

Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Санкт-Петербургский государственный технологический институт
(технический университет)»

На правах рукописи

ЕГОРОВА ЕКАТЕРИНА ГЕННАДЬЕВНА

ОПЕРАТИВНОЕ УПРАВЛЕНИЕ ПРОЦЕССОМ
ПРОИЗВОДСТВА ЖЕЛЕЗОРУДНОГО АГЛОМЕРАТА

05.13.06 – Автоматизация и управление технологическими
процессами и производствами (металлургия)

ДИССЕРТАЦИЯ
НА СОИСКАНИЕ УЧЕНОЙ СТЕПЕНИ КАНДИДАТА
ТЕХНИЧЕСКИХ НАУК

Научный руководитель -
доктор технических наук,
профессор Русинов Л.А.

Санкт-Петербург
2016

ОГЛАВЛЕНИЕ

ОГЛАВЛЕНИЕ.....	2
СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ.....	4
ВВЕДЕНИЕ	5
ГЛАВА 1 Описание предметной области	12
1.1 Описание процесса подготовки железорудного агломерата	12
1.2 Обзор существующих систем диагностики процесса агломерации.....	17
1.3 Анализ процесса подготовки железорудного агломерата как объекта диагностики и оперативного управления	20
1.4 Выводы. Постановка задачи исследования	24
ГЛАВА 2 Структура системы оперативного управления.....	27
2.1 Структура типовой системы оперативного управления.....	27
2.2 Требования к системе оперативного управления	28
2.3 Обзор систем диагностики	31
2.3.1 Подход на основе качественных соотношений	32
2.3.2 Подход на основе количественных соотношений	34
2.3.3 Подход, использующий массивы данных с процесса	37
2.4 Диагностические нейросетевые модели.....	43
2.4.1 Виды нейронных сетей.....	47
2.5 Выводы по 2-й главе	52
ГЛАВА 3 Разработка структуры и алгоритма работы системы диагностики	54
3.1 Диагностическая модель процесса	54
3.1.1 Структура диагностической модели	54
3.1.2 Метод главных компонент	58
3.1.3 Мониторинг с использованием МГК.....	60
3.2 Структурирование возможных нарушений в ходе процесса агломерации	62
3.2.1 Методика формирования перечня нарушений.....	62
3.2.2. Структурирование нарушений и формирование перечня ситуаций на процессе агломерации.....	64
3.3 Увеличение глубины диагностики введением цифровых оптических камер	74
3.3.1. Места установки и выбор типа камер	74
3.3.2 Алгоритмы обработки изображений.....	77

3.4 Алгоритм работы СОУ.....	88
3.5 Выводы по 3-й главе	94
ГЛАВА 4 Экспериментальное исследование системы оперативного управления	97
4.1 Порядок исследования	97
4.2 Описание структуры программного обеспечения для исследования системы, разработанного в среде MATLAB	97
4.3 Подготовка исходных данных.....	98
4.4 Разработка СВУ и СЧУ.....	106
4.5 Имитационное моделирование и тестирование ДМ.....	109
4.6 Выводы по 4-й главе	118
ЗАКЛЮЧЕНИЕ.....	120
СПИСОК ЛИТЕРАТУРЫ	123
ПРИЛОЖЕНИЕ.....	132

СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

MES	- manufacturing execution system (система управления производственными процессами)
PC	- principal components (главные компоненты)
PCA	- principal component analysis (метод главных компонент)
SCADA	- supervisory control and data acquisition (диспетчерское управление и сбор данных)
АСУ ТП	- автоматизированная система управления технологическим процессом
ГК	- главная компонента
ГПСС	- граф причинно-следственных связей
ДМ	- диагностическая модель
МГК	- метод главных компонент
МНК	- метод наименьших квадратов
НС	- нейронная сеть
НСГ	- направленный сигнальный граф
РБФ	- радиально-базисная функция
СВУ	- сеть верхнего уровня
СКО	- среднеквадратичное отклонение
СНУ	- сеть нижнего уровня
СОУ	- система оперативного управления
ЭС	- экспертная система

ВВЕДЕНИЕ

Повышенные требования к качеству выпускаемой продукции и снижению её себестоимости на современных металлургических предприятиях ставят во главу угла задачу получения качественного продукта на всех этапах металлургического производства и, в частности, на начальном переделе – агломерационном производстве. При модернизации существующих металлургических производств и строительстве новых особое внимание уделяется подготовке высококачественного железорудного агломерата – основного компонента для выплавки чугуна в доменных печах. В настоящее время доля железорудного агломерата в шихте доменных печей составляет более 80%.

Процесс агломерации относится к числу сложных, многомерных технологических процессов; протекает в условиях большого числа возмущающих воздействий: изменение химико-минералогического, гранулометрического состава компонентов шихты; условий увлажнения, дозирования, смешивания и укладки шихты на поверхность агломашины. Процесс автоматизирован, однако системы управления процессом агломерации на современных производствах не позволяют обеспечить максимальную производительность агломашин и постоянство высокого качества выходного продукта. В этой связи должны совершенствоваться методы и системы управления технологией подготовки железорудного агломерата.

Опрос экспертов и анализ регламента позволил выделить ряд нарушений, с которыми система автоматизации не справляется. Следует отметить, что различные нарушения на процессе часто имеют сходные проявления, что приводит к несвоевременному обнаружению предпосылок аварий обслуживающим персоналом и служит причиной ошибочных решений по управлению процессом. Действие системы защиты в таких условиях сводятся в основном к отключению оборудования и переводу процесса в безопасный режим, что ведет к экономическим потерям предприятия.

Поэтому возникает задача обнаружения и идентификации возможных нарушений в ходе процесса агломерации на ранних стадиях их развития. Это достигается использованием системы непрерывного мониторинга и диагностики технологического процесса, работающей параллельно с традиционной системой управления. Задачей системы является обеспечение раннего выявления отклонений от нормального

характера протекания процесса подготовки железорудного агломерата и возможность оперативного управления им с целью своевременной ликвидации этих отклонений посредством выдачи рекомендаций по их предотвращению, чтобы уменьшить выход продукции несоответствующего качества. Диагностическая модель системы строится на основе экспертной и теоретической информации о процессе. В законченном варианте система оперативного управления представляет собой подсистему АСУ ТП, реализующую дополнительные функции в ходе процесса агломерации, а именно: обнаружение нарушения, определение его причины и выдачу соответствующих рекомендаций операторам, ведущим процесс.

Вопросам создания систем оперативного управления процессом агломерации уделяется серьезное внимание, о чем свидетельствует большое количество публикаций, особенно в зарубежной литературе. Это напрямую говорит об актуальности проблемы, рассматриваемой в данной работе.

Цель работы

Целью работы является разработка структуры и алгоритма функционирования системы оперативного управления процессом производства железорудного агломерата на основе нейросетевой диагностической модели. Система должна обеспечивать раннее обнаружение нарушений и определение причин, их вызвавших.

Задачи, решаемые в работе

Для достижения указанной цели в диссертационной работе поставлены и решены следующие задачи:

1. Проведено исследование процесса производства железорудного агломерата.
2. Осуществлен сбор и обработка теоретической и экспертной информации о процессе. Сформирован перечень типовых нарушений на процессе.
3. Разработаны методы выявления нарушений, не имеющих измеряемых непосредственно на процессе или лабораторно проявлений (симптомов).
4. Сформирована диагностическая модель процесса агломерации и проведена её идентификация.

5. Разработан алгоритм работы системы на основе двухуровневой диагностической модели процесса агломерации с нейронной сетью на верхнем уровне и рядом подчинённых сетей на нижнем.

6. Проведена проверка работоспособности системы методом имитационного моделирования.

Методы исследования

При выполнении работы были использованы метод главных компонент, методы матричного исчисления, статистического анализа, технической диагностики и имитационного моделирования, технологии нейронных сетей.

Научная новизна

1. Сформирована двухуровневая нейросетевая диагностическая модель процесса: сеть верхнего уровня работает с преобразованной с целью сокращения размерности методом главных компонент исходной информацией, производит локализацию возможных нарушений; сети нижнего уровня производят идентификацию причин их возникновения. Это позволило сократить размерности сетей и существенно уменьшить время переобучения.

С целью увеличения глубины диагностики для контроля симптомов нарушений, проявляющихся во внешнем виде агломерационного пирога и непосредственно влияющих на качество агломерата, введены оптические цифровые камеры и разработаны алгоритмы обработки получаемых с них изображений, использующие нечеткую логику для учета неопределенностей в исходной информации.

2. На основании анализа возможных нарушений на технологическом процессе агломерации предложен комбинированный метод диагностики нарушений: во время непрерывного мониторинга производится обнаружение факта возникновения нарушения на процессе агломерации статистиками T^2 и Q ; после этого определение причины нарушения проводится на базе нейросетевой диагностической модели.

Основные защищаемые положения

1. Двухуровневая нейросетевая диагностическая модель процесса производства железорудного агломерата: сеть верхнего уровня работает с преобразованной методом главных компонент исходной информацией, производит локализацию возможных нарушений; сети нижнего уровня производят идентификацию причин их возникновения.

С целью увеличения глубины диагностики для контроля симптомов нарушений, проявляющихся во внешнем виде агломерационного пирога и непосредственно влияющих на качество агломерата, введены оптические цифровые камеры и разработаны алгоритмы обработки получаемых с них изображений, использующие нечеткую логику для учета неопределенностей в исходной информации.

2. Комбинированный метод диагностики нарушений: во время непрерывного мониторинга производится обнаружение факта возникновения нарушения на процессе агломерации статистиками T^2 и Q ; после этого определение причины нарушения проводится на базе нейросетевой диагностической модели.

Практическая значимость

Разработан алгоритм работы системы, включающий:

- на предварительном этапе - первичное обучение сетей, с возможностью последующего их переобучения (например, при изменении параметров исходного сырья);
- на рабочем этапе - собственно мониторинг и диагностику нарушений; и отличающийся тем, что предусмотрены меры по предотвращению возможной «потери» нейронной сетью опознанной причины из-за отсутствия результатов действий оператора и продолжения развития нарушения.

Разработанная система оперативного управления процессом производства железорудного агломерата позволяет проводить в реальном времени диагностику ситуаций с определением нарушений, их вызвавших. Система позволяет повысить эффективность оперативного управления технологическим процессом производства

агломерата, так как определение нарушений в реальном времени и выдача рекомендаций оператору, дает возможность вовремя принять соответствующие меры для возвращения процесса в регламентный режим.

Алгоритм работы и структура диагностической модели могут быть использованы для аналогичных процессов в других отраслях промышленности.

Апробация результатов

Результаты диссертационной работы были представлены в виде докладов на конференциях:

Международная научная конференция «Математические Методы в Технике и Технологичеках ММГТ- 29» (Санкт-Петербург, 31 мая – 3 июня 2016 г.);

Международный симпозиум по хемометрике WCS-10 (Самара, 29 февраля – 4 марта 2016 г.);

Научная конференция «Традиции и инновации», посвященная 187-й годовщине образования Санкт-Петербургского государственного технологического института (технического университета) (Санкт-Петербург, 3– 4 декабря 2015 г.);

Международная научно-практическая конференция «Инновационные технологии в минерально-сырьевом комплексе на базе научных достижений, автоматизации и диспетчеризации предприятий» (Санкт-Петербург, ФГБОУ ВПО Национальный минерально-сырьевой университет «Горный», 30 – 31 мая 2013 г.);

Научно-практическая конференция молодых ученых Санкт-Петербургского государственного технологического института (технического университета) «Неделя науки-2013» (Санкт-Петербург, 2 – 4 апреля 2013 г.);

Научно-практическая конференция, посвященная 184-й годовщине образования Санкт-Петербургского государственного технологического института (технического университета) (Санкт-Петербург, 29 – 30 ноября 2012 г.).

Научно-практическая конференция молодых ученых «Неделя науки-2012» Санкт-Петербургского государственного технологического института (технического университета) (Санкт-Петербург, 28 – 29 марта 2012 г.);

Научно-практическая конференция молодых ученых «Неделя науки-2011» Санкт-Петербургского государственного технологического института (технического университета) (Санкт-Петербург, 30 марта – 1 апреля 2011 г.);

Научно-практическая конференция Санкт-Петербургского государственного технологического института (технического университета), посвященная 182-й годовщине образования (Санкт-Петербург, 25 – 26 ноября 2010 г.).

Публикации

По теме диссертационной работы опубликовано 12 печатных работ, в том числе 3 статьи в журналах из списка ВАК.

Структура и объем работы

Материал диссертационной работы сгруппирован в 4-х главах, снабжен заключением, списком литературы и содержит одно приложение. Работа изложена на 133 страницах основного текста, содержит 33 рисунка, 3 таблицы и список использованной литературы, включающий 88 наименований.

Во введении показана актуальность темы диссертационной работы, сформулирована ее цель, приведены основные результаты и описана структура работы.

В первой главе дано краткое описание процесса производства железорудного агломерата, обращено внимание на параметры, существенно влияющие на качество готового продукта. Сформулированы цели и задачи исследований, направленные на повышение качества готового агломерата.

Во второй главе рассмотрена типовая структура автоматизированной системы оперативного управления (СОУ). Показано, что важными функциями СОУ являются функции мониторинга и диагностики состояния контролируемого процесса в реальном времени.

Сравнение возможностей диагностических моделей разных видов показало, что ни одна из них не является универсальной. На основании литературного обзора при разработке диагностической модели процесса был выбран нейросетевой тип модели, свободный от ряда недостатков экспертных диагностических моделей, используемых в основном для построения систем диагностики нарушений на процессе агломерации.

В третьей главе рассмотрены вопросы формирования комбинированной диагностической модели процесса агломерации и разработки алгоритма работы подсистемы диагностики в рамках системы оперативного управления процессом.

В четвертой главе приводятся данные экспериментального исследования разработанной системы. Исследование системы проводилось в среде MATLAB 2013 методом имитационного моделирования на массиве данных с процесса.

Заключение содержит основные выводы и результаты проведённого исследования.

ГЛАВА 1 Описание предметной области

1.1 Описание процесса подготовки железорудного агломерата

Процесс агломерации представляет собой спекание руд, концентратов и измельчённого топлива в прочные пористые куски – агломерат. Кратко, процесс агломерации можно описать следующим образом: шихту, состоящую из мелкого железорудного концентрата, измельчённого известняка, железосодержащих добавок, возврата (некондиционный агломерат от предыдущего спекания) и топлива, загружают на конвейерную агломерационную машину, зажигают сверху и спекают, просасывая воздух через слой спекаемых материалов.

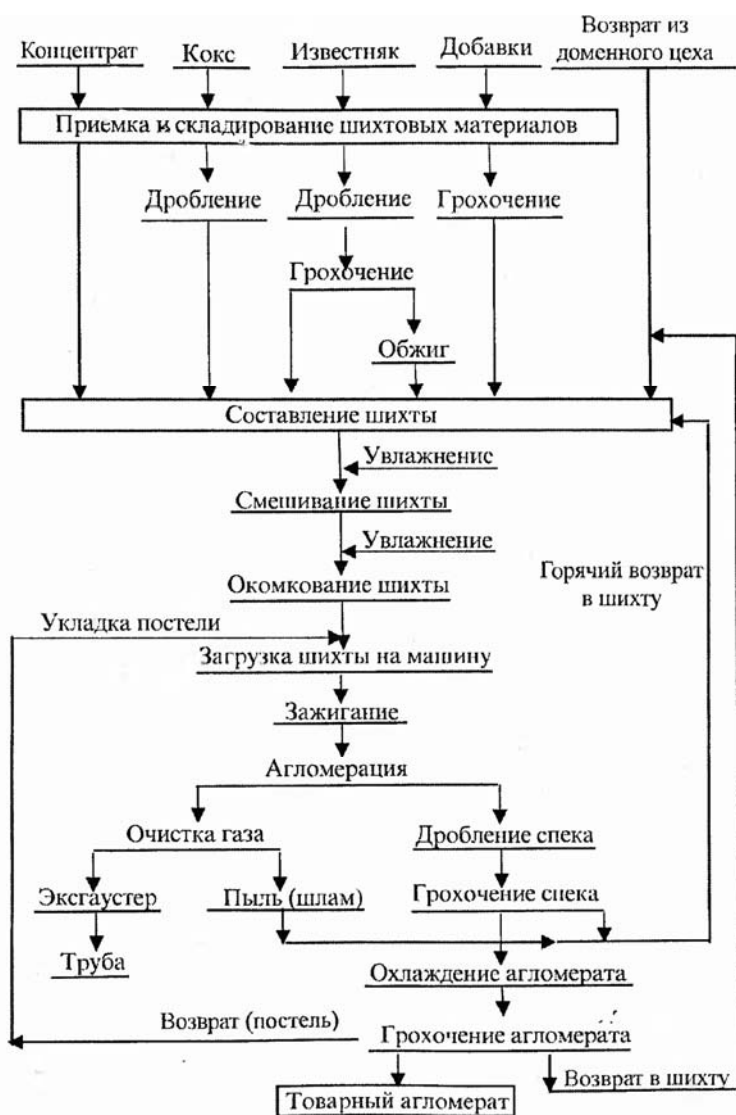


Рисунок 1.1 – Технологическая схема производства агломерата [1]

Основные стадии процесса агломерации приведены на рисунке 1.1. На рисунке 1.2 показан внешний вид агломерационной машины. Упрощённая схема процесса спекания представлена на рисунке 1.3.




Рисунок 1.2 – Внешний вид агломерационной машины




Рисунок 1.3 – Упрощённая схема процесса спекания

Компоненты шихты с рудного двора поступают в приёмный бункер 1, откуда по транспортёрам-конвейерам 2 и 4 подаются в первичный смеситель-окомкователь 5, где происходит их смешивание, увлажнение и первичное окомкование. Из бункера 3 в смеситель поступает возврат. Дозирование компонентов шихты осуществляется с помощью тарельчатых или вибрационных питателей 26. Далее шихта загружается в бункер 6 и транспортёром 7 в определённом соотношении с коксиком (топливом) из бункера 8 подаётся во вторичный смеситель-окомкователь 9 и далее в бункер 13 [1].

Подготовленную шихту 15 из бункера 13 непрерывно подают системой загрузки на аглоленту 17 и укладывают на бесконечную движущуюся цепь колосниковых тележек (паллет), предварительно поместив на неё постель 16, которая поступает из приёмного 10 и промежуточного 12 бункеров по транспортёру 11. Встречается на аглофабриках и другая технологическая схема с укладкой шихты двумя слоями (кроме постели) разного состава с самостоятельными смесителями-окомкователями [1].

Затем включают работающий на отсос эксгаустер 25, под колосниковой решёткой создаётся разрежение, благодаря чему в слой засасывается поток горячих газов, обеспечивающих зажигание шихты, т.е. нагрев поверхностного слоя [1]. Зажигание шихты происходит при прохождении её под зажигательным горном 14, отапливаемом жидким или газообразным топливом. По мере движения тележек горение коксика распространяется в нижние слои за счёт атмосферного воздуха, просасываемого с помощью размещённых под тележками вакуум-камер 22, в которых эксгаустером 25 создаётся разрежение до 10-15 кПа [2].

Готовый агломерат после машины дробят в дробилках 18, отсеивают на грохотах 19, охлаждают и отправляют в доменный цех по транспортеру 20. Неспекшийся материал (возврат) помещают в приёмные бункеры 21 и возвращают для повторного спекания. Продукты сгорания из вакуум-камер 22 по коллектору 23 поступают на очистку в циклоны 24 и удаляются эксгаустером 25 в трубу 27.

Общее время процесса агломерации можно разделить на три этапа (рисунок 1.4): начальный τ_n – зажигание аглошихты; основной τ_o – спекание шихты, во время которого происходит перемещение по слою зон формирования агломерата, интенсивного нагрева, сушки; заключительный τ_3 – охлаждение агломерата.




Рисунок 1.4 – Схема расположения отдельных зон в продольном сечении агломерируемого слоя: t_g – температура отсасываемого газа; 1 – готовый агломерат; 2 – зона плавления; 3 – зона интенсивного нагрева; 4 – зона сушки; 5 – зона переувлажнения; 6 – зона конденсации; 7 – исходная шихта

Процесс считается законченным, когда зона формирования агломерата дойдёт до колосников спекательных тележек. При вертикальной скорости спекания 20мм/мин слой шихты толщиной 300мм превращается в агломерат за 15 мин [1].

Из-за высокой удельной поверхности шихты ($30-50\text{см}^2/\text{см}^3$) особенностью агломерации железорудных материалов является интенсивный теплообмен и массообмен в слое шихты, чем объясняется небольшая высота зон плавления, интенсивного нагрева, сушки, что в свою очередь приводит к небольшому времени пребывания каждого элементарного объёма спекаемого материала при высоких температурах. Поэтому необходимо обеспечить такие условия процесса (скорость движения газа в слое, крупность частиц компонентов шихты), чтобы за небольшое время успели пройти процессы, обеспечивающие получение агломерата требуемого качества (выгорание углерода и серы, нагрев рудных частиц до температур плавления, их слипание) [1].

Основными показателями хода процесса агломерации являются качество готового агломерата и производительность агломашины. Контроль качества агломерата в процессе производства осуществляется посредством контроля качества выпускаемой продукции и контроля технологических параметров оборудования [3].

Качество готового продукта оценивают по химическому составу, прочности и восстановимости. Отношение $\text{FeO}/\text{Fe}_2\text{O}_3$ является косвенным показателем качества агломерата [2].

Процесс производства агломерата протекает под воздействием множества факторов: изменений химико-минералогического, гранулометрического состава, условий дозирования, смешивания, окомкования, укладки шихты на аглоленту [2].

На начальном этапе подготовки агломерационная шихта для обеспечения нужной газопроницаемости увлажняется. Заданная газопроницаемость обеспечивается путём регулирования расхода воды в смеситель-окомкователь [2].

Интенсивность зажигания напрямую влияет на весь процесс спекания: при недостаточной интенсивности может произойти «недопёк» части слоя, при избыточной - возможно оплавление верхнего слоя агломерата, уменьшение газопроницаемости и снижение скорости спекания [2].

Качество выплавляемого агломерата определяется характером процесса спекания. Управление процессом спекания заключается в стабилизации места его окончания на аглоленте и выборе входных параметров (состав шихты, влажность, содержание углерода), обеспечивающих выход агломерата требуемого качества. Место окончания процесса спекания напрямую зависит от состава шихты, её влажности и плотности, высоты слоя шихты, скорости движения аглоленты. Данные возмущения проявляются через вертикальную скорость спекания слоя шихты на аглоленте, являющуюся возмущающим воздействием для системы управления [2].

Агломерат как основной компонент для доменной плавки должен обладать следующими свойствами: высокое содержание железа и минимальное содержание вредных примесей, хорошая восстановимость (способность отдавать связанный с железом кислород восстановителю; максимум восстановимости относится к агломерату основности $\text{CaO} + \text{SiO}_2 = 1,4-1,5$), однородный гранулометрический состав, высокая температура размягчения и малый интервал температур плавления. Сложность получения агломерата высокого качества заключается в том, что условия для получения тех или иных свойств агломерата оказываются противоречащими друг другу. При достижении максимальной производительности агломашин качество агломерата не всегда соответствует заданному. Данные факты усложняют процесс управления подготовкой железосодержащего агломерата, при котором необходимо подобрать режим, который давал бы возможность получать выходной продукт высокого качества при максимальной производительности агломашин [1].

В приложении А приведена типовая функциональная схема автоматизации процесса агломерации. Основными контролируруемыми технологическими параметрами являются: температура (в вакуум-камерах, перед циклонами, перед эксгаустером, отходящих газов, агломерата на ленте, агломерата на выдаче, возврата); давление (воды на увлажнение, после нагнетателя), разрежение (в вакуум-камерах перед циклонами, перед эксгаустером); количество продуктов горения; уровень (в бункерах газохода, в бункерах циклонов, в бункере возврата), контроль выдачи шихты, контроль забивки точки, влажность шихты, скорость движения агломашины.

1.2 Обзор существующих систем диагностики процесса агломерации

Продолжительное время, с момента развития технологий железорудного спекания, вопросом повышения качества железорудного агломерата занимаются как на отечественных, так и на зарубежных предприятиях, но ни один из применимых в настоящее время на предприятиях методов не решает задачу в достаточном объёме.

В современной литературе представлены системы управления процессом агломерации, в том числе включающие подсистемы диагностики нарушений процесса агломерации [4].

Первая экспертная система для управления процессом спекания была применена на металлургическом заводе в Японии в начале 80-х годов двадцатого века. В настоящее время она значительно усовершенствована. На металлургическом заводе корпорации Kawasaki Steel в г. Тиба разработана система оперативного управления, которая включает систему управления энергопотреблением процесса спекания, систему управления подачей материала и систему управления химическим составом шихты. Применение данной системы оперативного управления уменьшает расход коксовой мелочи, стабилизирует управление. Также в Японии, Kawasaki Steel Corp разработала и внедрила на агломашинах № 3 и № 4 металлургического завода в г.Мицусима автоматизированную систему управления технологическим процессом, в составе которой тоже использована экспертная система, основными функциями которой являются: управление скоростью машины по результатам контроля точки окончания процесса спекания, управление циклами возврата, контроль состояния оборудования, контроль качественных характеристик агломерата [5].

На японском металлургическом заводе Yawata Nippon Steel в городе Табата для управления процессом спекания используется экспертная система, основными функциями которой являются: анализ процесса и прогноз его развития, контроль состояния оборудования, выявление отклонений процесса и состояния оборудования от нормы. Применение экспертной системы в составе АСУТП позволило значительно снизить расход твердого топлива и флюса в аглошихту [6].

Японская компания «Кобэ сталь» разработала управляющую систему процессом спекания агломерата, которая при помощи знаний оператора о доле оборотных продуктов, на основе теории нечетких множеств и теории сетей позволяет проанализировать связь между технологическими параметрами и выходом годного агломерата [6].

В работе [7] описывается интеллектуальная система поддержки принятия решений, разработанная китайскими учёными, которая позволяет производить сбор и анализ данных в режиме реального времени. Система выполняет контроль химического состава агломерата на основе адаптивного прогноза характеристик агломертата с применением нейронных сетей, контроль состояния агломерационного процесса, а также диагностику состояния процесса спекания на основе оценки газопроницаемости слоя шихты.

Также китайскими учёными разработана система оптимизации процесса спекания на основе нейронных сетей, которая прогнозирует основные показатели эффективности процесса для дальнейшей его оптимизации [8], и система извлечения данных о процессе агломерации, основанная на технологиях data mining [9].

На агломашине Аньшаньского металлургического комбината в КНР внедрена экспертная система, включающая в своём составе экспертный и пользовательский блоки; интерфейс; базы знаний и данных; блоки управления базой знаний и прогноза, предназначенная для стабилизации химического состава агломерата. На основе сравнения новых и предыдущих данных, блок прогноза предсказывает химический состав агломерата на последующие два часа, а экспертная система оценивает химический состав путем сравнения результатов прогноза с заданными предельными значениями. Если одно из прогнозных значений не удовлетворяет принятым нормативным цифрам, то экспертная система анализирует причины отклонений и выдает рекомендацию, как скорректировать соотношение компонентов аглошихты,

например, рекомендации на снижение содержания известняка в шихте при резком увеличении основности агломерата [6].

В работе [10] представлена система диагностики процесса агломерации одной из китайских аглофабрик. Система основана на нечёткой логике: изменение газопроницаемости слоя шихты в начальной стадии спекания оценивается интегрированной нечеткой подсистемой; окончание спекания «нечетко» определяется на основании температуры отходящих газов; производится прогнозирование момента окончания спекания. Практическое применение данной системы показывает, что флуктуации основных параметров могут быть снижены на 18-25%. Позднее, в работе [11] с использованием знаний об энергетических балансах процесса агломерации, рассмотрен вопрос подсосов, появляющихся вследствие образования неплотностей. Результатом данного исследования явилась разработка экспертной системы диагностики, позволяющей локализовать места возникновения неплотностей.

В работе [12] европейскими исследователями предложена система диагностики процесса агломерации, которая определяет оптимальное количество кокса, необходимое количество кислорода для спекания, объем газа необходимого для зажигания шихты, объем отходящих газов, на основании этих данных изменяется производительность эксгаустера для поддержания процесса спекания в норме.

Немецкими учёными разработана система диагностики качества агломерата, основанная на использовании нейро-нечетких сетей для прогноза качественных характеристик агломерата [13].

Румынские исследователи разработали математическую модель аглопроцесса, которая обеспечивает минимизацию расхода твёрдого топлива при высокой производительности агломашины [6].

Финская компания Outotec предлагает систему диагностики, которая производит контроль законченности процесса спекания и газопроницаемости слоя, расчет оптимального соотношения компонентов шихты [14].

Немецкая компания Siemens VAI предлагает интегрированную экспертную систему, которая стабилизирует основность, гранулометрический состав агломерата и снижает расход твёрдого топлива посредством поддержания расхода шихтовых компонентов, оптимизации скорости движения агломашины, контроля законченности спекания процесса [15].

В работе [16] описан разработанный отечественными учёными во главе с Зобниным Б.Б. и Малыгиным А.В. программный продукт применительно к условиям АГП ОАО «Северсталь», позволяющий прогнозировать химический состав агломерата по реальным значениям состава компонентов шихты, вследствие чего своевременно корректировать состав шихты с целью получения агломерата соответствующего качества.

Исследователи Важинский А.И. и Жуков С.Ф. предложили систему поддержки принятия решений на базе микропроцессорной техники и SCADA-системы, с использованием математической модели, включающей в себя уравнения баланса: материального, основности и теплового. Система позволяет давать прогноз химического состава готового агломерата на основании данных о составе компонентов исходной аглошихты, также включает в себя подсистему диагностики технического состояния оборудования [17].

В работах Ершова Е.В. [18-21] сообщается о разработке метода корректировки процесса спекания агломерационной шихты, отличающегося использованием способов распознавания высокотемпературной зоны излома и температурного поля поверхности спекаемого слоя за зажигательным горном, что повышает оперативность и достоверность принятия решения.

1.3 Анализ процесса подготовки железорудного агломерата как объекта диагностики и оперативного управления

Агломерат как основной компонент сырья для доменной плавки, от которого, в конечном счёте, зависит качество выплавляемого металла, должен обладать следующими характеристиками [1]:

- высокая механическая прочность, высокая пористость;
- высокое содержание железа (низкое содержание пустой породы);
- минимальное содержание вредных примесей;
- основность (весовое соотношение CaO/SiO_2), достаточная для полного вывода из доменной шихты сырого известняка;
- минимальные колебания содержания железа (от $\pm 0,5$ до $\pm 1,0\%$) и основности (от $\pm 0,05$ до $\pm 0,1\%$) [3];

- хорошая восстановимость;
- однородный гранулометрический состав — наибольшее количество кусков должно иметь размеры в пределах 20-60 мм (при минимальном содержании мелочи -5 мм);
- высокая температура размягчения и малый интервал температур плавления.

