

## НЕЙРОСЕТЕВОЙ КОНТРОЛЛЕР С ПРЕДСКАЗАНИЕМ В СИСТЕМЕ УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ

Басистов Ю.А., Яновский Ю.Г.

*ФГБУН Институт прикладной механики РАН, г. Москва, Россия*

### РЕЗЮМЕ

В работе рассматривается задача применения нейронных сетей в системе управления технологическими процессами в производстве вязкоупругих сред. Приводятся классические методы управления, их недостатки и рассматриваются нейросетевые методы управления. В качестве примера решается задача управления концентрацией продукта на выходе каталитического реактора с помощью двухслойной нейронной сети прямого распространения. Критерием качества оптимального управления выбран алгоритм с предсказанием, когда нейронная сеть предсказывает реакцию объекта управления на определённом интервале времени в будущем. Приведены графики ошибок обучения и тестирования нейросетевой модели каталитического реактора. Приведены графики сравнения целевого и выходного сигналов в системе управления. Сделан вывод о том, что система управления на основе нейронной сети с алгоритмом предсказания можно использовать для управления концентрацией продукта на выходе каталитического реактора.

**Ключевые слова:** каталитический реактор; динамическая нейронная сеть прямого распространения; принцип удаляющегося горизонта; управление с предсказанием; идентификация модели; алгоритм Левенберга-Марквардта

## NEURAL NETWORK CONTROLLER WITH PREDICTIVE FOR PRODUCTION VISCOELASTIC MEDIUMS

Basistov Yu.A., Yanovsky Yu.G.

*Institute of Applied Mechanics of Russian Academy of Science, Moscow, Russia*

### SUMMARY

The problem of the use of neural networks in the control system for the production of viscoelastic media is considered. Classical methods of process control are considered. A new approach to the process control of using neural networks is offered. As an example, the problem of control product concentration at the outlet of the catalytic reactor into a two-layer feedforward neural network is solved. Quality criterion of optimal control algorithm with the prediction when the neural network predicts the reaction of the control object at a certain time interval in the future is selected. Graphic errors of training and testing the neural network as model of a catalytic reactor is given. It is concluded that the control system based on a neural network with the prediction algorithm can be used to control the concentration of the product at the outlet of the catalytic reactor.

**Key words:** continuous stirred tank reactor; straightforward dynamic network; receding horizon technique; predictive control; plant identification; Levenberg-Marquardt algorithm

## ВВЕДЕНИЕ

В настоящее время теория автоматического управления развита достаточно хорошо. Большинство исследований в этой теории носят сугубо научный характер и вызывают затруднения при использовании их в повседневной практике. Исключением из этого правила является работа [1], в которой доступно излагаются идеи и методы экстремального управления. Несмотря на то, что работа [1] выполнена достаточно давно, она актуальна и в современных условиях. Внедрение нейронных сетей в системы автоматического управления [2], показывает, насколько упрощаются методы и алгоритмы их реализации при синтезе системы управления по сравнению с классическими методами, приведёнными в [1].

Формально процесс управления объектом можно описать следующим образом. Пусть объект управления описывается некоторым оператором, зависящим от параметров

$$Y = F(X, U, A) \quad (1)$$

где  $X, Y$  – соответственно вход и выход объекта,  $U$  – сигнал управления и  $A$  – матрица (вектор) параметров. Цель управления объектом состоит в определении такого управления  $U^*$ , которое переведёт объект в желаемое состояние  $Y^*$ . Для достижения этой цели необходимо построить модель объекта – оператор  $F'$ , который аппроксимирует неизвестный оператор объекта (1), и провести операцию идентификации модели путём оценки параметров  $A$ . Единственным источником информации о значении  $A$  является эксперимент с объектом. Если вход объекта  $X$  изменяется интенсивно, то необходимую информацию можно получить, пассивно наблюдая поведение объекта

$$Y'_i = F'(X_i, U', A), \quad i = 1, \dots, N \quad (2)$$

Операцию идентификации можно свести к решению вариационной задачи для параметров  $A$  при отсутствии вариации управления, т.е.  $U' = const$ .

$$A^* = \min_{A \in \Omega} \sum \Phi(Y_i, Y'_i) \quad (3)$$

где  $\{Y_i, Y'_i\}$  – желаемый и фактический выходы модели соответственно при подаче на её вход сигналов  $\{X_i\}$ . Пару  $\{X_i, Y_i\}$  называют обучающей выборкой для идентификации модели.

