



ISSN 1815-4840

Himičeskaâ tehnologiâ. Kontrol' i upravlenie
**CHEMICAL TECHNOLOGY.
CONTROL AND MANAGEMENT**

2020, №1 (91) pp.73-83

International scientific and technical journal
journal homepage: <https://uzjournals.edu.uz/ijctcm/>



Since 2005

NEURO-FUZZY MODELING FOR PREDICTIVE CONTROL SYSTEMS WITH COMPLEX TECHNOLOGICAL PROCESSES AND PRODUCTION

Nodirbek Rustambekovich Yusupbekov¹, Shuxrat Manapovich Gulyamov²,
Malika Yuldashovna Doshchanova³

^{1,2}Tashkent State Technical University named after Islam Karimov
Address: 2, University str., 100095, Tashkent, Uzbekistan;

³Tashkent University of Information Technology named after Muhammad Al-Khorazmi
Address: 108, Amir Temur Avenue, 100200, Tashkent, Uzbekistan
E-mail: yulduzxon_85@mail.ru, Phone: +998-97-441-41-24.

Abstract: The paper implements a modification of a fuzzy neural network, which is suitable for predictive control purposes. Adaptation of a multidimensional programmable controller based on a neural algorithm for the back propagation of forecasting errors is proposed, as well as neural parametric identification of a fuzzy mathematical model of complex technological processes and production based on experimental data and expert estimates.

Keywords: model, neural networks, predictive control, neural identifier, neuro-fuzzy identification, input signal, fuzzy production rules, neuro-fuzzy model, catalytic cracking, reactor-regenerative unit.

Аннотация: Башоратли бошқариш мақсадлари учун мос келадиган норавшан нейрон тўри модификацияси амалга оширилган. Башоратлашнинг хатоларни тескари тарқатиш нейрон алгоритми асосида дастурланувчи кўп ўлчовли контроллерни адаптациясини амалга ошириш таклиф қилинмоқда, шунингдек тажриба маълумотлари ва эксперт баҳолари асосида мураккаб технологик жараёнлар ва ишлаб чиқаришнинг норавшан математик моделини нейрон параметрик идентификациялаш амалга оширилган.

Таянч сўзлар: модель, нейрон тармоқлар, башоратли бошқариш, нейронли идентификатор, нейронли норавшан идентификациялаш, кириш сигнали, норавшан маҳсулий қоидалар, нейрон-норавшан модель, каталитик крекинг, реактор-регенераторли блок.

Аннотация: Реализована модификация нечеткой нейронной сети, которая подходит для целей прогнозного управления. Предложено осуществлять адаптацию многомерного программируемого контроллера на основе нейронного алгоритма обратного распространения ошибки прогнозирования, а также осуществлять нейронную параметрическую идентификацию нечеткой математической модели сложных технологических процессов и производств на основе экспериментальных данных и экспертных оценок.

Ключевые слова: модель, нейронные сети, прогнозирующее управление, нейронный идентификатор, нейро-нечеткая идентификация, входной сигнал, нечеткие производственные правила, нейро-нечеткая модель, каталитический крекинг, реакторно-регенераторный блок.

Введение

Прогнозирующее управление – научное направление, которое развивается быстрыми темпами в последние годы. Были разработаны различные прогнозирующие алгоритмы, но самое широкое применение нашло предложенное Д.В.Кларком, С.Мохтади и П.С.Туффсом [1] обобщенное прогнозирующее управление. Прогнозирующие алгоритмы в целом относятся к классу адаптивных саморегулирующихся регуляторов и как таковые могут быть реализованы в явном и неявном виде [2].

Постановка задачи и ее решение

Обратимся к разработке алгоритмов для программируемых логических контроллеров, осуществляющих функции регуляторов в системах оперативно-прогнозного управления сложными технологическими процессами и производствами. Распределенная адаптивная

нейро-нечеткая архитектура [3] в таких системах поддержки принятия решений представляет собой шестислойную структуру с механизмом вывода Такаги-Сугено, структура которой представлена на рис. 1. Основная идея заключается в том, что входные сигналы «распределяются» по отдельным нейро-нечетким структурам. Таким образом, создается сеть нейро-нечетких структур, каждая из которых играет роль отдельной подмодели, а совокупная (глобальная) модель представляет собой набор из q подмоделей.

