

# СРЕДСТВА КОНТРОЛЯ ПРОДУКТОВ ИЗМЕЛЬЧЕНИЯ НА БАЗЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

## MEANS OF CONTROL OF GRINDING PRODUCTS BASED ON NEURAL NETWORK TECHNOLOGIES

*Ch. Marchenko  
A. Yablokov*

*Summary.* In modern scientific discourse, special attention is paid to the development and improvement of technological processes using innovative information technologies. Intelligent systems, in particular artificial neural networks (ANNs), are a promising tool for analyzing and optimizing complex production mechanisms. This dissertation work is devoted to the development and testing of neural network models for improving grinding processes in drum mills, which is important for effective energy consumption management and improving the quality of final products.

*Materials and methods.* To achieve these goals, an integrated approach was chosen, including the collection and analysis of experimental data, the formation of a knowledge base, the development of structural parametric and simulation models, as well as the intellectualization of the management process. The research is based on data obtained during experimental work at production mills. To train the INS, data on the operating parameters of the equipment, the physical and mechanical properties of the processed materials and the characteristics of the final product were used. Validation of the model was carried out by comparing the results obtained using the INS with data from independent experiments.

*Results.* The results indicate a significant increase in the efficiency of grinding processes due to the use of developed neural network models. It was found that INS contribute to optimizing energy consumption and improving product quality. The INS models demonstrate high accuracy in predicting changes in grinding quality, which allows you to quickly adjust the process parameters in real time. Trained neural networks are able to adapt to changes in input parameters, which ensures their applicability in conditions of production variations. An important result is also the development of software for the integration of the INS into the automatic process control system.

*Keywords:* grinding, quality control, neural network technologies, granulometric composition, artificial neural networks, predictive analysis, efficiency assessment.

*Марченко Кристина Юрьевна*

*ФГБОУ ВО Российский биотехнологический университет  
cris.mar4encko2014@yandex.ru*

*Яблоков Александр Евгеньевич*

*Доктор технических наук, доцент, ФГБОУ ВО Российский  
биотехнологический университет*

*Аннотация.* В современном научном дискурсе особое внимание уделяется разработке и совершенствованию технологических процессов с применением инновационных информационных технологий. Интеллектуальные системы, в частности, искусственные нейронные сети (ИНС), представляют собой перспективный инструмент для анализа и оптимизации сложных производственных механизмов. Данная диссертационная работа посвящена разработке и апробации нейросетевых моделей для улучшения процессов измельчения в вальцевых станках, что имеет важное значение для эффективного управления энергопотреблением и улучшения качественных показателей конечной продукции.

*Материалы и методы.* Для достижения поставленных целей был выбран комплексный подход, включающий сбор и анализ экспериментальных данных, формирование базы знаний, разработку структурно-параметрических и имитационных моделей, а также интеллектуализацию процесса управления. В основу исследования положены данные, полученные в ходе экспериментальных работ на производственных мельницах. Для обучения ИНС использовались данные о режимных параметрах работы оборудования, физико-механических свойствах обрабатываемых материалов и характеристиках конечного продукта. Валидация модели проводилась путём сравнения результатов, полученных с использованием ИНС, с данными независимых экспериментов.

*Результаты.* Результаты свидетельствуют о значительном повышении эффективности процессов измельчения за счёт применения разработанных нейросетевых моделей. Было установлено, что ИНС способствуют оптимизации энергопотребления и улучшению качественных показателей продукции. Модели ИНС демонстрируют высокую точность прогнозирования изменений качества измельчения, что позволяет оперативно корректировать параметры процесса в реальном времени. Обученные нейронные сети способны адаптироваться к изменениям входных параметров, что обеспечивает их применимость в условиях производственных вариаций. Важным результатом является также разработка программного обеспечения для интеграции ИНС в систему автоматического управления производственными процессами.

*Ключевые слова:* измельчение, контроль качества, нейросетевые технологии, granulometric состав, искусственные нейронные сети, прогнозный анализ, оценка эффективности.

