

# РАЗРАБОТКА НЕЙРОСЕТИ ДЛЯ ПОДДЕРЖАНИЯ КАЧЕСТВА ДИХЛОРЕТАНА В СРЕДЕ MATLAB И МОДЕЛИРОВАНИЕ ВИРТУАЛЬНОГО АНАЛИЗАТОРА В MATLAB SIMULINK

DEVELOPMENT OF A NEURAL NETWORK FOR MAINTAINING THE QUALITY OF DICHLOROETHANE IN THE MATLAB ENVIRONMENT AND SIMULATION OF A VIRTUAL ANALYZER IN MATLAB SIMULINK

*E. Muravyova  
G. Maskov*

*Summary.* The article presents the development of a neural network (НС) for quality control of dichloroethane in the MATLAB environment, as well as the simulation of a virtual analyzer in MATLAB Simulink. The architecture chosen is a Feed-forward backpropagation network, trained using the Levenberg—Marquardt algorithm. The НС includes a hidden layer with ten sigmoid neurons and an output layer with two linear neurons. The input parameters are the consumption of hydrogen chloride, ethylene, and oxygen, and the output parameters are the concentrations of dichloroethane and CO<sub>2</sub>.

The following metrics were used to evaluate the effectiveness of training: mean square error (MSE), error distribution histogram and linear regression. The simulation results in Simulink confirmed the adequacy of the НС operation, which allows it to be integrated into the process control system.

*Keywords:* neural networks, MATLAB, quality control, error back propagation, modeling, virtual analyzer, regression analysis.

**Муравьева Елена Александровна**

*д.т.н., профессор, Уфимский государственный  
нефтяной технический университет  
muraveva\_ea@mail.ru*

**Масков Газинур Гайсарович**

*Уфимский государственный  
нефтяной технический университет  
maskov.gazinur.gaz@yandex.ru*

*Аннотация.* В статье представлена разработка нейронной сети (НС) для контроля качества дихлорэтана в среде MATLAB, а также моделирование виртуального анализатора в MATLAB Simulink. В качестве архитектуры выбрана сеть прямого распространения с обратным распространением ошибки (Feed-forward backprop), обученная по алгоритму Левенберга — Марквардта. НС включает скрытый слой с десятью сигмовидными нейронами и выходной слой с двумя линейными нейронами. Входными параметрами являются расходы хлористого водорода, этилена и кислорода, а выходными — концентрации дихлорэтана и CO<sub>2</sub>.

Для оценки эффективности обучения использованы метрики: среднеквадратичная ошибка (MSE), гистограмма распределения ошибок и линейная регрессия. Результаты моделирования в Simulink подтвердили адекватность работы НС, что позволяет интегрировать её в систему управления технологическим процессом.

*Ключевые слова:* нейронные сети, MATLAB, контроль качества, обратное распространение ошибки, моделирование, виртуальный анализатор, регрессионный анализ.

## Введение

Контроль качества дихлорэтана в химическом производстве требует оперативного мониторинга концентраций. В работе предложено решение на основе нейронной сети, разработанной в MATLAB. Использована архитектура Feed-forward backprop с алгоритмом обучения Левенберга-Марквардта. Модель анализирует расходы хлористого водорода, этилена и кислорода для прогнозирования концентраций дихлорэтана и CO<sub>2</sub>.

**Разработка нейросети для поддержания качества дихлорэтана в среде MATLAB и моделирование виртуального анализатора в MATLAB Simulink**

Системы управления на основе искусственных нейронных сетей (НС) — один из ярких примеров управле-

ния, когда принципы функционирования и управления эффективно использованы для создания нового поколения систем управления технологическими процессами и объектами.

Виртуальные анализаторы на основе НС эффективны в случаях, когда создание адекватной аналитической модели исполнительской системы и синтез дихлорэтана затруднен. Использование виртуального анализатора для определения концентрации CO<sub>2</sub> и дихлорэтана в процессе окислительного хлорирования этилена имеет большую значимость, поскольку наряду с основной реакцией получения дихлорэтана возможно протекание побочных реакций глубокого окисления этилена с образованием оксидов углерода.