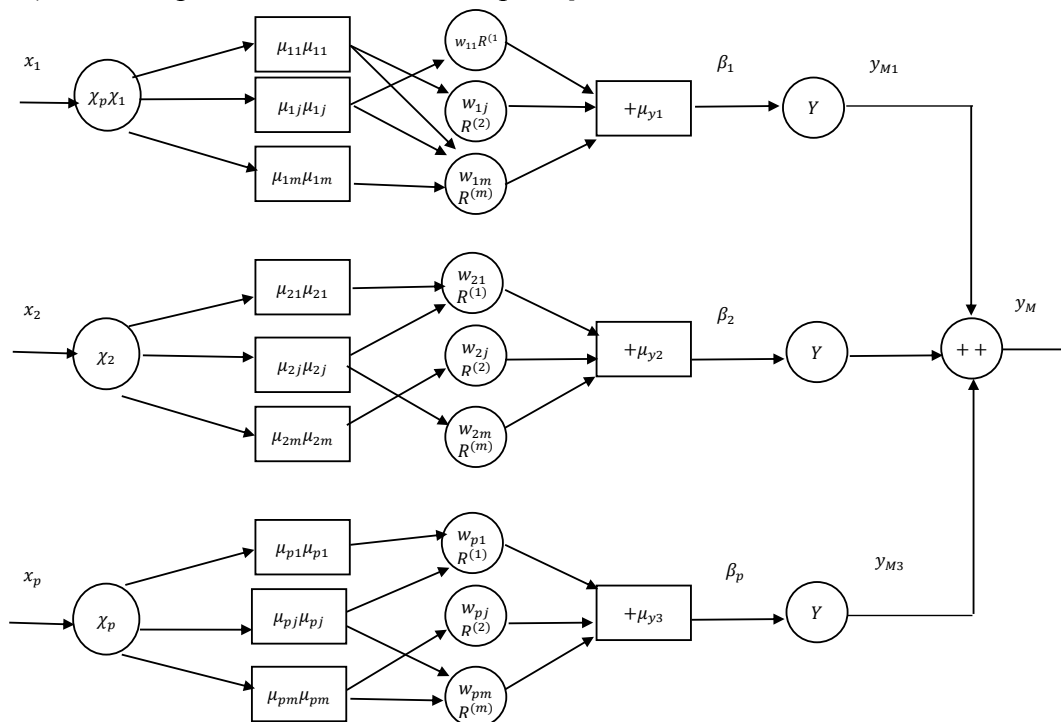


Рис. 1. Структура распределенной адаптивной нейро-нечеткой модели (ПАННМ).

Основным преимуществом обобщенной модели является то, что количество нечетких правил значительно сокращено. Последнее определяется выражением $N = m^p$, тогда как для рассматриваемой модели это делается по формуле:

$$N = m_1^{p_1} + m_2^{p_2} + \dots + m_q^{p_q} \tag{1}$$

Отдельные слои модели работают следующим образом:

1-слой: Нейроны первого слоя принимают входные сигналы и передают их на следующий слой.

2-слой: Выполняется операция размытия, которая требует определения типа и количества используемых вспомогательных функций. В конкретном случае используются гауссовские вспомогательные функции:

$$\mu_{x_p, m}^{(n)} = \exp \frac{-(x_p - x_{x_p, m})^2}{2\sigma_{x_p, m}^2} \tag{2}$$

где $\mu_{p1} \dots \mu_{pm}$ - степени принадлежности входной переменной x_p к m -нечеткому набору, а $\sigma_{x_p, m}$ - соответственно центр и ширина отдельных наборов.

3-слой: Этот слой является своего рода генератором правил, потому что именно здесь формируются нечеткие правила следующего типа:

$$\begin{aligned} R^{(N)} : & \text{if } x_i(k+j) \text{ is } \tilde{X}_1^{(N)} \text{ and } x_i(k+j) \text{ is } \tilde{X}_2^{(N)} \dots \\ & \text{if } x_p(k+j) \text{ is } \tilde{X}_1^{(N)} \text{ then } f_y^{(N)}(k+1) \end{aligned} \tag{3}$$

где $\tilde{X}_p^{(N)}$, $p = 1 \dots P$ - активированные нечеткие множества, $f_y^{(N)}$ - функция Такаги-Сугено.

4-слой: Реализуется следующее выражение:

$$f_y^{(N)}(k+j) = a_1^{(N)}y(k+j-1) + \dots + a_{n_y}^{(N)}y(k+j-n_y) + \dots + b_1^{(N)}u(k+j) + \dots + b_{n_u}^{(N)}u(k+j-n_u) + b_0^{(N)} \quad (4)$$

где $f_y^{(N)}$ - функция Такаги-Сугено, а свободный член b_0 играет роль фильтра помех.

Данный посыл можно доказать, если преобразовать формулу следующим образом:

$$f_y^{(N)}(k+j) = a_1^{(N)}y(k+j-1) + \dots + a_{n_y}^{(N)}y(k+j-n_y) + \dots + b_1^{(N)}u(k+j) + \dots + b_{n_u}^{(N)}u(k+j-n_u) + d(k+j). \quad (5)$$

Это преобразование вступает в силу при $T(q-1) = 1$.

5-слой: В выражении (5) $d(k)$ существует неизвестное возмущение, которое определяется по формуле:

$$d(k) = \frac{T(q^{-1})}{\Delta(q^{-1})}v(k). \quad (6)$$

Это выражение является частью модели, которая обычно используется в универсальных прогнозирующих регуляторах:

$$A(q^{-1})\hat{y}(k) = B^{(i)}(q^{-1})u(k) + \frac{T(q^{-1})}{\Delta(q^{-1})}v(k), \quad (7)$$

где $v(k)$ - неизвестная переменная с нулевым математическим ожиданием, которое описывает как влияние помех, так и измеряемый шум.