После того, как оператор модели  $F'$  определён и идентифицирован путём оптимизации параметров  $A$ , приступаем ко второму этапу алгоритма управления объектом – поиску оптимального сигнала управления путём решения вариационной задачи

$$U^* = \min_{U \in \Omega} f(F'(X, U, A^*) - Y^*) \quad (4)$$

где  $Y^*$  – вектор цели управления.

При построении оператора  $F'$ , как правило, используют интегро-дифференциальные уравнения, зависящие от параметров. При решении задачи (2), (3) встречаются затруднения, связанные с нелинейностью управляемого процесса и неустойчивостью модели этого процесса к малым изменениям в исходных данных (некорректность решения задачи идентификации). В последнее время актуально адаптивное управление, например, управление с самонастройкой. Недостатком такого управления является узкая область его применения, т.к. при изменениях в структуре управляемого процесса модель требуется

перестраивать, заново производить идентификацию и вычислять сигнал управления. Такие модели не обладают свойством обобщать изменения в технологическом процессе. Кроме того, далеко не для всякого технологического процесса можно построить математическую модель, адекватную технологическому процессу и, тем более, осуществить её идентификацию и определить сигнал управления.

Альтернативой классическим методам управления является использование нейронных сетей. Преимущество нейросетевого управления перед традиционным управлением является следующее:

1. Нейронные сети могут обучаться любым отображениям «вход-выход». Важно только правильно выбрать конструкцию нейронной сети, качество и объём обучающей выборки.
2. Нейронные сети позволяют избежать использования сложного математического аппарата для построения модели технологического процесса. Более того, для сложных нелинейных процессов адекватную математическую модель не всегда удаётся построить.
3. Использование нелинейных функций активации в нейронных сетях позволяет реализовать адекватные нелинейные модели без применения процедуры их линеаризации или разложения в ортогональные ряды базисных функций.
4. В нейронных сетях можно использовать алгоритмы самообучения, что существенно расширяет гибкость нейронных сетей к вариациям параметров в технологическом процессе.
5. Высокая степень параллельности вычислительных процессов в нейронной сети обеспечивает высокую производительность и помехозащищённость нейронных сетей, т.к. при повреждении одних ветвей нейросети их функции передаются оставшимся работоспособным ветвям.

Отсюда следует, что нейросетевые модели имеют большие перспективы для управления сложными технологическими процессами.

## 1. МОДЕЛЬ ОБЪЕКТА УПРАВЛЕНИЯ

В качестве модели объекта управления примем процесс управления каталитическим реактором, изображённым на рис.1 [3].




Рис.1. Каталитический реактор.

На рис.1 изображён каталитический реактор с параметрами  $w_1$  – скорость потока продукта с концентрацией  $C_{b1}$ . Положим  $C_{b1}=29.4$ ,  $w_2=0.1$  – скорость потока продукта с концентрацией  $C_{b2}=0.1$ ,  $h$  - уровень продукта в резервуаре (не контролируется). Цель регулирования состоит в поддержании заданной концентрации  $C_b$  конечного продукта путём автоматического регулирования скорости  $w_1$ .

Динамическая модель каталитического реактора рис.1 описывается системой дифференциальных уравнений [3]

$$\begin{aligned} \frac{dh(t)}{dt} &= w_1(t) + w_2(t) - 0.2\sqrt{h(t)} \\ \frac{dC_b(t)}{dt} &= (C_{b1} - C_b(t))\frac{w_1(t)}{h(t)} + (C_{b2} - C_b(t))\frac{w_2(t)}{h(t)} - \frac{k_1 C_b(t)}{(1 + k_2 C_b(t))^2} \end{aligned} \quad (5)$$

Пусть  $k_1 = k_2 = 1$ . Модель (5) имеет входной сигнал  $w_2(t)$  и выходной сигнал  $C_b(t)$ .

