

СТАРООСКОЛЬСКИЙ ТЕХНОЛОГИЧЕСКИХ ИНСТИТУТ ИМ. А. А. УГАРОВА
(филиал) федерального государственного автономное образовательное учреждение высшего
образования «Национальный исследовательский технологический университет «МИСиС»
(СТИ НИТУ «МИСиС»))

На правах рукописи

ЦЫГАНКОВ ЮРИЙ АЛЕКСАНДРОВИЧ

**РАЗРАБОТКА МЕТОДИКИ ГИБРИДНОГО
НЕЙРОСЕТЕВОГО ПРОГНОЗИРОВАНИЯ СОДЕРЖАНИЯ
ЖЕЛЕЗА ДЛЯ СОВЕРШЕНСТВОВАНИЯ АСУ ТП
ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТРАТА**

Специальность 05.13.06 – «Автоматизация и управление технологическими
процессами и производствами» (промышленность)

ДИССЕРТАЦИЯ
диссертации на соискание ученой степени
кандидата технических наук

НАУЧНЫЙ РУКОВОДИТЕЛЬ
доктор технических наук, профессор,
почетный работник высшего профессионального образования РФ

Еременко Юрий Иванович

НАУЧНЫЙ КОНСУЛЬТАНТ
кандидат технических наук, доцент,
Полещенко Дмитрий Александрович

Старый Оскол – 2021

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	5
ГЛАВА 1. АНАЛИЗ СУЩЕСТВУЮЩИХ ПРОБЛЕМ И МЕТОДОВ РЕШЕНИЯ ЗАДАЧИ АВТОМАТИЗИРОВАННОГО УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМ ПРОЦЕССОМ ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТРАТА.....	15
1.1. ОПИСАНИЕ ТЕХНОЛОГИЧЕСКОГО ПРОЦЕССА ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТРАТА	15
1.1.1. ТЕХНОЛОГИЧЕСКИЙ ПРОЦЕСС ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТРАТА КАК ОБЪЕКТ АВТОМАТИЗАЦИИ. АНАЛИЗ СУЩЕСТВУЮЩИХ ПРОБЛЕМ И НЕДОСТАТКОВ.....	27
1.2. АНАЛИЗ НЕДОСТАТКОВ СУЩЕСТВУЮЩИХ АЛГОРИТМОВ УПРАВЛЕНИЯ. ОЦЕНКА ПЕРСПЕКТИВНОСТИ ИСПОЛЬЗОВАНИЯ ПРОГНОЗНОГО ПОДХОДА.....	37
1.3. АНАЛИЗ СПОСОБА УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМИ ОБЪЕКТАМИ С ПРИМЕНЕНИЕМ АРС-СИСТЕМ	41
1.3.1. ПОДХОД К ПОСТРОЕНИЮ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ ПРОЦЕССА ИЗМЕЛЬЧЕНИЯ НА ОСНОВЕ ОПИСАНИЯ ФИЗИЧЕСКИХ ПРИНЦИПОВ ФУНКЦИОНИРОВАНИЯ	47
1.3.2. ПОДХОД К ПОСТРОЕНИЮ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ НА ОСНОВЕ АППАРАТА ЛИНЕЙНЫХ ПЕРЕДАТОЧНЫХ ЗВЕНЬЕВ.....	54
1.3.3. ПОДХОД К ПОСТРОЕНИЮ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ НА ОСНОВЕ АППАРАТА РЕГРЕССИОННОГО АНАЛИЗА	59
1.4. АНАЛИЗ ВОЗМОЖНОСТИ ИСПОЛЬЗОВАНИЯ АППАРАТА ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ (ИНС) ДЛЯ РАЗРАБОТКИ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ	63

ВЫВОДЫ ПО ГЛАВЕ 1	69
ГЛАВА 2. РАЗРАБОТКА АЛГОРИТМА СОЗДАНИЯ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ ПРОЦЕССА ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТАРА НА ОСНОВЕ РЕТРОСПЕКТИВНОЙ ИНФОРМАЦИИ.....	72
2.1. АНАЛИЗ ТЕХНОЛОГИЧЕСКОЙ СХЕМЫ ПРОИЗВОДСТВА И СИГНАЛОВ ПЕРЕДЕЛА ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО СЫРЬЯ	72
2.2. РАЗРАБОТКА АЛГОРИТМА ПОДГОТОВКИ РЕТРОСПЕКТИВНЫХ ДАННЫХ ДЛЯ ПРОВЕДЕНИЯ ПРОЦЕДУРЫ МОДЕЛИРОВАНИЯ.....	77
ВЫВОДЫ ПО ГЛАВЕ 2	93
ГЛАВА 3. РАЗРАБОТКА ЦЕПИ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ ПРОЦЕССА ОБОГАЩЕНИЯ	94
3.1. РАЗРАБОТКА МОДЕЛИ КОМПЛЕКСА «ГОЛОВНАЯ ШАРОВАЯ МЕЛЬНИЦА – СПИРАЛЬНЫЙ КЛАССИФИКАТОР».....	94
3.1.1. РАЗРАБОТКА МОДЕЛИ КОМПЛЕКСА «ГОЛОВНАЯ ШАРОВАЯ МЕЛЬНИЦА – СПИРАЛЬНЫЙ КЛАССИФИКАТОР» С ПРИМЕНЕНИЕМ АППАРАТА РЕГРЕССИОННОГО АНАЛИЗА.....	95
3.1.2. РАЗРАБОТКА МОДЕЛИ КОМПЛЕКСА «ГОЛОВНАЯ ШАРОВАЯ МЕЛЬНИЦА – СПИРАЛЬНЫЙ КЛАССИФИКАТОР» С ПРИМЕНЕНИЕМ АППАРАТА МНОГОСЛОЙНЫХ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ	102
3.1.3. РАЗРАБОТКА МОДЕЛИ КОМПЛЕКСА «ГОЛОВНАЯ ШАРОВАЯ МЕЛЬНИЦА – СПИРАЛЬНЫЙ КЛАССИФИКАТОР» С ПРИМЕНЕНИЕМ АППАРАТА ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ.....	116
3.2. РАЗРАБОТКА МОДЕЛЕЙ АГРЕГАТОВ ТЕХНОЛОГИЧЕСКОГО ПРОЦЕССА ОБОГАЩЕНИЯ	137

ВЫВОДЫ ПО ГЛАВЕ 3	146
ГЛАВА 4. РАЗРАБОТКА ПРОГРАММНОГО КОМПЛЕКСА ПРОГНОЗИРУЮЩЕЙ НЕЙРОСЕТЕВОЙ СИСТЕМЫ	147
ВЫВОДЫ ПО ГЛАВЕ 4	157
ЗАКЛЮЧЕНИЕ	158
СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ	160
ПРИЛОЖЕНИЯ	172

ВВЕДЕНИЕ

Актуальность темы и степень ее разработанности. На сегодняшний день горно-металлургическая отрасль является самой энергоемкой в структуре промышленности России. Значительные объемы перерабатываемого сырья, производимой продукции и высокий спрос на нее на мировом рынке делают актуальной задачу повышения показателей эффективности всех этапов производства, что, при условии отсутствия изменений в технологии производства и значительных капитальных затрат, возникающих при замене существующего оборудования, возможно лишь путем внесения изменений в алгоритмическое и программное обеспечение систем управления.

Технологический процесс обогащения железорудного концентрата на горно-обогатительном предприятии представляет собой дискретно-непрерывную последовательность производственных операций, осуществление которых происходит в условиях вариативности физико-механических свойств поступающего сырья, обусловленной непостоянством минералогического состава, дрейфа параметров оборудования вследствие эксплуатационного износа частей и прочих особенностей, осложняющих автоматизированное управление. Контроль качественного показателя выходного продукта, характеризующего работу обогатительного передела – процентного содержания железа в концентрате – не реализован в автоматизированном режиме и производится только посредством лабораторного анализа, отбор проб для которого выполняется с дискретно, с интервалом, значительно превышающим продолжительность технологического процесса.

Это значительно усложняет управление технологическим переделом, поскольку его необходимо реализовывать с соблюдением регламентов, учетом нестабильности внешних факторов, многие из которых недоступны в оперативном режиме или не измеряются вовсе, при этом выполняя требования по достижению целевого значения содержания железа и общим показателям производительности.

В настоящее время управление технологическими объектами осуществляется с применением ПИД-регулирования в локальных контурах, алгоритмически не связанных друг с другом. То есть анализ их показаний, с восстановлением взаимосвязи между переменными, предоставляется оператору и выражается в формировании уставок по контурам управления, обеспечивающих достижение технологических требований. С целью предотвращения выхода за границы технологических допусков в условиях нестабильности неизмеряемых свойств сырья и параметров оборудования, отсутствии значений выходного показателя, определяемых в режиме реального времени, оператор осуществляет управление с формированием так называемых зон «запаса сверху», обеспечивая получение требуемого по качеству выходного продукта, при этом не снижая показатели удельной эффективности процесса.

Актуальным в данных условиях представляется применение методов предиктивного управления, основанного на построении и использовании моделей технологических объектов. В исследовании предполагается выполнить разработку модели процесса обогащения, способной, на основе анализа текущих технологических показателей, осуществлять прогнозирование хода процесса. Наличие данного инструмента обеспечит возможность, в масштабе реального времени, спрогнозировать изменение контролируемых технологических показателей и осуществить подбор вектора значений управляющих переменных с целью повышения эффективности работы реальной системы управления процессом.

Широко известны использованием данного подхода системы усовершенствованного управления - АРС-системы. Они позволяют в условиях многопараметричности и нестационарности дискретно-непрерывного распределенного технологического процесса оптимизировать значения управляющих переменных, стабилизируя в эффективной области технологические показатели, при этом получая итоговый продукт требуемого качества. Ядром этих

систем являются модели технологических объектов, применяемые для прогнозирования изменений процесса, на основе результатов которого осуществляется подбор значений управляющих параметров. На сегодняшний день при реализации АРС-систем применяются широко распространенные классические методы идентификации, не позволяющие, получать модели многопараметрических объектов, функционирование которых описывается нелинейными многомерными зависимостями, что характерно для процессов горно-обогатительного производства, с достаточно высокой точностью функционирования. В условиях наличия прогнозирующего функционала, процедура управления становится более понятной, но все же из-за невысокой точности моделей осуществляется «по-среднему», что сказывается на эффективности функционирования системы в целом.

Поэтому актуальным вопросом становится повышение точности функционирования модели процесса с использованием ретроспективных данных. В данных условиях для построения моделей технологических объектов оправданным является применение интеллектуальных алгоритмов, и, в частности, одного из методов машинного обучения – аппарата искусственных нейронных сетей (ИНС). Нейронные сети обладают способностью аппроксимации и экстраполяции сложных нелинейных многомерных функций, что позволяет обосновать их использование в рамках представленной задачи.

Принципы аппроксимации многомерных функций путем представления в виде суперпозиции непрерывных одномерных функций были доказаны еще в работах А.Н. Колмогорова. Дальнейшее развитие теории стало основой вычислительного аппарата ИНС. Обоснование и доказательство его возможностей решения практических задач представлены в циклах работ С. Омату, С. Хайкина, Р. Хехт-Нильсена, К. Хорника, К. Фунахаши, Г. Цыбенко, А.Н. Горбаня, Я. Лекуна, Дж. Хинтона и прочих. Возможность применения нейросетевого аппарата в решении задач горно-металлургического сегмента промышленности показана в

работах Ю.И. Еременко, П.В. Сараева, М.Ю. Зарубина, Д.А. Полещенко. ИНС позволяют получить положительный результат при решении задач моделирования агрегатов металлургического производства. В цикле работ П.В. Сараева рассматривается и доказывается эффективность такого направления идентификации как нейроструктурное моделирование технологических процессов. В работах М.Ю. Зарубина выполняется успешное моделирование работы измельчительного агрегата.

Поэтому в рамках исследования актуальной представляется задача разработки методики прогнозирования содержания железа в выходном продукте технологического процесса обогащения железорудного концентрата на основе поагрегатных нейросетевых моделей. Наличие прогнозирующей системы позволит, путем анализа текущих значений технологических показателей, оценить возможные изменения процентного содержания железа в концентрате. Использование для идентификации ретроспективных данных обеспечит учет опыта оператора обогатительной фабрики. В итоге использование прогнозирующей системы в существующей АСУ ТП позволит, в ответ на коррекцию управляющих воздействий и изменений в работе оборудования, вызванных неизмеряемыми изменениями свойств сырья, расширить возможности управления за счет своевременной оценки изменения содержания железа на основе результатов прогнозирования, что обеспечит функционирование агрегатов в более узких значениях технологических границ без формирования «областей запаса» и приведет к повышению общей эффективности обогатительного передела.

Целью диссертационной работы является разработка методики прогнозирования значения процентного содержания железа в выходном продукте процесса обогащения железорудного концентрата синтезированной поагрегатной нейросетевой моделью передела, инвариантной к свойствам сырья и параметрам оборудования, для совершенствования существующей АСУ ТП.

Задачи исследования. Для достижения результата необходимо решение следующих задач:

- анализ: процесса обогащения железорудного концентрата; функционирующих технологических объектов; перечня измеряемых параметров; границ их допустимого изменения, согласно технологии; факторов, обуславливающих нестационарность процесса и опосредованно влияющих на качество железорудного концентрата;

- анализ существующих в теории управления методов идентификации технологических объектов с использованием ретроспективных данных, наиболее широко применяемых на практике. Исследование возможности их применения для реализации прогнозирующего функционала;

- разработка алгоритма предобработки данных эксплуатации технологических объектов, включающего процедуры первичного анализа, фильтрации и разбиения на обучающую и тестовую выборки, используемых при моделировании;

- разработка методики построения нейросетевых моделей технологических объектов, заключающейся в подборе аппарата и гиперпараметров ИНС прогнозирующих процентное содержание железа в концентрате с погрешностью, не превышающей $|\text{Fe}| = 0.5\%$, что соответствует технологии и позволит повысить точность в сравнении с существующими подходами к прогнозированию;

- разработка алгоритма подбора рекомендуемых значений уставок для объектов технологического передела на основе полученного прогноза;

- разработка алгоритма функционирования подсистемы прогнозирования содержания железа в железорудном концентрате для ее интеграции в существующую систему управления, реализованную на базе SCADA-системы WinCC;

- оценка эффективности применения разработанной подсистемы прогнозирования процентного содержания железа в железорудном концентрате, посредством анализа изменения объемов перерабатываемого сырья при функционировании обогатительного передела.

Научная новизна диссертационной работы заключается в следующем:

- предложена методика идентификации объектов технологического процесса обогащения железорудного концентрата на базисе глубоких гибридных нейросетевых моделей, отличающихся параллельностью функционирования разнородных типов архитектур, что обеспечивает инвариантность моделей к свойствам поступающего сырья, оборудования и отсутствие автокорреляции в данных прогноза;

- создана модель секции обогащения железорудного концентрата, разработанная с использованием поагрегатного принципа на базе аппарата глубоких гибридных ИНС, прогнозирующая содержание железа в готовом концентрате с погрешностью не более $|\text{Fe}| = 0.5\%$;

- разработан оригинальный алгоритм анализа и предобработки ретроспективных данных технологического процесса обогащения железорудного концентрата, обеспечивающий обучение гибридных нейросетевых моделей подсистемы прогнозирования процентного содержания железа в концентрате, величина ошибок которых при функционировании не превышает требований технологических регламентов.

Теоретическая значимость работы представляется в разработке универсальной методики построения моделей технологических объектов процесса обогащения железорудного концентрата на основе глубоких гибридных нейронных сетей. Данная методика позволяет учитывать действия человека-оператора за счет проведения процедур обучения глубоких нейросетевых моделей гибридной архитектуры на репрезентативной выборке данных функционирования

технологических объектов передела и дополняет функционал управления, повышая эффективность существующей АСУ ТП, за счет применения поагрегатной модели процесса обогащения, способной, на основе анализа текущих значений технологических переменных, обеспечить прогноз возможных изменений процентного содержания железа в концентрате, в условиях нестационарности свойств сырья и параметров оборудования, с погрешностью в пределах $|\text{Fe}| = 0.5\%$.

Практическая значимость работы. Разработанная прогнозирующая подсистема реализована в виде приложения для взаимодействия с промышленной SCADA-системой WinCC, что делает возможным ее интеграцию в существующую систему без внесения принципиальных изменений в процесс управления. В результате чего у оператора появляется функционал, предоставляющий прогноз значения процентного содержания железа в концентрате с откликом в режиме реального времени, актуальность которого обеспечивается адаптивным алгоритмом функционирования системы, предполагающим выполнение процедуры обучения ИНС моделей на актуальных наборах данных при превышении порогового значения ошибки прогноза. Данное ПО позволяет, в случае наступления ситуации получения негативного прогноза по значению выходного параметра, выделить участок производства, функционирование которого может привести к отклонению содержания железа в концентрате от заданного, и, посредством разработанного алгоритма, осуществить процедуру подбора и коррекции уставок для локальных контуров, предотвращающих данную ситуацию. Повышение стабильности показателя качества позволяет увеличивать среднюю загрузку производственных мощностей секции, что обеспечивает повышение объема перерабатываемого сырья на 1,5-2% или 170 тыс. тонн в годовом исчислении.

Методология и методы исследования. В ходе выполнения исследования были изучены классические методы теории автоматического управления для

идентификации технологических объектов на основе данных их эксплуатации, к которым относится апробированный для моделирования аппарат передаточных звеньев, статистического регрессионного анализа. Основным аппаратом, исследованным в работе, был выбран один из методов машинного обучения – глубокие искусственные нейронные сети. Методологическую и теоретическую основу диссертационной работы составили научные труды отечественных и зарубежных авторов в области горного дела, идентификации сложных систем, интеллектуальных систем управления, нейроструктурного моделирования и машинного обучения.

Научные положения, выносимые на защиту:

- методика нейросетевой идентификации технологических объектов секции обогащения железорудного концентрата на основе ретроспективных данных их эксплуатации, отличающаяся тем, что обеспечивает инвариантность модели при изменении входных параметров, обусловленных непостоянством свойств поступающего сырья, в интервале до $\pm 20\%$ от номинальных значений;

- поагрегатная модель секции обогащения железорудного концентрата на базе аппарата гибридных глубоких ИНС, применяемая для прогнозирования содержания железа в готовом концентрате;

- алгоритм анализа и предобработки ретроспективных технологических данных для обучения гибридных глубоких нейронных сетей, позволяющий обеспечить сходимость процесса обучения моделей подсистемы прогнозирования процентного содержания железа в концентрате, с погрешностью при функционировании не более $|\text{Fe}| = 0.5\%$.

Достоверность результатов диссертационной работы обеспечивается соблюдением требований к проведению процедуры математического моделирования, использования в ходе экспериментов данных, полученных с помощью специализированного ПО – SCADA-системы WinCC, осуществления

опытов в среде программирования Matlab и Google Colab, высоким качеством результатов экспериментов, осуществленных на базе реальных данных производства.

Реализация и внедрение результатов работы. Основные практические результаты, полученные при разработке прогнозирующей системы, рекомендованы к внедрению на АО «Стойленский ГОК» и АО «Лебединский ГОК», что подтверждено актами, приведенными в Приложениях.

Результаты диссертационного исследования используются в учебном процессе Старооскольского технологического института им. А.А. Угарова (филиала) ФГАОУ ВО «Национальный исследовательский технологический университет «МИСиС» в дисциплинах «Технические средства автоматизации» и «Проектирование систем верхнего уровня».

Апробация результатов. Основные аспекты исследований и результаты диссертационной работы докладывались, обсуждались и получили положительную оценку на 21 международной и всероссийской научно-технической конференции: XIII Всероссийское совещание по проблемам управления ВСПУ-2019 (Москва, 2019), Всероссийская школа-конференция молодых ученых «Управление большими системами», (Самара, 2016), Международная научно-практическая конференция «Современные сложные системы управления» (Липецк, Старый Оскол, 2017, 2018), XXVI международный научный симпозиум «Неделя горняка - 2017» (Москва, 2017), Международная конференции «Проблемы управления и моделирования в сложных системах» (Самара, 2017, 2019), Всероссийская научно-практическая конференция (с международным участием) AS'2017 «Системы автоматизации в образовании, науке и производстве» (Новокузнецк, 2017), Международная научно-техническая конференция «Актуальные проблемы прикладной математики, информатики и механики» (Воронеж, 2017), V Всероссийская научная конференции молодых ученых с международным участием «Информатика, управление и системный анализ» (Ростов-на-Дону, 2018),

Всероссийская научно-практическая конференция с международным участием «Современные проблемы горно-металлургического комплекса. Наука и производство» (Старый Оскол, 2015-2019).

Связь исследований с научными программами: исследования велись в рамках научно-исследовательской работы по приоритетным направлениям развития науки, техники и критическим технологиям для студентов и аспирантов вузов, предоставленным Департаментом внутренней и кадровой политики Белгородской области (договор №57 от 12.09.2018 г.); научно-исследовательской работы прикладных научных исследований Министерством образования и науки Российской Федерации, договор № 14.575.21.0133 (RFMEFI57517X0133); Программы поддержки технического образования Фонда Арконик для молодых преподавателей.

Публикации. Основные результаты (научных исследований) диссертационной работы опубликованы в 9 научных работах, из которых 6 – в периодических изданиях, рекомендованных ВАК, 4 – в материалах публикаций, индексируемых в WoS и SCOPUS. Получены 2 свидетельства о регистрации программы для ЭВМ.

ГЛАВА 1. АНАЛИЗ СУЩЕСТВУЮЩИХ ПРОБЛЕМ И МЕТОДОВ РЕШЕНИЯ ЗАДАЧИ АВТОМАТИЗИРОВАННОГО УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМ ПРОЦЕССОМ ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТРАТА

Существующие сегодня рыночные условия, требования, тенденции заставляют промышленные предприятия довольно активно осуществлять трансформацию технологических процессов с целью повышения результатов производства, получения экономической выгоды путем увеличения удельной производительности, качества изготавливаемой продукции, снижения себестоимости и общей оптимизации процессов.

Но период, когда достижение подобных результатов было возможным за счет установки дорогостоящего оборудования прошел. На сегодняшний день большое число крупных технологических предприятий представляют собой довольно высокоавтоматизированные производственные комплексы, что усложняет задачу повышения эффективности их работы без внесения принципиальных изменений в устоявшиеся схемы производства продукции.

В связи с этим, одним из немногих подходов, способных повысить эффективность существующих производственных комплексов без значительных капитальных затрат и внесения существенных изменений в ход технологического процесса, является модернизация алгоритмов функционирования систем управления. Примером технологического процесса подобного типа является процесс обогащения железорудного концентрата на горно-обогатительном комбинате, рассмотрение которого выполнено в работе.

1.1. ОПИСАНИЕ ТЕХНОЛОГИЧЕСКОГО ПРОЦЕССА ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТРАТА

Железорудный бассейн КМА является одним из крупнейших в мире. Полоса магнитных аномалий КМА шириной от 0 до 250 км и протяженностью более 850 км простирается на территории Белгородской, Курской, Орловской и Воронежской областей, являясь частью обширного железорудного бассейна. К этому бассейну

относятся Криворожско-Кременчугский, КМА, Белорусский, Прибалтийский, Карельский и Кольский железорудные районы.

Продуктивной на железные руды является коробковская свита курской серии. В составе выделяются две железорудные подсвиты мощностью 200-270 метров и 250-330 метров, сложенные железистыми кварцитами. В составе подсвит выделяются горизонты различных минеральных типов железистых кварцитов. Железистые кварциты представлены: магнетитовыми, железослюдко-магнетитовыми, куммингтонито-магнетитовыми и биотито-магнетитовыми минеральными типами.

В профиле коры выветривания железистых кварцитов Стойленского месторождения выделяются следующие зоны:

- окисленные и полуокисленные железистые кварциты, содержание железа магнетита в которых равно или менее 12 %, - отнесены к забалансовым, складироваться при отработке в спецотвал;

- богатые железные руды, содержание железа общего равно или более 45 %.

Полезными ископаемыми Стойленского месторождения являются богатые железные руды, неокисленные и окисленные железистые кварциты, а также попутно добываемые породы вскрыши железорудного карьера: рыхлые (глины и суглинки, мергель, мел, песок), скальные (кристаллические сланцы, кварцито-песчаники, гранито-гнейсы), выветрелые сланцы.

Неокисленные железистые кварциты представляют собой мелко- и тонкозернистые полосчатые породы, основными минералами которых являются магнетит, кварц, железная слюдка и минералы группы силикатов. В зависимости от состава железистые кварциты разделяются по данным детальной разведки на четыре основные минералогические разновидности [1,2]. Весовое количественное соотношение минералогических разновидностей по месторождению представлено в таблице 1.

Таблица 1. Весовое количественное соотношение минералогических разновидностей по месторождению

Минералогические разновидности	Весовое количество, %				
	Магнетитов.	Силикатно-магнетитовые		Железнослюдко-магнетитовые	Слаборудн.
		Куммингто-нитовые	Биотитовые		
Кол-во от общих запасов, %	47,5	20,1	17,0	14,6	0,8

Основным рудным минералом является магнетит. Он слагает самостоятельные прослои с небольшим количеством кварца, силикатов и карбонатов, где наблюдается в виде крупных зерен и агрегатов полигональной формы. В полуокисленных кварцитах наблюдается начальная стадия окисления с образованием мартита в виде каемок и пятен на зернах и агрегатах магнетита. Вторым по значению рудным минералом является железная слюдка, которая приурочена, главным образом, к железнослюдко-магнетитовым и магнетитовым с железной слюдкой кварцитам, образует в них самостоятельные, а также смешанные с магнетитом прослои.

Основным нерудным минералом является кварц. Вторыми по значению нерудными минералами являются силикаты, которые образуют самостоятельные и смешанные с кварцем и рудными минералами прослои. К постоянным минералам, присутствующим в кварцитах в незначительных количествах, относятся пирит и апатит.

Железнослюдко-магнетитовые, магнетитовые и полуокисленные кварциты в среднем по типам являются породами средней крепости, а силикатно-магнетитовые – породы высокой крепости. Средние значения коэффициента

крепости железистых кварцитов по типам составляют: железнослюдко-магнетитовый – 10,75; магнетитовый – 11,63; силикатно-магнетитовый – 13,83; полуокисленный – 11,59.

Самой низкой удельной работой разрушения характеризуются железнослюдко-магнетитовые кварциты – 11,61 кгм/см³ (от 9,84 до 14,88 кгм/см³). В магнетитовых кварцитах удельная работа разрушения составляет в среднем 12,95 кгм/см³ (от 6,26 до 17,63 кгм/см³). В силикатно-магнетитовых кварцитах значение удельной работы разрушения в среднем достигает 16,25 кгм/см³ (от 9,82 до 20,0 кгм/см³). В полуокисленных кварцитах удельная работа разрушения в среднем составляет 12,88 кгм/см³ (от 10,09 до 14,1 кгм/см³) [1,2].

Данные химических анализов, текстурно-структурных особенностей и физико-механических свойств геолого-технологических типов и минералогических разновидностей железистых кварцитов приведены в таблице 2.

Таблица 2. Характеристика железистых кварцитов Стойленского месторождения (по данным детальной разведки)

Геолого-технологический тип	Минералогические разновидности	Химический состав			Мощности прослоев			Размер зерен и агрегатов магнетита, мкм	Коэф. крепости по Протодьяконову	Удельная работа разрушения, кгс/см ³	Удельная производительность мельницы при 65% кл.-0.071 мм, кг/д.час	Показатели обогащения концентрата при крупности изм.92% кл.-0,044 мм			Массовая доля железа в хвостах, %		Коэффициент захвата, д.ед.
		Fe общ.	Fe магн	FeO	Рудные	Смешанные	Нерудные					Выход, %	Массовая доля железа в концентрате, %	Извлечение железа в концентрат	Fe общ.	Fe магн	
Железно-слюдко-магнетитовый	Железно-слюдко-магнетитовый	37,5	23,08	11,12	2,1	2,8	2,9	86,5	10,75	11,61	0,625	33,3	70,93	62,9	20,84	0,75	1,046
Магнетитовый	Магнетитовые	37,14	33,08	15,91	2,1	3,2	2,9	77,2	11,75	13,12	0,527	51,0	67,06	92	5,98	1,03	1,049
	С железной слюдкой	35,98	27,77	13,31	2,1	2,7	2,9	78,4	10,25	10,89	0,569	40,1	70,35	78,2	12,85	1,1	1,04
	С щелочными амфиболами	35,89	32,22	15,83	2,5	3,0	3,2	74,8	11,8	13,2	0,503	46,9	69,59	90,6	6,07	1,02	1,03
	С актинолитом	36,19	32,85	16,22	2,6	3,6	3,5	71,4	11,84	13,25	0,512	48,9	68,17	95	5,54	1,1	1,033
	С куммингтонитом	35,03	31,46	17,62	2,3	3,3	3,4	68,3	12,55	14,32	0,432	45,6	67,51	87,8	7,81	1,15	1,032
	С биотитом	28,7	24,97	13,17	2,2	3,5	4,0	63,2	13,24	15,36	0,513	36,7	68,21	87	5,76	1,41	1,038
	Среднее по типу	35,55	31,12	15,78	2,4	3,2	3,2	73,5	11,63	12,95	0,502	45,4	68,8	87,8	7,58	1,08	1,033
Силикатно-магнетитовый	Куммингтонито-магнетитовые	29,19	21,26	18,09	2,3	3,6	4,1	53,6	13,83	16,26	0,364	32,7	66,11	74,9	11,28	1,07	1,053
	Биотито-магнетитовые	25,1	16,27	16,59	3,8	6,9	5,9	44,1	13,41	15,61	0,408	25,1	66	65,81	1,45	0,86	1,056
	Среднее по типу	28,43	20,33	17,81	2,3	3,6	4,2	53,5	13,83	16,25	0,372	31,3	66,09	71,6	11,31	1,03	1,054
Полуокисленный	Полуокисленные	35,92	21,56	11,61	2,7	3,0	3,8	55,3	11,59	12,88	0,466	33,2	68,2	63,0	19,87	1,37	1,098

Сравнительная оценка измельчаемости минералогических разновидностей железистых кварцитов выполнена при крупности измельчения 65 % класса – 0.071 мм, соответствующей I стадии промышленного измельчения (таблица 2). Анализ приведенных данных показывает, не только значительные отличия удельной производительности по типам железистых кварцитов, но и существенные колебания в пределах одной минералогической разновидности. Это обусловлено текстурно-структурными особенностями железистых кварцитов.

Наилучшей измельчаемостью характеризуются железослюдко-магнетитовые (0,625 кг/л.час), магнетитовые с железной слюдкой (0,569 кг/л.час); наиболее низкой – куммингтонито-магнетитовые (0,364 кг/л.час), биотито-магнетитовые (0,408 кг/л.час) и магнетитовые с куммингтонитом (0,432 кг/л.час) кварциты.

Сравнительная оценка полученных концентратов выполнена при конечной крупности измельчения 92 % класса – 0,045 мм (таблица 2). Качество концентратов, определяемое, в основном, структурными особенностями, изменяется в широком диапазоне – от 61,3 % до 71,6 %. Наиболее высокой массовой долей железа характеризуются концентраты, полученные из железослюдко-магнетитовых кварцитов (70,93 %), наиболее низкой – из силикатно-магнетитовых кварцитов (66,09 %) [1,2].

Проектный химический, минералогический составы и физико-механические свойства железистых кварцитов приведены в таблицах 3, 4, 5.

Таблица 3. Химический состав неокисленных железистых кварцитов

Химическое соединение	Массовая доля, %	Химическое соединение	Массовая доля, %
Fe _{общ.}	34,32	P	0,1
Fe _{магн.}	27,28	CaO	1,9
FeO	15,68	MgO	1,93
SiO ₂	44,2	TiO ₂	0,075
Al ₂ O ₃	1,22	MnO	0,071
S	0,106	-	1,87

Таблица 4. Минералогический состав неокисленных железистых кварцитов

Минерал	Средняя массовая доля, %
Магнетит	37,7
Гематит	31
Силикаты	24,7
Сидериты	3,1
Пирит	0,2
Кварц	29
Карбонаты	1,4
Апатит	0,5
Прочие	0,3
Сумма минералов	100

Таблица 5. Физико-механические свойства железистых кварцитов

Показатель	Ед.изм.	Наименование типов кварцитов		
		Неокисленные	Полуокисленные	Окисленные
Объемный вес	г/см³	3,44	3,37	3,22
Пористость	%	3,97	4,23	
Влажность	%	3	3	3
Удельная работа разрушения	г/см³	12,3	9,1	
Крепость по шкале Протоджяконова		12÷16 до 18	6÷12 до 16	5÷12

Одним из наиболее тяжело поддающихся автоматизации процессов в горнодобывающей промышленности является технологический процесс обогащения железорудного концентрата [2,3,4,5,6,7,8,9]. В производственной цепочке данный процесс занимает место после дробления и предшествует операциям обезвоживания и отгрузки, что в комплексе является одними из важнейших переделов работы горно-обогатительного комбината (ГОКа).

Ниже представлен ход технологического процесса на примере обогатительной фабрики (ОФ) ОАО «Стойленский ГОК». Представленная схема является в достаточной мере типовой для обогатительных комбинатов.

Горная масса, добываемая в карьере, транспортируется в корпус крупного дробления, после чего сырье поступает в корпуса среднего и мелкого дробления. Затем порода следует на участок обогащения, включающий в себя три последовательные стадии измельчения и собственно обогащение.

При стандартном режиме функционирования рассматриваемой ниже технологической секции № 4 обогатительной фабрики (ОФ), применяется так называемая схема {2:2:1}: две мельницы в первой стадии измельчения, две мельницы – во второй стадии и одна – в третьей.

При работе по указанной схеме дробленая руда крупностью 15-0 мм из бункера системой конвейеров подается на грохоты. Надрешетный продукт грохотов поступает на сухую сепарацию в сепараторы 2ПБС 90/250, немагнитный продукт которых транспортируется на склад щебня, магнитный продукт конвейерами транспортируется в мельницы типа МШЦУ 55×65А 1-й стадии измельчения. Подрешетный продукт грохотов поступают в зумпфы, откуда насосами подается в сепараторы ПБМ 120/300, немагнитный продукт - поступает в хвостовой лоток, а магнитный – в мельницы первой стадии, объединяясь с магнитным продуктом сепаратора.

Мельницы 1-й стадии измельчения, работают в замкнутом цикле с двухспиральными классификаторами. Слив классификаторов поступает на 1-ю стадию ММС в магнитные сепараторы с противоточной ванной. Магнитные продукты 1-й стадии обогащения самотеком поступает в зумпфы № 1, и №4, откуда насосами подаются на вторую стадию классификации в гидроциклоны, а хвосты самотеком направляются в сборный хвостовой лоток.

Пески гидроциклонов поступают в мельницы 2-й стадии измельчения.