Выходы отдельных подмоделей $\hat{y}_{M1}, \hat{y}_{M2}, \dots, \hat{y}_{Mq}$ формируются в соответствии с выражениями (6)-(7). Q указывает количество используемых подмоделей:

$$\hat{y}_M(k+j) = \frac{\sum_{i=1}^q f_y^{(i)}(k+j)\mu_y^{(i)}(k+j)}{\sum_{i=1}^q \mu_y^{(i)}(k+j)}. \quad (8)$$

6-слой: Выход совокупной модели получается как сумма выходов отдельных подмоделей $\hat{y}_{M1}, \hat{y}_{M2}, \dots, \hat{y}_{Mq}$.

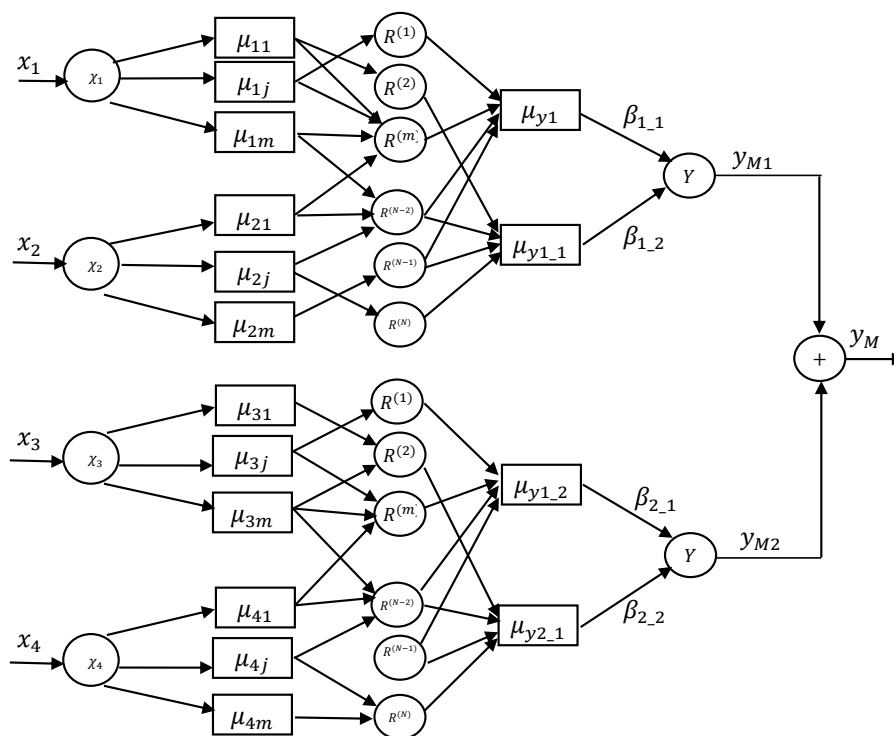


Рис. 2. Структура распределенной адаптивной нейро-нечеткой модели с двумя подмоделями.

Таким образом, если у нас есть 4 входа (два предыдущих выходных значения, предыдущее и текущее управляющее значение), 3 нечетких набора, количество правил не больше 81. Это, в свою очередь, значительно сократит количество параметров, которые должны определяться при каждом шаге обучения. Поскольку общее количество параметров определяется выражением $N * (3P + 1)$, в этом случае их будет только 156, а не 1053.

Для целей настоящего исследования распределение входных сигналов основано на типе входных сигналов. В этом случае распределенная адаптивная нейро-нечеткая модель в рисунке 1 преобразуется в форму, показанную на рисунке 2. В этом случае модель будет состоять из двух подмоделей, каждая из которых реализуется с помощью нейро-нечеткой структуры приведенной на рис. 3.

