

## АВТОМАТИЗАЦИЯ ПРОЦЕССОВ ХИМИЧЕСКОЙ ТЕХНОЛОГИИ

DOI: 10.15593/2224-9400/2022.2.09

Научная статья

УДК 681.5.03, 004.032.26

**Е.А. Муравьева, Р.В. Казанцев, Д.В. Подлесский**

Филиал ФГБОУ ВО «Уфимский государственный  
нефтяной технический университет»  
в г. Стерлитамаке, Стерлитамак, Россия

### РАЗРАБОТКА НЕЙРОННОЙ СЕТИ ДЛЯ УПРАВЛЕНИЯ ПРОЦЕССОМ ЩЕЛОЧНОЙ ОТМЫВКИ ИЗОПЕНТАН- ИЗОПРЕН-ТОЛУОЛЬНОЙ ФРАКЦИИ С ИСПОЛЬЗОВАНИЕМ ВИРТУАЛЬНОГО АНАЛИЗАТОРА

*Во всех промышленно развитых странах химический комплекс относится к числу базовых секторов обрабатывающего производства. В структуре химического комплекса особое место занимает промышленность синтетического каучука. Важность развития производства синтетического каучука в России обуславливается особой значимостью конечных изделий, наличием широкой сырьевой базы, необходимых трудовых ресурсов, высокой экономической эффективностью, а также большими перспективами роста потребления как внутри страны, так и за ее пределами. Устойчивое развитие производства синтетического каучука будет способствовать решению задач экономической безопасности, социальных проблем, задач по улучшению экологической обстановки в крупных регионах-производителях каучуков [1]. Щелочная отмывка изопентан-изопрен-толуольной фракции (ИИТФ) является важным узлом при производстве полиизопренового каучука и предназначена для разрушения вредных примесей в растворителе, таких как карбонильные соединения. Качество щелочной отмывки ИИТФ непосредственно влияет на качество получаемого каучука.*

*В ходе проекта необходимо исследовать на основе производственных данных математическую модель виртуального анализатора, а также спроектировать его рабочую модель. На основе вычисленного виртуальным анализатором показателя качества, а также других технологических параметров, таких как температура подогретой щелочи и расход щелочи, необходимо разработать нейронную сеть для регулирования данных параметров. Разработанные модели позволят повысить степень автоматизации и контроля технологического процесса.*

*В результате проекта были разработаны виртуальный анализатор, непрерывно прогнозирующий показатель качества процесса в виде массовой доли щелочи после отмывки и нейросеть для регулирования технологических параметров щелочной отмывки.*

**Ключевые слова:** анализатор, виртуальный, сеть, нейросеть, отмывка.

**E.A. Muravyova, R.V. Kazantsev, D.V. Podlesskiy**

Branch of the Federal State Budgetary Educational Institution  
of Higher Education "Ufa State Petroleum Technological University"  
in Sterlitamak, Sterlitamak, Russian Federation

## **DEVELOPMENT OF A NEURAL NETWORK FOR CONTROLLING THE PROCESS OF ALKALINE WASHING OF ISOPENTANE- ISOPRENE-TOLUENE FRACTION USING A VIRTUAL ANALYZER**

*In all industrialized countries, the chemical complex is one of the basic sectors of manufacturing. The synthetic rubber industry occupies a special place in the structure of the chemical complex. The importance of the development of synthetic rubber production in Russia is due to the special significance of the final products, the availability of a wide raw material base, the necessary labor resources, high economic efficiency, as well as great prospects for consumption growth both within the country and abroad. Sustainable development of synthetic rubber production will contribute to solving problems of economic security, social problems, and tasks to improve the environmental situation in large rubber-producing regions [1]. Alkaline washing of the isopentane-isoprene-toluene fraction (IITP) is an important node in the production of polyisoprene rubber and is designed to destroy harmful impurities in the solvent, such as carbonyl compounds. The quality of alkaline washing of IITF directly affects the quality of the rubber obtained.*

*During the project, it is necessary to investigate the mathematical model of the virtual analyzer based on production data, as well as design its working model. Based on the quality indicator calculated by the virtual analyzer, as well as other technological parameters, such as the temperature of the heated alkali and the consumption of alkali, it is necessary to develop a neural network for regulating these parameters. The developed models will increase the degree of automation and control of the technological process.*

*As a result of the project, a virtual analyzer was developed that continuously predicts the process quality indicator in the form of a mass fraction of alkali after washing and a neural network for regulating the technological parameters of alkaline washing.*

**Keywords:** analyzer, virtual, network, neural network, laundering.

**Введение.** Виртуальные анализаторы (ВА) являются важнейшими элементом системы АРС. Виртуальный анализатор представляет собой программно-математический комплекс для оценки текущих состояний и прогноза показателей качества промежуточных или продуктовых потоков процесса. В промышленных производствах для анализа качества продукции чаще всего применяют поточные анализаторы (ПА), используемые для определения физико-химических свойств продуктов в режиме реального времени, и различные инструменты лабораторных анализов. И те и другие имеют свои достоинства и недостатки. Так, лабораторные анализы хоть и обладают хорошей точностью, но проводятся периодически, что не позволяет оперативно реагировать на измене-

ния в текущем технологическом процессе (например, на смену режимов работы установки). Несмотря на высокую точность и непрерывность измерений, самодиагностику и визуализацию показаний, поточные анализаторы тоже имеют свои недостатки: необходимость периодической калибровки показаний, требования квалифицированного обслуживания, невозможность определения показаний в некоторых производствах и, главное, высокую стоимость оборудования. Использование в промышленности виртуальных анализаторов служит дополнением к описанным выше методам и позволяют автоматизировать процесс расчета и оценки показателей качества предприятия, позволяют повысить качество ведения технологического процесса путем непрерывного контроля показателей качества. При этом ВА представляют собой модель, предназначенную для косвенного измерения качественных показателей того или иного процесса, построенную на основе архивных производственных данных и данных лабораторных анализов [2].