Процесс подготовки железорудного агломерата относится к числу сложных, многокритериальных технологических процессов; протекает в условиях большого числа возмущающих воздействий: изменение химико-минералогического, гранулометрического состава компонентов шихты; условий увлажнения, дозировки, смешивания и укладки шихты на поверхность агломашины. Основные характеристики процесса агломерации, представленные как совокупность технологических характеристик и характеристик устройств процесса, перечислены ниже:

1. Большое запаздывание результатов анализа

Шихта для того, чтобы стать готовым агломератом проходит через этапы дозирования, смешивания, подачи на аглоленту, зажигания, спекания, горячего дробления, охлаждения. Весь этот процесс занимает около двух часов. Кроме того, количество и качество выходного продукта необходимо проверять каждые два часа, при этом анализ качества является довольно времяемким, длится 1-2 часа. Таким образом, рабочие состояния дозирования, смешивания, подачи шихты до спекания могут быть отражены посредством анализа количества и качества готового агломерата только после не менее трёх часов. Другими словами, колебания количества и качества выходного продукта в настоящем определяются причинами ситуаций, которые произошли четыре часа назад на процессе. Большое запаздывание результатов анализа процесса агломерации усложняет достижение точного управления на процессе и является одной из ключевых проблем при управлении процессом спекания.

2. Сложность процесса

Процесс агломерации включает в себя такие процессы, как сжигание топлива, теплообмен в спекаемой «постели», испарение и конденсация влаги, разложение карбонатов, окисление, реакция в твёрдой фазе, образование и конденсация жидкой фазы во время процесса спекания. Процесс агломерации является довольно сложным процессом, протекающим под воздействием большого числа химико-физических возмущений, он описывается большим количеством параметров. Процесс непрерывен,

нелинеен и характеризуется плохой наблюдаемостью и высоким уровнем неопределенности [22]. Как уже упоминалось ранее, условия для получения тех или иных свойств агломерата оказываются противоречащими друг другу.

Процесс автоматизирован, однако существующие системы управления процессом агломерации не позволяют обеспечить максимальной производительности агломашин и постоянства высокого качества выходного продукта — агломерата. Высокий уровень автоматизации современных технологических процессов и наличие в них большого количества контуров управления существенно затрудняют проведение диагностики нарушений, возникающих в контурах, из-за маскирующих эффектов обратных связей.

Опрос экспертов и анализ регламента позволил выделить ряд нарушений, с которыми система автоматизации не справляется. Как уже отмечалось выше, различные нарушения на процессе часто имеют сходные проявления, что приводит к несвоевременному обнаружению причин аварий обслуживающим персоналом и служит источником ошибочных решений по управлению процессом [4].

Колебания химического состава шихты могут вызывать нарушения, происходящие в ходе процесса спекания. Так отклонение содержания углерода в шихте от оптимального приводит к уменьшению выхода агломерата заданного качества. По данным, приведенным в работе [3], увеличение содержания углерода приводит к увеличению температуры в нижних слоях спекаемой шихты, что в сочетании с повышенным расходом топлива вызывает формирование расплавленного слоя агломерата, непроницаемого для газа. Данный факт приводит к увеличению расхода топлива и уменьшению длительности нагрева, что негативно влияет на восстановительные качества агломерата и скорость процесса [3]. При пониженном содержании углерода в шихте для выравнивания температуры вертикально по слою агломерата необходимо увеличивать длительность нагрева. Таким образом, нарушения, связанные с колебаниями содержания углерода в шихте возможно корректировать посредством изменения расхода топлива, но это вмешательство необходимо проводить на ранних этапах. Для этой цели необходимо как можно раньше определять массовую долю углерода в шихте.

По данным [23] внешними признаками, по которым можно судить о массовой доле углерода в шихте, являются:

- Длина раскальной поверхности агломерата после выхода из-под

зажигательного горна (при неизменном качестве коксика). При нормальной массовой доле углерода поверхность агломерата светится до 5 вакуум-камеры. Более короткая зона указывает на недостаток, а удлинённая зона до 6-7 вакуум-камер – на избыток углерода.

- Состояние зоны спекания, наблюдаемое при пробивании верхней корки агломерата над (5-6) вакуум-камерами. При избытке углерода шихта в зоне спекания чрезмерно размягчается и имеет ярко-белый цвет.

- Вид излома пирога агломерата на разгрузочном конце агломашин. При нормальной массовой доле углерода агломерат в изломе раскалён до $(1/4 - 1/3)$ высоты спёка, нет языков пламени догорающего углерода. При избытке топлива агломерат имеет ярко-белый цвет и раскалён до $(1/2 - 2/3)$ высоты спёка. Кроме того, у колосников появляется слой неспёкшейся шихты и при сходе агломерата со спекательных тележек синие языки пламени догорающего коксика, агломерат имеет крупные поры, сильно оплавлен. При недостатке массовой доли углерода в шихте в изломе пирога появляются бурые гнёзда неспёкшейся шихты и агломерат сходит со спекательных тележек почти тёмным с мелкими порами.

Поджиг шихты производится зажигательным горном, работающим на коксовом газе. В зависимости от температуры зажигания шихты изменяется внешний вид поверхности «пирога» [24]:

- При оптимальной температуре зажигания шихты поверхность «пирога» после охлаждения имеет чёрный цвет с металлическим отливом.

- При повышенной температуре зажигания поверхность «пирога» оплавлена, имеет повышенную прочность.

- При пониженной температуре зажигания поверхность «пирога» имеет рыжеватый цвет (неспёкшиеся кусочки руды) и пониженную прочность.

Указанные выше особенности проявления нарушений технологического процесса производства агломерата позволяют сформулировать задачу оперативного контроля процесса посредством использования оптико-электронных средств контроля (далее будет рассмотрено в пункте 3.3).

Количество топлива в шихте должно быть минимально необходимым для получения годного агломерата. Отсутствие возможности влияния на химический состав топлива и изменение топлива в шихте только корректировкой расхода топлива,

приводят к необходимости заранее предотвратить ситуации, которые могут привести к необходимости данной корректировки. Расход топлива увеличивается при увеличении доли флюсов вследствие расхода тепла на диссоциацию карбонатов кальция и магния, а преобладание низкокалорийного топлива приводит к получению выходного агломерата несоответствующего качества из-за низких температур в верхних слоях спекаемой шихты [25].

Отклонение соотношений сортов твёрдого топлива от заданных приводит к нарушению режима спекания, можно выделить следующие ситуации, причиной которых является преобладание высококалорийного топлива: снижение концентрации кислорода в аглогазе, повышение температуры у эксгаустера, повышение доли процессов восстановления, увеличение доли оксидов FeO в агломерате, а, следовательно, повышение прочности агломерата и уменьшение доли возврата.

На основании работы [25] можно выявить причины изменения расхода твёрдого топлива: это изменение характеристик самой шихты; изменение характеристик кокса; температура готового агломерата при разгрузке; химический состав готового агломерата.

1.4 Выводы. Постановка задачи исследования

На основании вышеприведенного описания процесса и обзора существующих систем диагностики можно сделать следующие выводы.

1. Из описания процесса следует, что процесс агломерации является сложным физико-химическим процессом с колебаниями химико-минералогического, гранулометрического состава компонентов шихты, условий ее увлажнения, дозирования, смешивания и укладки шихты на поверхность агломашины, характеристик топлива, режима зажигания и т.п. факторов. Все это приводит к тому, что процесс часто сопровождается достаточно большим числом возможных технологических нарушений, уменьшающих выход годного агломерата, увеличивающих количество возврата и снижающих, таким образом производительность агломашины. Оперативное управление процессом возложено на операторов, это не позволяет с большой степенью надежности обнаруживать возникающие нарушения на ранних стадиях их развития, что сопровождается материальными потерями, выходом продукта несоответствующего качества.

2. Процесс достаточно хорошо автоматизирован, однако, существующие системы управления процессом агломерации не позволяют обеспечить постоянство высокого качества выходного продукта. Связано это с тем, что возмущения, в основном, относятся к качественным характеристикам участвующих в процессе компонентов, которые прямо не измеряются.

3. Большое количество неизмеряемых факторов, влияющих на качество получаемого агломерата, привело к увеличению роли оперативного управления процессом с использованием методов искусственного интеллекта, в основном, экспертных систем. На эти системы, в основном, возлагались функции диагностики состояния процесса, обнаружения нарушений и сообщения о них операторам, ведущим процесс.

4. Обзор отечественных и зарубежных источников и анализ методов диагностики процесса агломерации показал, что большое количество работ ограничиваются фактом обнаружения нарушений без выявления вызвавших их причин. В литературе также отсутствует перечень основных нарушений на процессе и характер их проявления (симптомы).

5. Рассмотрены основные причины, приводящие к нарушениям на технологическом процессе, и проявления данных нарушений, в том числе влияющие на внешний вид спекаемого агломерата на разных этапах процесса.

Целью диссертационной работы является разработка структуры и алгоритма функционирования системы оперативного управления процессом производства железорудного агломерата на основе нейросетевой диагностической модели. Система должна обеспечивать раннее обнаружение нарушений и определение причин, их вызвавших.

На основании выводов и согласно поставленной цели можно сформулировать основные задачи, которые необходимо решить в процессе выполнения диссертационной работы:

1. Разработать структуру и алгоритм работы системы мониторинга и диагностики (как основной составляющей системы оперативного управления) процесса подготовки железорудного агломерата, которые будут удовлетворять требованиям обеспечения раннего обнаружения нарушений и их идентификации.

2. Из-за отсутствия возможности измерения в реальном времени некоторых внешних проявлений нарушений процесса (симптомов), разработать методики их выявления.

3. Провести анализ структур диагностических моделей, выбрать наиболее подходящие для процесса агломерации.

4. Провести сбор данных, обработать полученную информацию для идентификации модели, сформировать перечень возможных нарушений на процессе и их симптомов, составить их описание для имитационного моделирования.

5. Разработать алгоритм функционирования системы оперативного управления, обеспечивающий раннее обнаружение и диагностику нарушения. Провести тестирование предложенного алгоритма методом имитационного моделирования.

ГЛАВА 2 Структура системы оперативного управления

2.1 Структура типовой системы оперативного управления

Термин «Система оперативного управления» (СОУ) используется в отечественной литературе, в зарубежной – «Supervisory control system». СОУ фактически может быть на каждом уровне иерархии: на уровне АСУ ТП – СОУ технологическим процессом, на MES-уровне – СОУ производством.

Основные функции СОУ [26]:

- Производят контроль состояния и распределение ресурсов для обеспечения управления ресурсами производства (материалами, оборудованием) и другими объектами.
- Осуществляют собственно оперативное управление и краткосрочное планирование, основанное на характеристиках и свойствах конкретного вида продукции.
- Проводят текущий мониторинг процесса производства, отслеживание в режиме реального времени качества выполнения операций и выявление нарушений в ходе процесса.
- Обеспечивают контроль качества продукции на основании результатов мониторинга с заострением внимания на критических точках. Здесь могут быть предложены действия по исправлению ситуации в данной точке на основе анализа диагностической модели, построенной на основе учета корреляционных зависимостей и статистических данных, а также причинно-следственных связей контролируемых событий.

Как уже отмечалось в предыдущей главе, одними из основных функций системы оперативного управления являются функции мониторинга текущего состояния процесса и диагностики причин возникающих нарушений. Это хорошо видно при анализе типовой структуры СОУ (рисунок 2.1), разработанной фирмой Yokagawa и ставшей почти классической [27].



Рисунок 2.1 – Типовая структура СОУ

Система, выполняющая мониторинг и диагностику состояния технологического процесса неразрывно связана с системой управления качеством, кроме того, ее эффективная работа позволяет повысить надежность процесса, не допустить развития аварийных ситуаций, приводящих к срабатыванию систем противоаварийной защиты. Поэтому, как отмечалось во введении, основное внимание уделено разработке именно системы мониторинга и диагностики, как составной части системы оперативного управления процессом агломерации.

2.2 Требования к системе оперативного управления

В основу разрабатываемой системы заложена концепция, заключающаяся в раннем обнаружении нарушений в ходе процесса спекания агломерата, определения причин этих нарушений и выдачи рекомендаций оператору по способам их ликвидации, не допуская их развитие до порогов срабатывания блокировок системы защиты. Такая система, как уже отмечалось выше, позволит увеличить время для оперативных

действий по изменению хода процесса, переконфигурирования, обслуживания, также существенно повысит эффективность процесса, уменьшит число простоев и остановов на ремонт оборудования.

Расположение модуля оперативного управления, объединяющего функции модулей диагностики и мониторинга, в иерархии АСУ ТП представлено на рисунке 2.2 [28].



Рисунок 2.2 – Связь СОУ с другими подсистемами АСУ ТП

Система диагностики состоит из двух основных подсистем: подсистемы мониторинга и подсистемы собственно диагностики. Функции подсистемы мониторинга заключаются в получении данных о процессе (обычно из SCADA-системы), преобразовании полученных значений переменных в диагностические показатели (если требуется), на основании которых происходит обнаружение нарушения. После обнаружения факта возникновения нарушения начинает работу подсистема диагностики, которая локализует данное нарушение и определяет его причины с последующей выдачей оператору рекомендаций по их устранению.

Снижение влияния человеческого фактора на управление технологическим процессом представляется важной задачей ввиду сложности процессов, в том числе металлургических. Оператор на аглофабрике, зачастую, поставлен в режим нехватки времени для принятия правильных решений по устранению причин, вызвавших

нарушение, до перехода процесса в предаварийную зону. Также возможны случаи отсутствия достаточного опыта у операторского персонала для принятия взвешенных решений. Работа системы диагностики в режиме «Советчик» позволяет обеспечить помощь оператору в сложных ситуациях, связанных с нарушениями на процессе, посредством выдачи советов и рекомендаций, основанных на знаниях опытных экспертов [29].

Диагноз строится на основании информации, получаемой с контролируемого процесса. Однако на практике система редко обладает полной информацией обо всех переменных процесса, в том числе из-за отсутствия необходимого числа датчиков на процессе. Поэтому необходимо привлекать дополнительную информацию: качественные характеристики процесса, определяемые операторами; результаты лабораторных исследований; данные о поверках оборудования. Также необходимы новые методы для определения тех или иных переменных процесса, определения проявлений (симптомов) и причин нарушений.

Система диагностики начинает работу в области между регламентными пределами и аварийными значениями. Для чего в этой области устанавливается эксплуатационный порог, превышение которого предупреждает оператора о возможном появлении и развитии нарушений в ходе процесса. Задача системы диагностики – обнаружение возможного нарушения в зоне между эксплуатационным и аварийным порогами, не допуская развития ситуации до перехода ее в аварийную зону [30].

Сформулируем основные требования, которым должна удовлетворять разрабатываемая система оперативного управления системы подготовки агломерата.

Система должна обеспечивать раннее обнаружение нарушений хода процесса. Данное требование является обязательным, т.к. при раннем обнаружении нарушения, в большинстве случаев ещё имеется возможность вернуть ход процесса в регламентные рамки; также оператор получает определённое количество времени для выполнения мероприятий по предотвращению развития аварийной ситуации, и, таким образом, может предотвратить развитие ситуации до порога срабатывания блокировок системы защиты.

Подсистема мониторинга должна определять сам факт нарушения, а подсистема диагностики, в свою очередь, должна идентифицировать нарушение, т.е. выяснять причину, вызвавшую нарушение. Если нарушение не было учтено при построении

диагностической модели в силу неполноты информации о процессе, необходимо, чтобы система определяла данное нарушение как новое, выдавала определённую полезную информацию оператору.

Большое значение имеет способность системы диагностировать множественные нарушения; различать нарушения, имеющие некоторые одинаковые симптомы, т.е. должна быть обеспечена высокая степень глубины диагностики.

Также необходимо, чтобы система была робастна по отношению к шумам, которые всегда присутствуют в промышленных условиях, при этом не допускать пропуски или позднее обнаружение нарушений.

Система должна выдавать рекомендации оператору для принятия решений по предотвращению аварийных ситуации при развитии нарушений на процессе.

2.3 Обзор систем диагностики

В литературе приведено множество различных классификаций систем диагностики. В настоящей работе обзор возможных реализаций систем диагностики проводится в соответствии с работой [31]. Выделяют три подхода к построению систем диагностики и соответствующие им следующие типы диагностических моделей (рисунок 2.3): модели, использующие качественные соотношения между параметрами объекта (графы причинно-следственных связей, деревья отказов и т.п.); модели на основе аналитических знаний (построенные на количественных соотношениях – детерминированные модели (феноменологические или балансовые), различные фильтры-наблюдателей (observes), часто - фильтры Калмана и др.); модели на основе данных с процесса – массивах из значений переменных процесса, накопленных за какой-то период его функционирования [31].

Диагностические модели – это модели, описывающие аномальное состояние процесса, нештатные ситуации на процессе; они связывают наблюдаемые характеристики процесса (диагностические показатели) с причинами, вызвавшими отклонение процесса от регламентных значений.

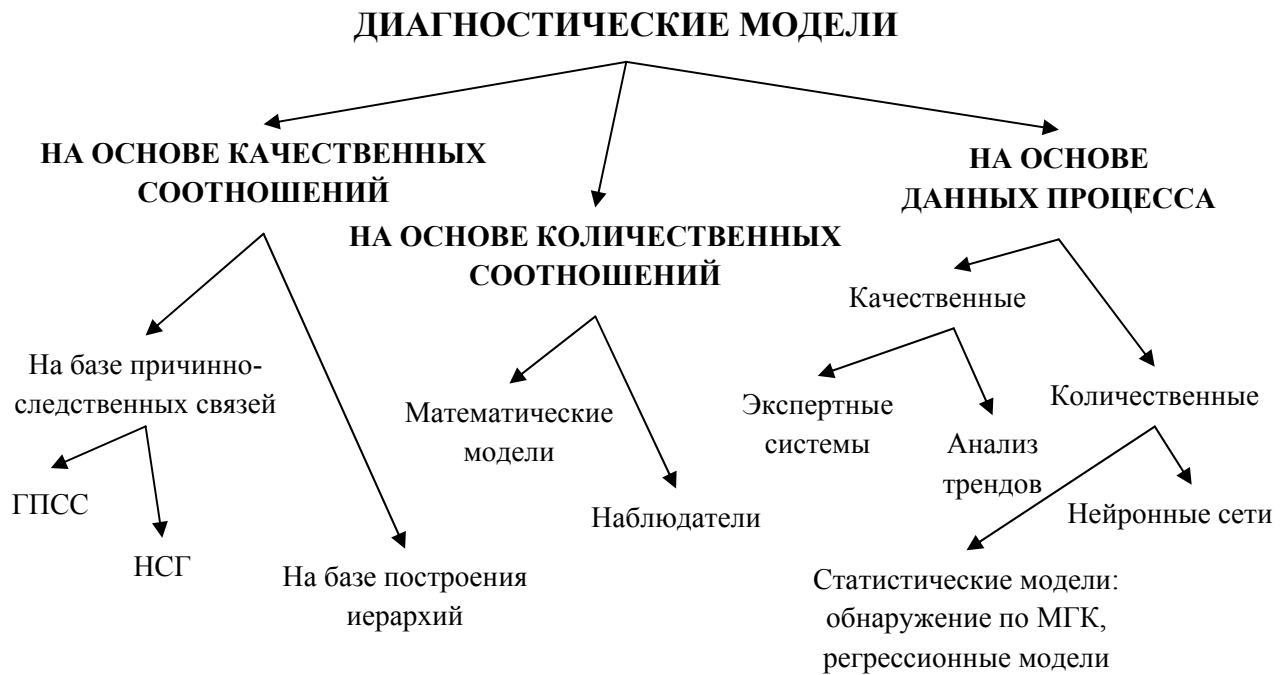


Рисунок 2.3 – Классификация диагностических моделей

2.3.1 Подход на основе качественных соотношений

Для систем большой размерности и сложности математические описания могут быть не всегда доступны в силу различных причин, в том числе ввиду необходимости больших временных и материальных затрат для их получения. Альтернативным решением является использование моделей, основанных на качественных соотношениях, таких как причинно-следственный анализ, построение направленных графов или деревьев отказов. Данный подход не требует использования сложных вычислительных операций, учитывает выходы переменных процесса за границы нормальных состояний.

Подходы, основанные на причинно-следственном анализе, используют выделенные при анализе причинно-следственные связи «нарушение-симптом». Примером данного подхода является направленный сигнальный граф (НСГ) [32]. НСГ представляет траектории причинно-следственных связей на ТП, при этом переменные и параметры процесса являются вершинами графа, а причинно-следственные связи – дугами между вершинами. Направленные дуги идут от вершины «Причина» к вершине «Следствие», имеют знак «+» или «-». Выбирая какую-либо вершину как корневую и считая, что в этой вершине произошло нарушение, можно, назначив его вид («+» или

«←») и следуя определенному алгоритму обработки графа, получить сценарий развития этого нарушения и определить его проявления (симптомы) [32]. Достоинством НСГ является тот факт, что все возможные вершины могут быть использованы для объяснения нарушений на процессе. Тем не менее, формирование НСГ на больших процессах, каким является процесс агломерации, является достаточно трудоёмкой задачей. Метод очень полезен для верификации экспертной информации при построении экспертных диагностических систем [33]. Используя НСГ, можно получить симптомы, задав возможные нарушения, и сравнить их с указными экспертами симптомами [34].

Граф причинно-следственных связей (ГПСС) можно рассматривать как частный случай НСГ. В ГПСС отсутствуют вершины, связанные с нормальной работой процесса, т.к. ГПСС содержит только вершины, соответствующие причинам, вызвавшим нештатные ситуации.

Дерево отказов очень сходно с ГПСС, представляет собой граф, связывающий нарушения с их симптомами, ранее использовалось при оценке рисков и анализе надежности систем.

Подход особенно приложим для систем, где точные математические модели отсутствуют, также эффективен, как упоминалось выше, как вспомогательный при проверке знаний, полученных от экспертов. Данный подход является качественным, отсутствие количественной информации снижает использование данного метода в диагностике. Были попытки увеличить область использования качественных моделей путём применения комбинированного метода с введением в качественные модели количественной информации. Так, на основе НСГ может быть построена производственная модель с последующим использованием в экспертной системе [35, 36].

Модели качественных соотношений визуально очень наглядны, для их построения необходимо знание процесса. Они наиболее применимы для анализа поведения процесса и отслеживания развития нарушений на процессе; чаще используются в режиме офф-лайн. В силу данных причин, данный подход редко используется в основе систем диагностики на объектах в режиме реального времени.

2.3.2 Подход на основе количественных соотношений

Подход на основе количественных соотношений представлен двумя группами методов: с использованием детерминированных моделей и с использованием различных фильтров-наблюдателей (observers) [31]. Детерминированные модели, в свою очередь, подразделяют на феноменологические (основываются на физических или химических законах изучаемых явлений, происходящих в ТП) и модели на основе балансовых уравнений.

Феноменологические модели довольно полно описывают процесс, имеют высокое качество прогнозирования, параметры данных моделей имеют определённый физический смысл, что является важным достоинством при диагностике. Но на фоне явных преимуществ, феноменологические модели имеют ряд недостатков, из-за которых редко используются в управлении и диагностике процесса. Это - трудности работы с данными моделями в режиме реального времени из-за их сложности, большое количество допущений, принятых при их синтезе [31]. Также необходимо отметить, что данные модели обычно описывают нормальное состояние процесса и плохо работают в аномальных его состояниях. Есть сложности при описании нелинейных процессов. Все это делает их непригодными для применения для диагностики процесса агломерации.

При работе с моделями на основе балансовых уравнений, по данным моделям выделяют нарушения по балансам: при нормальной работе невязки равны «0», при нарушениях предполагается, что равенство не выполняется. Не все нарушения возможно выявить по балансовым уравнениям, так нарушения, влияющие на качественные характеристики продукта, не затрагивая количественные, не всегда определяются посредством балансовых уравнений. Поэтому данный метод чаще используется как дополнительный совместно с другими методами диагностики [31, 37, 38].

Еще один класс диагностических моделей, формируемых при данном подходе, это модели на основе фильтров (в англоязычной литературе их часто называют наблюдателями, observers) [31]. Обычно фильтры следят за отклонениями той или иной переменной состояния процесса. Значение контролируемой переменной рассчитывается на основе невязки измерений \bar{y} , получаемых с датчиков процесса, и значений параметров, оцененных фильтром-наблюдателем. Разница между измеренными и

расчётными выходами используется в качестве вектора невязок и описывается формулой (1):

$$\boldsymbol{\varepsilon}_k = (\bar{\mathbf{y}} - \mathbf{y}_k), \quad (1)$$

Далее невязка умножается на рассчитанную матрицу усиления фильтра \mathbf{K}_k и полученное значение используется для корректировки старого значения параметра состояния:

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_k) + \mathbf{K}_k \cdot \boldsymbol{\varepsilon}_k \quad (2)$$

$$\mathbf{y}_k = \mathbf{h}(\mathbf{x}_k) \quad (3)$$

Из всех существующих способов выбора матрицы усиления наиболее часто применяется метод минимизации квадрата невязок, т.е. метод минимизации суммы среднего квадратичного отклонения модели процесса от выхода реального объекта (4).

$$J = \lim_{t \rightarrow \infty} E(\boldsymbol{\varepsilon}_t^T \cdot \boldsymbol{\varepsilon}_t) \quad (4)$$

Сигналом о возникновении нарушения служит отклонение невязки от нулевого значения.

Из фильтров-наблюдателей для диагностики наиболее часто используется фильтр Калмана, который позволяет оценивать в реальном времени параметры состояния объекта [39, 40]. Фильтр Калмана – это рекуррентная система оценки параметров, когда данные обрабатываются последовательно во времени по мере поступления выборочных значений. Классический фильтр Калмана работает с линейными объектами, описываемыми системой уравнений вида:

$$\mathbf{x}(\mathbf{k} + 1) = \mathbf{A} \cdot \mathbf{x}(\mathbf{k}) + \mathbf{B} \cdot \mathbf{u}(\mathbf{k}) + n \quad (5)$$

$$\mathbf{y}(\mathbf{k} + 1) = \mathbf{C} \cdot \mathbf{x}(\mathbf{k}) + w \quad (6)$$

где $\mathbf{x}(k)$, $\mathbf{y}(k)$, $\mathbf{u}(k)$ - векторы параметров состояния, выходных и входных переменных соответственно на k -том шаге (в k -тый момент времени), \mathbf{A} , \mathbf{B} , \mathbf{C} - известные матрицы предсказания, управления и наблюдения, \mathbf{n} , \mathbf{w} - шумы.

Фильтр вычисляет по уточненной (апостериорной, отмечена верхним индексом $+$) оценке вектора состояний на $(k-1)$ -шаге его предварительную (априорную, отмечена верхним индексом $-$) оценку на k -том шаге:

$$\mathbf{x}_k^+ = \mathbf{x}_k^- + \mathbf{K}_k \cdot \boldsymbol{\varepsilon}_k \quad (7)$$

$$\boldsymbol{\varepsilon}_k = \bar{\mathbf{y}}_k - \mathbf{y}_k \quad (8)$$

$$\mathbf{y}_k = \mathbf{C} \cdot \mathbf{x}_k^- \quad (9)$$

где $\boldsymbol{\varepsilon}_k$ - разность выхода фильтра \mathbf{y}_k и измеренного вектора выходных переменных объекта $\bar{\mathbf{y}}_k$, т.е. уточненное значение вектора состояния вычисляется добавкой к априорному величине, пропорциональной текущей невязке; \mathbf{C} - матрица наблюдения, связывает вектор измерений и вектор состояния. При этом \mathbf{K}_k - матрица усиления фильтра:

$$\mathbf{K}_k = \mathbf{P}_k^- \cdot \mathbf{C}^T \cdot [\mathbf{S}_k]^{-1} \quad (10)$$

где \mathbf{P}_k^- , \mathbf{S}_k - априорные оценки корреляционных матриц.

$$\mathbf{P}_k^- = \mathbf{A} \cdot \mathbf{P}_{k-1}^+ \cdot \mathbf{A}^T + \mathbf{Q}_k \quad (11)$$

где \mathbf{P}_{k-1}^+ - апостериорная ковариационная матрица, оцененная на предыдущем $k-1$ шаге; \mathbf{Q}_k - ковариационная матрица случайного характера эволюции, которая интерпретирует дисперсии погрешности вектора прогнозируемой оценки; матрица \mathbf{A} описывает переходный процесс системы.

$$\mathbf{S}_k = \mathbf{C} \cdot \mathbf{P}_k^- \cdot \mathbf{C}^T + \mathbf{R}_k \quad (12)$$

где \mathbf{R}_k - ковариационная матрица, по диагонали которой расположены дисперсии шумов измерения с датчиков.

Новая апостериорная ковариационная матрица может быть вычислена из уравнения Риккати:

$$\mathbf{P}_k^+ = \{\mathbf{I} - \mathbf{K}_k \cdot \mathbf{C}\} \cdot \mathbf{P}_k^- \quad (13)$$

Для нелинейных объектов, описываемых системой уравнений вида:

$$\begin{aligned} \mathbf{x}(k) &\approx \mathbf{f}(\mathbf{x}(k-1), \mathbf{u}(k-1)) \\ \mathbf{y}(k) &\approx \mathbf{h}(\mathbf{x}(k-1), \mathbf{u}(k-1)) \end{aligned} \quad (14)$$

где $\mathbf{f}(\mathbf{x}, \mathbf{u})$ и $\mathbf{h}(\mathbf{x}, \mathbf{u})$ - нелинейные функции, используются нелинейные модификации фильтров Калмана, например, расширенный фильтр Калмана. При этом значительно усложняются вычислительные процедуры, появляется необходимость контроля устойчивости работы фильтров [41, 42].

Использование фильтров Калмана не исключает необходимости иметь математическое описание объекта в качестве «внутренней модели» фильтра. Кроме того, при использовании фильтров для диагностики нарушений требуется организовывать банк фильтров, каждый из которых настраивается предварительно на свое нарушение [43-45].