Измельченный продукт 2-й стадии измельчения поступает самотеком на 2-ю стадию обогащения в магнитные сепараторы с противоточной ванной. Концентрат 2-й стадии обогащения самотеком поступает в зумпфы №2 и №15, затем насосами подается на 3-ю стадию классификации в гидроциклоны, объединенные в батареи. Пески гидроциклонов возвращаются в цикл 2-й стадии измельчения. Слив гидроциклонов 2-й и 3-й стадии классификации самотеком направляется в дешламаторы для обесшламливания и сгущения. Сгущенный продукт обесшламливания (пески) поступает в зумпфы № 5 и № 6, откуда насосами подается на 3-ю стадию обогащения в двухбарабанные магнитные сепараторы с полупротивоточной ванной, слив самотеком направляется в сборный хвостовой лоток.

Концентрат 3-й стадии обогащения поступает в зумпф №7 и насосами направляется на грохоты тонкого грохочения. Подрешетный продукт грохотов поступает в зумпф № 12, откуда насосами подается на 4-ю стадию ММС в сепараторы, магнитный продукт которых является одним из конечных продуктов схемы и поступает в зумпф № 10. Немагнитный продукт направляется в зумпф 9, где объединяется со сливом мельницы третьей стадии измельчения. Надрешетный продукт грохотов поступает в зумпф № 11, откуда насосами подается на магнитные сепараторы 5-ой стадии, магнитный продукт которых самотеком направляется в мельницу третьей стадии измельчения.

Измельченный продукт третьей стадии измельчения поступает в зумпф № 9, откуда насосами подается в гидроциклоны, работающие в замкнутом цикле с мельницей 3-й стадии. Слив гидроциклонов поступает на 2-ю стадию обесшламливания в дешламатор, сгущенный продукт которого поступает в зумпф № 8 и насосами транспортируется на 6-ю стадию ММС. Магнитный продукт 6-й стадии ММС самотеком поступает в зумпф № 10, где объединяется с магнитным продуктом 4-й стадии ММС. Объединенный продукт является конечным концентратом технологической секции №4, который насосами подается на

уплотняющую сепарацию. Хвосты 2-й стадии обесшламливания и 5-й стадии ММС самотеком поступают в хвостовой лоток. Магнитный продукт 3-й стадии ММС обеих полусекций является конечным продуктом и из зумпфа № 7 направляется на уплотняющую сепарацию.

Схема цепи аппаратов секции № 4, технологический процесс функционирования которой описан, приведена на рисунке 1. Возможным является функционирование технологической секции № 4 по схеме {1:1:1}. В этом случае работает одна мельница 1-й стадии, одна мельница второй стадии и мельница третьей стадии. При этом задействованы все те же производственные агрегаты, что и при работе по схеме {2:2:1}. Схема движения потоков пульпы аналогична. Решение о смене схемы загрузки мощностей принимается исходя из анализа требований производственного плана и графиков проведения профилактических работ.

Для обезвоживания концентрата конечный концентрат из зумпфа № 10 технологической секции № 4 насосами подается на однобарабанные сепараторы, хвосты которых направляются в хвостовой лоток.

Корпус обогащения. Секция №4

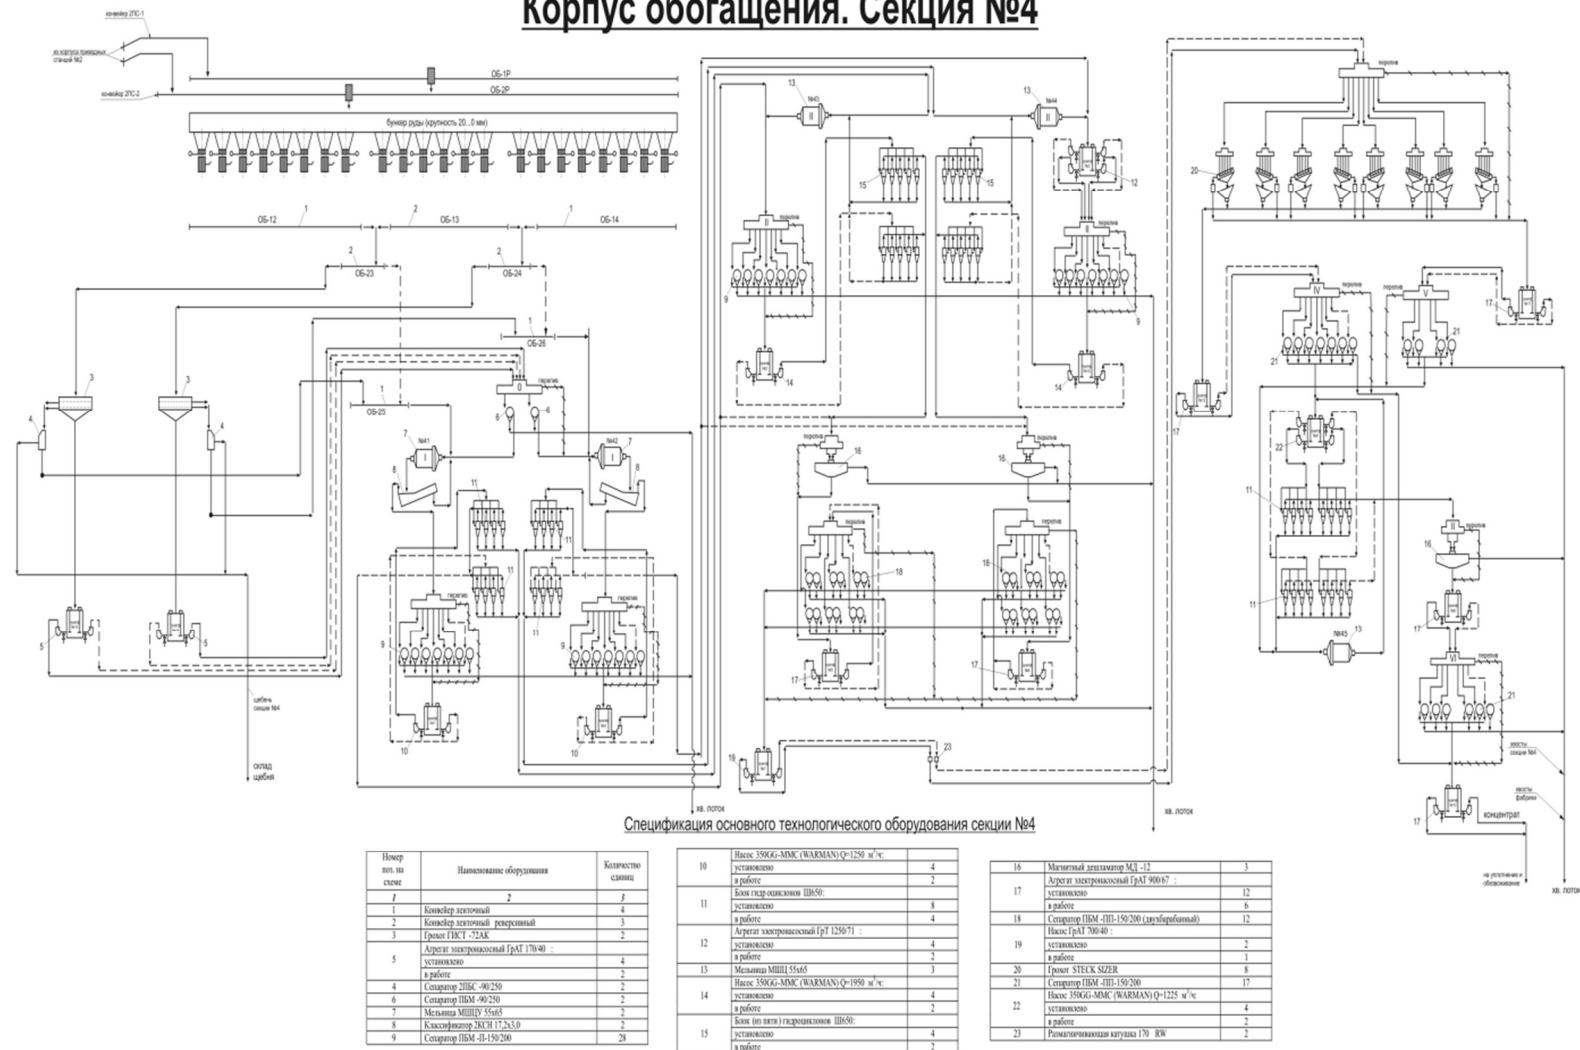


Рисунок 1. Схема цепи аппаратов технологической секции №4

Концентрат направляется в перемешиватели для усреднения, откуда насосами подается на пульподелители и затем на вакуум-фильтры. Обезвоженный концентрат (кек) конвейерами может подаваться на склад концентрата или на погрузку концентрата в вагоны. Перелив ванн вакуум-фильтров возвращается в перемешиватели МП-15. Отгрузка концентрата со склада концентрата в вагоны осуществляется двумя грейферными кранами грузоподъемностью 20 тонн через самоходные бункеры и системой конвейеров [1].

Из представленного описания можно сделать вывод, что технологический процесс обогащения представляет собой непрерывный многостадийный производственный цикл дискретного типа. Наиболее весомым фактором, серьезно усложняющим задачу автоматизированного управления, представляется непостоянство физико-механических свойств поступающего сырья, что обусловлено разнообразием минералогического состава рудного материала, добываемого на территории предприятия. Перед подачей сырья на переработку в секцию обогащения, предварительно производятся процедуры усреднения. Это позволяет снизить разброс свойств до определенных значений, но не ликвидировать его. К тому же, подача материала осуществляется системой конвейеров, на которые руда попадает из аккумулирующего хранилища, представляющего собой емкость с некоторым количеством течек – каналов подачи. Стоит обратить внимание, что и алгоритм равномерности загрузки емкости рудой, и алгоритм открытия течек сведены к цели обеспечения равномерности потоков, а значит никаким образом не учитывают разброс свойств подаваемого материала. Данное обстоятельство если не нивелирует результат процесса усреднения, то явно не повышает уровень стабильности физико-химических показателей. Ввиду указанного, наблюдаются изменения, в достаточно широком диапазоне, значений таких важных показателей, как, например, коэффициента крепости, дробимости, размеров зерна, удельной работы разрушения и т.д. Наступление подобных ситуаций требует практически непрерывного внесения изменений в значения

уставок по управляющим переменным. Принятие верного решения по управлению дополнительно усложняется отсутствием оперативной информации анализа свойств входящего потока сырья, что делает невозможным и учет данных показателей при построении аналитических характеристик процесса обогащения железорудного концентрата.

1.1.1. ТЕХНОЛОГИЧЕСКИЙ ПРОЦЕСС ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТРАТА КАК ОБЪЕКТ АВТОМАТИЗАЦИИ. АНАЛИЗ СУЩЕСТВУЮЩИХ ПРОБЛЕМ И НЕДОСТАТКОВ.

Измельчение и классификация руды являются основными подготовительными операциями перед ее обогащением. Из всех технологических операций переработки горно-обогатительного комбината измельчение является наиболее энергозатратным. Его доля в энергопотреблении горно-обогатительного комбината составляет порядка 55—60% [10]. Годовое потребление энергии ОАО «Стойленский ГОК» превышает 1,2 млрд кВт·ч [11]. Именно поэтому контроль параметров работы головных мельниц представляется наиболее важной и сложной задачей, поскольку работа данного объекта оказывает наибольшее влияние на целевые параметры сырья. Для оценки качества работы в процессе эксплуатации мельниц необходимо осуществлять контроль таких показателей, как:

- минералогический и качественный состав поступающей руды;
- крупность продуктов измельчения и классификации;
- загрузка мельниц шарами.

В настоящий момент для реагирования на изменяющиеся значения показателей сырья с целью поддержания качества выходного продукта производятся лишь промежуточные опробование и контроль качества продукции. В ходе выполнения технологического процесса систематически контролируются:

- вес исходной руды, перерабатываемой на фабрике обогащения, по показаниям весов, установленных на конвейерах (непрерывно);

- массовая доля железа общего, магнетита и класса + 10 мм в исходной руде (дискретно);
- массовая доля железа общего, влаги и класса – 0,045 +0 мм в концентрате;
- массовая доля железа общего и магнетита в отвальных хвостах мокрого обогащения (дискретно);
- массовая доля железа общего и магнетита, класса -5 + 0 мм, в хвостах сухого обогащения (дискретно);
- массовая доля железа общего, двуокиси кремния и влаги в отгружаемом концентрате (дискретно).

Представленные показатели оказывают значительное влияние на ход технологического процесса и являются его главными показателями с точки зрения эффективности, запаса возможного его улучшения. Но помимо этого, важную роль играют и значения промежуточных технологических показателей, что контроль за изменением которых осуществляется при функционирования локальных контуров управления технологическими объектами. В ходе осуществления обработки сырья на рассматриваемой обогатительной фабрике, технологический процесс которой представляется достаточно типовым для данного вида отрасли, осуществляется контроль производства в соответствии с технологической инструкцией по представленной ниже схеме.

На столе оператора технологической секции №4 установлены 5 автоматизированных рабочих мест (АРМ) со специализированным ПО для контроля и управления технологическим процессом. В ходе выполнения данных функций осуществляется контроль таких показателей, как контроль давления воды на вводах трубопровода секции и по полусекциям, контроль веса руды на конвейерах загрузки руды в головные мельницы. Дополнительно, на всех мельницах установлена система контроля объёмного заполнения шаровых мельниц – ВАЗМ-1 (виброакустический анализатор загрузки мельницы). Контролируемыми

параметрами системы являются объемное заполнение и выход скрапа. Исходя из требований технологии, на шаровых мельницы, как головных, так и пристежных, функционирует система контроля и регулирования соотношения содержания твердого к содержанию жидкого (Т:Ж). В нее входят схема контроля веса руды и схема контроля подачи воды в мельницу. Она имеет два режима работы:

- дистанционное регулирование, в этом случае задатчиком скорости питателя вручную устанавливается требуемая нагрузка в мельницу по весу, а также вручную (ключом пульта управления ПУ «больше» – «меньше») открывается задвижка подачи воды в мельницу;

- автоматическое регулирование, в этом случае задатчиком скорости питателя устанавливается требуемая нагрузка в мельницу по весу, а также задатчиком устанавливается, согласно режимной карте, требуемое количество воды в мельницу.

Одним из важнейших показателей работы шаровой мельницы, характеризующим ее работу и состояние, является значение активной мощности, потребляемой приводом, значение которой также контролируется преобразователями и передается на пульта управления.

Для оценки эффективности работы комплекса «мельница-классификатор» производится контроль плотности слива классификатора радиоизотопным плотномером. Схема имеет два режима работы:

- дистанционное регулирование, при котором вручную с пульта управления «больше-меньше» открывается клапан, регулирующий подачу воды на бутару. Оценка расхода воды выполняется расходомером воды, подаваемой на бутару. При этом, на АРМ оператора будет отображаться изменение плотности в большую или меньшую сторону;

- автоматическое регулирование, в этом случае задатчиком устанавливается соответствующая плотность и регулирующий комплекс автоматически, открывая

или закрывая исполнительным механизмом задвижку, поддерживает заданную плотность.

С целью контроля и поддержания уровня пульпы в технологических зумпфах № 1, 2, 4, 5, 6, 7, 8, 9, 11, 13, 14 секции № 4 установлены уровнемеры, сигнал уровня передается в операторский пункт и регулирующий комплекс.

Контроль плотности слива гидроциклонов также осуществляется радиоизотопным плотномером. Аналогично, схема контроля разгрузки дешламатора предусматривает датчик, являющийся радиоизотопным плотномером: в зависимости от плотности слива дешламатора, исполнительный механизм закрывает или открывает разгрузочную задвижку дешламатора. Переход от автоматического к дистанционному режиму и установка задания аналогичны схеме регулировки плотности слива классификатора. Контроль массовой доли железа магнетита в отвальных хвостах осуществляется непрерывно.

Сбор сигналов с датчиков на 3-4 секции ОФ выполняется распределенной периферией, затем оцифрованные сигналы собираются в аппаратной АСУТП на PLC, которые их обрабатывают, управляют технологическими агрегатами 4 секции обогатительной фабрики и передают данные на серверы с целью архивирования и передачи на АРМ оператора 4 секции, АРМ руководителей и специалистов ОФ.

В таблице 6 представлены численные значения некоторых показателей, измеряемых в ходе работы оборудования рассматриваемого технологического процесса [1,2].

Таблица 6. Некоторые технологические параметры процесса обогащения и диапазон их изменения

Технологический параметр	Единицы измерения	Значение параметра
Производительность мельницы по исходной руде	т/ч	490-600

Потребляемая мощность приводом мельницами 1, 2, 3 стадий измельчения	кВт	3300-3900
Вес шаровой загрузки в мельницах 1, 2, 3 стадий измельчения	т	265-290
Объем воды, подаваемой в мельницу 1 стадии измельчения	м ³ /ч	100-130
Плотность слива классификатора 2КСН 3х17,2 1 стадии	г/л	1500-2000
Содержание класса -0,045+0мм в сливе классификатора 1 стадии	%	35-45
Плотность слива мельницы 1 стадии измельчения	г/л	2100-2400
Плотность питания 1 стадии ММС	г/л	1300-1700
Плотность слива гидроциклонов (г/ц) 2 стадии классификации	г/л	1100-1250
	% тв.	14-22
Плотность песков 2 стадии классификации	г/л	2300-2600
Содержание класса -0,045+0мм в сливе г/ц 2 стадии	%	50-65
Давление на входе в г/ц	атм	1,8-3,0
Плотность слива мельницы 2 стадии измельчения	г/л	2200-2400
Уровень пульпы в зумпфах	м	2,5-3,0
Плотность питания 3 стадии ММС	г/л	1500-1800
Плотность песков обесшламливания 1 стадии	г/л	1600-2000
Плотность слива г/ц 3 стадии	г/л	1100-1200
	% тв.	12-22
Плотность песков г/ц 3 стадии	г/л	2500-2700
Плотность слива мельницы 3 стадии измельчения	г/л	2100-2350
Плотность песков обесшламливания 2 стадии	г/л	2000-2200
Плотность питания 4 стадии ММС	г/л	1300-1450

Плотность песков обесшламливания 3 стадии	г/л	1600-2000
Плотность питания 5 стадии ММС	г/л	1300-1450

Представленные данные позволяют сделать вывод, что рассматриваемый процесс представляет собой многосвязный процесс, в котором большая часть функционирующих объектов представляют собой многопараметрические агрегаты с, зачастую, нелинейными зависимостями изменения параметров. Это требует от оператора достаточно глубокого понимания происходящих внутри аппаратов процессов для точного управления ими в рамках предоставляемых ограничений на показатели эффективности.

Из численных значений видно, что допустимый и предполагаемый разброс большинства показателей, согласно технологической карты, составляет порядка 10-20% от медианного, а некоторые переменные изменяются и с большей амплитудой. Это подтверждает предположение о нестабильности параметров промежуточного продукта. Причем данный разброс значений показателей априорно учтен при составлении технологической карты производственного процесса, что уже говорит о значительных интервалах допуска в ходе производства, в итоге приводящих к разбросу значений качества выходного продукта.

Помимо нестабильности свойств поступающего сырья, наблюдается дрейф параметров и самого функционирующего производственного оборудования. Данное явление достаточно хорошо прослеживается на примере одного из главных агрегатов производственного цикла – головном комплексе «шаровая мельница – спиральный классификатор». Так, в процессе работы наблюдается износ футеровки барабанных мельниц, что приводит к изменению внутримельничного объема, а, соответственно, и параметров объекта с точки зрения теории управления, таких как значение постоянной времени, коэффициента усиления объекта [3,4,5,8]. Также стоит учитывать, что при функционировании мельниц данного типа в ходе работы

осуществляется дискретная догрузка мельящих тел – шаров различного диаметра. Причем не все ранее загруженные шары изнашиваются полностью. Часть из них, достигая определенного размера, скапливаются внутри мельницы и перестают выполнять работу по измельчению материала, занимая некоторый объем и являясь, по сути, балластом. А догрузка новой порции шаров вызывает некоторый рост производительности мельницы в последующие моменты времени [3,4,8,9,12].

Обобщая вышесказанное, технологический процесс обогащения можно охарактеризовать следующими отличительными признаками, затрудняющими процесс управления и оказывающими негативное влияние на его эффективность:

- нестационарность свойств поступающего на переработку материала, выражающееся в непостоянстве физико-химических свойств руды и различном объеме обрабатываемого сырья в зависимости от загрузки производства;
- дрейф параметров технологических объектов, возникающий в результате износа составных частей, различной загрузки мощностей;
- нестабильное качество ведения технологического процесса в зависимости от опыта оператора, управляющего объектом в данный момент;
- значительная величина запаздывания в объектах, возникающая по причине транспортировки перерабатываемого материала внутри объекта и длительности самого процесса переработки;
- высокая инерционность процесса обогащения за счет многоемкостности - наличия значительных по объему промежуточных емкостей, в которых происходят процессы перемешивания и изменения плотностей [2,3,4,5,6,7,8,9,10,13,14].

Данные аспекты значительно усложняют процедуру управления технологическим процессом обогащения с использованием классического подхода с применением локальных контуров управления без их взаимного обмена информацией. Применение подобных алгоритмов управления позволяет функционировать производственному циклу на достаточно стабильном уровне,

реализуя задачу управления «по среднему», что обеспечивает устойчивость процесса, но не его наилучшую эффективность. Оператору весьма сложно осуществлять управление территориально распределенным переделом производства из нескольких агрегатов с учетом не только требований технологии и планов по объемам производства, но и оценивая эффективность функционирования каждого из объектов в отдельности. Дополнительно задачу управления усложняет тот факт, что многие из функционирующих технологических агрегатов являются сложными многосвязными объектами, выходные параметры которых зависят как от нескольких входных переменных [15], так и от состояния самих агрегатов, результатов работы предыдущих переделов. Поэтому на сегодняшний день управление процессом происходит исходя из опыта и знаний оператора обогатительной фабрики и операторов отдельных технологических агрегатов. Вполне логично, что при данном подходе невозможно достигать максимума эффективности управления технологическим процессом.

В данных условиях, для поддержания требуемого качества, оператор зачастую осуществляет изменение управляющих воздействий с учетом формирования так называемого «запаса сверху» - создания излишнего по амплитуде управляющего воздействия с целью создания условий гарантированного получения на выходе годного продукта. Такой способ управления ведет к перерасходу энергоносителей и отрицательно сказывается на эффективности всего процесса. Происходит это по той причине, что помимо прямых потерь энергоносителей, наблюдается снижение удельной производительности и, собственно, эффективности. Также достаточно ярко наблюдается проблема зависимости эффективности управления технологическим процессом от опыта оператора, его психофизического состояния. При негативных тенденциях данных факторов увеличивается вероятность нарушения границ технологических допусков в ходе производственного процесса, появления

аварийных ситуаций [16]. Каждое из перечисленных явлений зачастую также приводит к необходимости либо снижения темпа производства, что сказывается на итоговых объемах, либо полной его остановке на данном участке. Оба этих события оказывают отрицательное влияние на показатели эффективности с экономической точки зрения.

Еще одной проблемой данного технологического процесса является сложность анализа свойств и качества входного сырья и выходного продукта. Поступающая руда, несмотря на проведение процедуры усреднения, как уже говорилось ранее, имеет неоднородные показатели химического состава, которые обуславливают ее физико-механические свойства, и, соответственно, различные реакции при осуществлении одинаковых этапов обработки [1,2,3,8]. Это приводит к получению концентрата с нестационарным распределением классов крупности, что влияет на количество материала рецикла, поступающего на необходимую дополнительную переработку. Для отработки возмущения подобного типа требуется смена уставок в системе управления на протяжении всего цикла переработки – коррекцию свойств невозможно произвести при помощи изменения работы лишь одного объекта. Данное обстоятельство требует уже глубокого понимания процесса от оператора, причем качество его действий в значительной степени зависит от опыта и способности спрогнозировать характер необходимой коррекции в зависимости от изменения некоторых параметров на входе секции. Однако, необходимые в таком случае результаты анализа рудного материала на входе в процесс, производимого лабораторным способом, не могут быть оперативно предоставлены персоналу для коррекции уставок контуров управления по причине длительности процедуры [1,2].

Имеются определенные недостатки и при оценке качества выходного продукта, а именно – содержания железа в готовом концентрате. Ввиду сложности реализации, функционирования и обслуживания оборудования для автоматической непрерывной оценки, в подавляющем большинстве случаев используется

лабораторный анализ содержания железа в концентрате $\{\text{Fe}, \%\}$, осуществляемый на рассматриваемом предприятии с дискретностью 1 раз в 2 часа [1,2]. Но большая часть обрабатываемого сырья проходит цикл обработки за время, составляющее по разным оценкам от 50 минут до 1,5 часов [3,4,5,6,7,8,9]. На время прохождения оказывают влияние физико-химические свойства руды, схема работы оборудования, темпы и требования производства. В итоге оператор не имеет возможности своевременно оценить результат изменения в управлении, а внесение корректив после получения данных анализа осуществляется уже на иной материальный поток сырья. Соответственно, результат определенных действий оператора, способных оказать воздействие на качество продукта, возможно будет оценить лишь через длительный промежуток времени, когда данная информация возможно уже будет неактуальна. А вносимые изменения, в большинстве, носят прогнозный, упреждающий характер, основываясь на понимании оператора.

Перечисленные факторы в значительной степени усложняют процесс управления, что увеличивает влияние опыта оператора, его возможностей прогнозирования изменения показателей процесса на качество и эффективность управления, явно демонстрируя необходимость наличия прогнозного инструмента. Причем дискретность времени прогнозирования и точность должны отвечать определенным требованиям, так как ситуации смены качества поступающего сырья довольно характерны, а интервалы допуска по изменению контролируемого процентного содержания невелики, относительно значения самого показателя.

Для приблизительной финансовой оценки положительного эффекта от наличия прогнозного аппарата стоит учитывать тот факт, что объем производства железорудного концентрата представленной обогатительной фабрикой составляет более 15 млн тонн в год на сумму порядка 1 млрд рублей [11]. Повышение эффективности производства подобного масштаба даже на несколько процентов принесет значительный положительный экономический эффект.

1.2. АНАЛИЗ НЕДОСТАТКОВ СУЩЕСТВУЮЩИХ АЛГОРИТМОВ УПРАВЛЕНИЯ. ОЦЕНКА ПЕРСПЕКТИВНОСТИ ИСПОЛЬЗОВАНИЯ ПРОГНОЗНОГО ПОДХОДА

Выполнение любой технологической задачи требует от работника-специалиста определенных навыков и опыта для осуществления не только качественного, но и эффективного ее исполнения. Подобное явление в полной мере наблюдается при оценке действий операторов, осуществляющих управление на уровне функционала SCADA-систем. Достаточно распространенной является схема организации, когда оператор управляет не одним отдельно взятым агрегатом, а некоторым набором объектов, последовательно или параллельно выполняющих технологические операции. Влияние знаний персонала на качество управления участком, с некоторым перечнем входных переменных и возмущений, воздействующих на объекты управления и изменяющихся в достаточно широком диапазоне ситуаций, представляется достаточно выраженным. Наличие подобных факторов, влияющих на эффективность, предъявляет дополнительные требования к знаниям управляющего персонала, причем знаниям глубоко специализированным. Ведь необходимо не только понимание технологии происходящих процессов, наличие навыков владения используемой системой управления и знаний в области управления, но и способность прогнозировать, предугадывать наступление изменений, связанных с изменением входов, учитывая дискретность происходящих процессов, возможную неполноту поступающей информации. Данное умение не всегда обосновывается сугубо знаниями и опытом оператора, порой снижение эффективности управления наблюдается при изменении психофизиологического и функционального состояния человека-оператора, что также стоит учитывать. Ситуация значительно усложняется при обучении новых кадров, когда уникальные критерии прогнозного понимания еще не сформированы в должной мере.

К тому же, общеизвестно, что на большинстве производственных объектов довольно эффективно реализованы и функционируют независимые друг от друга

локальные контуры управления. Но в действительности, ни один производственный объект не функционирует обособленно, управляемые и выходные параметры расположенных последовательно агрегатов имеют связь с точки зрения физических процессов технологии переработки. Поэтому попытки улучшить работу одного локального контура могут нивелироваться влиянием взаимосвязанных контуров, либо приводить к отрицательным последствиям в дальнейших переделах производства. Из чего следует, что системы управления, реализованные по подобному алгоритму невозможно значительно модифицировать за счет оптимизации функционирования одной только из существующих подсистем (локального контура). Для решения задачи значительного повышения эффективности процесса и, как следствие, повышения производительности и качества выпускаемой продукции, необходимо реализовывать оптимизацию с учетом особенностей работы всех существующих подсистем и в интересах глобального показателя качества функционирования передела [17]. Особенно ярко это наблюдается в тех случаях, когда подобные подходы применяются при управлении многоагрегатной технологической цепочкой дискретно-непрерывных производственных процессов со значительным числом управляющих и наблюдаемых параметров, стохастических возмущений. К подобному классу можно отнести и процесс обогащения железорудного сырья, рассматриваемый в работе.

Одним из главных недостатков существующих методов управления является применение алгоритмов, линейных по своей природе. Но подавляющее большинство технических систем и агрегатов нелинейны, а, соответственно, охарактеризовать их работу и попытаться осуществить управление в рамках оптимальных технико-экономических границ с применением данного функционала крайне сложно. Потому что подавляющее большинство современных технологических процессов, как уже было сказано ранее, представляют собой многопараметрические объекты управления. В данных условиях, управление

посредством изменения задания только в одном контуре может не принести пользы для работы объекта в целом и дальнейших переделов производства. В итоге эффективно вести управление процессом, с поддержанием на выходе необходимого по качеству продукта и обеспечением минимальных затрат энергоносителей на различных стадиях, способен лишь опытный оператор. По этой причине появляется своеобразная «зависимость» от опыта данного сотрудника, который не всегда представляется возможным передать другим работникам. Но и даже опытный оператор не всегда осуществляет управление процессом эффективно с точки зрения экономических показателей, т.е. он порой, для недопущения ситуации выпуска брака в условиях высоких требований по объемам производства, ведет управление с перерасходом сырья, энергоресурсов, создавая так называемый «запас по качеству» [12,13,14,17,18,19,20].

В ходе проведения подробного анализа технологического процесса обогащения на горно-обогатительном предприятии было выяснено, что управление данным процессом дискретно-непрерывного типа осложняется многими свойствами самого процесса и возмущениями, носящими, в большинстве случаев, стохастический характер. К основным особенностям технологического процесса, усложняющим задачу управления, можно отнести:

- непостоянство физико-химических свойств поступающего сырья;
- дрейф параметров собственно технологических агрегатов;
- значительные промежутки допуска, согласно технологии, как по параметрам работающего оборудования, так и значениям измеряемых показателей сырья;
- отсутствие интеграции локальных контуров различных технологических объектов в единую систему, вследствие чего задачей каждого из контуров является отслеживание и управление выходными параметрами только одного агрегата, что может негативно сказываться на последующих агрегатах и переделах;

- отсутствие у оператора возможности получения актуальной и достоверной информации о процентном содержании железа в выходном концентрате и откликах на изменения в управлении по причине высокой длительности процесса обогащения и трудностях при использовании методов автоматизации анализа в условиях реального производства.

Указанные особенности производственного процесса обогащения обосновывают актуальность разработки инструмента, обладающего способностью на основании текущих измерений входных технологических параметров в условиях изменения характеристик сырья и параметров оборудования, достаточно точно прогнозировать ход развития процесса как в отдельных агрегатах, так и в производственной цепочке в целом. Оператор же, имея возможность в реальном времени оценить влияние смены уставки на дальнейшее развитие технологического процесса, сможет более эффективно вести управление процессом, приближая графики изменения технологических показателей ближе к верхним границам, тем самым ликвидируя «запас сверху» [21].

Учитывая представленные особенности, проблемы и цели автоматизированного управления процессом обогащения железорудного сырья, перспективным предполагается применение парадигмы управления с прогнозирующими моделями (MPC – Model Predictive Control) [22,23,24,25,26,27,28,29,30,32,33,34,35,36,39,40,41,42,43]. Подход заключается в построении модели или набора моделей технологического агрегата с некоторым разнообразием набора характеристик, что позволяет выполнять экстраполяцию изменения выходных переменных на основе анализа входных показателей и имеющейся информации о системе. Зачастую осуществляется подбор управляющих воздействий, с учетом целевого показателя и ограничений, обеспечивающих изменение состояния агрегата лишь в допустимых технологических границах. Применение MPC-подхода позволяет управлять многомерными и многосвязными объектами со сложной структурой, выполняя

оптимизацию процессов в масштабе реального времени с учетом предъявляемых технологических и технических ограничений на управляющие и управляемые переменные в условиях неопределенности, стохастических изменений и существенного влияния запаздываний [44,45,46,47,48]. Даже приблизительное понимание предстоящего изменения значительно упрощает задачу управления сложным многопараметрическим объектом. При подобном подходе ядром прогнозирующих систем, естественно, является модель технологического агрегата, параметры работы которого и требуется прогнозировать [17,18,20,22,23,24,25,26,27,40,41,42,43]. Главное отличие подходов, существующих на сегодняшний день, заключается в применении различного аппарата моделирования

[21,22,23,24,25,26,27,28,29,30,31,32,33,34,35,36,37,38,39,40,41,42,43], что позволяет достигать различной точности и стабильности качества прогнозирования в условиях реального функционирования технологических объектов.

1.3. АНАЛИЗ СПОСОБА УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМИ ОБЪЕКТАМИ С ПРИМЕНЕНИЕМ АРС-СИСТЕМ

Среди множества существующих подходов к повышению эффективности технологических процессов при изменении алгоритмов функционирования оборудования, базирующихся на основе прогнозирующего управления, достаточно широкое распространение в последние годы на предприятиях получил класс систем усовершенствованного управления технологическими процессами (АРС-системы, Advanced Process Control) [23,24,46,47,48,49,50]. Идея заключается в прогнозировании будущего хода технологического процесса и выборе таких управляющих воздействий, которые обеспечат лучшее значение заданного критерия качества функционирования объекта при соблюдении технико-экономических ограничений [51,52,53,54,55]. Данная идея не нова и, по сути, представляет собой разновидность предиктивного/прогнозирующего управления на основе модели. Основоположниками данного направления являются

отечественные ученые, и первые работы были опубликованы еще в 1970-1980-х годах [56,57]. Затем данное направление по ряду причин перестало бурно развиваться в нашей стране, но идеи нашли применение в ряде западных стран. Мировые лидеры в сфере автоматизации, такие как Honeywell, Schneider Electric и прочие оценили преимущества систем на основе данного функционала и создали запатентованные программные продукты, которые активно внедряются во всем мире [47,48,49,50,52,53,54,55,58].

Для создания подобного функционала применяется построение модели объекта управления с использованием стандартных процедур. Модель должна иметь возможность описания динамики объекта для реализации качественного отображения характера работы агрегата (или процесса), а также иметь возможность корректировки, для подстройки ее под изменяющиеся внешние условия и характеристики технологической установки.

Одним из главных качеств, обеспечивающих возможность реализации системы, стал декомпозиционный подход при моделировании и построении многопараметрических контроллеров. На этапе проектирования и создания модели на составляющие части разбивается весь технологический цикл, его участок или сложный многопараметрический объект [23,24,47,48,59]. Еще одним положительным аспектом является наложение на управление технологическим процессом экономических и производственных критериев оптимальности, таких как повышение объема производительности, повышение качества продукции и т.д.