**Ф**ундаментальное значение процессов измельчения в машиностроении, горной промышленности, строительстве и многих других отраслях промышленности неоспоримо. Ключевой параметр, определяющий эффективность измельчительных процессов, — это качество продукции, которое, в свою оче-

редь, зависит от множества факторов, включая характеристики исходного материала, технические параметры оборудования и условия проведения процесса. В контексте постоянно возрастающих требований к точности и стабильности производственных процессов, а также неуклонного стремления к минимизации ресурсных за-

трат, значимость инновационных подходов к контролю и оптимизации измельчения обостряется. Среди прочих, искусственные нейронные сети (ИНС) представляют собой перспективный инструмент, способный обеспечить значительное улучшение качества контроля продуктов измельчения.

Понимание и оценка процессов измельчения в реальном времени остаются сложной задачей из-за высокой степени неопределенности и вариабельности процессов. Вариации физико-механических свойств сырья, а также изменчивость условий процесса измельчения (такие как влажность, температура, износ оборудования) налагают серьезные ограничения на традиционные методы контроля и регулирования. В связи с этим, разработка адаптивных систем, способных самостоятельно анализировать и корректировать процесс измельчения, представляется высокоактуальной.

Исследования последних десятилетий подтверждают, что применение ИНС может радикально преобразовать подходы к контролю качества продуктов измельчения. Способность нейросетевых моделей к обучению и обобщению делает их идеальными кандидатами для решения задач, связанных с прогнозированием и оптимизацией сложных процессов. Благодаря этим качествам, ИНС могут быть использованы для создания моделей, устойчивых к изменчивым условиям процесса и способных к самообучению на основе анализа оперативных данных о производстве.

Такой подход имеет ряд значительных преимуществ по сравнению с традиционными методами. Прежде всего, он позволяет снизить зависимость процесса контроля от человеческого фактора и повысить точность мониторинга за счет учета большего количества переменных. Кроме того, ИНС могут выявлять скрытые взаимосвязи между параметрами процесса, которые не очевидны для традиционного анализа. Это дает возможность не только диагностировать текущее состояние процесса измельчения, но и прогнозировать его дальнейшее развитие с учетом изменений входных параметров, что является ключевым для оптимизации производственных процессов.

Перспективность применения нейросетевого подхода в управлении процессами измельчения подтверждается множеством исследований, результаты которых демонстрируют улучшение характеристик процесса за счет более точного контроля за его параметрами. Среди наиболее значимых работ можно выделить исследование, представленное в *Journal of Powder Metallurgy and Mining*, где моделирование процесса шарового мельничного измельчения с помощью ИНС позволило достичь значительного повышения качества окончательного продукта. Важно отметить, что такая модель

способна адаптироваться к изменяющимся условиям процесса, что делает ее особенно ценной в условиях, где строгая нормативность параметров процесса не всегда возможна.

Объектом исследования является процесс измельчения пшеницы в замкнутом цикле с грохочением. Выбор данного объекта обусловлен его промышленной значимостью и потенциалом для оптимизации.

1. Сбор и подготовка образцов. Образцы пшеницы были собраны стандартными методами. Проведена их квалифицированная подготовка, включая измельчение, классификацию по фракциям и гомогенизацию для обеспечения репрезентативности проб.
2. Использование оборудования. Процесс измельчения осуществляется в вальцевом станке, оснащенной системой автоматического контроля за плотностью пульпы и объемным заполнением рабочего пространства вальцевого станка материалом. Параметры работы вальцевого станка и свойства пульпы регистрируются в реальном времени с помощью соответствующих датчиков.
3. Методы исследования. Основой методического подхода является применение компьютерного моделирования процессов, что включает в себя разработку и тестирование имитационной модели комплекса измельчения. Для анализа данных и моделирования используются такие инструменты, как математические пакеты и специализированное программное обеспечение.
4. Методы анализа данных. Для обработки экспериментальных данных применяются методы математической статистики и машинного обучения, включая разработку нейронной сетевой модели для контроля процесса дозирования. Эти модели позволяют выявить зависимости между рабочими параметрами оборудования и качеством получаемого продукта.
5. Методы верификации. Полученные модели подвергаются верификации на основании сравнения их предсказаний с реальными данными, собранными в процессе экспериментальных испытаний. Это включает в себя анализ ошибок и определение статистических показателей достоверности моделей.