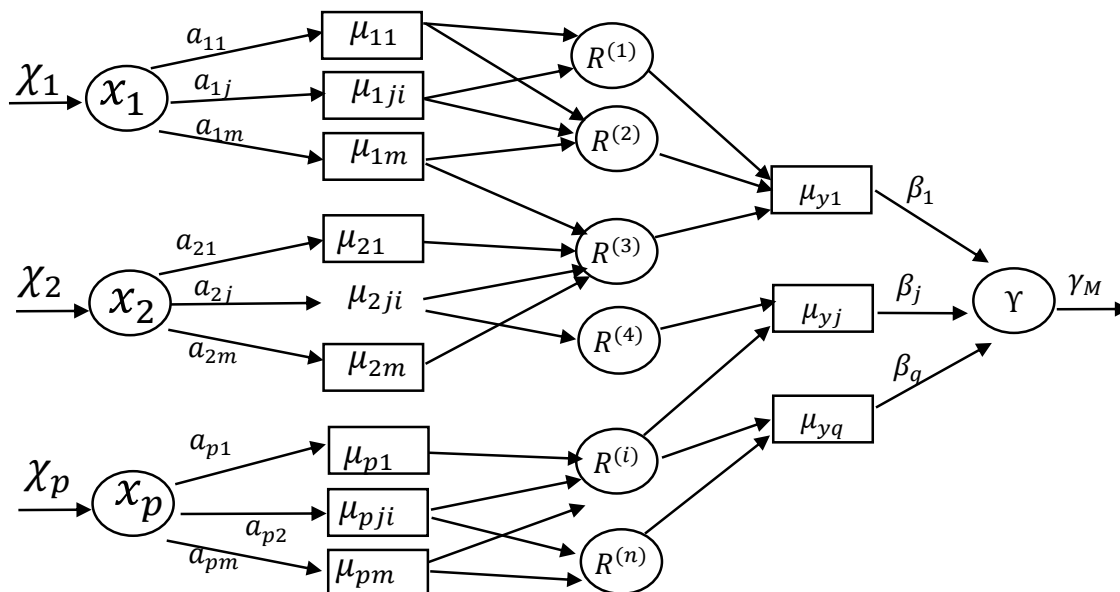


Рис. 3. Нейро-нечеткая структура модели объекта исследования.

Для одной подмодели входными значениями являются значения вектора y (т.е. предыдущие значения выходных данных объекта $x_1 = y(k - 1)$ и $x_2 = y(k - 2)$), а для других - значений вектора управления u , т.е. $x_3 = u(k)$ и $x_4 = u(k - 1)$. В этой настройке количество нечетких правил равно 18, а изученных параметров - 234. Общая блок-схема модели представлена на рис. 4. В нем FNN1 и FNN2 обозначают две нейро-нечеткие структуры модели, показанной на рис. 3, в которой обрабатываются значения вектора управления u и значения вектора y .




Рис. 4. Блок-схема распределенной адаптивной нейро-нечеткой модели с двумя подмоделями.

Нейро-нечеткая модель с частичным размытием входных сигналов представляет собой пятислойную структуру с механизмом логического вывода Такаги-Сугено. В этом случае [4]

некоторые из входных сигналов не размыты, а введены с их действительными значениями, взвешенными по соответствующему весовому коэффициенту, в третьем слое (слой нечетких правил), т.е. непосредственно представление с помощью механизма логического вывода функций Такаги-Сугено.

Таким образом, с одной стороны, уменьшается количество нечетких правил, а с другой стороны, уменьшается число обратных параметров, которые должны быть определены в процессе обучения. Например, если модель имеет 4 входа (2 нечетких и 2 четких, соответственно, выход объекта и элемент управления), то общее число правил, которые должны быть сгенерированы, равно 9.

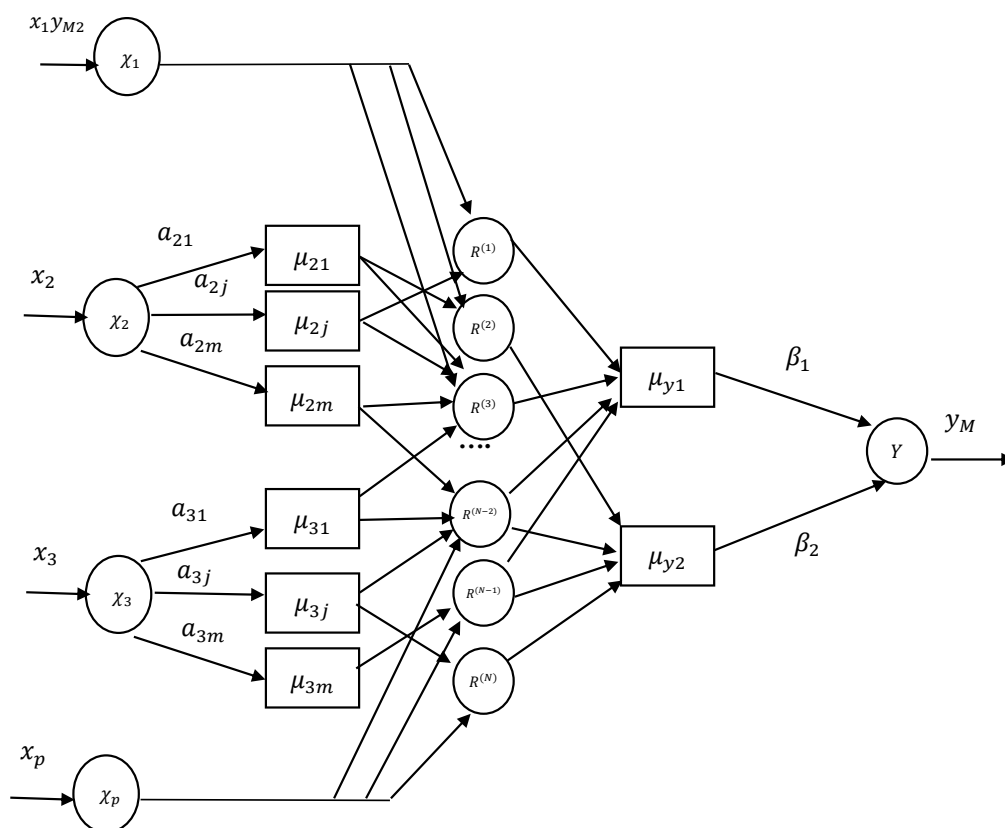


Рис. 5. Структура нейро-нечеткой модели с частичным размытием входных сигналов.