Можно было бы решить систему (5) относительно  $C_b(t)$  известными способами, но в системе MATLAB имеется программное средство Simulink – типичный представитель визуально-ориентируемых языков программирования. Пользователь практически не имеет дело с обычным программированием. Программа в кодах автоматически генерируется в процессе ввода выбранных блоков компонентов, их соединений и задания параметров компонентов в реальном масштабе времени. Средства визуализации результатов моделирования настолько наглядны, что созданная в виде блок-схемы модель работает в реальном масштабе времени [4,5]. В среде Simulink система (5), набранная в виде работающей блок-схемы, представлена на рис.2.

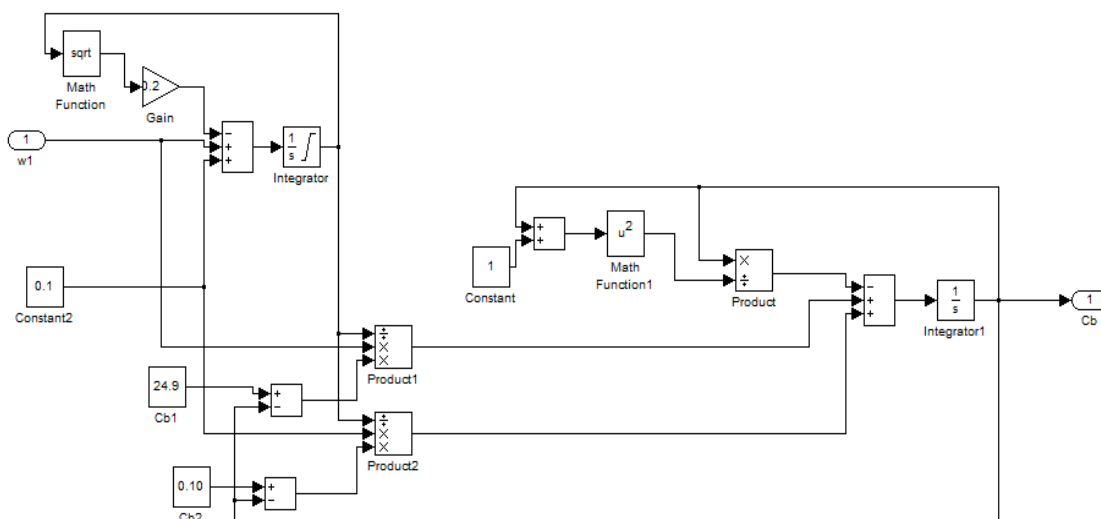


Рис.2. Блок-схема каталитического реактора в среде Simulink.

Из рис.2 видно, что левый верхний угол блок-схемы моделирует решение  $h(t)$  первого уравнения системы (5). Затем это решение вставляется во второе уравнение (5), которое решается относительно  $C_b(t)$ . Это смоделировано на остальной части блок-схемы.

## 2. ФОРМИРОВАНИЕ ОБУЧАЮЩЕЙ ВЫБОРКИ

Для формирования обучающей выборки необходимо синтезировать входной и выходной сигналы с помощью активации блок-схемы рис.2 в системе Simulink. В качестве входного сигнала принят случайный как по амплитуде, так и по времени, ступенчатый сигнал. На рис.3 представлены графики входного и выходного сигналов после активации блок-схемы рис.2.

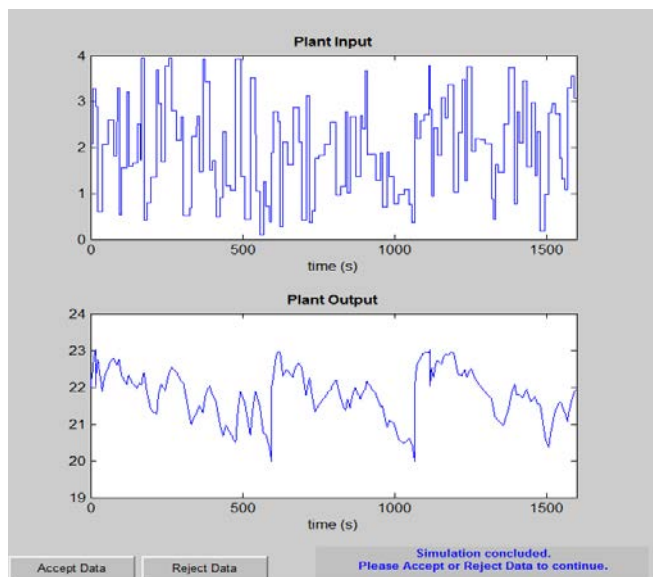


Рис.3. Входной и выходной сигналы каталитического реактора.