Разработка виртуального анализатора для узла щелочной отмывки изопентан-изопрен-толуольной фракции, обеспечивающего прогнозирование показателя качества отмывки, в отличие от лабораторного анализа позволит непрерывно контролировать качество ведения технологического процесса, а значит, своевременно реагировать на какие-либо неисправности в автоматической системе управления технологическим процессом (АСУ ТП). Нейросетевой регулятор на основе спрогнозированного виртуальным анализатором показателя качества, расхода щелочи и температуры щелочи позволит регулировать степени открытия клапанов для поддержания соответствующего качества, что повысит адаптивность системы.

***Краткая характеристика узла щелочной отмывки изопентан-изопрен-толуольной фракции цеха И-5П-Т9 ОАО «Синтез-Каучук».*** Узел конденсации, щелочной и водной отмывки изопентан-изопрен-толуольной фракции (ИИТФ) (рис. 1) является необходимым узлом для получения полиизопренового каучука. Сконденсированная ИИТФ поступает в диафрагменный смеситель С-1 на узел щелочной отмывки, для разрушения вредных примесей в растворителе. Расход контролируется прибором FE21-1. Щелочь предварительно подогревается в трубном пространстве теплообменника Т-1 и подается в диафрагменный смеситель С-1 с целью разрушения вредных для полимеризации примесей, которые могут образовываться в процессе разрушения каталитического комплекса и дегазации полимеризата. Подогрев щелочи производится водяным паром давлением 1,0 МПа (10,0 кгс/см<sup>2</sup>), подаваемым в межтрубное пространство теплообменника Т-1.

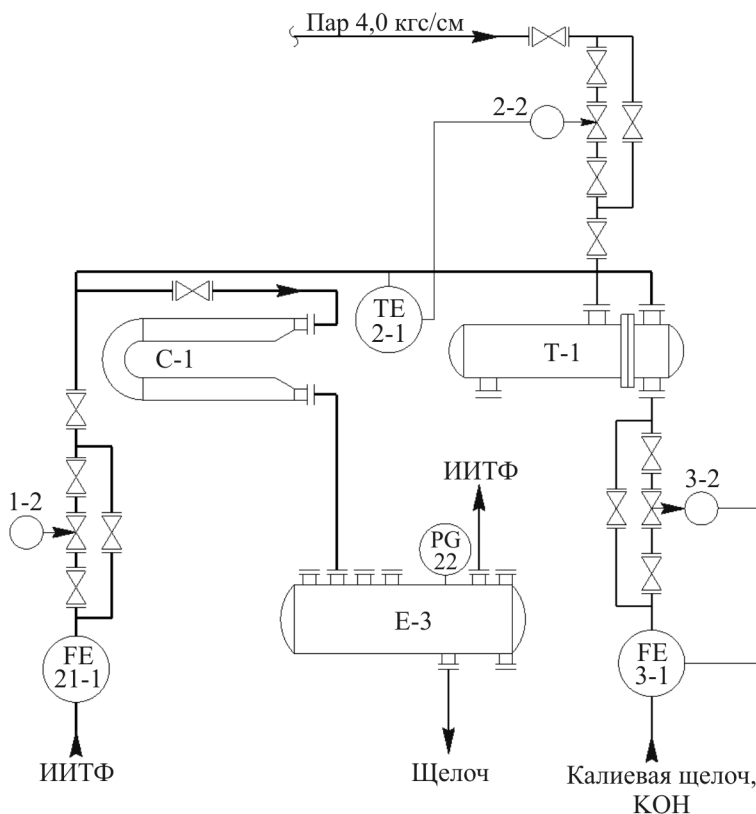


Рис. 1. Узел щелочной отмывки

Температура щелочи ТЕ2-1 после теплообменника Т-1 поддерживается с помощью регулятора температуры 2-2 с регулирующим клапаном, установленным на трубопроводе подачи пара в теплообменник Т-1. Конденсат из теплообменника Т-1 сливается в сборник. Расход щелочи FE3-1 регулируется клапаном 3-2.

Углеводороды со щелочью смешиваются в диафрагменном смесителе С-1, откуда поступают в сосуд Е-3.

Доля щелочи после смесителя С-1 должна быть не менее 13 % и поддерживается подпиткой щелочью регулятором 3-2 в зависимости от расхода FE21-1. Также для более качественной отмывки необходимо регулировать температуру ТЕ2-1 подаваемой в смеситель щелочи регулятором 2-2.

**Разработка виртуального анализатора.** В качестве альтернативного подхода для оценки значений трудноизмеримых параметров технологического процесса предлагается использовать алгоритмы виртуального измерения, на базе которых реализуются так называемые виртуальные анализаторы (ВА).

Виртуальные анализаторы – математические модели, производящие косвенный расчет показателей качества ТП на основе архивных производственных данных и данных лабораторных анализов [3].

На рис. 2 представлена структурная схема виртуального анализатора.




Рис. 2. Структурная схема виртуального анализатора

Виртуальный анализатор, рассчитывающий показатель качества в виде массовой доли щелочи после смесителя С-1, представлен на рис. 3.

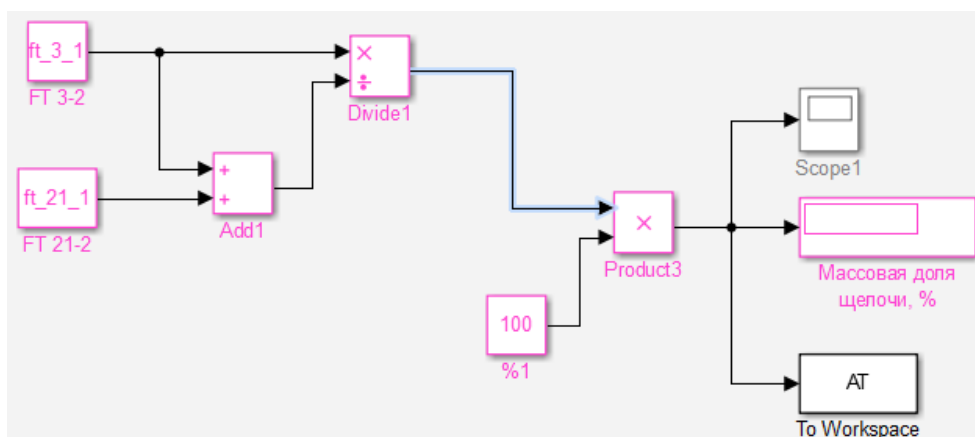


Рис. 3. Виртуальный анализатор, разработанный в среде MATLAB

Разработан виртуальный анализатор в среде Simulink Matlab. Анализатор рассчитывает массовую долю щелочи после смесителя С-1 на основе расхода ИИТФ в смеситель С-1, расхода щелочи в смеситель С-1, а также температуры щелочи, подаваемой в смеситель С-1. В разработанной модели блоки Add1 (сложение), Divide1 (деление), реализуют формулу расчета массовой доли вещества в растворе:

$$\mu = \frac{m_i}{m_{tot}},$$

где  $m_i$  – масса щелочи,  $m_{tot}$  – масса смеси ИИТФ и щелочи.