Общее количество параметров, которые должны быть определены в модели обучения равно 64.

Кроме того, модель приближается по структуре к линейной модели, поэтому ее можно назвать полу- или квазилинейной. Это также гарантирует снижение вычислительной нагрузки во время процедуры оптимизации при принятии управленческих решений в реальном времени.

Основная трудность в использовании модели состоит в том, как определить, какой из входных сигналов должен быть размытым, а какой включить непосредственно в последующую часть нечетких правил.

Для математического описания исследуемого технологического процесса как сложного динамического объекта с изменяющимися характеристиками, функционирующего в нечеткой и неопределенной среде, можно было бы использовать лингвистические «ЕСЛИ...ТО» продукционные правила. Однако добывать у оператора такие знания часто оказывается нелегкой задачей. Кроме того, общеизвестны трудности [7,8] обучения таких нечетких моделей, основанных на знаниях вышеупомянутой конструкции. В подобных ситуациях нейро-нечеткий подход к моделированию дает эффективные результаты [9-15].

Структура блока нейро-нечеткой идентификации динамических характеристик процесса каталитического крекинга представлена на рис. 6.

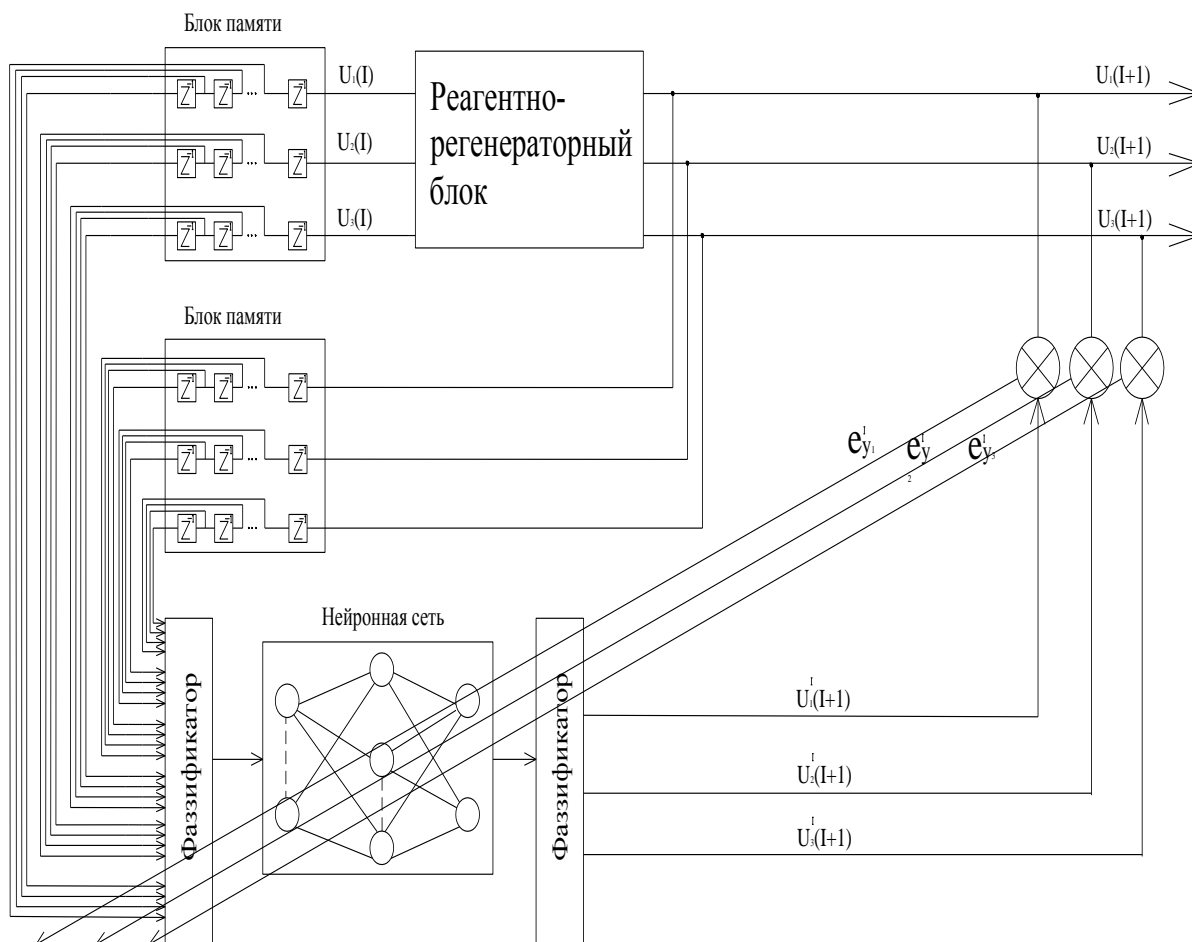


Рис.