## 3. ПОСТРОЕНИЕ МОДЕЛИ $Y'_i = F'(X_i, U', A)$ , $i = 1, \dots, N$ В ВИДЕ НЕЙРОННОЙ СЕТИ

Построение модели для системы управления реактором, как и формирование обучающей выборки для нейронной сети являются важнейшими этапами синтеза системы. В настоящее время эти этапы реализуются эвристически. Исходя из опыта авторов [6,7], динамические нейронные сети с обратными связями имеют сложности в процессе их идентификации. Сложность состоит в возможной нестабильности процесса минимизации функционала качества, которая требует использовать дополнительные средства регуляризации процесса. В связи с этим в данной работе предлагается выбрать в качестве модельного оператора  $Y'_i = F'(X_i, U', A)$ ,  $i = 1, \dots, N$  динамическую нелинейную двухслойную нейронную сеть прямого распространения (без обратных связей) с двумя входами и одним выходом с линиями задержки для каждого входа в отдельности. Функциональная схема этой нейронной сети представлена на рис.4.

Сеть описывается соотношениями

$$\begin{aligned} a^1 &= \text{tansig}(\mathbf{IW}^{1,1} y_p + \mathbf{IW}^{1,2} u + b^1) \text{ – для первого слоя и} \\ y_m &= \text{purelin}(\mathbf{LW}^{2,1} a^1 + b^2) \text{ – для второго слоя} \end{aligned} \quad (6)$$

Роль параметров  $A$  в операторе  $F'(X_i, U', A)$  (6) выполняют весовые матрицы  $\mathbf{IW}^{1,1}$ ,  $\mathbf{IW}^{1,2}$ ,  $\mathbf{LW}^{2,1}$  и векторы  $b^1, b^2$ .

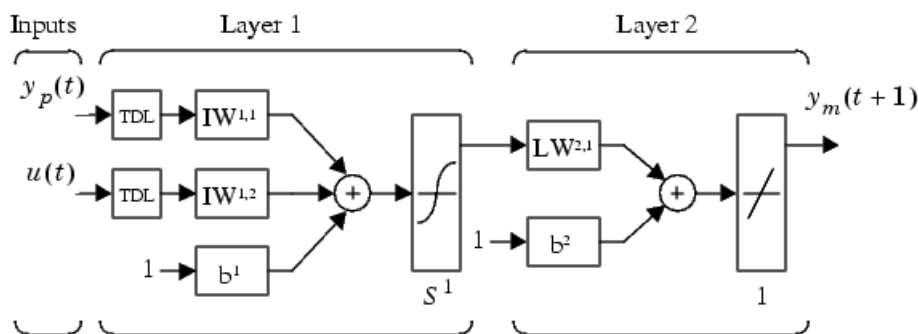


Рис.4. Нейронная сеть, моделирующая оператор  $F'(X_i, U', A)$ .

Далее переходим к процедуре оценки параметров  $A$  согласно соотношению  $A^* = \min_{A \in \Omega} \sum \Phi(Y_i, Y'_i)$  (3). Эта процедура выполняет идентификацию модели рис.4 в соответствии с некоторым критерием качества идентификации  $\Phi(Y_i, Y'_i)$ . В качестве функционала  $\Phi(\cdot)$  выбран средний квадрат разности между желаемым сигналом  $y_r$  и реакцией нейросети  $y_m$

$$\Phi = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2 \quad (7)$$

при некотором фиксированном пробном сигнале управления  $U'$  согласно (3).  $j \in [N_1, N_2]$  определяет интервал ошибки прогноза в будущее при идентификации модели.  $j=1, \dots, N_u$  определяет интервал, в котором прогноз ошибки приращения сигнала управления вычисляется. Величина  $\rho$  определяет вклад, который вносит мощность управления в совокупный критерий качества.

Критерий (7) определяет алгоритм управления с предсказанием, когда нейросетевая модель предсказывает реакцию объекта управления на определённом временном интервале в будущем [4].

