

Федеральное Государственное бюджетное учреждение науки
Институт проблем управления имени В.А. Трапезникова
Российской Академии наук

На правах рукописи

Черешко Алексей Анатольевич

**МЕТОДЫ УПРАВЛЕНИЯ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ
НА ОСНОВЕ АССОЦИАТИВНЫХ ПРОГНОЗИРУЮЩИХ МОДЕЛЕЙ**

Специальность 2.3.3 – Автоматизация и управление технологическими
процессами и производствами (технические науки)

Диссертация на соискание ученой степени
кандидата технических наук

Научный руководитель:
доктор техн. наук, профессор
Бахтадзе Наталья Николаевна

Москва, 2022

Оглавление

Введение	4
Глава 1. Алгоритмы управления с прогнозирующей моделью	17
1.1. Управление нелинейными процессами на основе прогнозирующей модели (NMPC – Nonlinear MPC).....	25
1.2. Стохастические алгоритмы	28
1.3. ПИД-предиктивное управление (PID-predictive control).....	30
1.4. Управление с нечеткой прогнозирующей моделью (Fuzzy MPC)	32
1.5. Адаптивное управление с прогнозирующей моделью (Adaptive predictive control)	34
1.6. Предиктивное управление с использованием нейронных сетей (Neural Network predictive control).....	35
1.7. Выводы	37
Глава 2. Метод разработки виртуальных анализаторов показателей качества на основе алгоритмов интеллектуального анализа технологических данных	39
2.1. Классические методы построения виртуальных анализаторов (множественная линейная регрессия с автоподстройкой).....	39
2.2. Виртуальные анализаторы на основе интеллектуального анализа технологических данных	41
2.2.1. Описание алгоритма ассоциативного поиска	42
2.2.2. Метод ассоциативного поиска с использованием вейвлет-анализа....	47
2.2.3. Процедура Мура–Пенроуза для построения моделей ассоциативного поиска при зависимых входах	49
2.3. Построение ВА показателей качества для непрерывных и полунепрерывных ТП	51
2.3.1. Описание текущего состояния	55
2.3.2. Разработка структуры базы знаний	56
2.4. Выводы	58
Глава 3. Разработка алгоритма управления с прогнозирующей моделью на основе ассоциативного виртуального анализатора.....	59
3.1. Описание алгоритма ассоциативного MPC	61
3.2. Алгоритм расчета вектора управляющих воздействий	66
3.3. Прогноз выхода на несколько тактов вперед в AMPC	67

3.4. Алгоритм расчета глубины прогноза для выхода в АМРС.....	68
3.5. Выводы	69
Глава 4. Практическое применение ассоциативных виртуальных анализаторов	71
4.1. Построение ВА для технологического процесса кальцинации	71
4.2. Построение ВА для технологического процесса гидроочистки бензина каталитического крекинга в колонне фракционирования	74
4.2.1. Краткое описание технологического процесса	74
4.2.2. Моделирование общего содержания серы в бензине	74
4.2.2.1. Множественная линейная регрессия.....	74
4.2.2.2. Множественная линейная регрессия с автоподстройкой	76
4.2.2.3. Модель ассоциативного поиска.....	78
4.2.2.4. Выводы.....	80
4.3. Практическое применение ВА на основе интеллектуального анализа технологических данных в замкнутом МРС-контуре обогатительной фабрики железорудного концентрата	81
4.3.1. Описание технологического процесса обогащения железорудного концентрата.....	81
4.3.2. Задачи МРС по управлению и оптимизации технологическим процессом.....	83
4.3.3. Описание контроллера МРС.....	84
4.3.4. Алгоритмы управления и оптимизации	85
4.3.5. Структура контроллера МРС	87
4.3.6. Разработка ВА на основе ассоциативного поиска	102
4.3.6.1. Содержание железа в секционном концентрате	102
4.4. Выводы	104
Основные результаты работы	105
Список литературы.....	106
ПРИЛОЖЕНИЕ.....	117

Введение

Актуальность темы. Повышение эффективности систем управления производственными и, прежде всего, технологическими процессами (ТП) становится определяющим фактором конкурентоспособности промышленных предприятий и повышения качества выпускаемой продукции.

Сегодня управление с прогнозирующей моделью (Model Predictive Control – MPC) является одним из наиболее эффективных методов управления ТП в перерабатывающих отраслях промышленности: нефтепереработке, производстве удобрений, нефтехимии, обогащении полезных ископаемых и др. MPC решает разнообразные задачи: от стабилизации работы объекта до его оптимизации по заданному критерию (максимуму производительности, минимуму себестоимости, минимуму удельного энергопотребления и пр.).

MPC осуществляется в режиме реального времени. Традиционно MPC-система содержит заранее построенную по экспериментальным данным прогнозирующую модель объекта. Эффективность управления в значительной степени определяется точностью этой модели.

На каждом такте работы системы реализуются следующие действия:

- от контрольно-измерительных приборов (КИП) через распределенную систему управления (PCY) поступают текущие значения регулируемых величин и наблюдаемых возмущений;
- вычисляются значения выходных переменных модели, определяющие прогноз поведения объекта на несколько тактов;
- решается задача линейного или квадратичного программирования с заданной целевой функцией (технико-экономическим критерием) оптимизации с учетом имеющихся технических и технологических ограничений, в результате чего вычисляется оптимальная последовательность управляющих воздействий на определенное число тактов управления;
- если найденные управляющие воздействия на текущем такте существенно не отличаются от действующих на объекте, то корректировка управления не

производится; в противном случае новые значения управлений передаются на управляющие органы ТП через РСУ.

- На следующем такте управления (интервал между тактами обычно составляет от нескольких десятков секунд до трех минут) описанные выше действия повторяются с учетом вновь накопленных данных приборных измерений.

Как правило, в МРС-системах реализованы идентификационные модели показателей качества продукции. Программно-алгоритмические комплексы, формирующие эти модели и обеспечивающие их функционирование, получили название виртуальных анализаторов (ВА). Для многих ТП ВА позволяют достаточно эффективно контролировать свойства получаемой продукции в режиме реального времени без значительных капитальных затрат и трудоемкого обслуживания.

В схемах МРС чаще всего используются ВА на основе линейных регрессионных моделей: они хорошо зарекомендовали себя на практике. Однако для некоторых нелинейных процессов прогноз ВА на основе линейной модели не всегда дает удовлетворительные результаты.

В диссертационной работе предлагается новый подход к разработке ВА: формирование идентификационной модели на основе индуктивных знаний об исследуемом ТП. Под индуктивными знаниями понимаются закономерности, получаемые восстановлением зависимостей по эмпирическим данным (термин В.Н. Вапника) [1].

Высокую точность идентификации для различных объектов показали алгоритмы ассоциативного поиска, предложенные Н.Н. Бахтадзе [2]. В отличие от традиционных подходов, модели нелинейных объектов, основанные на этих алгоритмах, получаются не посредством линеаризации объекта с последующей адаптивной настройкой модели, а путем генерации новой модели на каждом временном такте в малой окрестности рабочей точки. При формировании такой «точечной» модели анализируется вся накопленная и обработанная к данному

моменту информация о динамике объекта в прошлые моменты времени с выявлением «похожих ситуаций» в прошлом.

ВА, разработанные автором на основе этих алгоритмов названы ассоциативными; представлены результаты разработки ассоциативных ВА в системах управления класса МРС, что особенно актуально для нелинейных и нестационарных ТП [3-5].

Одним из важных требований к МРС-алгоритмам является робастность управления [6]. Под робастностью МРС-системы понимается ее способность достигать цели управления в условиях ограниченной неопределенности, с некоторым запасом по какому-либо критерию качества. Алгоритмы управления действующих на современном производстве МРС-систем, как правило, робастны при управлении различными ТП. Однако для широкого класса нелинейных объектов функционирование традиционных МРС-алгоритмов с линейными моделями не всегда приводит к удовлетворительным результатам [7-10].

Для решения задачи управления нелинейными ТП автором предложен альтернативный подход к управлению с прогнозирующей моделью – так называемое «ассоциативное управление с прогнозирующей моделью» – на основе ассоциативных ВА.

Алгоритмы ассоциативного поиска продемонстрировали высокую точность для объектов различных классов: технических, экономических, медико-биологических. Применение высокоточных методов прогнозирования в ВА МРС-систем на различных промышленных объектах позволит проектировать и разрабатывать более эффективные системы усовершенствованного управления ТП (СУУТП) и, благодаря этому, заметно повышать эффективность работы предприятий. Кроме того, предлагаемый подход обеспечивает возможность дальнейшего совершенствования научных основ и формализованных методов проектирования и реализации СУУТП, а также развитие методов математического моделирования ТП.

Поэтому тематика исследований диссертационной работы, направленных на разработку и совершенствование методов управления ТП с прогнозирующей

моделью, представляется весьма важной и актуальной и соответствует заявленной специальности.

Степень научной разработанности проблемы. Актуальность применения идентификационных моделей в системах автоматического управления ТП отмечена в работах известных ученых: К.Й. Острема, Л.Льюнга, Я.З. Цыпкина, Н.С. Райбмана, И.И. Перельмана, В.М. Чадеева, В.А. Лотоцкого, А.В. Назина, А.Л. Бунича, А.Г. Александрова, А.Ю. Торгашова, и многих других.

Объектом диссертационного исследования являются ТП непрерывных и полунепрерывных производств.

Предмет диссертационного исследования – методы и алгоритмы разработки ВА ТП непрерывных и полунепрерывных производств, основанные на идентификационных моделях ассоциативного МРС.

Целью диссертационной работы является разработка ВА ТП на основе ассоциативного поиска и алгоритмов управления ТП непрерывных и полунепрерывных производств с прогнозирующей моделью, формируемой с использованием ассоциативных ВА.

Для достижения данной цели поставлены и решены следующие задачи:

- Детальный анализ и исследование существующих алгоритмов управления ТП с прогнозирующей моделью и выделение магистральных направлений в области исследования;
- Разработка ВА показателей качества ТП на основе алгоритма ассоциативного поиска, обеспечивающих повышение точности моделей, в том числе для нелинейных нестационарных процессов;
- Разработка алгоритма МРС с использованием ассоциативных ВА для непрерывных и полунепрерывных производств – «ассоциативного МРС» (АМРС);
- Формирование критерия выбора глубины горизонта прогнозирования АМРС для повышения качества управления ТП;

- Разработка программного приложения, реализующего предложенные методы, и проведение вычислительных экспериментов для подтверждения их эффективности.

Результаты проведенных исследований должны продемонстрировать эффективность предложенных методов и алгоритмов в практических разработках.

Научная новизна диссертации обеспечивается следующими полученными результатами:

- Разработан метод построения ВА показателей качества продукции перерабатывающих отраслей промышленности на основе алгоритма ассоциативного поиска, позволяющий повысить точность моделей ТП, в том числе для нелинейных процессов.
- Предложен метод автоматического управления с прогнозирующей моделью – «ассоциативное MPC» (АМРС), позволяющий повысить эффективность управления нелинейными нестационарными ТП непрерывных и полунепрерывных производств.
- Разработан алгоритм расчета глубины прогноза выхода объекта управления, при задании которой гарантируется достижение цели управления с учетом принятых ограничений.
- Предложены методы разработки программно-алгоритмического комплекса, реализующего управление ТП с ассоциативными прогнозирующими моделями нелинейных процессов и формирующего базу индуктивных знаний.

Соответствие шифру специальности. Работа соответствует шифру специальности 2.3.3 и охватывает следующие области исследований, входящие в специальность: п. 3. Методология, научные основы и формализованные методы построения автоматизированных систем управления технологическими процессами (АСУТП) и производствами (АСУП), а также технической подготовкой производства (АСТПП) и т.д.; п. 4. Теоретические основы и методы математического моделирования организационно-технологических систем и комплексов, функциональных задач и объектов управления и их алгоритмизация;

п. 6. Научные основы, модели и методы идентификации производственных процессов, комплексов и интегрированных систем управления.

Теоретическую значимость имеют методы разработки ВА ТП непрерывных и полунепрерывных производств на основе алгоритмов ассоциативного поиска и методы автоматического управления с прогнозирующей моделью ТП с использованием ассоциативных ВА.

Практическая ценность диссертационной работы заключается:

- в программной реализации методов разработки ассоциативных ВА и управления с прогнозирующими моделями, подтвердившей эффективность предложенных методов посредством численных экспериментов;
- во внедрении разработанных методов на промышленном объекте с документальным подтверждением эффекта внедрения.

Методология и методы исследования. Теоретические основы и методы идентификации систем управления, методы интеллектуального анализа данных, методы ассоциативного поиска, методы управления с прогнозирующей моделью в условиях неопределенности.

На защиту выносятся следующие положения:

- Метод построения ВА показателей качества продукции технологического объекта на основе ассоциативного поиска.
- Метод автоматического управления с ассоциативными ВА ТП непрерывных и полу-непрерывных производств – «ассоциативное MPC» (АМРС).
- Алгоритм расчета глубины прогноза выхода объекта для АМРС, при задании которой гарантируется удовлетворение системы управления необходимым ограничениям.

Апробация результатов

Основные положения диссертационной работы докладывались на 61 и 62 научно-технических конференциях МФТИ (НИУ) (Москва, 2018-19 гг.), на международных симпозиумах IFAC: 7th Symposium on Information Control Problems in Manufacturing (2021, Будапешт, Венгрия); Manufacturing Modelling, Management and Control – 10th MIM 2022 (г. Нант, Франция, 2022 г.); Information Manufacturing

Systems, IMS'2022 (г. Тель-Авив, Израиль, 2022 г.), а также на научных семинарах в Институте проблем управления имени В.А. Трапезникова РАН.

Реализация и внедрение результатов работы.

Основные результаты исследований были использованы АО «Стойленский ГОК» в рамках внедрения СУУТП на фабрике обогащения железорудного концентрата.

Обоснованность и достоверность научных положений обеспечивается корректным применением фундаментальных положений теории идентификации систем управления и проведенным всесторонним анализом эффективности современных подходов к управлению с прогнозирующей моделью. Близость результатов расчетов с использованием тестовых данных с результатами, полученными при внедрении на производстве, также свидетельствует о достоверности положений, выносимых на защиту.

Публикации. Основное содержание диссертационной работы отражено в восьми печатных работах, в том числе трех статьях в рецензируемых изданиях из перечня, рекомендованного ВАК.

Объем и структура работы. Диссертационная работа состоит из введения, четырех глав, заключения, списка литературы и приложения. Диссертация изложена на 116 страницах, список литературы включает 122 наименования. Приложение содержит акт, подтверждающий внедрение результатов диссертационной работы.

В первой главе представлен аналитический обзор основных направлений развития методов управления с прогнозирующей моделью (МРС), описаны традиционно применяемые в МРС алгоритмы идентификации и управления. На основании проведенного анализа и исследований существующих методов управления с прогнозирующей моделью сформулированы цель и научные задачи работы. Следующие главы посвящены решению задачи МРС при помощи методов ассоциативного поиска с использованием базы индуктивных знаний.

Вторая глава посвящена методу разработки виртуального анализатора (ВА) качества продукции на основе идентификационных алгоритмов ассоциативного поиска. Выявлены преимущества данного метода по сравнению с традиционными.

Качество продукции является важнейшим параметром оптимизации технологических процессов (ТП). Несмотря на важность показателей качества продукта, их не всегда возможно измерять напрямую в режиме реального времени. Это – сложная задача, которая требует специального аналитического оборудования, оперативно реагирующего на изменения измеряемых показателей в ходе функционирования технологического объекта. Хотя различные методы и средства отбора и физико-химического анализа проб продукта на выходе ТП широко распространены на производстве, они, как правило, являются инерционными и дорогостоящими. Поэтому ВА приобрели популярность в качестве недорогой альтернативы сложных аналитических систем [11-14].

ВА представляют собой специальные программно-алгоритмические комплексы, формирующие модели прогнозирования показателей качества. Они позволяют точно контролировать свойства продукции в режиме реального времени без капитальных затрат и трудоемкого обслуживания. ВА способны контролировать свойства, не поддающиеся контролю с помощью традиционных поточных анализаторов, к ним применимы минимальные требования при калибровке и обслуживании.

ВА используются для мониторинга физических и химических свойств в местах, где использование обычных анализаторов физически невозможно или экономически нецелесообразно.

ВА на основе линейной регрессии с автоподстройкой свободного члена по данным лабораторного контроля хорошо показали себя на практике, но для некоторых нелинейных объектов они дают неадекватный прогноз. В диссертационной работе предлагается новый подход к прогнозированию показателей качества. Модели, построенные при помощи алгоритмов ассоциативного поиска, используют базу знаний ТП для построения на каждом

временном такте лучшей в смысле метода наименьших квадратов (МНК) модели ТП.