2.3.3 Подход, использующий массивы данных с процесса

В отличие от вышерассмотренных подходов к построению систем диагностики, при использовании которых необходимы либо количественные, либо качественные априорные знания о процессе, в рассматриваемом подходе необходимо лишь большое количество зафиксированных данных с процесса. Именно по этой причине этот подход получил широкое распространение на практике. Существуют различные пути по преобразованию и представлению данных с процесса в качестве априорной информации для системы диагностики. Существуют два метода, которые основаны на использовании качественной (в смысле, неколичественной) информации о процессе: экспертные системы и анализ трендов.

Экспертная система – система, которая использует человеческий опыт для поддержки принятия решений. Экспертные системы особенно удобны для он-лайн диагностики ввиду использования экспертных, как правило, эмпирических и

основанных на правилах знаний о ситуациях, причем результатом работы системы может быть не только диагноз, но и рекомендации по устранению нештатных ситуаций [46].

Для формирования базы знаний ЭС необходимые знания о поведении контролируемого процесса, о возможных нарушениях получают от опытных экспертов, владеющих навыками работы на процессе. Как правило, полученные знания эксперт выдает в вербальной форме. Очень часто они носят качественный, в значительной степени неопределённый характер.

ЭС имеют большое распространение в диагностических системах ввиду ряда явных преимуществ: относительная простота разработки, получение довольно достоверных результатов, прозрачность вывода [47, 48]. Однако, существуют ограничения для использования ЭС [49]:

- По мере увеличения базы знаний модуль логического вывода, возможно, не сможет принять решение своевременно.
- Большинство экспертных систем довольно специфичны и, как правило, разработаны для индивидуального применения, не являются широко применимыми.
- Сбор данных от экспертов и последующее их представление является довольно трудоёмкой задачей ввиду довольно больших неопределённостей и сложности поиска экспертов, знающих досконально контролируемый процесс.

Для преодоления вышеуказанных ограничений перспективным решением является интеграция экспертных систем с другими подходами, такими как нечеткая логика, нейронные сети, методы распознавания образов, которые описаны в следующих источниках: [49-51].

Вторым подходом этого класса является анализ трендов. Данный подход используется для объяснения различных ситуаций, происходящих на процессе, диагностики неисправностей и прогнозирования будущих состояний. С процедурной точки зрения, для того, чтобы получить сигнальный тренд не слишком восприимчивый к мгновенным изменениям из-за шума, необходимо проводить фильтрацию. Для этого можно использовать фильтр (например, фильтр экспоненциального сглаживания) с предварительно выбранным коэффициентом сглаживания фильтра. Однако по трендам не всегда можно отличить реальную неисправность от неустановившегося состояния. [31]. Чтобы обойти данную проблему, необходимо рассматривать тренд в разных

временных масштабах. Для задач диагностики анализ трендов часто дает существенную информацию, которая облегчает понимание поведения процесса.

Карты Шухарта являются примером реализации метода анализа трендов [52, 53]. Они довольно часто применяются на реальных процессах, но вместе с тем имеют ряд недостатков, ограничивающих их применение. Так необходимо искусственно завышать пороги для уменьшения ложных срабатываний на объектах с большой длительностью переходных процессов. Также затруднительны построение и обработка карт Шухарта на процессе с большим количеством изменяющихся во времени параметров, каким, например, является процесс агломерации. В этом случае одномерный контроль нескольких переменных, т.е. построение для каждой переменной карты Шухарта, приводит к резкому увеличению ошибок, особенно ложных тревог, т.к. не учитывается корреляция между переменными [54, 55]. В таких случаях целесообразнее использовать многомерные карты Шухарта.

Идея большинства многомерных контрольных карт сводится к использованию той или иной меры расстояния до центральной точки процесса, определяемой координатами вектора с номинальными значениями переменных. При этом устанавливается всего одно пороговое значение, превышение которого будет означать наличие нарушения. В многомерных картах (типа карт Шухарта) используется статистика Хотеллинга:

$$T^2 = n(\bar{x} - \mu_0)^T S^{-1}(\bar{x} - \mu_0) \quad (15)$$

где n , \bar{x} - объем и среднее выборки, по которой производится контроль, μ_0 - желаемое значение, S - ковариационная матрица. Статистика T^2 фактически представляет собой расстояние Махаланобиса от средней точки текущей выборки до точки с номинальными значениями параметров процесса.

Сложности при использовании такого вида мониторинга резко возрастают с ростом размерности объекта, поэтому целесообразно применить статистические методы, способные сократить размерность модели процесса при сохранении необходимой информации о нем. К таким методам относится, прежде всего, метод главных компонент (МГК, в английской терминологии – PCA) [56].

МГК основан на ортогональном разложении ковариационной матрицы переменных процесса по направлениям, которые "объясняют" максимальное изменение

дисперсии данных. Метод использует разложение исходного массива данных процесса по собственным векторам ковариационной матрицы исходных данных на две ортогональные матрицы: матрицу нагрузок (она же матрица главных компонент) и матрицу счетов (проекций исходных переменных на главные компоненты). Хотя число главных компонент (principal components - PC) равно числу исходных переменных (предполагается, что число измерений в массиве превышает число переменных), но т.к. остаточная дисперсия после первых нескольких PC становится очень малой (например, 5% от исходной), то в модели ограничиваются этим числом PC, считая остальные образованными шумом. Этим объясняется снижение размерности исходных данных практически без информационных потерь. Это - основное достоинство метода.

Таким образом, если некоторые из переменных в наборе данных являются коррелированными, то потребуется существенно меньшее число главных компонент q для объяснения большей части дисперсии в данных. При этом часть дисперсии, оставшаяся необъясненной главными компонентами PC, попадает в подпространство невязок, которое, как было отмечено выше, связывается с шумом процесса или аппаратуры.

Для мониторинга в пространстве главных компонент используются две статистики. Статистика T^2 (аналогична статистике Хотеллинга) позволяет обнаружить нарушения, учтенные моделью МГК, а статистика Q , представляющая собой квадрат невязок модели, вызванных в том числе из-за отбрасывания в модели при сокращении размерности главных компонент высоких порядков, обнаруживает нарушения, неучтенные моделью МГК.

МГК способен работать в нелинейных системах, что достигается за счет применения различных его модификаций, в частности керн-МГК [57, 58].

Значительным недостатком метода является потеря физического смысла для главных компонент. Кроме того, метод эффективно работает при мониторинге процесса, т.к. для обнаружения нарушения требуется контролировать всего две статистики T^2 и Q , однако идентификация причин нарушений с помощью МГК затруднительна. На практике метод широко используется в системах диагностики в сочетании с другими моделями только для сокращения размерности и обнаружения нарушений, а диагностика производится системами, базирующимися на таких моделях, как экспертные или нейросетевые [46, 59].

В последние годы интерес к нейронным сетям при решении задач диагностики значительно возрос. Нейронная сеть – это параллельная распределенная информационная структура, состоящая из обрабатывающих информацию элементов (нейронов), соединенных между собой сигнальными связями. Каждый нейрон имеет один выход, который может разветвляться и соединять его с любым числом других элементов сети. Выходной сигнал нейрона может быть любой формы, обработка данных внутри элемента задается произвольно, а результат зависит от текущих значений сигналов, подаваемых на вход [60].

Нейронные сети используются для задач классификации и аппроксимации функции. При использовании НС для распознавания определённого нарушения необходимо иметь хорошо структурированные данные, включающие максимальное число возможных нарушений. Общее нелинейное поведение нейронной сети определяется выбором топологии сети, функциями активации нейронов и весами связей между нейронами. Нейронные сети можно классифицировать по двум признакам: архитектура сети и по способу обучения сети.

НС способны диагностировать множественные нарушения без априорного знания математической модели. Нейронные сети используются в системах диагностики в промышленных процессах. Например, в работе [61] описана адаптивная гибридная система, построенная на априорных знаниях и нейронных сетях для моделирования стратегий управления процессом с неопределёнными параметрами в сильно нелинейном реакторе с постоянным перемешиванием в четырёхстадийной флотационной установке. В работе [62] представлено применение нейронных сетей для моделирования процесса стеклования, также нелинейного, где происходит процесс инкапсулирования высокоактивных жидких отходов в стекло для обеспечения безопасного и удобного способа хранения. Нейросетевая модель также применялась для определения отказов реактора, используемого в том же стеклоплавильном процессе. В [63] адаптировали нейронные сети для нелинейного процесса оценки и управления химической реакцией с выделением тепла. В [64] представлена разработка архитектуры робастной нейросетевой модели управления с прогнозированием. В работе [65] описана двухступенчатая система оперативного управления на основе нарушений с использованием нейронных сетей. Система определения нарушения была реализована для идентификации точного

местоположения нарушения и их диагностики на опытной экспериментальной установке.

Нейросетевой подход более подробно будет рассмотрен далее.

В таблице 1.1 [31] приведены сравнительные характеристики некоторых диагностических моделей, на основе данного сравнения можно сделать вывод, что ни один из приведённых методов не является универсальным.

Таблица 1.1 – Сравнение возможностей СД на базе типовых диагностических моделей

Характеристика \ Тип ДМ	Фильтры	Графы	ЭС	Карты	МГК	НС
Раннее обнаружение и диагноз	Да	?	Да	Да	Да	Да
Локализация	Да	Нет	Да	Да	Да	Да
Робастность	Да	Да	Да	Да	Да	Да
Идентификация неучтенных нарушений	?	Да	Нет	?	Да	Да
Адаптивность	Нет	Да	Нет	?	Нет	Нет
Способность к объяснению	Нет	Да	Да	Да	Нет	Нет
Объемы вычислений	Да	?	Да	Да	Да	Да
Определение множественных нарушений	Да	Да	Да	Нет	Нет	Да

При этом необходимо отметить, что в промышленности наиболее часто используются методы, основанные на обработке выборок данных, полученных с датчиков, установленных на контролируемом процессе, и на результатах лабораторных и иных анализов. Это объясняется отсутствием в большинстве случаев математических описаний сложных, трудно формализуемых технологических процессов, которые в большинстве случаев нелинейны. Эти ограничения применимы к процессу агломерации.

Методы, использующие графы, применяются чаще на этапе анализа процессов при их проектировании или при оценке их безопасности.

Следует отметить, что процесс агломерации отличается высоким уровнем неопределенностей, большими неконтролируемыми возмущениями (например, из-за разброса параметров исходного сырья), существенной внутренней нелинейностью.

Использование экспертных систем для решения задач диагностики нарушений часто неэффективно из-за маскировки многих нарушений работой системы

регулирования. Кроме того, возникают проблемы с назначением пороговых значений диагностических параметров в условной части правил, весовых коэффициентов и порогов для работы критериев близости и т.д. В то же время от таких проблем свободен нейросетевой подход, который особенно приложим для процессов, имеющих слишком сложные точные математические модели либо их получение слишком трудоемко. Недостатком этого подхода является трудность идентификации новых ситуаций, которые не были учтены в обучающем массиве или для которых не было предусмотрено выходного нейрона в структуре сети. Другими недостатками являются трудности с множественными нарушениями, недопустимые времена обучения и т.п. Однако эти недостатки относительно легко преодолеваются. Поэтому НС было решено использовать для нелинейного процесса агломерации.

2.4 Диагностические нейросетевые модели

В последние несколько лет резко возрос интерес к нейронным сетям [66], они находят успешное применение в самых разных областях. Нейронные сети вошли в практику везде, где нужно решать задачи прогнозирования, классификации или распознавания, поскольку они применимы практически в любой ситуации, когда имеется связь между входными и выходными переменными, даже если эта связь имеет сложную природу и ее трудно выразить в обычных терминах.

Нейронные сети нелинейны по своей природе и представляют собой мощный метод моделирования, позволяющий воспроизводить чрезвычайно сложные зависимости. На протяжении многих лет в качестве основного метода в большинстве областей используется линейное моделирование, поскольку для него хорошо разработаны процедуры оптимизации. Там, где линейная аппроксимация неудовлетворительна и линейные модели работают плохо, а таких задач достаточно много, основным инструментом являются нейросетевые методы [31].

Нейросетевой метод моделирования применяется тогда, когда неизвестен точный вид связей между входами и выходами. Слои связаны так, что сигнал с входов может распространяться через сеть и достигать выходов. Поведение нейронных сетей детерминировано в соответствии с функциями преобразования нейронов, топологией

сети, видом соединения слоев. Среди всех форм нейронных сетей наиболее популярна сеть прямого распространения (многослойный персептрон) [60, 66-67].

Этот тип сетей состоит из нескольких слоев нейронов. Нейроны первого слоя (входного) не производят никакой обработки входной информации, а только распределяют сигналы, поданные на вход сети, между нейронами следующего слоя. Функция активации у них линейная. Нейроны выходного слоя могут быть как линейными, так и нелинейными. Фактически сеть общается с внешним окружением только через нейроны этих двух крайних слоев.

Основная обработка информации производится нейронами скрытых слоев с нелинейными функциями активации, не имеющих связей с внешним окружением сети. Внутри слоев соединения между нейронами не разрешены, и поток информации идет только в одном направлении. В качестве функции активации для нейронов скрытых слоев обычно выбираются различные виды сигмоидных функций (собственно сигмоида, гиперболический тангенс и т.п.). Настраиваемыми параметрами сети являются синаптические (весовые) коэффициенты, на которые умножаются сигналы, поступающие на входы нейрона с нейронов предыдущего слоя.

Показано, что этот многослойный персептрон может достаточно хорошо аппроксимировать любое функциональное (взаимооднозначное или «много переменное») непрерывное отображение от одного пространства конечной размерности на другое, если число скрытых слоев и число нейронов в этих слоях достаточно велико [68].

Нейронные сети могут быть применены для обнаружения нарушений и диагностики в качестве модели процесса или классификатора образов. Нейронные сети для обнаружения нарушений и диагностики могут быть сгруппированы в три категории [69-72], как показано на рисунке 2.4.

Первая группа (рисунок 2.4 а) использует нейронную сеть для разделения по классам различных образов нарушений от нормального состояния процесса согласно измеренным выходным данным процесса. Обучение нейронных сетей может быть как в режиме off-line (с учителем), так и в реальном времени. Естественно, первый вариант предпочтительнее, так позволяет сразу обучить сеть распознавать все известные нарушения, которые могут произойти на данном процессе.

Во второй группе нейронные сети используются как классификаторы, обнаруживающие нарушения, представленные разностями (невязками) между выходами процесса и модели. Модель процесса может быть математической (рисунок 2.4 б), основываясь на которой облегчается выполнение и обучение нейронного классификатора. В случаях, когда математические модели процесса не доступны, для получения невязок может использоваться нейронная модель процесса (рисунок 2.4 в), а другая сеть – для обнаружения нарушений.

Процедура обучения нейронной сети использует ошибку в значениях выходов для модификации весовых коэффициентов, пока не будет достигнута ошибка в пределах допустимого уровня. Время обучения для сети прямого распространения, использующей одну из вариаций алгоритма обратного распространения, может быть достаточно велико. Для простой системы с двумя входами и двумя выходами при 50 обучающих выборках 100000 итераций не является исключением [73]. Для крупномасштабных систем, память и время обучения нейронной сети может превышать допустимые пределы. Это было узким местом при разработке алгоритмов диагностики нарушений в промышленных приложениях.

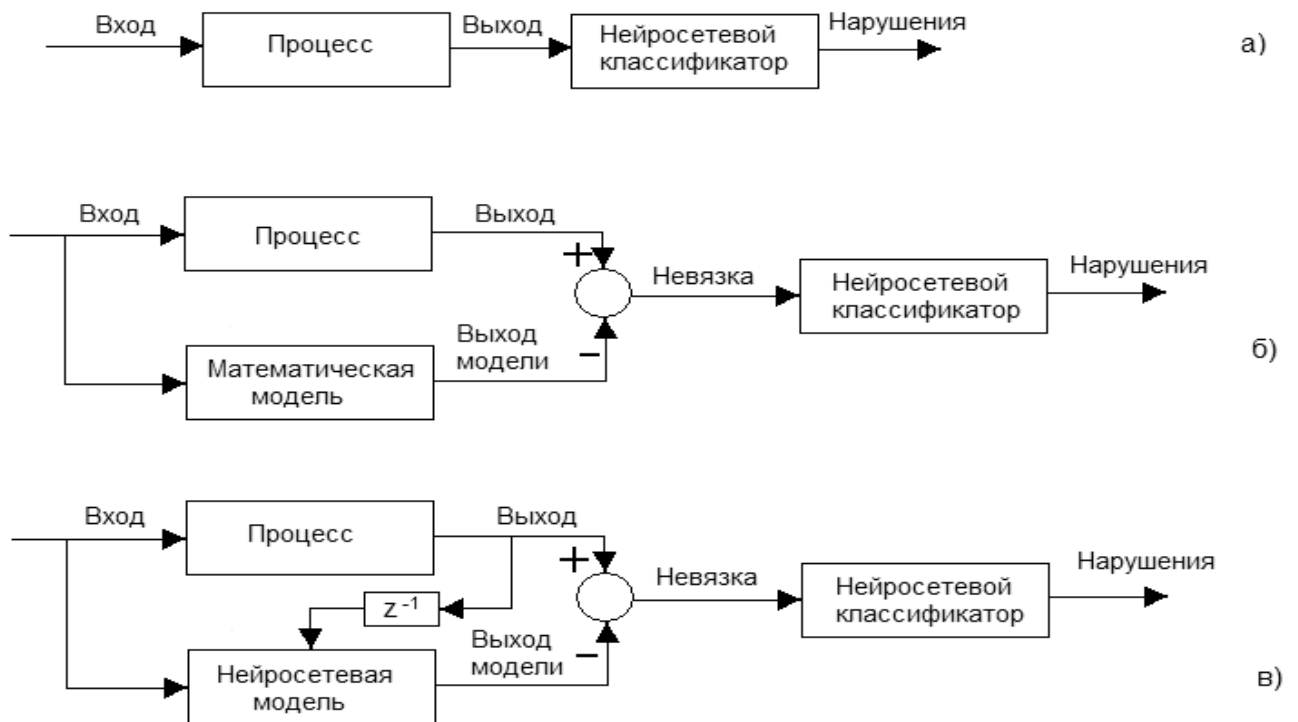


Рисунок 2.4 – Различные способы использования нейронных сетей для обнаружения и диагностики нарушений

Различают алгоритмы обучения с учителем и без учителя. Обучение с учителем предполагает, что для каждого входного вектора существует целевой вектор, представляющий собой требуемый выход. Вместе они называются обучающей парой. Сеть обучается на некотором числе таких обучающих пар, образующих обучающий массив. В процессе обучения на вход сети подается входной вектор пары, вычисляется выход сети и сравнивается с соответствующим целевым вектором. Веса изменяются в соответствии с алгоритмом обучения, стремящимся минимизировать ошибку. Векторы обучающего массива предъявляются последовательно, каждый раз вычисляются ошибки и веса подстраиваются для каждого вектора до тех пор, пока средняя ошибка по всему обучающему массиву не достигнет приемлемо низкого уровня.

Таким образом, целью обучения является минимизация функции ошибок на данном массиве примеров путем выбора значений весов W . Достижение минимума называется сходимостью процесса обучения. Поскольку ошибка зависит от весов нелинейно, то получить решение в аналитической форме невозможно, и поиск глобального минимума осуществляется посредством итерационного процесса реализуемого обучающим алгоритмом. Разработано уже более сотни разных обучающих алгоритмов, отличающихся друг от друга стратегией оптимизации и критерием ошибок [74].

Подобно другим управляемым данными методам, качество работы нейронных сетей определяется доступными данными. Высока вероятность того, что нейронные сети сгенерируют непредсказуемый выход, если на входы попадет сигнал из диапазона не представленного в обучающем массиве. Это предполагает необходимость повторного обучения нейронных сетей, если произойдут небольшие изменения в нормальных условиях работы установки, что является существенным недостатком в связи с тем, что пока нейронные сети обучаются в режиме офф-лайн, система не работает. Однако, на периодических процессах из-за использования общего оборудования для получения нескольких продуктов и изменчивости операций от цикла к циклу рабочие области редко постоянны. Это требует довольно частой интерактивной подстройки нейронной сетевой модели процесса и классификатора нарушений, что усложняет работу обслуживающего персонала, отвечающего за подстройки сети.

2.4.1 Виды нейронных сетей

Уравнение нейрона имеет вид:

$$y_i = w_{0i} + \sum_{l=1}^p w_{li} f_l(\mathbf{X}), \quad (i = 1, 2, \dots, m), \quad (16)$$

где $\mathbf{X} = (x_1, x_2, \dots, x_n)^T$ - входной вектор; w_{li} - веса связей, ($l = 1, 2, \dots, p, i = 1, 2, \dots, m$); w_{0i} - смещение для i -ого нейрона.

По архитектуре связей НС могут быть сгруппированы в два класса: сети прямого распространения, в которых граф, характеризующий сеть, не имеет петель обратной связи: однослойный персептрон, многослойный персептрон, RBF-сеть, и рекуррентные сети (сети с обратными связями): соревновательные сети, сеть Кохонена, сеть Хопфилда, модели ART, персептрон с обратными связями.

По результатам аналитического обзора наиболее перспективными структурами для решения задач диагностики являются сети прямого распространения. Именно они будут рассмотрены более подробно.

В сетях прямого распространения сигналы проходят от входов через скрытые нейроны на выходные. Такая сеть не имеет обратных связей. Эти сети имеют входной слой с линейными функциями активации нейронов, один или более скрытых слоев нейронов с нелинейными, например, сигмоидными функциями активации, и выходной слой с нейронами с линейными или нелинейными функциями активации. Сети с такой архитектурой могут воспроизводить весьма сложные нелинейные зависимости между входом и выходом сети. Они могут достаточно точно воспроизводить любую функцию, если задать достаточное число нейронов скрытого слоя.

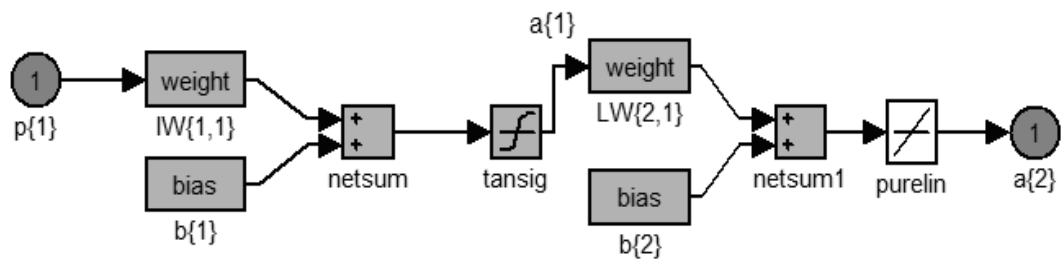
Возможности соединения нейронов в сети практически не ограничены, но обычно для каждой конкретной модели сети указывается тип допустимых связей. Каждая связь определяется тремя параметрами: элементом, от которого исходит данная связь; элементом, к которому данная связь направлена; и весовым коэффициентом. Структура связей представляется в виде весовой матрицы W , в которой каждый элемент w_{ij} представляет величину весового коэффициента связи, идущей от элемента i к элементу j . Для описания структуры связей может использоваться не одна, а несколько

весовых матриц, так как элементы сети сгруппированы в слои. Общий вид весовой матрицы:

$$W = \begin{bmatrix} W_{11} & W_{12} & \dots & \dots & \dots & W_{1n} \\ \vdots & & & & & \vdots \\ W_{i1} & W_{i2} & \dots & W_{ij} & \dots & W_{in} \\ \vdots & & & & & \vdots \\ W_{m1} & W_{m2} & \dots & \dots & \dots & W_{mn} \end{bmatrix}, \quad (17)$$

где n – число нейронов в следующем слое; m – число элементов в данном слое.

Входные, скрытые и выходные нейроны должны быть связаны между собой. Сеть прямого распространения в среде Matlab будет иметь вид (рисунок 2.5):



$$a\{1\} = \text{tansig}(IW\{1,1\}p\{1\} + b\{1\})$$

$$a\{2\} = \text{purelin}(LW\{2,1\}a\{1\} + b\{2\})$$

Рисунок 2.5 – Сеть с прямой передачей сигнала

При использовании для обучения сети алгоритма обратного распространения ошибки сеть рассчитывает возникающую в выходном слое ошибку и вычисляет вектор градиента как функцию весов и смещений. Этот вектор указывает направление кратчайшего спуска по поверхности для данной точки, поэтому если продвигнуться в обратном градиенту направлении, то ошибка уменьшится. Последовательность таких шагов должна привести к минимуму, хотя не всегда к глобальному. Определенную трудность здесь вызывает выбор величины шага. На практике величина шага выбирается пропорциональной крутизне склона (градиенту функции ошибок).

Сети, использующие радиальные базисные функции (РБФ), являются частным случаем трехслойной сети прямого распространения. В основе их создания и построения

лежит подход, основанный на разбиении пространства окружностями или (в общем случае) гиперсферами. Гиперсфера задается своим центром и радиусом. В качестве функций активации для входного и, часто, выходного слоев сетей РБФ применяют линейные функции, а для скрытого и иногда для выходного слоев - функции Гаусса [75,76]. Выходной слой объединяет полученные таким образом выходы нейронов скрытого слоя путем вычисления их линейной взвешенной комбинации (рисунок 2.6).




Рисунок 2.6 – Структура сети RBF

Функции $f_l(X)$ - это функции активации нейронов скрытого слоя, определяемые как

$$f_l(\mathbf{X}) = \varphi_l(\|\mathbf{X} - C_l\|), \quad (l = 1, 2, \dots, p), \quad (18)$$

где $\|\mathbf{X} - C_l\|$ - норма вектора $\mathbf{X} - C_l = (x_1 - C_{l1}, x_2 - C_{l2}, \dots, x_n - C_{ln})^T$; $C_l = (C_{l1}, C_{l2}, \dots, C_{ln})$ - вектор из обучающего массива, задаваемый в качестве центра l -той области моделируемых ситуаций на процессе; φ_l - радиальная (положительно определенная) базисная функция, принимающая максимальное значение при нулевом значении аргумента, т.е. когда вектор \mathbf{X} близок к вектору C_l , и монотонно убывающая с удалением от центральной точки при $\|\mathbf{X} - C_l\| \rightarrow \infty$.

Наиболее часто в качестве функции $f_l(X)$ выбирается Гауссова функция:

$$f_l(\mathbf{X}) = \exp\left[-\sum_{j=1}^n \frac{(x_j - C_{lj})^2}{2\sigma_{lj}^2}\right], \quad (l = 1, 2, \dots, p), \quad (19)$$

где σ_{ij} - параметр, определяющий ширину функции. График функции активации представлен на рисунке 2.7.

Диапазон нормирования обычно принимается равным $[0, +1]$, т.е. функция имеет максимум, равный 1, когда аргумент равен $X - C_l = 0$.




Рисунок 2.7 – График функции активации РБФ сети

Таким образом, РБФ нейрон действует как индикатор, который формирует значение 1, когда вектор X идентичен вектору C_l . Смещение позволяет корректировать чувствительность радиального базисного нейрона.

Т.к. настраиваемые веса в РБФ сети линейно связаны с выходами y_i , то они могут быть найдены непосредственно с помощью метода наименьших квадратов МНК. При этом минимизируется суммарная квадратичная ошибка сети

$$E = \frac{1}{2} \sum_{r=1}^R \sum_{i=1}^m (y_j^r - d_j^r)^2, \quad (20)$$

где y_j^r - j -тый выход сети при предъявлении r -того входного вектора X_r ; d_j^r - желаемый j -тый выход сети для входа X_r ; R - размерность обучающего массива.

Здесь важно отметить, что в RBF-сетях размерность скрытого слоя, существенно (на порядок и более) может превышать размерность входного слоя $p \gg n$, т.к. задача классификации данных в пространстве более высокой размерности с большей вероятностью удовлетворяет требованию линейной разделимости и таким образом обеспечивает высокую точность аппроксимации. Поэтому решение системы нормальных уравнений МНК, где требуется обращения ковариационной матрицы, при большой размерности помимо больших вычислительных затрат приводит к серьезным проблемам вследствие ее плохой обусловленности. Это потребует применения регуляризации [76]. Однако, в отличие от часто встречающейся ситуации, когда использование метода обратного распространения ошибки при настройке весов

персептрона приводит лишь к достижению локальных минимумов, здесь нахождение весов связей осуществляется быстрее и точнее. Однако, для больших значений n число требуемых базисных функций резко возрастает, возрастают и трудности в выборе их параметров.

Разработчикам диагностической модели на основе нейронной сети требуется следующее:

- выбрать соответствующую модель сети;
- определить топологию сети (т.е. число элементов и их связи);
- указать параметры обучения.

Архитектура сети описывается количеством слоев, количеством нейронов в каждом слое, видом функции активации каждого слоя и информацией о соединении слоев. Архитектура сети зависит от той конкретной задачи, которую должна решать сеть.

Работа сети состоит в вычислении выходов сети на основе известных входов с целью формирования желаемого отображения вход/выход. Конкретная задача определяет число входов и число выходов сети. Кроме числа нейронов в выходном слое сети, для проектировщика важно знать число нейронов в каждом слое. Большее количество нейронов в скрытых слоях и самих слоев обеспечивает более мощную сеть, но возникает опасность «переобучения» сети. Поэтому важно найти некий компромисс. Сети со смещением позволяют отразить более сложные связи между входами и выходами, чем сети без смещения.

Первый шаг при работе с нейронной сетью – это создание модели сети. После того, как сформирована архитектура сети, должны быть заданы начальные значения весов и смещений, или, иными словами, сеть должна быть инициализирована.

При решении с помощью нейронных сетей прикладных задач необходимо собрать достаточный и представительный набор данных (обучающий массив) для того, чтобы обучить нейронную сеть решению таких задач.

После того как определено количество слоев сети и число нейронов в каждом из них, нужно определить значения весов и смещений, которые минимизируют ошибку решения. Это и достигается в процессе обучения.

Главное отличие и преимущество НС перед классическими средствами прогнозирования и классификации заключается именно в их способности к обучению.

2.5 Выводы по 2-й главе

1. Рассмотрена структура автоматизированной системы оперативного управления (СОУ). Показано, что одной из важных функций СОУ являются функции мониторинга текущего состояния процесса и диагностики причин возникающих нарушений. Показана функциональная связь системы с другими системами, входящими в АСУТП.

2. В главе перечислены основные требования к разрабатываемой системе оперативного управления. Важнейшими функциями СОУ являются функции мониторинга и диагностики состояния контролируемого процесса с возможностью раннего обнаружения нарушений в его протекании, когда они еще обратимы, и выдачей рекомендаций оператору по их устранению.