Блок Product3 умножает на 100 полученную массовую долю щелочи для представления показателя в виде процентов. Блок To Workspace назначает переменной имя, для дальнейшей работы с ней. Блок Scope1 отображает график показателя качества во времени.

На рис. 4 представлен виртуальный анализатор в режиме работы. При минимальных допустимых значениях технологических параметров получили массовую долю щелочи 13,35 % (что соответствует условию: не менее 13 %). Блоки «Расход щелочи», «Расход ИИТФ», «Температура смеси» отображают текущие входные значения параметров FT3-1, FT21-1, TT2-1 соответственно.

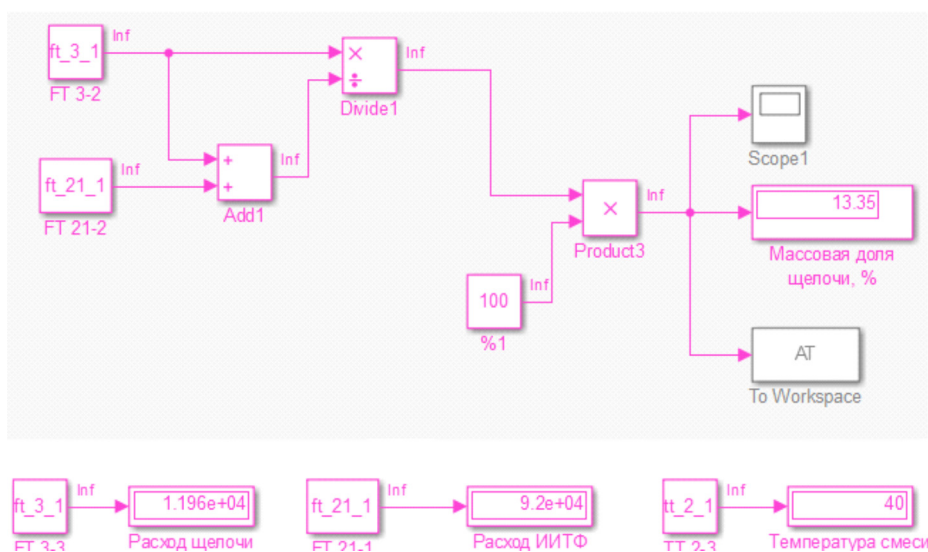


Рис. 4. Виртуальный анализатор, разработанный в среде MATLAB

**Разработка нейронной сети для поддержания качества.** На рис. 5 представлена концептуальная модель нейронной сети для регулирования параметров процесса в зависимости от значения параметра качества технологического процесса, полученного на выходе ВА. На вход нейронной сети подаются значения АТ (показатель качества, массовая доля щелочи после смесителя), расход щелочи FE3-1 в смеситель С-1, температура щелочи ТЕ2-1 в трубопроводе подачи в смеситель С-1. При изменении показателя качества АТ соответственно прямо пропорционально изменяется расход щелочи FE 3-1. Также на качество влияет температура подогреваемой щелочи, при ее изменении изменяется и массовая доля щелочи после смесителя, коэффициент влияния выявлен в ходе лабораторных исследований. На выходе в зависимости от параметров входа необходимо

регулировать степени открытия клапанов 3-2 и 2-2. В табл. 1 приведены входные параметры процесса щелочной отмывки ИИТФ, в табл. 2 – выходные параметры данного процесса.

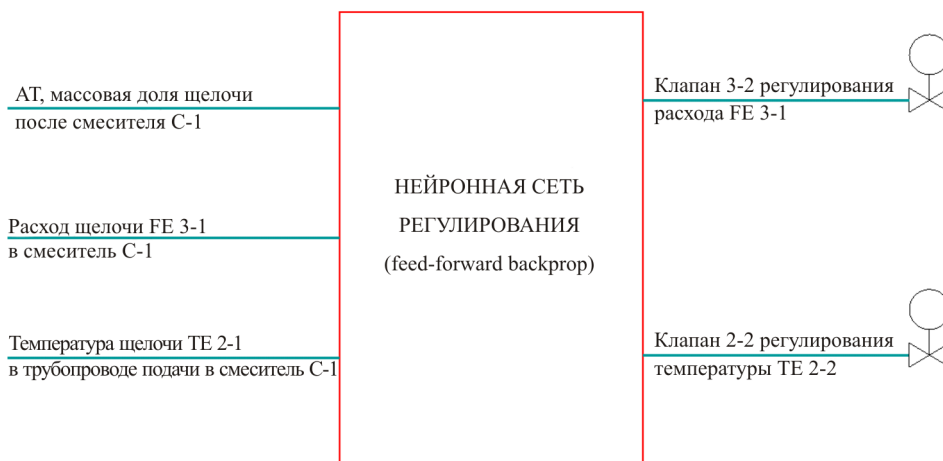


Рис. 5. Концептуальная модель нейронной сети для регулирования технологических параметров

Таблица 1

Входные параметры процесса щелочной отмывки ИИТФ

Позиция	Наименование	Пределы регулирования	Единицы измерения
ТЕ 2-1	Температура подогретой щелочи в трубопроводе подачи в смеситель С-1	40...70	°С
FE 3-1	Расход щелочи в смеситель С-1	11960...102987	кг/ч
АТ	Массовая доля щелочи после смесителя С-1	Не менее 13	%

Таблица 2

Выходные параметры процесса щелочной отмывки ИИТФ

Позиция	Наименование	Пределы регулирования	Единицы измерения
2-2	Регулирующий клапан	0...100	%
3-2	Регулирующий клапан	0...100	%

1. *Разработка нейронной сети.* Для разработки нейронной сети управления параметрами процесса щелочной отмывки ИИТФ в среде MATLAB используются пакеты MATLAB Neural Network Toolbox и Simulink. Существуют несколько типов нейронных сетей, некоторые из них представлены в табл. 3.