Для разработки виртуального анализатора используем нейронную сеть. Для построения и обучения НС вос-

пользуемся встроенным инструментом NNTool среды MATLAB [1].

Чтобы запустить NNTool, необходимо выполнить одноименную команду в командном окне MATLAB: `>>nntool`

После этого появится главное окно «Окно управления сетями и данными» (Network/DataManager). Загрузка базы данных для обучения осуществляется через импорт из рабочей области MATLAB (Import from MATLAB workspace).

Во вкладке Network окна создания нейронной сети можно выбрать архитектуру нейронной сети (рисунок 1), диапазон входных значений (Input data), функцию тренировки сети (Training function), адаптивную функцию обучения (Adaption learning function), функцию ошибки (Performance function), количество слоев нейронной сети (Number of Layers) и для каждого слоя указано  $m$  количество нейронов (Number of neurons) и активационную функцию (Transfer Function).

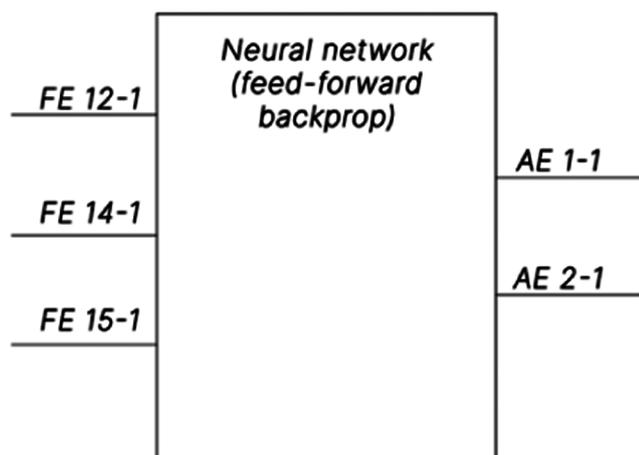


Рис. 1. Концептуальная модель нейронной сети для определения концентраций дихлорэтана и  $\text{CO}_2$

Архитектура нейронной сети — это структура и организация нейронов, слоев и связей в нейросети [4,3]. Она определяет, как данные протекают через сеть, какие операции выполняются на каждом уровне и как нейроны взаимодействуют друг с другом для выполнения конкретной задачи, такой как классификация, регрессия или обработка изображений. Архитектура нейронной сети может включать в себя различные типы слоев, функций активации, методы оптимизации и другие параметры, которые определяют ее поведение и способность к обучению на определенном наборе данных.

Существует несколько различных архитектур слоев нейронов в нейронных сетях, которые могут быть использованы для различных задач машинного обучения.

Некоторые из наиболее распространенных видов архитектур слоев нейронов включают в себя:

1. Полносвязанные слои (Dense layers): в полносвязанных слоях каждый нейрон связан с каждым нейроном предыдущего и последующего слоев. Это классическая архитектура нейронных сетей.
2. Сверточные слои (Convolutional layers): сверточные нейронные сети обычно используются для анализа изображений. Сверточные слои применяют фильтры к входным данным для извлечения признаков.
3. Рекуррентные слои (Recurrent layers): рекуррентные нейронные сети обрабатывают последовательные данные, такие как текст или временные ряды. Рекуррентные слои имеют память и могут учитывать контекст из предыдущих шагов.
4. Пулинг слои (Pooling layers): пулинг слои используются в сверточных нейронных сетях для уменьшения размерности данных и извлечения наиболее важных признаков.
5. Слой нормализации (Normalization layers): слои нормализации могут помочь в стабилизации обучения нейронных сетей путем нормализации входных данных. Это лишь несколько примеров архитектур слоев нейронов, которые могут быть использованы в нейронных сетях для различных целей и задач машинного обучения.
6. Архитектура нейронной сети — Feed-forward backprop (прямого распространения сигнала) представляет собой один из типов нейронных сетей, который используется для обучения и предсказания.