6. Структура нейро-нечеткого идентификатора.

Четкие текущие значения $V_i, i = \overline{1,3}$ и управляемых $y_j(l+1), j = \overline{1,3}$ параметров объекта (реакторно-регенераторного блока) через блоки памяти, которые определяют порядок моделей, поступают в фаззификатор (z^{-1} означает блок задержки). На вход нейронной сети поступают нечеткие текущие и задержанные значения входов и управлений (выходов) объекта. Нейронная сеть представляет собой трехслойную структуру, генерирующую значения функций принадлежности выходных параметров объекта.

После выполнения операции дефаззификации четкие значения выходов нейронного идентификатора $y_j^u(l+1) = y_j(l+1) - y_j^u(l+1), j = \overline{1,3}$ сравниваются с текущими значениями выходов реакторно-регенераторного блока $y_j(l+1), j = \overline{1,3}$ и определяются ошибки идентификации

$$e_{y_j}^u(l+1) = y_j(l+1) - y_j^u(l+1), j = \overline{1,3}. \tag{9}$$

Используя функцию ошибки нейронной сети в виде:

$$E(l+1) = \frac{1}{2} [y_j(l+1) - y_j^u(l+1)]^2, j = \overline{1,3} \tag{10}$$

и алгоритм обратного распространения ошибки [7,16] можно сконструировать искомые нечеткие модели объекта.

На рис. 7 – рис. 17 представлены результаты компьютерной симуляции процесса идентификации модели реакторно-регенераторного блока. При этом многомерный

управляемый объект (технологический процесс каталитического крекинга) описывается следующей преобразованной в разностную форму системой дифференциальных уравнений:

$$\begin{aligned}
 y_1(n) &= c_{11}y_1(n-1) - c_{21}y_1(n-2) + c_{31}y_1(n-3) - c_{41}y_1(n-4) + d_{011}U_1(n-z_{11}) - \\
 &- d_{111}U_1(n-1-z_{11}) + d_{211}U_1(n-2-z_{11}) + d_{012}U_2(n-z_{12}) - d_{112}U_2(n-1-z_{12}) + \\
 &+ d_{212}U_2(n-2-z_{12}) - d_{312}U_2(n-3-z_{12}) + d_{013}U_3(n-z_{13}) - d_{113}U_3(n-1-z_{13}) + \\
 &+ d_{213}U_3(n-2-z_{13}) - d_{313}U_3(n-3-z_{13}); \\
 y_2(n) &= c_2y_2(n-1) + d_{02}U_2(n-z_{22}) / U_3(n); \\
 y_3 &= c_3y_3(n-1) + d_{03}U_3(n-z_{33}); \\
 c_{11} &= 3,363; c_{21} = 4,162; c_{31} = 2,230; c_{41} = 0,432; d_{011} = 0,06; d_{111} = 0,011; \\
 d_{211} &= 0,005; d_{012} = 0,006; d_{112} = 0,017; d_{212} = 0,016; d_{312} = 0,005; d_{013} = 0,014; \\
 d_{113} &= 0,043; d_{213} = 0,041; d_{313} = 0,0013; d_{02} = 0,500; d_{03} = 0,333; c_2 = 0,5; \\
 c_3 &= 0,667; t_0 = 0,25 \text{ мин.}; z_{11} = 2 \text{ мин.}; z_{12} = 2 \text{ мин.}; z_{13} = 2 \text{ мин.}; \\
 z_{22} &= 1 \text{ мин.}; z_{33} = 1 \text{ мин.}
 \end{aligned} \tag{11}$$

Рассмотрим нейронную идентификацию технологического процесса каталитического крекинга. Идентифицируемый объект (реакторно-регенераторный блок) является объектом с существенно изменяющейся динамикой. Для учета этого эксперименты по совокупностям нейронной идентификации были проведены с существенно различными коэффициентами тестовых моделей процесса каталитического крекинга.

Обратимся к нейронной идентификации модели для температуры реактора. Предполагается, что идентифицируемая модель характеризуется четырьмя существенно изменяющимися параметрами: $a_i, i = \overline{1,3}$ (характеризуют временную динамику модели) и f_t (коэффициент усиления). Во время экспериментов в компьютерной симуляции указанные коэффициенты подвергались двух- и трехкратному изменению, что вполне охватывает действительную изменчивость параметров реального процесса в промышленных условиях.

Рассмотрены следующие четыре случая совокупности параметров идентифицируемого процесса: а) $a_0 = 6,3; a_1 = 11,2; a_2 = 1; f_t = 5,1$; б) $a_0 = 12,6; a_1 = 11,2; a_2 = 1; f_t = 8,1$; в) $a_0 = 6,3; a_1 = 12; a_2 = 3; f_t = 5,1$; д) $a_0 = 8; a_1 = 6,5; a_2 = 1; f_t = 10$.

На рисунках изображена реальная температура на выходе реактора и ее значения на выходе идентификатора, когда U (вход объекта) является синусоидальным сигналом. Как видим, для значительных изменений параметров объекта (в 2-3 раза) нейронный идентификатор быстро обучается и при этом обеспечивается приемлемое совпадение реального выхода объекта и выхода идентификатора.