Алгоритм построения аппроксимирующей поверхности для точечной идентификационной модели состоит из следующих этапов:

1. Создается база индуктивных знаний на основе анализа архивных данных функционирования ТП.
2. Все наполнение базы знаний ТП за достаточно большой период разбивается на кластеры с использованием одного из известных методов кластеризации.
3. В каждый момент времени анализируется, в какой кластер попал текущий вектор входов.
4. Из данного кластера выбираются входные векторы, характеризующиеся незначительной корреляцией с текущим (с учетом больших объемов баз данных современных АСУ ТП такой выбор возможен). Из архива выбираются соответствующие реальные значения выходов.
5. Далее для конкретного исследуемого момента времени определяются коэффициенты ассоциативной модели и прогнозируемое значение выхода.

ВА для систем управления ТП с ассоциативными моделями могут содержать статистически зависимые переменные. В подобных случаях значения коэффициентов модели и прогноз выхода получаются как псевдо-решения систем линейных уравнений в соответствии с методом наименьших квадратов (МНК) с применением процедур типа Мура–Пенроуза и сингулярного разложения матриц.

Эту процедуру можно применить для формирования цифровых идентификационных моделей в замкнутом контуре управления ТП. Алгоритм ассоциативного поиска позволяет получить модели, которые для каждого временного такта описываются синхронизированными наборами значений входов, выходов, управляющих воздействий, коэффициентов, т.е. цифровые модели, которые формируются идентификатором в цепи обратной связи МРС. В данном

случае идентификатор является цифровым двойником, поскольку он формирует цифровую предиктивную модель на основе текущих и статистических данных ТП.

Для нестационарных процессов метод ассоциативного поиска также предлагает конструктивное решение задачи идентификации – с применением вейвлет-преобразования [15]. Такой подход продемонстрировал эффективность как для нестационарного входного сигнала, так и в случае немоделируемой внутренней динамики объекта управления. Для того чтобы применить алгоритм ассоциативного поиска для прогнозирования динамики нестационарных ТП, необходимо выбрать из технологического архива векторы, близкие к текущему в смысле критерия, формируемого для коэффициентов кратно-масштабного вейвлет-разложения.

Предложен метод разработки программно-алгоритмического комплекса для формирования в режиме реального времени моделей ассоциативного поиска – ассоциативного ВА. В каждый текущий момент по результатам первичной обработки и анализа данных создается структура точечной модели и формируется база индуктивных знаний. Далее осуществляется обучение системы идентификации. На данном этапе осуществляется кластеризация наборов переменных, характеризующих состояние ТП для каждого временного такта. Для кластеризации может использоваться один из известных методов. Для построения ассоциативных цифровых моделей реального времени осуществляется актуализация индуктивных знаний в базе, построенной на этапе обучения системы.

При построении модели необходимо учитывать специфику работы лаборатории на производстве для ТП определенного типа. Зачастую лабораторный анализ продукции производится не на разовых, а на усредненных пробах. Моделирование должно обеспечивать не только достаточно точное описание ТП данного класса, но и адекватно отражать конкретику производственной ситуации и особенностей конкретного технологического объекта, т.е. максимально возможным образом использовать всю имеющуюся априорную информацию. В частности, необходимо учитывать все ограничения, определяемые как технологическим регламентом, так и экспертными мнениями. В качестве эксперта,

анализирующего ситуацию, выступает лицо, принимающее решения – оператор или технолог. Таким образом, при разработке ВА ТП выделяются следующие основные элементы:

- Описание ТП: его особенности, позволяющие формализовать процесс с помощью определенных математических моделей; учет отдельных данных технической документации, в частности, технологического регламента, что позволяет ввести все необходимые ограничения.
- База технологических регламентов содержит (в формализованном виде) описание следующих позиций:
 - технологические нормативы;
 - правила выполнения операций в различных ситуациях;
 - детальный порядок ведения ТП;
 - правила ведения режима;
 - параметры режима.
- База библиотек формализованного представления процессов и их математических моделей.
- Схема информационных потоков исследуемого ТП, формируемая пользователем системы с помощью интерактивного интерфейса, которая позволяет формализовать описание моделируемого процесса в виде дифференциальных либо разностных уравнений.
- База индуктивных знаний ТП должна содержать архив «производственного опыта» конкретного ТП: от синхронизированных во времени входов и соответствующих им выходов – до архивов настроенных моделей и архивов формализованных ситуаций – «закодированных» признаков и характеристик текущего состояния. Основными элементами системы для формирования и хранения знаний, интерпретируемых как закономерности, характеризующие ТП, являются:
 - База данных функционирования исследуемого ТП;

- данные технологического оборудования – фактические расходы в конкретные моменты времени технологических параметров: расходы, давления, температуры и т.д.; возможные отклонения от штатных ситуаций (набор шаблонов), дополнительные ограничения;
- база построенных точечных моделей процессов (архив построенных моделей): наборы значений входов и управлений, а также соответствующих им выходов (готовая продукция, побочная продукция, отходы) по данным мониторинга;
- Оценки результатов и рекомендации для управления (в том числе, формализованные) – оценки, получаемые с помощью ассоциативных алгоритмов идентификации, а также формализованные значения оценок экспертов (например, с помощью нечетких моделей).

В третьей главе рассмотрен метод управления с прогнозирующей моделью с использованием метода ассоциативного поиска и базы индуктивных знаний.

Алгоритм управления в схеме АМРС предполагает следующую последовательность действий. Предполагается, что при нахождении необходимого управления можно выйти за ограничение $|u| \leq U$.

Если получаемый по модели выход на следующем такте удовлетворяет требуемым ограничениям, то управление остается неизменным. Если же прогнозируемое значение выходного сигнала на следующем такте не удовлетворяет ограничению, предлагается процедура выбора управляющего воздействия.

Приводится обобщение решения задачи управления с прогнозирующей моделью на случай с векторного управляющего воздействия.

Сформирована процедура прогноза выхода объекта на несколько тактов вперед; приведен алгоритм расчета глубины прогноза, при котором гарантируется робастность алгоритма управления.

В четвертой главе описана СУУТП, реализованная на обогатительной фабрике АО «Стойленский ГОК», с использованием представленных в диссертации методов прогнозирования. Приведены результаты экспериментов.

СУУТП реализована в виде одного многопараметрического контроллера, который охватывает: шаровые мельницы, зумпфы и дешламаторы. Приведена модельная матрица, состоящая из передаточных функций, в которой отражены взаимосвязи входных и выходных параметров ТП.

Для проверки работоспособности предложенных алгоритмов был проведен ряд вычислений, для проведения сравнительного анализа работы различных типов ВА содержания железа в секционном концентрате. Показано, что на основе методов, предложенных автором, удалось на 2,3% увеличить загрузку руды на вход головных мельниц обогатительной фабрики, а также на 34% уменьшить дисперсию лабораторных значений показателей качества железорудного концентрата; эффект от внедрения подтвержден АО «Стойленский ГОК».

В Заключении приведены основные результаты и выводы.

Глава 1. Алгоритмы управления с прогнозирующей моделью

Наиболее распространенными методами управления в системах управления ТП с обратной связью на современном производстве являются: ПИД-регулирование [16,17] и управление с прогнозирующей моделью (Model Predictive Control – MPC) [18-20].

ПИД-регулирование – один из классических подходов к регулированию SISO-контуров (от англ. «Single-input, single-output», т.е. с одним входом и одним выходом) с обратной связью, обладающих минимально-фазовыми характеристиками [21]. Управляющий сигнал на объект подает ПИД-регулятор (от «пропорционально-интегрально-дифференциальный»). Сигнал состоит из трех слагаемых: первое пропорционально входному сигналу на регулятор, (ошибка управления), второе есть интеграл входного сигнала, а третье – производная управляющего сигнала.

Если в регулировании не используется какая-либо составляющая ПИД-регулятора, то регулятор называют пропорциональным, интегральным, дифференциальным, пропорционально-интегральным, пропорционально-дифференциальным и т.п. На вход регулятора подается значение ошибки управления – разности между текущим значением регулируемой величины и задающего значения, называемого также «уставкой». Целью управления является поддержание текущего значения регулируемой величины равным уставке, т.е. сведение ошибки управления к нулю.

Как показано в работе [22], основные трудности в управлении SISO и MIMO (от англ. «multiple inputs, multiple outputs», т.е. несколько входов и несколько выходов) системами возникают при наличии в них контуров с явлениями запаздывания или обратного отклика. Данные явления дестабилизируют классические контуры ПИД-регулирования, затрудняют управление ТП, тем самым повышая вероятность нарушения технологического режима.

Классические методы ПИД-регулирования плохо справляются с контурами, в которых присутствует обратный отклик или чистое запаздывание. Использование элементов так называемого расширенного регулирования (сложные каскады ПИД-регуляторов, компенсаторы, управление отношением, управление с опережением и запаздыванием, упредители и т.д.) не всегда дает желаемый эффект.

Наиболее универсальным и эффективным методом управления многосвязными объектами при наличии описанных выше сложностей в последние десятилетия стало т.н. «усовершенствованное управление с прогнозирующей моделью» ТП (MPC – от англ. «Model Predictive Control») [23].

Сфера применения MPC в задачах оптимизации сложных многомерных объектов с ограничениями постоянно расширяется. MPC-алгоритмы применяются в управлении электрическими микросетями [24], водопроводными сетями [25], системами отопления зданий [26], автопилотом для моделирования движения транспортных средств [27], управлением космическими аппаратами [28] и др.

В целом, MPC принадлежит к наиболее эффективным средствам автоматического управления сложными ТП. Данная технология позволяет решать разнообразные задачи: от стабилизации работы объекта, до его оптимизации по заданному критерию (максимуму производительности, минимуму себестоимости, минимуму удельного энергопотребления и пр.) [29].

В MPC-систему встроена заранее разработанная на основе экспериментальных данных динамическая модель объекта по всем регулируемым величинам от всех управляющих воздействий и наблюдаемых возмущений. Прогнозирующая динамическая модель в алгоритмах MPC необходима для построения прогноза динамики ТП. На основе построенного прогноза MPC-система вырабатывает необходимые корректирующие воздействия на ТП.

Задача управления с прогнозирующей моделью формулируется следующим образом. Пусть система управления описывается системой обыкновенных нелинейных дифференциальных уравнений вида [30]:

$$\dot{x}(t) = f(t, x(t), u(t)), \quad x(0) = x_0, \quad (1)$$

где $\mathbf{x}(t)$ – вектор состояний размерности n , а $\mathbf{u}(t)$ – вектор управления размерности m . На компоненты векторов состояний и управления могут быть наложены ограничения, например, в виде:

$$\begin{aligned} x_{imin} &\leq x_i \leq x_{imax}, i = 1, \dots, n, \\ u_{jmin} &\leq u_j \leq u_{jmax}, i = 1, \dots, m. \end{aligned} \quad (2)$$

Будем считать, что целью управления является выполнение равенств:

$$\lim_{t \rightarrow \infty} \|\mathbf{x}(t) - \mathbf{r}_x(t)\| = 0, \quad \lim_{t \rightarrow \infty} \|\mathbf{u}(t) - \mathbf{r}_u(t)\| = 0. \quad (3)$$

Здесь заданные векторные функции $\mathbf{r}_x(t)$ и $\mathbf{r}_u(t)$ определяют желаемую динамику объекта. Качество управления при этом будет оцениваться с использованием целевой функции $J(\mathbf{x}(t), \mathbf{u}(t))$, заданной на управляемых траекториях движения объекта. Задача оптимального управления – доставить минимум функционалу J при соблюдении всех требуемых ограничений.

Для решения задачи МРС используется прогнозирующая модель ТП.

$$\dot{\bar{\mathbf{x}}}(\tau) = \mathbf{f}(\tau, \bar{\mathbf{x}}(\tau), \bar{\mathbf{u}}(\tau)), \quad \bar{\mathbf{x}}(\tau)|_{\tau=t} = \mathbf{x}(t) \quad (4)$$

В линейном МРС она имеет вид «модельной матрицы», элементами которой являются конечно-импульсные характеристики или передаточные функции, описывающие зависимости между управляющими и контролируемыми переменными МРС-системы. Пример модельной матрицы размерности 3×3 с передаточными функциями представлен на рис. 1.1.




Рис. 1.1 Модельная матрица ТП (пример):

CV – контролируемые переменные, MV – управляющие переменные

Алгоритм МРС включает в себя следующие основные этапы:

1. Оценивание вектора состояния $x(t)$ реального объекта;
2. Решение оптимизационной задачи $J(x(t), u_{\text{пр}}(t), T_p, T_c) \rightarrow \min$, где T_p – горизонт прогнозирования, T_c – горизонт управления, $u_{\text{пр}}$ – прогнозируемое управление;
3. Применение найденного оптимального управления в качестве программного на отрезке $t \in [t; t + \delta]$, где δ – интервал дискретизации системы;
4. Замена времени t на $t + \delta$ и повторение операций 1–3.

Решение задачи МРС проиллюстрировано на рис. 1.2.




Рис. 1.2 Решение задачи MPC

В задачах MPC наиболее распространенным видом целевой функции J является квадратичный функционал [31]:

$$J = \int_0^{\infty} [(x(t) - r(t))^T R (x(t) - r(t)) + \lambda^2 u^T(t) Q u(t)] dt, \quad (5)$$

где $r(t)$ — задающий сигнал, R и Q — диагональные матрицы с весовыми коэффициентами. Первое из двух слагаемых в квадратных скобках «штрафует» целевую функцию при отклонении от задающего сигнала, а второе ограничивает размеры управляющих воздействий («шагов» по управляющим переменным).

Если целевая функция задана в виде квадратичного функционала, а прогнозирующая модель — линейная, то задача поиска оптимального управления сводится к задаче линейно-квадратичного программирования.

Представим дискретную математическую постановку задачи управления на основе прогнозирующей модели. В таком виде она решается в промышленных многопараметрических контроллерах:

$$\begin{aligned}
x[k+1] &= Ax[k] + Bu[k], x[0] = x_0, \\
J[k] &= \sum_{i=1}^p w_i (x[k+i|k] - r[k+i|k])^2 \\
&\quad + \sum_{i=1}^c r_i \Delta u[k+i-1|k]^2 \rightarrow \min_{u[k|k], \dots, u[k+p-1|k]}, \\
u_{min} &\leq u[k+i-1|k] \leq u_{max}, i = 1, \dots, c, \\
-\Delta u_{min} &\leq \Delta u[k+i-1|k] \leq \Delta u_{max}, i = 1, \dots, c, \\
x_{min} &\leq x[k+i|k] \leq x_{max}, i = 1, \dots, p.
\end{aligned} \tag{6}$$

Здесь c, p – соответственно горизонты управления и прогнозирования, выраженные в количестве шагов по времени; выражение $x[i | j]$ интерпретируется как значение x в момент времени i , определенное в момент времени j .

В работе [32] численно оценена область робастности линейных алгоритмов MPC – максимально допустимое расхождение прогнозирующей модели и динамики ТП, при котором сохраняется адекватное управление. Область робастности приведена на рис. 1.3.

Линейные алгоритмы MPC робастны по отношению к коэффициентам прогнозирующей модели, что позволяет адекватно управлять ТП, даже при заметном рассогласовании.




Рис. 1.3 Область робастности линейных алгоритмов MPC

Тем не менее, существует большое количество систем, управление которыми при помощи линейного MPC невозможно из-за сильной нелинейности объекта управления. Поэтому в последние годы традиционные линейные алгоритмы MPC уже не могут удовлетворить возрастающим требованиям сложных промышленных ТП к точности и эффективности управления.

Алгоритмы MPC комбинируют с другими алгоритмами ради создания более эффективных стратегий управления. В качестве примеров можно привести сочетание инженерной экономики с предиктивным управлением для нелинейного модельного предиктивного управления [33], алгоритм оптимального управления в сочетании с нейронной сетью [34], алгоритм MPC на основе нечеткого моделирования [35], MPC на основе обучения с подкреплением [36] и др.

Можно выделить следующие основные направления развития MPC за последние годы:

1. Управление с прогнозирующей моделью нелинейными процессами (Non-linear Predictive Control – NMPC).
 - 1.1. Предиктивное управление нелинейными процессами с использованием линеаризации (Linearized nonlinear predictive control – NMPC). В системах

этого типа сначала линеаризуется нелинейная модель, далее решается задача оптимизации для линеаризованных моделей.

1.2. Гибридные системы управления с прогнозирующей моделью (Non-linear predictive control of hybrid systems). Этот тип MPC хорошо подходит для описания дискретных динамических процессов с логическим переключением. Путем добавления логических переменных сегментированная система с характеристиками логического переключения преобразуется в гибридную логическую, после чего формируется оптимальное управление.

1.3. Многомодельные методы предиктивного управления (Multi-model NMPC).

В рамках данного подхода при формировании управления используются несколько видов различных линейных моделей для аппроксимации нелинейности.