Таблица 3

## Типы нейронных сетей

№ п/п	Тип сети	Название сети
1	Competitive	Конкурирующая сеть
2	Cascade-forward backprop	Каскадная сеть с прямым распространением сигнала и обратным распространением ошибки
3	Elman backprop	Сеть Элмана с обратным распространением ошибки
4	Feed-forward backprop	Сеть с прямым распространением сигнала и обратным распространением ошибки
5	Time delay backprop	Сеть с запаздыванием и обратным распространением ошибки
6	Generalized regression	Обобщенная регрессионная сеть
7	Hopfield	Сеть Хопфилда
8	Linear layer (design)	Линейный слой (создание)

Сети, приведенные в табл. 3, имеют следующие особенности:

- для сетей 2, 3, 7 в данной версии интерфейса NNTool не обеспечивается просмотр структурных схем;
- сети 5, 8 допускают введение линий задержек на входе;
- сети 3 допускают введение линий задержек в слое;
- сети с двумя слоями имеют последовательную структуру, когда выход первого слоя служит входом второго слоя. Исключение составляют сети 3, которые допускают наличие обратной связи в первом слое и передачу входного сигнала на входы обоих слоев [4].

Рассмотрим подробнее сеть 4 с прямым распространением сигнала и обратным распространением ошибки (Feed-forward backprop). Для обучения описанной нейронной сети был использован алгоритм обратного распространения ошибки (backpropagation) [5]. Этот метод обучения многослойной нейронной сети называется обобщенным дельта-правилом. Этот алгоритм определяет 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 двигается в обратном направлении, в результате происходит корректировка весовых коэффициентов связей сети. В результате разработки нейронной сети данным методом необходимо, чтобы полученная ошибка обучения была не более  $0,1 \cdot 10^{-3}$ .

Для решения этой задачи выбрана сеть Feed-forward backprop с десятью сигмоидными нейронами скрытого слоя и двумя линейными нейронами выходного слоя. На рис. 6 представлена схема нейронной сети регулирования, где AT, FE3-1, TE2-1 – входные параметры, а сте-



пени открытия клапанов 3-2 и 2-2 – выходные параметры. Алгоритм обучения – Левенберга-Маркардта. С такой конфигурацией сеть после 1000 эпох обучения дала ошибку порядка  $2,761 \cdot 10^{-5}$ , что не выходит за пределы допустимых значений.

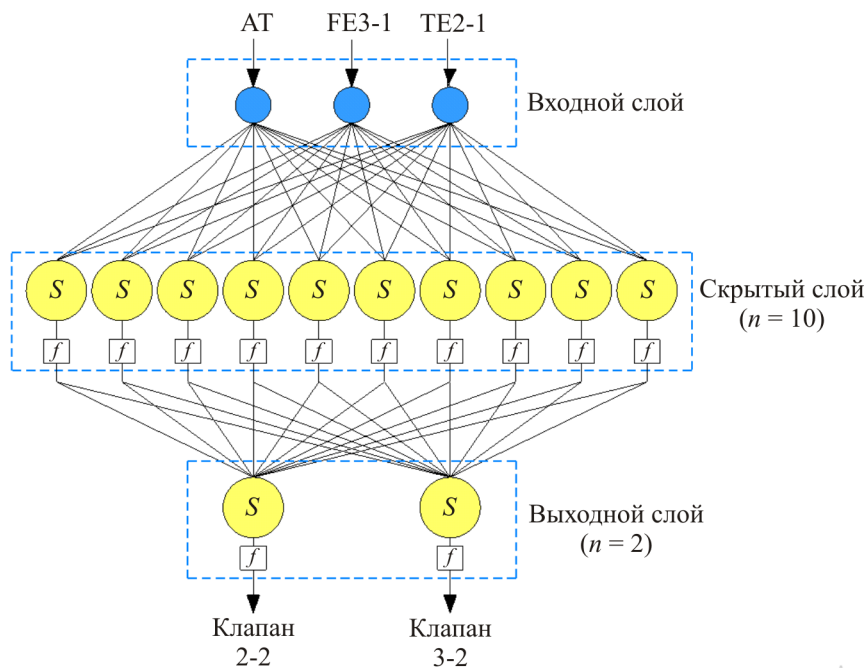


Рис. 6. Концептуальная модель нейронной сети для регулирования технологических параметров

2. *Обработка и подготовка данных.* Используя вышеперечисленные закономерности, создадим таблицу в программе Excel с обучающим набором данных. Она будет состоять из 7000 примеров, представленных в табл. 4.

Таблица 4

Обучающий набор данных

№	FT 3-1, кг/ч	ТТ 2-1, °С	АТ, %	FV 3-2, %	FV 2-2, %
1	11960	40	13,35	10	20
2	11972,89	40,00429	13,36	10,00857	20,00857
	...	...	...	...	...
7000	102187,1	69,99571	52,62	69,99143	79,99143

3. *Выбор типа и архитектуры нейронной сети.* Запустим инструмент nntool, позволяющий в графической среде спроектировать искусственную нейронную сеть.

В открывшемся окне необходимо указать входные и выходные (целевые) значения нейронной сети и спроектировать структуру нейронной сети. Для ввода входных и выходных значений сети необходимо нажать на кнопку Import. Откроется окно Import to Network.

Далее в окне Import to Network выберем импорт из рабочей области MATLAB, в блоке Select a Variable (выбор переменной) необходимо указать входные и желаемые выходные значения сети. В блоке Select a Variable выбираем  $x$ , в блоке Destination (назначение) указываем Input Data (входные данные) и нажимаем кнопку Import. Появится сообщение о добавлении в блок входных данных инструмента NNTool.