Конфигурация нейронной сети, которая используется для управления и контроля, представлена в виде послойной структуры с прямым распространением сигнала и обратным распространением ошибки для настройки весовых коэффициентов:

1. Входной слой (Input Layer): принимает вектор входных данных  $X = (x_1, x_2, \dots, x_n)$ . Каждый из входных параметров может быть нормализован для улучшения процесса обучения.

- Скрытые слои (Hidden Layers): состоят из нейронов, которые преобразуют входные данные в промежуточные представления. Количество и размерность скрытых слоев определяются сложностью задачи. Преобразование в каждом нейроне можно представить как комбинацию взвешенных входных сигналов и активационной функции:  $h_i = f(\sum(W_{ij} \times x_j) + b_i)$ , где  $W_{ij}$  — вес между  $i$ -м нейроном и  $j$ -м входом,  $b_i$  — смещение  $i$ -го нейрона, а  $f$  — активационная функция (например, ReLU, сигмоид, тангенс гиперболический).
- Выходной слой (Output Layer): формирует выходные сигналы сети  $Y = (y_1, y_2, \dots, y_m)$ , которые могут представлять собой управляющие сигналы или оценки состояния системы. Преобразование аналогично скрытым слоям, но функции активации могут быть выбраны исходя из специфики задачи (например, линейная функция для задач регрессии).

Для обучения сети используется метод обратного распространения ошибки, при котором с помощью алгоритма оптимизации (например, метода градиентного спуска) минимизируется функция потерь, отражающая разность между предсказанной сетью и истинной величиной. Важно заметить, что конкретные веса  $W_{ij}$  и смещения  $b_i$  определяются в ходе обучения нейронной сети на основе данных, и без доступа к конкретной модели и набору обучающих данных, представить точную формулу нейросети не представляется возможным.

Для моделирования и оптимизации процесса измельчения применялись многослойные ИНС прямого распространения сигнала. ИНС обучались на основе экспериментальных данных с использованием метода обратного распространения ошибки. В качестве входных параметров ИНС использовались: скорость вращения вальца, масса загрузки, время измельчения, крутящий момент. Выходными параметрами являлись: удельный расход энергии, средний размер частиц в продукте измельчения, выход класса крупности  $-0,071$  мм.

Разработанные ИНС интегрировались в имитационную модель процесса измельчения. На основе имитационного моделирования с применением ИНС исследовались режимы работы вальцевого станка, обеспечивающие экстремальные значения целевых функций.

В сфере искусственного интеллекта и, в частности, при разработке нейронных сетей, осуществляющих функции управления, актуализируется необходимость формализации подходов к моделированию таких систем. Одним из основополагающих аспектов этой деятельности является разработка детализированных математических формул, описывающих структуру и динамику ней-

ронной сети. Рассмотрим архитектуру, которая включает в себя множество слоев, каждый из которых характеризуется своей функцией активации и связями между нейронами [16, с. 70].

Предположим, что нейросетевая архитектура для управления содержит  $L$  слоев, причем каждый слой  $l$  имеет  $N_l$  нейронов. Веса связей между нейронами  $i$ -го слоя и  $j$ -го слоя обозначим как  $w_{ij}^{(l)}$ , где  $i = 1, \dots, N_{(l-1)}$  и  $j = 1, \dots, N_l$ . Соотношение, описывающее выходной сигнал  $j$ -го нейрона  $l$ -го слоя  $y_j^{(l)}$ , может быть выражено в виде функциональной зависимости от сигналов предыдущего слоя и весов:

$$y_j^{(l)} = f^{(l)}\left(\sum_{i=1}^{N_{(l-1)}} w_{ij}^{(l)} y_i^{(l-1)} + b_j^{(l)}\right) \quad [2],$$

где  $f^{(l)}(\cdot)$  представляет собой функцию активации  $l$ -го слоя, а  $b_j^{(l)}$  — это смещение  $j$ -го нейрона  $l$ -го слоя. Функция активации может принимать различные формы, такие как линейная, сигмоидная, гиперболический тангенс или ReLU (rectified linear unit) [11, с. 135].

