

СТАРООСКОЛЬСКИЙ ТЕХНОЛОГИЧЕСКИХ ИНСТИТУТ ИМ. А. А. УГАРОВА
(филиал) федерального государственного автономного образовательного учреждения высшего
образования «Национальный исследовательский технологический университет «МИСиС»
(СТИ НИТУ «МИСиС»))

ЦЫГАНКОВ ЮРИЙ АЛЕКСАНДРОВИЧ

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

Специальность 05.13.06 – «Автоматизация и управление технологиче-
скими процессами и производствами» (промышленность)

АВТОРЕФЕРАТ

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

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

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 разра-

ботку 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 $|Fe| = 0.5\%$, 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 $|Fe| = 0.5\%$;

- 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 $|Fe| = 0.5\%$.

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 $|Fe| = 0.5\%$.

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 пояснительной записке.

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.

Структура и объемы работы. Диссертационная работа состоит из введения, четырех глав, заключения, списка литературы из 122 наименований, 5 приложений, содержит 62 рисунка и 18 таблиц.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Во введении представлена актуальность темы исследования, поставлены цель и задачи исследования, приведено краткое содержание диссертационной работы по главам, показаны основные результаты работы, определена их научная новизна, теоретическая и практическая значимость.

В первой главе проведен анализ технологического процесса обогащения железорудного концентрата на горно-обогатительном комбинате. В ходе переработки происходит доизмельчение рудного материала, поступающего из корпуса дробления, осуществляется несколько стадий классификации, магнитной сепарации, обесшламливания и др. Перерабатываемый материал представляет собой смесь измельченных частиц руды различной крупности и воды – пульпу. Плотность пульпы, в зависимости от этапа переработки, может изменяться, что обусловлено особенностями работы агрегатов и необходимостью транспортировки сырья по коммуникациям передела. Итоговой задачей работы передела является получение продукта с процентным содержанием железа на уровне 66,5-67,5%.

В результате было выявлено, что управление в автоматизированном режиме данным дискретно-непрерывным процессом затруднено по целому ряду причин. Большинство агрегатов, выполняющих производственную задачу, представляют собой сложные многопараметрические технологические объекты, отличающиеся нестабильностью параметров. Также великого число переменных, измеряемых на объектах передела, которые подвержены взаимному влиянию, достаточно тяжело поддающемуся оценке. Однако основной особенностью процесса представляется существенная нестационарность химико-физических свойств самого сырья – рудного материала, что является источников неизмеряемых возмущений. Разброс свойств поступающей руды в некоторой степени нивелируется проведением процедуры усреднения материала, однако не обеспечивает стабильность на желаемом уровне. Управление процессом необходимо производить с учетом перечисленных негативных аспектов для достижения требуемого значения качественного показателя выходного продукта – процентного содержания железа, вариация значений которого допускается лишь в пределах $|Fe| = 0.5\%$, согласно требованиям технологической инструкции.

В условиях существующей системы, базирующейся на регулировании посредством локальных контуров, решение задачи управления осуществляется путем создания на многих агрегатах так называемых «зон запаса» - формирования управляющего воздействия, превышающего достаточное в данных условиях, что приводит к снижению общей эффективности процесса в угоду выполнения требований технологии. Значительным недостатком, усложняющим задачу, является отсутствие у оператора актуальных данных по значению выходного показателя. На текущий момент его измерение осуществляется посредством лабораторного анализа, с дискретностью, значительно превышающей время прохождения перерабатываемого материала через технологический передел. По этой причине оператор не имеет возможности в режиме реального времени оценить изменение параметров процесса в ответ на изменение управляющего воздействия, а тем более заблаговременно увидеть момент воздействия внешних возмущений на ход

переработки.

В данных условиях актуальным становится использование предиктивного управления, для осуществления которого необходимо произвести разработку математических моделей агрегатов процесса, что довольно затруднительно по причине указанных нестационарностей и сложного характера функциональных зависимостей, описывающих изменение технологических переменных. Аппарат классической теории автоматического управления в подобных условиях не позволяет разработать точные модели объектов, устойчивые к смене параметров и возмущений, для повышения эффективности процесса прогнозирования. Поэтому в качестве методики построения системы был выбран поагрегатный принцип моделирования, представленный в работах П.В. Сараева как нейроструктурное моделирование, используемое применительно к объектам металлургических производственных процессов. Создание поагрегатных моделей технологических объектов процесса обогащения и их интеграция в единую систему для выполнения процедуры прогнозирования, позволит оператору своевременно получать актуальную информацию по изменению выходного показателя в зависимости от изменения управляющих параметров и внешних возмущений.

Подобный подход применяется и при разработке АРС-систем, активно внедряемых для решения задачи эффективного управления в смежных отраслях промышленности. Повышение показателей эффективности процесса достигается за счет наличия прогноза изменения выходного показателя, имея который, оператор получает возможность осуществлять смену уставок до наступления негативной ситуации. Это позволяет сузить рабочий диапазон промежуточных показателей, что обеспечивает стабилизацию значения содержания железа в выходном концентрате. Однако, недостатком данных систем также является аппарат моделирования, используемый при идентификации, который не позволяет в полной мере учитывать сложный характер функциональных зависимостей измеряемых показателей.

Поэтому был сделан выбор в пользу интеллектуальных методов, и, в частности, одного из методов машинного обучения – искусственных нейронных сетей (ИНС), аппроксимирующие и экстраполирующие возможности подхода доказаны еще в работах А.Н. Колмогорова, а в исследованиях таких авторов, как С. Омату, С. Хайкина, Р. Хехт-Нильсена, К. Хорника, К. Фунахаши, Г. Цыбенко, А.Н. Горбаня, Я. Лекуна, Дж. Хинтона и других доведены до нынешнего представления. Возможность применения данного аппарата для решения актуальных проблем горно-металлургического сегмента представлено в работах Ю.И. Еременко, П.В. Сараева, М.Ю. Зарубина, Д.А. Полещенко.