3. Функционирование системы диагностики производится на основе диагностических моделей (ДМ), связывающих нарушение с симптомами (диагностическими показателями или измеряемыми прямо или косвенно проявлениями нарушений). Приведена классификация ДМ.

4. Сравнение возможностей диагностических моделей разных видов показало, что ни одна из них не является универсальной.

5. Из разных типов диагностических моделей в системах диагностики в промышленности наиболее часто используются модели, основанные на обработке выборок данных, полученных с датчиков, установленных на контролируемом процессе, с привлечением результатов лабораторных анализов. Это объясняется отсутствием в большинстве случаев математических описаний трудно формализуемых технологических процессов. Даже в случае, когда такие модели есть, они, как правило, описывают отдельные части технологического процесса, как в случае процесса агломерации, либо регламентные состояния процесса и для диагностики малопригодны.

6. Для диагностики ситуаций, особенно в сложных случаях, если ситуация сопровождается изменением многих переменных, хорошо зарекомендовали себя экспертные системы, использующие диагностические модели, построенные на основе экспертной информации. Изучение возможностей использования экспертных систем на базе таких диагностических моделей, выявило ряд недостатков. В частности, возникают

проблемы с назначением пороговых значений диагностических параметров в условной части правил, весовых коэффициентов и порогов для работы критериев близости и т.д.

7. В то же время от таких проблем свободен нейросетевой подход, который и было решено использовать при разработке системы оперативного управления для процесса агломерации, являющегося нелинейным процессом.

8. С целью сокращения времени переобучения нейронной сети целесообразно использовать иерархическую структуру диагностической модели, что позволяет снизить размерности входящих в модель сетей.

9. На основании анализа различных типов нейронных сетей показана целесообразность применения нейронных сетей прямого распространения.

ГЛАВА 3 Разработка структуры и алгоритма работы системы диагностики

3.1 Диагностическая модель процесса

3.1.1 Структура диагностической модели

Методика создания системы онлайн-диагностики включает несколько этапов:

1. Анализ контролируемого процесса и выявление возможных нарушений.
2. Определение диагностических показателей (симптомов) для характеристики нарушения
3. Выбор структуры диагностической модели и ее анализ.
4. Определение технических средств, обеспечивающих измерения и наблюдение за выбранными показателями. Определение возможности контроля показателей, не имеющих технических средств для прямого измерения.
5. Оценка эффективности выбранных показателей и средств. Уточнение структуры системы мониторинга и диагностики
6. Разработка алгоритмов работы, необходимого программного обеспечения, тестирование.

Определение контролируемых диагностических показателей основано на анализе процесса на предмет возможных нарушений. Для этого используются как литературные источники (регламентные материалы, технологические инструкции, описания типовых неисправностей, отказов, износов и т.п.), так и знания экспертов. По вектору основных диагностических показателей можно определить нарушение, анализ значений дополнительных показателей позволяет выйти на наиболее вероятную причину нарушения. В зависимости от выявленной причины выдаются соответствующие рекомендации по ее устранению.

Реализация процедур диагностики состоит из двух этапов. На первом этапе – этапе мониторинга состояния процесса - определяется сам факт наличия нарушения, а

затем, на втором этапе - этапе собственно диагностики - производится его идентификация, т.е. выяснение причины, вызвавшей это нарушение. Также выделяют промежуточный этап – локализацию нарушения – определение блока (участка, структурной единицы) контролируемого процесса, где это нарушение произошло.

Диагноз строится на основании сравнения информации о нарушениях на контролируемом процессе, заложенной в системе, с той, которая, поступает в реальном времени с датчиков. Однако, для обеспечения требуемой глубины диагностики, определяемой способностью системы различать причины, проявляющиеся практически одинаково, этой информации обычно не достаточно. Поэтому необходимо привлекать дополнительную информацию такую, как результаты лабораторных анализов, качественные характеристики процесса, определяемые оператором, данные о поверках датчиков и сроках работы оборудования и т.п.

Для обнаружения факта наличия нарушения на процессе используются статистики T^2 и Q , для которых известны пороговые значения. Если хотя бы одна из статистик превысит своё пороговое значение, то начинает работать система диагностики.

Из разного типа диагностических моделей, представленных во втором разделе выбрана нейросетевая [31]. Достоинством нейронных сетей, как там отмечалось, является их хорошая способность к классификации образов. В обучающий массив данных при этом должны быть заложены все возможные (выделенные разными экспертами) состояния процесса, чтобы обученная сеть могла распознать причину возникновения ситуации, к которой относится нарушение.

Существенным недостатком нейросетевых моделей для сложных процессов является большое время обучения и переобучения в связи с большой размерностью сети. Для уменьшения размерности сети необходимо провести декомпозицию объекта или множества возможных ситуаций, которые могут возникнуть на объекте в процессе его работы.

Проведение декомпозиции приводит к введению иерархии в структуру диагностической модели. При этом в случае декомпозиции объекта с выделением как

можно более автономных структурных единиц на сеть верхнего уровня (СВУ) возлагается определение места возникновения нарушения. В случае декомпозиции множества ситуаций с выделением их по тому или иному признаку сеть верхнего уровня выделяет эти ситуации.

Сети нижнего уровня (СНУ) используются для идентификации конкретного нарушения, то есть определения причин, вызвавших эту ситуацию на процессе.

Важным преимуществом такой двухуровневой нейросетевой модели является существенное снижение размерности образующих модель сетей, а это значит – резкое сокращение времени обучения и, главное, переобучения, что иногда требуется для адаптации модели к изменяющимся условиям на контролируемом объекте.

Дополнительным преимуществом такой модели является тот факт, что при появлении нарушения, неучтенного в обучающем массиве, оно будет обнаружено подсистемой мониторинга, хотя и не идентифицировано. Если появляется знание относительно нового нарушения, то должна быть повторно обучена только соответствующая сеть нижнего уровня, а она имеет низкую размерность.

Декомпозиция процесса агломерации может быть проведена по комбинированному признаку: по территориальному признаку естественно выделить участки, соответствующие стадиям процесса агломерации, указанным в п.1.1. Кроме того, для общего контроля качества целесообразно выделить блок и по функциональному признаку, например, «блок качества», который учитывал бы такие технологические факторы, как: массовая доля возврата, влажность шихты, высота слоя, температура зажигания шихты и др. В результате получаем следующие структурные единицы: блок подготовки шихты, блок зажигания, блок спекания, блок охлаждения и «блок качества».

Однако, анализ процесса показал, что выделенные блоки далеко не автономны, поэтому произвести однозначную локализацию нарушения (определение места его возникновения) затруднительно. Таким образом, учитывая, что число ситуаций на процессе, как будет показано ниже, относительно невелико, было решено отказаться от декомпозиции объекта и использовать декомпозицию множества ситуаций.

Архитектура двухуровневой нейросетевой диагностической модели приведена

на рисунке 3.1. Подсистема диагностики на основе нейросетевой ДМ начинает работать только в случае поступления разрешающего сигнала от подсистемы мониторинга, т.е. в случае обнаружения факта нарушения на процессе (превышение своего порогового значения хотя бы одной из указанных выше статистик). Все сети в ДМ многослойные, прямого распространения, что было выбрано на основании аналитического обзора нейронных сетей (п.2.4.1), где было показано, что данный вариант отличается простотой, хорошей проработанностью методов обучения.

Каждая сеть СНУ должна быть настроена на определение конкретных причин возникновения соответствующей ситуации, т.е. число выходных нейронов каждой СНУ будет равно числу возможных причин, которые выявлены при анализе процесса и учтены в обучающих массивах для данной ситуации. При этом, как уже отмечалось выше, если ситуация возникнет по неучтенному в модели нарушению, она будет все равно обнаружена, но идентификацию вызвавшего ее нарушения провести не удастся. Скорей всего будут определены как возможные (не выявленные!) нарушения с симптомами частично совпадающими с симптомами неизвестного нарушения. Таким образом, даже в этом случае оператор, по крайней мере, будет знать о возникновении нарушения. Что касается количества сетей нижнего уровня СНУ, то оно определяется соответственно числом структурных блоков.

В результате сеть верхнего уровня СВУ должна иметь столько выходных нейронов, сколько структурных блоков (ситуаций) выделено при декомпозиции, что касается входов сети, то их число определяется числом переменных, ответственных за возникновение ситуаций. Их количество может быть достаточно велико и размерность сети верхнего уровня может оказаться все-таки большой, что, как уже отмечалось выше, влечёт за собой большое время переобучения. Поэтому встаёт вопрос дополнительного снижения размерности данной сети.

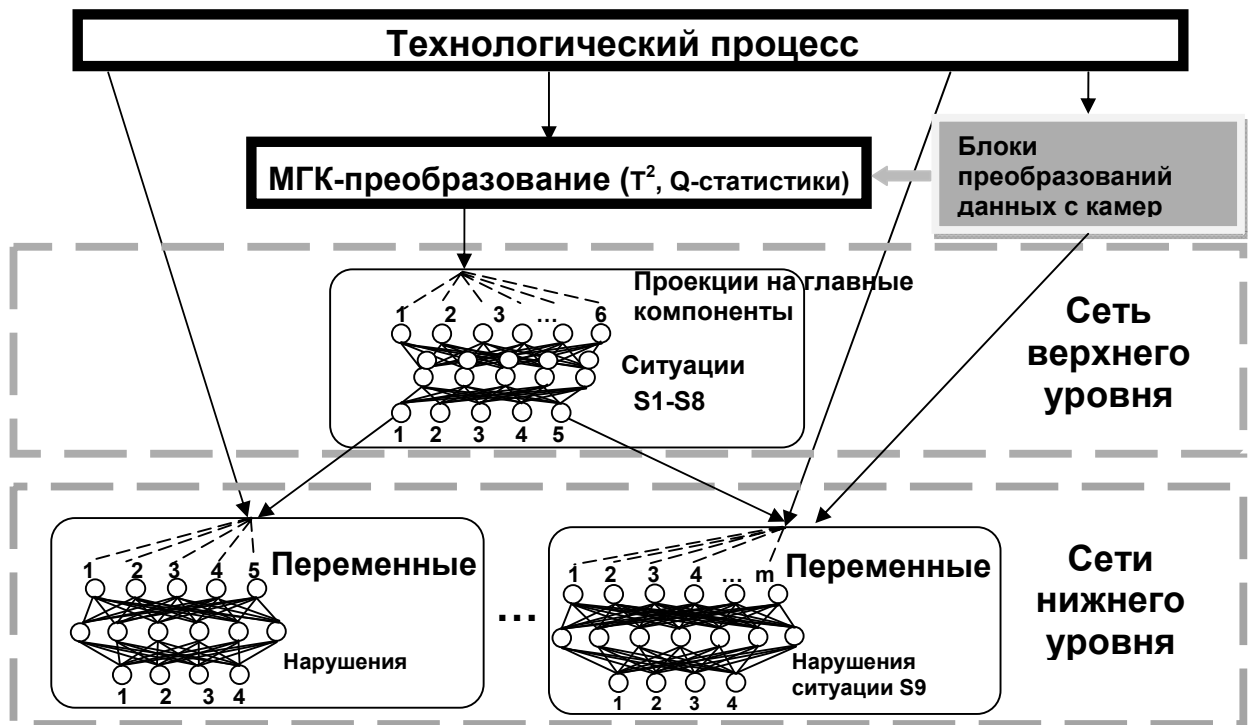


Рисунок 3.1 – Структура двухуровневой нейросетевой диагностической модели

3.1.2 Метод главных компонент

Из наиболее популярных методов снижения размерности высокую эффективность обеспечивает метод главных компонент (МГК) [77]. Преобразование выполняется на стадии предварительной обработки информации и на вход сети СВУ подаются не сами переменные, а их проекции в пространство главных компонент (ГК). В результате число входов СВУ снижается до числа ГК, учитываемых моделью (количество ГК в данной работе определяется по формуле (23), приведённой ниже).

Принцип МГК заключается в том, что направления с самыми большими дисперсиями считаются наиболее значимыми и принимаются за главные. Таким образом, МГК представляет собой ортогональное линейное преобразование исходных данных к новой системе координат такой, что самая большая дисперсия, при проекции данных по любой координате новой системы, оказывается на первой координате (названной первой главной компонентой), вторая самая большая дисперсия - по второй координате, и так далее. При этом часть дисперсий, необъяснённая главными

компонентами, попадает в пространство невязок [56, 77].

Линейное преобразование, используемое в МГК, имеет вид:

$$\mathbf{X} = \mathbf{TP}^T \quad \text{или} \quad \mathbf{T} = \mathbf{XP}, \quad (21),$$

где \mathbf{X} [nхр], матрица данных из n выборок измерений с р переменными каждое, нормированными к нулевому среднему и единичной дисперсии. Матрицу \mathbf{P} [рхр] называют матрицей нагрузки, она же является матрицей собственных векторов корреляционной матрицы исходных данных и новым базисом, преобразующим матрицу \mathbf{X} в матрицу \mathbf{T} , или матрицей главных компонент. Матрица \mathbf{T} [nхр] имеет размерность исходной матрицы \mathbf{X} и называется матрицей счетов (score matrix) или матрицей проекций.

Главные компоненты могут быть вычислены разными способами. В [56] приводится итерационный алгоритм NIPALS, однако, чаще на практике применяют вычисление главных компонент, разлагая ковариационную матрицу \mathbf{XX}^T по собственным векторам. Т.к. МГК масштабно зависимый метод, то исходные данные нормируются к нулевому среднему и к единичной дисперсии [77].

Произвольную матрицу \mathbf{X} [mхn] можно разложить на две ортонормированные матрицы и одну диагональную в следующей форме

$$\mathbf{X} = \mathbf{USV}^T, \quad (22)$$

где $\mathbf{U}=\{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_p\}$ – множество собственных векторов матрицы \mathbf{XX}^T ; диагональная матрица $\mathbf{S}=\{\sigma_i, i = 1, 2, \dots, p\}$, σ_i - корни из собственных значений матрицы $\mathbf{X}^T\mathbf{X}$; $\mathbf{V}=\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p\}$ – множество собственных векторов матрицы $\mathbf{X}^T\mathbf{X}$ [28].

Для определения количества ГК q ($q < p$), учитываемых в МГК модели, наиболее часто определяется доля CPV общей дисперсии исходных данных, объясняемая первыми главными компонентами. Если эта доля достигает $CPV \geq 90\%$ и более, то считается, что модель адекватно описывает корреляционные связи переменных в процессе:

$$CPV = 100 \left(\frac{\sum_{i=1}^q \lambda_i}{\sum_{i=1}^p \lambda_i} \right) \% \quad (23)$$

где p – число переменных, λ_i – i -ое собственное число ковариационной матрицы \mathbf{S} нормированного массива данных \mathbf{X} . При очень большом уровне шума в исходных данных этот критерий дает несколько завышенные оценки количества q компонент, которые необходимо учесть в модели МГК.

МГК модель процесса строится на данных обучающего массива, соответствующих нормальному состоянию процесса. Новая многомерная выборка измерений переменных \mathbf{x}_n проецируется в подпространство главных компонент, определенное матрицей \mathbf{P} для получения вектора счетов (проекций) – $\mathbf{t}_n = \mathbf{P}_q^T \mathbf{x}_n$, \mathbf{P}_q – первые q колонок в матрице \mathbf{P} , которые определяют базис ГК. Значения счетов подаются на входы сети СВУ.

3.1.3 Мониторинг с использованием МГК

Для мониторинга процесса (обнаружения факта нарушения) на основе данных МГК строятся две статистики T^2 (статистика Хоттеллинга) и Q (стандартная ошибка предсказания SPE). Для них известны пороговые значения, если переменные, входящие в матрицу \mathbf{X} , принадлежат генеральной совокупности, т.е. распределены нормально с нулевым средним и неизменившейся ковариационной матрицей \mathbf{S} . Если корреляционные связи между переменными процесса изменяются, чем обычно сопровождается возникновение нарушения, то та или иная статистика превышает пороговое значение. Первая статистика имеет вид [78]:

$$T^2 = \mathbf{x}_i^T \mathbf{S}^{-1} \mathbf{x}_i \quad (24)$$

В связи с тем, что ковариационная матрица \mathbf{S} переменных процесса, в большинстве случаев, плохо обусловлена, иногда вырождена, если переменные сильно коррелированы между собой, то вместо выражения (24) используется уравнение (25):

$$T_k^2 = \mathbf{t}_k (\mathbf{T}_q^T \mathbf{T}_q)^{-1} \mathbf{t}_k^T \quad (25),$$

где \mathbf{t}_i – проекции исходного вектора \mathbf{x} текущих значений переменных процесса на главные компоненты (счета); k индекс координаты в базисе главных компонент;

вместо ковариационной матрицы \mathbf{S} применяется диагональная ковариационная матрица проекций вектора на главные компоненты, учитываемые в модели [78]. Статистика T_k^2 в (25) является квадратичной формой, фактически определяющей расстояние по координате k от данного вектора до центра массива данных, по которым строилась модель МГК. Учитывая, что слагаемые ортогональны, для вычисления статистики T^2 будет использована более удобная формула [78]:

$$T^2 = \sum_k^q \frac{t_k^2}{s_k^2} \quad (26)$$

где q – количество главных компонент в модели, s_k^2 – дисперсия t_k .

Пороговое значение для статистики T^2 определяется исходя из того, что её распределение аппроксимируется распределением Фишера с q , $(n-q)$ степенями свободы [78]:

$$C_T = \frac{(n-1)(n+1)q}{n(n-q)} F_\alpha(q, (n-q)) \approx \frac{(n+1)q}{n-q} F_\alpha(q, (n-q)) \quad (27)$$

Статистика T^2 в графическом отображении формирует гиперэллипс, который представляет допустимые пределы вариаций, объясняемых моделью МГК. Если вариация вектора новых измерений выходит за пределы гиперэллипса вариаций допустимых в ходе процесса, то фиксируется факт нарушения. При нормальном ходе процесса должно выполняться неравенство:

$$T_i^2 \leq C_T \quad (28),$$

Если возникает новая ситуация, которой не было в исходной модели МГК, ее вектор попадает в подпространство невязок. Этот тип событий может быть обнаружен с помощью Q -статистики, отражающей вариации в этом подпространстве. Статистика Q представляет собой Евклидово расстояние от рабочей точки процесса до гиперплоскости, сформированной учитываемыми в модели главными компонентами:

$$Q = \mathbf{e}^T \mathbf{e} = (\mathbf{x} - \bar{\mathbf{x}})^T (\mathbf{x} - \bar{\mathbf{x}}) = \sum_{j=1}^p (x_j - \bar{x}_j)^2 \quad (29),$$

где $\mathbf{e} = (\mathbf{I} - \mathbf{P}_q \mathbf{P}_q^T) \mathbf{x}$ - невязки выборки \mathbf{x} , j – индекс переменной в выборке.

Пороговое значение для Q -статистики определяется из выражения [78]:

$$C_\alpha = \theta_1 [1 - \theta_2 h_0 (1 - h_0) / \theta_1^2 + z_\alpha (2\theta_2 h_0^2)^{1/2} / \theta_1]^{1/h_0} \quad (30)$$

где

$$\theta_1 = \sum_{j=q+1}^p \lambda_j, \theta_2 = \sum_{j=q+1}^p \lambda_j^2, \theta_3 = \sum_{j=q+1}^p \lambda_j^3, h_0 = 1 - 2\theta_1\theta_3 / 3\theta_2^2$$

z_α - процентная точка нормального распределения; λ_j ($j = q+1, \dots, p$) - собственные значения матрицы S , соответствующие не учтённым моделью собственным векторам (q - число ГК, тогда размерность подпространства невязок $(p-q)$); α - уровень значимости.

В случае превышения статистикой Q порогового значения C_α фиксируется факт возникновения нарушения.

T^2 и Q -статистика служат индикаторами обнаружения факта нарушения. Если T^2 и-или Q значения для нового наблюдения превышают свои пороговые значения, то начинает работать нейронная сеть, задачей которой является идентификация нарушения.

3.2 Структурирование возможных нарушений в ходе процесса агломерации

3.2.1 Методика формирования перечня нарушений

В процессе разработки системы диагностики значимым фактором, определяющим возможность создания данной системы, является наличие необходимого объёма знаний о возможных нарушениях на процессе и их характеристиках. Это необходимо для идентификации диагностической модели.

Источниками информации для сбора знаний о возможных нарушениях являются техническая литература; технологические инструкции и регламенты; тренды и графики, записанные в ходе процесса, а также эксперты, на основании своего опыта хорошо знакомые с данным процессом и его особенностями. В нашем случае такими экспертами явились агломератчики, ведущие процесс.

На пути получения информации возникает ряд сложностей. Во-первых, в связи

со строгим контролем на современных металлургических предприятиях за фактом неразглашения коммерческой тайны, доступ к ознакомлению с технологическими инструкциями и журналами о ходе процесса ограничен. По этой же причине не хватает информации от высококвалифицированных, опытных экспертов. В зарубежной и отечественной литературе по данной тематике в открытом доступе не приводится перечень нарушений на процессе, также отсутствуют какие-либо статистические данные о ситуациях в ходе эксплуатации. Всё вышеперечисленное усложняет сбор полной и достоверной информации, как о процессе, так и о нарушениях на процессе для создания когнитивной системы диагностики.

Методы получения знаний можно разделить на коммуникационные (работа с экспертами: анкетирование, интервьюирование) и текстологические (изучение литературы, технологических регламентов, инструкций и другой нормативной литературы).

На первом этапе целесообразно использовать текстологические методы сбора информации для получения общего представления о предметной области, на основе чего в дальнейшем строить своё взаимодействие с экспертами и классифицировать знания, полученные от экспертов. В качестве экспертов при выполнении данной работы выступали операторы аглоцеха.

При работе с экспертами необходимо учитывать следующие моменты, которые усложняют процесс сбора знаний:

- использование экспертами профессионального сленга, который бывает нелегко понять разработчику системы;
- сложность преобразования знаний, лежащих в основе многих специфических областей знания эксперта, в термины диагностической модели;
- трудность выявления и формализации знаний экспертов, полученных в ходе личного опыта по сравнению с обычным перечнем фактов и нарушений;
- получение неполного объёма знаний от экспертов, в связи с тем, что многие моменты кажутся экспертам само собой разумеющимися, но для неспециалиста в данной узкой предметной области таковыми не являются.

На основании вышеизложенного применение комбинированного метода сбора

знаний становится наилучшим решением. Поэтому первый этап формирования множества «Нарушения-причины» состоял в знакомстве с технологическими инструкциями, специальной литературой, статьями в научных журналах, докладами, монографиями и другими нормативными документами по процессу агломерации. Далее на основе прямого контакта с экспертами полученная информация систематизировалась.

Возможные нарушения и сценарии их возникновения и развития обсуждались с экспертами, выяснялись возможные причины возникновения каждого нарушения и их проявления в отклонениях контролируемых переменных процесса. В дальнейшем из них был сформирован список диагностических показателей (симптомов) и возможные диапазоны их значений при возникновении соответствующих нарушений. Дополнительно выяснялись возможные способы ликвидации возникающего нарушения (действия, рекомендации). Далее полученная информация подвергалась дополнительной верификации и уточнению. При этом определялась значимость показателя для идентификации ситуации, возможные последствия развития ситуации и т.п. дополнительная информация.

В результате был составлен перечень технологических нарушений на процессе агломерации с указанием диагностических показателей и причин, приводящих к возникновению данных нарушений, а также способов их ликвидации.

3.2.2. Структурирование нарушений и формирование перечня ситуаций на процессе агломерации

При формировании массивов данных необходимо учитывать контролируемые существующей системой автоматизации параметры (схема автоматизации – Приложение А), такие как: температура и разряжение во всех вакуум-камерах, температура отходящих газов, температура и давление коксового газа на горелки, также технические параметры: давление воздуха в коллекторе, расход и давление воды на увлажнение, давление после нагнетателя, разрежение перед циклоном и перед эксгаустером, уровень в бункерах газохода, уровень в бункерах циклонов.

Кроме того, ряд параметров определяется лабораторно. Это, например, гранулометрический состав готового агломерата, фактический состав шихты и др. Но некоторые важные с точки зрения диагностики параметры, как это будет показано ниже) не имеют в существующей системе автоматизации средств измерения.

Анализ выделенных нарушений показал, что многие из них приводят к одним и тем же ситуациям, т.е. проявляются в состоянии процесса похожим образом, например, приводят к непропеканию шихты или, наоборот, к расплавлению агломерата и т.п. Поэтому такие ситуации решено использовать как структурные единицы, получаемые при декомпозиции множества нарушений, и их обнаружение возложить на сеть верхнего уровня диагностической модели.

Всего было выделено 9 таких ситуаций. Их список приведен в таблице 3.1. Определение конкретных нарушений, приведших к возникновению этих ситуаций, производится сетями нижнего уровня диагностической модели.

Большинство экспертов определило значения эксплуатационных порогов (значений переменных процесса, которые могут свидетельствовать о развитии нарушения) как 20% отклонения от значения нижнего или верхнего регламентного порога (от первого - вниз, а от второго - вверх). Зона изменения переменных от эксплуатационных порогов до границ предаварийной зоны является зоной ответственности СОУ, то что выше – зона ответственности системы противоаварийной защиты.

Некоторые нарушения, содержат несколько определяющих диагностических показателей (симптомов). Превышение эксплуатационного порога одним таким показателем может стать важным условием определения данного нарушения, а значение другого показателя - дополнительным условием.

Посредством декомпозиции сформированного множества нарушений на процессе по функциональному признаку в основном выполнено разбиение знаний с выделением знаний, описывающих ситуации, а дополнительный анализ нарушений на процессе позволил сформировать более детализированную картину, в частности собрать ситуации и связанные с ними нарушения, относящиеся непосредственно к процессу спекания.

После окончания формирования списка диагностических показателей выяснилось, что далеко не все необходимые параметры снабжены средствами непрерывного автоматического или лабораторного контроля. Так, например, для определения таких параметров как «рыжеватость» шихты, «раскалённость поверхности над 4-5 вакуум-камерами после горна», «удлинённость зоны свечения поверхности агломерата до 6-7 вакуум-камер» и ряда других, на предприятии отсутствуют приборы измерения. Для этой цели ниже предлагается установка дополнительной аппаратуры, а именно цифровых оптических камер.