#### 4. ИДЕНТИФИКАЦИЯ МОДЕЛИ

Блок-схема процесса идентификации модели представлена на рис.5. Схема содержит нейросетевую модель, каталитический реактор (Plant) и блок алгоритма обучения, который должен минимизировать ошибку (7) между целевым сигналом  $y_r$  и сигналом с выхода модели  $y_m$ . Далее необходимо конкретизировать число параметров нейронной сети рис.4. Эта конкретизация представлена на рис.6. Из рис.6 видно, что модель содержит 7 нейронов в первом слое, 0.2 с. – интервал дискретизации сигналов в обучающей выборке, справа 2 и 2 – количество элементов задержки (TDL на рис.4), 8000 – это ограничение на число дискретных отсчётов в сигналах обучающей выборки. Окно Browse показывает, что из библиотеки Simulink выбрана модель каталитического реактора cstr. 200 – это ограничение на число итераций при минимизации среднеквадратичной ошибки при обучении модели. Use Validation Data – означает, что 25% обучающей выборки будет использовано для формирования контрольного и тестового подмножеств выборки. Из окна Training Function видно, что для обучения модели выбран алгоритм Левенберга-Марквардта [5]

$$x_{k+1} = x_k - (J^T J + \mu I)^{-1} J^T e \quad (8)$$

где  $e(\mathbf{w})$  – вектор ошибки между целевым сигналом и выходом нейронной сети, который зависит от весовых матриц сети  $\mathbf{w}$ .  $\mathbf{J} = \left\{ \frac{\partial e_i}{\partial w_j} \right\}$  – матрица Якоби,  $\mathbf{I}$  – единичная матрица и  $\mu$  – параметр регуляризации. Если  $\mu = 0$ , то алгоритм (8) становится методом Ньютона с аппроксимацией матрицы Гессе  $\mathbf{H} = \mathbf{J}^T \mathbf{J}$ . Если значение  $\mu$  очень большое, то (8) становится градиентным методом с малым шагом итерации.

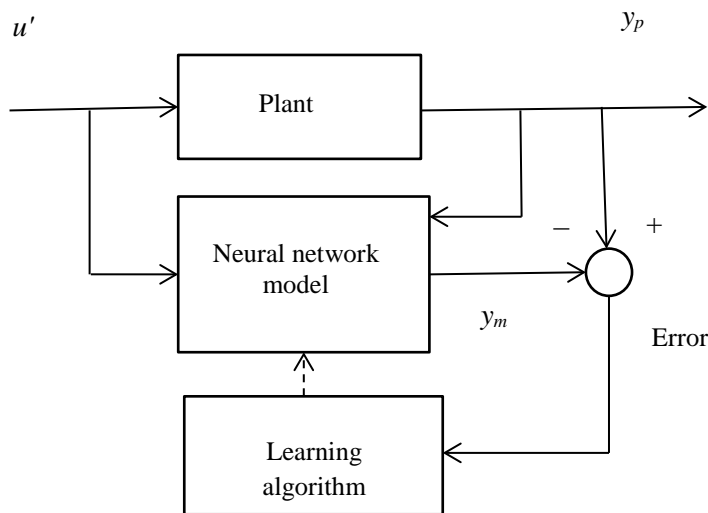


Рис.5. Блок-схема процесса идентификации модели.

Plant Identification	
Network Architecture	
Size of Hidden Layer	7
Sampling Interval (sec)	0.2
No. Delayed Plant Inputs	2
No. Delayed Plant Outputs	2
<input type="checkbox"/> Normalize Training Data	
Training Data	
Training Samples	8000
Maximum Plant Input	4
Minimum Plant Input	0
Maximum Interval Value (sec)	20
Minimum Interval Value (sec)	5
Simulink Plant Model:	cstr
<input checked="" type="checkbox"/> Limit Output Data	
Maximum Plant Output	23
Minimum Plant Output	20
Training Parameters	
Training Epochs	200
Training Function	trainlm
<input checked="" type="checkbox"/> Use Current Weights	<input checked="" type="checkbox"/> Use Validation Data
<input type="checkbox"/> Use Testing Data	
<input type="button" value="Generate Training Data"/> <input type="button" value="Import Data"/> <input type="button" value="Export Data"/>	
<input type="button" value="Train Network"/> <input type="button" value="OK"/> <input type="button" value="Cancel"/> <input type="button" value="Apply"/>	
Generate or import data before training the neural network plant.	

Рис.6. Параметры идентификации нейросетевой модели.