Эта архитектура состоит из входных, скрытых и выходных слоев нейронов [2]. В ней нет циклических связей, то есть информация движется только в одном направлении — от входных нейронов к выходным.

В процессе обучения сети используется метод обратного распространения ошибки (backpropagation), который позволяет корректировать веса связей между нейронами для минимизации ошибки в выходном слое.

Для решения поставленной задачи выбрана сеть Feed-forward backprop с десятью сигмовидными нейронами скрытого слоя и двумя линейными нейронами выходного слоя. Алгоритм обучения — Левенберга — Маркардта.

Рассмотрим подробнее сеть с прямым распространением сигнала и обратным распространением ошибки (Feed-forward backprop)[1]. Для обучения описанной нейронной сети был использован алгоритм обратного распространения ошибки (backpropagation). Этот метод обучения многослойной нейронной сети называется обобщенным дельта правилом. Этот алгоритм определя-

ет два «потока» в сети. Входные сигналы двигаются в прямом направлении, в результате чего мы получаем выходной сигнал, из которого мы получаем значение ошибки. Величина ошибки движется в обратном направлении, в результате происходит корректировка весовых коэффициентов связей сети.

На (рисунке 2) представлена схема архитектуры нейронной сети, где расходы хлористого водорода, этилена и кислорода (FE 12-1, FE 14-1, FE 15-1) — входные параметры, а концентрации дихлорэтана и CO<sub>2</sub>(AE 1-1 и AE 2-1) — выходные параметры.

Во время обучения нейронной сети можно наблюдать, как изменяется ошибка обучения.

График среднеквадратичной ошибки (MSE, Mean Squared Error) в MATLAB [2] показывает изменение сред-

неквадратичной ошибки нейросети во время процесса обучения. Этот график представляет собой зависимость MSE от числа итераций (эпох обучения). Высокий MSE означает, что нейросеть делает много ошибок в предсказаниях, низкий MSE — что нейросеть делает меньше ошибок и обучается более эффективно (рисунок 3).

С помощью гистограммы можно визуализировать ошибки, разницу между целевыми и прогнозируемыми значениями после обучения нейронной сети с прямым распространением сигнала и обратным распространением ошибки (рисунок 3).

График гистограммы среднеквадратичной ошибки нейронной сети в MATLAB [1] обычно показывает распределение ошибок на различных участках данных. Каждый столбец гистограммы представляет собой ча-