Алгоритм многопараметрического управления достигает экономических целевых показателей за счет оптимизационных механизмов выработки управляющих сигналов по принципам линейного и квадратичного программирования [23,24,47,59].

На основе полученных от системы АСУ ТП сигналов, алгоритмический контроллер APC-системы вычисляет развитие хода процесса, проверяет его

соответствие технологическим и экономическим ограничениям, в случае необходимости, корректирует управляющие воздействия в данных условиях (с наличием конкретных внешних условий и помех) так, чтобы выдержать эти ограничения и достичь цели по экономическим критериям. Регулирование «на уставку» сменяется принципом регулирования в пределах определенного коридора значений, согласованного с требованиями технологии, дополняемого, например, использованием аппарата нечеткой логики. Повторение алгоритма происходит циклически в соответствии с динамикой процесса [54].

При наличии качественных моделей создается структура из нескольких контроллеров нижнего уровня для каждого конкретного процесса или агрегата, функционирующих по описанным уже принципам, и одного «главного» контроллера. Система может управлять процессом как напрямую, так и через воздействие на существующие контуры ПИД-регулирования при должной их настройке [23,24,47,59,60,61,62]. Это обстоятельство является серьезным преимуществом, поскольку позволяет избежать серьезной технической модернизации, а, соответственно, и затрат. Однако данное требование предъявляет дополнительные условия по качеству работы исходных регуляторов и полевого уровня АСУ ТП.

В настоящий момент для реализации модели разработчиками используется аппарат передаточных звеньев для описания объектов. Для этого создаются наборы моделей на передаточных звеньях, которые потом объединяются в глобальную модель [55,59]. Однако данный механизм обладает определенными недостатками [17,19,20,21,48].

В работах [24,48,58,59] отмечается, что наибольшую выгоду APC приносят при функционировании на объектах с существенными нелинейностями, значительным транспортным запаздыванием, взаимозависимыми переменными и множеством соблюдаемых ограничений. Подобные проекты уже имеют место, однако они затрагивают наиболее прибыльный ценовой сегмент – производство

цветных металлов. В них, на этапе измельчения, управляют производительностью мельниц, степенью измельчения сырья, энергопотреблением, плотностью за счет моделирования и регулирования расхода сырья, воды, мощности двигателя мельницы и потоком рецикла. Стоит заметить, что по той же причине - финансовой составляющей, большинство проектов по внедрению APC-систем реализованы в нефтегазовой отрасли и химическом производстве [24,48,51,54,58,59].

В составе систем данного типа возможно применение виртуальных анализаторов. Виртуальные анализаторы – это смоделированный на основе ретроспективных статистических данных «датчик», который, по сути, представляет из себя модель, базирующуюся на аппарате регрессионного анализа или нейронных сетях (НС), и при помощи линейных и нелинейных зависимостей позволяет в режиме реального времени оценивать будущее изменение выбранного параметра [59,63,64]. Данный подход применяется к таким технологическим параметрам, измерение которых в потоке затруднено, невозможно, либо производится только на основе лабораторного анализа, но они представляют собой важные показатели качества работы установки. Наличие подобного функционала позволяет оператору в режиме реального времени отследить изменение важных технологических параметров при изменении управления, даже если реальное их изменение наступит через длительный промежуток времени или же не будет доступно для оператора вовсе. При изучении литературы были найдены публикации, рассматривающие возможность применения для реализации ВА многослойных и радиально-базисных нейронных сетей [52,53,54,63]. Однако при анализе существующих проектов APC-систем, наличие моделей именно технологических объектов на базе НС в работающей системе не обнаружено. Иными словами, данный функционал применяется для создания глобальной статистической модели, позволяющей спрогнозировать изменение лишь критически важного для процесса показателя, используя для анализа возможных изменений также незначительное число параметров, имеющих наибольшую связь

с прогнозируемым параметром. Из-за применения подобного подхода, получаемая модель не имеет последовательной физической связи с происходящим процессом, что позволяет оператору лишь увидеть возможное ухудшение показателей производства, но не предоставляет возможности понимания и локализации причин, повлекших это изменение.

Ввиду вышесказанного, к положительным аспектам данной системы можно отнести:

- возможность заблаговременно оценить возможное изменение выходных параметров при изменении управляющих воздействий или внешних воздействий и предупредить его;
- снижение количества колебаний значений технологических переменных в ходе реализации алгоритма управления процесса;
- повышение качества управления в стабильном режиме и при переходных процессах, что позволяет получить выходной продукт более высокого качества;
- ликвидацию запаса по качеству при управлении процессом;
- за счет снижения колебательности повышается срок службы оборудования, т.к. снижается количество «рывков» [65];
- за счет накопления статистических данных для уточнения моделей и реализации нечеткого логического выхода происходит уход от зависимости качества управления от опытности оператора, появляется аспект интеллектуализации управления [61,62].

Однако, при наличии вышеуказанных достоинств, подобная система имеет и недостатки, которые не позволяют применить ее функционал при построении прогнозирующей системы, которая является целью данной работы. К таким недостаткам можно отнести:

- недостаточная точность моделей, на которых основано «ядро» системы. В настоящий момент в большинстве реализуемых продуктов при разработке моделей объекта используется аппарат линейных передаточных звеньев, который не способен обеспечить достаточного качества обобщения. По этой причине необходимо либо создавать набор моделей агрегата, который все же не безупречен, т.к. набор возможных изменений объекта и внешних условий достаточно широк, либо создавать достаточно грубую модель, что отрицательно скажется на качестве управления. Для ликвидации данного недостатка необходимо наличие механизма адаптации модели. На данный момент это влечет за собой необходимость корректировки моделей со временем;

- преимущественное применение методов регрессионного анализа при построении виртуальных анализаторов. Несомненно, ход изменения множества технологических параметров возможно описать линейными функциями, либо нелинейными полиномами невысоких порядков. Однако, для некоторых комплексно-зависимых параметров необходимо применение либо полиномов высоких степеней, что существенно снижает обобщающую способность модели, либо их может быть также недостаточно для удовлетворительного качества моделирования;

- разработка и использование виртуальных анализаторов лишь в качестве глобального статистического прогнозирующего аппарата, сигнализирующего о возможном наступлении нерегламентированной ситуации, но не идентифицирующего причин ее наступления.

Однако, учитывая озвученные недостатки АРС-систем, стоит отметить, что поагрегатный подход при построении моделей технологических агрегатов единого производственного процесса представляется достаточно перспективным при разработке системы помощи оператору обогатительной фабрики, поскольку в данном случае при моделировании выходного сигнала будет учитываться весь перечень измеряемых сигналов и свойств моделируемых объектов. А наличие

нескольких моделей, в сравнении с подходом, когда строится единая глобальная модель процесса, будет обеспечивать лучшую интерпретируемость получаемой информации, позволяя сделать вывод об отклонении в работе конкретно каждого из агрегатов.

Поэтому решение актуальной задачи повышения эффективности работы производственного оборудования процесса обогащения железорудного концентрата на горно-обогатительном предприятии представляется возможным при реализации прогнозирующей системы, способной на основе анализа текущих значений показателей процесса спрогнозировать возможный ход развития с достаточно высокой точностью. Для реализации данного функционала предполагается разработать математические модели технологических агрегатов на основе анализа ретроспективной информации. Использование больших массивов данных позволит учесть различные производственные ситуации, широкий диапазон возможных изменений свойств поступающего сырья, дрейф параметров самого оборудования.

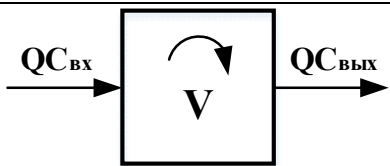

1.3.1. ПОДХОД К ПОСТРОЕНИЮ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ ПРОЦЕССА ИЗМЕЛЬЧЕНИЯ НА ОСНОВЕ ОПИСАНИЯ ФИЗИЧЕСКИХ ПРИНЦИПОВ ФУНКЦИОНИРОВАНИЯ

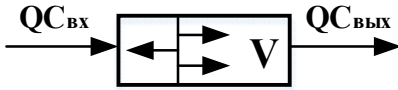
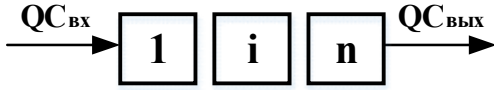
Наиболее распространенным методом описания характеристик, свойств и принципов работы технологических объектов является разработка аналитических моделей на основе происходящих физических, гидродинамических, механических процессов. Данный подход известен достаточно давно и, ввиду фундаментальности процесса разработки, является преобладающим на сегодняшний день. Суждение справедливо и для рассматриваемого технологического процесса обогащения железной руды, что подтверждается анализом источников [12,13,14,22,23,24,25,26,27,28,31] в рамках исследования. В частности, при разработке модели процесса измельчения наиболее распространены два подхода. Возможным является построение математического описания, например, процесса

измельчения, в конкретной точке путем рассмотрения процессов измельчения и смешения, происходящих в мельнице, на основе методов механики гетерогенных сред, получении выражений для движущих сил измельчения частиц дисперсных фаз в многофазовом потоке для описания механизма разрушения частиц. После чего производится экстраполяция полученных выражений на весь объем рабочего пространства. Сложность создания таких моделей обуславливается большим набором идентифицируемых параметров.

Существует и иной подход, получивший более широкое распространение, когда рабочее пространство агрегата рассматривается в виде единого объема, что позволяет получить более простые функциональные зависимости формирования выходного материального потока и процессов, происходящих в нем. Подобным образом рассматриваются технологические объекты и при построении статистических моделей. Для разработки же функциональных физических моделей, в рамках данного подхода были разработаны типовые модели структуры потоков в измельчительных аппаратах, подобных шаровым мельницам, представляющие собой идеальные звенья перемешивания, вытеснения, диффузии [66]. Некоторые примеры подобных моделей представлены в таблице 7. Модели, представленные ниже, отражают зависимость между главным показателем продукта (C) и параметрами: Q –массовым расходом, V –массовой загрузкой, U –линейной скоростью передвижения материала, D_L –коэффициентом обратного перемешивания, n –числом ячеек, L –длиной агрегата.

Таблица 7. Типы модели процесса измельчения

Вид модели	Структурная схема модели	Уравнение структуры потока модели
Идеальное смешивание		$\frac{dC}{dt} = \frac{Q}{V}(C_{\text{вх}} - C)$
Идеальное вытеснение		$\frac{dC}{dt} = -U \frac{dC}{dx}$

Диффузионная модель		$\frac{dC}{dt} = D_L \frac{d^2 C}{dx^2} - U \frac{dC}{dx}$
Ячеечная модель		$\frac{1}{n} \frac{dC_i}{dt} = \frac{Q}{V} (C_{i-1} - C_i)$

Для учета неоднородности потоков процесса возможно дополнительное введение в модель факторов застойной зоны, байпаса и рецикла.

Однако, стоит отметить, что у данного подхода имеются недостатки, заключающиеся в линейаризации большинства зависимостей представления происходящих процессов в более упрощенной форме. В тех же случаях, когда применяются нелинейные математические зависимости для описания функциональных закономерностей – наблюдается значительное усложнение математических моделей и увеличение числа определяемых параметров. При существующих возможностях вычислительных средств это не является значительной проблемой, однако процесс расчета порой занимает время, не обеспечивающее возможности достаточного быстрогодействия с точки зрения задач автоматического управления, что актуально и в рамках рассматриваемой задачи. Учитывая значительную длительность переходных процессов в некоторых объектах технологической цепочки, стоит также отметить и значительное число сложных многопараметрических агрегатов, принимающих участие в переработке рудного сырья. То есть в рамках рассматриваемой задачи необходимо одновременное функционирование набора моделей таких агрегатов, что дополнительно увеличивает вычислительную нагрузку.

В большинстве случаев в расчетных формулах присутствуют различные расчетные коэффициенты, которые являются жестко привязанными к конкретным данным и условиям [12,13,14,24,25,26,27,28,30,31]. Соответственно, подобные расчетные величины требуют необходимости корректировки, реализации

механизма адаптивности при изменяющихся внешних условиях, входных характеристиках процесса.

Еще одним аспектом, существенно усложняющим создание строго определенных моделей с принципиальной связью с происходящими в объекте процессами, является высокая стохастичность возникающих возмущений. Это обусловлено широким списком возможных возмущений и изменений по технологическим факторам, перечень и границы которых порой неспособны однозначно описать даже технологи обогатительных фабрик. К тому же, тяжело предугадать момент наступления данных возмущений. И если изменение параметров оборудования еще возможно описать функциональной зависимостью, несколько пренебрегая точностью аппроксимации, то моменты изменения физико-химических свойств поступающего сырья, несмотря на наличие операции усреднения, достаточно стохастичны и нестационарны, что было представлено ранее. Их наличие возможно определить по дрейфу режимов работы технологических агрегатов.

Перечисленные особенности в совокупности приводят к тому, что для обеспечения устойчивой работоспособности подобного функционального аппарата требуется глубокое понимание происходящих процессов и принципов построения зависимостей, взаимного влияния переменных, что требует привлечения экспертного персонала. Поэтому, как правило, решения на основе данного аппарата не приживаются на производстве ввиду необходимости временных затрат и дополнительного стороннего обслуживания, прекращается их актуализация, что влечет за собой снижение качества работы, и, в конечном итоге, отказе от использования.

В качестве примера возможно рассмотреть моделирование процесса измельчения в [32], где данный процесс представляется как каскад из трех последовательно функционирующих идеальных смесителей. Схема представлена на рисунке 2.

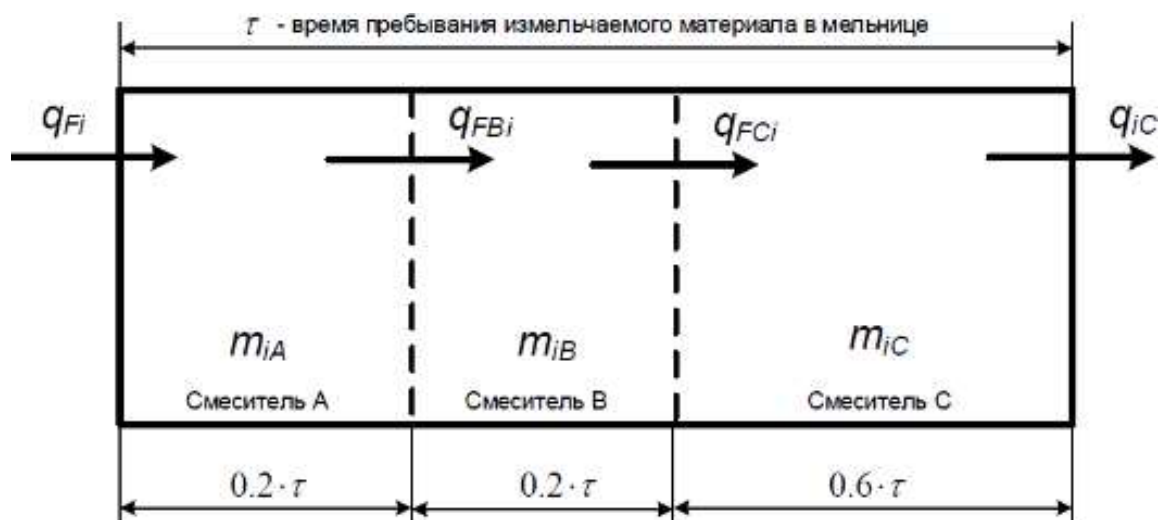


Рисунок 2. Моделирование процесса измельчения в шаровой мельнице в каскадном виде

С учетом физики процесса, кинетическое уравнение представлено в виде системы:

$$\begin{cases} \frac{dm_{iA}}{dt} = \frac{f_{iA}}{\tau_A} - s_i m_{iA} + \sum_{j=1}^{i-1} b_{ij} s_j m_{jA} - \frac{m_{iA}}{\tau_A}, \\ \frac{dm_{iB}}{dt} = \frac{f_{iB}}{\tau_B} - s_i m_{iB} + \sum_{j=1}^{i-1} b_{ij} s_j m_{jA} - \frac{m_{iB}}{\tau_B}, \\ \frac{dm_{iC}}{dt} = \frac{f_{iC}}{\tau_C} - s_i m_{iC} + \sum_{j=1}^{i-1} b_{ij} s_j m_{jB} - \frac{m_{iC}}{\tau_C}. \end{cases} \quad (1)$$

где m_{iA}, m_{iB}, m_{iC} - масса i -ой фракции крупности (класса), находящейся в смесителях А, В, С соответственно;

f_{iA}, f_{iB}, f_{iC} - масса i -ой фракции крупности (класса) на входном канале смесителей А, В, С соответственно;

τ_A, τ_B, τ_C - время пребывания в определенном смесителе;

b_{ij} - функция разрушения, которая определяет переход материала из j -го класса в i -ый крупностный класс (класс крупности);

s_i, s_j - функция отбора, которая характеризует скорость разрушения i -го и j -го класса крупности соответственно.

Из системы (1) видно, что если значение массы фракции в каждом из смесителей еще возможно подвергнуть сравнению с реальными показателями на основе измерения массы загружаемой руды, то коэффициенты функции разрушения и отбора, которые несут в себе значительный вычислительный смысл, возможно получить лишь при помощи проведения анализа состава поступающего сырья и экспериментов в процессе измельчения. Собственно, в данной работе и производится попытка разработки альтернативного способа получения значения этих коэффициентов на основе учета множества наборов данных о процессе. Это приводит к появлению модели, отвечающей за выбор коэффициентов основной модели, что влечет за собой сложности при эксплуатации, озвученные выше. К тому же, и значение показателя времени пребывания материала в каждом из смесителей необходимо будет подвергать корректировке, так как в зависимости от свойств руды и состояния мельницы, получение требуемого класса крупности будет происходить за разное время, а значит и распределение материала по областям внутри мельницы будет непостоянным, что не учтено в представленном алгоритме.

В [67] осуществляется разработка алгоритма построения математической модели шаровой мельницы с целью подбора ее оптимальных конструктивных параметров под конкретные условия функционирования. С использованием описания гидродинамики потоков, проходящих в мельнице, строится обобщенная модель, представленная на рисунке 3, которая представляет собой комбинацию зон смешения и вытеснения рудного материала, с учетом возможных неоднородностей в потоках, к которым относятся области застоя и потоки рецикла.

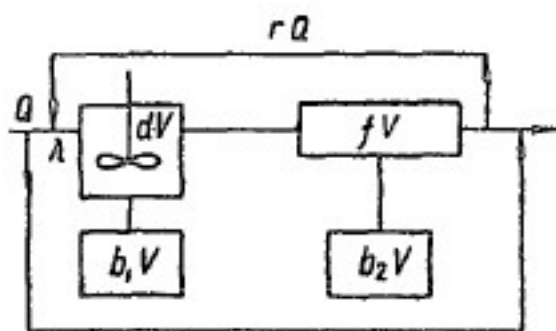


Рисунок 3. Общий вид структуры потока в разрабатываемой модели шаровой мельницы

В представленной модели параметры Q – массовый расход; V – массовая загрузка; b_1, b_2 – доля объема зоны измельчения, занимаемая застойной зоной, присоединенной к зоне смешения; r – доля потока, занимаемая внутренним рециклом; d, f – доли объема зоны измельчения, занимаемые идеальным смешением и вытеснением ($d + f = 1$). Функционирование данной модели осуществляется в соответствии с системой (2):

$$\begin{cases} C_{\text{вых}} = C_{\text{вх}} \frac{\lambda^2 F + (1 - \lambda)(\lambda + r(1 - F))}{\lambda + r(1 - F)}, \\ F = \frac{\lambda + r}{\lambda + r + k_1(1 - b_1)t_1} e^{-k_2 t_2 \frac{1 - b_2}{\lambda + r}}. \end{cases} \quad (2)$$

где $C_{\text{вх}}$ – содержание недомолотого продукта на входе в мельницу, $C_{\text{вых}}$ – содержание недомолотого продукта на выходе из мельницы, λ – доля потока, проходящего через последовательно расположенные зоны смешения и вытеснения, $k_1 t_1 (k_2 t_2)$ – произведение константы скорости измельчения на время измельчения в зоне смешения (вытеснения).

Несмотря на отсутствие в описании физических, логических или математических ошибок, применение данной модели возможно лишь в целях проектирования и первоначального расчетного приближения параметров работы агрегата. Причиной тому является наличие в уравнении, описывающем движение материала и объем выходной продукции, таких параметров как константа скорости

измельчения, которая является табличным значением и подбирается под конкретные условия, учет времени измельчения в каждой отдельно взятой зоне, что является достаточно нестационарным значением. Далее в [67] производится оценка требуемой загрузки мелющих тел, которыми являются шары. Она производится путем оценки суммарной площади тел помола, однако распределение их по размерам также не является постоянным. Динамика изменения данного параметра в значительной степени зависит как от параметров поступающего на переработку материала, так и от состояния самого объекта.

Указанные параметры в процессе функционирования могут в значительной степени изменяться ввиду стохастичности возникающих возмущений, что приводит к необходимости их корректировки, сложность проведения которой уже была озвучена ранее. Данный факт делает затруднительным применение подобной модели при функционировании реального объекта для формирования прогнозных значений выходных параметров.

1.3.2. ПОДХОД К ПОСТРОЕНИЮ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ НА ОСНОВЕ АППАРАТА ЛИНЕЙНЫХ ПЕРЕДАТОЧНЫХ ЗВЕНЬЕВ

Еще одним методом описания режимов работы технологических объектов, их динамики на основе данных промышленной эксплуатации является использование классического аппарата линейных передаточных звеньев [12,13,14,25,26,27,68,69,70].

Основными направлениями использования моделей на основе аппарата передаточных звеньев являются исследовательские и экспериментальные работы по изучению свойств объекта, его динамики при разработке систем управления. Так в [69] осуществляется разработка системы управления одним из агрегатов рассматриваемого технологического процесса – магнитного сепаратора, с целью стабилизации содержания магнетитового железа в концентрате на выходе. С этой целью производится построение модели агрегата на основе технических

параметров его составляющих частей. В итоге, модель системы управления магнитным сепаратором приобретает схематичный вид, представленный на рисунке 4.




Рисунок 4. Пример схемы модели системы регулирования содержания магнетитового железа в концентрате

При осуществлении процедуры моделирования, авторами были получены результаты, подтверждающие правильность проведенной процедуры, что выражается в функционировании модели системы управления с достижением целевых значений по показателям качества.

Однако, стоит отметить, что данная модель позволяет только экспериментально оценить выбранный подход. Ее применение в производственном процессе затруднительно и не позволит обеспечить достижение показателей качества с течением времени без реализации дополнительных функционалов, что, собственно, и подтверждается дальнейшими исследованиями авторов [68,70]. Это обусловлено тем фактом, что для расчета параметров блоков (например, контура регулирования тока статора асинхронного привода барабанного сепаратора по каналу напряжение на обмотке – ток) используются такие технические характеристики, значения которых с течением времени изменяются (3):

$$\left\{ \begin{array}{l} W_{U_i}(p) = \frac{k_i}{T_i p + 1}, \\ k_i = \frac{1}{R_s + \left(\frac{L_m}{L_R}\right)^2 \cdot R_R}, \\ T_i = k_i \cdot \left(L_s - \frac{L_m}{L_R}\right)^2. \end{array} \right. \quad (3)$$

где k_i — коэффициент передачи, А/В; T_i — постоянная времени, с; R_s , R_r — сопротивление обмотки статора и ротора соответственно, Ом; L_s , L_r — индуктивности обмоток статора и ротора соответственно, Гн; L_m — взаимная индуктивность обмоток, Гн.

Такие параметры, как сопротивления обмоток особенно подвержены некоторому изменению, так как в процессе функционирования наблюдается нагрев данных обмоток, что вызывает за собой изменение и индуктивной составляющей.

Эти, на первый взгляд, незначительные изменения параметров, способны оказывать достаточное влияние на функционирование агрегатов, особенно стоит учесть, что барабанные магнитные сепараторы зачастую функционируют группой, называемой «батарея». То есть один и тот же поток пульпы подается на несколько сепараторов, а их выход затем вновь объединяется. И управление, как правило, осуществляется сразу всей батареей, по среднему. В подобных условиях даже указанные небольшие расхождения параметров будут оказывать существенное влияние на выходные показатели процесса.

Еще одним примером является работа [71], где осуществляется разработка эффективной системы управления таким важным объектом передела, как мельничный агрегат. Отличием, от рассматриваемого процесса, является то, что рассматриваются мельницы мокрого самоизмельчения (ММС). Это привносит некоторые особенности, однако, не влияет кардинально на суть. Автор неоднократно отмечает, что подтверждается и в [10,12,14,72,73] - модели на основе

физико-химических и кинематических принципов функционирования агрегатов не приживаются на производстве по причине сложности процесса разработки за счет необходимости учета множества нестационарных изменяющихся параметров – то есть возможно разработать качественную модель на отдельно взятый режим работы и под конкретные характеристики сырья, сложности эксплуатации с точки зрения производственного персонала. Поэтому в данный момент самым популярным решением является управление «по среднему». Значимым мнение автора представляется по той причине, что он является непосредственным работником инженерной службы обогатительной фабрики и как никто другой ознакомлен с ситуацией «в поле». В [71] рассматривается создание эффективной системы управления измельчительным агрегатом посредством разработки наблюдателя и регулятора состояния, являющейся эффективной надстройкой над моделью ММС, разработанной с использованием аппарата линейных передаточных звеньев, обеспечивающей адаптацию параметров в зависимости от измеряемых технологических сигналов, что представляется наиболее приемлемым подходом в условиях производства. Структурная схема управления представлена на рисунке 5. Все же стоит заметить, что применимо к рассматриваемой задаче, потребуется приложить значительные усилия по тиражированию модели на каждый из агрегатов технологической секции обогащения железорудного сырья, с учетом всего перечня управляющих воздействий и измеряемых сигналов, причем для всех них необходимо будет разработать первичные, даже не слишком точные модели, что придаст разрабатываемому функционалу по прогнозированию содержания железа в выходном продукте значительный «вес». При эксплуатации инженер будет вынужден вникнуть достаточно глубоко в методику работы системы для обеспечения возможности ее диагностики.

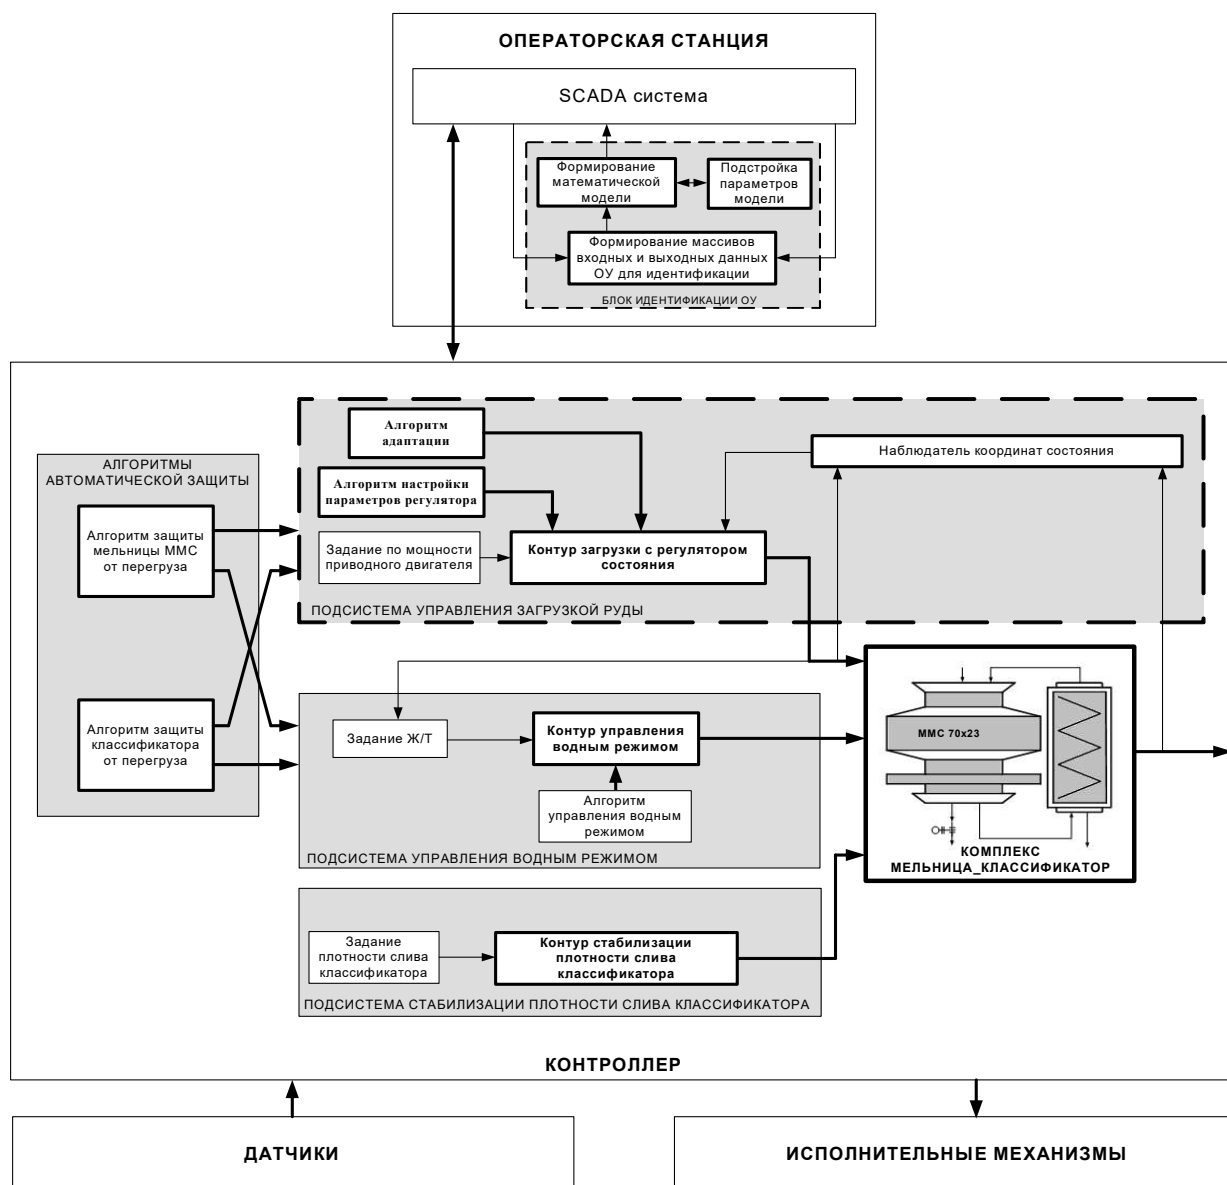


Рисунок 5. Структурная схема управления комплекса мельница-классификатор

Обобщая вышесказанное, можно отметить, что применение моделей на основе аппарата линейных передаточных звеньев допустимо при выполнении исследовательских задач, проектировании системы управления для первоначальной оценки ее функционирования. При функционировании данных моделей в «живой» системе управления, они позволяют обеспечивать работу «по-среднему», что зачастую удовлетворяет требования производителей, которые в отсутствии иного аппарата, положительно воспринимают подобный метод.

Однако в данных системах возникает потребность корректировки коэффициентов моделей, что позволяет использовать их в качестве базиса в тех методах реализации управления, где планируется реализация какого-либо алгоритма адаптации параметров модели. Возможным решением данной задачи может являться создание дополнительного функционала, как в [71], или же реализация некоторого набора моделей для различных режимов работы объекта [17,19,20,21,28,31,68]. Но в этом случае эффективность системы сильно зависит от дискретности шага при создании моделей, т.е. насколько далеко в плане отличия свойств отстоят друг от друга различные модели. Излишнее «усреднение» при настройке может привести к нечувствительности модели на невысокие по амплитуде возмущения. Иначе же это приводит к проблеме размерности базы моделей.

Дополнительно стоит учесть, что для осуществления процедуры идентификации данным методом возможно проведение как пассивного эксперимента - использования ретроспективных данных работы объекта, так и активного - подачи тестового воздействия в канал управления, однако, для этого необходимо обеспечить определенные условия идентификации, такие как разомкнутое состояние контура управления или установившееся состояние системы и управление только по одному из каналов и т.д. Все это приводит к необходимости вмешательства в технологический процесс, что не является предпочтительным для любого вида производства. И при первом, и при втором типе эксперимента у данного аппарата имеется еще один значительный недостаток – эксперимент будет проведен лишь в одном из режимов работы агрегата, что не позволит оценить характер изменения параметров при наступлении иных условий и ситуаций, возвращая исследователей к решению задачи адаптации.

1.3.3. ПОДХОД К ПОСТРОЕНИЮ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ НА ОСНОВЕ АППАРАТА РЕГРЕССИОННОГО АНАЛИЗА

Достаточно распространенным методом ретроспективной идентификации данных функционирования является регрессионный анализ. Его преимуществом

является возможность проведения процедуры пассивного эксперимента для построения модели без необходимости вмешательства в ход технологического процесса с целью создания особых условий.

В процессе построения статистической модели технологического агрегата для полинома определенного вида, например (4), исходя из выбранных независимых переменных $x_1 \dots x_n$, представляющих собой входные переменные и их комбинации, осуществляется нахождение коэффициентов регрессии $b_0 \dots b_n$ с применением оптимизационного алгоритма, позволяющего получить моделируемое значение зависимой переменной Y , минимизирующее величину ошибки (5), что обеспечивает качество получаемого прогноза.

$$Y(x) = b_0 + b_1 x + b_2 x^2 + b_3 x^3 + b_3 \frac{1}{x} + \dots + b_n x, \quad (4)$$

$$E = (Y_{\text{реальн}} - Y_{\text{модельн}}), \quad (5)$$

Однако на возможность применения данного способа идентификации для разработки моделей агрегатов с целью их использования в реальных САУ влияют ограничения, лежащие в алгоритме его реализации и принципах, условиях функционирования технологических объектов. И одним из главных является общепринятое требование о проведении экспериментов (получении данных) на разомкнутой контуре управления – в условиях отсутствия обратной связи для получения «чистых» данных по функционированию идентифицируемого объекта [74,75,76,77,78,79]. Проведение эксперимента на объекте управления без обратной связи обеспечивает выполнение еще одного требования к независимым переменным регрессии $x_1 \dots x_n$ – отсутствия мультиколлинеарности, заключающегося в недопустимости корреляции между входными параметрами [80,81]. Данное условие также сложно соблюсти без разрыва контура управления, поскольку в системе управления реальным объектом чаще всего управляющие воздействия также зависят друг от друга, например, соотношение твердое:жидкое,

регулирующее соотношения подаваемой руды и воды в шаровую мельницу в рассматриваемом технологическом процессе.