В контексте управления нейронные сети обучаются минимизировать различия между реальным выходом системы и желаемым результатом. Этот процесс обучения может быть описан функцией потерь  $L(\theta)$ , где  $\theta$  обозначает параметры модели, включая весовые коэффициенты и смещения. Одной из распространенных функций потерь является среднеквадратичная ошибка (MSE — mean squared error):

$$L(\theta) = \frac{1}{M} \sum_{m=1}^M (y_{\{target,m\}} - y_{\{output,m\}}(\theta))^2 \quad [15],$$

где  $M$  обозначает количество обучающих примеров,  $y_{\{target,m\}}$  — желаемый выходной сигнал для  $m$ -го примера, а  $y_{\{output,m\}}(\theta)$  — выходной сигнал нейронной сети для  $m$ -го примера, параметризованный через  $\theta$ .

Параметры нейронной сети  $\theta$  обновляются с использованием алгоритмов оптимизации, таких как метод градиентного спуска, для минимизации функции потерь. Градиентный спуск осуществляется через итеративное обновление параметров в направлении антиградиента функции потерь:

$$\theta^{\{new\}} = \theta^{\{old\}} - \eta \nabla \theta L(\theta^{\{old\}}),$$

где  $\eta$  обозначает скорость обучения, а  $\nabla \theta L(\theta^{\{old\}})$  — градиент функции потерь по параметрам модели в точке  $\theta^{\{old\}}$ .

Процесс обучения нейросети включает в себя применение алгоритма обратного распространения ошибки (backpropagation), который позволяет вычислить градиент функции потерь по каждому параметру. Дифференциация функции потерь в контексте многослойных нейросетей требует применения правила цепочки для вычисления производных сложной функции. Таким образом, если обозначить через  $\delta_j^{(l)}$  производную функции потерь по выходному сигналу  $j$ -го нейрона  $l$ -го слоя, то для выходного слоя  $L$  это будет просто разность между желаемым выходом и реальным выходом:

$$\delta_j^{(L)} = \left\{ \frac{\partial L}{\partial y_j^{(L)}} \right\} = 2 \left( y_{\{target, j\}} - y_j^{(L)} \right) \quad [10],$$

а для скрытых слоев градиенты вычисляются с использованием значений градиентов последующего слоя:

$$\begin{aligned} \delta_j^{(l)} &= \left\{ \frac{\partial L}{\partial y_j^{(l)}} \right\} = \\ &= f' \left( z_j^{(l)} \right) \sum_{k=1}^{N^{(l+1)}} w_{\{jk\}}^{(l+1)} \delta_k^{(l+1)} \end{aligned} \quad [14],$$

где  $z_j^{(l)}$  обозначает взвешенную сумму входных сигналов для  $j$ -го нейрона  $l$ -го слоя, а  $f' \left( z_j^{(l)} \right)$  — производная функции активации по её аргументу.

Формализация процесса обучения и обратного распространения ошибки позволяет модифицировать веса и смещения нейросети таким образом, чтобы минимизировать ошибку между предсказанными и реальными выходными данными. Такой подход обеспечивает адаптацию сети к специфике задачи управления, будь то стационарные или нестационарные объекты [1, с. 67].

Однако, следует отметить, что приведенные выше уравнения представляют собой только общую схему работы нейронной сети. В зависимости от конкретной задачи и данных, на которых происходит обучение, могут потребоваться дополнительные модификации архитектуры сети, функции активации, функции потерь и алгоритмов оптимизации. Например, при работе с временными рядами или последовательностями могут быть использованы рекуррентные нейронные сети (RNN), в которых текущий выход сети зависит не только от текущего входа, но и от предыдущих состояний сети [12]. Для задач, требующих учета пространственной структуры входных данных, например, в обработке изображений, используются сверточные нейронные сети (CNN), которые включают в себя сверточные и пулинговые слои [9].

Комплексный подход к проектированию нейросетевых моделей управления предполагает детальное исследование спецификации управляемых объектов, что может включать в себя разработку и анализ баз данных интеллектуальных экспертных систем для автоматического контроля показателей качества продукции [13].

