' - C_4'$ - локальные результаты логического вывода;
- * C - результирующее нечеткое значение выходной переменной;

Таблица 2.

Задание системы правил в форме (4)

Правило	Индекс переменной i	Номер правила j	$k(i, j)$	$h(j)$	$A_{i, k(i, j)}$	Лингв. зн-е вх. перем.	Лингв. зн-е вых. перем. ($B_{h(j)}$)
$R^{(1)}$	1	1	1	1	$A_{1,1}$	A_1	C_1
	2	1	1		$A_{2,1}$	B_1	
$R^{(2)}$	1	2	1	2	$A_{1,1}$	A_1	C_2
	2	2	2		$A_{2,2}$	B_2	
$R^{(3)}$	1	3	2	2	$A_{1,2}$	A_2	C_2
	2	3	1		$A_{2,1}$	B_1	
$R^{(4)}$	1	4	2	3	$A_{1,2}$	A_2	C_3
	2	4	2		$A_{2,2}$	B_2	

Требования к алгоритмам параметрического обучения. Единственность представления лингвистических значений переменных системы (4) обеспечивается за счет правил связанной адаптации параметров [2,7]. Градиентные алгоритмы параметрической оптимизации [7], направленные на минимизацию текущей E_p или интегральной ошибки E ,

приводит к получению модели, обладающей следующими характеристиками: количество лингвистических термов для переменной совпадает с числом правил, а количество различных лингвистических значений выходной переменной также совпадает с количеством правил.

Для построения *интерпретируемых* систем правил требуется специальная организация алгоритмов обучения (адаптации) и учет в алгоритмах следующих требований:

- корректность параметров ФП (например, для треугольных ФП $mf_{\Delta}(x; a, b, c)$, где a, b, c - числовые параметры, должно выполняться неравенство $m < a < b < c < M$);
- сохранение взаимного расположения (исходного порядка) нечетких подмножеств внутри доменов (для треугольных ФП, например, параметры a, b, c должны удовлетворять неравенству $(a, b, c)_{left} < (a, b, c) < (a, b, c)_{right}$, где $(a, b, c)_{left}$ и $(a, b, c)_{right}$ - параметры левой и правой ФП, смежных с данной);
- сохранение требуемого уровня перекрытия между смежными нечеткими подмножествами.

Выполнение указанных требований обеспечивает целостность нечеткой модели.

Таким образом, в процессе параметрического обучения должна осуществляться условная оптимизация, т.е. проверка условий и корректировка приращений параметров.

Основные концепции построения интерпретируемых нечетких моделей на основе методов обучения:

1. Использование нелокальных нейро-нечетких моделей.
2. Двухэтапный синтез начальной (приближенной) структуры модели.
3. Связанная адаптация параметров [2].
4. Условная параметрическая оптимизация.

Основные выводы. Из рассмотрения нейросетевой модели нечеткого вывода видны потенциально большие возможности данного представления: может быть получена нечеткая система, основанная на правилах, путем настройки эквивалентной ей нейронной сети. Соответственно, возможно улучшение существующей базы правил или приобретение новых знаний в форме правил при интерпретации результата обучения. Рассмотрены основные концепции построения интерпретируемых нечетких моделей на основе методов обучения и предложена процедура автоматизированного формирования нечеткой модели методом обучения с учетом критериев интерпретируемости. Предлагаемая процедура, основанная на нелокальной нейро-нечеткой модели и двухэтапной процедуре синтеза с последующей связанной адаптацией с учетом требований интерпретируемости, даст возможность построения нечетких моделей разного уровня детализации в зависимости от поставленных целей точного моделирования или общего описания объекта в форме системы правил минимальной сложности.

Литература

1. *Castellano, G., Fanelli A.M., and Mencar C.* “Design of Transparent Mamdani Fuzzy Inference Systems,” 2003.
2. *Тимофеев В.В., Кукса П.П.* Построение и идентификация нечетких систем в приложениях управления и системного моделирования // Аэрокосмические технологии: Материалы первой международной научно-технической конференции / Под ред. Симоньянца Р.П.–М.: Изд-во МГТУ им. Н.Э. Баумана, НПО Машиностроения, 2004.–430 с.
3. *Paiva, R.P., and Dourado A.* “Interpretability and learning in neuro-fuzzy systems”, 2003
4. *Rutkowski, L.* “Flexible Neuro-fuzzy Systems: Structures, Learning and Performance Evaluation.” Kluwer Academic Publishers, 2004. –296 p.
5. *Tikk, D., L. T. Koczy, T. D. Gedeon* “A survey on the universal approximation and its limits in soft computing techniques,” 2003. – 22 p.
6. *Кукса П.П.* Структурная идентификация и оптимизация лингвистических нечетких моделей // Сборник трудов кафедры «Компьютерные системы и сети».–М.: МГТУ им. Н.Э. Баумана, 2003.
7. *Dadone, P.* “Design optimization of fuzzy logic systems.” Ph.D. diss., Virginia Polytechnic Institute and State University, Blacksburg, Virginia, 2001. –197 p.