Таблица 3.1 – Список возможных нарушений и вызывающих их причин, которые могут возникнуть на процессе агломерации

Нарушение	Причины	Симптомы
Ситуация S1.Нарушение пропекания шихты		
S1.1 Неполное пропекание шихты	Низкая температура зажигания шихты Увеличение содержания влаги в шихте (приводит к изменению порозности слоя, следствие - ухудшение газопроницаемости) Массовая доля углерода в возврате превышена	Температура горна $T_{гор} \downarrow$ Влажность шихты $W_{ших} \uparrow$ Массовая доля углерода в возврате $M_{угл/возв} \uparrow$
	Увеличение среднего диаметра частиц шихты приводит к тому, что крупные частицы не успевают расплавиться	Гранулометрический анализ (лаборатория)
	Увеличение размера частиц кокса (горение частиц происходит медленно, они не успевают догорать)	Гранулометрический анализ (лаборатория)
	Увеличение естественной основности шихты (приводит к снижению температуры в слое)	Контроль состава (лаборатория)
S1.2 Образование расплавленного агломерата	Высокая температура зажигания шихты Снижение доли низкокалорийного топлива Малая скорость движения агломашины	Температура горна $T_{гор} \uparrow$ Массовая доля низкокалорийного топлива $M_{низк.топ} \downarrow$ Скорость движения агломашины $V_{агл} \downarrow$
	Малый средний диаметр частиц шихты (быстрое плавление частиц)	Гранулометрический анализ (лаборатория)
	Снижение газопроницаемости	Уменьшение массовой доли влаги в шихте (приводит к изменению

		порозности слоя) $W_{\text{ших}} \downarrow$
	Уменьшение естественной основности шихты (приводит к повышению температуры в слое)	Контроль состава (лаборатория)
	Недостаточный расход топлива (при повышенной крупности)	Контроль состава (лаборатория)
Ситуация S2. Увеличение скорости спекания		
S2.1 Увеличение скорости спекания	Увеличение массовой доли в шихте возврата и повышение крупности	Количество возврата в шихте $M_{\text{возвших}} \uparrow$ Крупность возврата превышена

Ситуация S3. Выход агломерата несоответствующего качества		
S3.1 Ухудшение качества агломерата	Недостаток углерода в шихте	<p>Более короткая зона свечения поверхности агломерата (до 5-6 вакуум-камер).</p> <p>В изломе пирога появляются гнёзда неспечённой шихты, агломерат сходит с паллет почти тёмным. (Симптом определяется по данным камеры)</p>
	Избыток углерода в шихте	<p>Удлинённая зона свечения поверхности агломерата (до 6-7 вакуум-камер).</p> <p>Шихта в зоне спекания раскалена до 2/3 высоты.</p> <p>При допекании шихты до колосников агломерат получается сильно оплавленный с крупными порами. (Симптом определяется по данным камеры)</p>
Ситуация S4. Увеличение выхода возврата от заданного значения		
S4.1 Повышение доли низкокалорийного топлива	Массовая доля низкокалорийного топлива ($M_{\text{низк.топ}} > M_{\text{низк.топ.ном}}$);	<p>Массовая доля низкокалорийного топлива $M_{\text{низк.топ}} \uparrow$</p> <p>Выход возврата $M_{\text{возв}} \uparrow$</p>
S4.2 Уменьшение содержания углерода (преобладание реакций окисления)	Массовая доля углерода ($M_{\text{угл}} < M_{\text{угл.ном}}$)	<p>Массовая доля углерода $M_{\text{угл}} \downarrow$</p> <p>Выход возврата $M_{\text{возв}} \uparrow$</p>

S4.3 Уменьшение содержания FeO в агломерате (преобладание реакций окисления)	Массовая доля FeO в агломерате ($M_{\text{FeO}} < M_{\text{FeO.ном}}$) (лаборатория)	Массовая доля FeO в агломерате $M_{\text{FeO.ном}} \downarrow$ Выход возврата $M_{\text{возв}} \uparrow$
S4.4 Снижение высоты слоя шихты	Высота слоя шихты < регламентного значения;	Высота слоя шихты $H \downarrow$ Выход возврата $M_{\text{возв}} \uparrow$
S4.5 Массовая доля влаги в шихте увеличена (преобладание реакций восстановления)	Влажность шихты ($W_{\text{ших}} > W_{\text{ших.ном}}$)	Влажность шихты $W_{\text{ших}} \uparrow$ Выход возврата $M_{\text{возв}} \uparrow$
S4.6 Уменьшение массовой доли влаги в шихте	Влажность шихты ($W_{\text{ших}} < W_{\text{ших.ном}}$)	Влажность шихты $W_{\text{ших}} \downarrow$ Выход возврата $M_{\text{возв}} \uparrow$
S4.7 Ухудшение прочности агломерата	Недостаточное пропекание агломерата (пониженная температура агломерата на выходе) Массовый расход топлива ($M_{\text{топ}} > M_{\text{топ.ном}}$); Увеличение крупности частиц агломерата	Температура агломерата $T_{\text{агл}} \downarrow$ Массовая доля топлива $M_{\text{топ}} \uparrow$ Выход возврата $M_{\text{возв}} \uparrow$

Ситуация S5. Нарушение на этапе зажигания шихты		
S5.1 Низкая температура зажигания	Низкая температура зажигания	Рыжеватый оттенок цвета поверхности спёка после охлаждения (Симптом определяется по данным камеры №2)
S5.2 Высокая температура зажигания	Высокая температура зажигания	Поверхность «пирога» оплавлена, имеет повышенную прочность (Симптом определяется по данным камеры №2)
Ситуация 6. Нарушение технологических параметров спекания		
S6.1 Превышение топлива и влаги в шихте	Массовая доля топлива в шихте увеличена Массовая доля влаги в шихте увеличена	Разрежение под колосниковой решёткой $P_{кр} \uparrow$ Влажность шихты $W_{ших} \uparrow$ Массовая доля топлива $M_{топ} \uparrow$
S6.2 Пониженная доля топлива и влаги в шихте	Массовая доля топлива в шихте уменьшена Массовая доля влаги в шихте уменьшена	Разрежение под колосниковой решёткой $P_{кр} \uparrow$ Влажность шихты $W_{ших} \downarrow$ Массовая доля топлива $M_{топ} \downarrow$
S6.3 Увеличение температуры зажигания шихты	Температура зажигания шихты увеличена	Разрежение под колосниковой решёткой $P_{кр} \uparrow$ Температура горна $T_{гор} \uparrow$
S6.4 Уменьшение температуры зажигания шихты	Уменьшение температуры зажигания шихты	Разрежение под колосниковой решёткой $P_{кр} \uparrow$ Температура горна $T_{гор} \downarrow$
S6.5 Уменьшение массы возврата и ухудшение его качества	Уменьшение массы возврата и ухудшение его качества	Разрежение под колосниковой решёткой $P_{кр} \uparrow$ Выход возврата $M_{возв} \uparrow$

		Остаточная доля углерода в возврате $M_{\text{УГЛ/ВОЗВ}} \uparrow$
S6.6 Уменьшение массы извести в шихте	Уменьшение массы извести в шихте	Разрежение под колосниковой решёткой $R_{\text{КР}} \uparrow$ Масса извести $M_{\text{ИЗВ}} \downarrow$
S6.7 Чрезмерное уплотнение шихты	Плотность шихты больше регламентного значения	Разрежение под колосниковой решёткой $R_{\text{КР}} \uparrow$ Плотность шихты \uparrow
Ситуация S7. Нарушение подачи воды на увлажнение		
S7.1 Нарушение подачи воды на увлажнение	Низкое давление воды на увлажнение	Давление воды $P_{\text{ВОДА}} \downarrow$ Влажность шихты $W_{\text{ШИХ}} \downarrow$
Ситуация S8. Нарушение времени спекания		
S8.1 Позднее окончание спекания. Пониженная газопроницаемость шихты	Увеличение содержания влаги в шихте (приводит к изменению порозности слоя) Малые размеры частиц кокса (горение частиц происходит быстро)	Скорость движения агломашины $V_{\text{АГЛ}} \uparrow$ Влажность шихты $W_{\text{ШИХ}} \uparrow$ Гранулометрический состав шихты (лаборатория)
S8.2 Позднее окончание спекания. Увеличение доли топлива в шихте	Увеличение доли топлива в шихте	Скорость движения агломашины $V_{\text{АГЛ}} \uparrow$ Массовый расход топлива $M_{\text{ТОП}} \uparrow$
S8.3 Более высокая температура в последней вакуум-камере по сравнению с температурой в предпоследней	Более высокая температура в последней вакуум-камере	Скорость движения агломашины $V_{\text{АГЛ}} \uparrow$ $T_{\text{В/К11}} - T_{\text{В/К10}} \uparrow$
S8.4 Более раннее окончание спекания	Понижение температуры в предпоследней вакуум-камере по сравнению с температурой в предыдущих Увеличенная скорость движения агломашины	Скорость движения агломашины $V_{\text{АГЛ}} \uparrow$ $T_{\text{В/К11}} - T_{\text{В/К10}} \downarrow$

Ситуация S9. Неравномерность распределения температуры по ширине аглоленты		
S9.1 Неравномерность распределения температуры по ширине аглоленты	Непостоянство температуры по ширине ленты	Симптом определяется по данным камеры №1

Ниже в качестве примера приведены номинальные значения некоторых технологических переменных процесса агломерации на одной из отечественных аглофабрик, используемых при оценке диагностических показателей (симптомов) в таблице (указаны нижние и верхние регламентные пределы):

Температура горна: $T_{\text{ГОР.НОМ.МИН}} = 800 \text{ }^{\circ}\text{C}$; $T_{\text{ГОР.НОМ.МАКС}} = 1250 \text{ }^{\circ}\text{C}$;

Выход возврата: $M_{\text{ВОЗВ.НОМ.МИН}} = 10 \text{ т/ч}$; $M_{\text{ВОЗВ.НОМ.МАКС}} = 30 \text{ т/ч}$;

Массовый расход топлива: $M_{\text{ТОП.НОМ.МИН}} = 3 \text{ т/ч}$; $M_{\text{ТОП.НОМ.МАКС}} = 3,5 \text{ т/ч}$;

Массовая доля углерода в возврате шихты $M_{\text{УГЛ/ВОЗВ.НОМ.МИН}} = 0,7\%$;

Массовый расход низкокалорийного топлива: $M_{\text{НИЗК.ТОП.НОМ.МИН}} = 0,1 \text{ т/ч}$;

Влажность шихты $W_{\text{ШИХ.НОМ.МАКС}} = 1,5\%$;

Скорость движения агломашины ($V_{\text{АГЛ.НОМ.МИН}}$) = 0,7 м/мин

3.3 Увеличение глубины диагностики введением цифровых оптических камер

3.3.1. Места установки и выбор типа камер

Как уже было отмечено в предыдущем параграфе, некоторые нарушения на процессе спекания могут быть идентифицированы по внешнему виду агломерационного пирога. Например, такие параметры как «цвет агломерата в конце аглоленты», «цвет агломерата на ленте после горна», «структура излома при сбросе агломерата с ленты», характеризующие равномерность нагрева, вертикальную скорость спекания и степень пропекания шихты, определяются визуально оператором («на-глазок»), и вводятся в систему управления вручную (параметры определяют нарушения, ситуации S3, S5, S9 (таблица 3.1)). Выявление данных нарушений на первый взгляд представляется довольно простой задачей, требующей только внимательности оперативного персонала. Но на практике человеческий фактор, опыт операторов далеко не всегда способствуют эффективному управлению процессом агломерации. Для оценки этих параметров предлагается оптико-электронный способ их определения, позволивший исключить человеческий фактор и ввести полученные значения в систему оперативного управления. С этой целью на участках агломашины, на которых можно выявить эти симптомы, предлагается установить цифровые оптические камеры с определёнными техническими характеристиками.

Предлагается следующее расположение цифровых оптических камер (рисунок 3.2):

Камера 1 (для выявления ситуации S9 «Неравномерность распределения температуры по ширине аглоленты») располагается над поверхностью агломерата в зоне 5-6-й вакуум-камер. Задача камеры – получение изображения для определения равномерности нагрева по ширине аглоленты, зон перегрева по длине аглоленты над 5-7 вакуум-камерами. Поэтому представляется целесообразным использовать инфракрасную камеру. Неравномерность свечения (температуры) одновременно по

ширине и длине аглоленты часто вызывается низкой температурой в зажигательном горне [3].

Камера 2 (для выявления ситуации S5 «Нарушение на этапе зажигания шихты») устанавливается в зоне охлаждения, в конце аглоленты, охватывая поверхность спеченного агломерата в зоне последней вакуум-камеры, для определения цвета «пирога». При оптимальной температуре зажигания шихты поверхность «пирога» имеет серовато-металлический цвет, при повышенной температуре «оплавлена», при пониженной температуре зажигания имеет рыжеватый цвет.




Рисунок 3.2 – Схема расположения цифровых оптических камер

Камеру 3 (для выявления ситуации S3 «Выход агломерата несоответствующего качества»), исходя из рекомендаций работы [3], предлагается разместить в просмотровом окне над грохотом в связи с тем, что при таком расположении камера располагается параллельно излому аглоспёка и перекрытие излома аглоспёка слоем минимально. При избытке топлива зона горения имеет значительную высоту и имеет белый цвет, при недостатке - агломерат сходит с паллет почти тёмным. Оптимальным цветом излома является тёмно-коричневый.

В работах [3, 79, 80] используются оптико-электронные средства на процессе агломерации для определения распределений температур по поверхности спекаемого агломерата и гранулометрического анализа состава агломерата. В настоящей работе

применяются аналогичные средства для определения температурных полей и цвета агломерата в определённых зонах агломашины. Это не требует тонкой настройки камер и не предъявляет повышенных требований к квалификации операторов.

Цвет агломерата зависит от его температуры. В таблице 3.2 приведены цвета каления твёрдых материалов в зависимости от температуры [81, 82].

Таблица 3.2 – Зависимость цвета каления твёрдых материалов от температуры

Температура	Цвет	Температура	Цвет
550	Темно-коричневый	900	Светло-красный
630	Коричнево-красный	950	Желто-красный
680	Темно-красный	1000	Желтый
740	Темно-вишневый	1100	Ярко-желтый
770	Вишневый	1200	Желто-белый
800	Ярко-вишневый	1300	Белый
850	Ярко-красный	1400	Белый

Для уверенного распознавания цвета агломерата очень важна правильная установка камер, ниже приведены основные требования, которые должны быть учтены при установке [3]:

- Камеры 1,3 не требуют дополнительного освещения, так как источником света является раскалённый агломерат.
- Камера 2 требует дополнительного верхнего рассеянного освещения.
- Поверхность спекаемого слоя имеет фиксированные размеры по ширине в зависимости от ширины аглоленты: 2000мм или 4000мм (это необходимо учитывать при установке камеры 1).
- Излом аглоспека имеет фиксированные размеры в зависимости от ширины аглоленты: 300x2000 мм или 300x4000 мм (это также необходимо учитывать при установке камеры 3).
- Процесс агломерации происходит неравномерно по ширине паллеты, что обусловлено проявлением бортового эффекта на расстоянии 0,8м от борта паллеты при ширине машины 4м. У бортов спекание происходит быстрее, чем в центре паллеты (необходимо учитывать при установке камер 1,2).

3.3.2 Алгоритмы обработки изображений

Блок-схема алгоритма обработки изображений инфракрасной камеры 1 приведена на рисунке 3.3 [83]. Камера настраивается так, чтобы аглолента занимала всю площадь кадра. Достаточно использовать камеру среднего разрешения с размером кадра, например, в L(lxг) - L(480x640) пикселей.

Изображение предварительно нормируется по интенсивности пикселей на 1 делением каждого элемента на 255 (предполагается байтовая кодировка интенсивности пикселя). Вся зона охвата камеры виртуально разделяется на 15 зон (операторы 3 и 4): на 5 зон по ширине аглоленты и на 3 зоны - по длине T1.1 - T5.1; T1.2-T5.2; T1.3-T5.3 (это соответствует участку аглоленты над 5-7 вакуум-камерами). Далее организуется цикл (операторы 5-8), во время которого подсчитываются среднее значение и СКО температуры по зонам, расположенным поперек аглоленты (оператор 9) и вдоль ее (оператор 10). Затем проверяется равномерность распределения температуры по ширине ленты: если средние температуры зон отличаются более чем на 2 СКО, то делается заключение, что материал прогрет не равномерно (оператор 13). Существует и другое нарушение в процессе прогрева - чрезмерный нагрев. Для процесса существует график определяющий профиль изменения температур вдоль ленты. Согласно ему температуры ближайших зон (вдоль ленты) не должны отличаться более чем на предельное значение отклонения температуры T_n (оператор 14). Далее информация о состоянии процесса передается в систему диагностики.

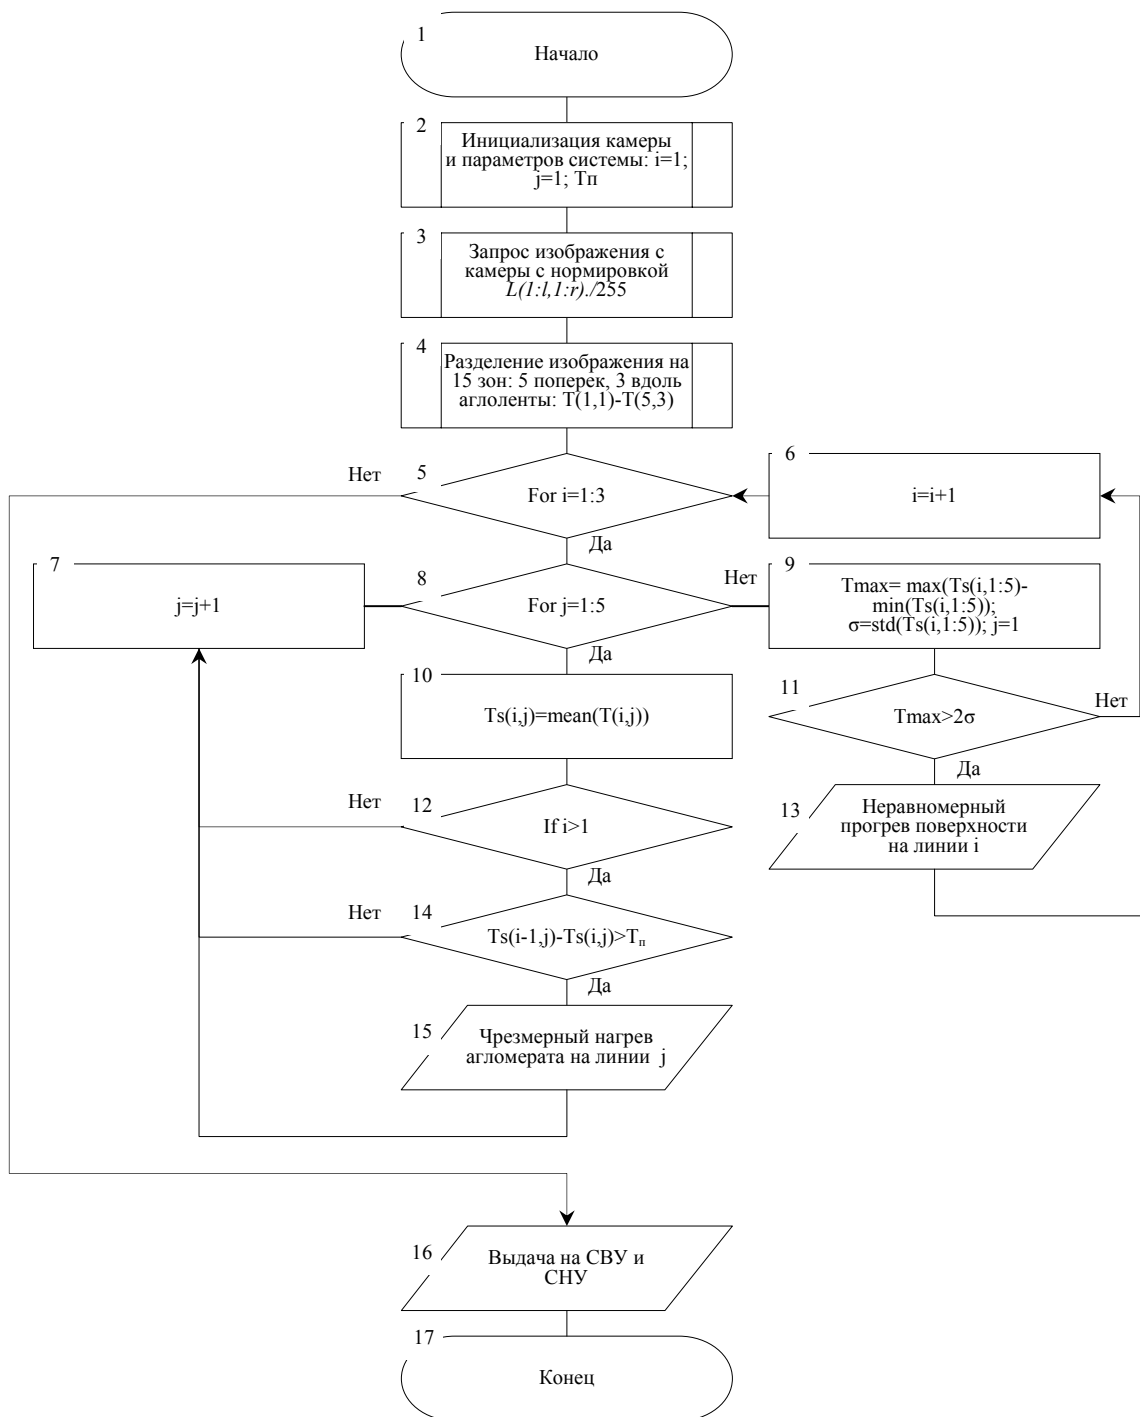


Рисунок 3.3 – Блок-схема алгоритма обработки изображения с первой камеры

В зоне расположения камеры 2, определяющей по «рыжеватости» агломерата на ленте его непропекание (пример ситуации S5 «Нарушение на этапе зажигания шихты»), требуется стороннее освещение рассеянным светом для увеличения

контрастности изображения. Цвет агломерата не равномерен, поэтому требуется интегральная оценка по всей поверхности, например, оценивая цвет каждого пикселя получаемого изображения с последующим усреднением. Учитывая, что важен цвет, точнее, его оттенки и их изменение, которые эксперты определили достаточно неопределенно, решено обработку проводить сравнением с эталонами. Для этой цели были получены 2 изображения агломерата, цвет которых соответствует нормальному ходу процесса и ходу процесса с нарушением. Эти образцы предъявляются камере одновременно, и система запоминает усредненную цветность предъявленных образцов, с которой она будет сравнивать цветность рабочих изображений, определяя относительную долю недопеченной шихты и нормально пропеченной шихты. Примеры таких образцов приведены на рисунке 3.4.




Рисунок 3.4 – Примеры образцов пирога: слева - нормальный, справа - с недопеком

Цвет каждого пикселя обоих изображений был нанесен в трехмерное пространство, где в качестве координат использовались значения интенсивности красного, зеленого и синих цветов соответственно. В результате были получены 2 массива точек (x - цвет агломерата при нормальном ходе процесса, o - цвет при наличии в ходе процесса нарушения), которые затем были объединены и подвергнуты кластеризации.

Предобработка изображения при настройке камеры состоит в проведении нечеткой кластеризации массива пикселей в два кластера: нормальный (2 кластер) и с нарушением (1 кластер). В качестве метода кластеризации принят метод нечеткой кластеризации Густафсона-Кесселя, обеспечивающий формирование кластеров различных форм [84, 85]. Нечеткая кластеризация разрешает объекту принадлежать

сразу нескольким кластерам с какой-то долей уверенности, определяемой значением функции принадлежности (в отличие от четкой кластеризации, где объект может принадлежать только одному кластеру). Это позволяет провести мягкую кластеризацию и учесть неопределенность задачи.




Рисунок 3.5 – Вид кластеров после обработки изображений эталонов с камеры 2

Процедура кластеризации состоит в следующем [86]:

Шаг 1. Установить параметры алгоритма:

c - количество кластеров (в нашем случае - 2);

m - экспоненциальный вес (обычно m принимается равным $m=2$);

ε - параметр останова алгоритма кластеризации;

N - размерность входного вектора (в нашем случае число цветовых координат пикселя изображения; $N=3$, т.к. предполагается использовать R, G, B - камеру).

Шаг 2. Случайным образом сгенерировать матрицу нечеткого разбиения U .

Шаг 3. Рассчитать центры кластеров:

$$c_j = \frac{\sum_{i=1}^N (u_{ij})^m \cdot x_i}{\sum_{i=1}^N (u_{ij})^m} \quad (31)$$

Шаг 4. Вычислить матрицу ковариации для j-ого кластера:

$$A_j = \frac{\sum_{i=1}^N (u_{ij})^m \cdot (x_i - c_j)^T \cdot (x_i - c_j)}{\sum_{i=1}^N (u_{ij})^m} \quad (32)$$

Шаг 5. Рассчитать расстояния между объектами из X и центрами кластеров (принимается в качестве оценки расстояния расстояние Махаланобиса):

$$D_{A_j} = (x_i - c_j) \cdot \left[(\det(A_j))^{1/N} \cdot A_j^{-1} \right] \cdot (x_i - c_j)^T \quad (33)$$

Шаг 6. Пересчитать элементы матрицы нечеткого разбиения:

$$\text{если } D_{A_j} > 0 \quad (34)$$

$$u_{ij} = \frac{1}{\left(D_{ij}^2 \sum_{k=1}^K \frac{1}{D_{ik}^2} \right)^{\frac{1}{m-1}}}$$

если: $D_{ij} = 0$

$$u_{ik} = \begin{cases} 1, k = j \\ 0, k \neq j \end{cases} \quad k = \overline{1, K} \quad (35)$$

Шаг 7. Проверить условие останова:

$$\|U - U^*\|^2 < \varepsilon \quad (36)$$

где U^* - матрица нечеткого разбиения на предыдущей итерации алгоритма.

Если неравенство выполняется, то перейти к шагу 8, иначе - к шагу 3.

Шаг 8. Окончание процедуры кластеризации.

В рабочем режиме алгоритм производит вычисление расстояний каждого пикселя изображения до определенных на этапе кластеризации центров кластеров c_j по выражению (32), классифицирует их и рассчитывает долю пикселей, принадлежащих каждому кластеру. В зависимости от доли «плохих» пикселей принимается решение о наличии нарушения и степени его проявления. Пример результатов кластеризации изображения эталонов показан на рисунке 3.5.

Блок-схема алгоритма обработки изображения со второй камеры приведена на рисунке 3.6. Кластеризация проводится предварительно, и системе на этапе инициализации (оператор 3) сообщаются центры кластеров c_j и матрицы ковариации A_j . Далее в цикле проводится вычисление расстояний Махаланобиса по (33) для каждого пикселя от центров кластеров $D1(i,k)$ и $D2(i,k)$, где (i,k) - координаты пикселей (оператор 10). Каждый пиксель проверялся на степень принадлежности к тому или иному кластеру; пиксель алгоритм относит к тому кластеру, расстояние, до центра которого, у него меньше (оператор 11). Если степень принадлежности к первому кластеру оказывалась больше чем ко второму, то добавлялась единица к значению счетчика (оператор 12). После проверки всех пикселей значение счетчика делилось на общее количество пикселей изображения, таким образом, мы получали относительную интегральную оценку (оператор 13). На блок-схеме непропеку соответствует 1-й кластер.

При использовании метода Густафсон-Кесселя точность определения состояния процесса составила почти 95% при использовании 2 кластеров. Похожие результаты были получены и при использовании метода С-средних. Однако, серьезно усложнился алгоритм обработки результата кластеризации.

Преимуществом этого метода задания настроечных параметров является снижение влияния человеческого фактора: образцы готовятся опытными агломератчиками высокой квалификации. Недостатком этого метода является

необходимость иметь такие образцы при каждом изменении характеристик исходного сырья (шихты и топлива).

Таким образом, в подсистему диагностики подаётся процент соответствия изображения кластеру с нарушением.

Если квалификация агломератчика достаточно высока, он может, не приготавливая эталонные образцы, просто указать на рабочем изображении с камеры системе точки, соответствующие нормальному состоянию «пирога» и непропеку.

Назначение третьей камеры - определять относительную долю зоны горения на изломе агломерационного пирога (рисунок 3.7). При нормальном ходе процесса площадь зоны горения должна составлять $1/3$ от общей площади излома аглоспека для машин без зоны стабилизации и $1/5$ - для машин с зоной стабилизации [87], передний фронт горения (нижняя граница) должен подойти к постели. При низкой реакционной способности и крупности топлива площадь зоны горения больше нормы, фронт горения достигает постели и наблюдается отставание заднего фронта горения (верхняя граница). И наконец, при высокой реакционной способности топлива зона горения сужается за счет снижения ее верхней границы.

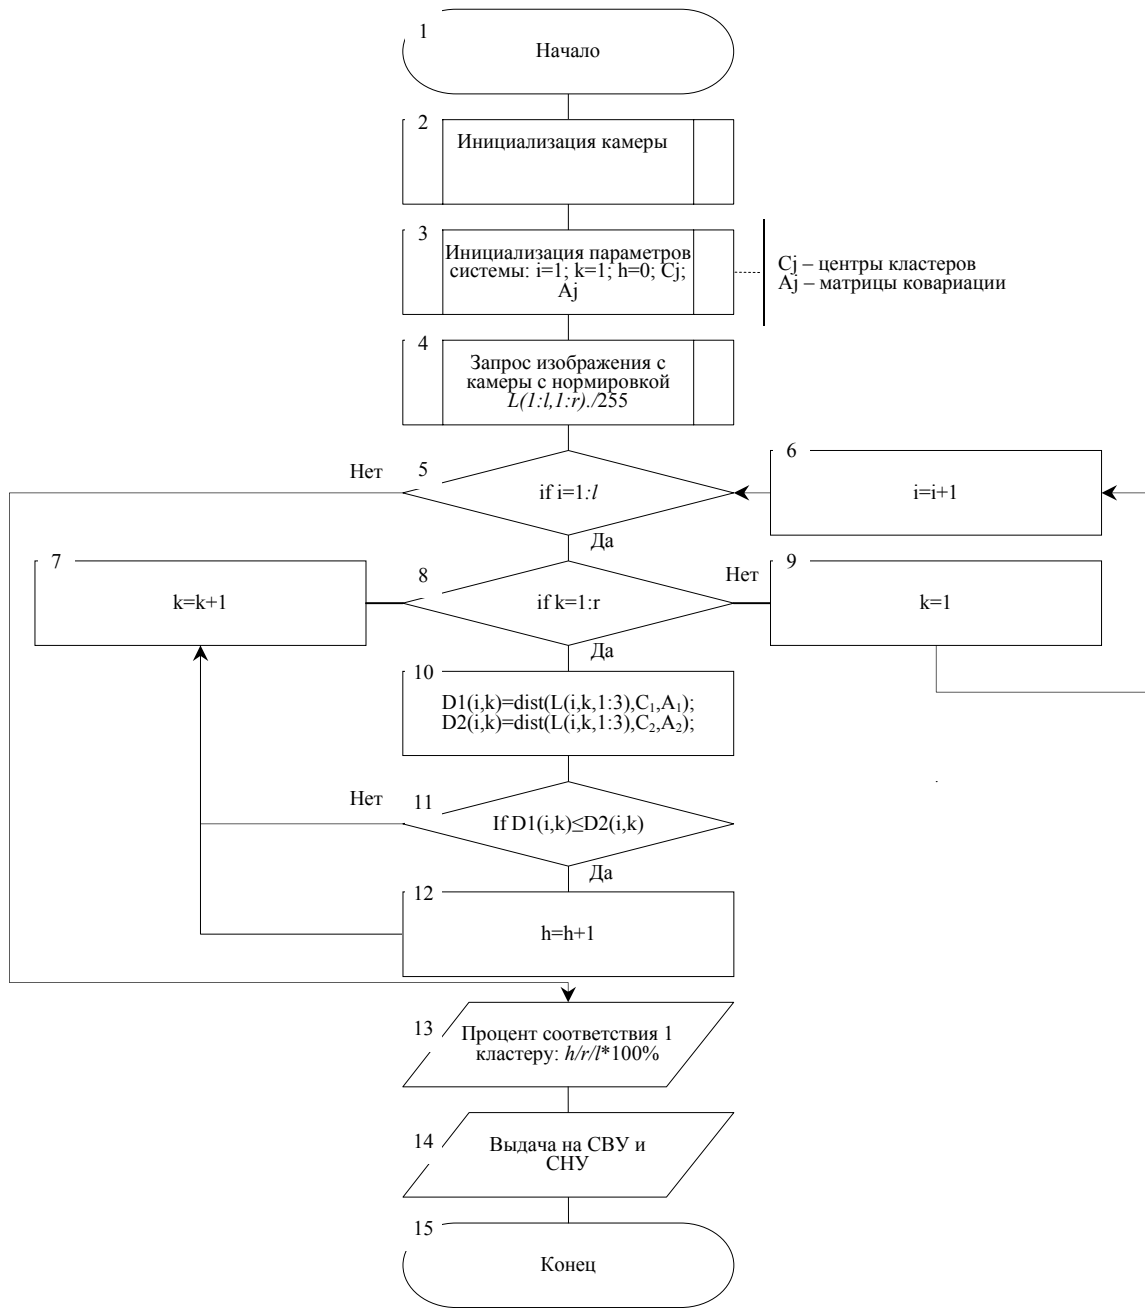


Рисунок 3.6 – Блок-схема алгоритма обработки изображения со второй камеры




Рисунок 3.7 – Положение зоны остаточного горения на изломе агломерационного пирога при нормальном ходе процесса (вверху) и при низкой (в середине) и высокой (внизу) реакционной способности топлива [3]

На полученном с камеры изображении оцениваются геометрические характеристики различных по температуре зон (а именно зон высоких и средних температур). Для этого производится поиск их границ. Задача выделения высокотемпературной зоны остаточного горения от остальной части изображения осложняется наличием зоны переднего и заднего фронтов горения с промежуточными интенсивностями. Так как процесс спекания шихты осуществляется с одинаковой скоростью относительно поверхности агломерата, то можно сделать допущение, что границы температурных зон можно провести параллельно поверхности агломерата. Для выделения этих зон решено использовать вычисление матожидания и СКО по столбцам массива изображения, что соответствует поперечному сканированию изображения излома аглоспека (перпендикулярно зоне горения). На основании полученных данных, кадр разделяется горизонтально (параллельно поверхности

агломерата) на 5 зон (1 - прогоревшая шихта, 2 - задний фронт, 3 - зона горения, 4 - передний фронт, 5 зона - не прогоревшая шихта).