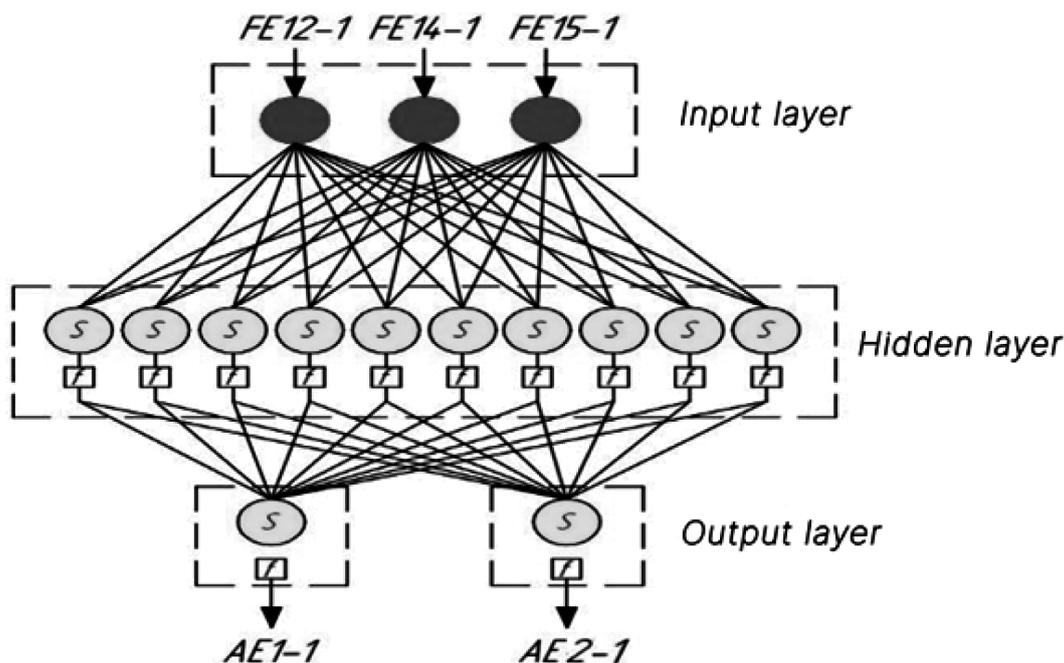


Рис. 2. Структура построения нейронной сети с 10 нейронами

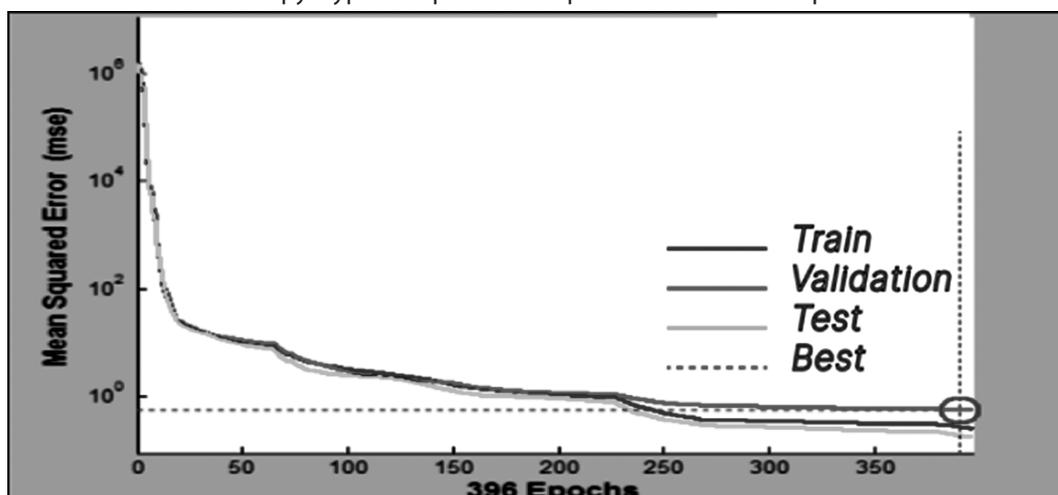


Рис. 3. Средняя квадратичная ошибка

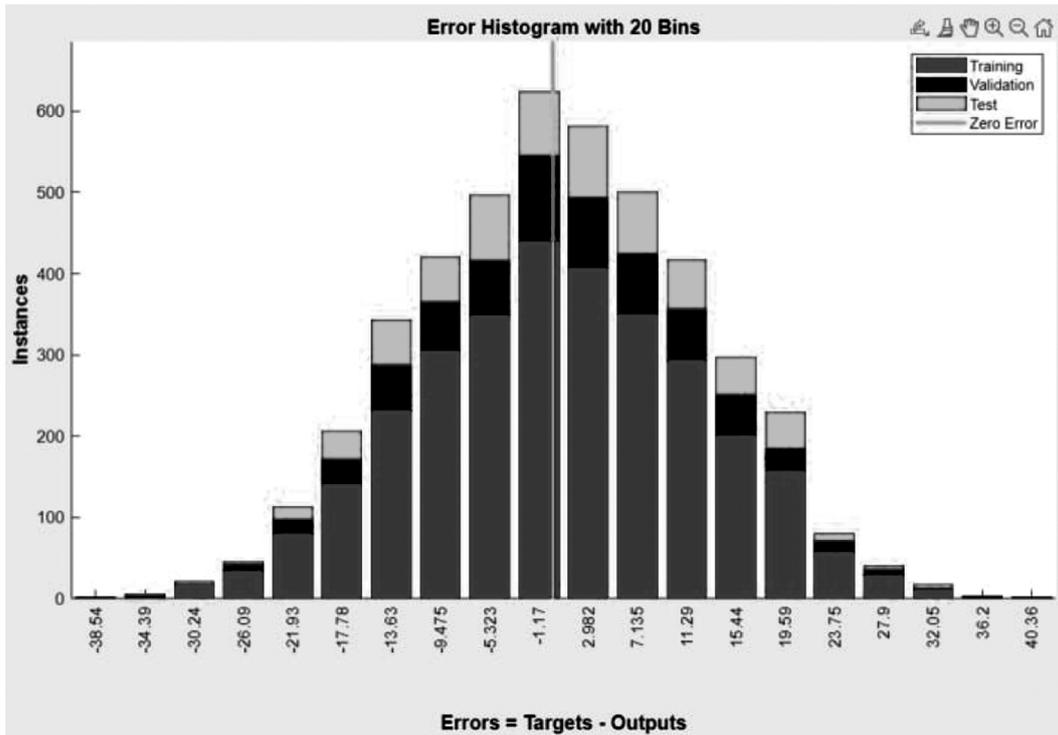


Рис. 4. Гистограмма среднеквадратичных ошибок

стоту ошибок, попадающих в определенный диапазон значений. Чем выше столбец, тем больше ошибок в этом диапазоне значений (рисунок 4).

Ячейки — это количество вертикальных полос, которые находятся на графике. Общий диапазон ошибок здесь разделен на 20 ячеек меньшего размера.

Ось X представляет количество выборок из набора данных, которые находятся в определенной ячейке. Например, в середине графика находится ячейка, соответствующая ошибке  $-1,17$ , и высота этой ячейки для обучающего набора данных находится ниже, но близко к 400, а для проверки и тестового набора данных — между 500 и 600. Это означает, что во многих выборках, из разных наборов, данных ошибка лежит в следующем диапазоне.

Нулевая линия ошибки, соответствующая нулевому значению ошибки на оси ошибок (т.е. оси X). В этом случае нулевая точка ошибки попадает под ячейку с центром  $-1,17$ .

Еще одним инструментом оценки результата обучения нейронной сети может быть функция регрессии результатов [5-7]. График регрессии отображает сетевые прогнозы (выходные данные) в отношении ответов (целевых) для наборов обучения, проверки и тестов (рисунок 5).

Так как точки лежат на линии прогноза в линейной регрессии в Neural Network Toolbox, то можно сделать

вывод о том, что модель адекватно описывает зависимость между входными и выходными параметрами. Это означает, что прогнозы модели совпадают с реальными значениями. Таким образом, можно считать модель очень точной и надежной.

Моделирование нейронной сети осуществляется с помощью среды моделирования Simulink, входящей в состав MATLAB [7].

Для того, чтобы построить модель в Simulink, достаточно импортировать натренированную модель в соответствующем пункте меню (рисунок 6).

Для того, чтобы задать входные и выходные значения был использован функциональный блок Constant. Объединение двух входных значений произведено с помощью блока Mux. Для отображения выходных значений использован блок Display. Разъединение одного сигнала в два произведено с помощью блока Demux (рисунок 7).

Моделирование нейронной сети показало адекватный результат концентраций дихлорэтана и  $CO_2$ , что говорит о возможности дальнейшего подключения нейросетевого блока к нечеткой системе управления для регулирования клапанов подачи расходов хлористого водорода, кислорода и этилена.