Зачастую, пренебрегая указанными требованиями, данный математический аппарат все же применяется для идентификации промышленных агрегатов. Полученные модели достаточно сильно усредняют характер функционирования объектов, что, однако, может удовлетворять поставленным задачам. Но стоит заметить, что для адекватного функционирования подобных моделей с течением времени зачастую реализовываются различные механизмы адаптации. Связано это с тем, что коэффициенты уравнения регрессии, найденные для определенных условий, со временем оказываются неверны, так как при протекании реальных технологических процессов наблюдается стохастические изменения параметров самого объекта, внешних неизмеряемых возмущений [25,26,27,48,80,81]. Еще одним недостатком функциональной зависимости, полученной на основе регрессионного анализа, является невозможность учета различной динамики по каналам управления, т.е. возможной разницы во времени переходных процессов, суммарный вклад которых формирует итоговое управляющее воздействие на выходную координату. Данное обстоятельство довольно часто встречается в реальных объектах и затрудняет процесс разработки их модели [25,26,27,28].

Но к наиболее сложным задачам идентификации с применением рассматриваемого аппарата можно отнести построение нелинейной многофакторной регрессии. Функционирование подавляющего большинства реальных технологических агрегатов возможно качественно описать только нелинейными функциями многих переменных, являющихся управляющими входами объекта [74,80,81]. Для реализации данной процедуры необходимо решить перечень задач, осуществив выбор методики статистической предобработки полученных данных, структуры модели, метода подбора коэффициентов, оценки качества полученной модели и т.д. С одной стороны, решение данных задач на текущий момент времени не представляется абсолютно невыполнимым, с другой

стороны – получаемая в итоге модель представляет собой сложную нелинейную функцию многих переменных, позволяющую достаточно точно описать закон функционирования промышленного агрегата, но требующую для непрерывной работы значительных вычислительных мощностей. А самое главное – механизм адаптации или полной коррекции модели потребует от обслуживающего персонала значительных знаний в области статистики, методики работы и построения модели, что достаточно часто приводит к отказу от данных моделей в условиях производства по причине высоких трудозатрат на поддержание их функционирования.

Приведенные примеры способов идентификации технологических объектов, когда применяются модели, базирующиеся на подробном описании химико-физических, гидродинамических процессов, происходящих в агрегате, аппарате линейных передаточных звеньев и статистическом методе регрессионного анализа, являются достаточно типовыми. Это позволяет утверждать, что ранее высказанное предположение о недостатках проанализированных широко распространенных аппаратов моделирования, затрудняющих их длительное и качественное применение в производстве, верно, что, однако, не говорит об их категорической неприемлемости. Однако основным направлением исследований стала разработка методики создания модели производственной цепочки обогащения железорудного концентрата, способной обеспечивать качественную работу прогнозирующего функционала в широких границах изменения технологических показателей и реализация алгоритма, позволяющего применять его в условиях непрерывного режима работы с минимальным отвлечением персонала от основных производственных задач.

1.4. АНАЛИЗ ВОЗМОЖНОСТИ ИСПОЛЬЗОВАНИЯ АППАРАТА ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ (ИНС) ДЛЯ РАЗРАБОТКИ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ

Основываясь на анализе примеров применения классических методов моделирования с использованием различных математических аппаратов, и выявленных недостатков подобных способов, к которым относится линеаризация описываемых функциональных зависимостей, относительно длительное время расчета выходного сигнала при усложнении аппроксимирующей функции, необходимость корректировки моделей при значительном изменении амплитуд входных сигналов и сигналов возмущений, закономерным является вывод, что практически приемлемыми могут быть только модели, обладающие робастностью к изменению некоторых из параметров. Обеспечить это для нелинейных систем достаточно сложно.

Поэтому перспективным выглядит применение в данном контексте аппарата искусственных нейронных сетей (ИНС). В представленных условиях процесса обогащения железорудного сырья, усложняющихся отсутствием единого подхода к моделированию, общепринятых структур и видов моделей большинства объектов технологического цикла, представляющих собой агрегаты со значительными нелинейностями, различной инерционностью по каналам управления, стохастичностью изменения как самого процесса, так и ответных реакций на эти воздействия, различием характера протекания операции переработки в пределах объекта, применение подхода построения непараметрических моделей на базе аппарата ИНС является оправданным [44,82]. Нейронные сети, обладая способностью к аппроксимации сложных зависимостей и учета нелинейностей за счет нелинейных функций активации в нейронах, позволяют получить модели с высокими показателями качества в условиях большого числа ограничений [83]. Дополнительно стоит заметить, что использование нейросетевого аппарата является одним из перспективных подходов при А разработанные с использованием поагрегатного принципа модели затем будут соединены согласно

хода технологического процесса, что обеспечит последовательное моделирование этапов обработки сырья, и, соответственно, возможных изменений показателей.

Стоит заметить, что нейронные сети в последние годы нашли широкое применение при решении задач идентификации по следующим причинам:

- нейронные сети - достаточно работоспособный аппарат аппроксимации и экстраполяции функций. Особенно это справедливо при наличии достаточно большого объема данных с хорошей репрезентативностью функциональных зависимостей для выполнения обучения и верификации нейронных сетей, и грамотно проведенной процедуры синтеза нейронной сети;
- наличие множественных нелинейных функций активации в многослойной нейронной сети, обеспечивающих эффективную реализацию достаточно гибких нелинейных преобразований. Это важно для решения задач с существенными нелинейностями, для которых традиционные подходы пока не дают практически реализуемых решений;
- методы и алгоритмы синтеза и обучения нейронных сетей инвариантны по отношению к размерности пространства входных и выходных сигналов.

Большая часть прикладных задач может быть сведена к реализации некоторого сложного функционального многомерного преобразования. В общем виде эта задача в настоящее время еще не решена, однако во всех известных случаях может быть найдено частное решение [33,34,35,37,38,39]. Достаточно важным свойством нейронной сети является способность к обучению и к обобщению полученных знаний. Выявляя зависимости и закономерности в процессе обучения, она обобщает накопленную информацию и реализует аппроксимирующие свойства на ранее неизвестных примерах.

В задаче идентификации нейронная сеть играет роль универсального аппроксиматора функции от нескольких переменных, реализуя нелинейную функцию:

$$Y = f(X), \quad (6)$$

где X - это входной вектор, а Y - выходной показатель, зависимый от нескольких переменных.

Значительным количеством работ доказано, что ИНС являются универсальным аппроксиматором, способным работать с функциями многих переменных. Так в работах [84,85] была показана возможность представления многочлена многих переменных с помощью нелинейного многочлена многих переменных, линейных операций и суперпозиций. Затем в серии работ [86,87,88] было показано, что при применении ИНС аппроксимация сложных зависимостей возможна с использованием многослойной сети с минимум одним скрытым слоем и достаточным количеством нейронов в нем, обоснованным в [89,90]. Обобщением данной серии работ стало доказательство в [91,92], показавшее, что от функции активации нейронов в скрытом слое требуется только нелинейность.

Несмотря на значительное количество уже известных практических приложений искусственных нейронных сетей, каждое новое практическое применение ИНС требует проведения конкретных исследований по определению структуры нейронной сети, условий ее обучения и обеспечению требуемого времени сходимости алгоритма обучения [19,20,21,33,92,93]. Для более точного построения модели в нейросетевом базисе необходимо как можно полнее проанализировать свойства объекта, выделить входные сигналы, влияющие на технологический процесс и необходимые для целей управления, так как тип и структура используемой нейросети во многом диктуется поставленной задачей. Количество скрытых слоев и количество нейронов в слое определяют структуру многослойного персептрона и должны быть найдены при синтезе нейросетевой системы обработки информации [19,20,21,33,34,35,93,94,95]. Настройка параметров многослойного персептрона может быть выполнена с помощью одного из многочисленных алгоритмов нелинейной оптимизации. Широкое распространение получил алгоритм обратного распространения ошибки и его модификации [37,38,39].

В вопросе выбора структуры нейронной сети необходимо опираться на априорные знания об объекте, модель которого разрабатывается. При этом необходимо иметь ввиду следующие особенности: возможности сети возрастают с увеличением числа нейронов сети, плотности связей между ними и числом слоев; введение обратных связей наряду с увеличением возможностей сети поднимает вопрос о динамической устойчивости сети; сложность алгоритмов функционирования сети, введение нескольких типов синапсов способствует усилению мощности нейронной сети [33,34,35]. Однако при этом увеличивается количество параметров нейронной сети и длительность процесса обучения, что относится к негативным моментам. Система или модель должна обладать возможностью быстрой подстройки при изменении состояния среды [19,20,21,33,34,35,93,94].

Так как проблема синтеза нейронной сети сильно зависит от решаемой задачи, дать общие подробные рекомендации затруднительно. В большинстве случаев оптимальный вариант получается на основе интуитивного и экспериментального подбора, хотя в литературе приведены доказательства того, что для любой задачи существует нейронная сеть, которая может реализовать [33,34,35,86,87,88,89,90,91,92].

Доказательством в пользу эффективности и актуальности построения математических моделей с использованием технологий, учитывающих опыт оператора и статистические данные для целей производства, является реализованный совместный проект Магнитогорского МК и компании Yandex. На основе статистики, предоставленной предприятием, подразделением YandexDataFactory с помощью технологий машинного обучения была реализована математическая модель, позволяющая специалистам кислородно-конверторного цеха заранее оценить свойства и химсостав производимой продукции посредством анализа исходного состава и массы элементов. В итоге это позволило им прогнозировать необходимый расход ферросплавов и добавочных материалов для

получения требуемого продукта [96]. Однако, как было уже сказано ранее, подобная статистическая модель даже при высоком качестве работы способна только показать проблему возможного выхода за рамки технологии или получения продукта, со свойствами, отличающимися от заданных, но не объяснить причину данного изменения, поскольку не привязана к протеканию процесса.

Работоспособность схожего по функционалу подхода представлена в рамках работы [63], где в ходе экспериментов были разработаны и протестированы модели технологических объектов на основе аппарата ИНС. Модели разрабатывались для агрегатов технологического процесса нефтеперерабатывающего завода. В итоге, были получены нейросетевые модели, показывающие довольно высокое качество работы. Но стоит отметить, что технологический процесс получения нефтепродуктов, не смотря на наличие большого числа нелинейных многопараметрических объектов, отличается высокой стабильностью процессов, отсутствием значительных стохастических возмущений. Данное обстоятельство обусловлено методикой проектирования подобных технологий с учетом высоких требований по безопасности.

Возможность и целесообразность применения аппарата ИНС непосредственно для построения моделей агрегатов технологического процесса обогащения представлена в цикле работ Зарубина М.Ю., примером которого является [97]. В ходе работы производится построение модели мельничного агрегата в условиях нестабильности входных параметров и состояния объекта. Разработанная модель показывает зависимость энергопотребления от различных уставок по каналу «жидкое:твердое» для некоторого набора типов руды, что в дальнейшем служит инструментарием для построения САУ с целью энергоэффективного управления измельчительным комплексом.

Возможность же применения именно декомпозиционного подхода при разработке нейросетевых моделей технологических агрегатов представлена в работах авторов Сараева П.В, Блюмина С.Л., Галкина А.В. [94,98,99].

Перспективность данного подхода представляется в его способности не только выполнить качественный прогноз развития хода технологического процесса, но и отобразить возможные изменения внутренних переменных, которые характеризуют аспекты работы некоторых отдельно взятых агрегатов. Это, в свою очередь, позволит оператору не только увидеть момент наступления изменений в ходе выполнения процесса обогащения концентрата, но и выделить причину наступления данных изменений. Это является весьма полезным для стабилизации показателей качества продукта на требуемом уровне по сравнению с общей моделью, когда оператор может лишь только увидеть изменения в выходном продукте, но не видит причину. Для понимания он должен обладать большим опытом для анализа ситуации и выявления причин ее возникновения.

ВЫВОДЫ ПО ГЛАВЕ 1

Анализ технологического процесса обогащения железорудного концентрата на горно-обогатительном комбинате показал, что данный процесс является достаточно сложным с точки зрения реализации единой системы автоматизированного управления. Это обусловлено широким перечнем причин. К ним можно отнести нестабильность физико-химических свойств поступающего на переработку сырья, значительное число сложных, многопараметрических технологических агрегатов, нелинейность функциональных зависимостей, характеризующих их. Существующая система управления предполагает наличие отдельных локальных контуров, работающих в режиме поддержания и стабилизации лишь одного выходного параметра, что может усложнять решение поставленной технологической задачи последующим контурам. В ходе реализации управления отсутствует возможность непрерывного оперативного контроля свойств поступающей руды и качественного анализа выходного продукта по причине сложности проведения данной процедуры и отсутствия датчиков, обеспечивающих в течении длительного времени достоверные показания измерения содержания Fe.

Указанные факторы значительно усложняют оператору задачу управления секцией обогащения, результатом которого должен являться выходной продукт с достаточно узким интервалом возможного разброса показателя качества (процентного содержания железа – {Fe, %}). Для достижения целевого значения, оператор должен обладать значительным опытом, достаточно глубоким пониманием физики и механики процесса, аспектов работы имеющегося оборудования, способностью интуитивно предугадывать возможные последствия изменения типа поступающего материала и заблаговременно корректировать управляющие переменные для недопущения ситуации выпуска бракованной продукции. К тому же, оператор вынужден осуществлять регулирование в рамках требований по эффективности технологического процесса, что предполагает

невозможность реализации единого перечня уставок для непрерывной работы оборудования.

Для решения актуальной задачи повышения эффективности производственного процесса обогащения железорудного концентрата предлагается разработать прогнозирующую систему, способную на основе анализа текущих значений технологических показателей отобразить возможный ход развития процесса с достаточно высокой точностью. Это обеспечит полноту и своевременность предоставляемой оператору информации об изменении качественных показателей хода технологического процесса, об отклике на смену уставок. При этом в процессе внедрения и функционирования системы не возникнет необходимости вмешательства в технологический процесс, модернизации оборудования. В результате, у оператора появится возможность оценить предполагаемое изменение выходного параметра - содержания железа в концентрате, с высокой степенью точности. Наличие подобного инструмента даст возможность оператору поддерживать значение итогового показателя в более узких границах, нежели технологические допуски. В результате оператор сможет сузить рабочие области изменения управляющих переменных. Это, в свою очередь, приведет к снижению неэффективного использования энергоносителей, повышению значения показателя удельной производительности и в целом – эффективности производственного процесса. Для реализации данного функционала предполагается:

- разработать, с учетом требований технологического процесса, структуру реализуемой прогнозирующей системы, создать алгоритм ее функционирования;
- разработать алгоритм взаимодействия, актуализации, адаптации моделей технологических агрегатов;
- на основе аппарата ИНС с использованием ретроспективной информации разработать математические модели технологических агрегатов с высокими

показателями качества функционирования, руководствуясь, в ходе создания моделей, поагрегатным принципом, заключающимся в создании отдельных моделей, описывающих различные технологические этапы;

- выполнить интеграцию разработанных нейросетевых моделей согласно хода технологического процесса, оценить качество работы набора моделей;

- реализовать схожий функционал с использованием одного из классических методов, провести сравнение показателей качества работы систем в нейросетевом базисе и с использованием классических моделей;

- разработать программное обеспечение, реализующее основные научные результаты, полученные в работе;

- разработать систему коррекции уставок локальных контуров управления, базирующуюся на функционировании модели прогноза содержания Fe в итоговом концентрате.

ГЛАВА 2. РАЗРАБОТКА АЛГОРИТМА СОЗДАНИЯ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ ПРОЦЕССА ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО КОНЦЕНТАРА НА ОСНОВЕ РЕТРОСПЕКТИВНОЙ ИНФОРМАЦИИ

2.1. АНАЛИЗ ТЕХНОЛОГИЧЕСКОЙ СХЕМЫ ПРОИЗВОДСТВА И СИГНАЛОВ ПЕРЕДЕЛА ОБОГАЩЕНИЯ ЖЕЛЕЗОРУДНОГО СЫРЬЯ

Первым этапом создания прогнозирующей системы стал процесс разработки схемы моделей технологических агрегатов. В качестве примера была выбрана одна из секций обогатительной фабрики СГОКа, технологический процесс которой, как уже отмечалось ранее, является в достаточной степени типовым для данного вида производства. В ходе работы был осуществлен анализ технологии производства, перечня функционирующих в ходе переработки сырья агрегатов и измеряемых технологических сигналов, поскольку именно с их помощью предполагается дальнейшая разработка моделей. В результате чего было выявлено наличие 34 основных поагрегатных этапа переработки железорудного сырья, причем в начале цикла обогащения сырье поступает на 2 параллельно работающие полусекции, выходной продукт которых, затем, объединяется в зумпфах и обрабатывается единым потоком. Ввиду особенностей процесса, в ходе переработки имеет место повторение некоторых технологических операций, таких, как, например, измельчение в шаровых мельницах, мокрая магнитная сепарация и другие. Отдельно необходимо упомянуть, что некоторые этапы переработки выполняются группой объектов, например, классификация батареей гидроциклонов или магнитная сепарация при помощи группы агрегатов. Поэтому, при рассмотрении подобных объектов, было принято решение оценивать итоговые входные\выходные показатели, измеряемые в точках объединения потоков, так же, как это осуществляется на предприятии. Поагрегатная схема этапов представлена ниже на рисунке 6.

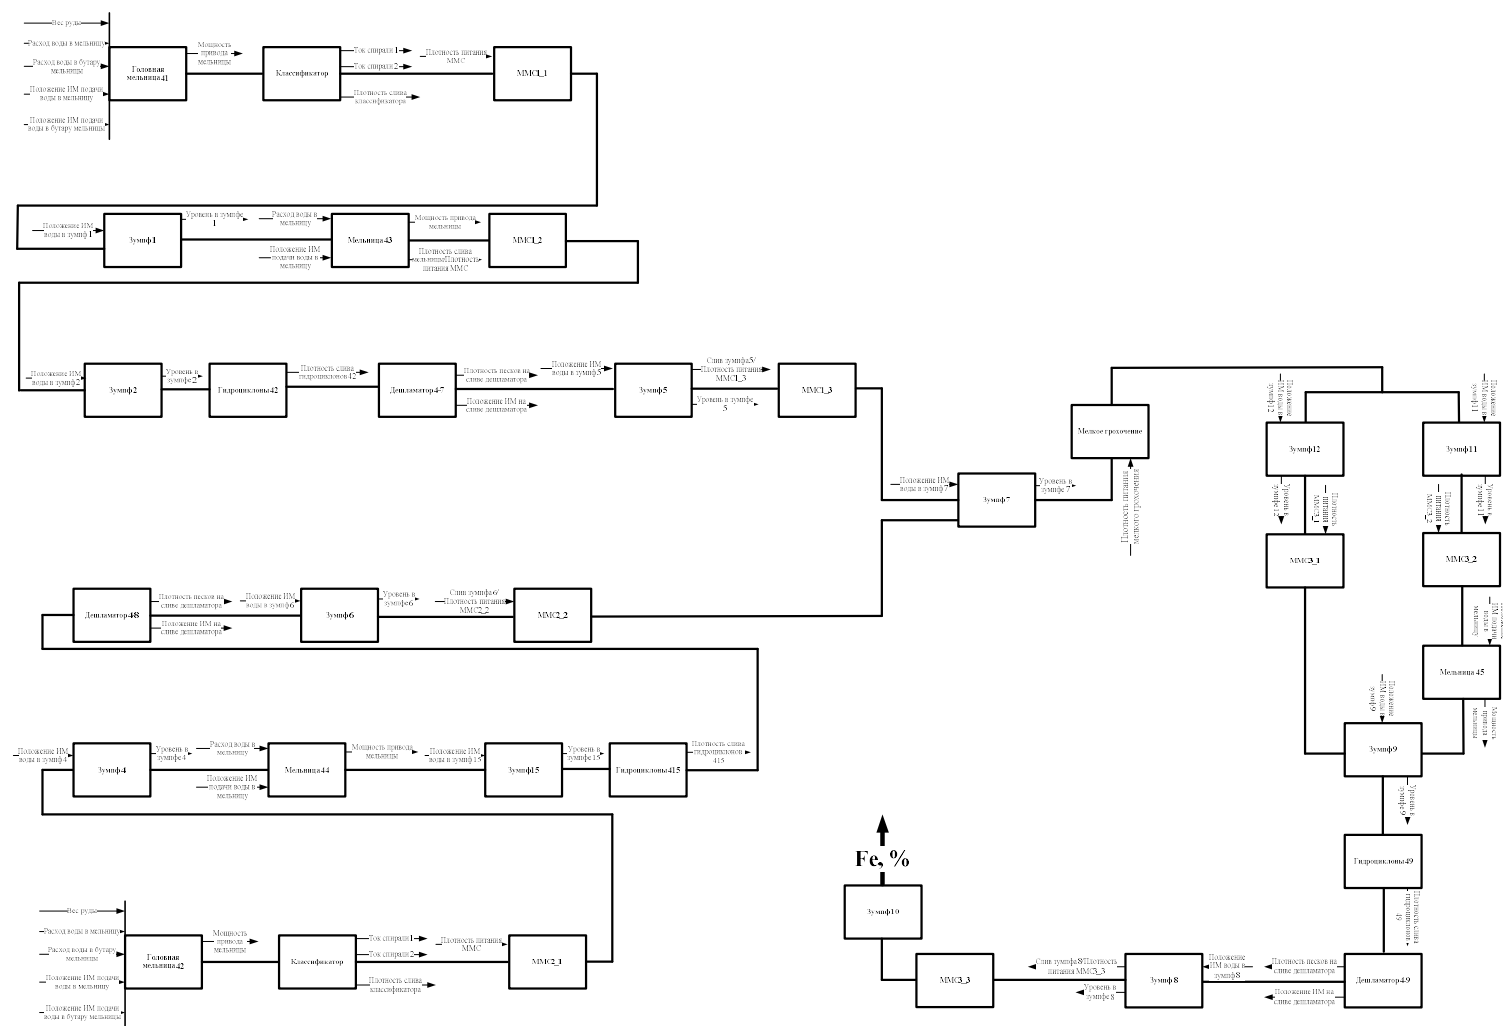


Рисунок 6. Поагрегатная схема производственной секции

Затем были проанализированы технологические агрегаты по выполняемым функциям и степени сложности процессов, происходящих при их работе. Поскольку использование для моделирования практически линейных зависимостей аппарата ИНС является излишним. В итоге, некоторые из объектов были объединены при составлении перечня моделей, то есть каждая из моделей приобретала более укрупненный вид, описывающий происходящее на отдельном этапе передела производства.

После чего были проанализированы измеряемые в ходе функционирования объектов передела технологические показатели, значения которых предоставляются оператору на экране кадра SCADA и доступны для изменения, а также подвергаются архивированию. Данные требования обусловлены тем, что существуют значительное число технологических сигналов, носящих информативный характер, необходимых для анализа функционирования оборудования или индикации наличия аварийных ситуаций, однако, они не имеют значительного влияния на качественные показатели процесса. Оператор имеет доступ к значениям данных показателей, но в большинстве случаев ведет их наблюдение и оперирует ими только в ситуации пуска/останова оборудования и при возникновении предаварийных/аварийных ситуаций.

Требование по необходимости архивирования обусловлено необходимостью извлечения массивов данных за значительные временные промежутки для оценки возможности их использования при моделировании, осуществления формирования выборок из данных, характеризующих различные производственные ситуации, за разные периоды работы оборудования с изменением свойств как сырья, так и оборудования – иными словами для обеспечения требования репрезентативности выбранных данных и возможности изменения периода выборки в случае необходимости очистки данных.

В ходе анализа было выявлено 69 параметров, удовлетворяющих озвученным выше требованиям. Однако не все из них могли быть использованы в ходе процесса

моделирования. А точнее – их использование не представлялось целесообразным, поскольку они являлись по своей природе дублирующими для некоторых из сигналов, как например сигнал объема расхода воды в бутару шаровой мельницы и сигнал степени открытия исполнительного механизма подачи воды в бутару шаровой мельницы. Поэтому, для снижения влияния эффекта мультиколлинеарности, было принято решение об исключении данных показателей из дальнейших экспериментов [80,81].

Следующим этапом стал выбор результирующего сигнала для каждой из моделей. Было принято решение таковым выбрать сигнал плотности пульпы, что позволяет осуществить разбиение технологической цепочки на последовательные этапы. Это обусловлено тем фактом, что на предприятии в ходе выполнения процесса переработки соблюдается условие стабилизации плотностного режима, что является технологическим требованием. В результате произведенных процедур был получен общий принцип объединения агрегатов и формирования схемы моделей, с которой в дальнейшем и велась работа.

Окончательный синтез схемы моделей должен был учитывать все озвученные требования и позволить объединить модели технологических агрегатов с учетом первоначальной обработки потока материала в двух параллельных полусекциях, с последующим соединением. Итоговый внешний вид схемы разрабатываемых моделей представлен на рисунке 7.

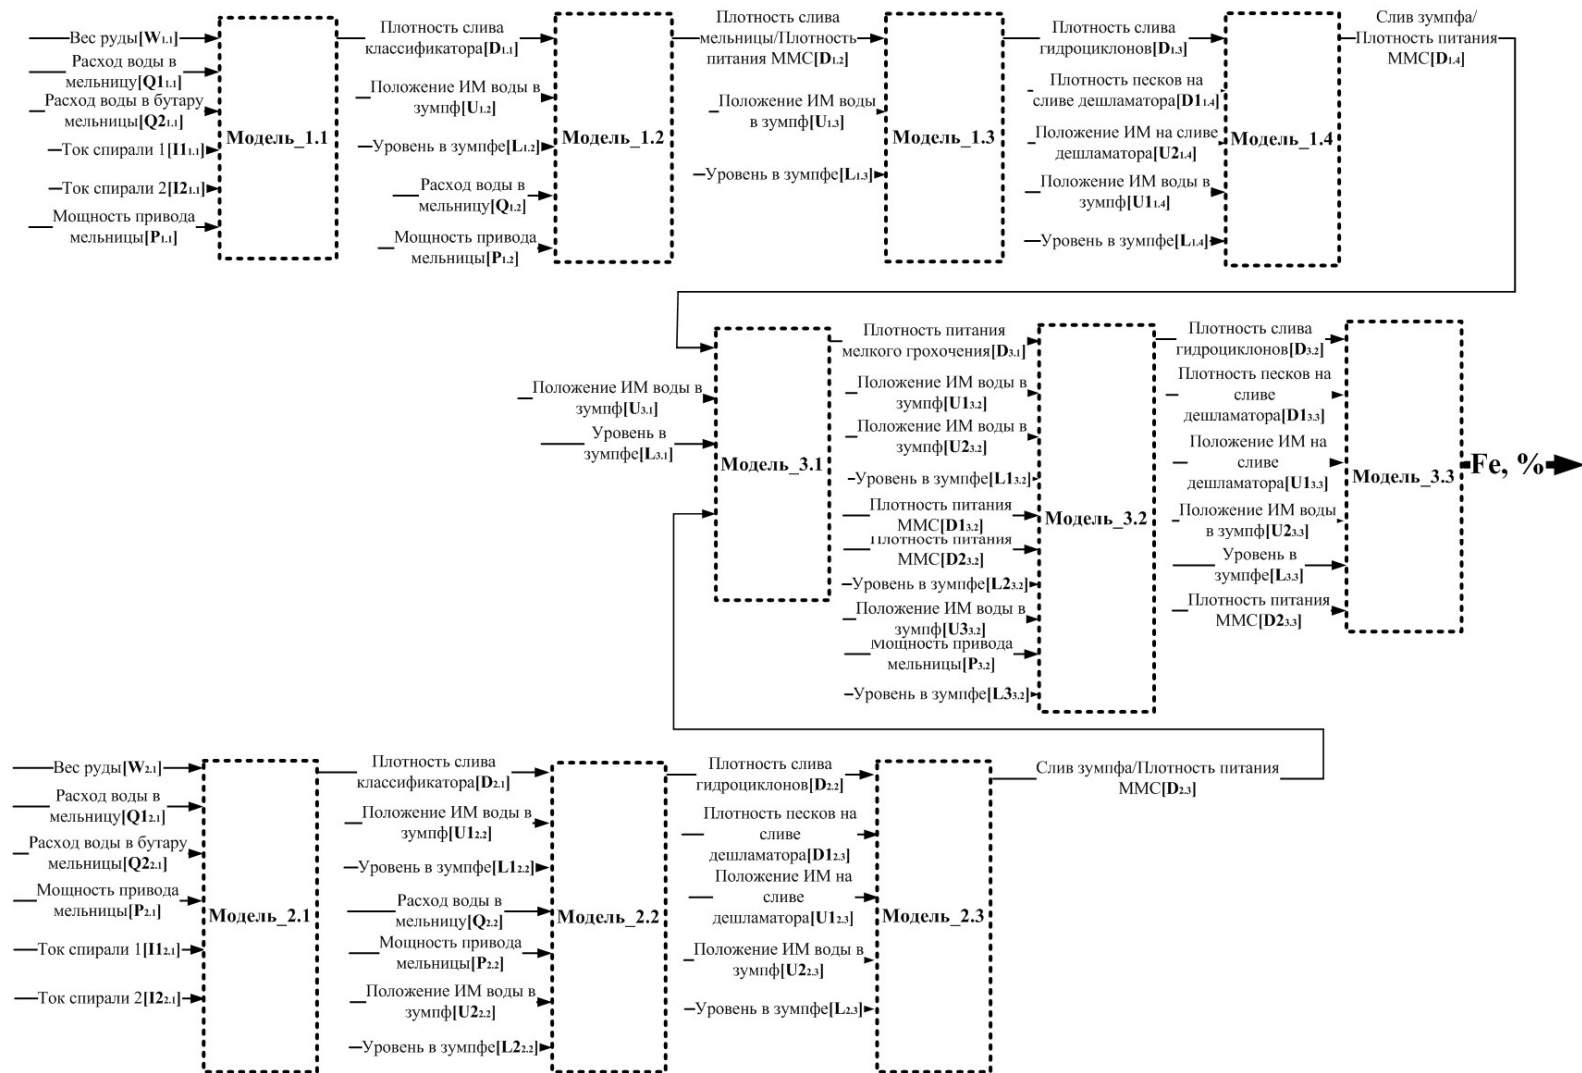


Рисунок 7. Схема нейросетевых моделей агрегатов процесса обогащения

2.2. РАЗРАБОТКА АЛГОРИТМА ПОДГОТОВКИ РЕТРОСПЕКТИВНЫХ ДАННЫХ ДЛЯ ПРОВЕДЕНИЯ ПРОЦЕДУРЫ МОДЕЛИРОВАНИЯ

После выполнения процедуры составления схемы моделей и консультаций с представителями производства на предмет ее целесообразности и возможности применения, следующим этапом работ была процедура извлечения и предобработки данных [100]. Извлечение данных происходило из архивов действующего проекта управления SCADA-системы WinCC. Первоначально извлечение данных функционирования технологической секции осуществлялось за временной промежуток порядка 15 месяцев.

Для оценки возможности применения данных была произведена их визуальная оценка, поскольку в выбранный период происходили различные ситуации остановки по производственным причинам. К ним можно отнести такие ситуации, как плановые остановки на ремонт, снижение объемов перерабатываемого сырья, в сравнении со средними показателями, отработка аварийных ситуаций с необходимостью прекращения управления по какому-либо из каналов, то есть физическое прекращение подачи материала, или же банальное отсутствие сигнала по причинам неисправностей средства измерения, канала связи и прочие причины.

С этой целью из данных требовалось удалить показания за временные периоды, соответствующие плановым ремонтам, в ходе которых значения всех извлеченных переменных находятся на уровне 0. Затем было произведено удаление явных выбросов, появляющихся по причине неисправности или временного сбоя канала обработки или передачи данных, либо же самого измерительного устройства.

Самым неоднозначным видом нестандартного характера данных стали провалы по одному из параметров или последовательно измеряемых сигналов. Дело в том, что при возникновении предаварийной или аварийной ситуации –

например завала мельницы, возможно, что для предотвращения развития события оператор прекращает или снижает подачу руды в мельницу, тем самым приближая значение данного показателя к нулевому уровню. Однако, при этом не происходит останова прочего оборудования. В графиках изменения значения переменных подобная ситуация представляет собой последовательную просадку нескольких параметров. Затем, после выхода из нестандартной ситуации, оператор возвращает значения параметров на прежний уровень требования технологии. То есть назвать данную ситуацию выбросом или периодом отсутствия измерений и исключить из выборки однозначно нельзя. Подобные ситуации крайне ценны с точки зрения поведения оборудования в граничных условиях. Поэтому проверка на наличие озвученных проблем выполнялась в ручном режиме, что значительно увеличивает время и сложность работы с данными.

В результате было принято решение об использовании в работе выборки за период, суммарно равный 5 месяцам, в течении которых наблюдалось наименьшее количество недостатков с точки зрения качества данных.

При более подробном анализе полученных данных было выявлено, что параметры обладали различной частотой дискретизации ввиду специфики процедуры измерения и актуальности обновления их значений. Значительное число параметров имело время дискретизации равное 3 или 5 секундам. Однако, некоторые параметры обновлялись 1 раз в минуту. Поэтому данное время дискретизации было принято в качестве базового. В ходе процедуры усреднения предстояло решить такие задачи, как получение среднего значения в расчете на различное число точек измерения в минуту, обработка ситуаций «выпадения» значения, когда измерение в один, конкретно взятый момент отсутствовало по причине ошибки при архивации данных. Дальнейшие работы по моделированию предполагалось проводить в среде программирования MATLAB, поэтому посредством именно этого языка была разработана программа, позволяющая

осуществить озвученные преобразования. Листинг программы для одной из переменных процесса представлен в Приложении А.

Следующим этапом процесса предобработки стало проведение процедуры нормировки данных. Необходимость проведения подобной операции была выявлена при осуществлении пробных экспериментов по моделированию с применением аппарата ИНС. Дело в том, что используемые стандартизированные функции активации в нейронах изменяются в пределах $[-1;1]$. Работа с данными, представленными в другом масштабе, искусственно занижает аппроксимационные способности нейронной сети. Поэтому было принято решение произвести масштабирование измеренных сигналов в пределах $[0;1]$, поскольку в данных не имеется отрицательной области значений. Процедура нормировки проходила по стандартному алгоритму с масштабированием относительно максимального и минимального значений величины. Подробная последовательность действий при выполнении процедуры нормировки представлена в алгоритме в Приложении Б.

После чего, перед осуществлением процедуры моделирования, была выполнена проверка распределения полученных выборок данных на нормальность, что позволяет считать полученные значения переменных случайными. Каждая переменная оценивалась посредством построения гистограммы значений, после чего производилось приведение к нормальному распределению, так как не все имеющиеся данные соответствовали этому требованию. Пример представлен на рисунке 8, где изображена гистограмма распределения значений сигнала подачи руды в шаровую мельницу.




Рисунок 8. Гистограмма распределения значений сигнала «Вес руды» в шаровую мельницу

Последующей операцией предобработки данных было осуществление процедуры их фильтрации. Как уже было озвучено, помимо основных типичных грубых недостатков промышленных сигналов, таких как отсутствие сигнала или выбросы, в них наблюдаются некоторые ошибки и погрешности измерения, искажающие реальную динамику изменения выбранного параметра и представляя неверную картину о рабочих свойствах производственных агрегатов.