Значение  $\mu$  уменьшается на каждом успешном шаге итерации (когда ошибка уменьшается) и увеличивается в противном случае. Для сокращения размера памяти для хранения матрицы Гессе в алгоритме `trainlm` используется факторизация

$$J^T J = \begin{bmatrix} J_1^T & J_2^T \end{bmatrix} \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = J_1^T J_1 + J_2^T J_2 \quad (9)$$

поэтому полная матрица Якоби не существует в одно и то же время.

Процесс обучения модели представлен на рис.7-9.

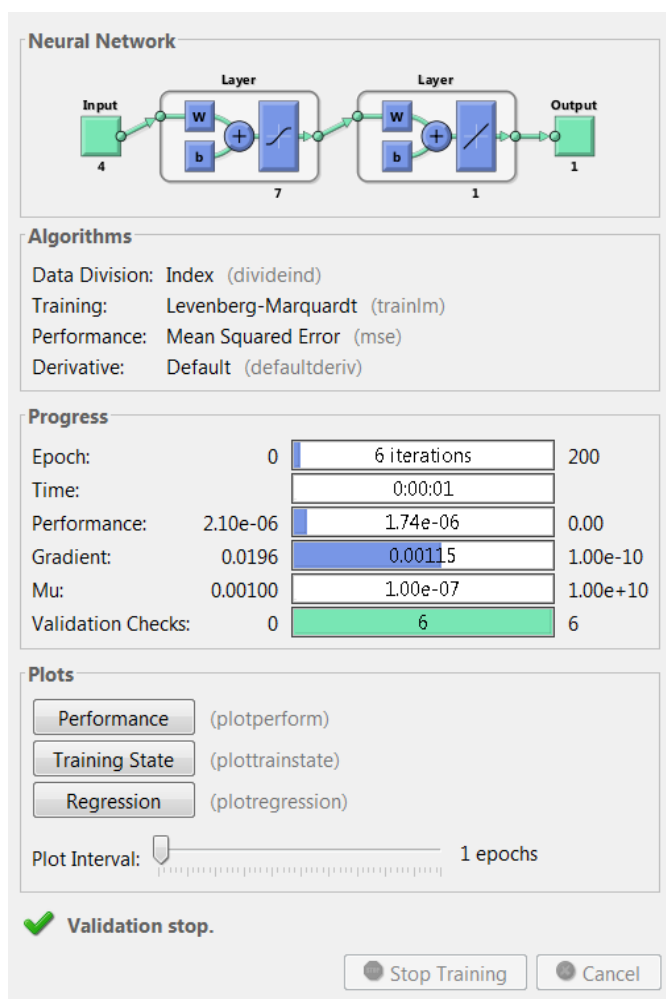


Рис.7. Параметры процесса обучения модели.

Процесс идентификации завершился после обработки всех 8000 дискретных отсчётов сигналов по времени.

Результаты обучения модели представлены на рис.10.

На рис.11 представлены результаты тестирования модели на 25% части обучающей выборки, которая не предъявлялась модели для обучения.

Из рис.10 и рис.11 следует, что модель обучилась качественно, и можно переходить к следующему этапу – формирования оптимального сигнала управления, представленному соотношением (4). В рассматриваемом случае необходимо минимизировать функционал (7) по сигналу управления  $u(t)$ , т.е. прогноз приращения ошибки сигнала управления должен быть минимизирован.



На рис.12 приведены конкретные параметры для функционала (7) с выбором метода минимизации.




Рис.8. Графики ошибок обучения и тестирования модели.




Рис.9. Графики параметров алгоритма обучения модели.




Рис.10. Результаты обучения модели.

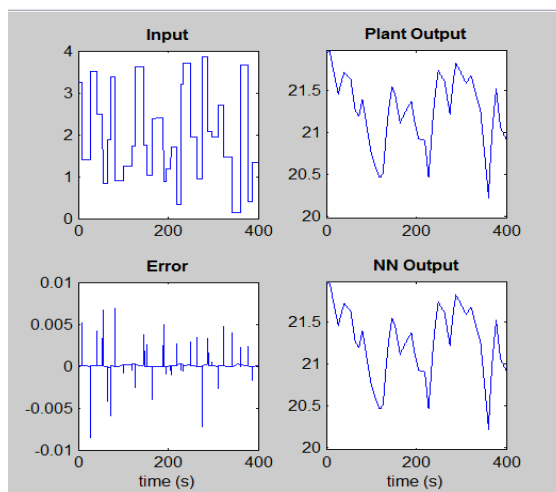


Рис.11. Результаты тестирования модели.