На рис. 7 представлены результаты нейронной идентификации реактора каталитического крекинга нефти по температурному каналу при случаях а), б), в) и д). Ниже графиков представлены оптимальные веса нейронного идентификатора.




Рис. 7. Результаты нейронной идентификации объекта управления.

На рис. 8 представлены результаты симуляции процесса идентификации, когда для случая а) один весовой коэффициент $w_{8,9}$ в нейронной сети изменился (было $w_{8,9} = 0,5281$, стало $w_{8,9} = 0,0281$). Видно ухудшение процесса идентификации при незначительном отклонении от оптимальной весовой матрицы нейронной сети. Для случаев б), с) и д) весовые матрицы остались прежними. Следовательно, результаты идентификации для этих случаев не изменились.




Рис. 8. Результаты нейронной идентификации объекта при единичном входном сигнале.

Для проверки оптимальной весовой матрицы нейронной сети, реализующей нейронный идентификатор, для двух случаев а) и б) изменены весовые коэффициенты сети (рис. 9). Для случая а) $w_{8,9}$ стало $w_{8,9} = 0,0281$ (оптимальное его значение было $w_{8,9} = 0,5281$). Для случая б) $w_{8,9}$ стало равно $w_{8,9} = 0,9767$ (оптимальное его значение было $w_{8,9} = 0,5767$).




Рис. 9. Результаты нейронной идентификации объекта при единичном входном воздействии на объект.

Как видно из рис. 10, даже при изменении только одного (из двадцати) весового коэффициента нейронного идентификатора от его оптимального значения появляется существенное отклонение выхода идентификатора от реального сигнала выхода объекта. Для сравнения на рис. 7 для случаев с) и д) оптимальные весовые матрицы нейронного идентификатора остались неизменными и нейронный идентификатор в обоих случаях обеспечивал приемлемую точность идентификации объекта.




Рис. 10. Результаты нейронной идентификации объекта при единичном входном воздействии на объект управления.

На рис. 11 представлены итоги выполнения симуляции процесса идентификации реактора, когда в случае а) $w_{8,9}$ стало $w_{8,9} = 0,0281$ ($w_{opt} = 0,5767$); в случае б) $w_{8,9} = 0,9767$ (w_{opt}

=0.5767); в случае с) $W_{8,9}=0.9307$ ($W_{opt}=0.5307$); и в случае d) весовая матрица осталась неизменной.




Рис. 11. Результаты нейронной идентификации объекта при единичном входном воздействии на объект.

Рис. 12 иллюстрирует картину идентификации модели реактора, когда во всех случаях a), b), c) и d) изменены по одному весовому коэффициенту нейронного идентификатора. Как видим имеет место ухудшение идентифицируемости во всех случаях.




Рис. 12. Результаты нейронной идентификации модели объекта при единичном воздействии.

На рис. 13 показана нейронная идентификация, когда входом объекта (соответственно и идентификатора) является единичный сигнал. Сплошная линия соответствует выходу объекта, а прерывистая – выходу нейронного идентификатора. Здесь же представлены оптимальные весовые матрицы нейронного идентификатора для всех четырех случаев. Как видим, результаты идентификации вполне удовлетворительные. Нейронная идентификация, когда входами объекта является единичный сигнал, показала вполне удовлетворительные результаты.

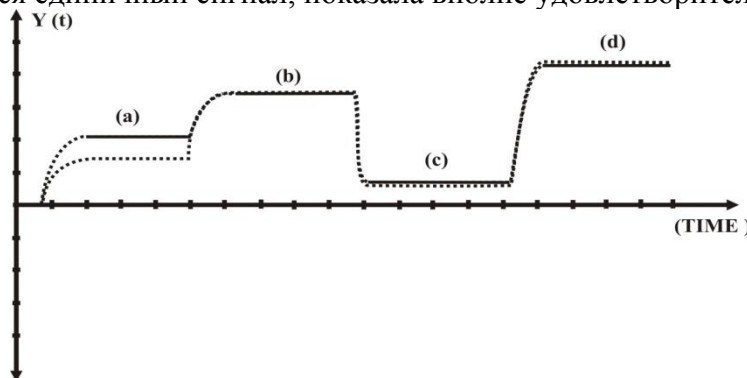


Рис. 13. Нейронная идентификация объекта при единичном входном сигнале.

На рис. 14 приведены результаты идентификации реактора, когда для случая a) вносилось случайное изменение в весовую матрицу нейронного идентификатора ($W_{8,9}$ стало $W_{8,9}=0,00044$; W_{opt} было $W_{opt}=0,6004$). Для случаев b), c) и d) весовые матрицы не корректировались. При первом случае видно ухудшение результатов идентификации.




Рис. 14. Нейронная идентификация объекта при единичном входном сигнале.

На рис. 15 показана симуляция процессов нейронной идентификации реактора, при внесении случайных изменений в весовые матрицы идентификатора (случаи а) и б)). Для случаев с) и д) весовые матрицы остались неизменными.