В результате проведенного в первой главе анализа технологического процесса обогащения железорудного концентрата, были выявлены особенности и сложности, затрудняющие управление переделом с наилучшей эффективностью. Первоначально было выполнено исследование методов решения представленных проблем с использованием аппарата классической теории управления, выявлены недостатки методов, не позволяющие решить задачу в представленных

условиях. В качестве актуальной идеи было выбрано использование аппарата искусственных нейронных сетей для разработки моделей технологических агрегатов и построения прогнозирующего функционала на их основе.

Во второй главе был произведен подробный анализ измеряемых показателей процесса и функционирующих технологических агрегатов с целью разработки схемы моделей и обеспечения возможности их последующей интеграции.

Технологические объекты были поэтапно объединены в единую схему, с учетом измеряемых сигналов. В результате была получена модель процесса обогащения концентрата, представленная на рис. 1, которая состоит из 10 отдельных моделей агрегатов передела. Технологическим параметром, обеспечивающим объединение моделей, стал сигнал плотности пульпы, измеряемый в выходящем из агрегатов потоке пульпы, поскольку для осуществления процесса обогащения важным является соблюдение плотностного режима.

Следующим этапом исследований стала разработка алгоритмов предобработки ретроспективных данных и построения с их использованием моделей агрегатов для обеспечения возможности предоставления прогноза по качественному показателю продукта в условиях нестационарности условий. При выполнении экспериментов по разработке алгоритма создания моделей технологических объектов передела, в качестве примера рассматривался комплекс «шаровая мельница – спиральный классификатор», как один из определяющих агрегатов технологического цикла.

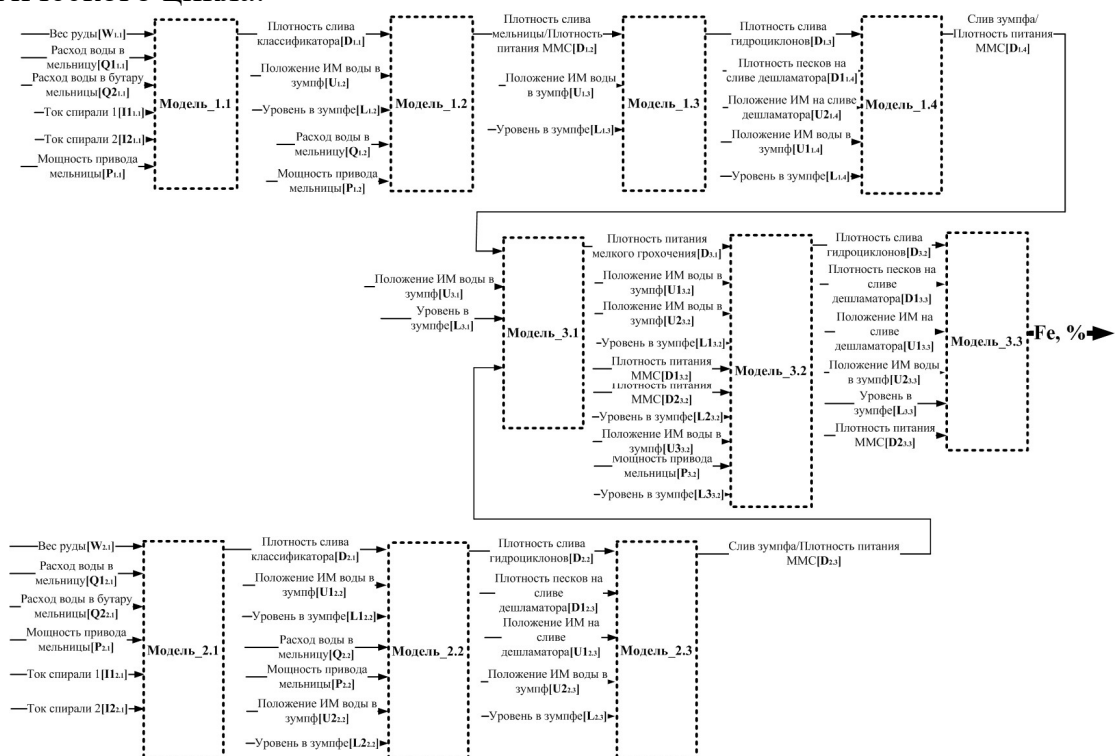


Рисунок 1. Схема нейросетевых моделей агрегатов процесса обогащения

Первоначально в работе были реализованы и тестировались модели данного агрегата с применением аппарата регрессионного анализа. Для проведения сравнительного анализа использовались такие аппроксимирующие функции, как линейная, дробная, экспоненциальная, степенные полиномы различного порядка.

Наилучший результат был достигнут при использовании функциональной зависимости, известной как полином Колмогорова-Габора (1), используемый для аппроксимации нелинейных многопараметрических зависимостей.

$$D_{l,l}(x_1...x_n) = b_0 + \sum_{i=1}^n b_i x_i + \sum_{i=1}^n \sum_{j=i}^n b_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=i}^n \sum_{k=j}^n b_{ijk} x_i x_j x_k + \dots + \sum_{i=1}^n \sum_{j=i}^n \dots \sum_{l=1}^n b_{ij\dots l} x_i x_j \dots x_l, \quad (1)$$

где $x[1..n]$ – значимые входные параметры модели, $D_{l,l}$ – моделируемый выходной сигнал плотности слива классификатора, b – коэффициенты регрессии.

Для осуществления экспериментов были проанализированы данные работы передела за период, равный 5 месяцам.