В данном случае сеть будет состоять из двух слоев.

Первый шаг – это выбор структуры нейронной сети. Будет использована каскадная сеть с прямым распространением сигнала и обратным распространением ошибки (feed-forward backprop). Далее необходимо выбрать количество нейронов в скрытом слое (10). Зададим входные (input data) и целевые (target data) данные. Обучение сети будет производиться по модифицированному алгоритму оптимизации, направленному на решение задач о наименьших квадратах: Levenberg-Marquardt = 'trainlm' (рис. 7).

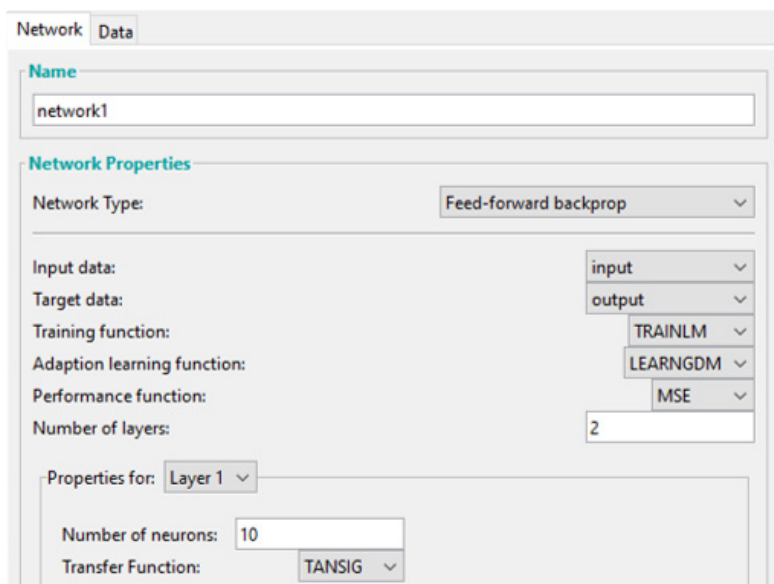


Рис. 7. Окно настройки нейронной сети

4. *Построение и обучение нейронной сети в MATLAB.* Далее реализуем и обучим нейронную сеть в MATLAB. На рис. 8 показана выбранная

структура искусственной нейронной сети. На вход нейронной сети поступает сигнал  $input$ , в проектируемой сети, это значения входных параметров: FT3-1, TT2-1 и АТ. Сумматор «+» умножает каждый вход  $b_i$  на вес  $w_i$  и суммирует взвешенные входы. Затем значение проходит через функцию активации соответствующего слоя и рассчитывается выход: степень открытия клапана 3-2, степень открытия клапана 2-2.




Рис. 8. Нейронная сеть с прямым распространением сигнала и обратным распространением ошибки (feed forward backprop)

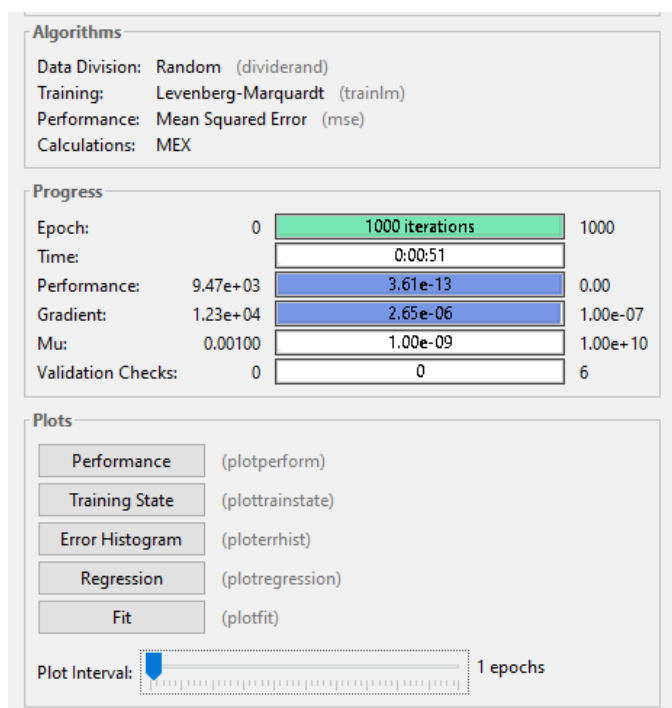


Рис. 9. Окно обучения сети

На рис. 9 показано окно `nntool`, при помощи которого можно получить различные графики (средняя квадратичная ошибка, линейная регрессия, гистограмма ошибок, состояния обучения), характеризую-

щие процесс и качество обучения сети. Как видно, нейросеть прошла все 1000 эпох обучения за 51 с.

В окне процесса обучения сети, нажав на кнопку Performance, можно увидеть график обучения сети, показывающий поведение ошибки обучения (рис. 10).

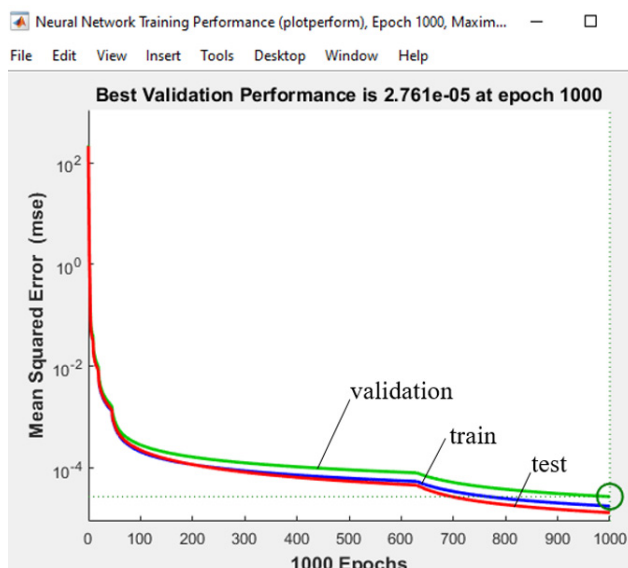


Рис. 10. Средняя квадратичная ошибка

По графику на рис. 10 видно, что и обучающее, и тестовое множества уменьшаются одинаково вплоть до 80 эпохи, а затем с небольшими отклонениями доходят до минимальной ошибки. За 1000 эпох итоговая среднеквадратичная ошибка, достигла значения  $2,761 \cdot 10^{-5}$  и является небольшой, это указывает на идеальное обучение проектируемой сети управления параметрами процесса щелочной отмывки ИИТФ.