Рис. 15. Нейронная идентификация объекта при единичном входном сигнале.

На рис. 16 представлены результаты идентификации реактора, когда введены случайные коррективы в весовые матрицы нейронного идентификатора для случаев а), б) и с), а оптимальная весовая матрица для случая д) осталась неизменной. Как видим, процессы идентификации в первых трех случаях существенно ухудшились, а в последнем случае остались оптимальными.




Рис. 16. Нейронная идентификация объекта при единичном входном сигнале.

На рис. 17 такие коррективы вносились во все весовые матрицы, в случае а) $W_{8,9}$ стало $W_{8,9}=0,00044$; б) $W_{8,9}=0,77794$; с) $W_{8,9}=0,02216$; д) $W_{8,9}=0,04662$. Имеет место ухудшение процессов идентификации во всех четырех случаях при отклонении от обученных нейронных идентификаторов с оптимальными весовыми матрицами.




Рис. 17. Нейронная идентификация объекта при единичном входном сигнале.

Заключение

В работе реализована модификация нечеткой нейронной сети, которая подходит для целей прогнозного управления.

Предложено осуществлять адаптацию многомерного программируемого контроллера на основе нейронного алгоритма обратного распространения ошибки прогнозирования.

Осуществлена нейронная параметрическая идентификация нечеткой математической модели сложных технологических процессов и производств на основе экспериментальных данных и экспертных оценок.

References:

1. Clarke D.W., C. Mohtadi and P.S. Tuffs . Generalized Predictive Control. Automatica, Vol. 23, Issue 2, 1987. pp. 137-148.
2. Velev K. Adaptivni sistemi. Sofiya. 1994.
3. Terziyska, M., A Distributed Adaptive Neuro-Fuzzy Network for Chaotic Time Series Prediction, Cybernetics and Information Technologies. Vol. 15, Issue 1, Pages 24–33, ISSN (Online) 1314-4081, DOI: 10.1515/cait-2015-0003, March 2015.
4. L. Doukovska, M. Petrov. Implicit GPC based on Semi Fuzzy Neural Network Model, IEEE Intelligent Systems IS'14, Warsaw, Poland, September 24-26, 2014.
5. Yamakawa, T., E. Uchino, T. Miki, and H. Kusanagi (1992). A neo fuzzy neuron and its applications to system identification and prediction of the system behavior. In Proc. 2-nd Int. Conf. on Fuzzy Logic and Neural Networks - IIZUKA-92, Japan, pages 477–483.
6. Terziyska, M., Y. Todorov, L. Doukovska, Neo-fuzzy Network for Modeling of Nonlinear MIMO Dynamics, International Conference TechSys'2015, Plovdiv Bulgaria, Published in Journal of Technical University-Sofia, branch Plovdiv, Bulgaria, "Fundamental Sciences and Applications" Vol. 21, book 1, pp. 65-70, ISSN 1310-8271, 2015.
7. Aliev R.A., Bonfig K.W., Aliev F.A. Messen. Steuern, Regeln Mit Fuzzy – logik. Munchen: Francis, 1994. - p.
8. Aliev R.A., Aliev F.A., Babaev M. Fuzzy process control and knowledge engineering in petrochemical and robotic manufacturing. Koln: Verlag TVY Rheinland, 1991. - p.
9. Lee M., Lee S., Park C. Neuzo-fuzzy identifiers and controllers. Journal of intelligent and fussy system.Vol.2, 1994. - pp.1-4.
10. Fuzzy sets, neural networks and Soft Computing, Yagez R.R., Zadh L.A. (Eds.), VAN Nostrand Reinhold, New York, 1994. - p.
11. Berenju H.R., Leazning and tuning fuzzy logic controllers through reinforaments. IEEE Trans on Neural Networks, 3(5), 1992. – pp.724-729.
12. Lee M., Lee S.Y., Park C.H., Neuro-fuzzy Identification model of nonlinear Dynamic Systems. Proceeding of the 2nd International Conference on Fuzzy Logic and Neural Networks, vol.1, 1992. – pp.485-488.
13. Lee C.C. Intelligent Control base on fuzzy logic and neural net theory. Proceeding of International Conference on Fuzzy Logic and Neural Networks, vol.2, 1990. – pp.759-764.
14. Lee M., Lee S.Y., Park S.H. Neuro-fuzzy identifiers and controllers for fuzzy systems. Proceedings of International Conference Fuzzy Systems Association, vol.1, 1993. – pp.77-80.
15. Mukaidono M., Yamato M.A. Learning method of fuzzy inference rules with neural networks and its application. Proceedings of the International Conference on Fuzzy Logic and Neural Networks, 1992. – pp.185-187.
16. Rumelhart D., Hinten G. E., Williams R.J. Learning internal Representation by Error Back Propagation. In Parallel Distributed Proceedings, vol.1, Exploration In the Micro Structures of Cognition, Rumelhart D.E., McClelland (Eds), MIT Press, Cambridge, MA, 1986. – pp.318-362.