2. Стохастическое MPC (Random Predictive Control Model).

Стохастическими называют системы, подверженные случайным воздействиям. Они могут характеризоваться определенными вероятностными характеристиками. Можно также говорить о случайной неопределенности, когда неопределенные воздействия принадлежат некоторому множеству.

3. MPC, объединенное с другими алгоритмами управления.

В последние годы в ряде исследований описывается возможность сочетания алгоритма MPC с другими алгоритмами для разработки класса новых стратегий предиктивного управления. Наиболее значимые примеры представлены в таблице 1.1.

Таблица 1.1. - Основные типы современных алгоритмов MPC

Стратегия управления	Применение
PID Predictive Control Улучшенный ПИД-регулятор на основе предиктивного функционального управления.	Пример и результаты тестирования представлены для исследования изменения давления в камере промышленной коксовой печи [37].
Fuzzy Predictive Control Управление с нечеткой предиктивной моделью	Использование Fuzzy Predictive Control для отопления зданий [38]
Adaptive Predictive Control Адаптивное управление с предиктивной моделью	Использование Adaptive Model Predictive Control для эффективного управления набором высоты квадрокоптером [39]
Neural Network Predictive Control Предиктивное управление с использованием нейронных сетей	Использование Neural Network Predictive Control для управления тепловыми процессами в целях экономии энергии [40]

1.1. Управление нелинейными процессами на основе прогнозирующей модели (NMPC – Nonlinear MPC)

Многочисленные внедрения алгоритмов MPC с линейной прогнозирующей моделью стали значимыми событиями в развитии теории и практики управления с обратной связью. Однако реальные ТП зачастую характеризуются нелинейными

свойствами, и разработанные для них линейные модели не всегда удовлетворяют необходимым требованиям.

Оптимизационная задача для линейного MPC с ограничениями формулируется следующим образом [41]:

$$\min_{\Delta u(k|k), \dots, \Delta u(k+N_u-1|k)} \left\{ \sum_{p=1}^N \|y^{sp}(k+p|k) - y(k+p|k)\|^2 + \alpha \sum_{p=0}^{N_u-1} \|\Delta u(k+p|k)\|^2 \right\}; \quad (7)$$

$$u_{min} \leq u(k+p|k) \leq u_{max}, \quad p = 0, 1, \dots, N_u - 1; \quad (8)$$

$$-\Delta u_{min} \leq \Delta u(k+p|k) \leq \Delta u_{max}, \quad p = 0, 1, \dots, N_u - 1; \quad (9)$$

$$y_{min} \leq y(k+p|k) \leq y_{max}, \quad p = 1, \dots, N, \quad (10)$$

где:

N_u – горизонт управления,

N – горизонт прогнозирования,

y^{sp} – желаемая динамика ТП,

y – предсказанный выход системы управления,

u – вход системы управления,

α – весовой коэффициент.

Выражение $u(k+p|k)$ обозначает предсказание управления для момента времени $k+p$, рассчитанное в текущий момент времени k .

Выражение (8) выступает в роли ограничения на входы системы управления, (9) – на максимальное изменение входов, а (10) – на контролируемые выходы.

На первый взгляд, идея обобщения линейного MPC на нелинейный случай выглядит достаточно просто: оставляя конструкцию (7) неизменной, нужно лишь использовать нелинейную модель ТП вместо линейной для прогнозирования выходов на горизонте прогнозирования. Однако нелинейная зависимость прогнозируемых выходов от входов приводит к тому, что задача оптимизации становится неквадратичной и, вообще говоря, невыпуклой. Универсальных оптимизационных процедур, которые обеспечивали бы надежное и быстрое решение таких задач, не существует.

Наиболее простым решением, позволяющим естественным образом обобщить известные свойства линейных алгоритмов прогнозирования (т.е. с линейными моделями процессов) на случай нелинейного прогнозирующего управления, являются алгоритмы, которые в каждый момент времени линеаризуют нелинейную модель, после чего вычисляют управляющие входы, используя линейный алгоритм MPC с линеаризованной моделью [42,43].

Этот подход является субоптимальным, но именно он дает гарантию того, что на каждом шаге алгоритма управления будет находиться решение задачи управления, удовлетворяющее заданным ограничениям, причем всегда в течение заданного времени. Рассмотренная структура субоптимального нелинейного MPC-управления с линеаризацией модели в литературе именуется MPC-NSL (MPC Nonlinear with Successive Linearizations).

Более точное, чем MPC-NSL алгоритмическое решение, в то же время простое в реализации, заключается в использовании нелинейной модели для построения свободного прогноза выхода системы, тогда как линеаризованная модель используется для расчета выхода, линейно зависящего от управляющих входов [44,45]. Эта структура называется MPC-NPL (MPC с нелинейным прогнозированием и линеаризацией).

Поскольку линеаризация нелинейной модели не всегда дает желаемый результат, ряд исследователей и разработчиков используют для решения задачи оптимального управления NMPC численные методы. Последние подразделяются на прямые и косвенные.

Косвенные методы основаны на принципе «сначала – оптимизация, затем – дискретизация», когда условия оптимальности сначала формулируются для непрерывной задачи оптимального управления, а получаемая краевая задача далее решается численными методами.

Прямые методы основаны на принципе «сначала – дискретизация, затем – оптимизация». В данном случае дискретная аппроксимация непрерывной задачи оптимального управления проводится в первую очередь, после чего полученная

конечномерная задача нелинейного программирования может быть решена с использованием итеративных алгоритмов.

При косвенном подходе для построения краевой задачи требуются значительные усилия. В целом, такой подход менее привлекателен для систем со стабильной динамикой, но широко используется для управления процессами, динамика которых нестабильна. Примером может служить управление спутником [46].

Основное преимущество прямых методов обеспечивает задача нелинейного программирования, получаемая в результате дискретизации задачи оптимального управления. Задачи нелинейного программирования хорошо изучены, и в настоящее время существуют эффективные программные реализации алгоритмов их численного решения, например, IPOPT [47].

Прямые методы делятся на две группы: последовательные и синхронные. Примером последовательного подхода является прямой метод однократной стрельбы, в котором переменные состояния вычисляются путем интегрирования динамики системы. В прямом методе многократной стрельбы [48], который является примером синхронного подхода, дискретизация управляющего воздействия полностью аналогична методу однократной стрельбы, но, в результате, задача Коши решается отдельно на каждом временном интервале.

Поскольку время, отведенное на вычисление оптимальной стратегии управления, строго ограничено, решение возникающих задач нелинейного программирования до полной сходимости обычно не представляется возможным в условиях ограниченности вычислительных мощностей. Это потребовало разработки алгоритмов, сходящихся к субоптимальным решениям за относительно короткое время [49,50].

1.2. Стохастические алгоритмы

Стохастическое прогнозирующее управление (stochastic MPC – SMPC, или Random MPC) становится областью исследований, представляющей существенный практический интерес [51,52]. Это обусловлено тем, что большинство объектов

управления характеризуются стохастической неопределенностью и подчиняются ограничениям, которые могут быть вероятностными по своей природе.

Дискретная модель системы в постановке SMPC может быть описана выражением:

$$x(k+1) = f(x(k), u(k), w(k)), \quad (11)$$

где $x(k) \in \mathbf{R}^{N_x}$, $u(k) \in \mathbf{R}^{N_u}$ – состояние системы и управляющий вход соответственно. Множество $\mathbf{R}^N$ обозначает n –мерное евклидово пространство, функция f характеризует динамику системы. Переменная $w(k) \in \mathbf{R}^{N_w}$ описывает неопределенность модели или внешнее возмущение с заданными распределениями вероятности $w(k) \sim \mathbf{P}_w$, где $\mathbf{P}_w$ обозначает распределение вероятности случайной величины w .

Оптимизационная задача SMPC формулируется аналогично задаче линейного MPC (7), но вместо ограничений (10) используются стохастические ограничения на прогнозируемые выходы системы управления:

$$\Pr_k[g_j(x(i|k)) \leq h_j] \geq 1 - p_j, j = 1..N_x, i = 0..N-1, \quad (12)$$

где N_x – общее число стохастических ограничений, p_j – вероятность нарушения ограничения. Функция $g_j(x(i|k)): \mathbf{R}^{N_x} \rightarrow \mathbf{R}$, $h_j \in \mathbf{R}$. $\Pr_k[\cdot]$ обозначает условную вероятность.

Существует несколько подходов к решению задачи SMPC. Одним из них является «построение стохастических трубок» – «stochastic tube-based approach» [53]. Построение стохастических трубок может обеспечить рекурсивную выполнимость алгоритма оптимизации, вероятностное удовлетворение ограничений и робастность системы управления. Были изучены многочисленные вариации построения стохастических трубок, такие как метод эллипсоидной трубки [54], метод трубки с вложенными слоями [55] и трубка с фиксированным сечением и изменяющимся масштабированием [56]. Эффективность алгоритма SMPC зависит от построения сечения трубки, которое в основном определяется распространением неопределенных компонентов через динамику системы.

Другим методом решения задачи SMPC является так называемый «сценарный подход» – «scenario-based approach» [57]. В данном подходе на основе «сценариев» в режиме реального времени генерируется достаточное количество различных неопределенностей, так что можно получить подходящее приближение к оптимизационной задаче SMPC. По сравнению с другими подходами SMPC этот метод может быть использован в более общих ситуациях, с использованием больших вычислительных ресурсов в режиме реального функционирования исследуемого объекта в [58].

Практическое применение алгоритма SMPC описано в работе [59], где вероятностные модели включены в алгоритм HEMS («Home Energy Management System»), а также [60] для учета неопределенности в прогнозах погоды для энергоэффективного использования систем отопления, вентиляции и кондиционирования зданий.

1.3. ПИД-предиктивное управление (PID-predictive control)

ПИД-регуляторы имеют широкое применение в системах автоматического управления. Хорошо известно, что обеспечение хорошего качества регулирования зависит от правильной настройки ПИД-регулятора. На протяжении долгой истории применения ПИД-регуляторов было предложено множество методов их настройки.

Наиболее известен и популярен метод Циглера–Никольса (Z-N-метод, [61]). Для того чтобы компенсировать ограниченность его применения в процессах с запаздыванием, Коэн и Кун предложили усовершенствованный подход к настройке параметров регулятора [62].

Tukey и Luypen разработали специальный метод TLC настройки параметров регулятора для объектов первого порядка с запаздыванием [63]. Позднее был предложен метод настройки ПИД-регулятора на основе «внутренней модели управления» для улучшения динамических характеристик замкнутой системы [64].

Однако для промышленных процессов с большой временной задержкой и нелинейностью применение вышеупомянутых традиционных ПИД-регуляторов может не дать желаемого эффекта. Для решения этой проблемы был предложен

упредитель Смита, который известен как усовершенствованный алгоритм ПИД-регулирования для объектов с запаздыванием [65,66].

В отличие от ПИД-регуляторов, упредитель Смита преобразует передаточную функцию замкнутой системы в выражение с выделенным запаздыванием, что приводит к совпадению кривой отклика всей замкнутой системы с откликом соответствующей замкнутой системы без временной задержки. Однако повысить качество регулирования с помощью упредителя Смита не просто в силу сложности построения моделей ТП в замкнутом контуре.

Существенным шагом вперед стало появление технологии управления с прогнозирующей моделью (МРС), развитие которой совпало с существенным повышением производительности вычислительных платформ. Было проведено исследование возможностей алгоритма в управлении ТП с временными задержками.

Технология МРС продемонстрировала хорошие результаты, предоставляя возможность прогнозирования и эффективный механизм коррекции управления по обратной связи, что позволяет учитывать сложное поведение процесса с неопределенностями. Однако применение МРС более проблематично, чем простое ПИД-регулирование в связи с дополнительными затратами на вычислительную технику, дорогостоящие программное обеспечение, проектирование и реализацию системы, что делает необходимым поиск компромисса между МРС с одной стороны и базовым и расширенным регулированием с другой.

В работе [67] на примере управления давлением в камере коксовой печи рассматривается алгоритм прогнозирующего функционального управления, который используется для создания нового ПИД-регулятора. Такой усовершенствованный регулятор обладает характеристиками алгоритма МРС при той же структуре, что и у традиционных ПИД-регуляторов.

1.4. Управление с нечеткой прогнозирующей моделью (Fuzzy MPC)

Нечеткое MPC (Fuzzy MPC) представляет собой алгоритм управления с прогнозирующей моделью, где модель получается на основе нечетко-логических построений.

Теория нечетких множеств была предложена Л.А. Заде (L.A. Zadeh) в 1965 г. [68], хотя ее первое успешное промышленное применение для целей управления имело место лишь в 1976 г. (на цементном заводе в Дании). Бурное развитие теории нечеткой логики и ее применений в задачах управления пришлось на конец 1980-х гг. и продолжается до сих пор. Нечеткие регуляторы весьма эффективны в отсутствие адекватного аналитического описания управляемого объекта и при наличии накопленных эмпирических знаний, опыта операторов, управляющих соответствующими процессами, или модели требуемого поведения объекта.

В Fuzzy MPC нелинейная система делится на ряд «почти линейных» подсистем. Далее, с помощью нечеткой логики для каждой подсистемы разрабатывается квазилинейная эмпирическая модель. Поведение всего объекта характеризуется взвешенной суммой выходов всех квазилинейных моделей. Данная методология облегчает разработку нелинейной модели, которая, по сути, является совокупностью ряда квазилинейных моделей, регулируемых нечеткой логикой.

В 1991 г. был разработан алгоритм FMPC с использованием модели типа T-S (Takagi-Sugeno's model) [69]. Для описания FMPC с использованием T-S-моделей рассмотрим «сильно» нелинейную SISO систему $\mathcal{S}$ (SISO – «Single Input Single Output»). Система разбивается на p подсистем, каждая из которых характеризуется линейным или «почти» линейным поведением. Для каждой подсистемы необходимо построить T-S-модель [70]. Подсистемы определены в нечетких областях R^i , $i = 1, 2, \dots, p$.

Каждая нечеткая область характеризуется декартовым произведением:

$$R^i = y(n) \times y(n-1) \times \dots \times y(n-m+1) \times u(n) \times u(n-1) \times \dots \times u(n-l+1), \quad (13)$$

где:

$y(n - j)$ – измеренный выход y в момент времени $n - j$;

$u(n - j)$ – измеренный вход u в момент времени $n - j$.

Для каждой области R существует нечеткое правило (fuzzy rule), на основе которого генерируется реакция системы на изменение входов [71]:

$$R_i: \text{IF } y(n) \text{ is } A_0^i, y(n - 1) \text{ is } A_1^i, \dots, y(n - m + 1) \text{ is } A_{m-1}^i,$$

и

$$u(n) \text{ is } B_0^i, u(n - 1) \text{ is } B_1^i, \dots, u(n - l + 1) \text{ is } B_{l-1}^i$$

$$\text{THEN } y^i(n + 1) = y(n) + \sum_{j=1}^T h_j^i \Delta u(n + 1 - j), \quad (14)$$

где:

A_j^i – нечеткое множество соответствующее выходу $y(n - j)$ в правиле i ;

B_j^i – нечеткое множество соответствующее входу $u(n - j)$ в правиле i ;

h_j^i – коэффициент импульсной переходной характеристики в правиле i ;

T – горизонт прогнозирования модели;

$\Delta u(n)$ – разница между $u(n)$ и $u(n - 1)$.

Полная нечеткая модель для системы S состоит из p компонентов. Выход системы $y(n + 1)$ определяется как взвешенное среднее значение выходов для каждого правила R^i :

$$y(n + 1) = \sum_{j=1}^p w^j y^j(n + 1) / \sum_{j=1}^p w^j, \quad (15)$$

где w^j – весовой коэффициент для каждого правила R^j .

Основная задача FMPC – минимизация прогнозируемой ошибки между выходом $y(n)$ и заданной траекторией движения системы $y^{ref}(n)$. Задача оптимизации может быть сформулирована следующим образом:

$$\min_{\Delta u(n), \Delta u(n+1), \dots, \Delta u(n+N_u)} \sum_{i=1}^{N_y} \mu_i \left(y(n + i) - y^{ref}(n + i) \right)^2 + \sum_{i=1}^{N_u} \vartheta_i \Delta u(n + i)^2, \quad (16)$$

где:

μ_i – весовой коэффициент для ошибки прогнозирования,

v_i – весовой коэффициенты для ошибки управления,

$y(n + j)$ – i -е значение предсказанного выхода,

$y^{ref}(n + j)$ – i -е значение требуемого выхода,

$\Delta u(n + i)$ – i -й шаг управления,

N_y – горизонт предсказания,

N_u – горизонт управления.

T-S-модели используются в FMPC и сегодня. Например, они нашли свое применение в системах отопления и кондиционирования зданий [72,73].