В исходных промышленных данных присутствуют такие типичные недостатки реальных измерений, как участки отсутствия сигнала, выбросы, шумовые составляющие. Для наилучшей информативности выборки, из нее были удалены участки, соответствующие временным промежуткам простоя агрегатов, периодам отсутствия значений некоторых из измеряемых параметров или приближения к минимальным значениям. Данные явления достаточно тяжело диагностировать в автоматическом режиме, поскольку не всегда это является ошибкой измерения, а может представлять ситуацию отработки оператором предаварийных условий, когда прекращается подача исходного сырья для разгрузки одного из агрегатов, отчего проседают технологические показатели цепочки в целом. Для уменьшения влияния амплитудных выбросов на статистические показатели временного ряда применялась процедура квантильного преобразования.

В рамках создания алгоритма предобработки данных были выполнены эксперименты по выбору алгоритма фильтрации, позволяющего удалить шумовые составляющие из данных. В качестве численных показателей точности функционирования моделей на данных различной фильтрации были использованы коэффициент корреляции ($corr\ k$) выходных векторов модели и реальных значений сигнала и значение СКО (MSE).

В экспериментах исследовались два метода фильтрации – это фильтр скользящего среднего (2) с различными параметрами, как наиболее простой и часто используемый в промышленности:

$$y_n = \frac{1}{N} \sum_{k=0}^{N-1} x_{n-k}, \quad (2)$$

где N – число точек данных, обрабатываемых фильтром, n – порядковый номер значения в векторе измерений параметра.

В качестве второго алгоритма фильтрации исследовался метод сингулярно-спектрального анализа (SSA), как один из современных и наиболее эффективных. Варьировались значения параметров ширины окна, в пределах от 55% до 70%, и числа компонент разложения в восстановленном сигнале от 20 до 8000. Наилучшие результаты фильтрации были получены в результате применения метода SSA с шириной окна 55% и числом компонент 2000.

В ходе проведения сравнительных экспериментов, заключавшихся в том, что одинаковый набор сигналов функционирования объекта «шаровая мельница – спиральный классификатор» был представлен в трех видах: без проведения

процедуры фильтрации (в оригинальном виде), с применением алгоритма усреднения «скользящее среднее» по 11 точкам и с проведением сингулярно-спектрального анализа. Результаты качества обучения и работы модели на тестовых данных с применением различных наборов выборок представлены в таблице 1. Из представленных данных видно, что наиболее качественный результат был получен при использовании сингулярно-спектрального анализа для фильтрации представленных данных. Причем, данный метод позволяет производить именно фильтрацию сигнала, а не его усреднение, то есть выделять главные характеристики сигнала и отделять шумы, а не производить «сглаживание».

Таблица 1. Численные показатели качества моделирования

	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

Данные результаты послужили причиной использования SSA-метода для фильтрации сигналов при идентификации агрегатов обогатительного передела для реализации прогнозирующей системы.

После выполнения процедур предобработки, располагаемый набор данных был разделен на обучающую и тестовую выборки для осуществления проверки получаемых моделей. Для этого был разработан алгоритм, при выполнении которого, в целях обеспечения непрерывности и репрезентативности выборок, их формирование происходит из целостных участков данных с учетом проверки условия вхождения граничных амплитудных значений тестовой выборки в границы амплитудных значений обучающей выборки по каждому из измеряемых параметров.

В результате был сформирован итоговый алгоритм предобработки данных, применявшийся при разработке моделей агрегатов. Подробный его вид представлен в виде блок-схемы в Приложении Б в тексте пояснительной записки диссертационного исследования.

С использованием представленного алгоритма предобработки исходных данных были разработаны модели агрегатов обогатительного передела с применением аппарата регрессионного анализа. Численные показатели качества функционирования набора моделей технологических агрегатов, согласно схемы на рис. 1, представлены в таблице 3 в столбце «Регрессионный анализ».

Во второй главе диссертации был произведен анализ перечня технологических агрегатов и измеряемых в ходе их функционирования сигналов. С учетом результатов, была разработана схема моделей технологических агрегатов, позволяющая осуществить их интеграцию в единую систему для реализации прогнозирующей системы. После чего была выполнена разработка алгоритма предобработки данных для осуществления экспериментов по идентификации технологических объектов передела обогащения. В ходе выполнения экспериментов

были изучены процедуры статистической предобработки данных, согласования временных и амплитудных параметров выборок для разделения на обучающую и тестовую, использования данных различной степени и способа фильтрации, что позволило реализовать набор моделей агрегатов секции с применением аппарата регрессионного анализа.

В третьей главе была осуществлена разработка моделей технологических объектов с использованием классических и глубоких искусственных нейронных сетей, и произведена их интеграция в единую систему.

Следующим этапом работы стала оценка возможности применения для моделирования работы технологических агрегатов передела обогащения классических многослойных ИНС. В выражении (3) представлена функциональная зависимость, описывающая работу классической многослойной нейросетевой модели с одним скрытым слоем агрегата «шаровая мельница – спиральный классификатор»:

$$D_{1.1}(t) = f_{1.1_2}(b_{1.1_m}^2 + \sum_{n=1}^N w_{1.1mn}^2 f_{1.1_1}(\sum_{i=1}^j w_{1.1_ni}^1 A_{1.1} + b_{1.1_n}^1)), \quad (3)$$

где $A_{1.1} = [W_{1.1}(t); Q1_{1.1}(t); Q2_{1.1}(t); P_{1.1}(t); I1_{1.1}(t); I2_{1.1}(t); D_{1.1}\{(t-1) \dots (t-z)\}]$ – кортеж сигналов входных параметров модели 1.1 (см. рис.1), $[D_{1.1}(t)]$ – моделируемый выходной сигнал плотности слива классификатора, $f_{1.1_1}^1(*)$, $f_{1.1_2}^2(*)$ – функции активации, $w_{1.1ni}^1$, $w_{1.1mn}^2$ – значения весовых коэффициентов в слоях соответственно, $b_{1.1n}^1$, $b_{1.1m}^2$ – значения смещения в слоях соответственно.