На рисунке 3.8 показаны графики нормированных значений математического ожидания и СКО интенсивности пикселей для двух изображений излома пирога рисунка 3.7, соответствующих нормальному ходу процесса и недопеку из-за низкой реакционной способности топлива.

На графиках нормального хода процесса четко просматриваются зона горения и передний и задний фронты. По расстояниям между пиками СКО можно судить о ширине зон, а зная их длину - об относительной площади зоны горения и ее фронтов.




Рисунок 3.8 – Графики нормированных значений математического ожидания интенсивностей (пунктир) и СКО (сплошная линия) при сканировании изображения излома аглоспека в поперечном направлении при нормальном ходе процесса (а) и недопеке (б)

При недопеке зона переднего фронта практически сливается с зоной горения (рисунок 3.8б). Промежуточный пик между началом заднего фронта и зоной горения по-видимому объясняется наличием языков пламени в непрогоревшей шихте. Довольно высокий уровень базисной линии объясняется наличием факторов, вызывающих перераспределение яркостей на изображении. Это, прежде всего, рассеивание светового излучения на частицах пыли, световые вспышки от ломающегося при сходе с паллеты агломерата, блики от конструктивных элементов

машины и т.п. Поэтому при обработке вводится некоторый порог, отсекающий явно шумовой уровень.

Тем не менее из графиков рисунка 3.8 следует, что границы интересующих зон просматриваются достаточно четко. Блок-схема алгоритма обработки изображения с третьей камеры приведена на рисунке 3.9. Инициализация алгоритма аналогична подобной процедуре для второй камеры. Далее в цикле производится вычисление математического ожидания и СКО интенсивностей пикселей по столбцам массива, что соответствует поперечному направлению по отношению к излому аглоспека (операторы 6 и 7). Далее вычисляются площади зон и их положение. На основании полученной геометрии система диагностики делает вывод о ходе процесса (оператор 13). Если скорость горения низкая, то зона горения будет смещена вверх и наоборот, а наличие широких переходных зон говорит о низкой теплопроводности материала, вызванной его чрезмерной измельченностью и т.д.

Для поиска максимумом пиков можно воспользоваться методами, применяемыми при обработке выходных сигналов спектральных аналитических приборов [88]. Далее определялись параметры зон и их площади (оператор 13). Вся информация подается на входы СВУ и соответствующей СЧУ, а также на монитор алгомератчика.

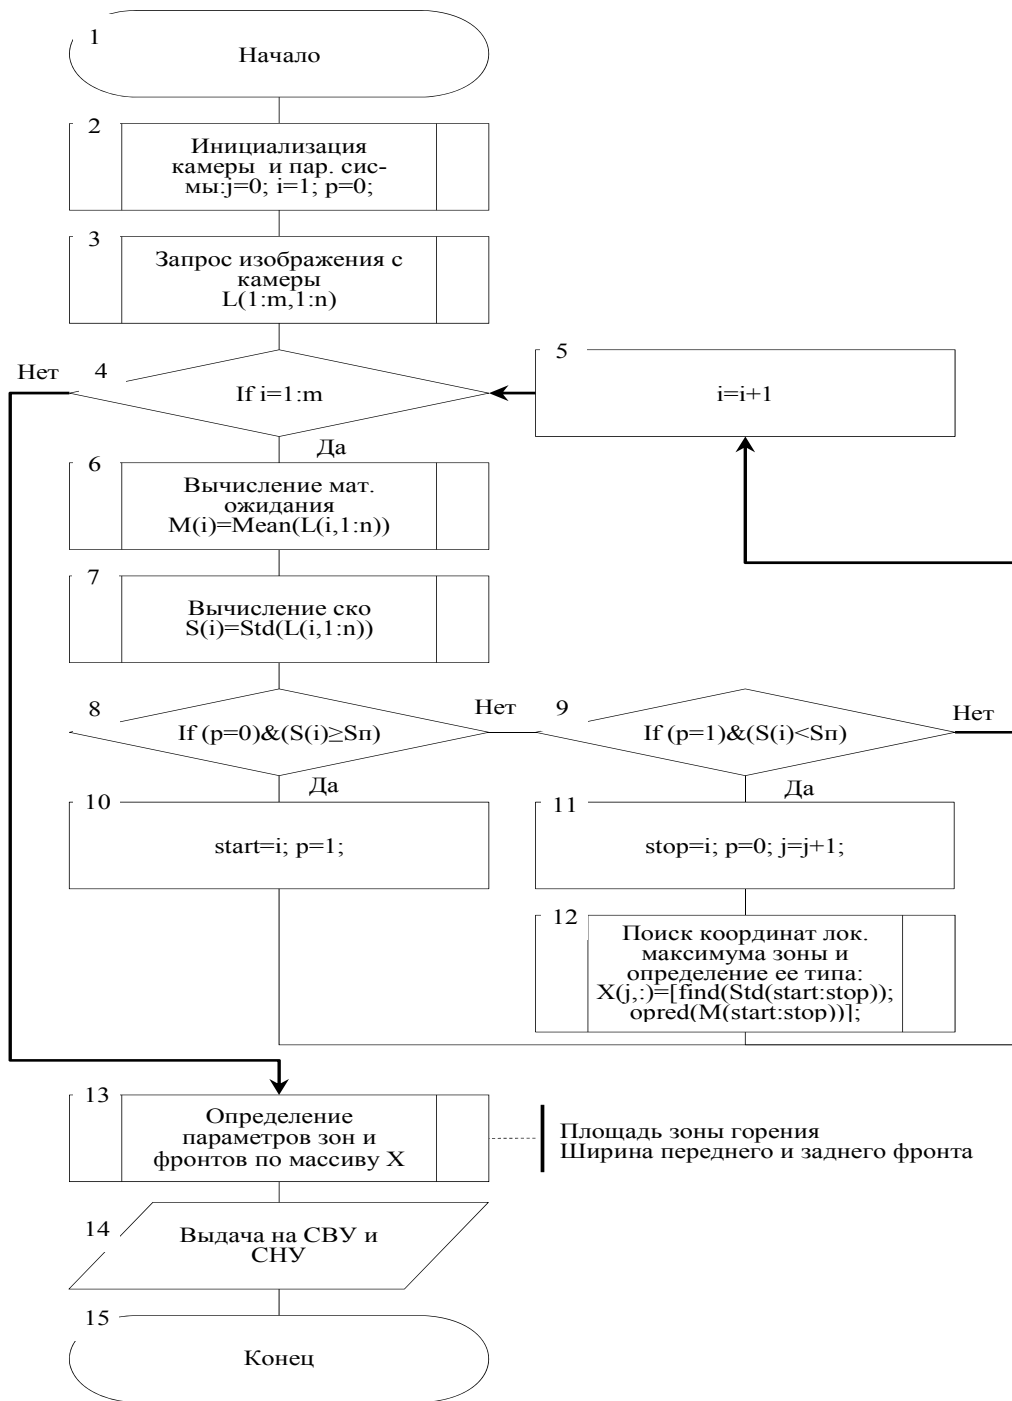


Рисунок 3.9 – Блок-схема алгоритма обработки изображения с 3-й камеры

3.4 Алгоритм работы СОУ

Работа системы оперативного управления включает работу системы мониторинга и работу системы диагностики.

Мониторинг производится следующим образом. Сначала формируется модель МГК на основе предварительно подготовленных данных для нормального состояния процесса, для модели вычисляются пороги для статистик Q и T^2 . Затем каждый новый вектор (выборка данных процесса) проецируется на главные компоненты модели, новые значения статистик Q и T^2 сравниваются с прежними пороговыми значениями. Если нарушения не обнаружены, процедура продолжается, при обнаружении нарушения запускается работа подсистемы диагностики.

Алгоритм работы подсистемы диагностики является одноэтапным с предварительным этапом, включающим подготовку данных, формирование обучающих массивов, обучение сети верхнего уровня и обучение сетей нижнего уровня.

Предварительный этап СОУ представлен на рисунке 3.10; основной этап представлен на рисунке 3.11.

На модуль предварительной обработки (операторы 1-4, рисунок 3.10) возлагается функции выборки данных из базы данных SCADA-системы АСУТП процесса и формирование обучающих массивов для СНУ и СВУ. Эти массивы подвергаются предварительной обработке (операторы 3 и 4), но далее разделяются и используются для обучения сетей диагностической модели каждый для «своей» сети.

При этом оказалось, что для устойчивой работы сети, во-первых, желательно выполнить предварительную фильтрацию исходных данных. Для этого был использован комбинированный фильтр из скользящей медианы и фильтра экспоненциального сглаживания (оператор 3). Первый позволяет отфильтровывать короткие выбросы, а второй – производить достаточно эффективное подавление флуктуационных шумов:

Алгоритм скользящей медианы реализует следующее выражение.

$$x_i^* = med(x_{i-k}), k = [0, 2m] \quad (37)$$

Под медианой $med X$ понимается значение среднего члена вариационного ряда, т.е. упорядоченной выборки, расположенной в порядке возрастания членов. Значение медианы выборки X объема $(2m+1)$ может быть приписано любому отсчету выборки, обычно последнему (при поступлении $(2m+1)$ -го отсчета первый отсчет

отбрасывается).

Фильтр экспоненциального сглаживания включается после фильтра медианы и реализует выражение:

$$x_i^* = (1 - \gamma)x_{i-1}^* + \gamma x_i \quad (38)$$

где x_i^* и x_{i-1}^* - сглаженные значения сигнала на i и $i-1$ шагах расчета, x_i - измеренные значения параметра, $\gamma \in [0, 1]$ - коэффициент, управляющий работой фильтра (чем меньше значение γ , тем лучше сглаживание, но больше искажения сигнала, поэтому обычно принимают $\gamma = 0,3-0,6$).

Кроме того, так как используется преобразование исходных данных для СВУ методом главных компонент, то, во-первых, необходимо ввести нормировку этих данных на нулевое среднее и единичную дисперсию. Это позволяет представить размерные переменные в безразмерном виде. Те же данные, которые подаются на СНУ также необходимо привести к безразмерному виду, например, делением на максимальное значение или аналогично предыдущему преобразовать их к нулевому среднему и единичной дисперсии (оператор 4).

Во-вторых, необходимо предотвратить ситуацию, когда сеть теряет опознанную причину из-за отсутствия результатов действий оператора, т.е. когда ситуация продолжает развиваться. Для этого при изменении технологического параметра Q в диапазоне от нижнего предельного значения Q^{\min} до верхнего Q^{\max} вводятся ограничения:

$$x_i = \begin{cases} -Q_{\min} & \text{при } Q \leq Q^{\min} \\ Q & \text{при } Q \in [Q^{\min}, Q^{\max}] \\ Q_{\max} & \text{при } Q \geq Q^{\max} \end{cases} \quad (39)$$

Эта операция также возлагается на оператор 4.

Далее операторы 5 и 8 производят выборки преобразованных обучающих массивов для обучения сетей СВУ и СНУ.

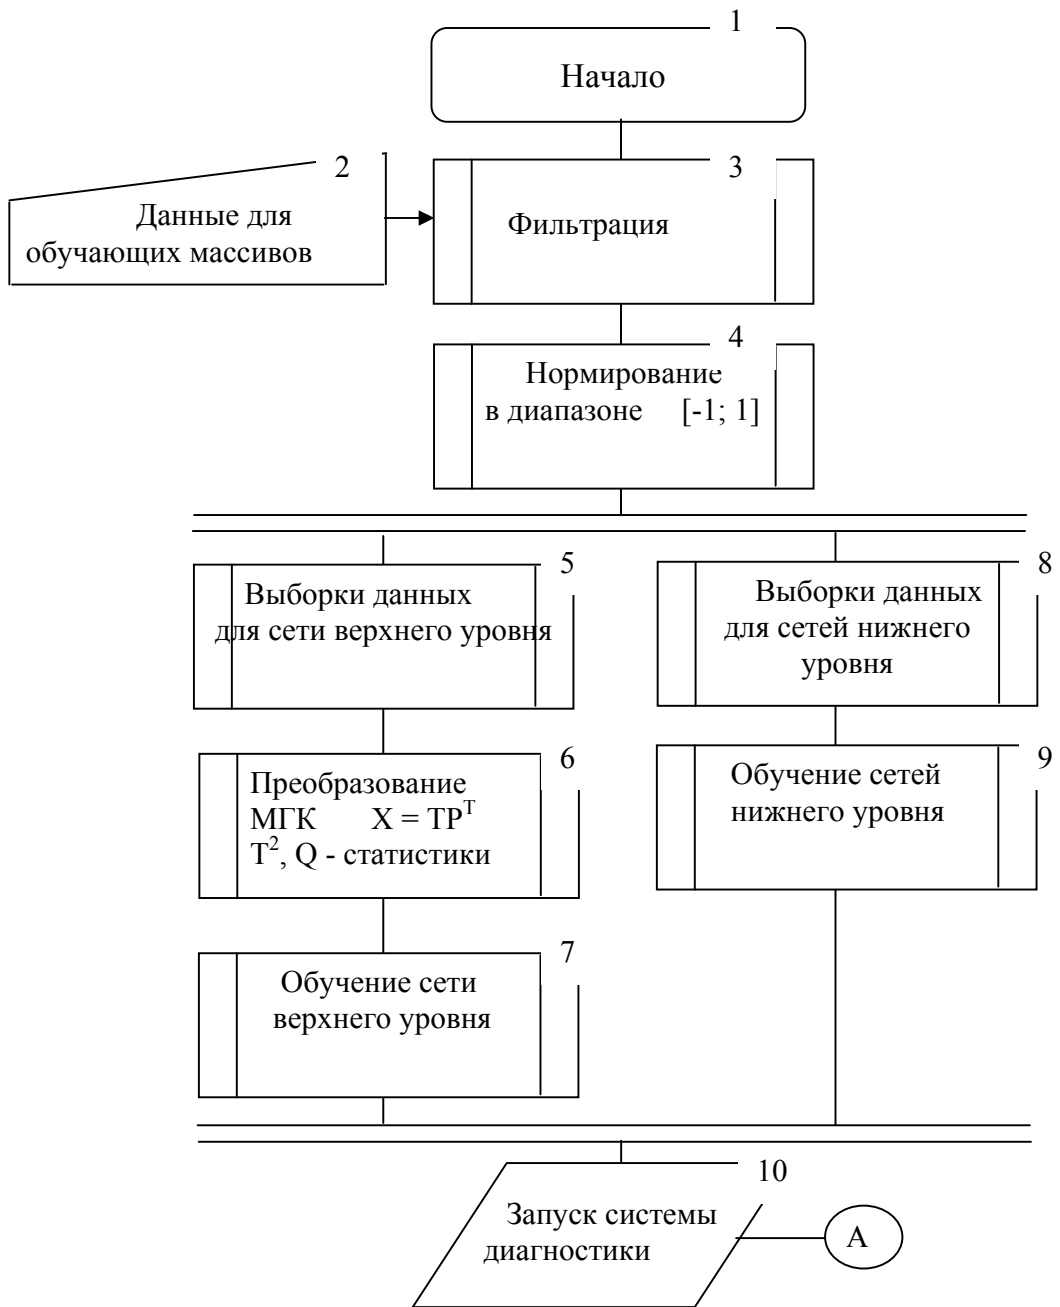


Рисунок 3.10 – Алгоритм работы подсистемы диагностики на подготовительном этапе

Для обучения сети СВУ соответствующий обучающий массив подвергается МГК-преобразованию (оператор 6). При этом формируется и запоминается матрица P из q главных компонент (их число определяется по критерию (23) (п.3.1.1)). Как уже было сказано ранее, МГК-преобразование производится для вычисления статистик T^2

и Q , также для снижения размерности сети верхнего уровня, без существенных потерь нужной информации.

Сети СНУ - это обычные трехслойные персептроны и обучаются методом обратного распространения ошибки.

После завершения обучения диагностическая модель готова к работе. При запуске системы диагностики производится считывание текущего вектора данных и его обработка (операторы 2-4 на рис.3.11), аналогичная обработке данных на этапе обучения (СВУ начинает работать только в случае обнаружения нарушения статистиками T^2 или Q). При этом компоненты нормированного вектора текущих значений переменных процесса должны быть распределены на соответствующие входы сетей диагностической модели. Данные, подаваемые на входы СВУ (оператор 6) предварительно проецируются в пространство главных компонент (вычисление счетов - оператор 5; а данные на сети СНУ передаются на их входы (оператор 9) непосредственно.

Сеть СВУ (оператор 6) работает, реализуя локализацию нарушения, т.е. определяя ситуацию, возникшую на процессе. Выходы нейронов СВУ сравниваются с пороговыми значениями γ (оператор 7), значения которых выбираются эмпирически. Если они будут велики (близки к 1), то нарушения будут определяться с большим запаздыванием, когда они разовьются до нежелательных пределов. Кроме того, могут быть пропущены малые нарушения. При малых порогах увеличивается число ложных обнаружений. Эксперимент показал, что удовлетворительная работа системы достигается при $\gamma=0,65-0,75$. При этом для разных ситуаций могут быть установлены разные значения порогов γ , с учетом важности пропуска нарушения для данной ситуации.

Каждый выход СВУ связан с разрешающим входным нейроном соответствующей СНУ (оператор 8). При определении ситуации эта сеть запускается и по выходным значениям ее нейронов определяется нарушение, явившееся её причиной.

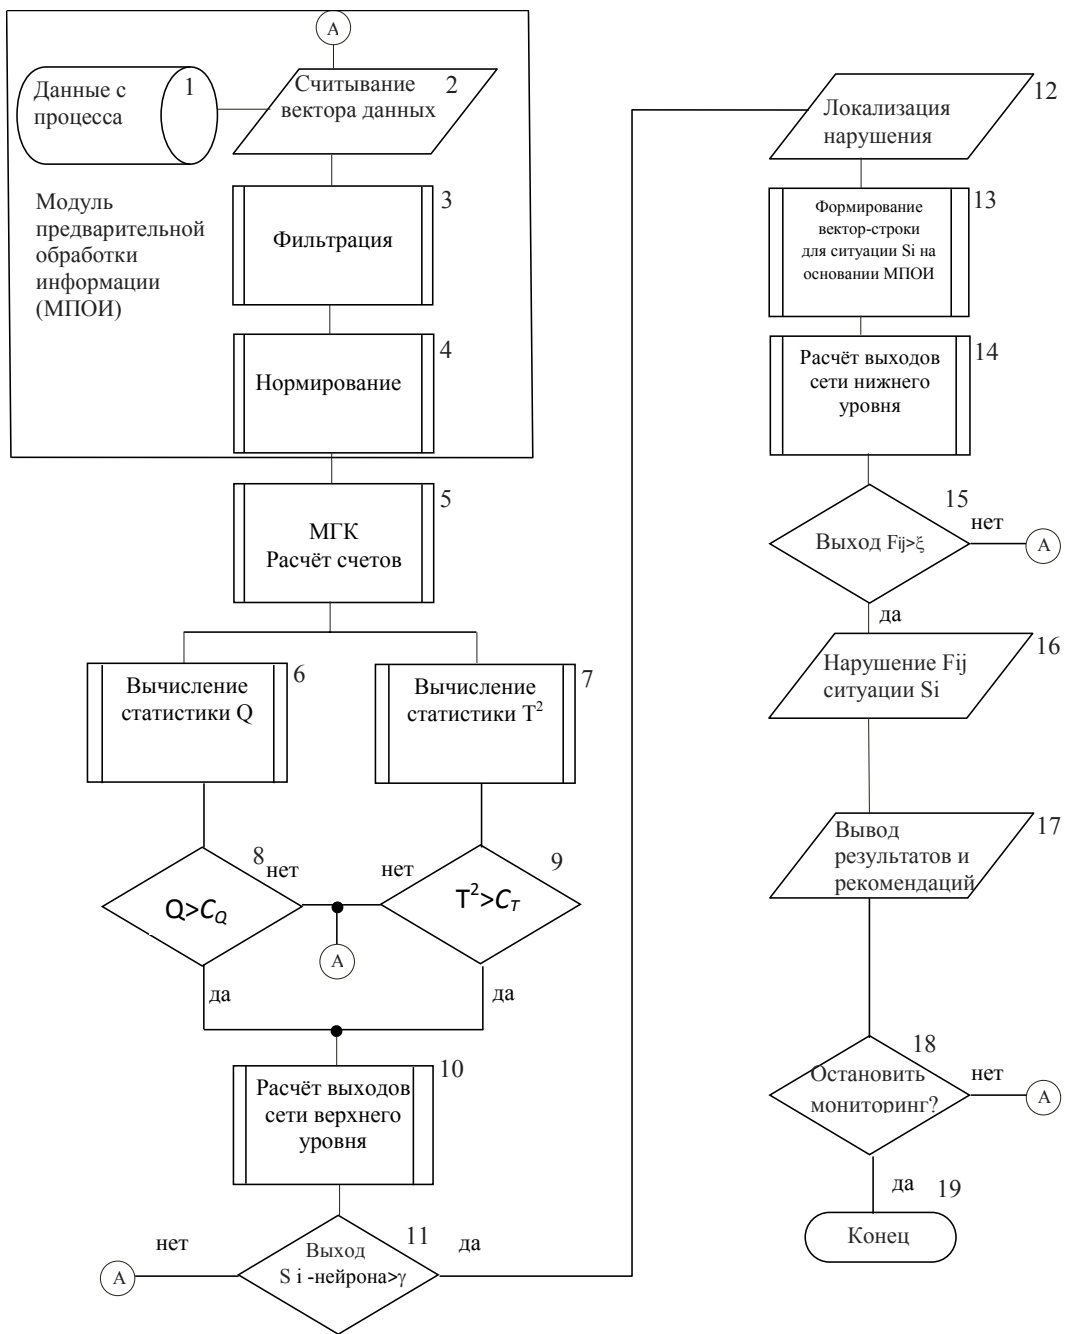


Рисунок 3.11 – Алгоритм работы системы на рабочем этапе

Нарушение считается идентифицированным при превышении выходом соответствующего нейрона порога ξ , введенного скорее для удобства оператора. Если порог ξ будет мал, то диагноз будет неоднозначным - будет показано несколько возможных причин нарушения и оператору потребуется дополнительно анализировать ситуацию для определения действительной причины нарушения. При

высоком пороге ξ система может не найти причину, например, из-за существенного отклонения диагностических показателей в данной реализации ситуации от их значений для этой ситуации в обучающем массиве. Значения ξ выбираются в диапазоне $\xi=0,7-0,9$ и также могут варьироваться оператором в зависимости от влияния данного нарушения на процесс и качество выходного продукта. Выходы СНУ передают информацию оператору о результатах диагностики и рекомендации по действиям по возврату процесса в регламентный режим.

3.5 Выводы по 3-й главе

1. На основании аналитического обзора возможных типов ДМ, проведенного в предыдущей главе, обоснован выбор для разрабатываемой системы нейросетевой модели. При этом для устранения существенного недостатка нейросетевых моделей для сложных процессов большой размерности - недопустимо большого времени обучения и переобучения (что особенно важно при работе в реальном времени) в ДМ введена иерархия, что позволяет снизить размерность используемых в ДМ нейронных сетей.

2. Введение иерархии предполагает наличие декомпозиции объекта или множества возможных ситуаций, которые могут возникнуть на объекте в процессе его работы. Показана целесообразность для процесса агломерации декомпозиции именно по множеству возможных ситуаций (по функциональному признаку).

3. Для обнаружения факта наличия нарушения на процессе используются статистики T^2 и Q , характеризующие изменения процесса, объясняемые и необъясняемые моделью метода главных компонент МГК, для которых известны пороговые значения. Если хотя бы одна из статистик превысит своё пороговое значение, то фиксируется факт нарушения. МГК используется также для еще большего снижения размерности входного вектора для сети верхнего уровня СВУ ДМ, что позволяет снизить избыточность в исходных данных без существенных потерь информации. На этапе обучения сети строится МГК-модель, определяется число главных компонент, объясняющих 90-95 % исходной дисперсии, а на входы

СВУ затем подаются проекции нормированных текущих векторов переменных с процесса агломерации.

4. После обнаружения нарушения начинает работать подсистема диагностики. При этом на СВУ возлагается функция определения ситуации, к которой относится обнаруженное нарушение; а на сети нижнего уровня СНУ - функция идентификации причины нарушения. При этом, т.к. размерности СНУ невелики, то дополнительного снижения размерности здесь не требуется.

5. Для получения информации о ситуациях на процессе был выбран комбинированный метод сбора экспертной информации с привлечением текстологического его варианта на начальной стадии (изучении регламента и литературы по процессу) и с использованием прямого контакта с экспертами для систематизации полученной информации (в качестве экспертов выступали операторы - агломератчики - 3 специалиста).

6. В результате декомпозиции на процессе выделено 9 ситуаций, вызванных нарушениями технологического характера. Анализ симптомов (диагностических показателей), сопровождающих эти нарушения, показал, что не все они снабжены автоматической измерительной аппаратурой, позволяющей контролировать их значения в режиме он-лайн; часть симптомов определяется лабораторно, часть определяется непосредственно оператором «на-глаз». Для устранения этого недостатка и для повышения глубины диагностики разрабатываемой системы предложено ввести для этих симптомов три цифровых оптических камеры.

7. Рекомендованы места установки камер: за зажигательным горном в районе 5-6 вакуум-камер для контроля равномерности температур по ширине аглоленты - инфракрасная камера; над зоной охлаждения агломерата для контроля состояния агломерата по его цвету - цветная камера и в смотровом окне у конца аглоленты для контроля площади горения на изломе «пирога» для контроля зоны горения на изломе аглоспека - еще одна инфракрасная камера.

8. Разработаны алгоритмы обработки изображений камер. При этом алгоритм обработки изображения первой камеры работает на сравнении средних по зонам, выделенным по ширине и длине аглоленты. Алгоритм обработки изображений второй камеры производит на этапе обучения нечеткую кластеризацию с выделением

двух кластеров - нормы и недопека с последующим отнесением пикселей текущего изображения к тому или иному кластеру по значениям расстояний Махаланобиса от вектора интенсивностей пикселя до центров кластеров. Алгоритм обработки изображения третьей камеры производит сканирование изображения в направлении толщины агломерационного пирога с вычислением математического ожидания и СКО интенсивностей пикселей. Показано, что по пикам графика СКО с контролем по графику математического ожидания можно уверенно определять параметры зоны остаточного горения и ее фронтов.

9. Разработана блок-схема алгоритма работы системы при обнаружении ситуаций и идентификации нарушений. На предварительном этапе - этапе обучения, формируются обучающие массивы и производится обучение сетей ДМ; на основном этапе - производится собственно мониторинг и диагностика.

10. Подготовка исходных данных включает фильтрацию с использованием комбинированного фильтра из фильтров скользящей медианы и экспоненциального сглаживания и нормирование данных.

11. В рабочем режиме на вход сети СВУ подаются проекции текущего вектора переменных процесса на главные компоненты. Выходы нейронов СВУ сравниваются с эмпирическими пороговыми значениями γ , которые могут варьироваться с учетом важности и опасности данной ситуации (типовое значение порога $\gamma=0,65-0,75$).

12. Нарушение считается идентифицированным сетью СНУ при превышении выходом соответствующего нейрона порога ξ , введенного для удобства оператора: при превышении порога $\xi=0,7$ нарушение считается возможным и требует привлечения внимания оператора; при превышении порога $\xi=0,9$ причина считается выявленной и оператору выдается соответствующая информация и рекомендации по устранению выявленной ситуации.

ГЛАВА 4 Экспериментальное исследование системы оперативного управления

4.1 Порядок исследования

Разрабатываемое алгоритмическое обеспечение системы оперативного управления процессом агломерации предназначено для интегрирования в существующую АСУТП. Для экспериментального исследования работоспособности предлагаемой структуры системы оперативного управления были выполнены следующие операции:

- сформированы обучающие массивы;
- разработана методика моделирования нарушений;
- произведена предварительная обработка обучающих массивов;
- сформированы нейронные сети обоих уровней;
- исследованы алгоритмы обработки изображений с камер;
- проведено тестирование работы системы на реальных данных.

4.2 Описание структуры программного обеспечения для исследования системы, разработанного в среде MATLAB

Для выполнения работ по имитационному моделированию и исследованию нейросетевого подхода для диагностики состояния процессов не существует единой оптимальной среды моделирования. В данной работе предпочтение отдано системе MATLAB 2013, т.к. в ее составе есть пакет NNTOOL.

Графический интерфейс этого пакета позволяет, не обращаясь к командному окну системы MATLAB, генерировать сети прямого распространения, выполнять создание, обучение, моделирование, а также импорт и экспорт нейронных сетей и данных, используя только инструментальные возможности GUI-интерфейса.

В языке MATLAB имеются файлы двух типов: так называемые Script-файлы (файл-сценарии, или управляющие программы) и файл-функции (процедуры). При помощи Script-файлов оформляются основные программы, управляющие от начала до конца организацией всего вычислительного процесса, и отдельные части основных

программ. Как файл-функции оформляются отдельные процедуры и функции (т.е. такие части программы, которые рассчитаны на неоднократное использование Script-файлов или других процедур при изменяемых значениях входных параметров и не могут быть выполнены без предварительного задания значений переменных, которые называют входными). Файл-функции или Script-файлы также называют М-файлами.

В состав системы MATLAB входит пакет моделирования динамических систем — Simulink 8.2. Для построения функциональной блок-схемы моделируемых устройств Simulink имеет обширную библиотеку блочных компонентов и удобный редактор блок-схем. Он основан на графическом интерфейсе пользователя и по существу является типичным средством визуально-ориентированного программирования. Важное достоинство Simulink — это интеграция не только с системой MATLAB, но и с рядом других пакетов расширения.

В пакете MATLAB имеется рабочая область, в которой хранятся: массивы исходных данных, сформированный обучающий массив, структуры обученных нейронных сетей, тестовые массивы. Гибкая структура пакета MATLAB делает доступной эту область разным рабочим программам.

Подготовка исходных данных осуществляется в М-файле NNMas3.m. Обучающие и тестовые массивы для каждой из сетей верхнего и нижнего уровней формируются в М-файлах NS_0.m и NS_1.m соответственно. Разработка нейронных сетей выполняется во встроенном пакете NNTOOL, который позволяет задавать произвольную структуру сетей прямого распространения, выбрать алгоритм обучения и экспортировать структуру и матрицы весовых коэффициентов в рабочую область. Отладка отдельных элементов иерархии нейросетевой структуры выполняется в пакете Simulink. Результаты моделирования выводятся в виде трендов на экран.