### Закключение

Таким образом, создана нейросетевая модель для контроля качества дихлорэтана. Модель успешно пред-

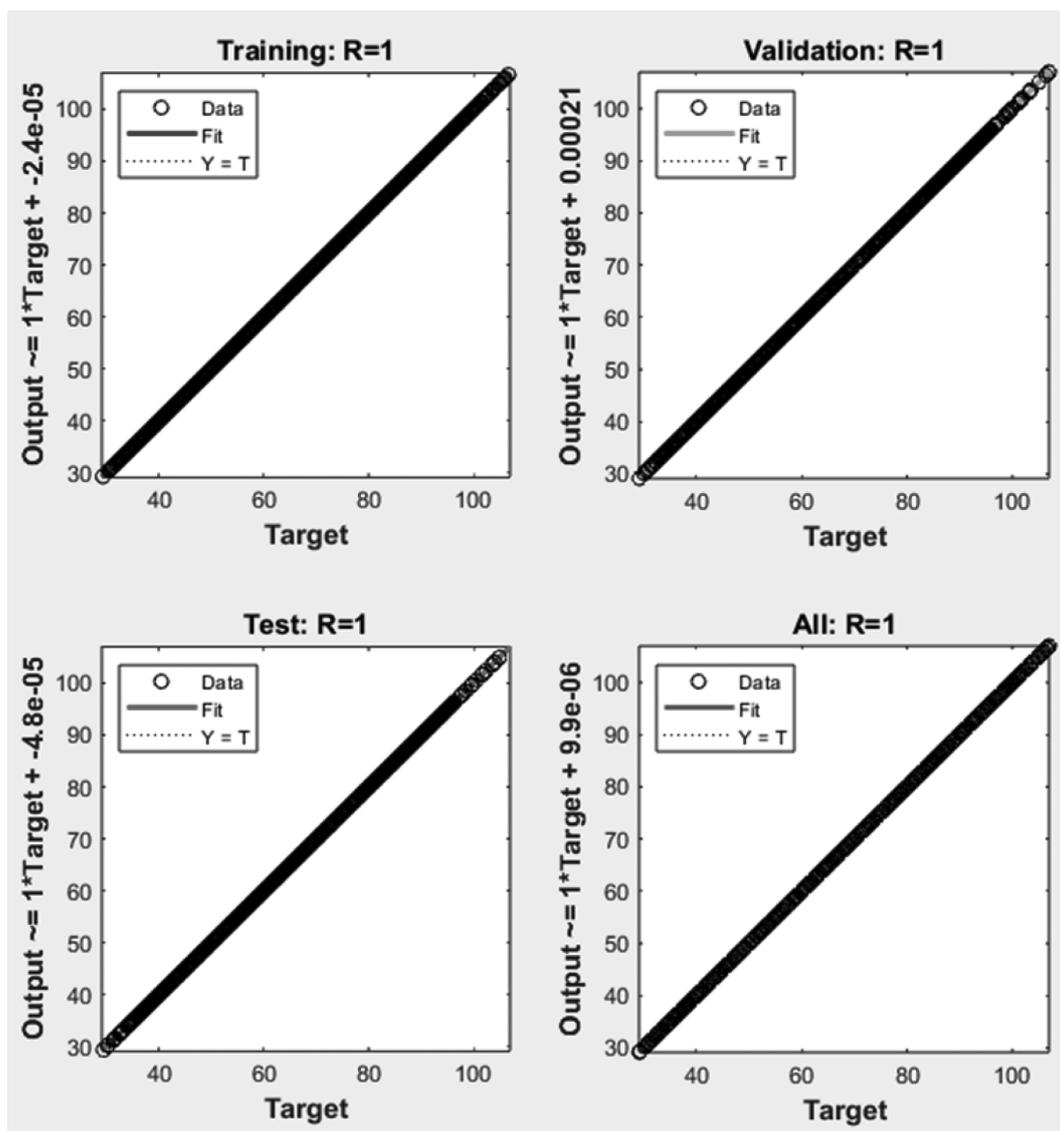


Рис. 5. Линейная регрессия НС



Рис. 6. Экспорт НС в Simulink

сказывает концентрации веществ на основе данных о расходах. Результаты показали, что такой подход можно использовать для автоматизации химического производства.