Еще одним инструментом оценки результата обучения нейронной сети может быть функция регрессии результатов (рис. 11). График регрессии отображает сетевые прогнозы (выходные данные) в отношении ответов (целевых) для наборов обучения, проверки и тестов.

Для идеального соответствия данные должны располагаться вдоль линии под углом 45 град, где выходные данные сети равны их откликам, на всех четырех графиках корреляции Training, Validation, Test и All данные располагаются вдоль такой линии. Коэффициент корреляции  $R$  для всех четырех графиков равен 1, что говорит о сильной связи между переменными и свидетельствует о точности постро-

енной нейронной сети. Достигается высокая точность построения и большая зависимость переменных.

Перейдем к графикам состояния обучения, изображенным на рис. 12.

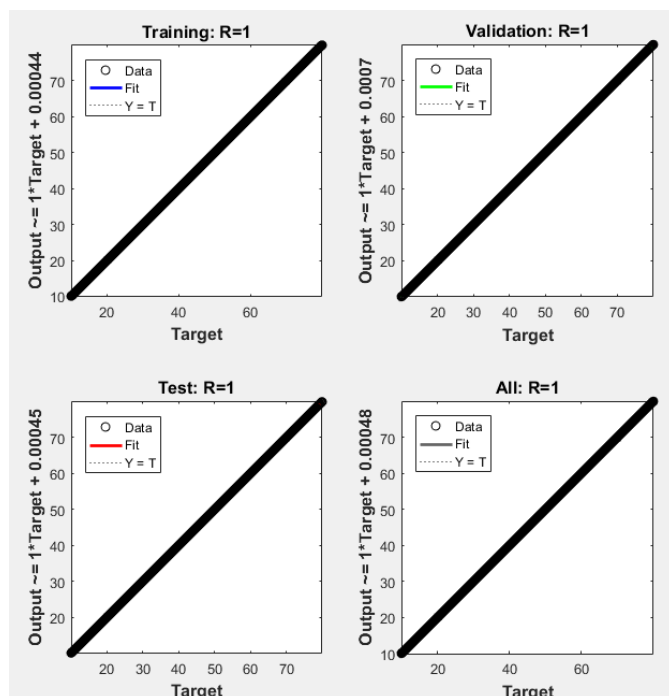


Рис. 11. График линейной регрессии

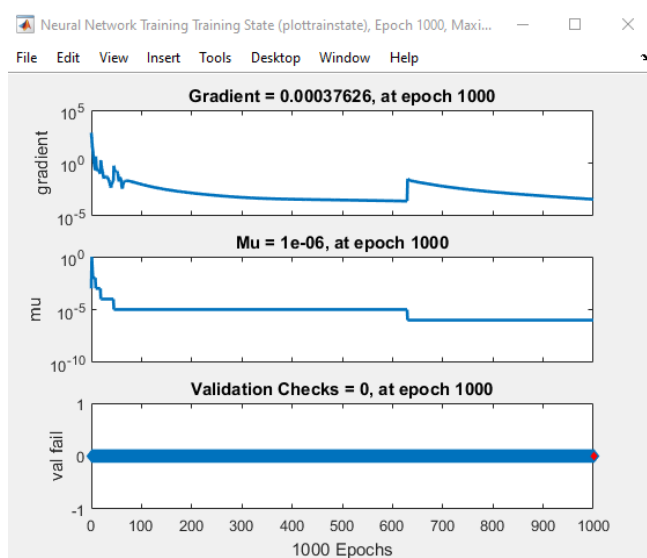


Рис. 12. Графики обучения сети

На графике Gradient видно, что чем ближе значение коэффициента градиента к нулю, тем точнее будет проводиться обучение и тестирование нейронной сети. В данном случае Gradient = 0,00037626, значение минимальное, следовательно, это говорит о более высокой точности обучения. График Mu показывает изменение параметра обучения  $\mu$  методом байесовской регуляризации, и чем ниже данное значение  $\mu$ , тем точнее будет проходить обучение сети. На графиках Mu и Gradient наблюдаются резкие скачки по достижении 620 эпох обучения. Здесь коэффициент градиента достигает своего минимального значения, параметр обучения  $\mu$  максимально приближен к нулю, значит, до 620 эпохи обучения точность и тестирование сети максимально. На графике Validation Checks показано изменение ошибки на контрольном множестве.

5. Проверка нейронной сети. Для тестирования нейронных сетей подадим на вход 3 входных значения (11960; 40; 13,350) соответственно для FT3-1, TT2-1, АТ с помощью вкладки Simulate окна настройки нейросети. В табл. 5 приведены проверочные данные для оценки полученных выходных значений.

Таблица 5

Проверочные данные

Выход		Вход		
VALVE 3-2	VALVE 2-2	FT 3-1	TT 2-1	АТ
10	20	11960	40	13,350
Полученные выходные значения		Проверочные входные значения		
10,0802	20,0802	11960	40	13,350

**Связь виртуального анализатора и нейронной сети.** При помощи команды gensim(net) добавим созданную нейросеть в среду Simulink MATLAB, при помощи мультиплексора Mux назначим на вход блока нейронной сети NNET входные значения, а именно параметры FT3-1, TT2-1 и параметр показателя качества АТ от виртуального анализатора (рис. 13).

После запуска проекта виртуальный анализатор рассчитывает массовую долю щелочи АТ после смесителя С-1, спрогнозированное значение передается на вход нейронной сети вместе с параметрами FT3-1 и TT2-1, на выходе NNET при помощи демультимплексора Demux получим соответствующие выходные значения (степени открытия клапанов 3-2 и 2-2). При входных значениях (11960; 40; 13,35) соответственно для FT3-1, TT2-1, АТ на выходе получены (9,998; 20,01) соответственно для клапанов 3-2 и 2-2.