1.5. Адаптивное управление с прогнозирующей моделью (Adaptive predictive control)

Качество прогнозирующей модели играет важную роль в MPC, но в модели в той или иной степени присутствуют неопределенности, которые могут значительно снизить производительность системы.

Одним из способов решения таких проблем является разработка робастных методов MPC, которые гарантируют определенную эффективность управления при неопределенности модели. Робастность классических методов MPC продемонстрирована, в частности, в работе [32]. В этом направлении исследований модель является фиксированной, поэтому эффективность управления ограничивается качеством фиксированной (исходной) модели.

Другим привлекательным способом обработки неопределенности модели является обновление последней в режиме реального времени на основе данных приборных измерений.

Разработка адаптивных алгоритмов MPC для нелинейных схем представляет собой весьма сложную задачу, поскольку широко используемое в теории линейного управления предположение о «принципе разделения» не применимо к общему классу нелинейных систем, в частности, при наличии ограничений. Адаптивные методы MPC с линейными прогнозирующими моделями исследуются в работах [74,75].

В работе [76] предложен адаптивный алгоритм МРС для класса ограниченных линейных систем с неопределенными параметрами. Алгоритм обновляет оценки параметров системы в режиме реального времени вырабатывает управляющее воздействие, удовлетворяющее заданным ограничениям.

Для построения такого адаптивного алгоритма МРС сначала был предложен алгоритм обновления параметров, основанный на оценивании скользящего горизонта. Он позволял предсказывать границу ошибки оценивания на заданном горизонте прогнозирования. Затем алгоритм оценивания был объединен с робастным методом МРС на основе модели сравнения, модифицированным для работы с изменяющимся во времени объектом.

Было показано, что предложенный алгоритм гарантирует реализуемость и устойчивость замкнутой системы при наличии ограничений на вход и(или) состояние.

В работе [77] представлен адаптивный метод создания МРС для нелинейных систем с параметрической неопределенностью. Характеристики системы улучшаются с течением времени, поскольку адаптивное управление обновляет ее модель в процессе функционирования объекта. Параметры многопараметрического контроллера обновляются только после получения их улучшенной оценки.

1.6. Предиктивное управление с использованием нейронных сетей (Neural Network predictive control)

В управлении производством и ТП предпринимались неоднократные попытки продемонстрировать результативность и эффективность нейросетевого прогнозирующего управления (NN-MPC).

Основная идея NN-MPC заключается в том, что для прогноза динамики ТП используется не линейная модель, а нейронная сеть. В работе [78] эффективность данного подхода проверяется с помощью имитационных экспериментов, а в качестве управляемого процесса выбран трубчатый теплообменник. Целью

управления является поддержание температуры нагретого выходного потока на заданном уровне при минимальном потреблении энергии.

В работе [79] нейронные сети используются для аппроксимации шага прогнозирования МРС и целевой функции оптимизации, а в [80] – для аппроксимации динамики нелинейной системы.

Существуют иные подходы к управлению с использованием нейронных сетей [81]. Основная идея заключается в следующем. В начале для заданного процесса и ограничений разрабатывается лучшая в своем классе архитектура МРС, обеспечивающая оптимальную производительность контроллера путем выбора лучшей модели ТП, лучшего алгоритма оценивания состояния и лучшего метода оптимизации. Очевидно, что такой многопараметрический контроллер будет иметь оптимальную производительность, но его практическое применение будет в значительной мере ограничено ввиду того, что построение лучшей в своем классе архитектуры МРС – задача весьма сложная, особенно для нелинейных и нестационарных ТП.

Далее, при имитационном моделировании формируются пары управляющих воздействий и выходов системы с использованием МРС. Сгенерированные данные содержат информацию об управлении, которое реализуется с помощью МРС путем решения сложной задачи оптимизации с ограничениями.

На следующей стадии, используя сгенерированные данные, нейросетевая модель обучается эмулировать управление, которое реализует «идеальное» МРС. После того как нейронная сеть обучена, МРС отключается, и нейронная сеть используется для самостоятельного управления объектом в режиме реального времени.

Основное преимущество данного метода заключается в том, что обученная нейронная сеть, в отличие от традиционного МРС, не решает никаких дорогостоящих задач оптимизации, что делает расчеты чрезвычайно быстрым и подходящим для управления в режиме реального времени.

Однако некоторые особенности искусственных нейронных сетей являются причиной ограниченности их применения в МРС промышленными объектами.

Прежде всего, к таким особенностям относится проблема «переобучения» [82]: запоминаются только «ответы», без анализа закономерностей входных данных. Эту проблему решают применением специальных методов регуляризации, либо увеличением объема обучающей выборки.

Другой проблемой является чувствительность к выбору обучающего набора [83,84].

Отличаются искусственные нейронные сети (в отличие от естественных) и ограниченной способностью к усвоению полученных при обучении навыков для последующего применения при решении новых задач [85]. Это существенно сужает их возможности при работе в динамически изменяющихся средах. Не всегда можно гарантировать, что однажды обученная сеть в определенной ситуации не перестанет работать.

1.7. Выводы

В настоящей главе отмечена практическая значимость метода МРС как наиболее эффективного средства автоматического управления сложными многосвязными объектами. Проанализированы основные направления развития МРС за последние 20 лет.

В параграфах 1.1, 1.3, 1.5 представлен аналитический обзор алгоритмов построения прогнозирующих моделей в схемах МРС, хорошо зарекомендовавших себя на практике.

При этом отмечено, что использование в схеме МРС цифровых алгоритмов идентификации, основанных на применении индуктивных знаний – закономерностей, извлекаемых посредством интеллектуального анализа данных, способствует увеличению эффективности управления нестационарными и нелинейными процессами.

Для идентификации нестационарных объектов применительно к МРС-системам актуальным представляется эффективным применение алгоритмов ассоциативного поиска с использованием вейвлет-анализа. Применение этого

подхода для разработки ВА ТП применительно к МРС представлено далее в Главе 2.

В параграфе 1.2 проанализированы известные алгоритмы прогнозирования, основанные на стохастической неопределенности объекта. В их основе лежит построение вероятностных моделей и их применение для решения оптимизационной задачи МРС. Задачи оптимального и квази-оптимального управления с неопределенностью в схеме МРС будут далее рассмотрены в Главе 2; там же исследуются возможности применения вейвлет-анализа для описания МРС в стохастической постановке.

В параграфе 1.4 рассмотрен контур МРС-регулирования с нечеткой прогнозирующей моделью. Исследованы методы, описывающие построение линейной динамической модели ТП в каждой точке фазового пространства (в терминах вход–выход). Отмечается целесообразность применения подхода на основе цифровых прогнозирующих моделей, в качестве обобщения известного алгоритма Fuzzy МРС. Соответствующий алгоритм, обеспечивающий применительно к МРС построение в каждый момент времени новой линейной модели нелинейного динамического объекта с использованием набора архивных данных, будет рассмотрен в Главе 3.

В параграфе 1.6 рассмотрены исследования, демонстрирующие применение в МРС-системах нейронных сетей для прогнозирования состояния ТП. Проведенный анализ публикаций показывает, что такие алгоритмы обеспечивают штатную эффективную работу соответствующей МРС-системы лишь в достаточно узкой области пространства технологических параметров, близкой к нормальному режиму. Для расширения сферы применимости МРС-систем представляется целесообразным рассмотреть альтернативный подход к построению прогнозирующей модели, при котором модель обучалась бы заранее, и далее дообучалась в процессе функционирования объекта. Такой подход предложен в Главе 3; там же исследована необходимая степень глубины прогноза, при которой гарантируется робастность алгоритма управления в смысле определения, приведенного в Главе 1.

Глава 2. Метод разработки виртуальных анализаторов показателей качества на основе алгоритмов интеллектуального анализа технологических данных

2.1. Классические методы построения виртуальных анализаторов (множественная линейная регрессия с автоподстройкой)

Качество продукции является важнейшим параметром оптимизации технологических процессов (ТП). Однако показатели качества достаточно трудно измерять в режиме реального времени, поскольку свойства продукта могут со временем изменяться под воздействием различных факторов. На современных производствах достаточно широко распространены различные методы и средства отбора и физико-химического анализа проб продукта на выходе ТП. Тем не менее, использование систем поточного анализа не всегда оправдано в силу их инерционности и высокой стоимости. Поэтому виртуальные анализаторы (ВА) приобрели популярность в качестве недорогой альтернативы сложных аналитических систем.

В МРС-системах посредством ВА реализуются модели прогноза показателей качества продукции [86-88]. Они позволяют с приемлемой точностью контролировать свойства продукции в режиме реального времени при сравнительно скромных затратах на развертывание и обслуживание. ВА могут контролировать физико-химические свойства, которые не поддаются контролю обычными анализаторами, и использоваться для мониторинга показателей качества там, где применение поточных анализаторов экономически нецелесообразно или технически невозможно [89-91].

МРС представляет собой многомерное управление на основе прогнозирующих моделей и позволяет напрямую контролировать качество продукции, оцениваемое с помощью ВА. Как правило, ВА в МРС-системах реализуют в виде простых регрессионных моделей:

$$Y = \sum_{i=1}^N b_i x_i + b_0, \quad (17)$$

где:

Y – показатель качества продукта,

$x_i, i = 1, 2, \dots, N$ – входные переменные (регрессоры),

$b_i, i = 1, 2, \dots, N$ – коэффициенты при входных переменных,

b_0 – подстраиваемый коэффициент (свободный член линейной регрессии).

Модель (16) разрабатывается на основе исторических данных ТП. Заводские данные часто содержат множество выбросов, что может привести к некачественному моделированию. Нетрудно показать, что модель, построенная с помощью метода наименьших квадратов (МНК), сильно искажается при наличии даже отдельных заметных выбросов. Существует так называемый обобщенный МНК – улучшенный метод построения линейной регрессии, когда выбросы не удаляются из данных по тем или иным причинам.

Для ВА вида (17) зачастую используется алгоритм подстройки свободного члена линейной регрессии на основе данных лабораторного контроля. Для этого коэффициент b_0 пересчитывается следующим образом:

$$bias_{new} = bias + bias_{mult} * (Y_{lab} - Y_{model}), \quad (18)$$

где:

Y_{lab} – лабораторный показатель качества продукта,

Y_{model} – показатель качества продукта, рассчитанный по модели,

$bias_{new}$ – новое значение b_0 ,

$bias_{mult}$ – весовой коэффициент учета поступающих данных лабораторного контроля.

ВА на основе линейной регрессии с автоподстройкой параметра b_0 хорошо показали себя при решении разнообразных практических задач.

Для нелинейных ТП такие модели могут оказаться неудовлетворительными. В этом случае представляется целесообразным использовать подход к прогнозированию показателей качества, основанный на интеллектуальном анализе данных (Data Mining) функционирования объекта и формировании для него базы индуктивных знаний.

2.2. Виртуальные анализаторы на основе интеллектуального анализа технологических данных

Модели, построенные при помощи алгоритмов ассоциативного поиска, используют базу индуктивных знаний ТП для построения на каждом временном такте лучшей в смысле МНК модели ТП. Понятие индуктивных знаний – закономерностей, извлекаемых из данных функционирования объекта («восстановление зависимостей по эмпирическим данным»), было введено В.Н. Вапником [1]. Такие модели будут и формироваться на каждом такте идентификатором системы на основе анализа информации о динамике ТП, накопленной к настоящему моменту. Эта информация позволяет обучать систему и пополнять базу индуктивных знаний.

Модель системы, формируемая ВА в определенный момент времени («точечная», «виртуальная»), пополняет на каждом такте соответствующую «Библиотеку моделей» в базе знаний. Эта – цифровая - модель полностью характеризуется набором значений следующих признаков: входы ТП; выход; коэффициенты. Далее эти модели могут быть использованы в традиционной схеме МРС.

В принципе, такие модели могут быть получены с использованием известных методов идентификации, например, МНК. Выбор для решения задач управления с прогнозом метода ассоциативного поиска [2] обусловлен, прежде всего, высокой точностью идентификационной модели для широкого класса нелинейных и нестационарных объектов [92-99]. Кроме того, предварительное обучение (кластеризация), с перманентным до-обучением в реальном времени, предоставляет алгоритму выигрыш в быстроедействие, что для определенного класса задач управления ТП может быть важным.

В алгоритме ассоциативного поиска идентификационная модель полностью описывается наборами входов и соответствующих им выходов системы, которые хранятся в архиве, и в этом аспекте ее можно считать цифровой моделью. Совокупность наборов статистических данных (значений признаков) дает «цифровой портрет» динамики ТП.



Процесс обработки индуктивных знаний сводится к восстановлению (ассоциативному поиску) знания по его фрагменту [102, 103]. При этом знание можно интерпретировать как ассоциативную связь между образами. В качестве образа будем использовать «наборы признаков», т.е. компонент векторов входов – входных переменных.

Критерий близости образов может формулироваться различными способами. В самом общем случае его можно представить в виде логической функции –

предиката. В частном случае, когда наборы признаков являются векторами в n -мерном пространстве, критерий близости может представлять собой расстояние в этом пространстве [104].

Ассоциативный поиск может осуществляться как процесс – либо восстановления образа по частично заданным признакам (или восстановления фрагмента знания в условиях неполной информации; как правило, именно этот процесс имитируется в различных моделях ассоциативной памяти), либо поиска других образов, связанных ассоциативно с данным, но привязанных к другим моментам времени.

Известны различные схемы ассоциативного поиска [105]. Так, во фреймовых системах задача поиска реализуется в виде сопоставления (*matching*) фреймов. В семантических сетях поиск осуществляется путем сопоставления фрагментов сети и графа-запроса.

Применительно к решению дискретных задач многокритериального выбора эффективным оказался подход, основанный на методе вербального анализа решений [106]. В рамках такого подхода производится декомпозиция описания объектов по многим критериям на их частичные описания меньшей размерности, которые предлагаются лицу, принимающему решения, для сравнения (в предположении попарно равных оценок по критериям, не вошедшим в такие описания).

Известна модель, описывающая процесс ассоциативного мышления как последовательного «вспоминания» на основе применения ассоциаций – пар образов, характеризующихся своим набором признаков. Такая модель представляется промежуточной генерацией между моделями нейронных сетей и логическими моделями, используемыми в классических системах искусственного интеллекта.

Будем рассматривать постановку задачи моделирования сигнала y как результат воздействия оператора (в общем случае, нелинейного) на векторный сигнал $x_1, \dots, x_L$ в дискретном времени [107]. В любой выбранный для анализа

момент времени каждый раз создается новая линейная модель в окрестности рабочей точки (вместо аппроксимации реального сигнала во времени).

Линейная динамическая модель имеет следующий вид:

$$y_N = \sum_{i=1}^m a_i y_{N-i} + \sum_{j=1}^n \sum_{s=1}^S b_{js} x_{N-j,s}, \forall j \in 1, \dots, N, \quad (19)$$

где:

y_N – прогноз выхода объекта на момент времени N ,

x_N – вектор входных воздействий,

m – глубина памяти по выходу,

n – глубина памяти по входу,

S – размерность вектора входов.

Заметим, что модель не является классической регрессионной: выбирается не весь динамический хронологический «хвост», а лишь определенные входы, в соответствии с заданным критерием. Коэффициенты при других входах полагаются равными нулю.

Для построения виртуальной модели, соответствующей некоторому моменту времени, из архива выбираются входные векторы, в определенном смысле близкие к текущему. Далее, на основе классического (не рекуррентного) МНК определяется значение выхода в следующий момент времени.

Такой алгоритм не создает единственную для всех моментов времени аппроксимирующую модель реального процесса, а строит новую модель для каждого фиксированного момента t . При этом каждая точка глобальной нелинейной поверхности регрессии формируется в результате использования «локальных» линейных моделей.




Рис. 2.2 Аппроксимирующая гиперповерхность пространства входных векторов и одномерного выхода

В отличие от классических регрессионных моделей, для каждого фиксированного момента времени из архива выбираются векторы входов, близкие к текущему входному вектору в смысле определенного критерия (а не в хронологической последовательности по шагам назад).

Критерии отбора получили название критериев ассоциативного поиска, или ассоциативных импульсов. Таким образом, в формуле (19) n представляет собой количество векторов из архива (от момента времени 1 до момента N), выбранных по критерию ассоциативного поиска. На каждом отрезке времени $\{N-1, N\}$ выбирается определенный набор из n векторов, $1 \leq n \leq N$.