Figure 12 is a screenshot of a software dialog box titled 'Neural Network Predictive Control'. It contains several input fields and buttons. The 'Cost Horizon (N2)' field is set to 7, and the 'Control Horizon (Nu)' field is set to 2. The 'Control Weighting Factor (ρ)' field is set to 0.05, and the 'Search Parameter (α)' field is set to 0.001. The 'Minimization Routine' is set to 'csrchbac' via a dropdown menu, and the 'Iterations Per Sample Time' field is set to 2. At the bottom, there are three buttons: 'Plant Identification', 'OK', and 'Cancel', along with an 'Apply' button.

Рис.12. Выбор параметров для функционала (7).

Здесь полагаем  $N_1=1$ ,  $N_2=7$  – означает число временных шагов в будущее (прогноз), в котором минимизируются ошибки предсказания.  $N_u=2$  – есть число временных шагов в будущее, в котором приращения управления минимизируются. Этот метод в [4] назван принципом удаляющего горизонта. Фактор  $\rho=0.05$  описан выше. Параметр  $\alpha=0.001$  определяет момент остановки алгоритма одномерного поиска экстремума для функционала (7). Алгоритм минимизации для поиска оптимального управления выбран `csrchbac` из библиотеки алгоритмов в системе Matlab. Этот алгоритм реализует одномерный поиск минимума методом перебора с возвратами. В правом нижнем углу рис.12 цифра 2 означает число итераций алгоритма минимизации ошибки в каждый момент времени.

На рис.13 представлена блок-схема контроллера для управления каталитическим реактором.

Работающая в системе Simulink общая блок-схема технологического процесса управления концентрацией продукта на выходе каталитического реактора путём изменения  $w_1$  скорости потока продукта с концентрацией  $C_{b1}$  представлена на рис.14.

Следующий рис.15 содержит два сигнала. Импульсный сигнал со случайной амплитудой и длительностью определяет целевое изменение концентрации продукта на выходе реактора. Другой сигнал – это фактическое изменение концентрации на выходе реактора после идентификации нейросетевой модели и определения оптимального управления (скорости потока  $w_1$  продукта с концентрацией  $C_{b1}$ ).

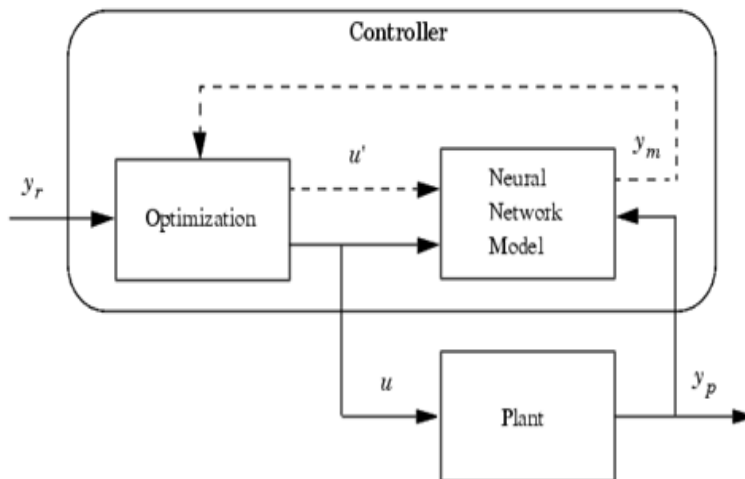


Рис.13. Блок-схема контроллера.