При разработке моделей были осуществлены эксперименты по подбору параметров архитектуры каждой искусственной нейронной сети. Для учета динамики агрегатов, во входной слой ИНС-модели добавлялись дополнительные нейроны, обрабатывающие вектор выходного сигнала, задержанный на 1 и более тактов, что является общепринятым способом. В ходе исследований были изучены вопросы выбора способа подачи задержанных сигналов и необходимого и достаточного числа задержек сигнала выхода для получения наиболее высоких численных показателей моделирования. Экспериментально было получено подтверждение, что подача кортежа задержанных сигналов последовательным методом $[(t-1), (t-2), (t-3) \dots (t-z)]$ позволяет достичь более высокого качества работы сети, нежели при дискретном методе $[(t-1), (t-z)]$ организации задержек.

Для стабильного достижения качественного результата моделирования был разработан алгоритм определения архитектуры и параметров классической нейросетевой модели. В ходе его выполнения осуществляется инициализация модели со структурой входного слоя, обрабатывающей кортеж переменных входных параметров и значений выхода, задержанного на 1 такт. Структура скрытого слоя рассчитана исходя из требования минимальности, приведенного и обоснованного в серии работ Р. Хехт-Нильсена. Далее данная сеть обучалась и тестировалась с фиксацией показателей качества. По завершении данной процедуры, изменялись значения параметров числа эпох обучения, нейронов в скрытом слое, количество задержек выходного сигнала на входе, осуществляется ва-

рыирование функций активации нейронов скрытого слоя. Все эти изменения вносятся в архитектуру последовательно, после чего запускалась процедура обучения новой сети для получения численных значений показателей качества и анализа результатов внесения изменений. В итоге, архитектура, позволяющая получить наилучший результат, запоминается в качестве основной для моделирования работы данного участка обогатительного передела.

Разработанный алгоритм предобработки данных, формирования выборок и построения классических ИНС моделей был применен и для разработки прочих агрегатов технологической секции, результаты функционирования которых приведены в таблице 3 в столбце «Классические многослойные ИНС». 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.

Для предотвращения данного явления в работе исследовалась возможность применения аппарата глубоких нейронных сетей. Модифицированные алгоритмы обработки данных и обучения позволяют достигать с их помощью более высоких вычислительных возможностей, нежели с использованием классических многослойных сетей. Первоначально была осуществлена попытка применения таких базовых глубоких архитектур, как многослойные, сверточные и LSTM-сети, функционирование которых в общем случае представлено в (4) и (5).

$$\begin{cases} X^{(1)} = f_{ReLU}(X_i^{(0)} \otimes k_j^{(1)} + b_j^{(1)}) \\ X^{(2)} = a^{(2)} \cdot \text{subsample}(X^{(1)}) + b^{(2)} \\ \dots \\ X^{(n)} = f_{ReLU}(X_i^{(m)} \otimes k_j^{(n)} + b_j^{(n)}) \\ X^{(l)} = a^{(l)} \cdot \text{subsample}(X^{(n)}) + b^{(l)} \end{cases}, \quad (4)$$

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.

$$\begin{cases} f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \\ i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \\ o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \\ c_t = f_t \circ c_{t-1} + i_t \circ \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \\ h_t = o_t \circ \sigma_h(c_t) \end{cases}, \quad (5)$$

где x_i - входной вектор, h_i - выходной вектор, c_i - вектор состояний, W, U, b - матрицы и вектор весовых параметров, f_i, i_i, o_i - вектор вентиляей, $\sigma_g, \sigma_c, \sigma_h$ - функции активации.

Однако это не позволило достичь желаемого результата с точки зрения точности прогнозирования. Максимальная корреляция была достигнута при применении LSTM сети и при функционировании на тестовой выборке была равна $corr\ k = 0.6744$. Поэтому далее в работе исследовалась возможность применения гибридной структуры, архитектура которой представлена на рисунке 2. Использование данной архитектуры позволило объединить положительные качества каждой из базовых архитектур. Это обеспечило отсутствие автокорреляционного эффекта при функционировании прогнозных моделей технологических агрегатов передела при условии обеспечения достаточного уровня точности.

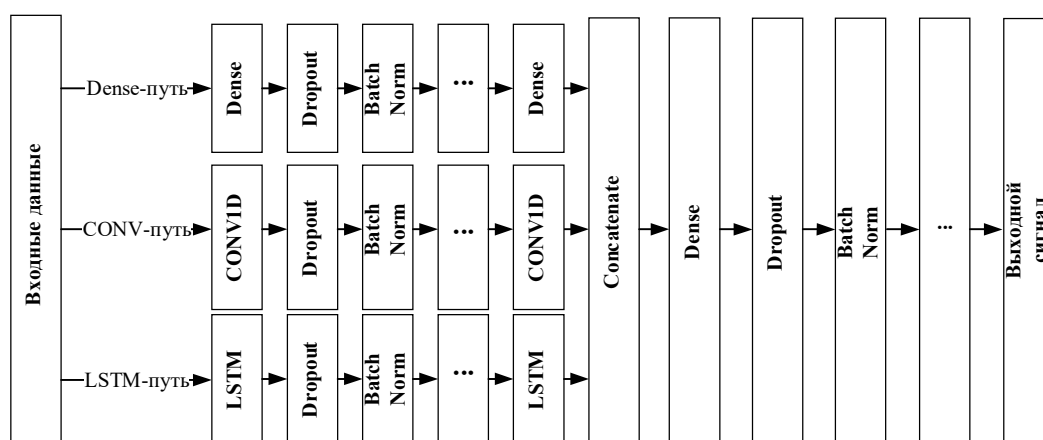


Рисунок 2. Архитектура гибридной глубокой нейронной сети

Для анализа устойчивости прогноза были выполнены эксперименты с различными соотношениями объемов обучающей и тестовой выборок, результаты представлены в таблице 2 (например, 90/10 – это 90 % данных используются для обучения, а 10 % - для тестирования).

Таблица 2. 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.