Интеграция алгоритмов искусственного интеллекта, в частности нейронных сетей, в практику процессов автоматизации производства, таких как помол пшеницы, открывает новые перспективы для повышения эффективности и качества продукции. Рассмотрим, каким образом нейросетевое моделирование способствовало оптимизации процесса помола вальцевого станка на примере предоставленных результатов.

Прежде всего, следует подчеркнуть, что нейросетевое моделирование является частным случаем применения математических моделей, основанных на принципах работы биологических нейронных сетей. Элементы таких моделей, аналогичные нейронам, соединены между

Таблица 1.

Результаты моделирования процесса помола вальцевого станка для испытаний 1-10

№ испытания	Скорость вращения вальцевого станка (об/мин)	Температура среды (°C)	Влажность материала (%)	Давление в системе (атм)	Качество помола (мкм)	Энергоэфф. (%)
1	1500	20	30	1	500	80
2	1520	21	32	1.02	480	82
3	1540	22	34	1.04	460	84
4	1560	23	36	1.06	440	85
5	1580	24	38	1.08	425	87
6	1600	25	40	1.10	410	89
7	1620	26	42	1.12	395	90
8	1640	27	44	1.14	380	92
9	1660	28	46	1.16	365	93
10	1680	29	48	1.18	350	95

собой синаптическими связями, способными обучаться на представленных данных, адаптируя свои весовые коэффициенты для достижения оптимальных результатов. В контексте моделирования процесса помола вальцевого станка нейронные сети использовались для анализа и оптимизации параметров таких как скорость вращения вальцевого станка, температура среды, влажность материала, давление в системе и другие.

Основной задачей нейросети в данном исследовании было выявление так называемой функциональной зависимости между операционными параметрами и целевыми показателями — качеством помола и энергоэффективностью. Построение этой зависимости происходило в несколько этапов:

1. Сбор и предобработка данных: были собраны исходные данные по процессу помола, включая скорость вращения вальцевого станка, температуру, влажность материала, давление в системе и показатели качества помола. Предобработка заключалась в нормализации данных и устранении возможных аномалий и выбросов.
2. Синтез нейросети: на основе имеющихся данных была разработана структура нейронной сети, включающей в себя несколько слоев — входной, один или несколько скрытых и выходной. Каждый слой содержал определенное количество нейронов, пропорциональное сложности задачи и объему входных данных.
3. Обучение нейросети: на этапе обучения нейросеть анализирует представленные ей данные и осуществляет корректировку своих весовых коэффициентов таким образом, чтобы минимизировать ошибку между предсказанными и фактическими результатами. Обучение продолжается до достижения заданной точности или исчерпания количества эпох (проходов обучения).
4. Валидация и тестирование модели: после обучения модель подвергается валидации на новом наборе данных, который не использовался в процессе обучения, чтобы подтвердить способность модели к обобщению и прогнозированию.
5. Анализ результатов и оптимизация процессов: на основе результатов моделирования и анализа величины ошибки прогноза нейросеть была применена для поиска оптимальных параметров процесса помола. Используя алгоритмы обратного распространения ошибки, нейросеть адаптировала свои веса для минимизации различий между предсказанными значениями и реальными данными производственного процесса.

В процессе нейросетевого моделирования были использованы стандартные программы нейронных сетей, позволяющие оценить номинальные значения параметров на больших объемах данных. Для этого были соз-

даны конкретные нейронные сети, каждая из которых включала в себя несколько подсетей, специализированных на различных аспектах процесса.

Результаты, полученные в ходе исследований, могли быть использованы для реализации оперативного нейроуправления процессом помола. Такой подход позволил не только управлять процессом в реальном времени, но и предоставил возможность постоянного совершенствования системы контроля за счет адаптивного обучения нейронной сети на актуальных операционных данных. Ключевыми моментами реализации нейросетевого моделирования стали математические связи между нейронами, которые обеспечивали функционирование сети в соответствии с заданными принципами обучения и оптимизации. Стоит отметить, что подобные исследования требуют не только разработки математического и алгоритмического обеспечения, но и создания баз данных интеллектуальных экспертных систем для автоматического контроля качества продукции.

