

Кукса П.П.

Московский Государственный Технический Университет  
им. Н.Э. Баумана

E-mail: kouxa@online.ru

WWW: <http://www.geocities.com/pkouxa>

## АНАЛИЗ НЕЙРОСЕТЕВЫХ-НЕЧЕТКИХ МОДЕЛЕЙ

Необходимость в средствах, которые бы обеспечили возможность настройки и оптимизации нечеткой модели, возникла сразу же на стадии практического применения нечетких систем. Характеристики точности и качества нечеткой модели сильно зависят от формы и взаимного расположения функций принадлежности (ФП). Настройка параметров нечеткой модели в значительной степени автоматизируется при использовании нейросетевых нечетких систем (ННС), в которых нейронная (адаптивная) сеть выступает в качестве механизма настройки параметров нечеткой модели (множество настраиваемых параметров, например, для TSK-модели определяется параметрами ФП условной части правил и линейными коэффициентами в заключительной части:  $(c_j^{(k)}, \sigma_j^{(k)}, b_j^{(k)})$  и  $(p_{k0}, p_{kj})$  соответственно, где  $k = 1 \dots r, j = 1 \dots n$ ).

Нечеткая модель:

R1: ЕСЛИ  $X_1 = B_{11}$  И  $X_2 = B_{12}$  И ... И  $X_n = B_{1n}$ , ТО  $Y = D_1$

R2: ЕСЛИ  $X_1 = B_{21}$  И  $X_2 = B_{22}$  И ... И  $X_n = B_{2n}$ , ТО  $Y = D_2$

...

Rr: ЕСЛИ  $X_1 = B_{r1}$  И  $X_2 = B_{r2}$  И ... И  $X_n = B_{rn}$ , ТО  $Y = D_r$

Нечеткие множества (НМ-1)  $(B_{ij})_{\substack{1 \leq j \leq n \\ 1 \leq i \leq r}}$  и  $(D_i)$  являются параметрами нечеткой модели, а структура правил и их количество  $r$  определяют структуру модели.

В процессе нечеткого моделирования (рис.1) возможно использование нейронных сетей для проведения структурной и параметрической идентификация нечеткой модели. При этом применение нейронной или адаптивной сети может осуществляться в рамках двух основных подходов. Первый подход приводит к кооперативным ННС и основан на взаимодействии нейронной сети и нечеткой системы, присутствующих в модели в виде отдельных составляющих. Второй подход совершенствует нечеткую систему и приводит к гибридным ННС (ГННС): нечеткая система подменяется нейронной сетью особой структуры, что придает ей свойства адаптивности, обучаемости, большую гибкость и точность. При таком представлении параметры нечеткой системы распределяются между узлами и связями сети, что делает возможным применение алгоритмов обучения нейронных сетей для проведения идентификации модели. Второй подход изначально предполагает наличие прямого соответствия между элементами структуры нейронной сети и компонентами нечеткой модели, что распространяет свойство интерпретируемости, присущее нечетким системам, на нейросетевую нечеткую модель и дает возможность представить результат обучения в форме гибких логических конструкций – лингвистических правил.