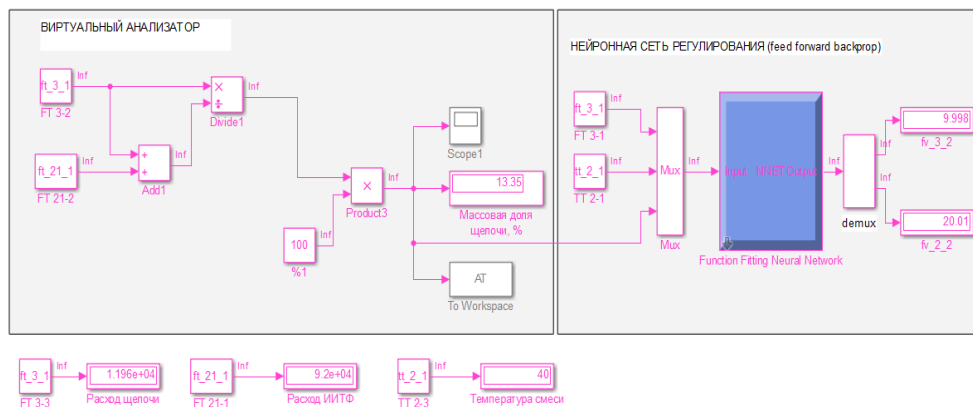


Рис. 13. Виртуальный анализатор и нейросеть

**Закключение.** Таким образом, в ходе проекта были получены следующие основные результаты: обоснована целесообразность разработки виртуального анализатора и нейронной сети для управления технологическим процессом щелочной отмывки изопентан-изопрен-толуольной фракции, разработан виртуальный анализатор, предназначенный для постоянного прогнозирования показателя качества (массовая доля щелочи) ведения процесса щелочной отмывки, для регулирования технологических параметров и поддержания соответствующего качества была разработана нейронная сеть (feed forward backprop) в среде MATLAB.

Виртуальный анализатор непрерывно прогнозирует показатель качества (массовая доля щелочи) щелочной отмывки ИИТФ на основе двух входных параметров: расход щелочи FT3-1 и расход ИИТФ FT21-1. Нейронная сеть позволяет непосредственно регулировать параметры щелочной отмывки для поддержания соответствующего качества на основе трех входных параметров: массовая доля щелочи AT, расход щелочи FT3-1, температура щелочи TT2-1. В результате совокупная работа виртуального анализатора и нейронной сети позволяет повысить качество ведения технологического процесса, а также степень его автоматизации.

### Список литературы

1. Совершенствование организационно-экономического механизма устойчивого развития предприятий синтетического каучука [Электронный ресурс]. – URL: <https://www.dissercat.com/content/sovershenstvovanie-organizatsionno-ekonomicheskogo-mekhanizma-ustoichivogo-razvitiya-predpri> (дата обращения: 18.10.2021).
2. Опыт создания моделей технологических процессов для предприятий нефтехимической промышленности [Электронный ресурс]. – URL: <https://isup.ru/articles/3/7504/> (дата обращения: 18.10.2021).

3. Виртуальные анализаторы [Электронный ресурс]. – URL: <http://rg-optimum.ru/index.php/products/va> (дата обращения: 18.10.2021).
4. GUI-интерфейс для ППП NNT [Электронный ресурс]. – URL: [https://studopedia.ru/15\\_68107\\_GUI-interfeys-dlya-ppp-NNT.html](https://studopedia.ru/15_68107_GUI-interfeys-dlya-ppp-NNT.html) (дата обращения: 18.10.2021).
5. Обучение нейронной сети. Алгоритм обратного распространения ошибки [Электронный ресурс]. – URL: <https://microtechnics.ru/obuchenie-nejronnoj-seti-algoritm-obratnogo-gasprostraneniya-oshibok/> (дата обращения: 18.10.2021).
6. Усков А.А., Кузьмин А.В. Интеллектуальные технологии управления. Искусственные нейронные сети и нечеткая логика. – М.: Горячая линия – Телеком, 2004. – 143 с.
7. Яхьяева Г.Э. Нечеткие множества и нейронные сети: учеб. пособие. – М.: Бином. Лаборатория знаний, 2008. – 316 с.
8. Галушкин А.И. Нейронные сети: основы теории. – М.: ГЛТ, 2010. – 496 с.
9. Галушкин А.И., Цыпкин Я.З. Нейронные сети: история развития теории: учеб. пособие для вузов. – М.: Альянс, 2015. – 840 с.
10. Рутковская Д., Пилиньский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. – М.: РиС, 2013. – 384 с.
11. Ширяев В.И. Финансовые рынки: Нейронные сети, хаос и нелинейная динамика. – М.: КД Либроком, 2016. – 232 с.
12. Редько В.Г. Эволюция, нейронные сети, интеллект: Модели и концепции эволюционной кибернетики. – М.: Ленанд, 2017. – 224 с.
13. Muravyova E.A., Gabitov R.F., Sabanov P.A. Separation process control system in the cement production facility // II International Scientific Conference on Metrological Support of Innovative Technologies. – Krasnoyarsk, 2021. – Vol. 1889. – P. 1–10. DOI: 10.1088/1742-6596/1889/2/022050
14. Muravyova E.A., Gabitov R.F. Development of the intellectual complex for parallel work of steam boilers // II International Scientific Conference on Metrological Support of Innovative Technologies. – Krasnoyarsk, 2021. – Vol. 1889. – P. 1–8. DOI: 10.1088/1742-6596/1889/2/022047
15. Muravyova E.A., Kochenkov A.V. Development of an intelligent control system for the process of preparation and water transfer in the cooling circuit of an ammonia station // Nanotechnologies in Construction. – 2021. – Vol. 13. – P. 252–258. DOI: 10.15828/2075-8545-2021-13-4-252-258

## References

1. Improving the organizational and economic mechanism of sustainable development of synthetic rubber enterprises [Electronic resource] – Access mode: <https://www.dissercat.com/content/sovershenstvovanie-organizatsionno-ekonomicheskogo-mekhanizma-ustoichivogo-razvitiya-predpri> (accessed: 18.10.2021).