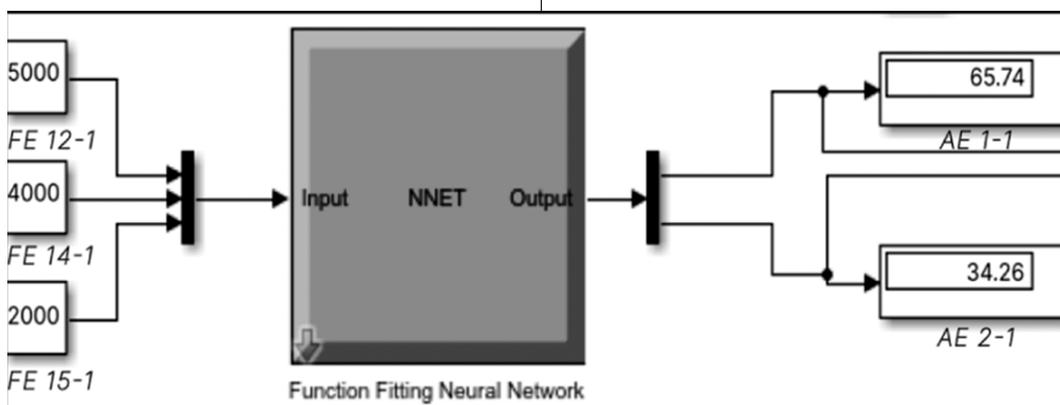


Рис. 7. Структурная схема созданной нейронной сети в среде Simulink

---

ЛИТЕРАТУРА

1. Муравьева Е.А. Интегрированные системы проектирования и управления [Текст]: учеб. пособие / Муравьева Е.А. — Уфа: Изд-во УГНТУ, 2011. — 354 с.
2. Такиуллина Д.Т. Разработка автоматизированной системы управления процессом окислительного хлорирования этилена в цехе №29 акционерного общества «Башкирская содовая компания» / Журнал «Наука и инновационные технологии», Кыргызстан. DOI:10.33942/sit042333, 2023. — 4 с.
3. Слетнев, М.С. Усовершенствованное управление (APC) нефтехимическим производством на основе многоуровневой нейросетевой системы поддержки принятия решений / М.С. Слетнев, А.П. Веревкин // Интеллектуальный потенциал XXI века: ступени познания. — 2012. — № 13. — С. 81–84. — EDNRPTNTV.
4. Методы робастного, нейро-нечёткого и адаптивного управления / под общ.ред. К.А. Пупкова. — М.: МГТУ им. Н.Э. Баумана, 2001. — 245 с.
5. MATLABbasedbooks (Neural/Fuzzy) — Аннотированный список книг по нечёткой логике и нейронным сетям, ориентированный на использование MATLAB [Электронный ресурс]. — URL: <http://www.mathworks.com/support/books/index.jsp?category=9> (дата обращения: 04.02.2022).
6. Штовба, С.Д. Проектирование нечетких классификаторов в системе MATLAB / С.Д. Штовба, О.Д. Панкевич // Труды Всероссийской научной конференции «Проектирование научных и инженерных приложений в системе MATLAB». — М., 2004. — 1318–1335 с.
7. Штовба, С.Д. Проектирование нечетких систем средствами MATLAB / С.Д. Штовба. — М.: горячая линия — Телеком, 2007. — 288 с.

---

© Муравьева Елена Александровна (muraveva\_ea@mail.ru); Масков Газинур Гайсарович (maskov.gazinur.gaz@yandex.ru)  
Журнал «Современная наука: актуальные проблемы теории и практики»