Критерий отбора входных векторов из архива для построения виртуальной модели в данный момент времени по текущему состоянию объекта может быть следующим. Вводится величина:

$$d_{t,t-j} = \sum_{p=1}^P |x_{tp} - x_{t-j,p}|, j = 1, \dots, s, \quad (20)$$

как расстояние (метрика в $\mathbf{R}^P$) между точками пространства входов размерности P , где, вообще говоря, $s < t$, а x_{tp} – компоненты входного вектора на текущем временном такте t . Предположим, что для текущего входного вектора x_t :

$$\sum_{p=1}^P |x_{tp}| = d_t. \quad (21)$$

Для построения аппроксимирующей гиперповерхности x_t , мы выбираем такие векторы x_{t-j} , $j = 1, \dots, s$ из архива исторических данных, что для заданного D_t выполняется следующее условие (рис. 2.3.):

$$d_{t,t-j} \leq d_t + \sum_{p=1}^P |x_{t-j,p}| \leq d_t + D_t, \quad j = 1, \dots, s. \quad (22)$$




Рис. 2.3 Область векторов входов допустимо близких к входному вектору

Предварительное значение D_t определяется на основе знаний о ТП. Если выбранная область не содержит достаточного числа входов для применения МНК, т.е. соответствующая система линейных алгебраических уравнений не имеет решения, то заданный критерий точек может быть ослаблен путем увеличения порогового значения D_t .

В целях повышения быстродействия алгоритма идентификации (как на этапе обучения, так и при последующем функционировании объекта) используется один из методов интеллектуального анализа данных – кластеризация (динамическая

классификация, автоматическая группировка данных, «обучение без учителя»). Методов кластеризации известно множество [108]: иерархические алгоритмы, алгоритм k -средних (k -means), алгоритм минимального покрывающего дерева, метод ближайшего соседа, и др. Все они определяют принадлежность точки в многомерном пространстве к одной из областей, на которые это пространство разбивается.

В результате, в каждый момент времени каждая исследуемая точка в многомерном пространстве может быть отнесена к какой-либо группе посредством присвоения ей кластерной метки. В задаче ассоциативного поиска для выбора векторов входов, «близких» к текущему, метка кластера определяется в соответствии с критерием ассоциативного отбора входных векторов из архива. Для построения виртуальных моделей векторы отбираются внутри соответствующего кластера.

2.2.2. Метод ассоциативного поиска с использованием вейвлет-анализа

Существует множество ТП, которые невозможно контролировать с помощью линейных прогнозирующих моделей. Метод ассоциативного поиска предлагает конструктивное решение для нелинейных нестационарных процессов [15, 95].

В технических системах нестационарность часто имеет осциллирующий характер. Типичным примером нестационарности является изменчивость свойств сырья технологической установки в связи с изменением поставщика сырья. Другой пример – сезонные и суточные колебания нагрузки в электрических сетях, которые непосредственно влияют на оптимизацию режимов управления передачей электроэнергии. Поэтому разработка прогнозирующих моделей с помощью метода ассоциативного поиска для такого типа изменяющихся во времени процессов является актуальной.

За последние 20 лет для анализа изменяющихся во времени процессов широко применялся метод вейвлет-преобразования [109]. Может быть рассмотрено применение вейвлет-анализа к задачам идентификации, в частности, для разработки моделей с помощью ассоциативного поиска. Такой подход выглядит

перспективным в условиях переходных процессов как для изменяющегося во времени входного сигнала, так и для немоделируемой динамики объекта управления.

В большинстве промышленных приложений, в частности, в системах управления с идентификатором, входной сигнал представляет собой вектор. Пусть каждая компонента входного вектора удовлетворяет условиям Гаусса–Маркова [110]. Также будем считать, что в каждый момент времени компоненты вектора статистически независимы. Предполагается, компоненты входного вектора характеризуются сингулярности, проявляющиеся в различные моменты времени, в определенном смысле похожи или идентичны.

Например, методы анализа фондового рынка позволяют обнаружить такие «закономерности» в динамике рынка. В технических системах некоторая повторяемость (не обязательно периодическая) свойств входного сигнала может быть обнаружена путем применения статистического анализа к историческим данным процесса. Некоторые процессы, такие как динамика нагрузки в электрических сетях, характеризуются явной цикличностью. Для того чтобы применить алгоритм ассоциативного поиска для прогнозирования динамики таких процессов, необходимо выбрать из истории ТП векторы, близкие к текущему в смысле выбранного критерия (ассоциативного импульса).

Для текущего момента времени рассматриваются дискретные вейвлет-разложения входных сигналов. В общем случае кратно-масштабное вейвлет-разложение входов и выходов системы может быть представлено следующим выражением. Для текущего вектора $x(t)$ для фиксированного уровня детализации L [111]:

$$\begin{aligned} x(t) &= \sum_{k=1}^N c_{L,k}^x(t) \varphi_{L,k}(t) + \sum_{l=1}^L \sum_{k=1}^N d_{l,k}^x(t) \psi_{l,k}(t), \\ y(t) &= \sum_{k=1}^N c_{L,k}^y(t) \varphi_{L,k}(t) + \sum_{l=1}^L \sum_{k=1}^N d_{l,k}^y(t) \psi_{l,k}(t), \end{aligned} \quad (23)$$

где: $\varphi_{L,k}(t)$ – масштабирующие функции; $\psi_{l,k}(t)$ – вейвлет-функции, которые получаются из материнских вейвлетов посредством масштабирования и сдвига:

$$\psi_{l,k}(t) = 2^{l/2} \psi_{\text{mother}}(2^l t - k) \quad (24)$$

В качестве материнских рассматриваются вейвлеты Хаара. l – уровень детализации; $c_{L,k}$ – масштабирующие коэффициенты, $d_{l,k}$ – детализирующие коэффициенты. Коэффициенты вычисляются с помощью алгоритма Малла [109].

Выбор входных векторов из базы индуктивных знаний осуществляется в соответствии с требованием [105]:

$$\begin{aligned} |x(t^*) - x(t)| &\leq |x(t^*)| + |x(t)| = \left| \sum_{k=1}^{\frac{N}{2^L}} c_k^* \varphi_k(t^*) + \sum_{j=1}^L \sum_{k=1}^{\frac{N}{2^j}} d_{jk}^* \psi_{jk}(t^*) \right| + \\ &+ \left| \sum_{k=1}^{\frac{N}{2^L}} c_k \varphi_k(t) + \sum_{j=1}^L \sum_{k=1}^{\frac{N}{2^j}} d_{jk} \psi_{jk}(t) \right| \leq \left| \sum_{k=1}^{\frac{N}{2^L}} c_k^* \varphi_k(t^*) \right| + \left| \sum_{k=1}^{\frac{N}{2^L}} c_k \varphi_k(t) \right| + \\ &+ \sum_{j=1}^L \left| \sum_{k=1}^{\frac{N}{2^j}} d_{jk} \psi_{jk}(t) \right| + \sum_{j=1}^L \left| \sum_{k=1}^{\frac{N}{2^j}} d_{jk}^* \psi_{jk}(t^*) \right| \leq c_L + L \tilde{c}_j = C = \text{const} > 0. \end{aligned}$$

$$\tilde{c}_j = \frac{N}{2^{j-1}} \max_{k=1, \dots, N/2^j} \tilde{c}_{jk}. \quad (25)$$

выполняемым для некоторого вектора $x(t^*)$ (выбранного внутри кластера, в который попал текущий вектор $x(t)$) и для фиксированной константы c_L .

Прогнозируемое значение $y(t)$ и коэффициенты модели вычисляются на основе МНК.

2.2.3. Процедура Мура–Пенроуза для построения моделей ассоциативного поиска при зависимых входах

Рассмотрим алгоритм определения неизвестных коэффициентов линейной динамической модели (19). Без ограничения общности, перепишем модель (19) в виде

$$y_N = \sum_{i=1}^Q \alpha_i \hat{x}_i, \quad (26)$$

где:

$\hat{x} = (\hat{x}_1, \hat{x}_2 \dots \hat{x}_r), r = m + nS$, $\hat{x}$ – расширенный вектор входов, для которого:

$$\{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_m\} = \{y_{N-1}, y_{N-2}, \dots, y_{N-m}\};$$

$$\{\hat{x}_{m+1}, \hat{x}_{m+2} \dots \hat{x}_{m+nS}\} = \{x_{N-1,1}, x_{N-1,2}, \dots, x_{N-1,S}, \dots, x_{N-n,S}\};$$

α – расширенный вектор коэффициентов входов, для которого:

$$\{\alpha_1, \alpha_2, \dots, \alpha_m\} = \{a_1, a_2, \dots, a_m\};$$

$$\{\alpha_{m+1}, \alpha_{m+2}, \dots, \alpha_{m+nS}\} = \{b_{1,1}, b_{1,2}, \dots, b_{1,S}, \dots, b_{n,S}\}.$$

Для построения модели (26) из архива исторических данных ТП выбираются входные векторы, близкие к текущему в определенном смысле, например, в смысле манхэттенского или евклидового расстояния.

После отбора векторов составляется матрица расширенных векторов входов:

$$\hat{X} = \begin{pmatrix} \hat{x}_1^1 & \dots & \hat{x}_r^1 \\ \vdots & \ddots & \vdots \\ \hat{x}_1^P & \dots & \hat{x}_r^P \end{pmatrix}, \quad P \gg r. \quad (27)$$

Для нахождения коэффициентов α_i модели (26) необходимо решить систему линейных уравнений вида:

$$\hat{X}\alpha = \hat{y}, \quad (28)$$

где $\hat{y}$ представляет собой выход системы на следующем такте для отобранных расширенных векторов входов ТП.

Если предположить, что матрица $\hat{X}$ полного ранга, т.е. $\text{rank } \hat{X} = r$, то при решении задачи (28) обычно применяется МНК для нахождения оценки $\hat{\alpha}$:

$$(\hat{y} - \hat{X}\hat{\alpha})^T (\hat{y} - \hat{X}\hat{\alpha}) = \min_{\alpha} (\hat{y} - \hat{X}\alpha)^T (\hat{y} - \hat{X}\alpha). \quad (29)$$

Необходимое условие минимума по α приводит к системе линейных алгебраических уравнений:

$$\hat{X}^T \hat{X} \alpha = \hat{X}^T \hat{y}. \quad (30)$$

В предположении, что $\hat{X}$ – матрица полного ранга, получаем:

$$\hat{\alpha} = (\hat{X}^T \hat{X})^{-1} \hat{X}^T \hat{y}. \quad (31)$$

$\hat{\alpha}$ является МНК-оценкой и, согласно теореме Гаусса-Маркова, обладает минимальной дисперсией в классе несмещенных линейных оценок параметра α .

Очевидно, что при плохой обусловленности матрицы $\hat{X}^T \hat{X}$ оценка (31) может быть неадекватной. Для динамических моделей имеем случай плохой обусловленности матрицы, ввиду статистической зависимости компонент расширенного вектора входов.

В таком случае предлагается использовать следующую процедуру Мура–Пенроуза [110-112].

В случае, если матрица $\hat{X}^T \hat{X}$ вырождена или плохо обусловлена, то система уравнений (28) всегда приводит к бесконечному набору оценок $\hat{\alpha}$. Предлагается искать оценку $\hat{\alpha}_0$, такую что:

$$\hat{\alpha}_0^T \hat{\alpha}_0 = \min \hat{\alpha}^T \hat{\alpha}. \quad (32)$$

Согласно [112] оценка $\hat{\alpha}$ минимизирует (35) тогда и только тогда, когда $\hat{\alpha}$ представима в форме:

$$\hat{\alpha} = \hat{X}^+ \hat{y} + (I - \hat{X}^+ \hat{X})p, \quad (33)$$

где p – произвольный r -мерный вектор. Поэтому оценка $\hat{\alpha}_0$ находится в виде:

$$\hat{\alpha}_0 = \hat{X}^+ \hat{y}, \quad (34)$$

и представляет собой аналог МНК-оценки (34).

2.3. Построение ВА показателей качества для непрерывных и полу-непрерывных ТП

Для разработки в режиме реального функционирования ТП моделей ассоциативного поиска создается программно-алгоритмический комплекс – ВА [85].

На первом этапе – *обработки текущей информации* – производится выгрузка архивных данных ТП за продолжительный период времени (от 1 до 3 лет), и осуществляются первичная обработка и анализ данных ТП. Удаляются значительные выбросы.

После усреднения данных производится их нормализация [113], поскольку значения входных параметров для построения модели могут изменяться в очень большом диапазоне и отличаться друг от друга на несколько порядков. Например,

температура на выходе из печи кальцинации может достигать 1000°C , при том, что загрузка сырья в печь варьируется от 50 до 100 тонн в час.

После нормализации все числовые значения входных параметров ТП будут приведены к одинаковой области их изменения – некоторому диапазону, обычно отрезку $[0,1]$.

Далее происходит процесс отбора информативных входных параметров ТП, путём расчёта коэффициента корреляции Пирсона для каждого входного параметра, учитывая различные смещения по времени, относительно времени лабораторных анализов. Какие-то параметры могут быть отобраны на основе экспертного анализа физико-технологических свойств ТП определенного класса [114].

Отобранные информативные входы ТП проверяются на автокорреляцию. Это делается, например, с использованием метода главных компонент или сингулярного разложения матриц. В определенных случаях автокорреляция очевидно следует из особенностей организации ТП. Например: имеется набор близко расположенных друг к другу датчиков температур. Для построения модели достаточно взять показания только одного датчика из такой группы.

После того, как информативные входы ТП отобраны, нормированы и проверены на автокорреляцию [115,116], формируется структура точечной линейной модели. Далее осуществляется *интеллектуальный анализ качества построенных моделей*, являющийся основой поддержки принятия решений.

При этом возможно введение *экспертом* опорного варианта решения задачи. Возможно, эксперт вводит дополнительные ограничения, связанные с оценкой ситуации по оперативным данным. Далее возможно в интерактивном режиме варьирование отдельных параметров, с последующей проверкой критериев эффективности – на стадии идентификации.

При построении модели необходимо учитывать специфику работы лаборатории на производстве для ТП определенного типа. Зачастую лабораторный анализ продукции производится не на разовых, а на усредненных пробах. Например, для ТП измельчения железорудных горных пород усреднение

лабораторной пробы составляет порядка 2 часов, а для процессов кальцинации может достигать и 8 часов.

Моделирование должно обеспечивать не только достаточно точное описание физико-технологических свойств ТП данного класса, но и адекватно отражать конкретику производственной ситуации и особенности технологической установки, т.е. максимально возможным образом использовать всю имеющуюся априорную информацию.

В частности, необходимо учитывать все ограничения, определяемые как технологическим регламентом, так и экспертными мнениями. В качестве эксперта, анализирующего ситуацию, выступает лицо, принимающее решения. В этом качестве могут выступать как оператор технологической установки, так и менеджеры более высоких звеньев, просчитывающие, например, экономику процессов – с целью прогнозирования, и т.п. Их мнение учитывается посредством интерактивного интерфейса. Возможен вариант, когда эксперт предлагает опорный вариант решения задачи.

Дальше начинается работа интеллектуального анализатора текущей ситуации. Может осуществляться, например, варьирование отдельных параметров с целью оптимизации модели.

Интеллектуальный анализ, являющийся основой поддержки принятия решений, реализует взаимодействие Идентификатора и формируемой на этапе обучения системы Базы индуктивных знаний – закономерностей, извлекаемых из статистических данных.

База знаний будет содержать архив «производственного опыта» – от синхронизированных во времени входов и соответствующих им выходов и уравнений для определенных ТП – до архивов настроенных моделей и архивов формализованных ситуаций – «закодированных» признаков и характеристик текущего состояния.

Такие библиотеки требуются как для экспертного анализа, так и для функционирования алгоритмов, моделирующих процесс принятия решений

человеком-оператором. К таким алгоритмам относятся, в частности, алгоритмы ассоциативного поиска.

С помощью алгоритмов ассоциативного поиска можно осуществлять аналитические операции, которые для оператора, анализирующего ситуацию, могут оказаться сложными, либо он не сможет учесть все факторы, неявно влияющие на ход процесса, т.е. его не моделируемую внутреннюю динамику.




Рис. 2.4. ВА в схеме автоматического управления ТП

Идентификатор в цепи обратной связи системы автоматического/автоматизированного управления ТП, по сути, выполняет роль цифрового двойника, который в каждый момент времени генерирует цифровую

модель. На вход идентификатора поступают различные элементы формализованного описания входов процесса, а также производственной ситуации.

К описанию процесса относятся: его особенности, позволяющие описать процесс с помощью определенных математических моделей. Выбор конкретного описания процесса осуществляется из Библиотеки моделей, также содержащейся в Базе технологических знаний.

К этому же классу относится учет отдельных данных технической документации, в частности, технологического регламента, что позволяет ввести все необходимые ограничения.

2.3.1. Описание текущего состояния

Схема информационных потоков, формируемая пользователем системы с помощью интерактивного интерфейса, позволяет конкретизировать описание моделируемого процесса в виде дифференциальных либо разностных уравнений.

Конкретизируется задача введения замечаний эксперта (технолога, оператора технологической установки, и т.д.) по текущей ситуации. Под ситуацией понимается набор факторов, определяющих функционирование ТП, помимо непосредственного формального описания его динамики.