4.3 Подготовка исходных данных

Исследование системы проводилось методом имитационного моделирования на массиве реальных данных. Для исследования использованы статистические данные аглофабрики №2 одного из отечественных предприятий. Данные получены с

процесса 21 и 22.04.2012г, дискретность измерений – 30 секунд. В итоге сформированы 2 исходных массива данных по 100 измерений каждый.

Согласно таблице 3.1 выделено 26 нарушений, которые сгруппированы в 9 ситуаций.

Обучающие массивы для сети верхнего уровня должны быть составлены с учетом предварительной подготовки данных:

- из общего массива данных с процесса выбирается массив, содержащий определяющие диагностические параметры для СВУ;
- по результатам предварительного анализа данных при необходимости выполняется их фильтрация;
- при моделировании нарушений устанавливалась зона отклонения по соответствующим параметрам, в которую попадают значения и пороги, установленные разными экспертами.
- полученные значения проецируются на матрицу ГК с целью получения счетов.

Формирование ГК требует также набора статистических данных, соответствующих нормальному состоянию процесса. По этому массиву определяются координаты главных компонент, их число и пороги для статистик T^2 и Q , используемые для обнаружения факта возникновения нарушения. Кроме того, должен быть также сформирован массив, содержащий все известные нарушения. Он проецируется в пространство главных компонент и используется для обучения сети верхнего уровня.

Для каждой сети нижнего уровня требуется сформировать свой массив данных представляющий собой набор отфильтрованных и нормированных значений.

Из всего набора статистических данных были выбраны те переменные, по изменению которых можно судить о возникновении ситуации – диагностические параметры для СВУ:

1. Скорость движения агломашины ($V_{\text{АГЛ}}$);
2. Температура зажигания горна ($T_{\text{ГОР}}$);
3. Массовый расход топлива ($M_{\text{ТОП}}$);

4. Массовая доля возврата ($M_{\text{ВОЗВ}}$);
5. Массовая доля извести ($M_{\text{ИЗВ}}$);
6. Температура в 9 вакуум-камере ($T_{\text{В/К9}}$);
7. Температура в 10 вакуум-камере ($T_{\text{В/К10}}$);
8. Массовая доля углерода в шихте ($M_{\text{УГЛ}}$);
9. Влажность шихты ($W_{\text{ШИХ}}$);
10. Массовая доля углерода в возврате шихты ($M_{\text{УГЛ/ВОЗВ}}$);
11. Массовая доля возврата в шихте ($M_{\text{ВОЗВ/ШИХ}}$);
12. Массовая доля FeO в агломерате (M_{FeO});
13. Массовая доля низкокалорийного топлива ($M_{\text{НИЗК.ТОП}}$);
14. Температура в каждой вакуум-камере ($T_{\text{В/К11}}$);
15. Разрежение в 9 вакуум-камере ($P_{\text{В/К9}}$);
16. Разрежение в 10 вакуум-камере ($P_{\text{В/К10}}$);
17. Разрежение в 11 вакуум-камере ($P_{\text{В/К11}}$);
18. Давление воды ($P_{\text{В}}$);
19. Разрежение под колосниковой решёткой ($P_{\text{КР}}$);
20. Высота слоя шихты (H);
21. Температура агломерата на выходе ($T_{\text{АГЛ}}$);
22. Доля мелких фракций в шихте;
23. Результаты обработки изображений с камеры №1: Постоянство температуры по ширине ленты (согласно п.3.3.2 настоящей работы);
24. Результаты обработки изображений с камеры №2: Цвет поверхности «пирога» (согласно п.3.3.2 настоящей работы);
25. Результаты обработки изображений с камеры №3: Цвет излома агломерата (согласно п.3.3.2 настоящей работы);

При этом часть параметров измеряется лабораторно.

При формировании обучающих массивов для сетей СНУ учитывались симптомы нарушений, включенных в ту или иную ситуацию, соответственно таблице 3.1.

Тогда для ситуации S1 должны быть в массиве учтены следующие переменные:

1. Температура горна ($T_{\text{ГОР}}$);
2. Влажность шихты ($W_{\text{ШИХ}}$);
3. Массовая доля углерода в возврате шихты ($M_{\text{УГЛ/ВОЗВ}}$);
4. Массовая доля низкокалорийного топлива ($M_{\text{НИЗК.ТОП}}$);
5. Скорость движения агломашины ($V_{\text{АГЛ}}$);

Для ситуации S2:

1. Массовая доля возврата в шихте ($M_{\text{ВОЗВШИХ}}$).

Для ситуации S3:

1. Результаты обработки изображений с 1, 3-й камер (согласно п.3.3.2 настоящей работы).

Для ситуации S4:

1. Выход возврата ($M_{\text{ВОЗВ}}$);
2. Массовая доля углерода ($M_{\text{УГЛ}}$);
3. Массовая доля FeO в агломерате (M_{FeO});
4. Массовая доля низкокалорийного топлива ($M_{\text{НИЗК.ТОП}}$);
5. Влажность шихты ($W_{\text{ШИХ}}$);
6. Высота слоя шихты H ;
7. Температура агломерата $T_{\text{АГЛ}}$;
8. Массовая доля топлива $M_{\text{ТОП}}$;

Для ситуации S5:

1. Результаты обработки изображения со 2-й камеры (согласно п.3.3.2 настоящей работы).

Для ситуации S6:

1. Температура горна ($T_{\text{ГОР}}$);
2. Массовый расход топлива ($M_{\text{ТОП}}$);
3. Выход возврата ($M_{\text{ВОЗВ}}$);
4. Масса извести ($M_{\text{ИЗВ}}$);
5. Влажность шихты ($W_{\text{ШИХ}}$);
6. Остаточная доля углерода в возврате ($M_{\text{УГЛ/ВОЗВ}}$);
7. Массовая доля мелких фракций (результаты гранулометрического анализа);

8. Разрежение под колосниковой решёткой ($P_{кр}$).

Для ситуации S7:

1. Давление воды (P_B);
2. Влажность шихты ($W_{ших}$).

Для ситуации S8:

1. Скорость движения агломашины ($V_{агл}$);
2. Массовый расход топлива ($M_{топ}$);
3. Влажность шихты ($W_{ших}$);
4. Температуры в 10-11 вакуум-камерах ($T_{в/к10-11}$);

Для ситуации S9:

1. Результаты обработки изображения со 1-й камеры (согласно п.3.3.2 настоящей работы).

Подготовка исходных данных, которые в дальнейшем будут использоваться для обучения сетей верхнего и нижнего уровней осуществляется в специально разработанном М-файле NNMas3.m.

Предварительный анализ исходных данных показал, что практически все сигналы сильно зашумлены с преобладанием высокочастотной составляющей шума, поэтому для устойчивой работы системы необходимо ввести предварительное сглаживание данных, т.к. в противном случае количество ложных срабатываний существенно возрастает. Хотя в процентном отношении по большинству переменных шумы не особенно заметны, однако, по некоторым основным параметрам, таким как температура в вакуум-камерах и разрежение в вакуум-камерах они значимы.

Для сглаживания сигналов датчиков был использован комбинированный фильтр из скользящей медианы и фильтра экспоненциального сглаживания. Первый фильтр позволяет отфильтровывать не очень протяженные выбросы, а второй – производить достаточно эффективное подавление флуктуационных шумов.

Алгоритм работы данных фильтров рассматривался ранее в главе 3 настоящей работы. Результат фильтрации для параметра «Температура зажигания горна» приведён на рисунке 4.1.




Рисунок 4.1 – Результат фильтрации для параметра «Температура зажигания горна» (Сплошная линия – до сглаживания; после работы фильтра – пунктирная).

Анализ исходных данных на предмет наличия в них динамики развития нарушений показал, что практически все данные соответствуют нормальному режиму функционирования процесса. По этим данным после сглаживания и нормирования на нулевое среднее и единичную дисперсию был построен первый массив, используемый, как уже отмечалось выше, для построения МГК-модели. Он позволил получить координаты главных компонент, определить их количество и пороговые значения для статистик T^2 и Q для проведения мониторинга процесса.

Что касается второго массива, по которому необходимо было обучить СВУ, то достать данные, соответствующие нарушениям не удалось из-за их закрытости. Поэтому были привлечены эксперты, и полученная от них информация послужила основой для моделирования нарушений наложением возмущений соответствующего вида на нормальные данные с процесса. Таким образом, развитие нарушений моделировалось искусственно путем наложения на реальные данные необходимых

возмущений. Сложность состояла в оценке скорости развития тех или иных ситуаций, т.к. абсолютно полной информации по этому вопросу по результатам экспертного опроса получено не было. Поэтому развитие ситуаций строилось инвариантно по отношению к конкретной временной шкале, но с учетом рекомендаций экспертов. Соответственно, в качестве единиц времени указываются не конкретные временные единицы, например, минуты, а шаги.

В результате был сформирован специальный массив данных, использующий матрицы настроечных параметров для задания развития возмущений, имитирующих соответствующие нарушения, включая также состояния работы установки в нормальном режиме. При обучении сети верхнего уровня на полученный базис из главных компонент проецировались вектор-строки обучающего массива, а при работе системы – текущие векторы данных с процесса.

При моделировании учитываются следующие условия: регулируемые параметры изменяются медленнее, чем нерегулируемые в силу маскировки этого процесса работой системы регулирования; изменение давления более динамичное, чем протекание теплообменных процессов; учитываются причинно-следственные влияния; оценивается территориальное расположение отдельных узлов агломашины.

Для каждого нарушения в соответствии с таблицей 3.1 моделировалось опытным путём изменение параметров. При формировании обучающего массива выбирается диапазон, в данном случае 0-100 шагов, на котором для каждого параметра выполняется моделирование изменения при развитии ситуации. Для каждой ситуации в качестве точки начала развития задан нулевой шаг. При развитии ситуации возмущения налагались на определяющие ситуацию параметры так, чтобы график конкретного параметра пересек пороговое значение данного параметра через определенное количество шагов, определяемое возможной динамикой развития данного нарушения.

Ниже на рисунке 4.2 приведён графический пример моделирования нарушения S1.1 «Неполное пропекание шихты» (относится к ситуации S1 «Нарушение пропекания шихты»). Для данного нарушения согласно таблице 3.1 используются следующие параметры из учитываемых при построении системы диагностики: $T_{ГОР}$ –

№2 на рисунке 4.2 ; $W_{\text{ШИХ}}$ – №9 на рисунке 4.2; $M_{\text{УГЛ/ВОЗВ}}$ – №10 на рисунке 4.2. На рисунке 4.2 показаны параметры при нормальном режиме работы ; также тренды параметров $T_{\text{ГОР}}$, $W_{\text{ШИХ}}$, $M_{\text{УГЛ/ВОЗВ}}$ при аномальном режиме протекания процесса, которые пересекаются с эксплуатационными порогами (горизонтальными пунктирными линиями). В качестве эксплуатационных порогов взяты расчётные значения, которые равны четырём среднеквадратичным отклонениям, что соответствует эксплуатационным порогам, полученным с аглофабрики.




Рисунок 4.2 – Имитация нарушения S1.1 «Неполное пропекание шихты»

Итогом предварительной подготовки исходных данных являются следующие массивы данных, сохранённые в рабочей области MATLAB:

`MACRO_NEURO_INPUT` – входной массив размерностью $[100 \times 25]$, состоящий из 27 подмассивов для 26 нарушений и 1 для нормального состояния процесса; содержит информацию 100 выборок данных с процесса, каждая из которых включает 25 предварительно обработанных значений переменных или параметров процесса.

`MACRO_NEURO_TARGET` – выходной массив желаемых выходов размерностью $[100 \times 10]$, который состоит из значений -1 и 1 (-1 означает что данной ситуации в предъявляемом сети образе нет, а 1 - что ситуация присутствует), для 10 ситуаций (согласно таблице 3.1 выделено 9 ситуаций и 1 ситуация соответствует нормальному ходу процесса). Аналогично массиву `MACRO_NEURO_INPUT` этот массив включает 26 блоков, соответствующих нарушениям и 1 блок, который соответствует нормальному ходу процесса;

MICRO_NEURO_INPUT – массив, который используется в качестве входного массива для сетей нижнего уровня, содержит нужные параметры для конкретной ситуации;

MICRO_NEURO_TARGET – массив, который используется в качестве массива желаемых выходов для сетей нижнего уровня, содержит нужные выходы для конкретной ситуации.

Процесс диагностики нарушений, вызывающих аномальную ситуацию на процессе, включает обнаружение факта возникновения нарушения, его локализацию (определение места возникновения нарушения на процессе), и идентификацию нарушения – определения причины данного нарушения. Первый этап процесса диагностики – обнаружение факта нарушения - реализован посредством построения T^2 и Q статистик. Данные T^2 и Q статистики взаимно дополняют друг друга: если хотя бы одна из них превысит своё пороговое значение, это свидетельствует о нарушении нормального протекания процесса. В случае обнаружения факта возникновения нарушения начинает работать нейросетевая модель: сначала СВУ определяет ситуации, далее начинает работать конкретная СНУ, которая и определит само нарушение.

4.4 Разработка СВУ и СНУ

Сеть верхнего уровня необходима для распознавания проявившейся ситуации. Предварительно исходные данные фильтруются, как указано выше, центрируются и нормируются на единичную дисперсию. Обучающие и тестовые массивы для СВУ формируются в М-файле NS_0.m.

Для оценивания робастности системы к шумам, были созданы три реализации исходных данных с шумами. Обучение системы проходило на данных массивах с шумами.

Матрица нагрузок (координаты главных компонент) P рассчитывается один раз и далее используется для формирования проекций векторов исходных данных в пространство главных компонент и мониторинга состояния процесса. В данной работе

предлагается для реализации МГК использовать сингулярное разложение. Перерасчет матрицы P производится при существенном изменении параметров процесса, например, при существенном изменении состава сырья, используемом для приготовления аглошихты.

Обычно, если q ГК объясняют 90-95% дисперсии исходных переменных, то остальные главные компоненты считаются шумом и игнорируются. Для определения минимального количества ГК, при которых модель МГК будет адекватна, реальной и многомерной системе, был применён критерий (23). При этом число q ГК в модели было принято $q=12$.

Таким образом, определилось число входных нейронов сети СВУ – 12. Число выходных нейронов сети определяется числом ситуаций (в нашем случае – 9).

Для осуществления процедур обучения СВУ массивы `MACRO_NEURO_INPUT` и `MACRO_NEURO_TARGET` были спроецированы в пространство главных компонент полученной МГК-модели. В результате были сформированы два массива с данными для обучения сети СВУ:

1. `MGK_INPUT` – массив, который хранит проекции на главные компоненты (включает 12 множеств счетов – проекций исходных данных в пространство ГК) и информацию о 27 нарушениях процесса (26 нарушений и одна ситуация, соответствующая нормальному ходу процесса);

2. `TARGET` – выходной массив желаемых выходов сети, который состоит из значений -1 и 1 (-1 означает что данной ситуации в предъявляемом сети образе нет, а 1 - что ситуация присутствует).

Была исследована нейронная сеть, которая обучалась по методу обратного распространения ошибки.

Для построения СВУ используется функция MATLAB newff. Рассматривается трехслойная сеть с числом нейронов во входном слое – 12 (число ГК) и числом нейронов в выходном слое – 9 (количество ситуаций согласно таблице 3.1). В качестве функций активации для входного и скрытого слоев сетей приняты сигмоидные функции, а для выходного слоя – линейная функция.

Сеть обучается с использованием алгоритма обратного распространения (метода Левенберга-Марквардта). При обучении были заданы следующие параметры:

epochs = 150 – максимальное количество циклов обучения;

min grad = $1.00e-5$ – минимальное значение градиента.

Рассмотрим формирование СНУ на примере сети, определяющей нарушения, связанные с ситуацией S1 «Нарушение пропекания шихты». Для первой ситуации S1 в соответствии с таблицей 3.1 определены 2 возможных нарушения: S1.1 «Неполное пропекание шихты», S1.2 «Образование расплавленного агломерата», для каждого нарушения найдены диагностические параметры:

S1.1: $T_{гор}$, $W_{ших}$, $M_{угл/возв}$;

S1.2 : $T_{гор}$, $W_{ших}$, $M_{низк.топ}$, $V_{агл}$.

В результате для обучения сети СНУ, связанной с первой ситуацией, были сформированы два массива: массив входных данных, который хранит нормированные и фильтрованные значения перечисленных выше диагностических параметров, и выходной массив желаемых выходов сети, состоящий из значений -1 и 1 (-1 означает что данного нарушения в предъявляемом сети образе нет, а 1 - что нарушение присутствует).

В качестве структуры СНУ была исследована полносвязная сеть прямого распространения – трехслойный персептрон, которая обучалась по методу обратного распространения ошибки. В качестве функций активации для входного и скрытого слоев сетей приняты сигмоидные функции, а для выходного слоя – линейная функция.

4.5 Имитационное моделирование и тестирование ДМ

Для тестирования ДМ используется не обучающий массив с данными от 21.04.2012, а массив с данными от 22.04.2012г.

Характер накладываемых возмущений остается тем же, что и при обучении, но за счет снижения коэффициентов и сдвижки по оси времени изменение отдельных параметров идет асинхронно и медленнее, то есть параметры достигают эксплуатационных порогов в разное время. Процедура отладки ДМ проводилась в пакете Simulink.

Для проверки работы сети в динамике разработана специальная модель в пакете Simulink. Она базируется на блоках нейронных моделей, хранящих матрицы весовых коэффициентов, полученные при обучении СВУ и СНУ. Общая блочно-модульная структура модели представлена на рисунке 4.3.

Схема на рисунке 4.3 включает в себя следующие блоки:

1. блок net0 - модель СВУ;
2. блоки net1, net4, net5, net6, net8, net9 – модели сетей нижнего уровня для распознавания нарушений, относящихся к ситуациям S1, S4, S5, S6, S8, S9 соответственно (в связи с тем, что остальные ситуации имеют в своем составе по одному нарушению, то отдельно сети нижнего уровня для них не выделены; используется соответствующий выход СВУ);
3. блок Process - итерационное считывание вектор-строк из предварительно созданного массива данных (данные после фильтрации и нормирования), расположенного в рабочей области и содержащего входные данные;
4. блок T2+Q – расчёт T^2 и Q статистик для предварительно подготовленных данных (для визуального удобства восприятия на графике, полученные статистики делятся на соответствующие пороговые значения, тем самым контрольные статистики сравниваются не с пороговыми значениями, а с единицей);
5. блок GK – блок перехода предварительно подготовленных данных в пространство ГК;

6. блоки S1, S4, S5, S6, S8, S9 – блоки выборки соответствующих параметров для сетей нижнего уровня.

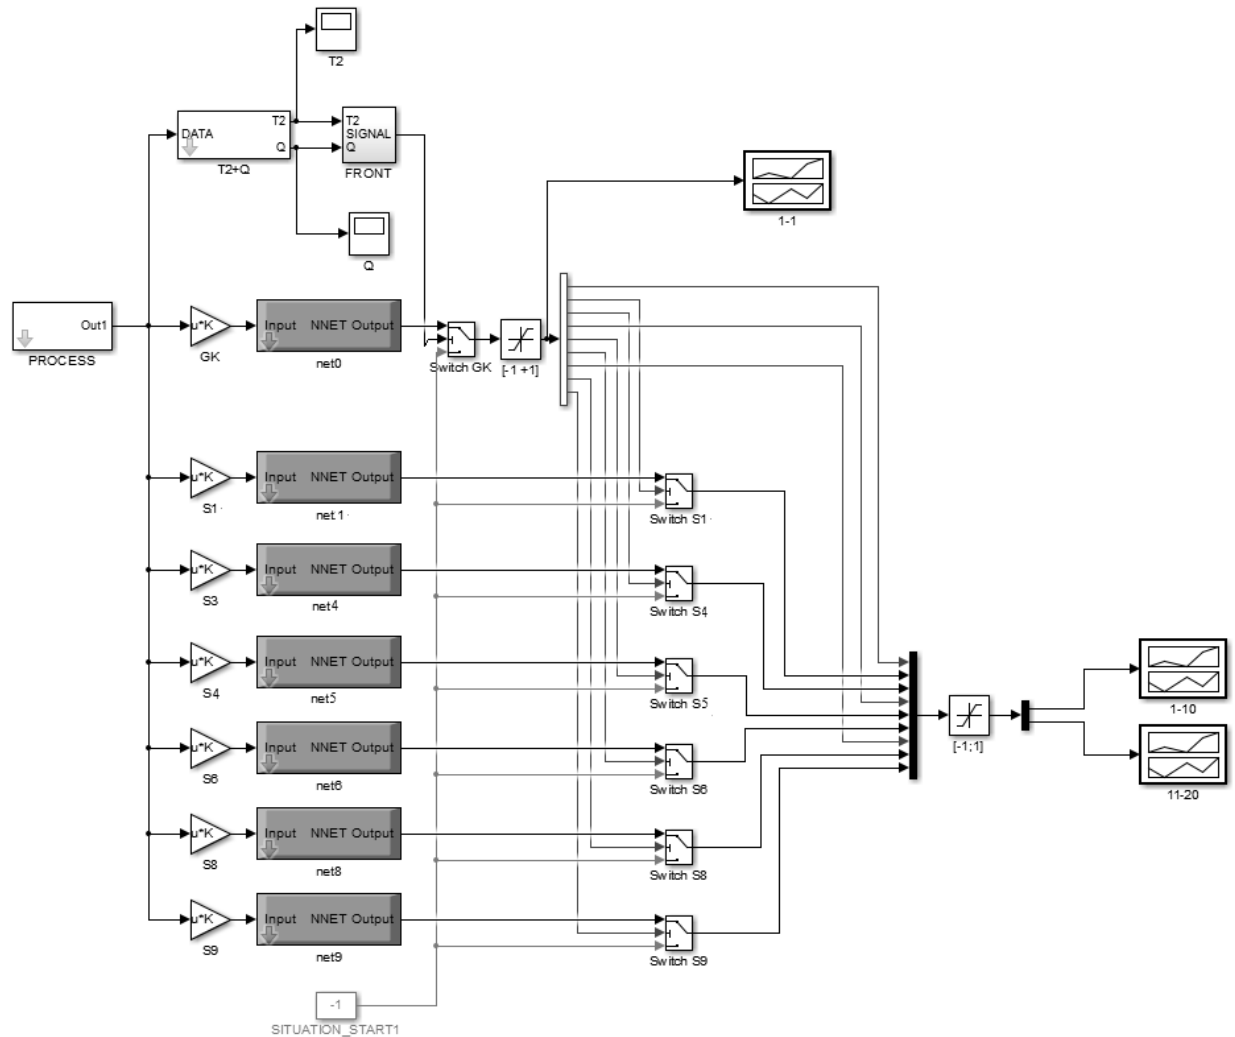


Рисунок 4.3 – Функциональная схема для тестирования работы двухуровневой нейросетевой модели в динамике

Каждая из сетей нижнего уровня также имеет трехслойную структуру. Функция активация нейронов скрытого слоя – сигмоидная. Обучение ведется по методу обратного распространения ошибки.

На переключатель Switch GK (после СВУ) подается либо значение -1 (ситуация не выявлена), либо при определении статистиками T^2 и Q наличия возникновения нарушения, выборки из главных компонент после СВУ.

На каждый из переключателей Switch S (после СВУ) подается либо значение -1 (ситуация не выявлена), либо при появлении на одном из выходов СВУ единицы, выборки из параметров для СВУ.

В качестве примера рассмотрим развитие нарушения S1.1 «Неполное пропекание шихты», входящее в ситуацию S1 «Нарушение пропекания шихты». Для этого, нажав на блок PROCESS двойным щелчком левой кнопки мыши, выберем в выпадающем окне выбора нарушений соответствующую ситуацию, как показано на рисунке 4.4.

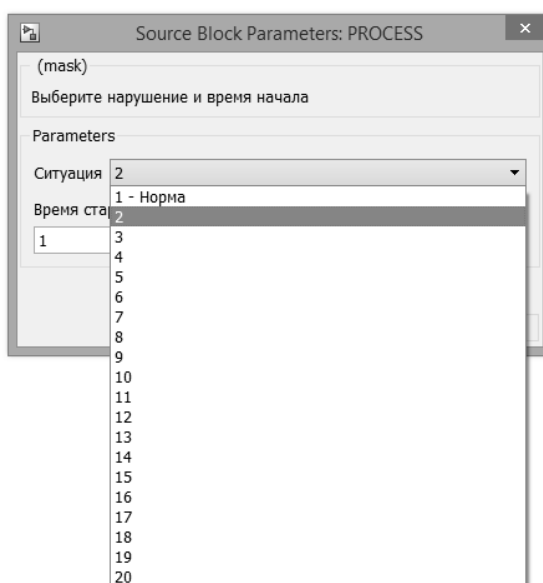


Рисунок 4.4 – Выбор нарушения для имитации работы модели в пакете Simulink

В связи с тем, что в качестве первого нарушения принята микроситуация, соответствующая нормальному ходу процесса, то нарушение S1.1, стоящее первым в таблице 3.1, будет находиться под цифрой 2.

Обнаружение факта нарушения происходит сравнением значений статистик Q и T^2 , вычисляемых для каждого полученного нового вектора измерений переменных процесса, с пороговыми значениями.

Статистика Q уверенно превысила порог на 28-ом шаге, статистика T^2 только на 85 шаге превысила. Превышение своего порогового значения хотя бы одной из статистик говорит о факте обнаружения ситуации S1.

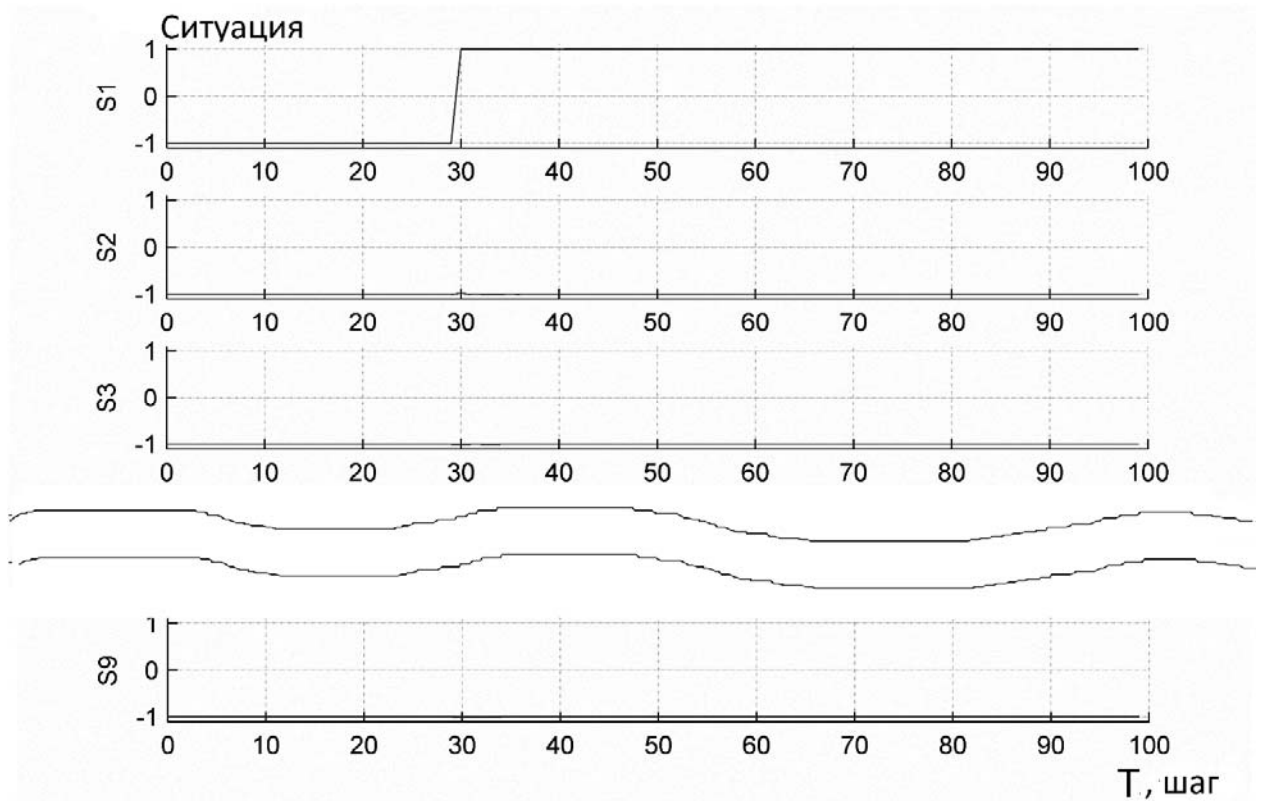


Рисунок 4.5 – Динамика работы сети верхнего уровня при распознавании ситуации S1

Результаты работы модели можно показать на трендах выходов сети верхнего уровня (рисунок 4.5). На рисунке видно, что сеть верхнего уровня распознает ситуации уже на 30 шаге.

За счет предварительной фильтрации данных динамика работы системы достаточно стабильная, т.е. отсутствуют ложные срабатывания (результаты обнаружения ситуаций S2-S9 близки к нулю). Как уже говорилось в 3 главе, выходы нейронов СВУ сравниваются с пороговыми значениями γ , значения которых выбираются эмпирически. Если они будут велики (близки к 1), то нарушения будут определяться с большим запаздыванием, когда они разовьются до нежелательных пределов. Кроме того, могут быть пропущены малые нарушения. При малых порогах увеличивается число ложных обнаружений. Моментом обнаружения ситуации S1 считается состояние соответствующего выхода СВУ равное 0,75. Именно с этого момента начинают работу СНУ1-СНУ2, что показано на рисунках 4.6, 4.8, на которых последовательно продемонстрированы результаты идентификации нарушений.

Динамика изменения определяющих нарушение S1.1 параметров совпадает с приведённой ранее на рисунке 4.2. Превышение порогового значения, заложенного в нейросетевую модель по $T_{ГОР}$ составляет 41 шаг, по $W_{ШИХ}$ - 43 шага, по $M_{УГЛ/ВОЗВ}$ - 62 шага. СНУ распознаёт нарушение S1.1 ориентировочно на 32 шаге. Результаты распознавания нарушения S1.1 показаны на рисунке 4.6.

Нарушение считается идентифицированным при превышении выходом соответствующего нейрона порога ξ , введенного скорее для удобства оператора. Значения ξ выбираются в диапазоне $\xi=0,7-0,9$ и также могут варьироваться оператором в зависимости от влияния данного нарушения на процесс и качество выходного продукта.