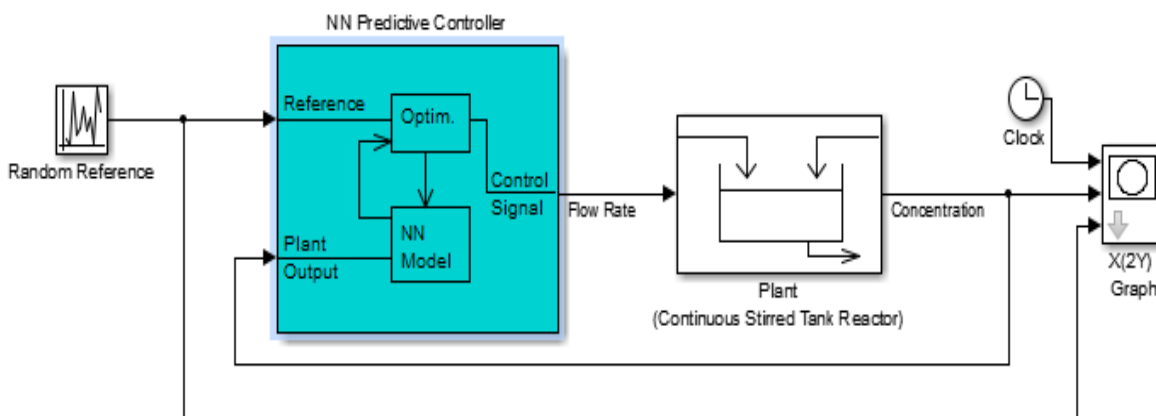


Рис.14. Блок-схема технологического процесса.




Рис.15. Сравнение целевого сигнала и выходного сигнала из контроллера.

Из рис.15 следует удовлетворительное изменение концентрации продукта на выходе реактора по сравнению с целевым сигналом. Возможно, что при увеличении числа нейронов в первом слое нейронной сети, позволит увеличить точность регулирования выходного сигнала с объекта управления. Однако, уже из рис.15 следует, что контроллер с предсказанием на основе нейронной сети можно использовать для управления каталитическим реактором.

## ВЫВОДЫ

1. Показано, что нейронные сети имеют преимущества перед классическими системами оптимального управления для реализации в системах управления технологическими процессами.
2. Приведена блок-схема каталитического реактора с использованием программирования Simulink в системе Matlab, на основе которой сформирована обучающая выборка для нейронной сети.
3. В качестве модели каталитического реактора выбрана и обоснована динамическая нейронная сеть прямого распространения (без обратных связей) с линиями задержки отдельно для сигналов входа, так и для сигналов управления.
4. Произведены процедуры идентификации (2) и оптимизации сигнала управления по критерию качества (7). Показано, что идентификация выбранной нейронной сети была успешной и реализовалась за 6 итераций алгоритмом обучения Левенберга-Марквардта на процессоре Intel Core i7. При этом критерий качества идентификации принял значение  $1.74e-06$ .
5. Произведено тестирование обученной нейронной сети на выборках сигналов, которые не предъявлялись для обучения. Показано, что контроллер с предсказанием на основе нейронной сети можно использовать для управления каталитическим реактором.

## ЛИТЕРАТУРА

1. *Растрюгин Л.А.* Системы экстремального управления. – М.: Наука, 1974. – 630 с.
2. *Хайкин С.* Нейронные сети (Полный курс). – Москва, С.-Петербург, Киев: «Вильямс», 2006. – 1103 с.
3. Neural Network Toolbox (For Use with MATLAB), “MathWorks”, Inc. Version 5.
4. *Soloway D., Haley P.J.* Neural generalized predictive control / 1996 IEEE International Symposium on Intelligent Control. Proceedings. – 1996. – P.277-281.
5. *Hagan M.T., Menhaj M.* Training feedforward networks with the Marquardt algorithm // IEEE Transactions on Neural Networks. – 1994. – Vol.5. – №6. – P.989-993.
6. *Басистов Ю.А., Яновский Ю.Г.* Нейродинамическая модель вязкоупругих сред с ассоциативной памятью // Доклады Академии наук. – 2010. – Т.430. – №4. – С.494-497.
7. *Басистов Ю.А., Яновский Ю.Г.* Нейронная сеть с ассоциативной и наследственной памятью как модель вязкоупругих сред // Нейрокомпьютеры, разработка, применение. – 2010. – №7. – С.29-39.

Поступила в редакцию 29 сентября 2014 года.

---

### Сведения об авторах:

Басистов Юрий Александрович – к.т.н., в.н.с., ФГБУН Институт прикладной механики РАН, г. Москва, Россия; e-mail: [yuabas@mail.ru](mailto:yuabas@mail.ru)

Яновский Юрий Григорьевич – д.т.н., проф., дир., ФГБУН Институт прикладной механики РАН, г. Москва, Россия; e-mail: [iam@iam.ras.ru](mailto:iam@iam.ras.ru)