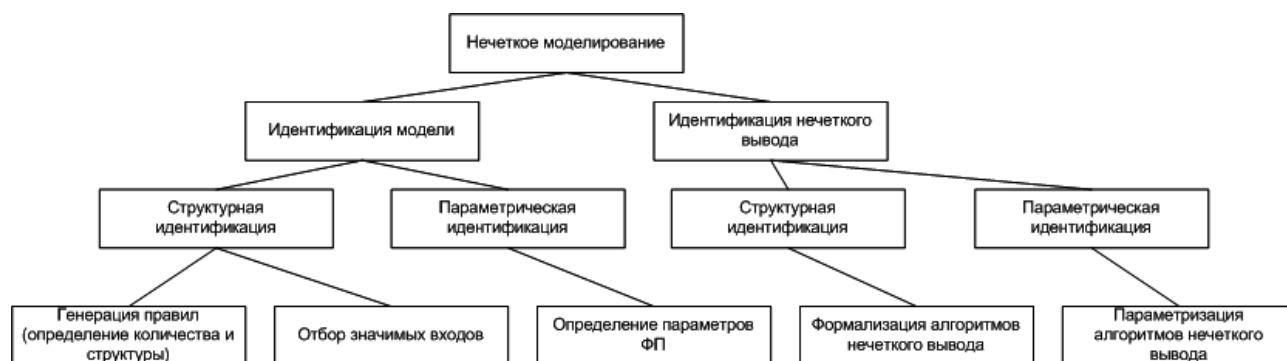


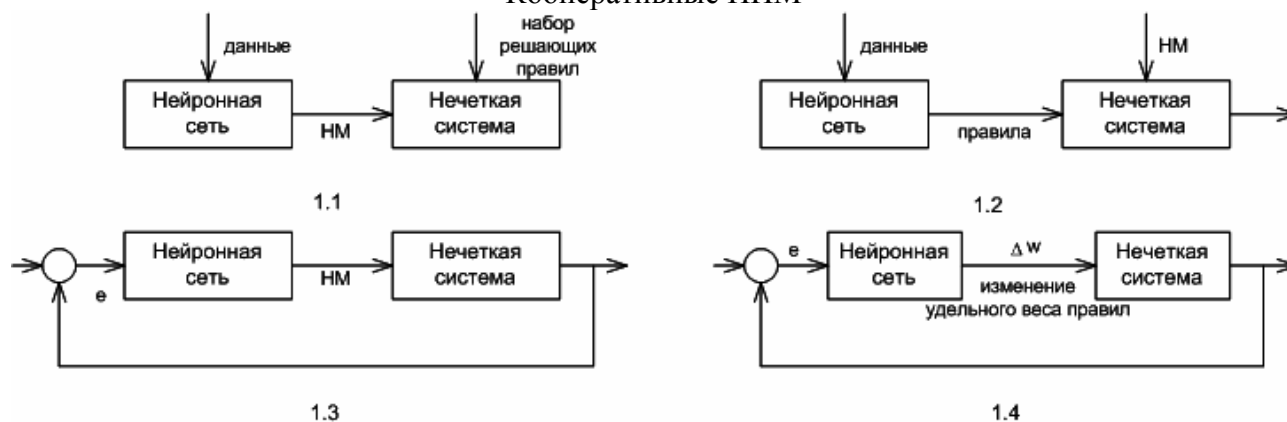
Рис. 1. Основные составляющие нечеткого моделирования

В настоящее время в литературе [1-6] предложено большое число различных по архитектуре, возможностям и используемым методам ННМ как гибридных, так и кооперативных (рис. 2). Анализ ННМ позволил выявить следующие ключевые свойства и отличительные особенности ННС:

- возможность индуцирования набора решающих правил
- ориентированность на определенный тип (семейство) нечетких систем
- применяемые алгоритмы обучения (алгоритмы оценивания параметров)
- возможность оперативного обучения
- возможность перестройки структуры (изменения, удаления некоторых связей, узлов)
- сохранение заложенных в систему знаний в процессе параметрической оптимизации или обучения новым правилам
- множество параметров нечеткой модели, которые могут быть настроены


Основные особенности некоторых ГНС приведены в табл. 1.

#### Кооперативные ННМ



#### Гибридные ННМ

##### 2.1 нейросетевая реализация нечеткого вывода



##### 2.2 нейроподобная нечеткая модель (представление нечеткой системы в виде нейронной сети)

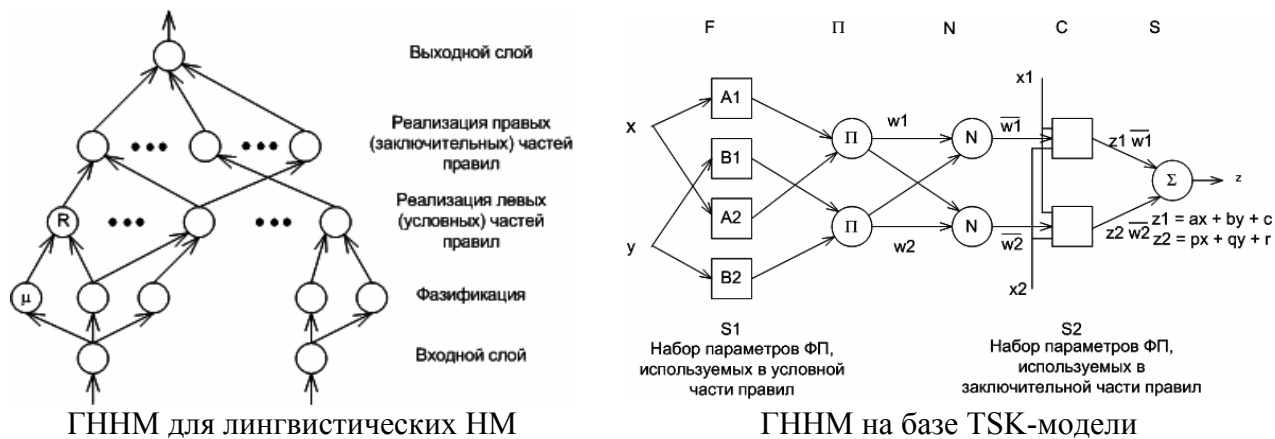


Рис. 2. Основные семейства ННМ

Рекомендации по выбору ННМ приведены в табл. 2 (с точки зрения полноты знаний о системе) и табл. 3 (в зависимости от области применения).