Замечания эксперта также вводятся интерактивно в виде выбора из предлагаемого *набора ситуаций* с возможной детальной конкретизации значений отдельных параметров. Набор «ситуаций» содержится в соответствующей библиотеке базы знаний.

Далее замечания эксперта могут быть обработаны в системе (формализованы), с последующим учетом при настройке модели. Формализация может осуществляться, например, на основе нечетких продукционных правил, которые также могут содержаться в БЗ.

В идентификаторе осуществляются следующие операции:

- Формирование структуры математической модели конкретного ТП на основе схемы информационных потоков и задания ограничений и начальных условий;
- корректировка модели с учетом описания текущего состояния;
- определение коэффициентов модели с помощью алгоритмов идентификации. В данной работе применялись методы кластеризации, выбор из определенного кластера наборов признаков и решение системы линейных уравнений в соответствии с методом наименьших квадратов.
- занесение ситуации и результатов моделирования в БЗ с целью ее дальнейшего до-обучения.

2.3.2. Разработка структуры базы знаний

Знания извлекаются из статистических данных технологического архива посредством интеллектуального анализа данных. Эффективным методом является кластеризация данных. База знаний пополняется и корректируется в темпе технологического процесса.

Основными элементами структуры базы для формирования и хранения знаний, интерпретируемых как закономерности, характеризующие технологический процесс, являются:

- **База функционирования ТП.** Содержит наборы значений входов и управлений, а также соответствующих им выходов (готовая продукция, побочная продукция, отходы) по данным мониторинга – из архива.
- **Оценки результатов** - формализованные значения оценок экспертов (например, с помощью нечетких моделей) и оценок, получаемых с помощью интеллектуальных алгоритмов идентификации в соответствии с выбранными критериями
- **База технологических регламентов** содержит описание следующих элементов:
 - технические средства;
 - технологические нормативы;

- ограничения для ТП;
- технологические операции, в частности:
 - правила выполнения операций в различных ситуациях;
 - детальный порядок осуществления технологического процесса;
 - правила ведения режима;
 - параметры режима, например:
 - температуры;
 - давления;
 - расходы;
 - скорости реакций;
 - другие параметры.
 - формализованные индикаторы нештатных ситуаций и характеризующие их параметры наборы параметров, характеризующих особенности протекания процесса.
- **База формализованных экспертных оценок ситуаций**, содержащая комментарии экспертов, например, в виде правил нечеткого вывода.
- **База библиотек формализованного представления процессов и их математических моделей** (наборы уравнений, соответствующие элементам схем информационных потоков).
- **База данных функционирования технологического процесса** (Данные технологического оборудования): фактические расходы в данный момент времени технологических параметров: расходы, давления, температуры и т.д.
В данной базе отражаются также возможные отклонения от штатных ситуаций (набор шаблонов), дополнительные ограничения.
- **База построенных математических моделей процессов** (Архив фактически построенных структур моделей)
- **Архив уточненных моделей** (с использованием дополнительной априорной информации из Базы знаний)
- **Архив настроенных** (посредством идентификатора) моделей.

2.4. Выводы

Представлена процедура построения ВА, основанная на цифровых алгоритмах идентификации – алгоритмах ассоциативного поиска. Для МРС-системы в качестве ВА, формирующего модель такого типа, рассматривается цифровой двойник – идентификатор в цепи обратной связи («ассоциативный ВА»). Выявлены преимущества данного метода перед традиционными. Поскольку ассоциативный ВА функционирует в замкнутом МРС-контуре, имеется статистическая зависимость между переменными в модели; для ее регуляризации предложено использовать процедуру Мура–Пенроуза.

Предложена процедура разработки ВА ТП непрерывных и полунепрерывных производств. Ассоциативные ВА формируют модели для МРС, используя специализированные базы индуктивных знаний, содержащие цифровые портреты и библиотеки формализованного описания различных ТП, технологических регламентов и дополнительных факторов, формирующих текущую ситуацию, включая формализованные мнения экспертов и нечеткие производственные правила.

Глава 3. Разработка алгоритма управления с прогнозирующей моделью на основе ассоциативного виртуального анализатора

Идентификация нелинейных динамических объектов в условиях неопределенности – сложнейшая задача, решение которой традиционными методами не представляется возможным [99]. Идентификация систем автоматического управления ТП особенно сложна при наличии разного рода возмущений [117-119]. Это обстоятельство, а также повышенные требования к быстродействию и точности управления вызвали необходимость разработки новых методов идентификации.

Алгоритм ассоциативного поиска – метод идентификации систем, основанный на интеллектуальном анализе данных ТП. Он обеспечивает построение прогнозирующей линейной модели нелинейного динамического объекта на каждом временном такте с использованием наборов архивных данных. Таким образом, метод ассоциативного поиска предполагает не аппроксимацию реального ТП во времени, а построение цифровой «точечной» линейной модели нелинейного динамического объекта – новой в каждый момент времени – с использованием наборов исторических данных («ассоциаций»), сформированных на этапе обучения и адаптивно корректируемых в соответствии с определенными критериями.

В целях увеличения быстродействия алгоритма идентификации (как на этапе обучения, так и при последующем функционировании объекта) используется один из методов интеллектуального анализа данных, а именно кластеризация (динамическая классификация, автоматическая группировка данных, «обучение без учителя»).

Сегодня известно множество методов кластеризации: иерархические алгоритмы, алгоритм k -средних, алгоритм минимального покрывающего дерева, метод ближайшего соседа, и др. Все они определяют принадлежность точки в

многомерном пространстве к одной из областей, на которые это пространство было разделено.

В результате, в каждый момент времени каждая исследуемая точка в многомерном пространстве включается в какую-либо группу посредством присвоения ей кластерной метки. В задаче ассоциативного поиска для выбора векторов входов, «близких» к текущему, метка кластера определяется в соответствии с критерием ассоциативного отбора входных векторов из архива. Для построения виртуальных моделей векторы выбираются внутри соответствующего кластера.

В диссертационной работе представлен альтернативный подход к управлению с прогнозирующей моделью – т.н. «ассоциативное МРС». Построение прогнозирующей модели ТП реализуется при помощи метода ассоциативного поиска. Такой алгоритм идентификации модели ТП в режиме реального времени состоит в построении на каждом временном такте новой аппроксимирующей гиперповерхности пространства входных векторов и соответствующих им одномерных выходов объекта. В диссертационной работе предлагается алгоритм МРС с использованием ассоциативных идентификационных моделей, названный «ассоциативным МРС» (Associative MPC – АМРС). Введен критерий выбора глубины горизонта прогнозирования АМРС [101].

Для построения АМРС-алгоритма на каждом временном такте будет формироваться линейная дискретная модель динамического процесса методом ассоциативного поиска. Математическая постановка задачи представлена ниже.

Виртуальные анализаторы для систем управления ТП с идентификационными моделями содержат статистически зависимые переменные. В подобных случаях значения коэффициентов модели и прогноз выхода получаются как псевдорешения систем линейных алгебраических уравнений в соответствии с МНК посредством применения сингулярного разложения матриц и процедур типа Мура–Пенроуза.

3.1. Описание алгоритма ассоциативного МРС

При управлении объектом в любой выбранный для анализа момент времени в окрестности рабочей точки создается новая линейная модель вида:

$$y(n + 1) = \sum_{i=1}^N a_i y(n + 1 - i) + \sum_{j=1}^Q \sum_{i=1}^M b_{ij} x_j(n + 1 - i) + \sum_{i=1}^K c_i u(n + 1 - i), \quad (35)$$

где:

$y(n + 1)$ – прогноз выхода объекта на момент времени $n + 1$,

x_j – вектор входных воздействий,

u – скалярное управление,

N – глубина памяти по выходу,

M – глубина памяти по входу,

K – глубина памяти по управлению,

Q – размерность вектора входов.

Заметим, что модель не является классической регрессионной: выбирается не весь динамический хронологический «хвост», а лишь некоторые входы, отобранные в соответствии с определенным критерием.

Алгоритм отбора входов для построения модели следующий:

1. Все наполнение базы знаний ТП за достаточно большой период разбивается на кластеры.
2. В каждый момент времени анализируется, в какой кластер попал вектор, состоящий из текущих значений входа.
3. Из данного кластера выбирается достаточное число независимых векторов, близких к текущему, и строится модель вида (35).

Введем понятие расширенного вектора входов процесса:

$$\hat{x} = (\hat{x}_1, \hat{x}_2 \dots \hat{x}_C), \text{ где } C = MQ + K + N. \quad (36)$$

Данный вектор будет состоять из следующих групп компонентов:

- значений входов $x_j(q)$, где $q \in [n + 1 - M, n], j \in [1, M]$;
- значений управления $u(r)$, где $r \in [1, K]$;

- значений выхода $y(p)$, где $p \in [n + 1 - N, n]$,

т.е.:

$$\begin{aligned} \{\hat{x}_1, \hat{x}_2 \dots \hat{x}_{MQ}\} &= \\ \{x_1(n), x_1(n-1), \dots, x_1(n+1-M), x_2(n), x_2(n-1), \dots, x_Q(n+1-M)\}; \\ \{\hat{x}_{MQ+1}, \hat{x}_{MQ+2} \dots \hat{x}_{MQ+K}\} &= \{u(n), u(n-1), \dots, u(n+1-K)\}; \\ \{\hat{x}_{MQ+K+1}, \hat{x}_{MQ+K+2} \dots \hat{x}_{MQ+K+N}\} &= \{y(n), y(n-1), \dots, u(n+1-N)\}. \end{aligned} \quad (37)$$

С учетом соответствующих переобозначений, уравнение (35) запишется в виде:

$$y(n+1) = \sum_{i=1}^C \alpha_i \hat{x}_i, \quad (38)$$

где:

$$\begin{aligned} \{\alpha_1, \alpha_2 \dots \alpha_{MQ}\} &= \{b_{ij}\}, \quad i \in [1, M]; j \in [1, Q]; \\ \{\alpha_{MQ+1}, \alpha_{MQ+2} \dots \alpha_{MQ+K}\} &= \{c_i\}, \quad i \in [1, K]; \\ \{\alpha_{MQ+K+1}, \alpha_{MQ+K+2} \dots \alpha_{MQ+K+N}\} &= \{a_i\}, \quad i \in [1, N]. \end{aligned} \quad (39)$$

Алгоритм ассоциативного поиска предусматривает для построения модели (38) выбор только тех векторов из кластера, которые удовлетворяют определенному критерию близости к текущему вектору $\hat{x}_{search}$, где $\hat{x}_{search}$ – вектор $\hat{x}$, состоящий только из входных воздействий и управления, т.е.:

$$\hat{x}_{search} = (\hat{x}_1, \hat{x}_2 \dots \hat{x}_L), \text{ где } L = MQ + K. \quad (40)$$

В качестве критериев близости могут быть выбраны евклидово расстояние, манхэттенское расстояние и т.д.

После отбора векторов из архива ТП можно составить матрицу расширенных векторов входов:

$$\hat{X} = \begin{pmatrix} \hat{x}_1^1 & \dots & \hat{x}_C^1 \\ \vdots & \ddots & \vdots \\ \hat{x}_1^P & \dots & \hat{x}_C^P \end{pmatrix}. \quad (41)$$

В матрице $\hat{X}$ по строкам записаны расширенные векторы входов, взятые из определенного кластера архива, с условием близости к текущему вектору $\hat{x}_{search}$ по определенному критерию. Количество таких векторов – P .

Мы предполагаем, что можно отобрать такое количество расширенных векторов P из архива, что $P \gg C$, причем матрица $\hat{X}^T \hat{X}$ будет хорошо обусловлена. С учетом значительных объемов хранимой информации в исторических БД современных АСУТП, данное предположение выглядит вполне реалистичным.

Для нахождения коэффициентов α_i модели (38) необходимо решить систему линейных алгебраических уравнений вида:

$$\hat{X}\alpha = \hat{y}, \quad (42)$$

где $\hat{y}$ представляет собой выход системы на следующем такте для отобранных расширенных векторов входов ТП.

Решение (42) можно выразить в явном виде:

$$\alpha = \hat{X}^+ \hat{y}, \hat{X}^+ = (\hat{X}^* \hat{X})^{-1} \hat{X}^*, \quad (43)$$

где $\hat{X}^+$ – псевдообратная матрица матрицы $\hat{X}$.

На данном шаге мы нашли коэффициенты α , и, следовательно, построили модель (42).

В построенную модель на каждом такте подставляются текущие значения входов системы, и рассчитывается значение выхода на следующем такте. Если выход на следующем такте удовлетворяет всем ограничениям, то управление остается прежним.

Рассмотрим алгоритм действий, если выход на следующем такте нарушил ограничение. Предположим, что выход объекта и управление ограничены:

$$|y| \leq Y, |u| \leq U, Y, U > 0. \quad (44)$$

Пусть, по расчетам, прогнозируемый выход y^* на такте $n + 1$ нарушит требуемые ограничения, т.е. $|y^*| > Y$. Во избежание этого прогнозируемый выход должен быть смещен с некоторым коэффициентом Δ_y , так чтобы $\Delta_y |y^*| \leq Y$.

После подстановки в выражение (35) получим:

$$\Delta_y y(n+1) = \sum_{i=1}^N a_i y(n+1-i) + \sum_{j=1}^Q \sum_{i=1}^M b_{ij} x_j(n+1-i) + \sum_{i=2}^K c_i u(n+1-i) + c_1 u(n). \quad (45)$$

В формуле (45) в роли переменной выступает управление в момент времени n , поскольку остальные параметры в этот момент времени известны. Положив $u(n) = \Delta_u u(n-1)$, получим:

$$\Delta_y y^* = T(y, x, u) + c_1 \Delta_u u(n-1), \quad (46)$$

где:

$$T(y, x, u) = \sum_{i=1}^N a_i y(n+1-i) + \sum_{j=1}^Q \sum_{i=1}^M b_{ij} x_j(n+1-i) + \sum_{i=2}^K c_i u(n+1-i). \quad (47)$$

Тогда можно явно выразить необходимое смещение по управлению Δ_u :

$$\Delta_u = \frac{\Delta_y y^* - T(y, x, u)}{c_1 u(n-1)}. \quad (48)$$

Найденное значение управления применяется на текущем такте; далее вся процедура повторяется.

Таким образом, мы описали алгоритм управления объектом со скалярным управлением с использованием методов ассоциативного поиска для построения модели ТП на каждом такте.

Если обобщить задачу на объект с вектором управляющих воздействий, то формула (46) примет вид:

$$\Delta_y y(n+1) = \sum_{i=1}^N a_i y(n+1-i) + \sum_{j=1}^Q \sum_{i=1}^M b_{ij} x_j(n+1-i) + \sum_{i=2}^K \sum_{j=1}^P c_{ij} u_j(n+1-i) + \sum_{l=1}^P c_{1l} u_l(n). \quad (49)$$

В уравнении (49) в роли переменных выступают P управлений в момент времени n , поскольку остальные параметры в этот момент времени известны. Уравнение (49) можно переписать в виде:

$$\Delta_y y^* = S(y, x, u) + \sum_{l=1}^P c_{1l} u_l(n), \quad (50)$$

где:

$$S(y, x, u) = \sum_{i=1}^N a_i y(n+1-i) + \sum_{j=1}^Q \sum_{i=1}^M b_{ij} x_j(n+1-i) + \sum_{i=2}^K \sum_{j=1}^P c_{ij} u_j(n+1-i). \quad (51)$$

В качестве управлений $u_l(n)$ в (50) примем:

$$u_l(n) = u_l(n-1)\Delta_y - \frac{S(y, x, u)}{P c_{1l}} (1 - \Delta_y). \quad (52)$$

Если подставить (52) в правую часть уравнения (50), то получим:

$$\begin{aligned} S(y, x, u) + \sum_{l=1}^P c_{1l} u_l(n) &= S(y, x, u) + \\ &+ \sum_{l=1}^P c_{1l} \left[u_l(n-1)\Delta_y - \frac{S(y, x, u)}{P c_{1l}} (1 - \Delta_y) \right] = S(y, x, u) + \\ &+ \Delta_y \sum_{l=1}^P c_{1l} u_l(n-1) - \frac{S(y, x, u)}{P} \sum_{l=1}^P (1 - \Delta_y) = S(y, x, u) + \\ &\Delta_y y(n+1) - \Delta_y S(y, x, u) - S(y, x, u) + -\Delta_y S(y, x, u) = \Delta_y y(n+1). \end{aligned} \quad (53)$$

Таким образом, управление в виде (52) можно применить на текущем такте.

Данный алгоритм управления подходит для решения широкого класса задач.

Но применительно к процессам с большим временем установления или чистым запаздыванием он требует обобщения.

В выражении (48) при нахождении необходимого управления в знаменателе стоит коэффициент c_1 , значение которого может быть достаточно малым для процессов с большим временем установления или равным нулю для процессов с чистым запаздыванием. В этом случае потребуются дополнительные условия на формирование управляющих воздействий для того, чтобы выполнялось ограничение $|u| \leq U$.