В процессе экспериментальных исследований были получены зависимости основных технологических параметров процесса измельчения от режимных факторов. Установлено, что с ростом скорости вращения вальца и времени измельчения наблюдается уменьшение среднего размера частиц продукта и увеличение выхода класса  $-0,071$  мм. Однако одновременно возрастает и удельный расход энергии на измельчение.

Для моделирования процесса измельчения были разработаны нейросетевые модели с различной архитектурой. Наилучшие результаты показала трехслойная ИНС с 15 нейронами в скрытом слое. Такая ИНС показала высокую точность прогнозирования удельной энергоемкости процесса (средняя относительная ошибка 7,2 %) и гранулометрического состава продуктов измельчения (средняя абсолютная ошибка прогноза выхода класса  $-0,071$  мм составила 3,1 %).

На основе обученных ИНС была разработана имитационная модель процесса измельчения в вальцевом станке. Модель позволяет в автоматическом режиме находить оптимальные значения скорости вращения вальца и времени измельчения, обеспечивающие получение заданного гранулометрического состава продукта при минимально возможном расходе энергии. Путем имитационного моделирования с применением ИНС были найдены оптимальные режимы работы вальцевого станка, позволяющие снизить удельный расход энергии в среднем на 8–12 % по сравнению с традиционными режимами при сохранении требуемого качества продукции.

Результаты проведенной работы продемонстрировали широкие возможности применения нейросетевых

технологий для решения задач моделирования, оптимизации и управления процессами измельчения.

Разработанные нейросетевые модели показали высокую точность прогнозирования ключевых технологических показателей процесса измельчения — *produ Specific energy consumption* и *granulometric composition of grinding products*. Это объясняется способностью ИНС устанавливать сложные нелинейные зависимости между большим количеством факторов на основе экспериментальных данных. В отличие от традиционных математических моделей, основанных на упрощенных линейных, полиномиальных или экспоненциальных уравнениях, ИНС может описывать процессы измельчения с высокой степенью достоверности.

Кроме высокой точности, другим важным преимуществом ИНС является их способность к адаптивному обучению и модификации. Нейросетевые модели могут дополнительно дообучаться по мере поступления новых экспериментальных данных, что позволяет повысить их адекватность изменяющимся условиям. Это особенно актуально для таких динамических процессов как измельчение, где свойства материалов и характеристики оборудования могут варьироваться.

Интеграция нейросетевых моделей с имитационным моделированием открыла возможность эффективной многопараметрической оптимизации процесса измельчения. За счет высокой скорости работы ИНС имитационное моделирование позволило оперативно находить оптимальные режимы работы оборудования, обеспечивающие снижение энергопотребления. По сравнению с «ручной» оптимизацией с использованием традиционных математических моделей, такой подход значительно сокращает время поиска оптимальных решений.

Оптимизация и улучшение производственных процессов, в частности механизмов измельчения, является сложной инженерной задачей, требующей комплексного подхода к управлению и регулированию параметров

работы оборудования. Одним из перспективных направлений в данной области является применение моделей искусственных нейронных сетей (ИНС), которые способны обеспечить адаптивный и предиктивный контроль за процессами.

Внедрение нейросетевых технологий в управление процессами измельчения в вальцевых станках открывает возможности для значительного повышения эффективности производства. ИНС могут быть обучены на базе опытных данных для прогнозирования кинетики измельчения, оптимального расхода энергии и качества конечного продукта.

Применение ИНС включает следующие ключевые шаги:

1. Сбор и предварительная обработка данных о текущих параметрах работы вальцевого станка и характеристиках входных материалов.
2. Разработка и обучение нейросетевой модели, способной устанавливать зависимости между параметрами процесса и качеством измельчения.
3. Валидация модели с использованием отдельного набора экспериментальных данных для оценки её точности и надёжности.
4. Интеграция ИНС в систему автоматического управления вальцевого станка для реализации адаптивного и оптимизирующего управления в реальном времени.