После интеграции разработанных моделей технологических объектов была произведена оценка качества представляемого прогноза по главному контролируемому критерию – процентному содержанию железа в концентрате. Функционирование общей модели осуществляется и представлено для наглядности в виде схемы на рис. 3:

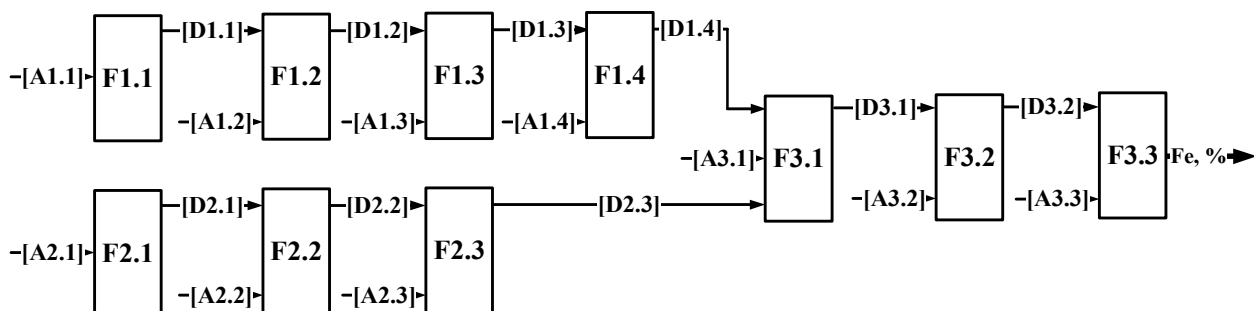


Рисунок 3. Схема функциональной зависимости единой модели секции обогащения

На рис. 3: $[Fe]$ – итоговый выходной сигнал содержания железа, $[D_{1.1}, D_{1.2}, D_{1.3}, D_{1.4}, D_{2.1}, D_{2.2}, D_{2.3}, D_{3.1}, D_{3.2}]$ – выходные сигналы плотности каждой из моделей соответственно, $[f_{1.1}, f_{1.2}, f_{1.3}, f_{1.4}, f_{2.1}, f_{2.2}, f_{2.3}, f_{3.1}, f_{3.2}]$ – функциональные зависимости работы объектов передела, $[A_{1.1}, A_{1.2}, A_{1.3}, A_{1.4}, A_{2.1}, A_{2.2}, A_{2.3}, A_{3.1}, A_{3.2}]$ – кортежи входных сигналов технологических объектов, 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 на рис. 3 векторы $A_{1.1} \dots A_{3.3}$ являются кортежами входных управляющих сигналов и представлены в выражении (6):

$$\left\{ \begin{array}{l} A_{1.1} = [W_{1.1}(t); Q_{1.1}(t); Q_{2.1}(t); P_{1.1}(t); I_{1.1}(t); I_{2.1}(t)], \\ A_{1.2} = [U_{1.2}(t); L_{1.2}(t); F_{1.2}(t); P_{1.2}(t)], \\ A_{1.3} = [U_{1.3}(t); L_{1.3}(t)], \\ A_{1.4} = [D_{1.4}(t); U_{1.4}(t); U_{2.4}(t); L_{1.3}(t)], \\ A_{2.1} = [W_{2.1}(t); Q_{1.2}(t); Q_{2.2}(t); P_{2.1}(t); I_{2.1}(t); I_{2.2}(t)], \\ A_{2.2} = [U_{1.2.2}(t); L_{1.2.2}(t); Q_{2.2}(t); P_{2.2}(t); U_{2.2.2}(t); L_{2.2.2}(t)], \\ A_{2.3} = [D_{1.2.3}(t); U_{1.2.3}(t); U_{2.2.3}(t); L_{2.3}(t)], \\ A_{3.1} = [U_{3.1}(t); L_{3.1}(t)], \\ A_{3.2} = [U_{1.3.2}(t); U_{2.3.2}(t); L_{1.3.2}(t); D_{1.3.2}(t); D_{2.3.2}(t); L_{2.3.2}(t); U_{3.3.2}(t); L_{3.3.2}(t); P_{3.2}(t)], \\ A_{3.3} = [U_{1.3.3}(t); U_{2.3.3}(t); L_{3.3}(t); D_{1.3.3}(t); D_{2.3.3}(t)] \end{array} \right. \quad (6)$$

В ходе проведения представленных экспериментов, была выявлена необходимость применения агрегированного критерия, предотвращающего ситуацию разнонаправленной оценки работы модели посредством применяемых ранее численных показателей. Данный критерий был обозначен $crit A$ (7):

$$crit A = \frac{corr k}{MSE}, \quad (7)$$

где $corr k$ - значение коэффициента корреляции, MSE - значение СКО.

Графики работы систем на основе различного аппарата, в сравнении с реальными значениями сигнала содержания железа в концентрате, представлены ниже на рис. 4.

Таблица 3 – 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




Рисунок 4. Результат работы систем на основе различного аппарата моделирования

Анализ данных графиков показывает, что модели на базе аппарата гибридных глубоких ИНС достигают качества моделирования при функционировании на тестовой выборке, обеспечивающее выполнения требований технологии.

Стоит отметить, что это достигается без появления эффекта автокорреляции выходного и исходного сигналов. Это наглядно продемонстрировано на рис.4, где видно, что система на базе глубоких гибридных ИНС заранее отрабатывает ситуацию изменения качественного показателя $[Fe, \%]$, в то время как регрессионная и классическая ИНС в большей степени опираются на предыдущие значения показателя. В итоге, это приводит к более высокому качеству функционирования системы прогнозирования в целом за счет лучшей интерпретации и анализа входных сигналов, что обеспечивает стабильность качества предоставляемого прогноза, независимо от изменения свойств процесса и агрегатов. Численные значения показателей качества моделирования представлены в таблице 3 в столбце «Глубокие ИНС гибридной архитектуры». Этот факт подтверждает правильность выбранного подхода.