3.2. Алгоритм расчета вектора управляющих воздействий

Из выражения (53) видно, что при выборе вектора управляющих воздействий вида (52) решение задачи управления на текущем такте будет удовлетворять необходимым условиям.

Опишем алгоритм расчета вектора управляющих воздействий при нарушении в (52) условия $|u| \leq U$.

Для простоты описания переобозначим переменные выражения (50):

$$\sum_{i=1}^N \alpha_i x_i = C, \quad (54)$$

где:

$$C = \Delta_y y^* - S(y, x, u);$$

$$\{c_{1l}, l = 1, \dots, P\} = \{\alpha_i, i = 1, \dots, N\};$$

$$\{u_l, l = 1, \dots, P\} = \{x_i, i = 1, \dots, N\}.$$

Ограничение $|u| \leq U$ можно переписать в виде:

$$a_i \leq x_i \leq A_i, \quad i = 1, \dots, N. \quad (55)$$

Таким образом, задача нахождения управления в (50) сводится к нахождению решения уравнения (54) при выполнении ограничений (55).

Выберем в качестве переменных в (54) управления, которые использовались на предыдущем такте $(x_i^*, i = 1, \dots, N)$, тогда:

$$\sum_{i=1}^N \alpha_i x_i^* = C_2, \quad (56)$$

Будем считать, без ограничения общности, $C_2 < C$. Тогда для поиска решения, для каждого $x_i, i = 1, \dots, N$, будем последовательно, начиная с $i = 1$, выполнять следующие действия:

1. Если $a_i > 0$, то заменим в (58) x_i^* на A_i . Если полученное новое значение левой части (58) больше C , то тогда i управлений достаточно для решения (56) с учетом ограничений (57). В ином случае зафиксируем значение для $x_i^* = A_i$ и увеличим i на единицу.

2. Если $a_i < 0$, то заменим в (58) x_i^* на a_i . Если полученное новое значение левой части (58) больше C , то i управлений достаточно для решения (56) с учетом ограничений (57). В ином случае фиксируем значение для $x_i^* = a_i$ и увеличиваем i на единицу.

Если решения найти не удалось, то управляемость системы гарантировать нельзя, и требуются дополнительные исследования.

3.3. Прогноз выхода на несколько тактов вперед в АМРС

Пусть необходимо построить прогноз для $y(n+1)$, $y(n+2)$, ..., $y(n+p)$, т.е. прогноз выхода y на p шагов вперед. Представим расчет для такта $n+2$ и обобщим его для p .

Подставляя $y(n+2)$ в выражение (35), получаем:

$$y(n+2) = \sum_{i=0}^{N-1} a_i y(n+1-i) + \sum_{j=1}^Q \sum_{i=0}^{M-1} b_{ij} x_j(n+1-i) + \sum_{i=0}^{K-1} c_i u(n+1-i), \quad (57)$$

Коэффициенты модели (35) уже найдены; также имеется выражение для $y(n+1)$ через неизвестные управления. Ограничиваемся рассмотрением случая, когда значения входов x_{ij} на рассматриваемом временном интервале являются неизменными, что реально имеет место для ряда технологических процессов.

Если подставить выражение для $y(n+1)$ в (57), то получим выражение для $y(n+2)$ через неизвестные значения управляющих воздействий:

$$y(n+2) = F(y, x, u) + c_1 u(n) + c_0 u(n+1). \quad (58)$$

В выражении (58) значения функции $F(y, x, u)$ известны. Очевидно, что подобными итерациями можно прийти к выражению выхода для такта p :

$$y(n+p) = F_1(y, x, u) + c_1 u(n) + c_0 u(n+1) + c_{-1} u(n+2) + c_{-2} u(n+3) + \dots + c_{-p+1} u(n+p-1). \quad (59)$$

$F_1(y, x, u)$ – известная функция, зависящая от предыдущих значений входов, выхода и управлений. Для решения задачи робастного управления необходимо

найти все спрогнозированные выходы в заданных границах $|y| \leq Y$, а также управления $|u| \leq U$. Иными словами, необходимо найти решения для

$$u(n), u(n+1) \dots u(n+p-1) \quad (60)$$

при выполнении следующих условий:

$$\begin{aligned} y(n+1) \leq Y, y(n+2) \leq Y, \dots, y(n+p) \leq Y, \\ u(n) \leq U, u(n+1) \leq U, \dots, u(n+p-1) \leq U. \end{aligned} \quad (61)$$

3.4. Алгоритм расчета глубины прогноза для выхода в АМРС

Необходимо определить, на сколько тактов вперед при данных условиях можно прогнозировать адекватно значение выхода, и далее решать задачу робастного управления [120]. Как было показано выше, расчет выхода на один такт не всегда гарантирует существование решения для управления, в особенности для ТП со значительным временем установления или чистым запаздыванием. Необходимо гарантировать попадание выхода в заданные границы при построении прогноза на p тактов вперед, применяя управляющее воздействие, удовлетворяющее соответствующим ограничениям.

Для оценивания p необходимо определить максимальное изменение выхода за один такт для каждого кластера:

$$y_{\Delta}^K = \max_{y \in K, i=1..L_K} |y(i) - y(i-1)|, \quad (62)$$

где:

y_{Δ}^K – максимальное изменение выхода за один такт для кластера K ;

L_K – количество элементов в кластере K .

Предполагается, что база знаний ТП достаточно информативна, и ее содержимого достаточно для получения адекватной и достоверной оценки параметра y_{Δ}^K .

Предположим, что на шаге прогноза p значение выхода $y(n+p)$ вышло за допустимые границы и смещение оказалось максимальным, то есть равным y_{Δ}^K . Тогда:

$$y(n+p) - y(n+p-1) = y_{\Delta}^K. \quad (63)$$

После подстановки значений для $y(n+p)$ и $y(n+p-1)$ получим:

$$y_{\Delta}^K = c_1 \Delta u(n) + c_0 \Delta u(n+1) + c_{-1} \Delta u(n+2) + c_{-2} \Delta u(n+3) + \dots + c_{-p+1} \Delta u(n+p-1), \quad (64)$$

где:

$$\Delta u(n) = u(n) - u(n-1). \quad (65)$$

Для обеспечения возможности смещения выхода в результате p управляющих воздействий должно выполняться условие:

$$y_{\Delta}^K \leq c_1 \Delta u(n) + c_0 \Delta u(n+1) + c_{-1} \Delta u(n+2) + c_{-2} \Delta u(n+3) + \dots + c_{-p+1} \Delta u(n+p-1). \quad (66)$$

С учетом ограничения $\Delta u(n) \leq \Delta u^{max}$ выражение (66) примет вид:

$$y_{\Delta}^K \leq (c_1 + c_0 + c_{-1} + c_{-2} + \dots + c_{-p+1}) \cdot \Delta u^{max}. \quad (67)$$

Вводя обозначения $\Delta = \frac{y_{\Delta}^K}{\Delta u^{max}}$, $P(p) = \sum_{i=0}^p c_{1-i}$, получаем $P(p) \geq \Delta$;

Следовательно, для нахождения максимального горизонта прогнозирования p , при котором гарантируется робастность управления, необходимо определить p , при котором достигается:

$$\min_{p \in N, P(p) \geq \Delta, |u| \leq U} P(p). \quad (68)$$

Задача (68) может не иметь решений. В таком случае мы не сможем гарантировать управляемость системы по данной переменной. Если же найти p удалось, то можно гарантировать ее управляемость за p тактов.

3.5. Выводы

Разработан алгоритм MPC с использованием ассоциативных идентификационных моделей. Данный алгоритм представляет собой альтернативу традиционному подходу, основанному на решении на каждом временном шаге оптимизационной задачи. Он получил название «ассоциативного MPC» (Associative MPC – AMPC). Алгоритм позволяет получать высокоточные модели

для широкого класса нелинейных процессов, что повышает эффективность алгоритмов МРС. Введен критерий выбора глубины горизонта прогнозирования АМРС. Эффективность разработанного алгоритма по сравнению с традиционными будет продемонстрирована в Главе 4.

Глава 4. Практическое применение ассоциативных виртуальных анализаторов

4.1. Построение ВА для технологического процесса кальцинации

Технологический процесс (ТП) кальцинации (прокалки) [121] связан с удалением химической влаги из материала. Материал (руда) подается в печь через холодную головку из расходного бункера. Материал по мере прохождения печи нагревается, при этом из него вначале удаляется физическая влага, а затем, при температурах около 1000°C химически связанная влага. Качество прокаленного материала зависит от температурного режима печи, времени нахождения материала в ней, а также от качества подаваемого материала (дисперсность, насыпная плотность, влажность).

В данной работе построена прогнозирующая линейная модель качества продукции печей кальцинации. Проведен анализ полученных данных, отобраны информативные входные переменные модели путем расчета коэффициентов корреляции Пирсона. После нормировки данных разработана линейная регрессионная модель следующего вида:

$$Q(t) = \sum_{i=1}^4 \alpha_i x_i(t), \quad (69)$$

где (все параметры нормированы):

$Q(t)$ – качество продукции (процент остаточной влаги в материале);

x_1, x_2 – температуры на входе в печь и на выходе;

x_3 – количество подаваемого материала в печь;

x_4 – параметр, характеризующий дисперсный состав подаваемого материала;

$\alpha_i, i = 1, 2, 3, 4$ – коэффициенты линейной регрессии.

Ассоциативная модель будет иметь структуру линейной модели, но ее принципиальное отличие заключается в формировании на каждом такте новой модели на основе базы знаний (архива исторических данных ТП) об объекте, которая с течением времени обновляется и уточняется. На основе анализа ТП установлено, что для построения точного прогноза на основе ассоциативной

модели в каждый момент времени необходимо из архива исторических данных ТП отбирать 15 входных векторов, близких к текущему. Для определения близости векторов использовалось манхэттенское расстояние.

Прогноз для рассматриваемого ТП строился на основе линейной и ассоциативной моделей вида (69) для 80 тактов (один такт – один день). Результаты моделирования приведены на рис. 4.1.




Рис. 4.1 Прогноз показателя качества продукции

Для оценивания точности прогноза применяется средняя абсолютная ошибка (MAE), которая вычисляется по формуле:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i(t) - \tilde{y}_i(t)|, \quad (70)$$

где: $y_i(t)$ – фактическое значение, $\tilde{y}_i(t)$ – прогнозируемое значение, N – количество рассматриваемых тактов.

Также рассматривалась среднеквадратичная ошибка (MSE):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i(t) - \tilde{y}_i(t))^2, \quad (71)$$

MSE чувствительна к появлению больших ошибок при прогнозировании.

Для построенных линейной и ассоциативной моделей был проведен анализ качества прогноза на основе MAE, MSE и коэффициента корреляции Пирсона. Результаты анализа представлены в таблице 4.1.

Таблица 4.1. Результаты проведенного анализа

Ошибка	Линейная модель	Ассоциативная модель	Выводы
Средняя абсолютная ошибка (MAE)	0,64	0,204	Ошибка MAE для ассоциативной модели меньше, чем для линейной модели. Ассоциативная модель точнее линейной модели.
Среднеквадратическая ошибка (MSE)	0,63	0,28	Ошибка MSE для ассоциативной модели меньше, чем для линейной модели. Прогноз на основе ассоциативной модели имеет меньше больших ошибок прогноза по сравнению с прогнозом на основе линейной модели.
Коэффициент корреляции Пирсона	0,558	0,895	Коэффициент корреляции Пирсона ассоциативной модели больше, чем для линейной модели. Прогноз на основе ассоциативной модели имеет более схожую динамику объекта по сравнению с прогнозом на основе линейной модели.

4.2. Построение ВА для технологического процесса гидроочистки бензина каталитического крекинга в колонне фракционирования

4.2.1. Краткое описание технологического процесса

Установка гидроочистки бензина каталитического крекинга (ГО БКК) предназначена для снижения содержания серы и диеновых углеводородов в бензине, поступающем с установки каталитического крекинга вакуумного газойля.

Установка гидроочистки состоит из нескольких технологических блоков. В первом блоке осуществляется гидрирование диенов, превращение легких соединений серы в более тяжелые, а также изомеризация олефиновых углеводородов.

В последующих блоках осуществляется конверсия соединений серы до сероводорода с последующим его удалением в отпарной и (или) стабилизационной колонне.

В первом блоке продукт реактора, в котором происходят химические реакции в присутствии катализатора, подается в колонну фракционирования, в целях разделения бензина на легкий и тяжелый. Одним из показателей качества легкого бензина является общее содержание серы. Ниже представлен ВА этого показателя качества.

4.2.2. Моделирование общего содержания серы в бензине

Разработаны модели различных типов для определения содержания серы в боковом погоне колонны фракционирования. При моделировании рассматривались данные с установки ГО БКК одного из российских нефтеперерабатывающих заводов.

4.2.2.1. Множественная линейная регрессия

На основе анализа данных построена прогнозирующая линейная модель следующего вида:

$$S(t) = b_0 + b_1(t)T_1(t) + b_2(t)T_2(t) + b_3P(t) + b_4R(t), \quad (72)$$

где $S(t)$ – содержание серы в легком бензине колонны фракционирования; $T_1(t)$ – температура выходного потока печи подогрева низа колонны фракционирования; $T_2(t)$ – температура в реакторе блока селективного гидрирования; $P(t)$ – давление кубового продукта колонны фракционирования; $R(t)$ – кратность орошения колонны фракционирования; $b_0, \dots, b_4$ – коэффициенты модели.

Для модели множественной линейной регрессии получены следующие коэффициенты:

$$b_0 = 0,8095; b_1 = 0,2925; b_2 = -0,1396; b_3 = -0,2252; b_4 = -0,4081.$$

На рис. 4.2 представлены данные для модели множественной линейной регрессии на обучающей выборке.

Статистические характеристики модели:

- Коэффициент корреляции – 0,77;
- Средняя ошибка – 0,05;
- Среднеквадратичная ошибка – 0,005.




Рис. 4.2 Модель множественной линейной регрессии (обучающая выборка)

На рис. 4.3 представлены данные для той же модели на тестовой выборке.

Статистические характеристики модели:

- Коэффициент корреляции – 0,21;
- Средняя ошибка – 0,33;
- Среднеквадратичная ошибка – 0,12.




Рис. 4.3 Модель множественной линейной регрессии (тестовая выборка)

Из рис. 4.3 и 4.4 видно, что качественные показатели модели значительно ухудшились при переходе на тестовую выборку. Такие изменения свойственны нелинейным и (или) нестационарным процессам.

В целях повышения точности на практике применяют модели множественной линейной регрессии с автоподстройкой.

4.2.2.2. Множественная линейная регрессия с автоподстройкой

Автоподстройка влияет на свободный член b_0 в модели множественной линейной регрессии (72). На каждом такте значение b_0 изменяется на ошибку модели, которая умножается на поправочный коэффициент.

Данные для модели множественной линейной регрессии с автоподстройкой на обучающей выборке представлены на рис. 4.6.




Рис. 4.4 Модель множественной линейной регрессии с автоподстройкой (обучающая выборка)

Статистические характеристики модели:

- Коэффициент корреляции – 0,84;
- Средняя ошибка – 0,046;
- Среднеквадратичная ошибка – 0,004.

На рис. 4.7 представлены данные для той же модели на тестовой выборке.

Статистические характеристики модели:

- Коэффициент корреляции – 0,35;
- Средняя ошибка – 0,1;
- Среднеквадратичная ошибка – 0,014.




Рис. 4.5 Модель множественной линейной регрессии с автоподстройкой (тестовая выборка)

Как видно из рис. 4.7, автоподстройка позволяет значительно улучшить качество линейной модели.

4.2.2.3. Модель ассоциативного поиска

Ассоциативная модель будет иметь структуру линейной модели (72), но, в отличие от (72), на каждом временном такте будет формироваться новая модель на основе базы знаний об объекте, которая с течением времени обновляется и уточняется. Проведенный анализа ТП показал, что для построения прогноза достаточной точности на основе ассоциативной модели в каждый момент времени необходимо отбирать из архива 25 входных векторов в определенном смысле близких к текущему.

Данные для модели ассоциативного поиска на обучающей выборке представлены на рис. 4.8.

Статистические характеристики модели:

- Коэффициент корреляции – 0,87;
- Средняя ошибка – 0,04;

– Среднеквадратичная ошибка – 0,003.




Рис. 4.6 Модель ассоциативного поиска (обучающая выборка)

На рис. 4.9 графически представлены данные для той же модели на тестовой выборке.

Статистические характеристики модели:

- Коэффициент корреляции – 0,58;
- Средняя ошибка – 0,057;
- Среднеквадратичная ошибка – 0,006.