Для устранения данного недостатка в работе было принято решение о необходимости применения процедуры фильтрации данных. С целью выбора метода фильтрации в ходе работы были осуществлены эксперименты, позволяющие сравнить несколько методов фильтрации сигнала и оценить возможность их применения для повышения качества работы имеющейся модели технологического процесса обогащения. Одинаковая выборка обучающих и тестовых данных, была представлена в трех видах: без фильтрации, с применением метода усреднения «скользящее среднее» и обработанная посредством сингулярно-спектрального анализа (SSA-метод)[101]. SSA-метод позволяет представить временной ряд в виде набора компонент, имеющих свой определенный вклад в формирование исходного сигнала. Затем, в результате сложения некоторого количества компонент разложения, возможно получить восстановленный сигнал, сохраняющий основные закономерности исходного, но отличающийся отсутствием определенного числа шумовых амплитуд. При проведении данного вида анализа в зависимости от задачи и цели возможно варьирование количества компонент и других параметров анализа, позволяющих влиять на качество фильтрации. Подробнее методика сингулярно-спектрального анализа представлена в работах [101,102].

Для осуществления экспериментов по выбору метода фильтрации в более короткие сроки и предотвращения взаимного влияния переменных на результаты опытов, было принято решение произвести данный анализ с использованием обобщенной модели секции обогащения, принцип построения которой представлен

в работах [46,47,48,49,50,51,52,53,54,55] и является достаточно типовым. Из большого набора исходных переменных было необходимо выбрать те, которые обладают наибольшим влиянием на один из основных качественных показателей процесса измельчения – процентное содержание железа в выходном продукте $\{Fe, \%\}$. Для этих целей был применен корреляционный анализ, который показал, что высоким уровнем корреляции с выходным параметром имеют 3 показателя – плотность слива гидроциклонов, работающих в процессе после зумпфов во второй стадии измельчения каждой из полусекций секции измельчения ($\rho_1(t), \rho_2(t)$), а также гидроциклонов, работающих после одного из выходных зумпфов секции ($\rho_3(t)$). В итоге было отобрано 3 входных и 1 выходной сигнал, что позволило описать процесс функциональной зависимостью, представленную на рисунке 9.

Для проведения процедур обучения и тестирования использовался фрагмент полученных ранее данных из реальной промышленной системы. Выборка данных соответствовала 2 неделям функционирования технологического процесса с дискретностью записи 1 мин по входным параметрам, и 2 часа по содержанию железа, что как раз связано с отсутствием автоматизированной системы контроля. Это позволяет говорить о широком наборе изменений входных переменных и состояний объектов.

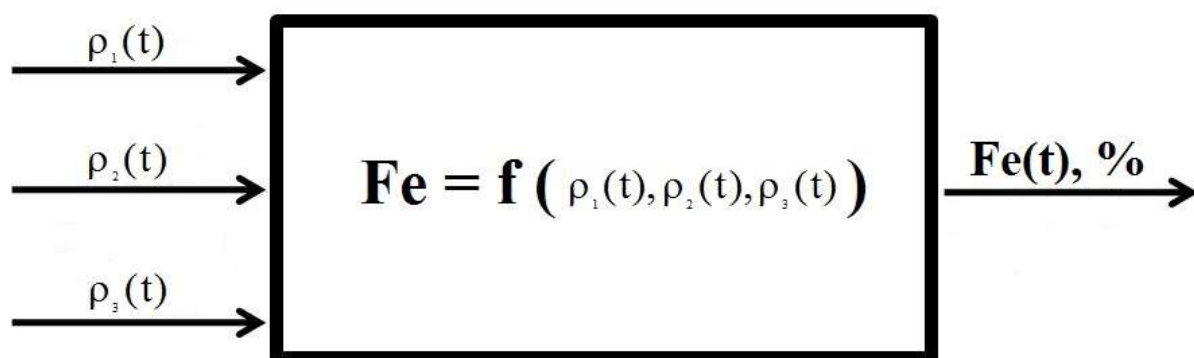


Рисунок 9. Функциональная схема модели содержания железа в выходном продукте

После выполнения озвученных процедур необходимо осуществить процесс разделения выборок на обучающую и тестовую. Для этого были учтены общепринятые требования, а именно: соотношение объемов обучающей и тестовой выборок должно быть равным 80/20%; в ходе проведения процедуры тестирования ИНС должны предъявляться данные за иной временной промежуток, нежели обучающая выборка, но все точки измерения выходного сигнала должны быть в интервалах области «известных» модели данных. То есть значения точек тестовой выборки должны входить в интервал граничных амплитудных значений обучающей выборки для обеспечения требования полноты предоставляемой информации. Главным условием при проведении данной операции является необходимость такого выбора отрезка данных для тестовой выборки, при котором максимальное и минимальное ее значения будут входить в промежуток минимального и максимального значений обучающей выборки.

Для большей чистоты эксперимента, набор данных для тестирования качества работы нейросетевой модели комплекса был выбран за период, удаленный от момента времени окончания формирования обучающего набора, тем самым было промоделировано изменение параметров сырья и самого комплекса.

При этом дополнительным требованием к обучающей и тестовой выборке стало требование о неразрывности временных промежутков – данные в выборках должны представлять собой единый участок измерений переменных, а не состоять из отрезков, дабы не допускать нарушения отображения динамических свойств технологических объектов. Это позволит предоставить ИНС-модели в ходе обучения большой набор свойств объекта, что повысит качество разрабатываемых моделей. Все указанные требования к свойствам обучающей и тестовой выборок должны учитываться одновременно. Подобное требование значительно уменьшает объем данных, подходящих для проведения экспериментов. Для учета требований и унификации подхода при работе с имеющимися переменными, был разработан алгоритм осуществления процедуры деления на выборки, учитывающий все

озвученные требования. Он является подалгоритмом единого алгоритма предобработки данных и приведен в Приложении Б.

После проведения всех указанных процедур преобработки данных и формирования выборок, была осуществлена серия экспериментов по выявлению архитектуры нейронной сети, позволяющей получить модель с лучшими показателями качества. В ходе этих экспериментов были апробированы структуры многослойной нейронной сети прямого распространения сигнала с различным количеством скрытых слоев, нейронов в них, функциями активации по слоям и количеством входных сигналов.

На рисунке 10 представлена общая архитектура многослойной нейронной сети с прямым распространением сигнала, адаптированная для решения задачи и использовавшаяся при проведении экспериментов.




Рисунок 10. Типовая архитектура многослойной нейронной сети, использовавшаяся в ходе экспериментов

На рисунке выше $X1, X2, X3$ – нейроны входного слоя сети, Y – нейрон выходного слоя сети, $s_1 = \sum_{i=1}^3 w_{ni}^1 x_i + b_n^1$, $s_2 = \sum_{n=1}^N w_{mn}^2 x_n + b_m^2$, $s_3 = \sum_{m=1}^M w_{km}^3 x_m + b_k^3$, $s_4 = \sum_{k=1}^K w_k^4 x_k + b^4$ – формулы расчета значений взвешенных сумм в слоях, $f_1(s_1), f_2(s_2), f_3(s_3), f_4(s_4)$ – функции активации в слоях, $w_{ni}^1, w_{mn}^2, w_{km}^3, w_k^4$ – значения весовых коэффициентов в слоях соответственно.

В ходе исследования были проведены эксперименты и отобраны 3 архитектуры НС, способные производить аппроксимацию подобных сигналов с достижением высокого качества.

Первая из них – это структура, состоящая из одного скрытого слоя и количеством нейронов в нем равным 60, 1 нейрон в выходном слое, функции активации – сигмоидальная и линейная соответственно (NN_1). Функционирование данной НС осуществляется согласно (7):

$$Y_1(t) = f_2(b_m^2 + \sum_{n=1}^N w_{mn}^2 f_1(\sum_{i=1}^3 w_{ni}^1 x_{ij}(t) + b_n^1)), \quad (7)$$

где $N = 60$ - число нейронов в скрытом слое, b_n^1, b_m^2 - смещения нейронов, w_{ni}^1, w_{mn}^2 - весовые коэффициенты по слоям.

В качестве более сложной структуры была использована модель, основанная на архитектуре НС с 2-мя скрытыми слоями, по 60 и 30 нейронов соответственно, 1 нейроном в выходном слое и функциями активации по слоям: тангенциальная, сигмоидальная и линейная (NN_2). Ее функционирование описывается зависимостью (8):

$$Y_2(t) = f_3(b^3 + \sum_{k=1}^M w_{km}^3 f_2(b_m^2 + \sum_{n=1}^N w_{mn}^2 f_1(\sum_{i=1}^3 w_{ni}^1 x_{ij}(t) + b_n^1))) \quad (8)$$

где $N = 60, M = 30$ - число нейронов в соответствующих слоях, b_n^1, b_m^2, b^3 - смещения нейронов, $w_{ni}^1, w_{mn}^2, w_{km}^3$ - весовые коэффициенты по слоям.

С целью повышения качества моделирования была предпринята попытка усложнения НС путем введения еще одного скрытого слоя. В итоге была отобрана структура с количеством нейронов 55, 50 и 45 в скрытых слоях, 1 нейрон в выходном слое и функциями активации: тангенциальная, сигмоидальная во втором и третьем скрытом слое, линейная в выходном слое (NN_3). Модель данной структуры представлена в (9):

$$Y_3(t) = f_4(b^4 + \sum_{k=1}^K w_k^4 f_3(b_k^3 + \sum_{m=1}^M w_{km}^3 f_2(b_m^2 + \sum_{n=1}^N w_{mn}^2 f_1(\sum_{i=1}^3 w_{ni}^1 x_i(t) + b_n^1))), \quad (9)$$

где $N = 55$, $M = 50$, $K = 45$ - число нейронов в соответствующих слоях, b_n^1, b_m^2, b_k^3, b^4 - смещения нейронов, $w_{ni}^1, w_{mn}^2, w_{km}^3, w_k^4$ - весовые коэффициенты по слоям.

Для подтверждения этого результата нами были использованы численные показатели оценки качества моделирования. Для этого применялись такие критерии качества, как функционал ошибки МНК ($F(LSM)$) (10) сигналов исходного сигнала содержания железа и выхода нейронной сети, и коэффициент корреляции ($corr k$) (11) данных сигналов.

$$F(LSM) = \sum_{i=1}^n (Y_{mod} - Y_{эксн})^2, \quad (10)$$

где Y_{mod} - значения реального сигнала, $Y_{эксн}$ - значения выходного сигнала модели.

$$corr k = \frac{\sum_{i=1}^n (Y_{mod_i} - \bar{Y}_{mod})(Y_{эксн_i} - \bar{Y}_{эксн})}{\sqrt{\sum_{i=1}^n (Y_{mod_i} - \bar{Y}_{mod})^2 \sum_{j=1}^n (Y_{эксн_j} - \bar{Y}_{эксн})^2}}, \quad (11)$$

$$\text{где } \bar{Y}_{mod} = \frac{1}{n} \sum_{i=1}^n Y_{mod_i}, \bar{Y}_{эксн} = \frac{1}{n} \sum_{i=1}^n Y_{эксн_i}$$

Численные значения показателей качества, полученные при обучении приведенных моделей приведены ниже в таблице 8.

Таблица 8. Численные значения показателей качества моделирования

Кортеж входных сигналов	Архитектура нейронной сети
-------------------------	----------------------------

	NN_1		NN_2		NN_3	
	$F(LSM)$	$corr\ k$	$F(LSM)$	$corr\ k$	$F(LSM)$	$corr\ k$
$[\rho_1(t), \rho_2(t), \rho_3(t)]$	338.8	0.745	294.2	0.784	207.65	0.8531

В ходе дальнейших экспериментов были апробированы измененные структуры, отличающиеся наличием дополнительных нейронов во входном слое, предназначенные для обработки входных сигналов, последовательно задержанных на 1, 2 и 3 такта.

Существенного повышения качества моделирования данный подход не обеспечил. Следующим шагом стала попытка изменения первоначальной структуры, приведенной на рисунке 11, путем введения дополнительного нейрона во входной слой первоначальной архитектуры сети, предназначенного для обработки выходного сигнала, задержанного на 1 такт, что является достижимым в условиях реального производства. В итоге, была получена общая структура, представленная на рисунке 11. Эксперименты с нейронными сетями, обладающими подобной структурой входного слоя привели к получению наилучшего результата при обучении.




Рисунок 11. Типовая архитектура многослойной НС с дополнительными нейронами обработки задержанного на 1 такт сигнала выхода

Об этом свидетельствуют и численные показатели качества, приведенные ниже в таблице 9. Причем стоит оговориться, что при добавлении дополнительных нейронов во входной слой, которые обрабатывают выходной сигнал содержания железа, задержанный на 2 и 3 такта, существенного повышения качества работы модели не произошло. Поэтому результаты данных опытов в работе не отражены.

Таблица 9. Численные значения показателей качества моделирования

Кортеж входных сигналов	Архитектура нейронной сети					
	NN_1		NN_2		NN_3	
	$F(LSM)$	$corr\ k$	$F(LSM)$	$corr\ k$	$F(LSM)$	$corr\ k$
$[\rho_1(t), \rho_2(t), \rho_3(t), Fe(t-1)]$	3.524	0.9977	2.11	0.9986	1.197	0.9992

Дальнейшим этапом проверки качества работы моделей стали эксперименты, связанные с подачей на вход сети тестовой выборки объемом 3500 точек, сформированной ранее, что соответствует 58 часам функционирования оборудования, в ходе которого присутствовали изменения характеристик входного сырья и внешних условий. По результатам данного этапа был получен результат, представленный в таблице 10.

Таблица 10. Численные значения показателей качества моделирования

Кортеж входных сигналов	Архитектура нейронной сети					
	NN_1		NN_2		NN_3	
	$F(LSM)$	$corr\ k$	$F(LSM)$	$corr\ k$	$F(LSM)$	$corr\ k$
Тестовая выборка	2.34	0.9912	16.81	0.9444	37.758	0.8681

Дальнейшая попытка улучшения качества работы модели и ее адаптация к возможности функционирования в условиях производства производилась с модифицированной архитектурой сети под названием NN_1.

Для возможного снижения количества эпох обучения и предотвращения явления переобучения нейронной сети был применен алгоритм выделения валидационной выборки в процессе обучения. На рисунке 12 представлен результат работы данной нейронной сети с применением алгоритма валидации при обучении, где жирной линией показан выходной сигнал модели, а тонкой штрихпунктирной линией – реальный график содержания железа в выходном концентрате, полученный на основе лабораторного анализа.




Рисунок 12. Результат работы модели шаровой мельницы на основе модифицированной структуры NN_1

Данный механизм позволил снизить количество необходимых эпох до 17 без потери качества работы модели, что отражается в значения численных показателей качества, равных: $F (LSM) = 2.1436$; $corr k = 0.992$.

Для проведения экспериментов по выбору методики фильтрации были взяты те же выборки сигналов и нейросетевая модель NN_1 с оптимизированной архитектурой. Все выборки были одинаковой длины с синхронизированной дискретностью измерения. Один набор сигналов не подвергался процедуре фильтрации, к другому был применен алгоритм «скользящее среднее», а к третьему

– сингулярно-спектральный анализ. После процедур обработки, данные были использованы для обучения ранее разработанной нейросетевой модели процесса обогащения и проверки ее работоспособности на тестовой выборке.

На рисунке 13 представлен график работы модели процесса при функционировании на тестовой выборке с использованием данных, не подвергнутых процедуре фильтрации. Оранжевым цветом представлен реальный график содержания железа в выходном продукте, синим – выходной сигнал модели.




Рисунок 13. Результат работы нейросетевой модели на данных без фильтрации

Затем были проведены исследования для оценки качества работы модели на данных, отфильтрованных по алгоритму «скользящее среднее», представленному в выражении (12):

$$y_n = \frac{1}{N} \sum_{k=0}^{N-1} x_{n-k}, \quad (12)$$

где x_{n-k} - оригинальное значение сигнала, y_n - значение сигнала, обработанное фильтром, N – число точек данных, обрабатываемых фильтром

Результат работы нейросетевой модели на тестовой выборке представлен на рисунке 14. Оранжевым цветом представлен реальный график содержания железа в выходном продукте, синим – выходной сигнал модели.




Рисунок 14. Результат работы нейросетевой модели на данных, отфильтрованных алгоритмом «скользящее среднее»

В ходе экспериментов изменялось количество точек, входящих в окно усреднения, для выявления их числа, позволяющего получить наилучший результат. Это значение варьировалось в пределах от 3 до 51 точки. Наилучший результат был получен при использовании 11 точек.

После этого были осуществлены эксперименты по реализации модели процесса обогащения на основе данных, подвергнутых сингулярно-спектральной фильтрации. В ходе их проведения изменялись значения таких параметров, как ширина окна и количество использованных компонент разложения для получения восстановленного сигнала.

Наиболее качественный результат работы НС был получен при использовании 2000 компонент разложения и шириной окна порядка 55% от длины обучающей выборки. График работы модели представлен на рисунке 15. Оранжевым цветом представлен реальный график содержания железа в выходном продукте, синим – выходной сигнал модели. Из представленных данных видно, что лучший результат был получен при использовании сингулярно-спектрального анализа для фильтрации имеющихся данных.




Рисунок 15. Результат работы нейросетевой модели на данных, отфильтрованных при помощи SSA-метода

Стоит отметить, что метод сингулярно-спектрального анализа позволяет производить именно фильтрацию сигнала, а не его усреднение, то есть выделять главные характеристики сигнала и отделять шумы, а не производить «сглаживание». Полученные результаты, представленные в таблице 11, позволяют сделать вывод о возможности использования SSA-метода для фильтрации прочих сигналов при создании моделей прочих агрегатов технологического процесса обогащения.

Таблица 11. Численные показатели качества моделирования при использовании данных, подвергнутых различным методам фильтрации

	Обучающая выборка		Тестовая выборка	
	corr k	MSE*10 ⁴	corr k	MSE*10 ⁴
Данные без фильтрации	0.9969	0.3114	0.9856	0.426557
Данные с фильтрацией «скользящее среднее»	0.9969	0.3149	0.9853	0.405478
Данные с фильтрацией SSA	0.9969	0.3108	0.9877	0.334301

ВЫВОДЫ ПО ГЛАВЕ 2

Во второй главе была выполнена разработка схемы моделей технологических агрегатов для решения задачи выполнения экспериментов по построению прогнозирующей системы. Сложность и необходимость процедуры объясняется неоднородным характером операций, производимых в ходе обработки железорудного сырья. Это обстоятельство приводит к различному перечню измеряемых параметров на схожих объектах, что в итоге затрудняет задачу выбора учитываемых в ходе моделирования агрегатов и переменных.

Еще одной задачей, которая была решена в рамках исследований, обозначенных во второй главе, стала разработка алгоритма предобработки данных, который бы позволил получать выборки для проведения процедуры идентификации. Исходные переменные имеют значительное число стандартных для промышленных сигналов недостатков, выражающихся в выбросах, провалах, наличии шумовых составляющих. Для подготовки данных был разработан алгоритм, учитывающий требования для обучения и тестирования моделей, включающий операции предобработки, подготовки и фильтрации данных.

ГЛАВА 3. РАЗРАБОТКА ЦЕПИ МОДЕЛЕЙ ТЕХНОЛОГИЧЕСКИХ АГРЕГАТОВ ПРОЦЕССА ОБОГАЩЕНИЯ

После разработки схемы моделей и создания алгоритма предобработки данных из реальной системы управления технологическим процессом железорудного концентрата и формирования выборок на их основе, были выполнены работы по созданию моделей агрегатов производственной цепочки.

Как уже было озвучено выше, при разработке APC-систем существует 2 пути – это разработка поагрегатных моделей технологических объектов и построение виртуальных анализаторов для прогнозирования изменения трудноизмеряемых параметров производства. Исходя из того, что ранее были проведены эксперименты, представленные в главе 2, по разработке общей модели процесса обогащения железорудного концентрата для апробации идеи применения аппарата ИНС в условиях поставленной задачи, показавшие положительные результаты, следующим этапом стала разработка поагрегатных моделей. Применение подобного метода моделирования на основании ограниченного числа параметров, осуществляющего прогнозирование итогового показателя на основе статистически наиболее значимых сигналов, несмотря на положительное качество моделирования, не учитывает множества факторов, отражающихся в полном наборе измеряемых параметров, и сложной динамики процесса в целом, чего не наблюдается при применении поагрегатного подхода.

3.1. РАЗРАБОТКА МОДЕЛИ КОМПЛЕКСА «ГОЛОВНАЯ ШАРОВАЯ МЕЛЬНИЦА – СПИРАЛЬНЫЙ КЛАССИФИКАТОР»

Для разработки модели технологического комплекса согласно схемы, были использованы данные из реальной системы управления, за временной период, обозначенный ранее в ходе выполнения экспериментов по выбору метода фильтрации. Из анализируемых параметров в качестве входных переменных разрабатываемой модели были выбраны: вес руды, загружаемой в мельницу ($W(t)$); объем подачи воды в загрузку мельницы ($Q1(t)$); объем подачи воды в разгрузочную бутару мельницы ($Q2(t)$); мощность, потребляемая приводом

мельницы ($P(t)$); ток 1-ой спирали классификатора ($I1(t)$); ток 2-ой спирали классификатора ($I2(t)$). Остальные сигналы, дублирующие получаемую в ходе анализа указанных параметров информацию, были отсеяны. В качестве выходного параметра был выбран сигнал плотности слива классификатора ($D(t)$), как один из основных измеряемых сигналов, характеризующий работу комплекса. В качестве зависимого параметра при моделировании был выбран именно сигнал плотности слива классификатора, так как в ходе технологического процесса предприятия требуется поддержание плотностного режима в необходимых пределах. Разрабатываемая модель соответствовала схеме, представленной на рисунке 16.




Рисунок 16. Функциональная схема модели шаровой мельницы

где $x1...x6$ – входы модели, соответствующие измеряемым промышленным показателям, Y – выход модели - сигнал плотности слива классификатора.

3.1.1. РАЗРАБОТКА МОДЕЛИ КОМПЛЕКСА «ГОЛОВНАЯ ШАРОВАЯ МЕЛЬНИЦА – СПИРАЛЬНЫЙ КЛАССИФИКАТОР» С ПРИМЕНЕНИЕМ АППАРАТА РЕГРЕССИОННОГО АНАЛИЗА

С целью апробирования метода и для проведения процедуры сравнительного анализа, первоначально были выполнены эксперименты по разработке моделей технологических агрегатов процесса на основе статистического аппарата регрессионного анализа, как наиболее применимого метода классической теории автоматического управления в рамках рассматриваемой задачи.

Для аппроксимации были использованы такие функции, как: линейная (13), дробная (14), степенные полиномы до 5-ого порядка включительно (15),

экспоненциальная функция (16) и полином Колмогорова-Габора (17), также известный как ряд Винера, используемый для описания нелинейных объектов в методе группового учета аргументов Ивахненко А.Г. [31,103,104,105,106], считающемся одним из первых алгоритмов глубокого обучения в некоторой интерпретации [107], и упомянутый во многих источниках [44]. Общий вид функций представлен ниже:

$$Y(x_1...x_n) = b_0 + \sum_{i=1}^n b_i x_i \quad (13)$$

$$Y(x_1...x_n) = b_0 + \sum_{i=1}^n \frac{1}{b_i x_i} \quad (14)$$

$$Y(x_1...x_n) = b_0 + \sum_{j=1}^m \sum_{i=1}^n b_{ij} x_i^j \quad (15)$$

$$Y(x_1...x_n) = b_0 + \sum_{i=1}^n \exp^{x_i} \quad (16)$$

$$Y(x_1...x_n) = b_0 + \sum_{i=1}^n b_i x_i + \sum_{i=1}^n \sum_{j=1}^n b_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n b_{ijk} x_i x_j x_k \quad (17)$$

Первоначально, для проведения регрессионного анализа, была выбрана выборка данных, соответствующая полным суткам работы агрегата. В результате анализа были получены коэффициенты перечисленных выше полиномов. Пример фрагмента представлен на рисунке 17.

Estimated Coefficients:					
	Estimate	SE	tStat	pValue	
b1	-4127.3	NaN	NaN	NaN	
b2	44.519	NaN	NaN	NaN	
b3	-39.511	NaN	NaN	NaN	
b4	-44.196	NaN	NaN	NaN	
b5	-0.12719	NaN	NaN	NaN	
b6	0.12172	NaN	NaN	NaN	
b7	-0.32723	NaN	NaN	NaN	
b8	0.074786	NaN	NaN	NaN	
b9	0.25458	NaN	NaN	NaN	
b10	0.23974	NaN	NaN	NaN	
b11	5.5e-05	2.7853e-05	1.9746	0.04859	
b12	0.0011561	NaN	NaN	NaN	
b13	0.0042241	NaN	NaN	NaN	
b14	-0.00024656	NaN	NaN	NaN	
b15	-1.78e-06	NaN	NaN	NaN	
b16	0.00037366	NaN	NaN	NaN	
b17	-0.00043752	0.00023168	-1.8885	0.059259	
b18	0.0019918	NaN	NaN	NaN	
b19	-0.002346	NaN	NaN	NaN	
b20	-0.001239	NaN	NaN	NaN	

Рисунок 17. Некоторые коэффициенты регрессии сигнала плотности для полинома Колмогорова-Габора

Однако корреляция полученных кривых и графика реального сигнала плотности была относительно невысока, общая точность моделей была ниже рекомендуемых 80% [108]. Тогда было предположено, что такая невысокая точность получена из-за сильной зашумленности данных, которая является следствием погрешностей в системе измерений. Для предотвращения подобного негативного влияния данные были отфильтрованы с применением алгоритма сингулярно-спектрального анализа, методика проведения которого представлена в главе 2. Полученные данные были вновь подвергнуты регрессионному анализу. На этот раз полученные описательные функции имели гораздо более высокую точность.

Затем для моделирования работы объекта в пакете Matlab были реализованы динамические составляющие математической модели мельницы, которые были реализованы при помощи апериодических звеньев 1-ого порядка вида (18):

$$T_{\theta i} \cdot \dot{y}(t) + y(t) = K \cdot x(t) \quad (18)$$

Постоянные времени для каждого входного сигнала $T_{\theta 1} \dots T_{\theta 6}$ были найдены в результате обработки данных изменения технологических параметров. Коэффициент усиления был принят равным 1. Звенья приняли вид, представленный в (19)-(21), где показаны звенья для каналов «вес руды», «расход воды в мельницу», «расход воды в бутару мельницы»:

$$4,4 \cdot \dot{y}(t) + y(t) = x(t) \quad (19)$$

$$12,1 \cdot \dot{y}(t) + y(t) = x(t) \quad (20)$$

$$8,4 \cdot \dot{y}(t) + y(t) = x(t) \quad (21)$$

В результате была получена динамическая модель объекта в пакете MATLAB. Схема представлена на рисунке 18.

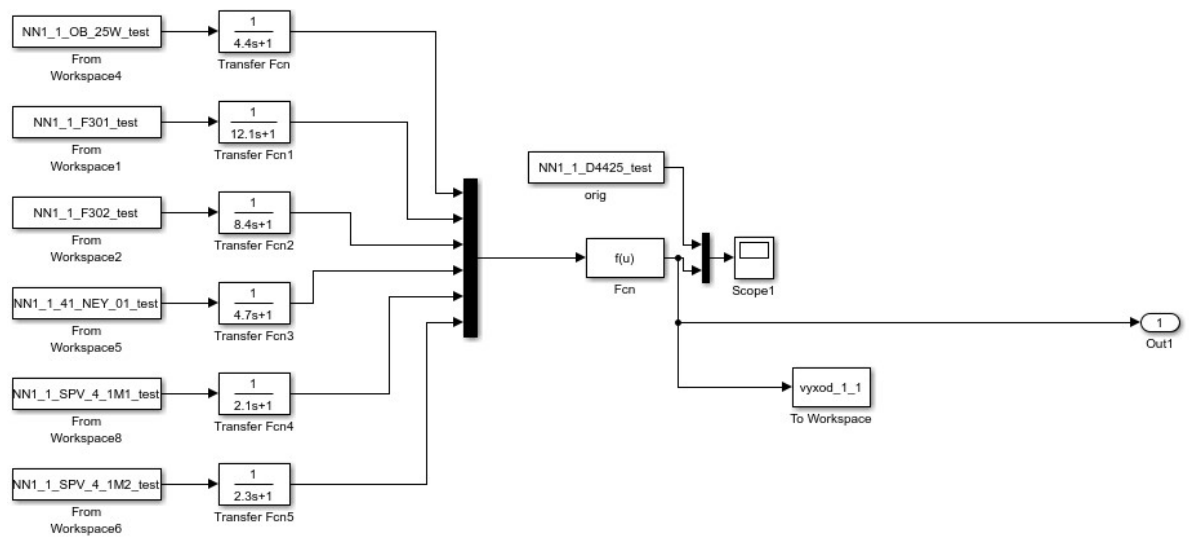


Рисунок 18. Схема динамической модели объекта «шаровая мельница - спиральный классификатор» в MATLAB Simulink

Далее было проведено моделирование работы мельницы с различными аппроксимирующими функциями. Результаты лучших из которых представлены на рисунках 18, 19, где жирная пунктирная линия – реальный график сигнала плотности, а тонкая штрихпунктирная линия – моделируемый выход объекта.

Как видно из графиков на рисунках 18 и 19, модели на основе функций, полученных методом регрессионного анализа, достаточно точно повторяет график сигнала плотности, что позволяет утверждать о допустимом качестве моделей.




Рисунок 18. Результаты моделирования работы объекта с использованием квадратичного полинома




Рисунок 19. Результаты моделирования работы объекта с использованием полинома Колмогорова-Габор

Для всех моделей были произведены расчеты значения функционала МНК и коэффициента корреляции, что позволило сравнить суммарную ошибку и качество моделирования. Результаты лучших значений критериев представлены в таблице 12.

Таблица 12. Численные значения критериев качества, полученные при проведении регрессионного анализа

Тип функции	F (LSM)	corr k
Квадратичный полином	6.9	0.6725
Полином Колмогорова-Габор	3.6	0.753

На указанных рисунках и в таблице представлены графики работы моделей, которые показали наибольшую точность и лучшие значения критерия и коэффициента корреляции. Модели на основе остальных полиномов были отсеяны.

Затем была предпринята попытка произвести регрессионный анализ полной выборки данных, с целью уточнить коэффициенты функциональных зависимостей и повысить качество разрабатываемой модели. Результаты работы моделей представлены на рисунках 20, 21 и 22. На указанных рисунка в верхней части изображен реальный график сигнала плотности, в нижней части – выходной сигнал модели.

Из представленных графиков видно, что исследуемые функциональные зависимости достаточно точно повторяют характер графика тока и находятся в небольшом разбросе по амплитуде.




Рисунок 20. Результат моделирования работы объекта на основе полинома Колмогорова-Габора с коэффициентами полной выборки




Рисунок 21. Результат моделирования работы объекта на основе линейной функции с коэффициентами полной выборки




Рисунок 22. Результат моделирования работы объекта на основе квадратичного полинома с коэффициентами полной выборки

По результатам вычисления был сделан вывод, что наиболее точное моделирование производится при использовании полинома Колмогорова-Габора.

3.1.2. РАЗРАБОТКА МОДЕЛИ КОМПЛЕКСА «ГОЛОВНАЯ ШАРОВАЯ МЕЛЬНИЦА – СПИРАЛЬНЫЙ КЛАССИФИКАТОР» С ПРИМЕНЕНИЕМ АППАРАТА МНОГОСЛОЙНЫХ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

После проведения экспериментов на основе регрессионного анализа и получения результатов не слишком высокой точности, было принято решение о попытке разработки математической модели шаровой мельницы с использованием аппарата искусственных нейронных сетей, которые обладая способностью выявлять скрытые и аппроксимировать нелинейные зависимости за счет нелинейных функций активации в слоях, предположительно должны обеспечить повышение качества моделирования.

Для опытов использовалась искусственная многослойная нейронная сеть прямого распространения сигнала. Подобный тип нейронных сетей широко используется для решения задач аппроксимации сложных функций, его возможности изучены и доказаны во множестве работ [19,20,21,33,34,35,37,38,86,87,88,89,90,91,92,93,94,95].

В ходе экспериментов были испытаны ИНС-модели с различной архитектурой. При проведении экспериментов изменялись различные параметры архитектуры искусственной нейронной сети, такие как количество скрытых слоев, нейронов в них, число эпох обучения, варьировались функции активации. Типовая архитектура подобной нейронной сети представлена на рисунке 23.




Рисунок 23. Типовая архитектура многослойной нейронной сети прямого распространения сигнала,

где $X[1..j]$ – нейроны входного слоя, Y – нейрон выходного слоя, w – весовые коэффициенты, s – сумма весовых коэффициентов, b – смещение, $f(s)$ – функции активации нейронов.

С целью выявления архитектуры нейронной сети, которая позволит получить наиболее качественный результат, были проведены эксперименты с изменением количества нейронов в слоях, использованы различные функции активации. Первоначально положительный результат был получен при использовании НС с 2-мя скрытыми слоями с 60 и 30 нейронами соответственно. После достижения максимальных показателей качества при обучении, на вход нейронной сети была подана тестовая выборка. В результате выход модели повторял сигнал плотности, однако имели место колебания, снижающие качество моделирования.

Поэтому было принято решение об усложнении структуры НС. Опыты с НС с 3-мя скрытыми слоями показали, что наиболее качественный результат получается при использовании структуры с 55, 50 и 45 нейронами соответственно

и функциями активации – гиперболический тангенс, сигмоидная функция во 2-ом и 3-ем скрытом слое, а также линейной функцией активации в выходном слое.

Результат работы данной НС на тестовой выборке представлен на рисунке 24, где реальный график сигнала плотности показан жирной линией, а выходной сигнал модели – пунктирной.




Рисунок 24. График работы нейронной сети с 3-мя скрытыми слоями

Дальнейшее усложнение структуры НС существенного повышения качества моделирования не принесло. Но стоит отметить, что в некоторые моменты времени на выходе модели заметны существенные по амплитуде колебания, которые могут отразиться на работе системы при ее промышленной эксплуатации.