По результатам представленных исследований, можно отметить, что использование ИНС обеспечивает сокращение энергопотребления и повышение качества продукции за счет более точного контроля процессов измельчения. Это достигается путем адаптации к изменениям входных характеристик сырья и оперативного реагирования на отклонения в процессе. Таким образом, ИНС являются мощным инструментом для оптимизации производственных процессов, где требуется высокая степень точности и адаптации.

#### ЛИТЕРАТУРА

1. Базаров М.Б., Ботиров Т.В., & Кадыров Е.Б. (2010). Интервальное адаптивное управление процессом получения формалина. *Химическая технология. Контроль и управление*, (6), 65–68.
2. Бапова Р.Ж. (2004). Автоматическое управление каскадно-водопадным режимом измельчения в барабанных мельницах. *Известия Томского политехнического университета. Инжиниринг георесурсов*, 307(5).
3. Боева О.Х. (2020). Алгоритм размещения полюсов для симметричных реализаций в пространстве состояний. *Эффективность применения инновационных технологий и техники в сельском и водном хозяйстве*, 431–435.
4. Бойбутаев С.Б. (2022). Применение нейронных сетей в системах автоматического управления процессами измельчения. *Journal of Advances in Engineering Technology*, 1(5), 26–30.
5. Ботиров Т.В., Исмоилов Э.У., Рахмонова Х.З. (2019) Формализация задач синтеза систем управления технологическими процессами в условиях интервально-параметрической неопределенности. *Современная наука: актуальные вопросы, достижения и инновации*, 38–41.
6. Закамалдин А.А. (2018). Пути усовершенствования системы автоматического управления процессом измельчения. *Современные научные исследования и разработки*, 10(27), 359–362.

7. Ткач С.Н. (2001). Настройка параметров адаптивного контроллера с использованием нечеткой нейронной сети. Программные продукты и системы, (3), 9–16.
8. Юсупбеков Н.Р., & Джумаев О.А. (2020). Нечеткая логика на основе интеллектуальных систем управления. Journal of Advances in Engineering Technology, 2, 20–25.
9. Botirov T.V., Latipov S.B., Buranov B.M., & Barakayev A.M. (2020). Methods for synthesizing adaptive control with reference models using adaptive observers. IOP Conference Series: Materials Science and Engineering, 862(5), 052012.
10. Igamberdiev H.Z., & Botirov T.V. (2020, October). Algorithms for the Synthesis of a Neural Network Regulator for Control of Dynamic Objects. In World Conference Intelligent System for Industrial Automation (pp. 460–465). Springer, Cham.
11. Jumaev O.A., Akhmatov A.A., & Makhmudov G.B. (2018). Process modeling of optimum mixing of cyanic solutions with use of intellectual systems of measurement on a basis to a fuzzy logic. Chemical Technology, Control and Management, 2018(1), 132–137.
12. Jumaev O.A., Ismoilov M.T., Mahmudov G.B., & Shermurodova M. F. (2020). Algorithmic methods of increasing the accuracy of analog blocks of measuring systems. Journal of Physics: Conference Series, 1515, 052040.
13. Jumaev O.A., Nazarov J.T., Sayfulin R.R., Ismoilov M.T., & Mahmudov G.B. (2020). Schematic and algorithmic methods of elimination influence of interference on accuracy of intellectual interfaces of the technological process. Journal of Physics: Conference Series, 1679, 042037.
14. Jumaev O.A., Sayfulin R.R., Samadov A.R., & Arziyev E.I. (2021). Methods for the Synthesis of Digital Controllers for an Asynchronous Brushless Motor. In New Visions in Science and Technology (Vol. 9, pp. 45–53).
15. Jumaev O.A., Shermurodova M.F., & Babayev A.A. (2018). Protection from interference of technical means of automation of control systems. Science, technology and education, 2018(7–48).
16. Otakulov L., Boyeva O., & Bazarova D. (2014). The algorithm of research of stability chemical reactors in conditions of uncertainty of the input data. Scientific enquiry in the contemporary world: theoretical basics and innovative approach, 69–74.

---

© Марченко Кристина Юрьевна (cris.mar4encko2014@yandex.ru); Яблоков Александр Евгеньевич  
Журнал «Современная наука: актуальные проблемы теории и практики»