Таблица 1.

ANFIS	ориентированность на TSK-модели; все настраиваемые параметры сосредоточены в 1-м и последнем скрытом слое; структура набора правил должна быть известна заранее (тип и количество ФП для каждой переменной); обучение в два этапа: на первом – параметры S1 фиксированы, МНК используется для оценки S2, на втором – S2 фиксированы, S1 оценивается алгоритмом обратного распространения ошибки
NEFCON	Лингвистические нечеткие модели; возможность индуцирования набора правил и его оптимизации
NEFCLASS	возможность приобретения новых правил и оптимизации набора правил
FALCON	обучение в 2 этапа: 1. обучение без учителя (НМ, правила) 2. метод градиентного спуска (параметрическая оптимизация)
FUN	случайный алгоритм перестройки связей и изменения параметров ФП

Таблица 2.

решающие правила	НМ	1.1	1.2	1.3	1.4	ГНМ
+	+	+		+	+	+
+	-	+		+		+
-	+		+			NEFCON, NEFCLASS, FUN и др.
-	-					NEFCON, SY+NN
±						NEFCON

При наличии некоторых (частичных) знаний о системе в виде набора правил, основной трудностью при использовании НМ является сохранение этих знаний в итерационном процессе обучения.

Алгоритмы, позволяющие на основе данных наблюдений строить в конечном итоге нечеткую систему, на начальных этапах используют либо нечеткую кластеризацию, либо покрытие пространства многомерными гиперкубами, либо оптимизацию многомерных решетчатых структур, возникающих при разбиении координатных осей n-мерного пространства на нечеткие подмножества. Основными проблемами в этом случае являются обеспечение единственности представления одного и того же лингвистического значения и интерпретируемости индуцированного набора правил (в общем случае для каждой переменной существует столько НМ, сколько кластеров, а каждое правило содержит свой уникальный набор нечетких множеств), приведение получаемых дискретных ФП к одной из стандартных форм, а также избежание серьезных информационных потерь после проецирования получаемых в результате кластеризации областей (прямое произведение нечетких множеств не воспроизводит в точности породивший их кластер).

Таблица 3.

Интеллектуальная обработка и анализ данных	NEFPROX, NEFCLASS
Задачи классификации	NEFCLASS
Принятие решений	Нечеткие модели на основе идентификации отношения “вход-выход” по внешнему описанию ( $x_i, y_i$ )
Аппроксимация и интерполяция, реализация нелинейных зависимостей	ANFIS, NEFPROX, системы нечетких базисных функций (FBF)
Интеллектуальное управление	NEFCON, ARIC, GARIC, ANFIS, FUN, AMN (на основе ассоциативной памяти)
Моделирование	NNDFR, ANFIS
Прогнозирование (выявление тенденций в данных)	FAM, NEFPROX

Обобщая взгляды [7, 8, 9] на процесс решения задачи в рамках нейро-нечеткого подхода, можно предложить следующий маршрут разработки нечеткой системы (табл. 4).

Таблица 4.

	задача	средства проектирования	подзадачи
структурная идентификация	получение лингвистического описания исследуемой системы (формулирование набора решающих правил)	кластерный анализ; покрытие области данных многомерными гиперкубами; решетчатые многомерные модели; модификация набора правил экспертом	оптимальное разбиение исходного множества данных на нечеткие подмножества; проецирование; селекция значимых входов; формирование ФП; оптимизация параметров нечеткого вывода.
параметрическая идентификация	оптимизация нечеткой системы	алгоритмы и модели обучения	формулирование правил модификации параметров ФП, конструирование целевой функции задачи оптимизации, получение аналитических выражений для алгоритма нечеткого вывода, оптимизация набора правил в целом

Рассмотрим простейший пример полного решения задачи аппроксимации функциональной зависимости в рамках нейро-нечеткого подхода:

$y = f(x) = \frac{\sin(x)}{x}, x \in [-10, 10]$ . Исходные данные представлены в виде матрицы  $TD = [x \ y]$ ,

где  $x = (x_1 \dots x_s)^T$ ,  $y = (y_1 \dots y_s)^T$ ,  $y_i = f(x_i)$ . Структура набора правил:  $R_l : \text{ЕСЛИ } x = A_l \text{ ТО } y = c_{l1} + c_{l2} \cdot x$ , где  $l = 1..r$ . Для входа  $x$  определим 5 ФП ( $r = 5$ ) колоколообразной формы, равномерно покрывающих область определения  $[-10, 10]$  (рис. ), каждая из которых характеризуется тремя параметрами  $\{a, b, c\}$ , физический смысл которых поясняется на рис. 3.