Поэтому для повышения качества моделирования посредством учета динамики объекта было принято решение об изменении структуры НС внесением дополнительных нейронов во входной слой. Дополнительные нейроны предназначены для обработки информации, представляющей собой все те же входные сигналы, однако с дискретной задержкой на 1 и более тактов, что является рекуррентной связью. Данный метод организации динамики при

идентификации технологических агрегатов является достаточно общепринятым [19,33,34,109]. Целесообразность организации рекуррентной связи обусловлена результатами, полученными К. Фунахаши и И. Накамура и зачастую представляемыми под названием «универсальная аппроксимационная теорема RNN (RNN - recurrent neural network) [110]:

Теорема 1. *Любая нелинейная динамическая система класса может быть аппроксимирована с любой точностью рекуррентной нейронной сетью, без ограничений на компактность пространства состояний системы, при условии, что сеть имеет достаточное количество нейронов в скрытом слое M .*

Опыты выполнялись с применением ИНС прямого распространения сигнала с различным количеством нейронов в скрытом слое, различными функциями активации, содержащими 6 нейронов во входном слое, обрабатывающих каждый из технологических сигналов, озвученных выше, и один нейрон в выходном слое. Первоначально были проанализированы результаты работы моделей комплекса на основе нейронных сетей, содержащих 1 скрытый слой с количеством нейронов в нем от 7 до 60, функция активации использовалась тангенциальная, либо логистическая. Внесение задержки по каналам на один такт позволило получить гораздо менее зашумленный колебаниями сигнал выхода модели. Причем было замечено, что он достигается при использовании НС с меньшим количеством нейронов, что является положительным моментом, поскольку позволяет использовать меньший объем вычислительных ресурсов системы. Затем, при усложнении структуры ИНС путем последовательного увеличения количества скрытых слоев до 3-х и нейронов в них, было замечено, что сеть показывает достаточно высокое качество обучения – коэффициент корреляции превышает значение 0.8. Однако при работе на тестовой выборке наблюдается значительная ошибка по амплитуде в исходном и моделируемом сигнале плотности. Пример представлен на рисунке 25, где пунктирной линией изображен реальный график плотности слива классификатора, а сплошной – выходной сигнал модели.




Рисунок 25. Результат работы модели комплекса «мельница-классификатор» на основе ИНС с использованием задержанного сигнала

Это выражалось в негативных численных значения показателей качества при работе на тестовой выборке ($F(LSM)=18.182$, $corr\ k=0.351$). Дальнейшее усложнение структуры ИНС путем увеличения количества слоев до 5 и нейронов в них повышения качества работы модели не принесло.

Поэтому было принято решение о попытке добавления в качестве еще одного входа ИНС выходного сигнала плотности слива классификатора, задержанного на 1 минуту. Реализация данного условия возможна в условиях производства, поскольку этот сигнал измеряется со временем дискретизации 5 секунд.

Применение данного сигнала в качестве входного позволило значительно повысить качество идентификации, что отразилось в значениях численных критериев при обучении, и значительном их улучшении при работе на данных тестовой выборки ($F(LSM)=0.827$; $corr\ k = 0.9326$). Стоит отметить, что данное высокое качество работы модели было достигнуто при использовании довольно простой структуры ИНС, состоящей из 1 скрытого слоя с 14 нейронами в нем и логистической ФА.

Для подтверждения чистоты эксперимента, был изучен массив весовых коэффициентов полученной ИНС. Анализ показал, что значения весовых коэффициентов относительно равномерно распределены между входными показателями. То есть нейрон, отвечающий за обработку сигнала плотности слива классификатора, не оказывается превалирующим в результате обучения нейронной сети.

Высокое качество работы модели подтверждается результатами на графиках, представленных на рисунке 26, где пунктирной линией изображен реальный график плотности слива классификатора, а сплошной – выходной сигнал модели.




Рисунок 26. Результат работы модели комплекса «шаровая мельница-спиральный классификатор» на основе ИНС с использованием задержанного сигнала

В качестве сравнения были произведены опыты по иному методу реализации динамики модели. Для этого в ходе опытов постепенно увеличивался шаг количества тактов задержки по каждому из входных сигналов. В ходе исследования предполагалось выяснить – для повышения показателей работы модели является ли необходимым условием введение дополнительных нейронов во входной слой в соответствии с каждым тактом задержки или же возможно делать это с большим дискретом? В частности, была исследована разница в работе нейросетевых моделей

комплекса «мельница-классификатор» с одинаковой архитектурой скрытых и выходного слоев, но различным количеством нейронов во входном слое.

Для этого была использована многослойная нейронная сеть прямого распространения сигнала с двумя скрытыми слоями: 30 нейронов в первом слое и логистическая функция активации (ФА); 15 нейронов во втором скрытом слое и также логистическая ФА. В выходном слое использовался 1 нейрон с линейной ФА. Количество же нейронов во входном слое варьировалось – 36 нейронов для обработки входных сигналов и каждого из них, задержанного на 1-5 тактов последовательно или 18 нейронов для обработки тех же сигналов, но с задержками только на 1 и 5 тактов.

В ходе экспериментов были получены следующие результаты, представленные в таблице 13. Для получения достоверных результатов каждая из архитектур нейронной сети обучалась неоднократно.

Таблица 13. Результаты работы нейросетевых моделей различной архитектуры на тестовой выборке

Номер эксперимента	Показатели работы НС с кортежем задержек сигналов [-1; -2;-3;-4;-5]		Показатели работы НС с кортежем задержек сигналов [-1;-5]	
	corr k	F(LSM)	corr k	F(LSM)
1	0.6899	7.1357	0.8116	8.852
2	0.7929	13.0733	0.723	12.24
3	0.7122	9.6484	0.6105	14.73
4	0.7888	7.72	0.6753	9.4185
5	0.5083	36.0423	0.852	11.93
6	0.7355	24.48	0.7042	23.06
7	0.7595	6.86	0.6128	18.61
8	0.803	6.83	0.5905	18.92
9	0.7596	12.066	0.7374	15.65
10	0.7821	11.7016	0.7612	13.74
Среднее значение	0.733	13.55	0.70785	14.75

Из представленных результатов можно сделать вывод, что нейросетевая модель комплекса «головная шаровая мельница-спиральный классификатор», содержащая во входном слое большее количество нейронов для обработки задержанных сигналов, позволяет достигать лучшего качества работы именно на тестовой выборке. Предположительно, данный эффект достигается за счет большего количества обрабатываемой информации и последовательного моделирования динамики работы объекта. Полученные результаты, обеспечивающие более высокое качество работы моделей, актуальны для процесса построения единой системы управления процесса обогащения и были учтены при разработке прочих агрегатов технологической цепочки.

Затем было проведено аналогичное исследование методики организации динамики модели, но уже применительно к сигналу плотности слива классификатора, то есть выходному сигналу модели. Процедура поиска наилучшей структуры заключалась в подборе числа задержанных сигналов, подаваемых на вход. Первоначально подача задержанного сигнала происходила потактно последовательно, то есть подавался сигнал задержки на 1 такт, затем на 1 и 2 такта и так далее. Структура ИНС для проведения моделирования представлена на рисунке 27, где $[(W(t)); (Q1(t)); (Q2(t)); (P(t)); (I1(t)); (I2(t))]$ – кортеж сигналов входных параметров, $[(D(t))]$ – выходной моделируемый сигнал плотности слива классификатора, $x[1..j]$ – нейроны входного слоя, Y – нейрон выходного слоя, w – весовые коэффициенты, s – сумма весовых коэффициентов, b – смещение, $f(s)$ – функции активации нейронов, $z[2...30]$ – такт задержки сигнала.




Рисунок 27. Структура нейросетевой модели комплекса «шаровая мельница-спиральный классификатор» с реализацией динамических свойств

При обучении нейросетевых моделей использовался метод обратного распространения ошибки с реализацией алгоритма градиентного спуска. Функционирование сети осуществлялось по формуле (22):

$$Y(t) = f_2(b^2 + \sum_{k=1}^n w_k^2 f_1(\sum_{i=1}^j w_{ki}^1 x_i(t) + b_k^1)) \quad (22)$$

В ходе экспериментов были получены результаты, представленные на рисунках 28 и 29 (а,б), где z – количество тактов задержки сигнала плотности слива классификатора на входе модели.




Рисунок 28. Графики изменения значений коэффициента корреляции при функционировании на обучающих и тестовых данных




Рисунок 29. Графики изменения значений функционала МНК при функционировании на обучающих и тестовых данных

Из графиков видно, что после подачи задержки на 9 тактов последовательным методом, оба показателя выходят в область насыщения, после

которого значительного улучшения качества моделирования не происходит. Отдельно взятые колебания не носят принципиального характера.

Результаты с использованием тестовой выборки также показали, что необходимое количество тактов задержки сигнала плотности, подаваемое на вход ИНС, равно 9. Данное количество тактов задержки коррелирует со временем протекания переходных процессов при работе комплекса, которое при различных условиях может составлять от 7 до 16 минут [3,4,5,6,7,8,9,10,12,13,14].

В рамках исследования также была предпринята попытка оценки качества работы ИНС моделей при подаче на вход задержек сигнала плотности слива классификатора дискретным образом, то есть задержка только на 1 такт, задержка только на 2 такта и так далее. В результате при данном способе организации динамики объекта были получены значительно худшие результаты в сравнении с первоначальными опытами. Значения численных показателей качества представлены в таблице 14.

Таблица 14. Численные значения показателей качества моделирования

	Подача на вход ИНС задержек сигнала плотности последовательным методом	Подача на вход ИНС задержек сигнала плотности дискретным методом	Регрессионная модель
Обучение			
corr k	0.9955	0.9533	-
F (LSM)	19.8323	200.636	-
Тест			
corr k	0.9644	0.7217	0.9291
F (LSM)	0.4241	5.0444	0.9823

После анализа данных результатов, для проведения сравнительного анализа был также произведен эксперимент по оценке показателей работы модели на

основе ИНС и модели, разработанной с помощью аппарата регрессионного анализа. Для этого была использована линейная функциональная зависимость, набор входных переменных использовался аналогичный, как и для модели на основе ИНС, с организацией последовательно на 9 тактов задержки сигнала выхода. В итоге при моделировании был получен положительный результат. Но при оценке численных значений показателей качества, было выяснено, что результат ниже, чем при использовании ИНС. И если по показателю коэффициента корреляции эта разница составляет незначительные 3,66%, то при анализе значений функционала МНК видно, что ИНС показывает результат лучше на 56,8%. При попытке усложнения регрессионной функциональной зависимости с целью возможного повышения качества работы, даже при добавлении лишь квадратичных составляющих, было отмечено значительное увеличение времени расчета выходного сигнала регрессионной моделью.

На рисунке 30 представлен результат работы регрессионной и ИНС моделей при функционировании на тестовой выборке с обеспечением 9 тактов задержки последовательным методом, где жирной сплошной линией показан реальный сигнал плотности слива классификатора, тонкой сплошной – выходной сигнал модели на основе ИНС, а пунктирной - выходной сигнал регрессионной модели. Тестирование во всех экспериментах производилось на исходной выборке, однако график, для презентативности, представлен за меньший временной промежуток.




Рисунок 30. Результаты функционирования различных моделей с рекуррентной подачей сигналов

После проведения всех озвученных экспериментов, также были проведены работы по оптимизации времени обучения нейросетевой модели комплекса. Для этого был применен алгоритм использования валидационной выборки при обучении, позволивший сократить время обучения от первоначальных 30-33 секунд, до 11-13 секунд, что значительно быстрее времени протекания переходных процессов в комплексе и технологическом цикле в целом.

Время же расчета выходного сигнала модели на используемой тестовой выборке составляет менее 1 секунды. Данные факты подтверждают возможность использования модели на основе ИНС в режиме реального времени в ходе функционирования в разрабатываемой системе.

Проведенные опыты подтвердили возможность использования аппарата многослойных ИНС для разработки модели комплекса «головная шаровая мельница-спиральный классификатор» как многосвязного и наиболее сложного объекта технологического процесса обогащения железорудного концентрата на

горно-обогатительном комбинате. Данные результаты позволили сделать вывод о правильности выбранного метода и возможности применения аппарата ИНС для идентификации прочих технологических объектов процесса обогащения.

3.1.3. РАЗРАБОТКА МОДЕЛИ КОМПЛЕКСА «ГОЛОВНАЯ ШАРОВАЯ МЕЛЬНИЦА – СПИРАЛЬНЫЙ КЛАССИФИКАТОР» С ПРИМЕНЕНИЕМ АППАРАТА ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ

Полученные результаты, представленные в предыдущем разделе, исходя из численных значений показателей качества, позволяли предположить правильность применения выбранного аппарата классических многослойных ИНС для идентификации прочих агрегатов обогатительного передела. Однако, в ходе детального анализа выходных векторов моделей и исходных сигналов, было замечено, что при функционировании как регрессионных, так и многослойных ИНС у указанных временных рядов наблюдается выраженный эффект автокорреляции. Этот факт является негативным для прогнозирующих моделей, и возникает в результате ошибочной избыточной оценки степени влияния какого-либо из входных сигналов на выходной. Наличие подобного явления сигнализирует о неполной интерпретации моделью входных данных и влечет за собой снижение качества прогноза при подаче на вход данных, значительно удаленных по времени от обучающей выборки. Пример такого явления, наблюдаемого при взаимном смещении графиков и оценке их корреляционных показателей, представлен на рисунке 31.




Рисунок 31. Пример оценки эффекта автокорреляции

На рисунке 32 представлен график, показывающий изменение показателя автокорреляции сигналов оригинального значения показателя плотности слива комплекса «шаровая мельница – спиральный классификатор», приведенного к относительным единицам, и выходного сигнала его нейросетевой модели. Из графика видно, что наблюдается явный эффект автокорреляции на временном шаге, равном 1 такту моделирования. Это представляется негативным явлением и говорит о том, что модель опирается, в основном, на данные выхода, задержанного на 1 такт, несмотря на то, что дополнительно, для моделирования динамики объекта, на вход подаются еще сигналы задержанного выхода вплоть до 9-ого такта. Стоит отметить, что данное явление не наблюдается при анализе весовых коэффициентов модели – соответствующим сигналам не отдается превалирующее значение.




Рисунок 32. Пример наблюдаемого эффекта автокорреляции на графиках

Оранжевый график выхода модели достаточно точно повторяет синий график, но при этом в пиках (непосредственно точках) наблюдается отставание как раз на 1 такт. И если в области «3» на рисунке это не настолько явно представлено, так как модель несколько своеобразно аппроксимировала оригинальную зависимость, то в областях «1» и «2» это выражено наиболее ярко, как и во многих других случаях.

В итоге, несмотря на качественные значения метрик оценки качества работы модели, таких как корреляция и среднеквадратичная ошибка, наличие подобного явления представляется негативным, поскольку модель снижает свои возможности экстраполяции, осуществляя прогноз все-таки опираясь не на все сигналы, а на один, более повторяя его, нежели выполняя прогноз.

Для предотвращения данного явления в работе было проведено исследование возможности применения аппарата глубоких нейронных сетей. Данные ИНС обладают большим объемом, за счет чего достигается более высокая вычислительная мощность, нежели при использовании классических многослойных сетей. Целесообразность применения данного аппарата ИНС для решения задачи идентификации многопараметрического сложного агрегата, позволяющего реализовывать отображение входных данных в пространство существенно большей размерности, обоснована теоремой Ковера [111]:

Теорема 1. *Нелинейное проецирование в пространство более высокой размерности заданного набора данных, не являющихся сепарабельными, повышает вероятность их линейной разделимости.*

Первоначально была осуществлена попытка применения базовых глубоких архитектур. К ним относятся такие архитектуры сетей как многослойные, являющиеся модификацией классических многослойных ИНС, увеличение вычислительных возможностей которых стало возможно с ростом вычислительных возможностей ЭВМ и модификацией применяемых алгоритмов обучения [44,112,113,114,115,116,117]. Для возможности проведения экспериментов в рамках разумных временных промежутков, первоначально была осуществлена выборка в 5000 точек из имеющегося набора данных. Основные процедуры предобработки, проводимые в ходе подготовки выборок, совпадали с ранее выполняемыми операциями, которые представлены в разделе об исследовании применимости классических многослойных ИНС. Стоит отметить, что эксперименты проводились с использованием среды Google Colab.

В ходе осуществления опытов, для выявления структуры, позволяющей получить наилучшее качество моделирования, варьировались такие параметры сети как: число нейронов во входном слое – от 200 до 400; число нейронов в скрытом слое 1 – от 150 до 250; число нейронов в скрытом слое 2 – от 150 до 250; число нейронов в скрытом слое 3 – от 150 до 250; число нейронов в выходном слое – от 200 до 400; число эпох обучения – от 15 до 35; размер батча данных – от 25 до 95.

Максимальный результат был получен при обучении сети со структурой [200;150;250;150;400;35;60], достигнутое значение ошибки $\text{loss (mse)} = 0.0044$. Результаты функционирования многослойной глубокой ИНС-модели (Dense) представлены на рисунках 33 и 34.




Рисунок 33. Пример аппроксимации точек обучающей выборки Dense сетью




Рисунок 34. Гистограмма распределения остатков Dense сети

На рисунке 35 представлен результат функционирования Dense модели на валидационной выборке, где исходные данные представлены оранжевым цветом, а результат работы глубокой ИНС – синим.




Рисунок 35. График функционирования Dense-модели на валидационной выборке

При осуществлении экспериментов, модели глубоких ИНС строились таким образом, чтобы прогнозировать изменение выходного показателя не только на 1 шаг, как это делалось при функционировании регрессионной и классической ИНС моделей, а на диапазон шагов от 1 до 10 с дискретностью 1 минута, совпадающей с общей дискретностью данных. Это осуществлялось с целью попытки увеличения горизонта прогнозирования для предоставления оператору большей информации

по возможному развитию процесса. Но все же, основным интересующим сигналом был прогноз сети на 1 шаг, поскольку именно он является наиболее информативным и понятным в условиях реальной эксплуатации.

Из представленных значений видно, что модель не позволяет достигнуть желаемого уровня качества функционирования – значение коэффициента корреляции существенно ниже 0.8, и к тому же лучший результат достигается при прогнозировании на 4 шага, что не соответствует поставленным условиям.

Таблица 15. Численные значения коэффициента корреляции при функционировании Dense модели на валидационной выборке

Шаг прогноза	Значение коэффициента
1	0.5625
2	0.5637
3	0.5141
4	0.605
5	0.5358
6	0.5666
7	0.5272
8	0.46144
9	0.5507
10	0.536

Однако, в результате экспериментов с Dense-структурой были получены и положительные результаты. При анализе автокорреляционных кривых видно, что при прогнозировании на 1 шаг у данной архитектуры не возникает эффекта автокорреляции, что представлено на рисунке 36:




Рисунок 36. Графики автокорреляционных кривых Dense-сети

При функционировании на данных полной выборки были получены графики, представленные на рисунке 37, значение коэффициента корреляции составило $\text{corr } k = 0.7972$.




Рисунок 37. График функционирования Dense-модели на полной выборке

Еще одной из базовых архитектур глубоких сетей являются сверточные слои, пример которых представлен на рисунке 38.




Рисунок 38. Глубокая сверточная сеть

Функционирование сверточного слоя в общем случае представлено в (23):

$$\left\{ \begin{array}{l} X^{(1)} = f_{ReLU}(X_i^{(0)} \otimes k_j^{(1)} + b_j^{(1)}) \\ X^{(2)} = a^{(2)} \cdot \text{subsample}(X^{(1)}) + b^{(2)} \\ \dots \\ X^{(n)} = f_{ReLU}(X_i^{(m)} \otimes k_j^{(n)} + b_j^{(n)}) \\ X^{(l)} = a^{(l)} \cdot \text{subsample}(X^{(n)}) + b^{(l)} \end{array} \right., \quad (23)$$

где k_j - ядро свёртки, \otimes - операция свёртки входа x с ядром k , a - коэффициент слоя подвыборки, $\text{subsample}(X)$ - операция выборки локальных максимальных значений, b - смещение, X_i - выход i -того слоя.

Первые исследования в области подобных структур датируются 1980-ми годами, одной из наиболее известных считается работа [118], связанная с распознаванием рукописных цифр почтовых индексов. После чего один из авторов данного труда продолжил свои исследования в выбранном направлении и в работе [119] был представлен практически прообраз применяемых сегодня сверточных слоев [115,116,117]. В дальнейшем было осуществлено множество исследований, как, например [120], совершенствовавших данную структуру, которая приобрела известность благодаря созданию сети под название AlexNet [121], победившей в соревнованиях по распознаванию изображений ImageNet, что и считается толчком к современному уровню интереса и применения машинного обучения.

В зависимости от размерности исходных обрабатываемых данных, сверточные сети также различаются в соответствии с числом осей измерений в данных. В случае рассматриваемой технологических агрегатов, где все сигналы представляют собой временные ряды, целесообразно и общепринято применение 1-мерной свертки, или так называемых CONV1D сетей, что и было рассмотрено в работе.

По аналогии с экспериментами на Dense сетях, была произведена оценка возможности применения сверточной структуры путем апробирования различных архитектур и перебора соответствующих гиперпараметров. Опытами были апробированы CONV1D сети следующей конфигурации: число нейронов во входном слое – от 50 до 150; число нейронов в скрытом слое 1 – от 50 до 150; число нейронов в скрытом слое 2 – от 50 до 150; число нейронов в выходном слое – от 200 до 400; число эпох обучения – от 15 до 35; размер батча данных - от 25 до 95.

Лучший результат был получен при функционировании сети со структурой [150, 150, 50, 200, 35, 60], значение ошибки loss (mse) = 0.003635986074571699.

Качество функционирования CONV1D сети на валидационной выборке представлен на рисунках 39 и 40.




Рисунок 39. Пример аппроксимации точек обучающей выборки CONV1D сетью




Рисунок 40. Гистограмма распределения остатков CONV1D сети

Из представленных рисунков видно, что аппроксимация точек сетью происходит менее качественно, чем при функционировании Dense сети, гистограмма остатков в меньшей степени соответствует нормальному распределению. Однако, при этом график предсказанных моделью значений, представленный на рисунке 41, где исходные данные представлены оранжевым цветом, а результат работы глубокой ИНС – синим, достаточно хорошо повторяет характер оригинального графика.




Рисунок 41. График функционирования CONV1D модели на валидационной выборке

Данный факт подтверждается и при анализе численных значений коэффициента корреляции, приведенных в таблице 16.

Таблица 16. Численные значения коэффициента корреляции при функционировании CONV1D модели на валидационной выборке

Шаг прогноза	Значение коэффициента
1	0.6255
2	0.5899
3	0.6395
4	0.618
5	0.62865
6	0.6107
7	0.5345
8	0.5961
9	0.6106
10	0.58252

На рисунках 42 и 43 представлены автокорреляционные кривые и графики функционирования сверточной сети при функционировании на всех данных.




Рисунок 42. Графики автокорреляционных кривых CONV1D сети




Рисунок 43. График функционирования CONV1D модели на полной выборке

Из представленных данных видно, что сверточная сеть гораздо более качественно улавливает общий тренд оригинального сигнала плотности, существенно фильтруя «колебания» графика, что позволяет получить достаточно высокое значение коэффициента корреляции $\text{corr } k = 0.8866$ при функционировании на полной выборке. Однако, негативным моментом данного типа сети является возникновение эффекта автокорреляции при функционировании.

Следующим видом типовых слоев, применяемых в глубоких сетях, являются LSTM (Long-Short Term Memory – долгая краткосрочная память) слои. Данный тип слоев является развитием рекуррентной архитектуры организации подачи данных и обеспечивает устранение недостатков, присущих классическим многослойным рекуррентным ИНС:

- фактически сети оперируют очень короткими динамическими контекстами, забывание «прошлого» идёт с экспоненциальной скоростью;

- в рамках одной сети очень сложно совмещать процессы различных масштабов, в том числе «быстрое» и «медленное» время, а также обрабатывать пропуски данных;

– рекуррентные сети, построенные по типу MLP, очень сложно обучать (используется алгоритм Backpropagation Through Time) при больших значениях К: градиент либо затухает, либо испытывает взрывной рост [44].

Для решения этих проблем в работе [122] Ш. Хохрайтером была представлена элементарная LSTM-ячейка, которая и стала основой для применения в слоях нового типа, обеспечивающая внутреннюю рекуррентную связь и предназначенная для работы с данными, являющимися последовательностями. Пример ячейки представлен на рисунке 44.




Рисунок 44. Элементарная LSTM ячейка

Функционирование LSTM ячейки в общем случае осуществляется согласно (24):

$$\begin{cases} f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \\ i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \\ o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \\ c_t = f_t \circ c_{t-1} + i_t \circ \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \\ h_t = o_t \circ \sigma_h(c_t) \end{cases}, \quad (24)$$

где x_t - входной вектор, h_t - выходной вектор, c_t - вектор состояний, W, U, b - матрицы и вектор весовых параметров, f_t, i_t, o_t - вектор вентилей, $\sigma_g, \sigma_c, \sigma_h$ - функции активации.

При проведении экспериментов с данным типом слоев, были рассмотрены архитектуры со следующими гиперпараметрами: число нейронов во входном слое – от 50 до 150; число нейронов в скрытом слое 1 – от 50 до 150; число нейронов в скрытом слое 2 – от 50 до 150; число нейронов в выходном слое – от 200 до 400; число эпох обучения – от 15 до 35; размер батча данных - от 25 до 95.

Лучший результат был получен при функционировании сети со структурой [50;50;50;400;15;60], достигнутое наилучшее значение ошибки $\text{loss (mse)} = 0.003916286093610083$. Качество функционирования CONV1D сети на валидационной выборке представлено на рисунках 45 и 46.




Рисунок 45. Пример аппроксимации точек обучающей выборки LSTM сетью




Рисунок 46. Гистограмма распределения остатков LSTM сети

На рисунке 47 представлен результат функционирования LSTM модели на валидационной выборке, где исходные данные представлены оранжевым цветом, а результат работы глубокой ИНС – синим.




Рисунок 47. График функционирования LSTM модели на валидационной выборке

На графике видно, что выходной сигнал LSTM сети в значительной степени усредняет оригинальный сигнал, то есть сеть улавливает главный тренд, но плохо отслеживает небольшие амплитудные колебания. Это выражается в численных значениях коэффициента корреляции, значения которого представлены в таблице 16.

Таблица 16. Численные значения коэффициента корреляции при функционировании LSTM модели на валидационной выборке

Шаг прогноза	Значение коэффициента
1	0.5648
2	0.5733
3	0.57185
4	0.5596
5	0.52816
6	0.559
7	0.529
8	0.4391
9	0.4505
10	0.4977

В ходе анализа автокорреляционных кривых было выяснено, что при функционировании данного типа сетей присутствует эффект автокорреляции, что представлено на рисунке 48.




Рисунок 48. Графики автокорреляционных кривых LSTM сети

График функционирования данной сети на полной выборке представлен ниже.




Рисунок 49. График функционирования LSTM модели на полной выборке

Несмотря на наличие эффекта автокорреляции, стоит отметить, что данная сеть очень хорошо прогнозирует общий характер графика, что выражается в значении коэффициента корреляции $\text{corr } k$ на всех данных: 0.82192.

После проведения экспериментов с типовыми архитектурами глубоких ИНС и выделения их положительных и отрицательных сторон, было сделано предположение, что создание структуры, включающей в себя все 3 типа архитектур, предположительно, позволит объединить в себе положительные моменты каждой из них и уменьшить влияние отрицательных свойств. Для этого на языке программирования Python в среде Colab была реализована структура сети, получившая название гибридная глубокая ИНС. На входе такой сети располагается полносвязный слой, обрабатывающий входную информацию и осуществляющий ее трансформацию. После чего данные передаются параллельно по 3м путям: полносвязному, сверточному (CONV1D) и LSTM. После чего обработанная информация вновь объединяется и интерпретируется набором выходных полносвязных слоев и предстает в итоговом виде. Общий вид данной структуры представлен на рисунке 50.

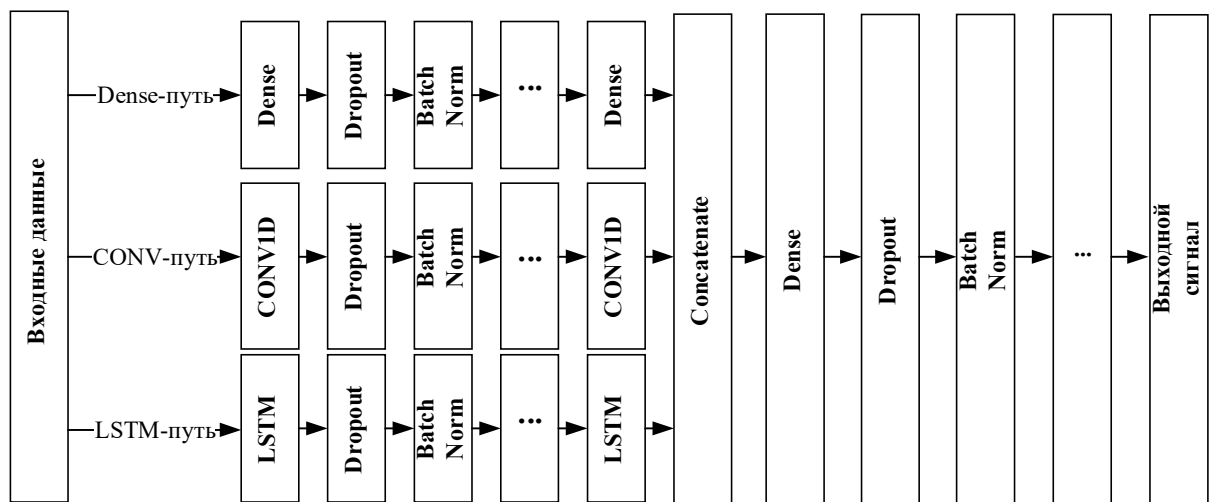


Рисунок 50. Структура гибридной глубокой ИНС

После реализации данной архитектуры в среде Colab, были выполнены эксперименты по подбору параметров сети, обеспечивающих получение наилучших результатов при ее функционировании. Ввиду высокой вычислительной сложности сети, диапазон изменения параметров был уменьшен, в сравнении с предыдущими глубокими ИНС структурами: число нейронов в LSTM слое – от 50 до 150; число нейронов в CONV1D слое – от 50 до 150; число нейронов в Dense слое – от 50 до 150; число нейронов в выходном слое – от 200 до 400; число эпох обучения – от 15 до 35; размер батча – от 25 до 95. Максимальное качество моделирования было достигнуто при использовании сети с конфигурацией [50;50;150;400;35;95], значение достигнутой ошибки $\text{loss (mse)} = 0.00357$. Результаты функционирования данной архитектуры с указанными параметрами представлены ниже на рисунках 51 и 52.




Рисунок 51. Пример аппроксимации точек обучающей выборки гибридной сетью




Рисунок 52. Гистограмма распределения остатков гибридной сети

График функционирования данной сети на валидационной выборке при прогнозировании на 1 шаг представлен на рисунке 53, где исходные данные представлены оранжевым цветом, а результат работы глубокой ИНС – синим.




Рисунок 53. График функционирования гибридной модели на валидационной выборке

Из представленных графиков можно сделать вывод, что данная архитектура позволяет в достаточной степени анализировать входные сигналы и осуществлять качественный прогноз, аппроксимируя не только общий характер тренда сигнала плотности слива, но и интерпретируя амплитудные колебания. Полученные автокорреляционные кривые и численные значения коэффициента корреляции также показали, что данная архитектура позволяет должным образом решать поставленную задачу предоставления качественно прогноза значения плотности на 1 такт без наступления автокорреляции.

Для анализа устойчивости прогноза были выполнены эксперименты с различными соотношениями объемов обучающей и тестовой выборок, результаты представлены в таблице 17.

Таблица 17. Численные показатели качества моделирования при вариации соотношения объема выборок

Соотношение выборки	90/10	80/20	70/30	60/40	50/50
corr k	0.867	0.8139	0.726	0.794	0.773
MSE*10²	0.31	0.36	0.41	0.37	0.36
crit A	279.67	226.083	177.07	214.59	214.72

Из представленных численных значений видно, что результат прогнозирования гибридной глубокой ИНС достаточно стабилен при значительной вариации соотношения объемов выборок.




Рисунок 54. Графики автокорреляционных кривых гибридной сети




Рисунок 55. График функционирования гибридной модели на полной выборке

Представленные результаты позволяют сделать вывод, что опробованный аппарат показывает достаточно качественные результаты. Необходимо отметить, что гибридная сеть, включающая набор стандартных глубоких сетей, объединенных в параллельную структуру, позволяет добиться стабильного результата предотвращения явления автокорреляции выходного сигнала модели без значительной потери качества работы. Это говорит о возможности ее

применения и для разработки моделей прочих агрегатов технологического процесса обогащения железорудного сырья для целей создания единой прогнозирующей системы.

3.2. РАЗРАБОТКА МОДЕЛЕЙ АГРЕГАТОВ ТЕХНОЛОГИЧЕСКОГО ПРОЦЕССА ОБОГАЩЕНИЯ

После выполнения представленных экспериментов и формирования алгоритма создания моделей технологических агрегатов, учитывающего требования предобработки данных, а также предполагающего создание и оптимизацию параметров моделей при выполнении первоначального запуска прогнозирующей системы, который представлен в Приложении Б, были созданы модели прочих технологических агрегатов на основе аппаратов моделирования, представленных ранее, и с использованием схемы, представленной на рисунке 7. Функциональные зависимости, описывающие работу моделей с учетом взаимной интеграции сигналов плотностей – то есть при выполнении операции прогнозирования, представлены в (25):

$$Fe(D_{1.1}, D_{1.2} \dots D_{1.4}, D_{2.1} \dots D_{2.3}, D_{3.1}, D_{3.2}) = f_{3.3}(f_{3.2}(f_{3.1}[f_{1.4}(f_{1.3}(f_{1.2}(f_{1.1}(A_{1.1}(t))), A_{1.2}(t))), A_{1.3}(t))), A_{1.4}(t)), f_{2.3}(f_{2.2}(f_{2.1}(A_{2.1}(t))), A_{2.2}(t))), A_{2.3}(t))), A_{3.1}(t)], A_{3.2}(t))), A_{3.3}(t))) \quad (25)$$

где [Fe] – итоговый выходной сигнал содержания железа, [D1.1, D1.2, D1.3, D1.4, D2.1, D2.2, D2.3, D3.1, D3.2] – выходные сигналы плотности каждой из моделей соответственно, 1.1...1.4 – индексы величин, относящихся к моделям агрегатов первой полусекции, 2.1...2.3 – индексы величин, относящихся к моделям агрегатов второй полусекции, 3.1...3.3 – индексы величин, относящихся к моделям агрегатов результирующего участка секции.