В третьей главе исследования произведена идентификация технологических объектов с использованием методов машинного обучения для соединения их моделей в единую систему прогнозирования. Также была выполнена разработка алгоритма создания моделей технологических агрегатов на базе нейронных сетей. В ходе выполнения сравнительного анализа, было выявлено, что модели на базе глубоких нейронных сетей гибридной архитектуры позволяют получить инвариантные к изменению свойств сырья и агрегатов модели без появления автокорреляции выхода, что обеспечивает устойчивость функционирования подобной модели и предоставление качественного прогноза на протяжении большего времени.

В четвертой главе произведена разработка программного комплекса, обеспечивающего коррекцию уставок локальных контуров в существующей системе управления. Работа комплекса реализована в виде алгоритма, представленного на рис. 5.

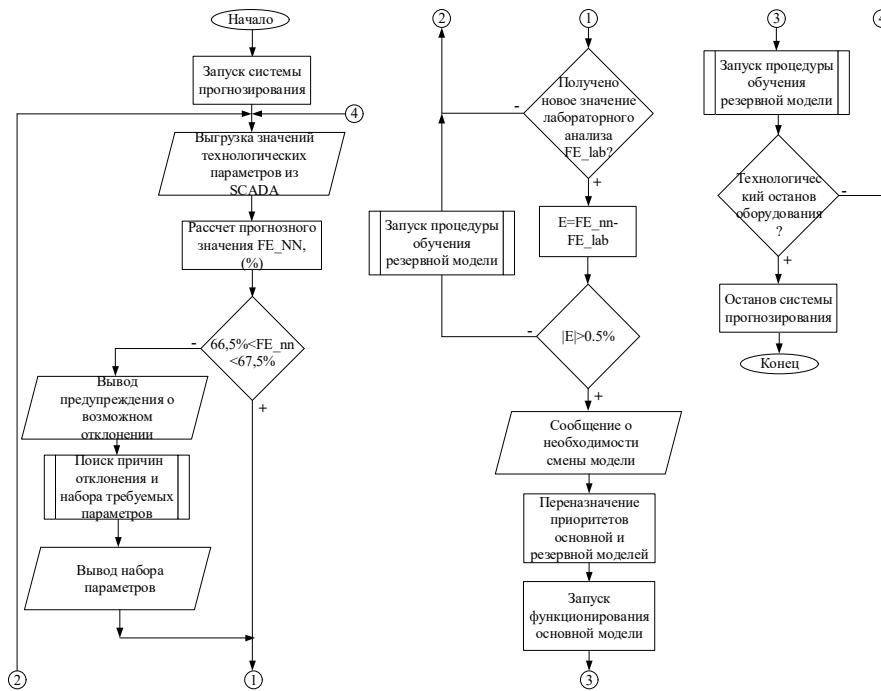


Рисунок 5. Алгоритм функционирования прогнозирующей системы

Для повышения надежности подсистемы прогнозирования, было предложено использовать два набора нейросетевых моделей: основной и резервный. В ходе функционирования системы выполняется процесс непрерывного предоставления прогноза «основной» моделью секции обогащения, в то же время происходит и обучение «резервной» модели на актуализированных данных. Затем, в момент отклонения значения содержания железа в концентрате нового лабораторного анализа более чем на 0.5% - выполняется процедура перехода работы системы с основной на резервную нейросетевую модель секции, в противном случае система продолжает функционирование в штатном режиме.

Для интеграции разработанного функционала в реальную систему управления в среде WinCC было разработано программное обеспечение, предоставляющее значение прогноза по содержанию железа в концентрате для помощи оператору обогатительной фабрики. Для этого, в окно главного кадра SCADA-системы было добавлено поле отображения значения прогноза по содержанию железа. В качестве дополнительного функционала был разработан и интегрирован в существующую структуру кадров, представленный на рис. 6, отображающий перечень моделей согласно разработанной схемы.

Анализируя значения сигналов с помощью представленного функционала, оператор имеет возможность оценить не только прогнозируемое изменение показателя (Fe,%), но и, в случае отклонения от задания, выявить переменные, которые приводят к этому. Однако, даже наличие данных показателей не во всех ситуациях позволит предотвратить наступление ситуации выхода за рамки технологических допусков.

Поэтому для помощи оператору был разработан дополнительный функционал, с помощью которого, оператор имеет возможность инициировать процедуру подбора параметров, которая позволяет привести систему к требуемым показателям выхода.

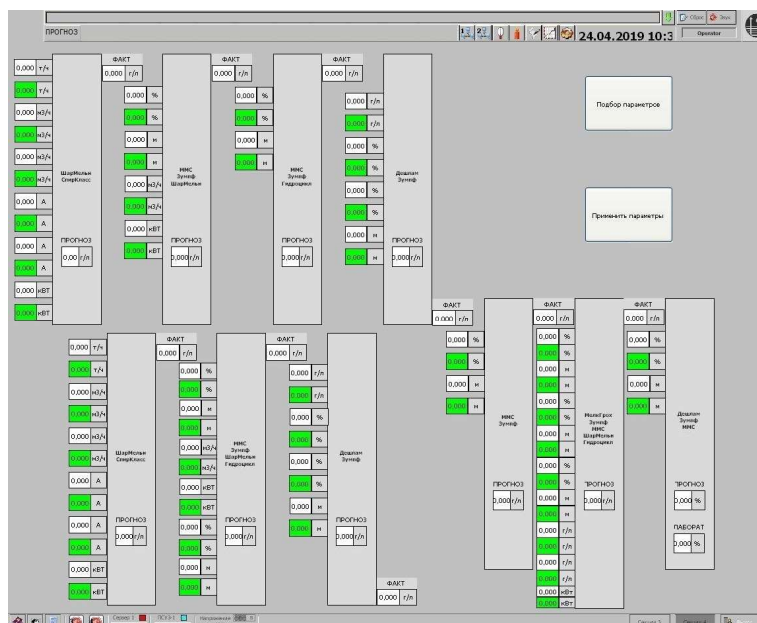


Рисунок 6. Экранная форма поагрегатной схемы моделей

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.