Рисунок 4.6 – Динамика работы сети нижнего уровня при распознавании нарушения S1.1 ситуации S1

Динамика изменения определяющих нарушение S1.2 «Образование расплавленного агломерата» параметров приведена на рисунке 4.7. Для данного нарушения согласно таблице 3.1 используются следующие параметры из 26-и, используемых в построении системы диагностики: $V_{АГЛ}$ – №1; $T_{ГОР}$ – №2 на рисунке 4.9 ; $W_{ШИХ}$ – №9 на рисунке 4.9; $M_{НИЗК.ТОП}$ – №13 на рисунке 4.9. На рисунке 4.9 показаны параметры при нормальном режиме работе; также тренды параметров $V_{АГЛ}$, $T_{ГОР}$, $W_{ШИХ}$, $M_{НИЗК.ТОП}$ при аномальном режиме протекания процесса, которые пересекаются с эксплуатационными пороговыми (горизонтальными пунктирными линиями).

Превышение порогового значения, заложенного в нейросетевую модель по

$V_{\text{АГЛ}}$ составляет 42 шага, по $T_{\text{ГОР}}$ – 48 шагов, по $W_{\text{ШИХ}}$ – 49 шагов, по $M_{\text{НИЗК.ТОП}}$ – 51 шаг.




Рисунок 4.7 – Динамика изменения параметров, характеризующих нарушение S1.2 «Образование расплавленного агломерата» - $V_{\text{АГЛ}}$, $T_{\text{ГОР}}$, $W_{\text{ШИХ}}$, $M_{\text{НИЗК.ТОП}}$.

Результаты распознавания нарушения S1.2 показаны на рисунке 4.8. СЧУ распознаёт нарушение S1.2 на 30 шаге.




Рисунок 4.8 – Динамика работы сети нижнего уровня при распознавании нарушение S1.2 ситуации S1

Анализ результатов показал, что СЧУ для S1 достаточно устойчиво обнаруживает развиваемые нарушения. Списки параметров, характеризующих нарушения S1.1 и S1.2 содержат по два одинаковых параметра. Распознавание S1.1 происходит на 32 шаге, распознавание S 1.2 на 30 шаге.

Таким образом, идентификация происходит:

- для ситуации S1– на 30 шаге;
- для нарушения S1.1– на 32 шаге; для нарушения S1.2 – на 30 шаге.

Согласно условиям моделирования выходы параметров за эксплуатационные пороги наступают:

- для нарушения S1.1: $T_{ГОР}$ на 41 шаге; $W_{ШИХ}$ на 43 шаге; $M_{УГЛ/ВОЗВ}$ на 52 шаге;
- для нарушения S1.2: $V_{АГЛ}$ на 44 шаге; $T_{ГОР}$ на 43 шаге; $W_{ШИХ}$ на 35 шаге; $M_{НИЗК.ТОП}$ на 44 шаге.

Таким образом, СНУ для S1 работали раньше, что отвечает требованию раннего обнаружения.




Рисунок 4.9 – Динамика работы сети верхнего уровня при распознавании ситуации S4

На рисунке 4.9 представлена идентификация ситуации S4 «Увеличение выхода возврата от заданного значения», которая может быть вызвана нарушениями S4.1-S4.7. На рисунке 14 видно, что сеть верхнего уровня распознает ситуации уже на 18 шаге.

Сеть верхнего уровня начала свою работу после обнаружения факта нарушения статистиками Q и T2. Статистика Q уверенно превысила порог на 17-ом шаге, статистика T2 – только на 70 шаге.

Результаты распознавания нарушений S4.2 «Уменьшение содержания углерода» и нарушения S4.5 «Массовая доля влаги в шихте увеличена» показаны на рисунках 4.10 и 4.11 соответственно.




Рисунок 4.10 – Динамика работы сети нижнего уровня при распознавании нарушение S4.2 ситуации S4




Рисунок 4.11 – Динамика работы сети нижнего уровня при распознавании нарушения S4.5 ситуации S4

Сети нижнего уровня, относящиеся к ситуации S4, идентифицируют:

- нарушение S4.1 «Повышение доли низкокалорийного топлива» на 25 шаге;
- нарушение S4.2 «Уменьшение содержания углерода» на 19 шаге;
- нарушение S4.3 «Уменьшение содержания FeO в агломерате» на 28 шаге;
- нарушение S4.4 «Снижение высоты слоя шихты» на 28 шаге;
- нарушение S4.5 «Массовая доля влаги в шихте увеличена» на 29 шаге;
- нарушение S4.6 «Уменьшение массовой доли влаги в шихте» на 27 шаге;
- нарушение S4.7 «Ухудшение прочности агломерата» на 30 шаге.

В ходе эксперимента установлено, что СЧУ для S4 работали раньше выхода соответствующих каждой ситуации параметров за эксплуатационные пороги, что

отвечает требованию раннего обнаружения.

Следует иметь в виду, что в ходе имитационного моделирования на параметры накладывались произвольные линейные возмущения, в то время как развитие ситуаций может отличаться от приведенных выше.

Введение пороговых значений для выходных нейронов СВУ позволяет более гибко оценить результаты работы системы диагностики. Так причину можно считать идентифицированной, если значение выходного сигнала с нейронов сети превышает порог $\zeta=0,7$. Необнаружение причины можно считать в том случае, если сигнал ниже порога $\zeta=0,3$. Нахождение сигнала нейрона в диапазоне между этими порогами означает необходимость дополнительного контроля ситуации оператором.

Использование такого подхода при локализации причины позволяет выиграть некоторое время, что для процесса агломерации весьма существенно, т.к. своевременное воздействие на процесс может позволить снизить выход агломерата несоответствующего качества.

Экспериментальное исследование работы системы на реальных данных методом имитационного моделирования все ситуаций, представленных в таблице 3.1, показало её работоспособность. Ситуации система уверенно обнаруживала при развитии в пределах 20% зоны от их максимального развития, хотя и с существенно различными скоростями, при этом на этапе мониторинга все развивающиеся ситуации были обнаружены статистиками Q и/или T2 на достаточно ранних стадиях – 10% от их максимального развития.

4.6 Выводы по 4-й главе

1. Экспериментальное исследование работы разработанной СОУ было проведено методом имитационного моделирования, для этого было рассмотрены все ситуации, относящиеся к ситуациям S1-S9.

2. Имитационное моделирование проводилось в среде MATLAB, на базе которой было создано отдельное приложение для реализации алгоритма работы СОУ. Для исследования использовались массивы реальных данных, полученные из рабочих

журналов работы агломашины за период 21.04.2012г - 22.04.2012г, на основании которых были сформированы массивы для обучения и тестовые.

3. В ходе исследования было выявлено, что исходные данные существенно зашумлены. Для фильтрации данных использован комбинированный фильтр, состоящий из фильтров скользящей медианы и экспоненциального сглаживания.

4. На этапе мониторинга все развивающиеся ситуации были обнаружены статистиками Q и/или T^2 на достаточно ранних стадиях – 10% от их максимального развития.

5. Система уверенно обнаруживала нарушения при развитии в пределах 20% зоны от их максимального развития, хотя и с существенно различными скоростями. Экспериментальное исследование работы системы на реальных данных методом имитационного моделирования показало её работоспособность. Особенностью системы является введение мер предотвращения возможной «потери» сетью опознанной причины из-за отсутствия результатов действий оператора и продолжения развития нарушения.

ЗАКЛЮЧЕНИЕ

1. Рассмотрена структура автоматизированной системы оперативного управления (СОУ). Показано, что одной из важных функций СОУ являются функции мониторинга текущего состояния процесса и диагностики причин возникающих нарушений. Функционирование системы диагностики производится на основе диагностических моделей (ДМ). Обосновано применение для рассматриваемого процесса агломерации нейросетевой ДМ с использованием нейронных сетей прямого распространения.

2. Для устранения существенного недостатка нейросетевых моделей для сложных процессов большой размерности - недопустимо большого времени обучения и переобучения (что особенно важно при работе в реальном времени) в ДМ введена иерархия, что позволяет снизить размерность используемых в ДМ нейронных сетей. Разработана структура диагностической модели (ДМ), представляющая собой двухуровневую нейросетевую модель процесса: определение ситуаций на процессе, создаваемых возникающими нарушениями в ходе процесса, проводится нейронной сетью верхнего уровня (СВУ), а идентификация нарушений, их вызвавших, производится нейронными сетями нижнего уровня (СНУ).

3. Еще большее снижение размерности СВУ достигнуто применением к исходной информации преобразования метода главных компонент (МГК) и подачи на входы СВУ проекций исходных данных в пространство главных компонент, что определило число входов СВУ. Так как размерности СНУ невелики, то дополнительного снижения размерности не потребовалось. Использование МГК позволило осуществить мониторинг процесса контролем двух статистик T^2 (статистика Хотеллинга) и Q (стандартная ошибка предсказания SPE). При этом СВУ запускается только при фиксировании факта обнаружения возникшего нарушения. Это позволило снизить ресурсоёмкость системы.

4. На основании анализа процесса и результатов проведенного экспертного опроса определены 26 нарушений технологического характера, сгруппированных в 9 ситуаций. Это определило число выходных нейронов в СВУ и число сетей СНУ.

Каждый выход СВУ связан с разрешающим входным нейроном соответствующей сети нижнего уровня. Нарушение считается идентифицированным СНУ при превышении выходом соответствующего нейрона порога ξ , введенного для удобства оператора: при превышении порога $\xi=0,7$ нарушение считается возможным и требует привлечения внимания оператора; при превышении порога $\xi=0,9$ нарушение считается выявленным и оператору выдается соответствующая информация и рекомендации по его устранению

5. Для повышения глубины диагностики в работе предложено ввести дополнительно три цифровых оптических камеры, расположенных сразу за зажигательным горном (инфракрасная камера), над зоной остывания агломерата (цветная камера) и на сходе агломерата с аглоленты для контроля излома агломерата (инфракрасная камера).

Разработаны алгоритмы обработки изображений с камер, устойчиво работающие в условиях шумов. Алгоритм обработки камеры, контролирующей оттенки цвета агломерата, включает обучение на эталоне с использованием нечеткой кластеризации векторов цветовых интенсивностей пикселей с последующим отнесением пикселей рабочего изображения к тому или иному кластеру по величине расстояния Махаланобиса до центра кластеров. Алгоритм определения относительной величины зоны горения на изломе аглоспека оценивает ее по расстоянию между пиками СКО интенсивностей пикселей.

6. Разработана блок-схема алгоритма работы системы: на предварительном этапе - этапе обучения, формируются обучающие массивы, и производится обучение сетей диагностической модели с последующими возможным их переобучением при изменении параметров исходного сырья. На рабочем этапе - производится собственно мониторинг и диагностика нарушений. Особенностью алгоритма является введение мер предотвращения возможной «потери» сетью опознанной причины из-за отсутствия результатов действий оператора и продолжения развития нарушения.

7. Экспериментальное исследование работы системы на реальных данных методом имитационного моделирования показало её работоспособность. Нарушения

на процессе система уверенно обнаруживала при развитии в пределах 20% зоны от их максимального развития, хотя и с существенно различными скоростями.

СПИСОК ЛИТЕРАТУРЫ

1. Коротич, В. И. Агломерация рудных материалов: науч. изд / В. И Коротич, Ю. А. Фролов, Г. Н. Бездежский. - Екатеринбург: изд УГТУ - УПИ, 2003. - 400 с.
2. Глинков, Г.М АСУ ТП в черной металлургии: Учебник для вузов / Г.М. Глинков, В.А. Маковский - 2-е изд. перераб. и доп, - М.: «Металлургия», 1999. - 310 с.
3. Ершов, Е.В. Методы, модели и алгоритмы управления технологическим процессом производства агломерата на основе оптико-электронного контроля его качества: дис. ... д-ра тех. наук: 05.13.06 / Е.В. Ершов; Череповецкий государственный университет. - Череповец, 2009.-398с.
4. Егорова, Е.Г. Анализ процесса подготовки агломерата из руд цветных и чёрных металлов как объекта автоматической диагностики / Е.Г. Егорова, Л.А. Русинов, М.А. Усачёв, З.Г. Салихов // Цветные металлы №11, 2013 / под общ. ред. А.В. Путилова - Москва: ИД «Руда и Металлы», 2013г. - С.87-91.
5. Haidong, W. Design and development of expert system for controlling sintering process / W. Haidong, Q.Guanzhou, H. Shengsheng // Trans. Nonferrous Met. Soc. China, China. – 1999. – Issue 3, V. 9. - P.651-654.
6. Сурин, А.А. Разработка АСУТП стабилизации химического состава агломерата: дис. ... кандидата тех. наук: 05.13.06 / А.А. Сурин; ГОУ ВПО «Уральский государственный горный университет». - Екатеринбург., 2005.-165с.
7. Xiao-hui, F. Real-time operation guide system for sintering process with artificial intelligence / F. Xiao-hui, C. Xu-ling, J. Tao // Journal of central south university of technology, China. – 2005. - Issue 5, V. 12 - P. 531-535.
8. Xiang, J. Intelligent Integrated Optimization Control Design of Comprehensive Production Indices for Sintering Process / J. Xiang, M. Wu // Control Conference, China, 2007.- P. 750-754.
9. Dai-fei, L. Development and Application of Sintering Process Data Mining System / L. Dai-fei, C. Xu-ling // Management and Service Science, Wuhan, 2009. - P.1-4.

10. Xu-ling, C. Operation Guidance System for Iron Ore Sintering Process / C. Xu-ling, F. Xiao-hui, J.Tao // Intelligent System Design and Engineering Application, Changsha, 2010. - P. 1053-1055.
11. Xiao-hui, F. Air Leakage Online Monitoring and Diagnosis Model for Sintering / F. Xiao-hui, J. Lijuan, C. Xu-ling // 2012 TMS Annual Meeting & Exhibition, 3rd International Symposium on High Temperature Metallurgical Processing, United States, Florida, 2012.
12. Kostial, I. Optimal control of the sintering process / I. Kostial, L. Doreak, J. Terpak // Proceedings of the 16th IF AC World Congress, vol. 16, part 1, Czech Republic, 2005.
13. Langer, M. Synthesis of plantwide quality prediction system for a sintering plant / M. Langer, B. Vogel // 15th Triennial World Congress, Barcelona, Spain, vol. 15, Part 1, 2002.
14. Sintering technologies [Electronic resource] / Outotec: more out of ore - Mode of access: <http://www.outotec.com/36252.epibrw>
15. Solutions for sinter plants [Electronic resource] / Mechanical, automation, and electrical engineering from a single source - economically and ecologically advanced solutions - Mode of access: <http://www.industry.siemens.com/datapool/industry/industrysolutions/metals/simetal/en/Solutions-for-sinter-plants-en.pdf>
16. Малыгин, А.В. Система управления качеством агломерата / А.В. Малыгин, Б.Б. Зобнин, С.С. Головырин, А.А. Сурин, В.П. Невраев, М.А. Гуркин, Р.Л. Катаев // Сталь, N 1, 2005.
17. Жуков, С.Ф. Автоматизация процессов управления и диагностирования электротехнических комплексов металлургического производства / С.Ф. Жуков, А.И. Важинский // Материалы XI Международной научно-технической конференции: Проблемы современной электротехники-2010, Киев, Украина.
18. Ершов, Е.В. Анализ гранулометрического состава агломерата с использованием методов обработки изображений Текст. / Е.В. Ершов, В.В. Селивановских, О.Г.

- Ганичева, В.В. Плащенко // Известия вузов. Приборостроение. 2007. Т. 50, № 8. - С. 65 - 68.
19. Ершов, Е.В. Анализ изображения поверхности спекаемого слоя для контроля зажигания при агломерации рудного сырья / Е.В.Ершов, М.Н. Фатиев // Компьютерные технологии в науке, проектировании и производстве: Тезисы докладов 2-й Всероссийской НТК. В 11 частях. Часть 6. - Нижний Новгород: НГТУ, 2000. - С. 10.
 20. Ершов, Е.В. Анализ макроструктуры агломерата в реальном масштабе времени / Е.В. Ершов, Е.В. Королева // Прогрессивные процессы и оборудование металлургического производства: Материалы 2-й Всероссийской НТК. - Череповец: ЧТУ, 2001. - С. 35-36.
 21. Ершов, Е.В. Контроль процесса спекания шихты на агломерационной машине с использованием методов обработки изображений на ЭВМ Текст. / А.И.Потапов, Е.В. Ершов, О.Л.Селяничев //Дефектоскопия. 1995.-№6.-С.19-2
 22. Xiao-hui, F. Expert System for Sintering Process Control / F. Xiao-hui, C. Xu-ling, Y. Wang // Expert systems, Croatia, 2010. - P. 65-90.
 23. Производство офлюсованного агломерата: Технологическая инструкция ТИ 00186246-ОА-01-2002. - Новотроицк, 2002.
 24. Спекание офлюсованного агломерата на аглофабриках № 2,3 горно-обогатительного производства: Технологическая инструкция ТИ-101-ГОП-11-99. - Магнитогорск, 1999.
 25. Ендияров, С.В. Диагностика процессов подготовки и производства агломерата. Методы и модели искусственного интеллекта/ С.В.Ендияров, С.Ю. Петрушенко. – Германия: LAP LAMBERT Academic Publishing, 2013.323 с.
 26. Загидуллин, Р. Р. Управление машиностроительным производством с помощью систем MES, APS, ERP / Р. Р. Загидуллин,—Старый Оскол: ТНТ, 2011. — 372 с.
 27. Гершберг А. Ф. и др. Концептуальные основы информационной интеграции АСУ ТП нефтеперерабатывающего предприятия./ А.Ф. Гершберг, А.А. Мусаев, А. А. Нозик, Ю. М. Шерстюк – СПб: Альянс-строй, 2003, 128с.

28. Venkatasubramanian, V. Abnormal Events Management in Complex Process Plants: Challenges and Opportunities in Intelligent Supervisory Control / V.Venkatasubramanian // Proceedings FOCAPO. - 2003, P. 117-132.
29. Ицкович, Э.Л. Оперативное управление непрерывным производством: задачи, методы, модели / Э.Л. Ицкович, Л.Р. Соркин - М.: Наука, 1988. - 160с.
30. Русинов Л.А. Методы и системы мониторинга и диагностики нарушений в технологических процессах производства химических наноматериалов: учебное пособие / Л.А. Русинов, В.В.Куркина. Под ред. Чистяковой Т.Б.- СПб: СПбГТИ (ТУ), 2012. - 48 с.
31. Venkatasubramanian, V. A review of process fault detection and diagnosis. Part I-III /V. Venkatasubramanian, R. Rengaswamy, K. Yin, S.N. Kavuri // Computers and Chemical Engineering. - 2003. - V.27. - P.293-311.
32. Maurya, M.R. Application of signed digraphs-based analysis for fault diagnosis of chemical process flowsheets / M. R. Maurya, R. Rengaswamy, V. Venkatasubramanian // Engineering Applications of Artificial Intelligence.- 2004.- V.17.-P. 501–518.
33. Русинов, Л.А. Повышение безопасности процесса получения пероксида водорода на основе диагностики его текущего состояния / Л.А. Русинов, Н.А. Александрова, П.В. Рашковский, Е.М. Кравченко // Химическая промышленность сегодня. - 2003. - N4. - С.45-50.
34. Александрова, Н.А. Использование метода сигнальных направленных графов для верификации экспертных знаний / Н.А. Александрова, Л.А. Русинов // Ред. журн. «Прикладная химия. РАН». СПб, 2002, 14с.
35. Kramer, M. A. A rule based approach to fault diagnosis using the signed directed graph / M. A. Kramer, B. L. Palowitch // American Inst. of Chem. Engineers J. - 1987. - V.33 №7.- P.1067-1078.
36. Tarifa, E. Fault diagnosis, directed graphs, and fuzzy logic / E. Tarifa, N. Scenna // Computers and Chemical Engineering. - 1997. - V.21. - P.649-654.

37. Fagarasan, I. Applications of Fault Detection Methods to Industrial Processes / I. Fagarasan, S.St. Iliescu // WSEAS transactions on systems. - 2008. - Issue 6, V.7, - P.812-821.
38. Sobhani, E. Fault Diagnosis of Nonlinear Systems Using a Hybrid Approach /E. Sobhani-Tehrani, K. Khorasani // Darmstadt: Springer. - 2009. - P.21-51
39. Chui, Ch.K. Kalman filtering with real-time applications / Ch.K. Chui, G. Chen, Kalman filtering with real-time applications // New York: Springer – 2009. – P.229.
40. Grewal, M.S. Kalman filtering: theory and practice using Matlab / M.S. Grewal, A.P. Andrews - N.Y.: John Willey & Sons, 2001. - 397pp.
41. Ford, J.J. Non-linear and Robust Filtering: From the Kalman Filter to the Particle Filter / J.J. Ford - DSTO-TR-1301 - Victoria: Aeronautical and Maritime Research Laboratory, 2002. - 49pp.
42. Reif, K. Stochastic Stability of the Discrete-Time Extended Kalman Filter / K. Reif, S. Gunther, E. Yaz, R. Unbehauen // IEEE Trans. on Automatic Control. - 1999. - V. 44 - №4. - P.714-728.
43. Rusinov, L.A. Fault diagnosis in chemical processes and equipment with feedbacks / L.A. Rusinov, N.V Vorobiev, V.V. Kurkina // Chemometrics and intelligent laboratory systems. - 2013. - V.126 - P.123-128.
44. Caccavale, F. An integrated approach to fault diagnosis for a class of chemical batch processes / F. Caccavale, F. Pierri, M. Iamarino, V. Tufano // Journal of Process Control. - 2009. - V.19 - P.827-841.
45. Alessandri, A. Fault diagnosis for nonlinear systems using a bank of neural estimators / A. Alessandri // Computers in Industry. - 2003. - V.52 - P.271-289.
46. Uraikul, V. Artificial intelligence for monitoring and supervisory control of process systems / V. Uraikul, Chr. W. Chan, P. Tontiwachwuthikul // Engineering Applications of Artificial Intelligence. - 2007. - V.20. P.115–131.
47. Мешалкин, В.П. Экспертные системы в химической технологии. Основы теории, опыт разработки и применение / В.П. Мешалкин - М.: Химия, 1995. - 368с.

48. Nan, C. Real-time fault diagnosis using knowledge-based expert system / C. Nan, F. Khan, M.T. Iqbal // *Process safety and environmental protection*.-2008. - V.86 - P.55-71.
49. Power, Y. Integration techniques in intelligent operational management: a review / Y. Power, A.P. Bahri // *Knowledge-Based Systems*, 20. – 2004, pp. 1–9.
50. Rengaswamy, R. An Integrated Framework for Process Monitoring, Diagnosis, and Control using Knowledge-based Systems and Neural Networks / R. Rengaswamy, V. Venkatasubramanian // *IFAC, Delaware, USA*. – 1992, pp. 49–54.
51. Venkatasubramanian, V. Towards integrated process supervision: current status and future directions / V. Venkatasubramanian // *IFAC Computer Software Structures Integrating AI/KBS Systems in Process Control, Lund, Sweden*. – 1994, pp. 1–13.
52. ГОСТ Р 50779.42-99 (ИСО 8258-91) Статистические методы. Контрольные карты Шухарта - М.: Изд. стандартов, 1999. - 36с.
53. Химмельблау, Д. Обнаружение и диагностика неполадок в химических и нефтехимических процессах / Д. Химмельблау - Л.: Химия, 1983. 352с.
54. Царев, Ю.В. Статистические методы контроля и управления качеством. Контрольные карты: учебно-методическое пособие / Ю.В.Царев, А.Н. Тростин - Иваново: ИГХТУ, 2006. - 160с.
55. Bersimis, S. Multivariate Statistical Process Control Charts: An Overview / S.Bersimis, S.Psarakis, J.Panaretos // *Qual. Reliab. Engng. Int.*, 2007. - V.23. - P.517–543.
56. Эсбенсен, К. Анализ многомерных данных / К. Эсбенсен - Черногловка: Изд-во ГЕОХИ РАН, 2005. - 158с.
57. Choi, S.W. Fault detection and identification of nonlinear processes based on kernel PCA / S.W. Choi, Ch. Leeb, J-M. Leeb, J.H. Park, I-B. Lee // *Chemometrics and Intelligent Laboratory Systems* - 2005. - V.75. - P. 55-67.
58. Lee, J. Nonlinear process monitoring using kernel principal component analysis. / J. Lee, Ch.Y. Yoo, S.W. Choi, P.A. Vanrolleghem, In-B. Lee. // *Chemical Engineering Science*. - 2004. - V.59. - P.223-234.

59. Zhao, J. On-line early fault detection and diagnosis of municipal solid waste incinerators / J. Zhao, J. Huang, W. Sun // *Waste Management*. - 2008. V.28. - P.2406-2414.
60. Мкртчян, С.О. Нейроны и нейронные сети (ведение в теорию формальных нейронов и нейронных сетей) / С.О. Мкртчян. – М.:Энергия,1971. – 232с.
61. Cubillos, A.F. L.E., 1998. Adaptive hybrid neural models for process control / A.F. Cubillos, L.E. Lima // *Computers & Chemical Engineering* 22 (Suppl.). -1998, P.989–992.
62. Lennox, B. Case study investigating the application of neural networks for process modelling and condition monitoring / B. Lennox, P. Rutherford, A.G.Montague, C. Haughin // *Computers & Chemical Engineering* 22 (21).- 1998, P.1573–1579.
63. Kavchak, M. Adaptive neural network structures for non-linear process estimation and control / M. Kavchak, H. Budman // *Computers & Chemical Engineering* 23. – 1998, P.1209–1228.
64. Tsai, F.P. Developing a robust model predictive control architecture through regional knowledge analysis of artificial neural networks / F.P. Tsai, Z.J. Chu, S.S. Jang, S.S. Shieh // *Journal of Process Control*, №13. – 2002, P. 423–435.
65. Power, Y. A two-step supervisory fault diagnosis framework / Y. Power, A.P. Bahri // *Computers & Chemical Engineering*, № 28. – 2004, P. 2131–2140.
66. Нейронные сети. STATISTICA Neural Networks: пер. с англ. – М.: Горячая линия – Телеком.,2001. – 182с.
67. Zhou, Yifeng. Fault detection and classification in chemical processes based on neural networks with feature extraction / Yifeng Zhou, Juergen Hahn, M. Sam Mannan // *ISA Transactions* 42.- 2003, PP 651-664.
68. Bishop, C.M. *Neural Networks for Pattern Recognition* / C.M. Bishop. New York: Oxford University Press, 1995.
69. Borairi, M. Actuator and sensor fault diagnosis of non – linear dynamic system via genetic neural networks and adaptive parameter estimation technique / M. Borairi, H. Wang // *IEEE Press*. – 1998, P. 278-282.

70. Gomm, J. B. Adaptive neural network approach to on-line learning for fault diagnosis / Gomm J. B. // *Trans. Meas. Control* 20. – 1998, P. 144-152.
71. Alessandri, A. Robust model-based fault diagnosis using neural nonlinear estimators / A. Alessandri, M. Baglietto // *IEEE Press.*-1998, P. 72-77.
72. Yu, D. L. Sensor fault diagnosis in a chemical process / D. L. Yu, J. B. Gomm // *Control Eng. Pract.* 7. -1999, P.49-55.
73. Chow, M. Y. Intelligent motor fault detection / M. Y. Chow, B. Li, G. Goddu // *CRC Press.* – 1999, P. 191-223.
74. Потемкин, В.Г. Система Matlab 5 для студентов / В.Г. Потемкин, П.И. Рудаков. – 2-е изд. испр. и доп. – М.: ДИАЛОГ МИФИ, 1999. - 488 с.
75. Васильев, В.И. Интеллектуальные системы управления. Теории и практика: уч. пособие / В.И. Васильев, Б.Г. Ильясов. - М.: Радиотехника, 2009. - 392 с.
76. Хайкин, С. Нейронные сети: полный курс / С. Хайкин. - М. : Изд. дом "Вильямс", 2006. - 1104 с.
77. Эсбенсен, К. Анализ многомерных данных: Сокр. пер. с англ./ К. Эсбенсен. Под ред. О.Родионовой.- М.: Издательство ИПХФ РАН, 2005. – 252 с.
78. Yang Q., Model-based and data driven fault diagnosis methods with applications to process monitoring. Thesis for the degree of PhD. - Case: Western Reserve University, 2004, 203 pp.
79. Ершов, Е. В. Использование оптико-электронного метода для анализа гранулометрического состава сыпучих материалов металлургического производства / Е. В. Ершов, В. В. Селивановских, О. Г. Ганичева // *Материалы 17-й межвузовской военно-научной конференции. — Часть 4. — Череповец: ЧВИИРЭ, 2007. - С. 116-117.*
80. Ершов, Е.В. Контроль процесса зажигания шихты в агломерационной машине с использованием оптико-электронного метода / Е.В. Ершов, О.Г. Ганичева, В.В. Селивановских, В.В. Плащенко // *Известия вузов. Приборостроение.* - 2007. Т. 50, № 5. - С. 70 - 73.
81. Гордов, А.Н. Основы температурных измерений /А.Н.Гордов, О.М. Жагулло, А.Г. Иванова -М.: Энергоатомиздат,1992. -304 с.

82. Общетехнический справочник / Под ред. Е.А. Скороходова. - 4-е изд. - М.: Машиностроение, 1990. - С. 496.
83. Воробьёв, Н.В. Система диагностики процесса агломерации железорудных материалов с использованием оптико-электронных устройств / Н.В. Воробьёв, Е.Г. Егорова, Л.А. Русинов // Известия Санкт-Петербургского государственного технологического института (технического университета). - 2014. № 27(53). - С. 77 - 82.
84. Palit, Ajoy K. Computational Intelligence in Time Series Forecasting. Theory and Engineering Applications Series Advances in Industrial Control / Ajoy K. Palit and D.Popovic - Hamburg: Springer,2005 -381p.
85. Зайченко, Ю.П. Нечеткие модели и методы в интеллектуальных системах / Ю.П.Зайченко - Киев: Слово, 2008 - 344с.
86. Волкова, Е.П. Анализ корректности кластеризации данных методами нечёткого кластерного анализа / Е.П. Волкова, В.С. Зияутдинов // Труды международного симпозиума «Надёжность и качество», 2010.
87. Братчиков, С.Г. Теплотехника окускования железорудного сырья / С.Г.Братчиков, Ю.А.Берман, Я.Л. Белоцерковский. и др - М.: Металлургия, 1970.- С. 344.
88. Русинов Л.А.Автоматизация аналитических систем определения состава и качества веществ / Л.А.Русинов - Л.:Химия, 1984 -160с.

ПРИЛОЖЕНИЕ