Указанные в выражении (25) векторы $A_{1.1} \dots A_{3.3}$ являются кортежами входных управляющих сигналов и представлены в выражении (26):

$$\left\{ \begin{array}{l} A_{1.1} = [W_{1.1}(t); QI_{1.1}(t); Q2_{1.1}(t); P_{1.1}(t); II_{1.1}(t); I2_{1.1}(t)], \\ A_{1.2} = [U_{1.2}(t); L_{1.2}(t); F_{1.2}(t); P_{1.2}(t)], \\ A_{1.3} = [U_{1.3}(t); L_{1.3}(t)], \\ A_{1.4} = [DI_{1.4}(t); U_{1.4}(t); U2_{1.4}(t); L_{1.3}(t)], \\ A_{2.1} = [W_{2.1}(t); QI_{2.1}(t); Q2_{2.1}(t); P_{2.1}(t); II_{2.1}(t); I2_{2.1}(t)], \\ A_{2.2} = [U_{1.2.2}(t); L_{1.2.2}(t); Q2_{2.2}(t); P_{2.2}(t); U2_{2.2}(t); L2_{2.2}(t)], \\ A_{2.3} = [DI_{2.3}(t); U_{1.2.3}(t); U2_{2.3}(t); L2_{2.3}(t)], \\ A_{3.1} = [U_{3.1}(t); L_{3.1}(t)], \\ A_{3.2} = [U_{1.3.2}(t); U2_{3.2}(t); L_{1.3.2}(t); DI_{3.2}(t); D2_{3.2}(t); L2_{3.2}(t); U3_{3.2}(t); L3_{3.2}(t); P_{3.2}(t)], \\ A_{3.3} = [U_{1.3.3}(t); U2_{3.3}(t); L_{3.3}(t); DI_{3.3}(t); D2_{3.3}(t)] \end{array} \right. \quad (26)$$

где $A_{1.1} = [(W_{1.1}(t)); (QI_{1.1}(t)); (Q2_{1.1}(t)); (P_{1.1}(t)); (II_{1.1}(t)); (I2_{1.1}(t))]$ – кортеж сигналов входных параметров модели «Модель_1.1» [вес руды, загружаемой в мельницу ($W_{1.1}(t)$); объем подачи воды в загрузку мельницы ($QI_{1.1}(t)$); объем подачи воды в разгрузочную бутару мельницы ($Q2_{1.1}(t)$); мощность, потребляемая приводом мельницы ($P_{1.1}(t)$); ток 1-ой спирали классификатора ($II_{1.1}(t)$); ток 2-ой спирали классификатора ($I2_{1.1}(t)$)], $A_{1.2} = [(D_{1.1}(t)); (U_{1.2}(t)); (L_{1.2}(t)); (F_{1.2}(t)); (P_{1.2}(t))]$ – кортеж сигналов входных параметров модели «Модель_1.2» [выходной сигнал плотности предыдущей модели ($D_{1.1}(t)$); положение ИМ подачи воды в зумпф ($U_{1.2}(t)$); уровень в зумпфе ($L_{1.2}(t)$); объем подачи воды в престожную мельницу ($F_{1.2}(t)$); мощность привода мельницы ($P_{1.2}(t)$)], $A_{1.3} = [(D_{1.2}(t)); (U_{1.3}(t)); (L_{1.3}(t))]$ – кортеж сигналов входных параметров модели «Модель_1.3» [выходной сигнал плотности предыдущей модели ($D_{1.2}(t)$); положение ИМ подачи воды в зумпф ($U_{1.3}(t)$); уровень в зумпфе ($L_{1.3}(t)$)], $A_{1.4} = [(D_{1.3}(t)); (DI_{1.4}(t)); (U_{1.4}(t)); (U2_{1.4}(t)); (L_{1.3}(t))]$ – кортеж сигналов входных параметров модели «Модель_1.4» [выходной сигнал плотности предыдущей модели ($D_{1.3}(t)$); плотность песков на сливе дешламатора ($DI_{1.4}(t)$); положение ИМ подачи воды в зумпф ($U_{1.4}(t)$); положение ИМ на сливе дешламатора ($U2_{1.4}(t)$); уровень в зумпфе ($L_{1.4}(t)$)], $A_{2.1} = [(W_{2.1}(t)); (QI_{2.1}(t)); (Q2_{2.1}(t)); (P_{2.1}(t)); (II_{2.1}(t)); (I2_{2.1}(t))]$ – кортеж сигналов входных

параметров модели «Модель_2.1» [вес руды, загружаемой в мельницу ($W_{2.1}(t)$); объем подачи воды в загрузку мельницы ($QI_{2.1}(t)$); объем подачи воды в разгрузочную бутару мельницы ($Q2_{2.1}(t)$); мощность, потребляемая приводом мельницы ($P_{2.1}(t)$); ток 1-ой спирали классификатора ($II_{2.1}(t)$); ток 2-ой спирали классификатора ($I2_{2.1}(t)$)], $A_{2.2}=[(D_{2.1}(t)); (UI_{2.2}(t)); (LI_{2.2}(t)); (F_{2.2}(t)); (P_{2.2}(t)); (U2_{2.2}(t)); (L2_{2.2}(t))]$ – кортеж сигналов входных параметров модели «Модель_2.2» [выходной сигнал плотности предыдущей модели ($D_{2.1}(t)$); положение ИМ подачи воды в зумпф ($UI_{2.2}(t)$); уровень в зумпфе ($LI_{2.2}(t)$); объем подачи воды в престожную мельницу ($F_{2.2}(t)$); мощность привода мельницы ($P_{2.2}(t)$); положение ИМ подачи воды в зумпф ($U2_{2.2}(t)$); уровень в зумпфе ($L2_{2.2}(t)$)], $A_{2.3}=[(D_{2.2}(t)); (DI_{2.3}(t)); (UI_{2.3}(t)); (U2_{2.3}(t)); (L2_{2.3}(t))]$ – кортеж сигналов входных параметров модели «Модель_2.3» [выходной сигнал плотности предыдущей модели ($D_{2.2}(t)$); плотность песков на сливе дешламатора ($DI_{2.3}(t)$); положение ИМ подачи воды в зумпф ($UI_{2.3}(t)$); положение ИМ на сливе дешламатора ($U2_{2.3}(t)$); уровень в зумпфе ($L2_{2.3}(t)$)], $A_{3.1}=[(D_{1.4}(t)); (D_{2.3}(t)); (U_{3.1}(t)); (L_{3.1}(t))]$ – кортеж сигналов входных параметров модели «Модель_3.1» [выходные сигналы плотностей предыдущих моделей ($D_{1.4}(t), D_{2.3}(t)$); положение ИМ подачи воды в зумпф ($U_{3.1}(t)$); уровень в зумпфе ($L_{3.1}(t)$)], $A_{3.2}=[(D_{3.1}(t)); (UI_{3.2}(t)); (U2_{3.2}(t)); (LI_{3.2}(t)); (DI_{3.2}(t)); (D2_{3.2}(t)); (L2_{3.2}(t)); (U3_{3.2}(t)); (L3_{3.2}(t)); (P_{3.2}(t))]$ – кортеж сигналов входных параметров модели «Модель_3.2» [выходной сигнал плотности предыдущей модели ($D_{3.1}(t)$); положение ИМ подачи воды в зумпфы ($UI_{3.2}(t), U2_{3.2}(t), U3_{3.2}(t)$); уровень в зумпфах ($LI_{3.2}(t), L2_{3.2}(t), L3_{3.2}(t)$); плотности питания мокрой магнитной сепарации ($DI_{3.2}(t), D2_{3.2}(t)$); мощность, потребляемая приводом мельницы ($P_{3.2}(t)$)], $A_{3.3}=[(D_{3.2}(t)); (UI_{3.3}(t)); (U2_{3.3}(t)); (L_{3.3}(t)); (DI_{3.3}(t)); (D2_{3.3}(t))]$ – кортеж сигналов входных параметров модели «Модель_3.3» [выходной сигнал плотности предыдущей модели ($D_{3.2}(t)$); положение ИМ подачи воды в зумпфы ($UI_{3.3}(t), U2_{3.3}(t)$); уровень в зумпфе ($L_{3.3}(t)$); плотность питания мокрой магнитной сепарации ($DI_{3.3}(t)$); плотность песков на сливе дешламатора ($D2_{3.3}(t)$)].

На основании схемы, представленной на рисунке 7, была разработана схема, представленная на рисунке 56, являющаяся наглядным изображением зависимости (25) и с набором сигналов (26):

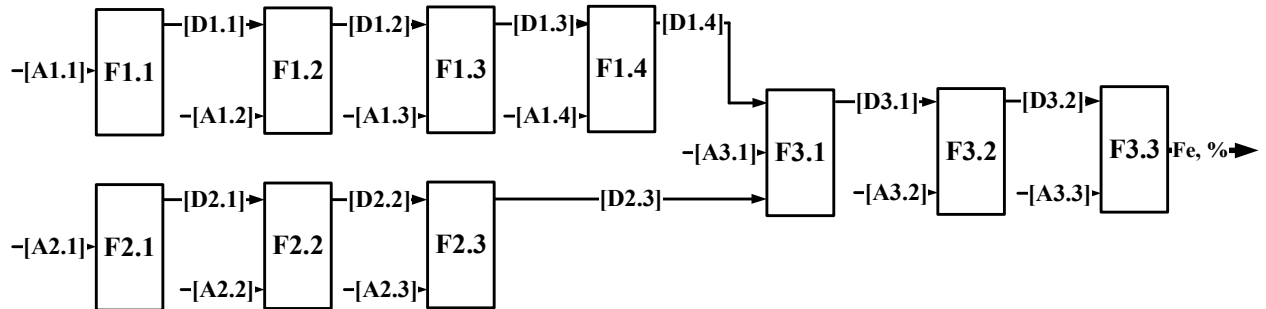


Рисунок 56. Схема функциональной зависимости единой модели секции обогащения

Параллельно с разработкой классических и глубоких нейросетевых моделей, как уже говорилось ранее, для проведения процедуры сравнительного анализа, были разработаны регрессионные модели объектов технологической цепи получения железорудного концентрата. При идентификации технологических агрегатов данным методом использовался тот же набор данных, что и при разработке моделей на базе аппарата ИНС. Однако, для чистоты эксперимента, была использована выборка данных объемом 30000 точек за иную дату, нежели данные, на которых производилось обучение и тестирование ранее. Они были подвергнуты тем же процедурам предобработки.

В процессе разработки моделей был выявлен недостаток, заключающийся в возможности разнонаправленной оценки качества работы модели в случае применения двух озвученных ранее критериев качества – коэффициента корреляции и среднеквадратичной ошибки (MSE). Для предотвращения данной ситуации был разработан и применен агрегированный критерий, представленный в выражении (27):

$$critA = \frac{corr_k}{MSE}, \quad (27)$$

где $corr\ k$ - значение коэффициента корреляции, MSE - значение среднеквадратичной ошибки.

Задачей моделирования с позиции оценки критериев, стала достижение максимального значения данного показателя.

После разработки моделей на основе аппаратов классических и глубоких ИНС и регрессии, их интеграции в единые системы, была произведена по модельная оценка качества работы на тестовых данных. Результаты представлены в таблице 18.

Таблица 18. Численные значения показателей качества работы прогнозирующей системы при использовании различного аппарата моделирования

№ модели	Аппарат моделирования								
	Регрессионный анализ			Классические многослойные ИНС			Глубокие ИНС гибридной архитектуры		
	corr k	MSE*10 ²	crit A	corr k	MSE*10 ²	crit A	corr k	MSE*10 ²	crit A
1_1 «Шаровая мельница – спиральный классификатор»	0.9856	0.383	257.354	0.9793	0.2053	476.91	0.8139	0.36	226.083
1_2 «ММС – Зумпф – Шаровая мельница»	0.9934	0.6268	158.489	0.9936	0.5913	168.034	0.8911	1.2781	69.721
1_3 «ММС – Зумпф – Гидроциклоны»	0.8169	2.828748	28.88	0.866	2.14	40.472	0.853	3.4376	24.81
1_4 «Дешламатор – Зумпф»	0.99	0.687	144.1	0.9959	0.43	231.81	0.916	1.347	68.003
2_1 «Шаровая мельница – спиральный классификатор»	0.9651	0.3549	271.963	0.9692	0.313	309.65	0.894	0.977	91.505

2_2 «ММС – Зумпф – Шаровая мельница - Гидроциклоны»	0.9756	0.7516	129.804	0.9811	0.6122	160.25	0.9018	1.663	54.23
2_3 «Дешламатор – Зумпф»	0.9456	1.896	49.87	0.9341	1.89	49.53	0.8632	2.492	34.64
3_1 «ММС – Зумпф»	0.9731	0.1252	777.24	0.9674	0.151	641.014	0.8574	1.224	70.05
3_2 «Мелкое грохочение – Зумпф – ММС – Шаровая мельница – Гидроциклоны»	0.9943	0.238	417.01	0.9943	0.24	414.6	0.8817	1.2861	68.56
3_3 «Дешламатор – Зумпф - ММС»	0.9949	0. 5082	195.78	0.9948	0.43	231.55	0.8547	1.757	48.645

Графики работы систем на основе различного аппарата, в сравнении с реальными значениями сигнала содержания железа в концентрате, представлены на рисунках 57 и 58.




Рисунок 57. Результат работы систем на основе различного аппарата моделирования




Рисунок 58. Результат работы систем на основе различного аппарата моделирования в укрупненном виде

Представленные результаты показывают, что модели на базе аппарата глубоких гибридных искусственных нейронных сетей позволяют получить удовлетворяющий по качеству прогноз без эффекта автокорреляции, что в итоге обеспечивает правильность функционирования системы прогнозирования в целом. Этот факт подтверждает правильность выбранного подхода.

ВЫВОДЫ ПО ГЛАВЕ 3

В ходе осуществления исследований, представленных в третьей главе, была выполнена разработка моделей одного из основных агрегатов технологического передела обогащения – комплекса «шаровая мельница – спиральный классификатор». При проведении экспериментов была рассмотрена возможность и произведен сравнительный анализ результатов использования аппарата регрессионного анализа, классических многослойных искусственных нейронных сетей и глубоких нейронных сетей.

В результате чего был сделан вывод о возможности глубоких нейронных сетей гибридной архитектуры аппроксимировать сложные нелинейные зависимости, которыми представлены технологические переменные, и выполнять прогнозирование хода развития процесса с достаточной точностью за счет экстраполяционных возможностей аппарата без появления эффекта автокорреляции. При совместном использовании алгоритмов предобработки данных и построения моделей, был разработан полный перечень моделей, осуществлена их интеграция.

ГЛАВА 4. РАЗРАБОТКА ПРОГРАММНОГО КОМПЛЕКСА ПРОГНОЗИРУЮЩЕЙ НЕЙРОСЕТЕВОЙ СИСТЕМЫ

Управление процессом обогащения осуществляется операторами через операторские станции, на которых технологический процесс отображается в виде мнемосхем, графиков, рапортов и сообщений. При этом контроллер опрашивает состояние приборов измерения, проводит все стадии предварительной обработки сигналов, выполняет необходимые расчеты, передает актуальную информацию в выходные блоки. Система визуализации запрашивает о необходимой для архивирования и визуализации информации, записывает данные для длительного хранения, выводит информацию о состоянии технологического объектов на экран, сообщает в особой форме о выходе технологических параметров за рамки допустимого. Кроме этого, система визуализации позволяет пользователю осуществлять оперативное управление технологическими механизмами непосредственно с операторской станции. При этом управляющие воздействия, команды, заданные значения и т. п. передаются в контроллер. Обмен данными между контроллером и системой визуализации происходит посредством локальной сети Industrial Ethernet. Архив данных (обучающая выборка) передаются в специализированный пакет Matlab и интерпретатор языка Python, где производится обучение НС.

Система автоматизации относится к классу распределенных и состоит из двух уровней:

- 1) уровень интерфейса пользователя (верхний уровень);
- 2) уровень автоматизации (нижний уровень).

На нижнем уровне системы реализуются следующие функции:

- сбор первичной информации от датчиков измерения параметров технологического процесса;
- выдача управляющих воздействий исполнительным механизмам технологического оборудования.

На верхнем уровне системы реализуются следующие функции:

- визуализация технологического процесса в реальном масштабе времени;
- управление оборудованием (дистанционный запуск/останов механизмов, управление контурами регулирования);
- хранение и отображение архивных данных о состоянии оборудования и данных технологического процесса;
- обработка информации в соответствии с разработанными алгоритмами.

Важным компонентом автоматизированных систем является SCADA-система. SCADA (Supervisory Control And Data Acquisition) - это совокупность аппаратно-программных средств, обеспечивающих возможность мониторинга (непрерывного наблюдения, контроля), анализа и управления параметрами технологического процесса человеком. Она является составной частью автоматизированной системы.

Информационное обеспечение разрабатывается на базе SCADA-системы Windows Control Center (WinCC). Технологический процесс управляется через операторские станции, на которых он отображается в виде мнемосхем, графиков, рапортов и сообщений.

Рабочая станция реализует следующие функции:

- отображение на мониторе мнемосхемы технологического процесса;
- выдачу на экран текущих значений технологических параметров;
- сигнализацию о нарушениях технологического регламента;
- сигнализацию о нарушениях в работе контроллера и в канале связи ПЭВМ-контроллер;
- просмотр истории технологических параметров в графической форме;
- дистанционное включение или выключение технологического оборудования;

- изменение уставок локальных контуров регулирования;
- перевод контуров регулирования в режим ручного управления и изменение положения исполнительного механизма;
- ввод значений ручных переменных;
- просмотр протокола аварийных ситуаций;
- просмотр протокола действий операторов;
- анализ состояния системы управления;
- получение оперативной помощи по работе оператора в любой момент времени.

Для реализации данных возможностей была разработана экранная форма. Экранная форма состоит из статических и динамических компонентов. Статические компоненты, например, текст и рисунки, не обновляются контроллером. Динамические же компоненты связаны с PLC и визуализируют текущие значения в памяти PLC. Визуализация может быть реализована в виде буквенно–цифровых индикаторов, трендов и гистограмм. Динамическими компонентами также являются поля ввода, с помощью которых значения, вводимые оператором с операторского терминала, попадают в память PLC. Связь с PLC осуществляется посредством тегов. Экранные формы состоят из отдельных объектов. Существуют различные типы объектов, которые можно использовать как угодно. “Как угодно” означает, что есть возможность задания количества и типа объектов, а также их положения на форме и размера.

Для обмена данными и взаимодействия операторского терминала и PLC необходимо использовать механизм тегов. Тег имеет символьное имя и определенный тип данных. Значение тега изменяется во время исполнения программы PLC. Теги, связанные с PLC, называются глобальными (занимает в PLC определенное адресное пространство, доступное для чтения и записи из операторского терминала и PLC). Теги, не связанные с PLC называются локальными (доступны только в пределах операторского терминала).

Для получения результатов работы в виде графической информации необходимо использовать тренды реального времени, у которых в каждый временной квант (задаваемый импульсами синхронизации) из PLC считывается и добавляется к тренду, отображаемому на операторском терминале, только одно значение. Тренды реального времени подходят для представления медленных, продолжительных процессов. Системы на базе Windows предоставляют возможность архивировать данные процесса (то есть хранить их как угодно долго и анализировать).

Исходя из требований к системе автоматизации необходимо выбрать контроллер, способный справиться с поставленной задачей, обладающий при этом значительным потенциалом для расширения системы. Часть функций контроллера может взять на себя программное обеспечение для разработки систем автоматического управления в реальном масштабе времени - SCADA-системы. Но при реализации алгоритма управления с помощью программного обеспечения типа WinCC необходимо учесть, что для работы построенной таким образом системы необходима одновременная работоспособность и контроллера, и рабочей станции, т.е. снижается надежность. Кроме того, все эти пакеты лицензированы, стоимость лицензии определяется количеством используемых внешних переменных, и при реализации регулирования, количество используемых переменных возрастет.

Контроллер – гораздо более надежное средство для решения задач децентрализованного управления. Кроме того, при выходе из строя рабочей станции, его автономность позволит по графику завершить технологический процесс, с потерей при этом функций учета и архивирования параметров технологического процесса. Если же рабочая станция вышла из строя не на долго, то резерв оперативной памяти CPU контроллера позволяет программно реализовать буфер параметров при прекращении квитирования, для важнейших передаваемых данных. Основными требованиями к контроллеру должны быть его надежность, достаточное количество аналоговых и цифровых входов и выходов,

возможность подключения системы визуализации, возможность объединения контроллеров в локальную сеть [93].

После реализации системы моделей и их интеграции, была произведена разработка программного комплекса, обеспечивающего функционирование системы прогнозирования с целью предоставления возможности ее интеграции в существующую систему управления и разработка алгоритма ее функционирования. С этой целью была разработана принципиальная схема интеграции функционала прогнозирования в существующую систему, представленная на рисунке 59.

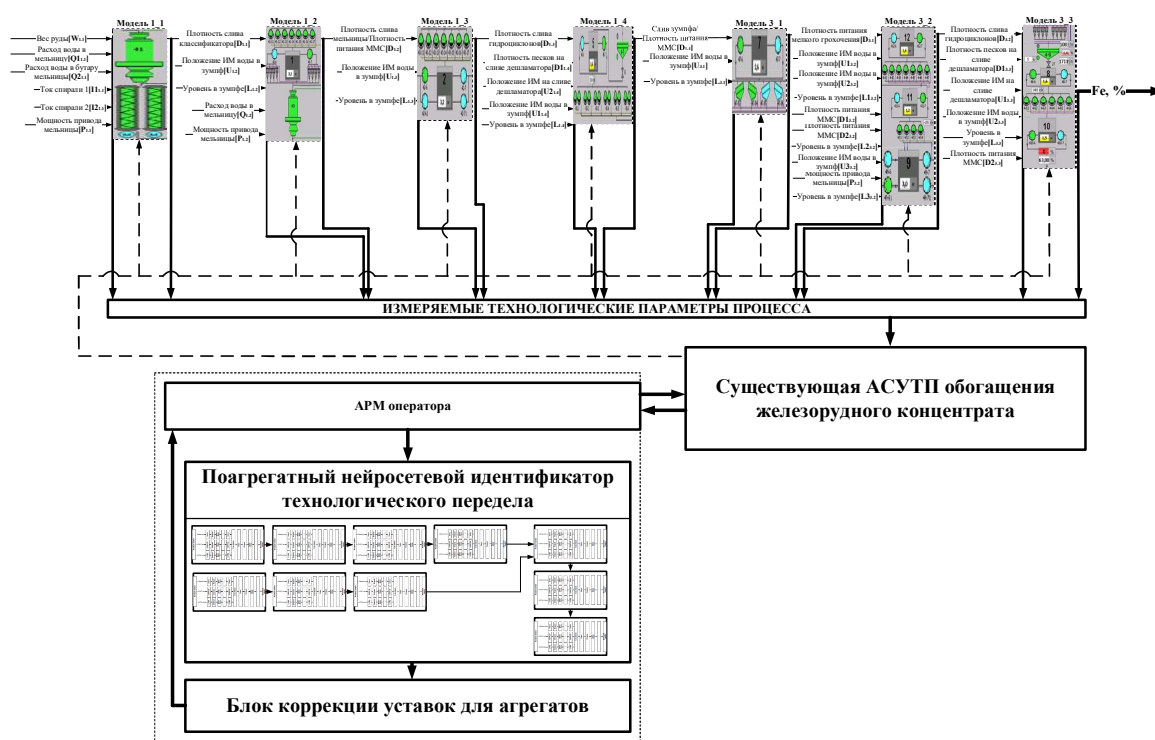


Рисунок 59. Принципиальная схема функционирования прогнозирующей системы при интеграции в существующую АСУТП

В ходе сравнения результатов функционирования систем на базе различного аппарата, была произведена оценка динамики изменения ошибки прогнозирования с течением времени – то есть в ходе процесса последовательного удаления временных моментов от границ обучающей выборки. Это симулировало

постепенное изменение параметров как поступающего сырья, так и самого работающего оборудования.

В данных условиях регрессионная модель продемонстрировала более быстрое снижение качества прогноза на тестовой выборке даже в сравнении с классическими многослойными ИНС, что позволило выявить проблему деградации системы моделей и ухудшения качества предоставляемого прогноза. Графики данной оценки представлены на рисунке 60.




Рисунок 60. График динамики изменения ошибки прогнозирования при функционировании систем на базе регрессионного аппарата и классических многослойных ИНС

Для предотвращения данного негативного явления разработана концепция параллельного создания двух наборов нейросетевых моделей. С целью реализации данной идеи был разработан алгоритм, предполагающий обозначение полученных моделей как «основная» и «резервная».

В ходе функционирования системы выполняется процесс непрерывного предоставления прогноза «основной» моделью, в то же время происходит и обучение «резервной» модели на актуализированных данных. Затем, в момент появления значения показателей процентного содержания железа в концентрате посредством нового лабораторного анализа, происходит оценка ошибки прогнозирования. В случае, если данное значение превышает граничное значение

показателя, равное 0,5% - выполняется процедура смены приоритетов, «резервная» модель, обученная на более актуальных данных, начинает осуществлять функции прогнозирования, «основная» модель выполняет процедуру обучения. Если ситуации превышения ошибки не наступает – система продолжает процесс функционирования в штатном режиме, «основная» модель выполняет процедуру прогнозирования, а «резервная» обучается по мере осуществления процесса набора и формирования актуализированных выборок данных.

Разработанный алгоритм функционирования системы прогнозирования представлен на рисунке 61.

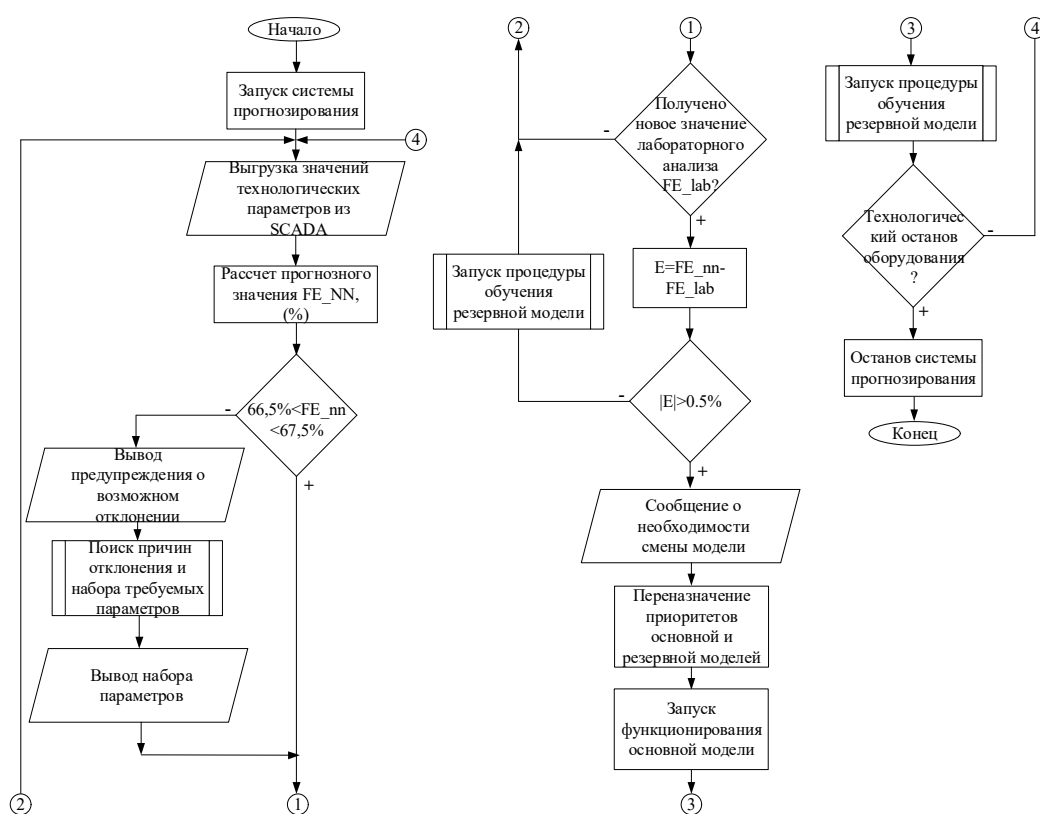


Рисунок 61. Алгоритм функционирования прогнозирующей системы

Для целей интеграции разработанного функционала в реальную систему управления в среде WinCC было разработано обеспечение, предоставляющее прогнозное значение качественного показателя содержания железа в концентрате для помощи оператору обогатительной фабрики с учетом требований по минимизации изменений, вносимых в процедуру управления.

С учетом этого, в окно главного кадра SCADA-системы было добавлено поле отображения прогнозного значения параметра содержания железа. В качестве основного функционала был разработан и интегрирован в существующую структуру проекта SCADA-системы WinCC кадр, представленный на рисунке 62, отображающий перечень моделей агрегатов секции согласно разработанной схеме.

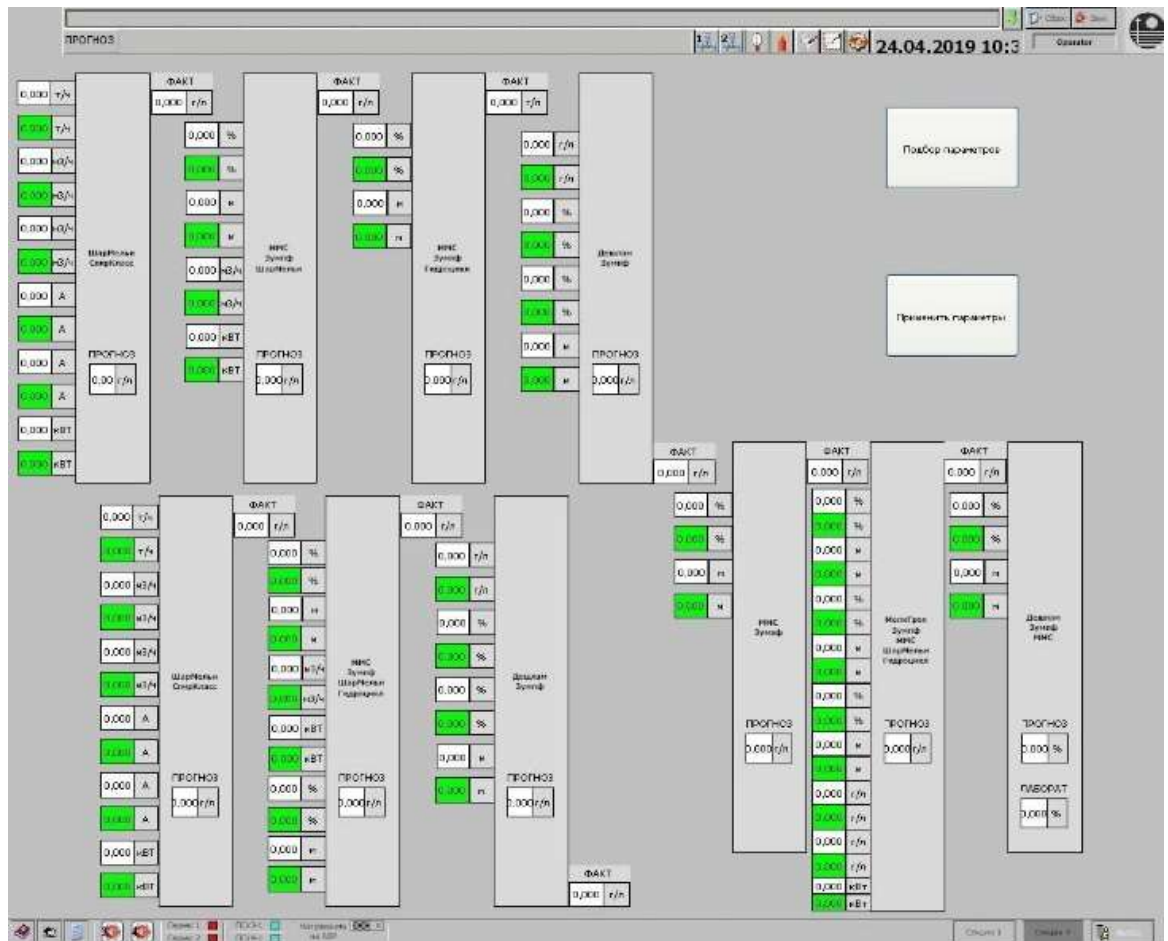


Рисунок 62. Экранная форма поагрегатной схемы моделей, реализованной в проекте в SCADA-системы

Оценивая значения параметров с помощью представленного функционала, оператор имеет возможность оценить не только прогнозируемое изменение показателя $\{Fe, \%\}$, но и выявить участок технологии, который оказывает негативное влияние на значение показателя. В случае наступления подобной ситуации оператору предоставляется возможность запустить процедуру подбора

параметров, которые позволят избежать ситуации выхода за технологические или желаемые границы значений процесса.

Для этого осуществляется процедура перебора наборов входных параметров начиная с текущих значений и изменяя их в рамках допуска по технологии. Затем, после окончания процедуры подбора, оператор может применить данные параметры.

Для реализации данного функционала были рассмотрены такие алгоритмы подбора параметров, как осуществление полного перебора значений входных сигналов для определения кортежа, обеспечивающего минимальную ошибку по выходу, и реализация поиска с применением эволюционного подхода – генетического алгоритма. Несмотря на гарантированную сходимость процедуры поиска при осуществлении полного перебора, основным его недостатком стало время работы. Так, в ходе эксперимента, при подборе параметров путем полного перебора, кортеж значений входных сигналов, обеспечивающий минимальную ошибку прогноза, был найден на 22254 итерации, что составило порядка 50 минут реального времени. Это сопоставимо со временем прохождения сырья через всю технологическую цепочку. Применение подбора с использованием генетического алгоритма позволило исключить данный недостаток и, при выполнении процедуры сравнительного моделирования, осуществить подбор параметров с допустимым уровнем ошибки за время, не превышающее 6-8 минут.

Предполагаемым положительным эффектом от использования данной прогнозирующей системы будет наличие у оператора технологического процесса обогащения инструмента, предоставляющего в режиме реального времени значение процентного содержания железа в концентрате с высокой степенью точности. Информация, получаемая путем функционирования данного программного комплекса, позволит оператору осуществлять управление в областях изменения значений переменных, приближенных к граничным, не нарушая требований технологии.

Одним из основных показателей работы обогатительного передела является объем обрабатываемого материала, который численно равен весу руды, подаваемой в головную мельницу технологической цепочки. При средних значениях показателя, измеренных в ходе экспериментов, равных приблизительно 579,1 тонны в час и возможном увеличении значения до 590 тонн в час за счет увеличения возможной зоны изменения параметра при учете недопущения превышения верхнего граничного значения, равного, согласно технологической карты, 600 тоннам в час. В годовом выражении, с учетом различных возможных нештатных ситуаций, прирост составит порядка 170 000 дополнительных тонн переработанного продукта. Чистая прибыль от производства дополнительной тонны товарного концентрата в час за вычетом затрат различного характера, позволяет предположить положительный экономический эффект на уровне более 230 миллионов рублей в годовом исчислении.

ВЫВОДЫ ПО ГЛАВЕ 4

В четвертой главе представлен процесс создания программного комплекса, реализующего прогнозирующий функционал на базе системы моделей, разработанных ранее. Для этого была использована SCADA система WinCC по причине широкого использования данного ПО в системах автоматизированного управления, и, в частности, на рассматриваемом горно-обогатительном комбинате.

Разработанный функционал предоставляет оператору возможность оценки содержания железа в выходном продукте обогатительного передела. Для этого на главном кадре проекта SCADA было добавлено окно отображения прогнозного значения. Дополнительно, была разработана экранная форма, предоставляющая доступ к прогнозу помодельных значений измеряемых параметров. Это обеспечивает оператору возможность их оценки, причем не только для выявления факта изменения значения процентного содержания железа, но и для установления причин, повлекших данное изменение. После проведения данной процедуры возможно осуществление операции подбора параметров, способных стабилизировать ход процесса.

Использование стандартных средств автоматизации, таких как SCADA система WinCC, позволяет минимизировать изменения, требуемых для внедрения прогнозирующей системы в ход управления переделом обогащения.

ЗАКЛЮЧЕНИЕ

Диссертационная работа посвящена решению важной научно-технической задачи разработки системы прогнозирования содержания железа в конечном продукте технологического процесса обогащения железорудного концентрата на основе поагрегатного нейросетевого моделирования.