Для функционирования указанного модуля на главном экране SCADA реализована кнопка «Подбор параметров», при нажатии которой, с использованием актуальной модели процесса, запускается процедура подбора значений уставок, способных обеспечить заданное содержание железа в текущих условиях. Полученные уставки для коррекции выводятся в поля, расположенные ниже действующих значений значений параметров. Оператор может применить данный набор уставок по управляющим сигналам, если посчитает их целесообразными, или отказаться от применения. Схематично функционирование прогнозирующей системы представлено на рис. 7.

Предполагаемым положительным эффектом от использования прогнозирующей системы будет наличие у оператора инструмента, предоставляющего в режиме реального времени значение процентного содержания железа в концентрате. Информация, получаемая при функционировании программного комплекса, позволит оператору осуществлять управление в областях значений переменных, приближенных к граничным, не нарушая требований технологии. Это

позволит повысить производительность технологической линии.

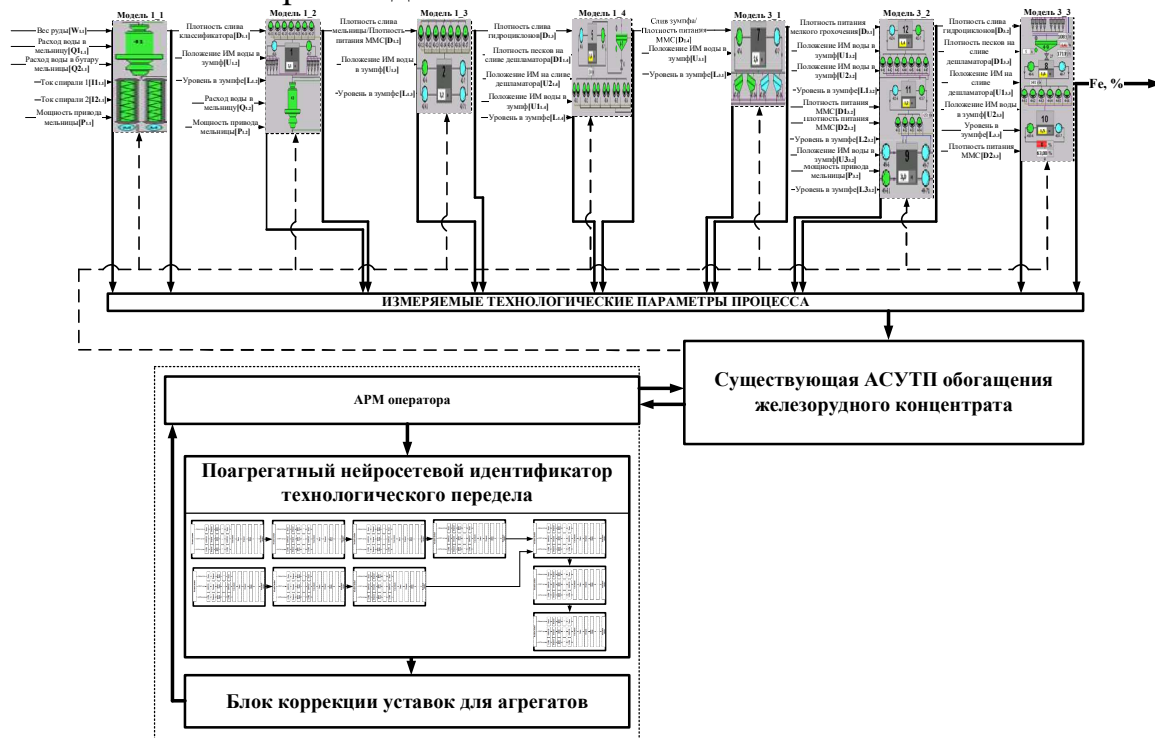


Рисунок 7. Принципиальная схема интеграции прогнозирующей подсистемы в существующую АСУ ТП

Одним из основных показателей работы обогатительного передела является объем обрабатываемого материала, который численно равен весу руды, подаваемой в головную мельницу технологической цепочки. При среднем значении показателя, рассчитанном в ходе экспериментов, равном порядка 579,1 тонны в час и возможном повышении значения до 590 тонн в час за счет увеличения допустимых интервалов изменения параметра, в годовом выражении, с учетом различных возможных внештатных ситуаций и ремонтов, прирост составит порядка 170 тыс. 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 млн рублей в годовом исчислении.

В четвертой главе была выполнена разработка алгоритма функционирования прогнозирующей системы, предполагающего контроль изменения значения процентного содержания железа. Для предотвращения ситуации снижения качества прогноза предусмотрена процедура актуализации моделей.

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 обогащения.

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.

ОСНОВНЫЕ ПУБЛИКАЦИИ ПО ТЕМЕ ДИССЕРТАЦИИ

Публикации в рецензируемых научных журналах из перечня ВАК РФ

1) Цыганков Ю.А. Идентификация шаровой мельницы по данным промышленной эксплуатации объекта / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А., Боровинских М.Д. // Горный информационно-аналитический бюллетень. – 2018. - №1. – С. 150-157.

2) Цыганков Ю.А. О построении нейросетевой модели технологического объекта на основе его информационно-аналитического представления / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. // Вести высших учебных заведений Черноморья. – 2018. - №1. – С. 45-57.

3) Цыганков Ю.А. О построении нейросетевой модели многопараметрических объектов горно-металлургического производства на примере комплекса «мельница-классификатор» / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. // Системы управления и информационные технологии, №2(76), 2019. – С. 53-58

Публикации, проиндексированные в SCOPUS и Web of Science

4) Tsygankov Y.A. Ball Mill States Classification using Competitive Neural Networks / Poleshchenko D.A., Tsygankov Y.A. // 2016 International Siberian Conference on Control and Communications (SIBCON-2016). National Research University "Higher School of Economics", Moscow, Russian Federation; 12 - 14 May 2016 – p.227-232, 2016.