2. Experience in creating models of technological processes for petrochemical industry enterprises [Electronic resource]. – Access mode: <https://isup.ru/articles/3/7504/> (accessed: 10/18/2021).
3. Virtual analyzers [Electronic resource]. – Access mode: <http://rg-optimum.ru/index.php/products/va> (accessed: 18.10.2021).
4. GUI interface for the NNT PPP [Electronic resource]. – Access mode: [https://studopedia.ru/15\\_68107\\_GUI-interfeys-dlya-ppp-NNT.html](https://studopedia.ru/15_68107_GUI-interfeys-dlya-ppp-NNT.html) (accessed: 18.10.2021).
5. Neural network training. Algorithm of error back propagation [Electronic resource]. – Access mode: <https://microtechnics.ru/obuchenie-nejronnoj-seti-algoritmobrathn-ogo-rasprostraneniya-oshibok/> (accessed: 18.10.2021).
6. Uskov A.A. Intelligent control technologies. Artificial neural networks and fuzzy logic. / A.A. Uskov, A.V. Kuzmin. – М.: Hotline-Telecom, 2004. – 143 p.
7. Yakhyaeva G.E. Fuzzy sets and neural networks: A textbook / G.E. Yakhyaeva. – М.: Binom. Laboratory of Knowledge, 2008 – 316 p.
8. Galushkin A.I. Neural networks: fundamentals of theory. / A.I. Galushkin. – М.: GLT, 2010. – 496 p.
9. Galushkin A.I. Neural networks: the history of theory development: A textbook for universities / A.I. Galushkin, Ya.Z. Tsyppkin. – М.: Alliance, 2015 – 840 p.
10. Rutkovskaya D. Neural networks, genetic algorithms and fuzzy systems / D. Rutkovskaya, M. Pilinsky, L. Rutkovsky. – М.: RiS, 2013. – 384 p.
11. Shiryaev V.I. Financial markets: Neural networks, chaos and nonlinear dynamics / V.I. Shiryaev. – М.: CD Librocom, 2016. – 232 p.
12. Redko V.G. Evolution, neural networks, intelligence: Models and concepts of evolutionary cybernetics / V.G. Redko. – М.: Lenand, 2017. – 224 p.
13. Muravyova E. A., Gabitov R. F. and Sabanov P. A. Separation process control system in the cement production facility // *II International Scientific Conference on Metrological Support of Innovative Technologies (Krasnoyarsk)*. – 2021. – Vol. 1889. – P. 1-10. DOI: 10.1088/1742-6596/1889/2/022050
14. Muravyova E. A. and Gabitov R. F. Development of the intellectual complex for parallel work of steam boilers // *II International Scientific Conference on Metrological Support of Innovative Technologies (Krasnoyarsk)*. – 2021. – Vol. 1889. – P. 1-8. DOI: 10.1088/1742-6596/1889/2/022047
15. Muravyova E. A. and Kochenkov A. V. Development of an intelligent control system for the process of preparation and water transfer in the cooling circuit of an ammonia station // *Nanotechnologies in Construction*. – 2021. Vol. – 13. – P. 252–258. DOI: 10.15828/2075-8545-2021-13-4-252-258

### Об авторах

**Муравьева Елена Александровна** (Стерлитамак, Россия) – доктор технических наук, профессор, зав.кафедрой «Автоматизированные технологические и информационные системы» филиала ФГБОУ ВО «УГНТУ» (453118, г. Стерлитамак, Проспект Октября., 2; e-mail: muraveva\_ea@mail.ru).

**Казанцев Радмир Валерьевич** (Стерлитамак, Россия) – студент кафедры «Автоматизированные технологические и информационные системы», филиала ФГБОУ ВО «УГНТУ» в г. Стерлитамаке (453118, г. Стерлитамак, Проспект Октября, 2; e-mail: radmiraklo@yandex.ru).

**Подлесский Дмитрий Викторович** (Стерлитамак, Россия) – магистрант кафедры «Автоматизированные технологические и информационные системы», филиала ФГБОУ ВО «УГНТУ» в г. Стерлитамаке (453118, г. Стерлитамак, Проспект Октября, 2; e-mail: radmiraklo@yandex.ru).

### **About the authors**

**Elena A. Muravyeva** (Sterlitamak, Russian Federation) – Doctor of Technical Sciences, Professor, Head of the Department "Automated Technological and Information Systems" of the branch of the Federal State Budgetary Educational Institution "USPTU" (2, October av., Sterlitamak, 453118; e-mail: muraveva\_ea@mail.ru).

**Radmir V. Kazantsev** (Sterlitamak, Russian Federation) – Student of the Department of "Automated Technological and Information Systems", branch of the Federal State Budgetary Educational Institution "USPTU" in Sterlitamak (2, October av., Sterlitamak, 453118; e-mail: radmiraklo@yandex.ru).

**Dmitriy V. Podlesskiy** (Sterlitamak, Russian Federation) – Undergraduate Student of the Department of "Automated Technological and Information Systems", branch of the Federal State Budgetary Educational Institution "USPTU" in Sterlitamak (2, October av., Sterlitamak, 453118; e-mail: radmiraklo@yandex.ru).

Поступила: 25.03.2022

Одобрена: 15.04.2022

Принята к публикации: 26.05.2022

**Финансирование.** Исследование не имело спонсорской поддержки.

**Конфликт интересов.** Авторы заявляют об отсутствии конфликта интересов.

**Вклад авторов** равноценен.

Просьба ссылаться на эту статью в русскоязычных источниках следующим образом:

Муравьева, Е.А. Разработка нейронной сети для управления процессом щелочной отмывки изопетан-изопрен-толуольной фракции с использованием виртуального анализатора / Е.А. Муравьева, Р.В. Казанцев, Д.В. Подлесский // Вестник ПНИПУ. Химическая технология и биотехнология. – 2022. – № 2. – С. 120–137.

Please cite this article in English as:

Muravyova E.A., Kazantsev R.V., Podlesskiy D.V. Development of a neural network for controlling the process of alkaline washing of isopentane-isoprene-toluene fraction using a virtual analyzer. *Bulletin of PNRPU. Chemical Technology and Biotechnology*, 2022, no. 2, pp. 120-137 (In Russ).