Рис. 3




Рис. 4. Исходные ФП

a	b	c					
2.5	2	-10	2.855	1.9587	-9.707	0.07776	0.6279
2.5	2	-5	3.189	2.154	-4.654	-0.2529	-1.708
2.5	2	0	3.092	2.188	-0.02176	0.01843	1.921
2.5	2	5	3.204	2.17	4.613	0.2573	-1.745
2.5	2	10	2.857	1.959	9.67	-0.07762	0.6258

Матрица параметров исходных ФП

Матрица параметров итоговых ФП

Матрица параметров (Cij)

Рис. 5




Рис. 6. Итоговые ФП

Множество параметров модели включает 15 (5x3) нелинейных и 10 (5x2) линейных

параметров. Аналитическое выражение нечеткого вывода  $y = \sum_{i=1}^r \bar{w}_i (c_{i1} + c_{i2})$ ,  $\bar{w}_i = \frac{\bar{w}_i}{\sum_{k=1}^r \bar{w}_k}$ ,

$w_i = \mu_{A_i}(x)$ . Целевая функция задачи оптимизации:  $RMSE = \sqrt{\frac{1}{S} \sum_{i=1}^S (y(i) - \hat{y}(i))^2} \rightarrow \min$ , где  $\hat{y}(i)$  – выход модели.

Результаты моделирования приведены на рис. 4,5,6 и 7. Рассмотренную задачу можно решать и для лингвистических нечетких моделей (выход  $y$  можно рассматривать как

линейную комбинацию центральных значений  $y_i^*$  выходных ФП:  $y = \frac{\sum_{l=1}^r w_l y_l^*}{\sum_{l=1}^r w_l}$ ).

В приведенном примере структура модели (вид и количество правил) была определена вручную, параметрическая идентификация осуществлена с использованием ННМ, в общем же случае применение ННМ позволяет произвести и структурный синтез нечеткой модели.

#### Литература

1. Jang R. ANFIS: Adaptive - Network - Based Fuzzy Inference System, IEEE Trans. On Systems, Man, Cybernetics, 23(03):665-685, 1993.
2. Sulzberger SM, Tschicholg-Gurman NN, Vestli SJ, FUN: Optimization of Fuzzy Rule Based Systems Using Neural Networks, In Proceedings of IEEE Conference on Neural Networks, San Francisco, pp 312-316, March 1993.
3. Nauck D, Kruse R, *Neuro-Fuzzy Systems for Function Approximation*, 4th International Workshop Fuzzy-Neuro Systems, 1997.
4. Lin C T & Lee C S G, Neural Network based Fuzzy Logic Control and Decision System, IEEE Transactions on Comput. (40(12): pp. 1320-1336, 1991.
5. Bherenji H R and Khedkar P, Learning and Tuning Fuzzy Logic Controllers through Reinforcements, IEEE Transactions on Neural Networks, Vol (3), pp. 724-740, 1992.
6. Stanislaw Osowski., Tran Hoai Linh, Neuro-fuzzy TSK network for approximation
7. Detlef D. Nauck Data Analysis with Neuro-Fuzzy Methods, 2000
8. Salehfar H., N. Bengiamin, J. Huang, Linguistic fuzzy modeling based on input-output data, Proceedings of the Winter Simulation Conference, 2000
9. Jan Jantzen, Neurofuzzy Modeling, 1998.

1 : ЕСЛИ  $x = A_1$  ТО  $y = 0.0776 + 0.6279 \cdot x$

2 : ЕСЛИ  $x = A_2$  ТО  $y = -0.2529 - 1.708 \cdot x$

3 : ЕСЛИ  $x = A_3$  ТО  $y = 0.01843 + 1.921 \cdot x$

4 : ЕСЛИ  $x = A_4$  ТО  $y = 0.2573 - 1.745 \cdot x$

5 : ЕСЛИ  $x = A_5$  ТО  $y = -0.07762 - 0.6258 \cdot x$

Рис. 7. Итоговый набор правил