5) Tsygankov Yu. A. Identification of Ball Mills by Operation Data / Eremenko Yu. I., Poleshchenko D. A., Tsygankov Yu. A., Borovinskikh M. D. // Mining Informational and Analytical Bulletin - 2018. – № 1. – p. 150 – 157.

6) Tsygankov Y.A. Development of neural network model of the multiparametric technological object / Eremenko Y.I., Poleshchenko D.A., Tsygankov Y.A. // Journal of fundamental and applied sciences – 2017. – Vol. 9. – № 7SI. – p. 706 – 721.

7) Tsygankov Yu.A. On neural network structure selection to solve problem of iron ore preparation process identification / Eremenko Yu. I., Poleshchenko D. A., Tsygankov Yu. A. // Journal of Physics: Conference Series. – 2019. - Vol. 1202. - Conf. 1. –012005.

8) Tsygankov Yu.A. On development of neural network model of multi-parametric objects of mining and metallurgical production using mill-classifier complex as example / Poleshchenko D.A., Tsygankov Y.A., Eremenko Y.I. // 2019 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM). Conference Proceeding. - Sochi, Russian Federation. - 2019.

9) Tsygankov Y.A. Neural network based identification of ore processing units to develop model predictive control system / Eremenko Y.I., Poleshchenko D.A., Tsygankov Y.A. // 2019 XXI International Conference Complex Systems: Control and Modeling Problems (CSCMP). Conf. Proc. - Samara, Russia. – 2019.

10) Tsygankov Y.A. Prediction of quality indicators of iron ore processing operations using deep neural networks / Eremenko Y.I., Poleshchenko D.A., Tsygankov Y.A. // 2020 2nd International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA). Conference Proceeding. - Lipetsk, Russia. – 2020.

Статьи и материалы конференций (выборочно)

11) Цыганков Ю.А. О нейросетевом моделировании динамических свойств технологического объекта / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. // XIII Всероссийское совещание по проблемам управления (ВСПУ-2019): Труды (17-20 июня 2019 г., Москва) / Под общ.ред. Д.А. Новикова. – М.: ИПУ РАН, 2019. – С. 2114 – 2119.

12) Цыганков Ю.А. О возможности построения экстремальной шаговой САУ шаровой мельницы / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. // Управление большими системами (УБС'2016). Материалы XIII Всероссийской школы-конф. молодых ученых / под общ. ред. Д.А. Новикова, В.Г. Засканова; Ин-т проблем упр. им. В.А. Трапезникова; Самарский ун-т. – М.: ИПУ РАН, 2016. – С. 611-622.

13) Цыганков Ю.А. Разработка математической модели шаровой мельницы для решения задач управления технологическим объектом / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. // Труды XI Всероссийской научно-практической

конференции «Системы автоматизации в образовании, науке и производстве» / под ред. С.М. Кулакова, Л.П. Мышляева - Новокузнецк: издательство «Сибирский государственный индустриальный университет», 2017. – С. 370-372.

14) Цыганков Ю.А. О возможности применения нейросетевого аппарата для идентификации шаровой мельницы / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. // Современные сложные системы управления (СССУ-2017): материалы XII международной научно-практической конференции (г. Липецк, 25-27 октября 2017г.). – Липецк: Изд-во Липецкого государственного технического университета, 2017. – Т.1. - с. 215-219.

15) Цыганков Ю.А. О возможности разработки модели шаровой мельницы на основе данных ее эксплуатации для построения эффективной системы управления объектом / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. // Сборник трудов Международной научно-технической конференции «Актуальные проблемы прикладной математики, информатики и механики», - ВГУ, Воронеж: Издательство «Научно-исследовательские публикации», ООО «Вэлборн», 2017. – С. 1625 – 1631.

16) Цыганков Ю.А. Идентификация многопараметрического технологического объекта при помощи нейронной сети / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А., Боровинских М.Д. // Проблемы управления и моделирования в сложных системах: Труды XIX Международной конференции / Под ред.: акад. Е.А. Федосова, акад. Н.А. Кузнецова, проф. В.А. Виттиха. – Самара: ООО «Офорт», 2017. – с. 123–128.

17) Цыганков Ю.А. Разработка модели процесса обогащения руды с использованием аппарата искусственных нейронных сетей / Еременко Ю.И., Полещенко Д.А., Цыганков Ю.А. // Информатика, управление и системный анализ: Труды V Всероссийской научной конференции молодых ученых с международным участием. – Ростов-на-Дону: Мини-Тайп, 2018. – С. 460 - 469.

Объекты интеллектуальной собственности

18) Свидетельство об официальной регистрации программы для ЭВМ № 2016663237 РФ. Анализатор уровня заполнения шаровой мельницы на базе конкурентной нейронной сети // Еременко Ю.И., Полещенко Д.А., Глущенко А.И., Цыганков Ю.А.; заявл. 11.10.2016; опубл. 29.11.2016 РОСПАТЕНТ.

19) Свидетельство об официальной регистрации программы для ЭВМ № 2020662881 РФ. Нейросетевой идентификатор цепочки агрегатов технологического передела // Цыганков Ю.А., Полещенко Д.А.; заявл. 08.10.2020; опубл. 20.10.2020 РОСПАТЕНТ.

Личный вклад автора в работы, выполненные в соавторстве, состоит в разработке методики построения динамических нейросетевых моделей технологических объектов процесса обогащения железорудного концентрата, выполнении сравнительного анализа при реализации данных моделей на базе иных идентификационных аппаратов [1,2,3,5,6,7,8,9,10,11,12,13, 14,15,16,17], разработке алгоритма предобработки данных и экспериментальном определении способа фильтрации сигналов [2,3,4,5,6,7,8,12,13,14].