В ходе решения данной задачи автором лично были получены следующие основные результаты:

1. Произведен анализ процесса обогащения железорудного концентрата, функционирующих технологических объектов, перечня измеряемых технологических параметров и границ их изменения, факторов, обуславливающих нестационарность процесса и опосредованно влияющих на качество железорудного концентрата.

2. Выполнен анализ возможности применения классических методов теории управления для идентификации технологических объектов на основе ретроспективных данных, выявлены особенности, препятствующие их применению.

3. Разработан алгоритм предобработки данных эксплуатации технологических объектов, который обеспечивает формирование датасетов, используемых при построении моделей объектов процесса обогащения железорудного концентрата с учетом выполнения требования репрезентативности.

4. Разработана методика создания моделей объектов технологического процесса обогащения железорудного концентрата посредством применения гибридной архитектуры глубоких ИНС, позволяющая получить устойчивое качество функционирования без эффекта автокорреляции.

5. Разработан алгоритм процедуры подбора вектора уставок для обеспечения функционирования агрегатов технологического процесса в рамках требований технологии при наступлении ситуации изменения свойств сырья и оборудования.

6. Разработан алгоритм функционирования прогнозирующего программного комплекса для интеграции в существующую систему управления с использованием SCADA-системы WinCC, обеспечивающий актуализацию моделей на поступающих данных.

7. Выполнена оценка эффективности применения прогнозирующей системы показывающая, что стабилизация качественного показателя содержания железа в концентрате в рамках технологии позволяет повысить средний уровень загрузки шаровых мельниц секции поступающим рудным материалом на 1,5-2% или 170 тыс. тонн в год.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Технологическая инструкция по производству железорудного концентрата. ТИ 00186826-10-51-2012.
2. Выписка из СТП 00186826-10-56-2007 «Производство железорудного концентрата. Карта технологического процесса»
3. Андреев С.Е. Дробление, измельчение и грохочение полезных ископаемых. – М.: «Недра», 1980. – 320 с.
4. Козин В.З., Тихонов О.Н. Опробование, контроль и автоматизация обогатительных процессов. М.: Недра, 1990г.
5. Козин В.З., Троп А.Е. Автоматизация процессов на обогатительных фабриках – М.: Недра, 1980.
6. Коржова Р.В. Сырьевая база и обогащение руд. Учеб. Пособие. Ч.1. Руды и минералы: - М.:МИСиС, 2001. – 194с.
7. Коржова Р.В. Сырьевая база и обогащение руд. Учеб. Пособие. Ч.2. Технология обогащения руд: - М.:МИСиС, 2002. – 149с.
8. Марюта А.Н. Автоматическая оптимизация процесса обогащения руд на магнитно-обогатительных фабриках. – М.: «Недра», 1975. – 328 с.
9. Олейников В.А., Тихонов О.Н. Автоматическое управление технологическими процессами в обогатительной промышленности. – М.: «Недра», 1966. – 245 с.
10. Виноградов В.С. Автоматизация технологических процессов на горно-рудных предприятиях. - М.:«Недра», 1984.-167с.
11. Электронный ресурс: <http://sgok.nlmk.com/ru/>
12. Тихонов О.Н. Решение задач по автоматизации процессов обогащения и металлургии. Л.: Недра, 1969. – 430с.
13. Утеуш З.В., Утеуш Э.В. Управление измельчительными агрегатами. М.: Машиностроение, 1973г.
14. Хан Г.А., Картушин В.П., Сорокер Л.В., Скрипчак Д.А. Автоматизация обогатительных фабрик. М.: "Недра", 1974г.

15. Дядик В.Ф. и др. Теория автоматического управления: учебное пособие/ В.Ф. Дядик, С.А. Байдали, Н.С. Криницын; Национальный исследовательский Томский политехнический университет. – Томск: Изд-во Томского политехнического университета, 2011. – 196 с.
16. Косников Ю.Н. Построение интерфейса человек-компьютер для системы автоматизированного управления сложными объектами // Известия высших учебных заведений. Поволжский регион. – 2014. - №4. – С. 82-92.
17. Ицкович Э.Л. Современные алгоритмы автоматического регулирования и их использование на предприятиях // Автоматизация в промышленности. – 2007. - №6. – с.39-44.
18. Дозорцев В.М., Ицкович Э.Л., Кнеллер Д.В. Усовершенствованное управление технологическими процессами (АРС): 10 лет в России // Автоматизация в промышленности. – 2013. - №1. – с.12-19.
19. Еременко Ю.И. Управление объектами горно-металлургического производства на основе использования искусственных нейронных сетей [Текст]: учебное пособие / Ю.И. Еременко. – Старый Оскол: ООО «ТНТ», 2004. – 180 с.
20. Еременко Ю.И. Повышение эффективности АСУ горно-металлургического производства на основе интеллектуализации управления. [Текст]: Монография / Ю.И. Еременко, Л.М. Боева, Л.А. Кузнецов, В.Б. Крахт. – Старый Оскол: ООО «ТНТ», 2005. – 408 с.
21. Еременко Ю.И. Исследование эффективности интеллектуального управления в металлургии. Диссертация на соискание ученой степени доктора технических наук: 05.13.06. – Липецк, 2005.
22. Туз А.А., Браун-Аквей В., Лемпого Ф., Кулаков К.А., Богатилов В.Н. Управление с прогнозирующими моделями // Труды Кольского научного центра РАН. № 3 (29). 2015 г. С. 151-161.
23. Comacho E.F., Bordons C. Model Predictive Control. SprinerVerlag, 1998.
24. Tatjevsky P. Advanced Control of Industrial Processes: Structures and Algorithms. L.: Springer. 2010.

25. Мазуров В. Автоматические регуляторы в системах управления и их настройка. Часть 1. Промышленные объекты управления // Компоненты и технологии. – 2003. - №4. – С. 154-157.
26. Мазуров В. Автоматические регуляторы в системах управления и их настройка. Часть 2. // Компоненты и технологии. – 2003. - №5. – С. 114-118.
27. Мазуров В. Автоматические регуляторы в системах управления и их настройка. Часть 3. // Компоненты и технологии. – 2003. - №6. – С. 146-151.
28. Методы классической и современной теории автоматического управления. В 5-и т. Т. 2. Статистическая динамика и идентификация систем автоматического управления / Под ред. К.А. Пупкова, Н.Д. Егупова. – 2-е изд., перераб. и доп. – М.: Изд-во МГТУ им. Н.Э. Баумана, 2004. - 640 с.: ил.; ISBN 5-7038-2190-8 (Т.2)
29. Назаров А.В. Нейросетевые алгоритмы прогнозирования и оптимизации систем / А.В. Назаров, А.И. Лоскутов; под редакцией М.В. Финкова. – СПб.: Наука и Техника, 2003. – 384 с.: ил.; ISBN 5-94387-076-8.
30. Гулай А.В., Зайцев В.М. Интеллектуальные технологии оперативного функционального контроля многопараметрических систем// Мехатроника, автоматизация, управления. – 2017. –Т.18. - №10. – с.670 - 678.
31. Ивахненко А.Г., Юрачковский Ю.П. Моделирование сложных систем по экспериментальным данным. М.: Радио и связь, 1987. – 120с.
32. Туз А.А. Управление технологическим процессом измельчения в шаровой мельнице в цикле подготовки питания флотации на основе нечетко-определенных импульсных моделей. Диссертация на соискание ученой степени кандидата технических наук: 05.13.06; 05.17.08. – Москва, 2017.
33. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В. Круглов, В.В. Борисов. -М.: Горячая линия-Телеком, 2002. — 382 с.
34. Галушкин А.И. Теория нейронных сетей. М.: ИПРЖР. Сер. «Нейрокомпьютеры и их применение». Кн. 1. 2000.

35. Галушкин А.И. Нейрокомпьютеры. М.: ИПРЖР. Сер. «Нейрокомпьютеры и их применение». Кн. 3. 2000.
36. Дорждамба Дамба-Очир. Система управления технологическим процессом измельчения сырья в субкритических режимах с применением интеллектуальных алгоритмов на базе нечеткой логики. Диссертация на соискание ученой степени кандидата технических наук: 05.13.06. – Москва, 2004.
37. Сигеру Омату. Нейроуправление и его приложения. Кн. 2. / Сигеру Омату, Марзуки Халид, Рубия Юсоф; пер. с англ. Н.В. Батина; под ред. А.И. Галушкина, В.А. Птичкина. – М.: ИПРЖР, 2000. – 272 с.: ил.; Перевод изд.: *Neurocontrol and its application / Sigeru Omatu, Marzuki Khalid, Rubiyan Yusof*.
38. Хайкин С. Нейронные сети / Саймон Хайкин – полный курс, 2-е изд., испр.; перевод с английского д.т.н. Н.Н. КуССуль, к.т.н. А.Ю. Шелестова. – М.: ООО «И.Д. Вильямс», 2006. – 1104 с.: ил.; *Neural networks / Simon Haykin*. Hamilton, Ontario, Canada.
39. Liu Xing, Due Truong Pham. *Neural Networks for Identification, Prediction and Control*. Springer-Verlag, 1995. – 242 p.
40. Льюнг Л. Идентификация систем: Теория для пользователя / Л. Льюнг; Пер. с англ. А. С. Манделя, А. В. Назина; Под ред. Я. З. Цыпкина. - М.: Наука, 1991. – 431 с.
41. Райбман Н.С., Чадеев В.М. Адаптивные модели в системах управления. – М.: Советское радио, 1966. – 160 с.
42. Цыпкин Я.З. Основы информационной теории идентификации. – М.: Наука, 1984. – 320 с.
43. Ljung L. *Pespectives on System Identification // IFAC Annual Reviews*. – 2010. – Spring Issue in Control. – Vol. 34(1). – P. 1–12.
44. Теория управления (дополнительные главы): Учебное пособие / Под ред. Д. А. Новикова. — М.: ЛЕНАНД, 2019. — 546 с.
45. Приступа М.Ю., Смагин В.И. Прогнозирующее управление дискретными системами с неизвестным входом и его применение к задаче

управления экономическим объектом // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. – 2012. – №1(18). – С. 5–15.

46. Дозорцев В.М., Крейдлин Е.Ю. Современные автоматизированные системы моделирования ТП // Автоматизация в промышленности. – 2009. - №6. – с.11-16.

47. Дозорцев В.М., Кнеллер Д.В. APC – усовершенствованное управление технологическими процессами // Датчики и системы. – 2005. - №10. – с. 56-62.

48. Кнеллер Д.В., Захаркин М.А. Применение методов и средств усовершенствованного управления технологическими процессами (APC) // Датчики и системы. – 2010. - №10. – с.57-71.

49. [Электронный ресурс]: <http://honeywell.com/>

50. [Электронный ресурс]: <https://www.schneider-electric.ru/>

51. Ковард Э. Объединение технологий динамического моделирования и усовершенствованного управления // Автоматизация в промышленности. – 2008. - №7. – с. 52-53.

52. Дозорцев В.М, Кнеллер Д.В., Лебединский А.А. Усовершенствованные АСУТП на основе PROFITCONTROLLER разработки корпорации Honeywell // Автоматизация в промышленности. – 2004. - №6. – с.39-41.

53. Аносов А.А., Бородин П.Е., Дозорцев В.М., Ефитов Г.Л., Кнеллер Д.В. Высокотехнологичные решения корпорации Honeywell на базе платформы ExperionPKS // Автоматизация в промышленности. – 2011. - №8. – с.29-37.

54. Кнеллер Д.В., Файрузов Д.Х., Бельков Ю.Н., Торгашов А.Ю. Система усовершенствованного управления установкой первичной переработки нефти: создание, внедрение, сопровождение // Автоматизация в промышленности. – 2013. - №8. – с.3-10.

55. Моррисон Д., Юренка Л., Кнеллер Д.В. Усовершенствованное управление технологическими процессами – ключ к повышению их эффективности // Автоматизация в промышленности. – 2009. - №9. – с.3-6.

56. Перельман И.И. Идентификация моделей для прогнозирования выходной реакции объекта // Труды IV симпозиума ИФАК по идентификации и оценке параметров систем. Тбилиси, 1975. - Т. 3. – С. 112–121.
57. Dozortsev V.M., Itskovich E. L., Nikiforov I.V., Perel'man I.I. Computer Control of a Cement Plant. // Proc.IFAC/IFIP Symposium Real-Time Digital Control Applications., At Guadalajara (Mexico), Volume: 1, pp.205-210, 1983.
58. Джонас Р.К., Кнеллер Д.В. Области применения и преимущества технологии усовершенствованного управления на глиноземном производстве // Автоматизация в промышленности. – 2009. - №8. – с.32-38.
59. Дозорцев В.М., Ицкович Э.Л., Кнеллер Д.В. Усовершенствованное управление технологическими процессами (APC): 10 лет в России // Автоматизация в промышленности. – 2013. - №1. – с.12-19.
60. Ротач В.Я. Теория автоматического управления: соответствуют ли ее основные положения действительности? // Промышленные АСУ и контроллеры. – 2007. - №3. – с. 1-5.
61. Ицкович Э.Л. Интеллектуальность средств и систем автоматизации // Автоматизация в промышленности. – 2006. - №6. – с.3-8.
62. Дозорцев В.М. О термине «интеллектуализация» в применении к средствам и системам управления ТП // Автоматизация в промышленности. – 2006. - №6. – с.8-9.
63. Зозуля Ю.И., Слетнёв М.С. Разработка программного комплекса нейросетевой системы поддержки принятия решений по безопасному оперативному управлению нефтехимическим производством // Автоматизация, телемеханизация и связь в нефтяной промышленности. – 2013. - №1. – с.7-14.
64. Ицкович Э.Л., Гребенюк Е.А. Методы оперативного определения не измеряемых поточными приборами качественных показателей химико-технологических процессов // Автоматизация в промышленности. – 2011. - №6. – с.5-13.

65. Беспалов А.В., Харитонов Н.И. Системы управления химико-технологическими процессами. М.: ИКЦ «Академкнига», 2007. 690 с.
66. Асташкин В.В., Кафаров В.В., Мешалкин В.П., Перов В.Л. Сравнительная оценка некоторых алгоритмов автоматизированного составления математических моделей гидравлических цепей химико-технологических систем // Автоматика и телемеханика. - 1976. - №4. – с. 166–174.
67. Стремнев А.Ю. Разработка математических моделей для автоматизированного проектирования шаровых барабанных мельниц. Диссертация на соискание ученой степени кандидата технических наук: 05.02.13. – Белгород, 2004.
68. Осипова Н.В. Модель стабилизации качества железорудного концентрата в процессе магнитной сепарации с использованием экстремального регулирования // Metallurg. – 2018. - №4. – С. 11 – 16.
69. Осипова Н.В., Самойлова В.Т. Модель системы регулирования содержания железа в концентрате процесса магнитной сепарации руды // Горный информационно-аналитический бюллетень. - 2017. - № 9. - С. 139–143.
70. Ананьев П.П., Осипова Н.В. Исследование модели функционирования измельчительного комплекса с применением импульсной электромагнитной обработки руды // Горный информационно-аналитический бюллетень. - 2012. - № 1. - С. 236-239.
71. Тараненко М.Е. Автоматизированная система управления технологическим процессом измельчения руды в мельницах мокрого самоизмельчения. Диссертация на соискание ученой степени кандидата технических наук: 05.13.06. – Москва, 2010.
72. Троп А.Е. Автоматическое управление технологическими процессами обогащательных фабрик: учебник для вузов // А.Е. Троп, В.З. Козин, Е.В. Прокофьев, - 2-е изд., доп. - М.: Недра, 1986. - 303 с.

73. Белоглазов И.Н., Тихонов О.Н., Хайдов В.В. Методы расчёта обогатительно-гидрометаллургических аппаратов и комбинированных схем. – М.: Металлургия, 1995. - 297 с.
74. Райбман Н.С., Чадеев В.М. Построение моделей процессов производства. М.: Энергия, 1975. 376 с.
75. Львова Е.И. Особенности идентификации объектов сложной структуры с распределенными управляющими воздействиями. // В сборнике: XII всероссийское совещание по проблемам управления ВСПУ-2014. Институт проблем управления им. В.А. Трапезникова РАН. 2014. С. 3202-3213.
76. Ротач В.Я. Расчет динамики промышленных автоматических систем регулирования. - М.: Энергия, 1973. 440 с.
77. Мышляев Л.П., Львова Е.И., Ивушкин А.А. Состояние и перспективы идентификации объектов в процессе создания и эксплуатации систем автоматизации управления // Фундаментальные исследования. - 2014. - № 12-3. - С. 495-499.
78. Львова Е.И. Методы и алгоритмы идентификации в системах управления промышленными объектами. Диссертация на соискание ученой степени доктора технических наук: 05.13.06. - Новокузнецк, 2006.
79. Мышляев Л.П., Евтушенко В.Ф., Кулаков С.М. Теория и практика прогнозирования в системах управления. - Кемерово: Кузбассвуиздат-АСТШ ; Москва : Российские университеты, 2008. – 486 с.
80. Дрейпер Н., Смит Г. Прикладной регрессионный анализ. Множественная регрессия / Applied Regression Analysis. – 3-е изд. – Москва: Диалектика, 2007. 912 с.
81. Шашков В.Б. Прикладной регрессионный анализ. Многофакторная регрессия: Учебное пособие. - Оренбург: ГОУ ВПО ОГУ, 2003. 363 с.
82. Дилигенская А.Н. Идентификация объектов управления. – Самара, изд-во СГТУ, 2009. – 136 с.

83. Васильев В.И., Ильясов Б.Г. Интеллектуальные системы управления. Теория и практика. – М.: Машиностроение, 2009. – 392 с.
84. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных суперпозициями непрерывных функций меньшего числа переменных // Докл. АН СССР. —1956. — Т. 108, № 2. — С. 179-182.
85. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного // Докл. АН СССР. — 1957. — Т. 114, № 5. — С. 953-956.
86. Cybenko G. Approximation by superposition of a sigmoidal function//Mathematics of Control, Signals, and Systems. — 1989. — Vol. 2. — P. 303-314.
87. Funahashi K. On the approximate realizations of continuous mappings by neural networks // Neural Networks. – 1989. – Vol. 2. – P. 183-192.
88. Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators // Neural Networks. — 1989. — Vol. 2. — P. 359-366.
89. Hecht-Nielsen, Robert. Theory of the backpropagation neural network // Proc. of the Int. Joint Conf. on Neural Networks, I, 593-611, IEEE Press, New York, June 1989.
90. Hecht-Nielsen, Robert. Kolmogorov's Mapping Neural Network Existence Theorem // Proc. International Conference on Neural Networks, IEEE Press, New York, 111(11-13), 1987.
91. Горбань А.Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей // Сиб. журн. вычисл. математики / РАН. Сиб. отделение. - Новосибирск, 1998. — Т. 1, № 1. — С. 11-24.
92. A. N. Gorban and D. Wunsch, “The general approximations theorem”, Proc. IEEE IJCNN, pp. 1271–1274, 1998.
93. Полещенко Д.А. Повышение эффективности управления чашевым окомкователем путем совершенствования алгоритмов экстремального

регулирования. Диссертация на соискание ученой степени кандидата технических наук: 05.13.06. – Липецк, 2007.

94. Сараев П.В. Суперпозиционное линейно-нелинейное нейроструктурное моделирование. Диссертация на соискание ученой степени доктора технических наук: 05.13.18. – Липецк, 2013.

95. Eremenko Y., Poleshchenko D., Glushchenko A. About Heating Plants Control System Developing on Basis of Neural Network Usage for PID-Regulator Parameters Optimization, Applied Mechanics and Materials, Vol. 682, pp. 80-86, 2014.

96. Электронный ресурс: <https://yandexdatafactory.com>

97. Зарубин М.Ю. Разработка самообучающейся САУ на ИНС для оптимизации процессов в условиях неустойчивости входных параметров // ScienceTime. №1. 2015 г. с. 146 – 151.

98. Сараев П.В., Блюмин С.Л., Галкин А.В. Некоторые современные подходы к моделированию и автоматизации сложных систем // Вести высших учебных заведений Черноземья. – 2017. - №1. – С. 53-66.

99. Дагман А.И., Блюмин С.Л., Сараев П.В., Галкин А.В., Титов В.Н., Анциферов м. Построение и анализ моделей влияния изменений производственных факторов на изменения удельного расхода кокса и производительности доменных печей // Вести высших учебных заведений Черноземья. – 2017. – № 3(49). – С. 73-82.

100. Ljung L. Perspectives on System Identification // IFAC Annual Reviews. – 2010. – Spring Issue in Control. – Vol. 34(1). – P. 1–12 /

101. Golyandina N., Nekrutkin V., Zhigljavsky A.A. Analysis of Time Series Structure: SSA and Related Techniques. Chapman and Hall/CRC, 2001. P. 320.

102. Голяндина Н.Э. Метод «Гусеница»-SSA: анализ временных рядов: Учеб. пособие. СПб.: ВВМ, 2003. 85 с.

103. Колмогоров А. Н. Интерполирование и экстраполирование стационарных случайных последовательностей // Изв. АН СССР. Сер. матем., т. 5:1, 1941. — С. 3-14.

104. Ивахненко А.Г. Индуктивный метод самоорганизации моделей сложных систем. Киев: Наукова думка. 1981.
105. Ивахненко А.Г., Степашко В.С. Помехоустойчивость моделирования. Киев: Наукова думка. 1985.
106. Malada, H.R., Ivakhnenko, A.G. Inductive Learning Algorithms for Complex Systems Modeling. CRC Press. 1994.
107. Schmidhuber J. Deep learning in neural networks: An overview // Neural Networks. — 2015. — Vol. 61. — P. 85—117.
108. Стукач О.В., Программный комплекс Statistica в решении задач управления качеством: учебное пособие / Томский политехнический университет. — Томск: Изд-во Томского политехнического университета, 2011. — 163 с.
109. Лубенцов В.Ф. Исследование САУ процессом ферментации с применением технологии нейронных сетей // Приборы и системы. Управление, контроль, диагностика. — 2005. - №9. — С. 1-4.
110. Funahashi K., Nakamura Y. Approximation of Dynamical Systems by Continuous Time Recurrent Neural Networks // Neural Networks. — 1993. — Vol. 6, No. 6. — P. 801–806.
111. Cover T. Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition // IEEE Transactions on Electronic Computers. — 1965. — EC-14. — P. 326–334.
112. Hinton G., Salakhutdinov R. Reducing the Dimensionality of Data with Neural Networks // Science. — 2006. — Vol. 313, No. 5786. — P. 504–507.
113. Nair V., Hinton G. Rectified Linear Units Improve Restricted Boltzmann Machines // Proc. of the Int. Conference on Machine Learning. — 2010. — P. 807–814.
114. Glorot X., Bengio Y. Understanding the Difficulty of Training Deep Feedforward Neural Networks // Proc. of the 13th Int. Conference on Artificial Intelligence and Statistics. — 2010. — Vol. 9. — P. 249–256.

115. Бенджио И., Гудфеллоу Я., Курвилль А. Глубокое обучение. ДМК-Пресс, 2018. – 652 с.
116. Николенко С.И., Кадурин А.А., Архангельская Е.О. Глубокое обучение. — СПб.: Питер, 2018. — 480 с.
117. Шолле Ф. Глубокое обучение на Python. — СПб.: Питер, 2018. — 400 с.
118. LeCun Y., Boser B., Denker J., Henderson D., Howard R., Hubbard W., Jackel L. Backpropagation Applied to Handwritten Zip Code Recognition // Neural Computation. – 1989. – Vol. 1, No. 4. – P. 541–551.
119. LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient-Based Learning Applied to Document Recognition // IEEE Intelligent Signal Processing. – 1998. – P. 306–351.
120. Ciresan D., Meier U., Gambardella L., Schmidhuber J. Deep Big Simple Neural Nets Excel on Handwritten Digit Recognition // ArXiv: 1003.0358.
121. Krizhevsky A., Sutskever I., Hinton G. ImageNet Classification with Deep Convolutional Neural Networks // Proc. of the 25th Int. Conference NIPS. – 2012. – Vol. 1. – P. 1097–1105.
122. Hochreiter S., Schmidhuber J. Long-Short Term Memory // Neural Computation. – 1997. – Vol. 9, No. 8. – P. 1735–1780.

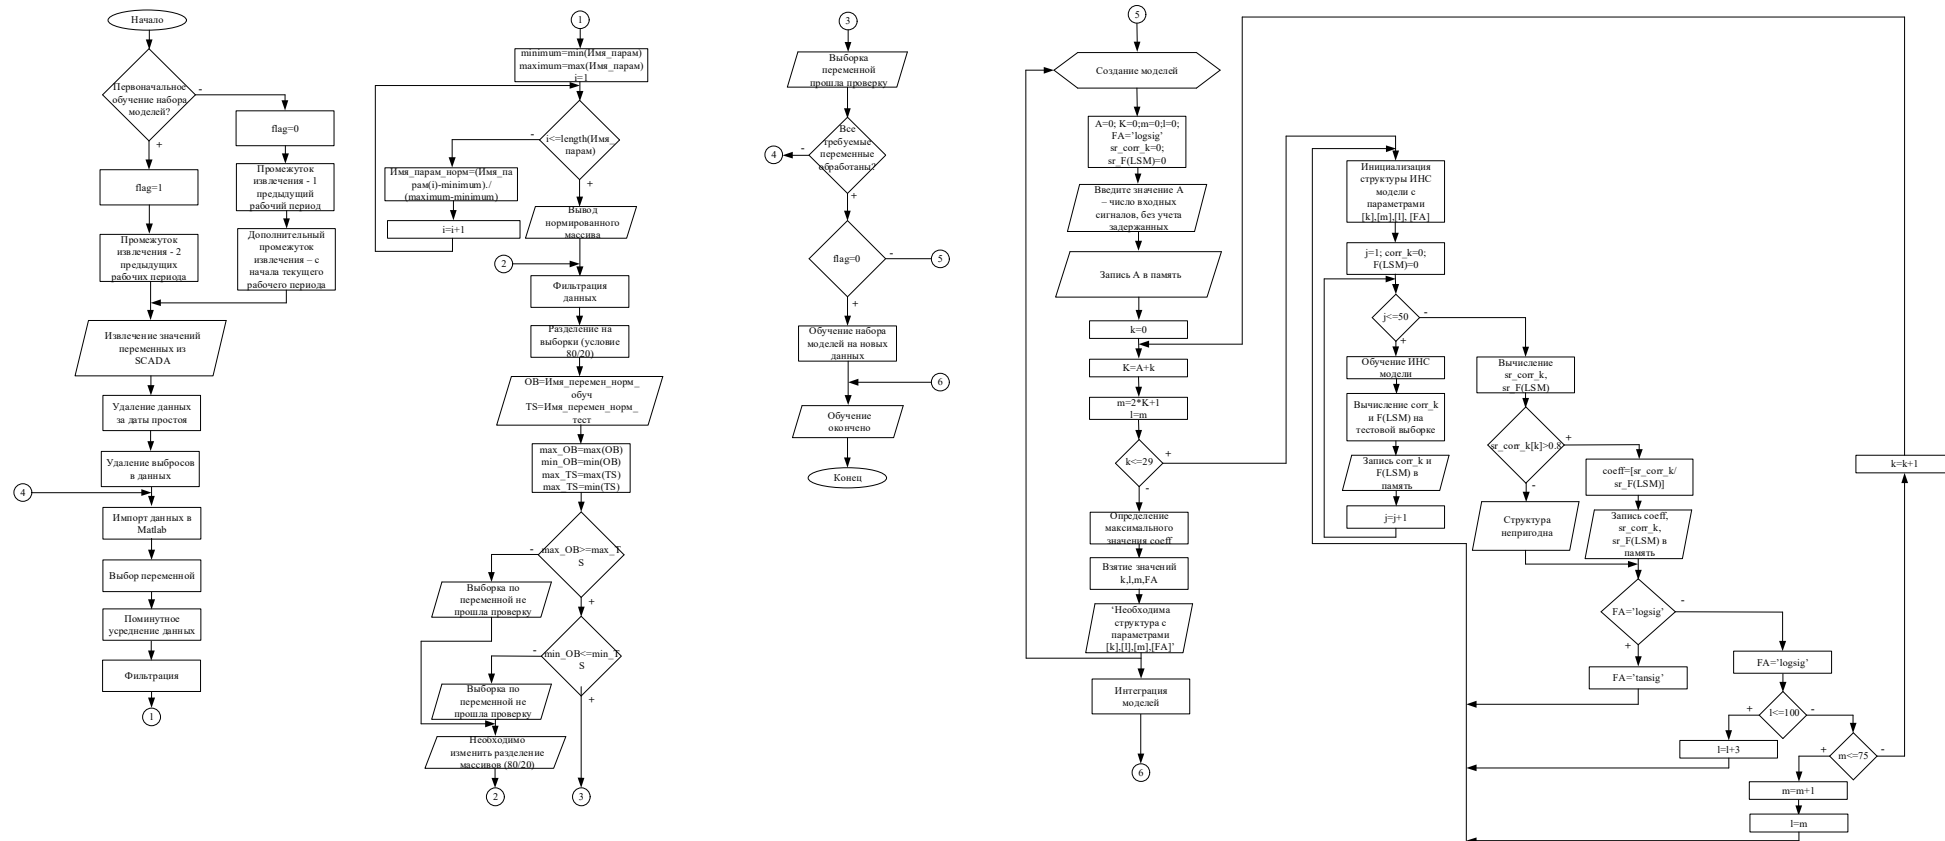
ПРИЛОЖЕНИЯ

Приложение А

Листинг программы первичной предобработки данных для одной из переменных процесса

```
s=0;
ii=0;
data_4U03=[];
minute=50;
for i=1:1:(length(Trend1Time)-1)
    if isnat(Trend1Time(i))==0
        a=datevec(Trend1Time(i));
        if a(5)==minute
            s=s+Trend1ValueY(i);
            ii=ii+1;
        else
            data_4U03=[data_4U03;s/ii];
            s=0;
            s=s+Trend1ValueY(i);
            minute=a(5);
            ii=1;
        end
    else
        b=datevec(Trend1ValueY(i+1));
        if (a(5)==59)
            if minute==b(5)
                s=s+Trend1ValueY(i);
                ii=ii+1;
            else
                data_4U03=[data_4U03;s/ii];
                s=0;
                s=s+Trend1ValueY(i);
                ii=1;
                minute=0;
            end
        else
            if minute==b(5)
                s=s+Trend1ValueY(i);
                ii=ii+1;
            else
                s=s+Trend1ValueY(i);
                ii=ii+1;
                data_4U03=[data_4U03;s/ii];
                s=0;
                ii=0;
                minute=a(5)+1;
            end
        end
    end
end
end
end
```

Алгоритм создания ИНС моделей агрегатов



Справка о возможности использования на АО «СГОК»

Утверждаю
Директор Дирекции по производству
АО «Стойленский ГОК»
А.В. Крючков
«17» *сентября* 2020г.

СПРАВКА

о возможности использования результатов исследований Цыганкова Ю.А., направленных на решение актуальной научно-технической задачи повышения эффективности управления технологическим процессом обогащения концентрата путем прогнозирования производственных показателей, выносимых на защиту кандидатской диссертации

Настоящий акт подтверждает, что следующие результаты, полученные лично Цыганковым Ю.А. в рамках выполнения исследований, являются актуальными для предприятия и представляют практический интерес:

- система прогнозирования содержания железа в концентрате, основанная на поагрегатной нейросетевой модели процесса обогащения;
- разработанный алгоритм функционирования системы, предполагающий обеспечение качества прогнозирования при изменении свойств сырья и параметров оборудования;
- разработанный алгоритм выдачи рекомендаций по изменению управляющих переменных, предотвращающий развитие ситуации выхода за технологические рамки в случае получения негативного прогноза по содержанию железа.

Перечисленные результаты, на наш взгляд, являются весомым вкладом в развитие систем управления обогатительного передела, что может позволить за счет улучшения качества управления стабилизировать выход годного продукта, и увеличить объем перерабатываемого секцией рудного материала на 1,5 – 2%, что составляет порядка 170 000 тонн в годовом выражении.

АО «Стойленский ГОК» планирует использование представленных к защите результатов исследования Цыганкова Ю.А. при модернизации существующей системы управления.

Начальник Управления автоматизации и метрологии

А.И. Татьяна
А.И. Татьяна

Справка о возможности использования на АО «ЛГОК»

СПРАВКА

о возможности использования результатов диссертационного исследования Цыганкова Ю.А., направленных на решение актуальной научно-технической задачи повышения эффективности управления технологическим процессом обогащения концентрата путем прогнозирования производственных показателей, выносимых на защиту кандидатской диссертации

Настоящий акт подтверждает, что разработанная в рамках диссертационной работы Цыганковым Ю.А. система прогнозирования технологических показателей процесса обогащения железорудного концентрата является эффективным способом для коррекции уставок для локальных контуров системы управления содержанием железа в выходном продукте. В результате успешного внедрения в производство, в условиях вариативности свойств сырья, данное решение позволит стабилизировать качество выходного продукта по содержанию железа, что может обеспечить повышение производительности передела обогащения по перерабатываемой руде ориентировочно на 1,5-2% в годовом исчислении.

Результаты исследований Цыганкова Ю.А. (модернизация существующей системы управления технологическим переделом) рекомендуются к внедрению на обогатительной фабрике АО «Лебединский ГОК».

Начальник обогатительной фабрики
АО «Лебединский ГОК»



С.Н. Копанев

Начальник управления эксплуатации
Регионального ИТ-Центра г.Губкин
ООО «Металло-Тех»

В.В. Куляба

Приложение Д

Справка о применении результатов диссертационного исследования в учебном процессе Старооскольского технологического института им. А.А. Угарова (филиала) ФГАОУ ВО «Национальный исследовательский технологический университет «МИСиС»

Утверждаю:
Заместитель директора СТИ НИТУ «МИСиС»
по науке и инновациям, д.т.н.
 Кожухов А.А.
« 1 » 02 2021 г.

Акт

о внедрении в образовательный процесс результатов кандидатской диссертационной работы Цыганкова Юрия Александровича

Настоящий акт подтверждает, что методические разработки, выполненные на основании исследований, проведенных в диссертационной работе Цыганкова Юрия Александровича, где описывается разработка метода построения прогнозирующей системы на базе глубоких гибридных нейронных сетей для осуществления прогноза изменения технологических показателей качества при производстве железорудного концентрата и осуществления упреждающего управления, используются в учебном процессе в СТИ НИТУ «МИСиС» на кафедре «Автоматизированных и информационных систем управления» в курсе предметов «Технические средства автоматизации» и «Проектирование систем верхнего уровня». По каждому из указанных курсов выпущены курсы лекций, методические указания к выполнению домашних заданий и лабораторных работ. Использование результатов диссертационной работы позволяет углубить знания студентов в сфере применения методов машинного обучения в управлении сложными многопараметрическими технологическими процессами.

Начальник методического отдела
СТИ НИТУ «МИСиС»



Косарева И.Н.

Заведующий кафедрой АИСУ
СТИ НИТУ «МИСиС»



к.т.н., доцент Глушенко А.И.