Рис. 4.7 Модель ассоциативного поиска (тестовая выборка)

4.2.2.4. Выводы

В таблице 4.2 приведены оценочные параметры по всем построенным моделям. Судя по данным таблицы 4.2, модель ассоциативного поиска работает лучше. Особенно хорошо это видно на тестовой выборке данных.

Таблица 4.2 Сводная таблица оценочных параметров моделей

Метод	Выборка	Коэффициент корреляции	Средняя ошибка	СКО
Множественная линейная регрессия	Обучающая выборка	0.77	0.05	0.005
Множественная линейная регрессия	Тестовая выборка	0.2	0.33	0.12
Множественная линейная регрессия с автоподстройкой	Обучающая выборка	0.84	0.046	0.004
Множественная линейная регрессия с автоподстройкой	Тестовая выборка	0.35	0.1	0.014
Ассоциативный поиск	Обучающая выборка	0.87	0.04	0.003
Ассоциативный поиск	Тестовая выборка	0.58	0.06	0.006

4.3. Практическое применение ВА на основе интеллектуального анализа технологических данных в замкнутом МРС-контуре обогатительной фабрики железорудного концентрата

Обогатительная фабрика – горное предприятие для первичной переработки твердых полезных ископаемых в целях получения технически ценных продуктов, пригодных для промышленного использования. С помощью различных технологий (флотации, магнитной сепарации и других) на обогатительных фабриках из добытой руды получают концентрат, в котором содержание полезного компонента намного выше, чем в исходном сырье. На обогатительных фабриках перерабатываются (обогащаются) руды черных и цветных металлов, неметаллические полезные ископаемые и уголь [122].

Объектом внедрения является обогатительная фабрика Стойленского горно-обогатительного комбината. Фабрика состоит из четырех секций, на каждой из которых происходит обогащение железорудного концентрата. Мы ограничимся описанием только одной секции.

4.3.1. Описание технологического процесса обогащения железорудного концентрата

Дробленая руда крупностью 120 мм из бункера системой конвейеров подается в две мельницы типа МШЦ (мельницы шаровые с центральной разгрузкой) первой стадии измельчения, работающие в замкнутом цикле с двуспиральным классификатором.

На разгрузочных горловинах мельниц первой стадии установлены бутары с отверстиями диаметром 40 мм. Продукт крупностью менее 40 мм через отверстия бутар разгружается в классификатор; продукт размером более 40 мм (количество продукта – единичные зерна) выгружается через горловину мельницы в специальные емкости и вывозится в отвал.

Слив спиральных классификаторов поступает на магнитные сепараторы с противоточной ванной первой стадии обогащения. В результате обогащения получается промпродукт (концентрат первой стадии ММС (мокрой магнитной

сепарации)) и отвальные хвосты, которые собираются в общий хвостовой лоток и транспортируются в хвостохранилище.

Концентрат первой стадии обогащения самотеком поступает в зумпф № 2, откуда насосами подается на классификацию в гидроциклоны.

Пески гидроциклонов поступают в мельницы второй стадии измельчения МШЦ, а слив гидроциклонов – на первую стадию обесшламливания в дешламатор.

Измельченный продукт второй стадии измельчения поступает самотеком на третью стадию обогащения в сепараторы с полупротивоточной ванной.

Концентрат третьей стадии обогащения объединяется с концентратом первой стадии ММС в зумпфе № 2 и возвращается в цикл второй стадии измельчения, а хвосты самотеком направляются в сборный хвостовой лоток.

Сгущенный продукт первой стадии обесшламливания (пески) насосами подается на четвертую стадию обогащения в двухбарабанные сепараторы, а слив первой стадии обесшламливания самотеком поступает в хвостовой лоток.

Концентрат четвертой стадии ММС направляется в зумпф № 3, откуда насосами подается на третью стадию классификации в гидроциклоны, а хвосты четвертой стадии ММС самотеком поступают в хвостовой лоток.

Пески гидроциклонов третьей стадии классификации самотеком поступают в мельницу МШЦ на третью стадию измельчения, а слив гидроциклонов – на вторую стадию обесшламливания в дешламаторы. Слив мельницы третьей стадии измельчения обогащается на второй стадии мокрой магнитной сепарации в сепараторах, хвосты которых направляются в хвостовой лоток, а промпродукт направляется в зумпф № 3, откуда насосами вместе с концентратом четвертой стадии ММС и добавочной водой подается на гидроциклоны третьей стадии классификации.

Сгущенный продукт второй стадии обесшламливания поступает в зумпф № 6, откуда насосами подается на пятую стадию обогащения на двухбарабанные магнитные сепараторы с полупротивоточной ванной, а слив – самотеком в хвостовой лоток.

Концентрат пятой стадии обогащения поступает в зумпф № 7, откуда насосами направляется в отделение обезвоживания, хвосты мокрой магнитной сепарации поступают самотеком в хвостовой лоток.

Обзорная операторская мнемосхема РСУ всей секции представлена на рис. 4.10.




Рис. 4.10. Обзорная мнемосхема РСУ секции 1 ОФ

4.3.2. Задачи МРС по управлению и оптимизации технологическим процессом

МРС-система на секции 1 ОФ предназначена для:

- обеспечения визуализации в режиме реального времени ключевых показателей качества продуктов посредством набора виртуальных анализаторов (ВА);
- автоматизированного управления показателями качества получаемых продуктов и другими важными технологическими переменными ТП как в условиях стабильного технологического режима, так и в условиях различных возмущений (изменение плановых заданий или внешние воздействия на секцию);

- решения задач оптимизации технологического режима, что подразумевает поиск и поддержание оптимальных режимов работы установки в соответствии с различными экономическими или технико-экономическими критериями.

Под автоматизированным управлением показателями качества получаемых продуктов понимается управление в замкнутом контуре ключевыми показателями качества получаемых продуктов. Оператор (или инженер-технолог), в данном случае, принимает решение о допустимых пределах изменения как для показателей качества продуктов, так и для управляющих переменных МРС-системы и вносит эти решения в систему. Система, в свою очередь, обеспечивает выполнение поставленных оператором (технологом) задач в автоматическом режиме. В этих целях в системе реализована подсистема ВА показателей качества продуктов.

4.3.3. Описание контроллера МРС

МРС-система реализована в виде одного многопараметрического контроллера, который охватывает следующие технологические блоки и узлы:

- Шаровые мельницы;
- Зумпфы;
- Дешламаторы.

Задачи управления:

- поддержание тока спирали либо плотности слива классификатора 11-2 в заданных оператором пределах,
- поддержание тока спирали либо плотности слива классификатора 12-1 в заданных оператором пределах,
- контроль содержания железа в секционном концентрате в заданных оператором пределах либо содержания класса 0.045 мм в секционном концентрате в заданных оператором пределах,
- управление уровнями в зумпфах,
- управление уровнем магнетита в дешламаторах 1-7 и 1-9.

Задачи оптимизации:

- максимизация загрузки руды на вход мельниц 11 и 12,

- максимизация тока спирали классификатора 11-2 по верхней границе операторских пределов,
- максимизация тока спирали классификатора 12-1 по верхней границе операторских пределов,
- максимизация уровней в зумпфах (без перелива),
- максимизация уровня магнетита в дешламаторах 1-7 и 1-9 при отсутствии магнетита в переливе,
- максимизация соотношения т:ж (твердое к жидкому) на мельницах 11 и 12 с ограничением по мощности приводов мельниц,
- минимизация расхода воды в прицепные мельницы 13 и 14.

4.3.4. Алгоритмы управления и оптимизации

- Контроль тока спиралей либо плотности слива классификаторов 11-2 и 12-1

Контроллер поддерживает ток в спиралях либо плотность слива классификаторов 11-2 и 12-1 в операторских пределах за счет управления подачей в бутары мельниц, соответственно, 11 и 12. При этом контроллер стремится максимизировать ток внутри операторских пределов.

- Контроль содержания железа в секционном концентрате

Контроллер поддерживает содержание железа в секционном концентрате в операторских пределах при помощи управления загрузкой мельниц 11 и 12. При этом он избегает конфликтов с задачей контроля содержания класса 0.045 в секционном концентрате.

- Контроль класса 0.045 мм секционном концентрате

Контроллер поддерживает содержание класса 0.045 мм в секционном концентрате в операторских пределах при помощи управления загрузкой мельниц 11 и 12. При этом он избегает конфликтов с задачей контроля содержания железа в секционном концентрате.

- Максимизация загрузки руды на вход мельниц 11 и 12

Контроллер стремится максимизировать загрузку руды на вход мельниц 11 и 12, с ограничением по:

- минимально допустимому содержанию железа в секционном концентрате
- минимально допустимому содержанию класса 0.045 мм в секционном концентрате
- максимально допустимому току спиралей классификаторов 11-2 и 12-1
- минимально допустимой мощности приводов мельниц 11 и 12.
- Контроль и максимизация уровней в зумпфах

Контроллер поддерживает уровни пульпы в зумпфах 1-2, 1-3, 1-7 и 1-8 посредством управления подачи воды в них; при этом контроллер стремится максимизировать уровни внутри операторских пределов.

- Контроль и максимизация уровней магнетита в дешламаторах 1-7 и 1-9

Контроллер поддерживает уровень (давление) магнетита в дешламаторах 1-7 и 1-9 в установленных оператором пределах посредством управления клапаном на сливе дешламатора. При этом контроллер стремится максимизировать уровень внутри операторских пределов с ограничением по содержанию железа в переливе дешламатора.

- Максимизация соотношения т:ж на мельницах 11 и 12

При наличии запаса мощности приводов мельниц 11 и 12 (от минимально допустимого предела) контроллер максимизирует соотношение т:ж на мельницах 11 и 12 с целью улучшить качество концентрата. При приближении мощности к нижнему пределу контроллер в первую очередь снижает соотношение т:ж до минимально установленного предела, затем он начинает понижать загрузку соответствующей мельницы.

- Минимизация расходы воды на прицепных мельницах 13 и 14

При наличии запаса мощности приводов мельниц 13 и 14 (от минимально допустимого предела) контроллер минимизирует расход воды на мельницах 13 и 14 с целью улучшить качество концентрата. При приближении мощности к нижнему пределу контроллер в первую очередь увеличивает расход воды до максимально установленного предела, после чего начинает понижать загрузку соответствующей головной мельницы.

4.3.5. Структура контроллера МРС

В таблицах 4.3-4 представлены перечни контролируемых и управляющих переменных контроллера секции 1 ОФ, а также матрица физических взаимосвязей между переменными, полученная в результате анализа исторических данных.

Таблица 1.3 Контролируемые переменные МРС-контроллера

№	Тэг	Описание	Ед.изм.	Назначение переменной
1	s1E1101	Мощность мельницы 11	кВт	Ограничение
2	s1D401	Плотность слива классификатора 11-2	кг/м ³	Управление
3	K11s2RIfact	Ток спирали классификатора 11-2	А	Ограничение
4	s1F305	Расход воды в бутару мельницы 11	м ³ /ч	Управление
5	s1E2101	Мощность мельницы 12	кВт	Ограничение
6	s1D402	Плотность слива классификатора 12-1	кг/м ³	Управление
7	K12s1RIfact	Ток спирали классификатора 12-1	А	Ограничение
8	s1F306	Расход воды в бутару мельницы 12	м ³ /ч	Управление
9	s1D408	Плотность слива дешламатора 1-7	кг/м ³	Управление
10	QE1_6_04	Содержание железа в переливе дешламатора 1-7	%	Ограничение
11	LT1E_1_11	Уровень магнетита в дешламаторе 1-7	м	Управление и оптимизация
12	s1L109	Уровень пульпы в зумпфе 1-2	м	Управление и оптимизация
13	s1L114	Уровень пульпы в зумпфе 1-3	м	Управление и оптимизация
14	1S_VA_FE	ВА содержание железа в секционном концентрате	% масс.	Управление и оптимизация
15	1S_PA_FE	ПА содержание железа в секционном концентрате	% масс.	Управление и оптимизация
16	1S_VA_SZ	ВА содержание класса 0.045 в секционном концентрате	% масс.	Управление и оптимизация

№	Тэг	Описание	Ед.изм.	Назначение переменной
17	1S_PA_SZ	ПА содержание класса 0.045 в секционном концентрате	% масс.	Управление и оптимизация
18	s1E3101	Мощность мельницы 13	кВт	Ограничение
19	s1D416	Плотность слива мельницы 13	кг/м ³	Управление
20	s1F303	Расход воды в бутару мельницы 13	м ³ /ч	Управление
21	s1E4101	Мощность мельницы 14	кВт	Ограничение
22	s1D417	Плотность слива мельницы 14	кг/м ³	Управление
23	s1F304	Расход воды в бутару мельницы 14	м ³ /ч	Управление
24	s1L139	Уровень пульпы в зумпфе 1-7	м	Управление и оптимизация
25	s1D150	Плотность слива зумпфа 1-7	кг/м ³	Управление
26	s2L252	Уровень пульпы в зумпфе 1-8	м	Управление и оптимизация
27	s2D254	Плотность слива зумпфа 1-8	кг/м ³	Управление

Таблица 4.4 Управляющие переменные МРС-контроллера

№	Тэг	Описание	Ед.изм.
1	1WIC01	Уставка загрузки мельницы 11	т/ч
2	1GIC01	Уставка соотношения т:ж мельницы 11	т/ч
3	1FIC02	Уставка воды в бутару мельницы 11	м ³ /ч
4	1WIC02	Уставка загрузки мельницы 12	м ³ /ч
5	1GIC02	Уставка соотношения т:ж мельницы 12	м ³ /ч
6	1FIC06	Уставка воды в бутару мельницы 12	м ³ /ч
7	1LIC07	Плотность слива дешламатора 1-7	г/л
8	1LIC02	Клапан подачи воды в зумпф 1-2	%

№	Тэг	Описание	Ед.изм.
9	1LIC03	Клапан подачи воды в зумпф 1-3	%
10	1FIC03	Расход воды в 13 мельницу	м ³ /ч
11	1FIC07	Расход воды в 14 мельницу	м ³ /ч
12	1LIC04	Клапан подачи воды в зумпф 1-7	%
13	1LIC05	Клапан подачи воды в зумпф 1-8	%
14	1LIC09	Плотность слива дешламатора 1-9	г/л

Передаточные функции для каждого элемента модельной матрицы из таблицы 4.5 приведены на рис.4.12-38.

Таблица 4.5 Матрица ТП MPC-контроллера

MV / CV	1WIC01	1GIC01	1FIC02	1WIC02	1GIC02	1FIC06	1LIC07	1LIC02	1LIC03	1FIC03	1FIC07	1LIC04	1LIC05	1LIC09
s1E1101	–	–												
s1D401	+		–											
K11s2RIfact	+		+											
s1F305			+											
s1E2101				–	–									
s1D402				+		–								
K12s1RIfact				+		+								
s1F306						+								
s1D408							–							
QE1_6_04							–							
LT1E_1_11							–							
s1L109								+						
s1L114									+					
1S_VA_FE	–			–										
1S_PA_FE	–			–										
1S_VA_SZ	–			–										
1S_PA_SZ	–			–										
s1E3101	–									+				

[illegible]




Рис. 4.11 Передаточные функции для CV1




Рис. 4.12 Передаточные функции для CV2




Рис. 4.13 Передаточные функции для CV3




Рис. 4.14 Передаточные функции для CV4




Рис. 4.15 Передаточные функции для CV5




Рис. 4.16 Передаточные функции для CV6




Рис. 4.18 Передаточные функции для CV7




Рис. 4.19 Передаточные функции для CV8




Рис. 4.20 Передаточные функции для CV9




Рис. 4.21 Передаточные функции для CV10




Рис. 4.22 Передаточные функции для CV11




Рис. 4.23 Передаточные функции для CV12




Рис. 4.24 Передаточные функции для CV13




Рис. 4.25 Передаточные функции для CV14




Рис. 4.26 Передаточные функции для CV15




Рис. 4.27 Передаточные функции для CV16




Рис. 4.28 Передаточные функции для CV17




Рис. 4.29 Передаточные функции для CV18




Рис. 4.30 Передаточные функции для CV19




Рис. 4.31 Передаточные функции для CV20




Рис. 4.32 Передаточные функции для CV21




Рис. 4.33 Передаточные функции для CV22




Рис. 4.34 Передаточные функции для CV23




Рис. 4.35 Передаточные функции для CV24




Рис. 4.36 Передаточные функции для CV25




Рис. 4.37 Передаточные функции для CV26




Рис. 4.38 Передаточные функции для CV27

4.3.6. Разработка ВА на основе ассоциативного поиска

Сравниваются значения результатов лабораторного контроля качества продукции с показаниями ВА, разработанных на основе: (а) множественной линейной регрессии и (б) ассоциативной модели.

Критериями качества работы ВА являются:

1. Средняя абсолютная ошибка модели ВА (разность показаний ВА и лаборатории)
2. Коэффициент корреляции.

4.3.6.1. Содержание железа в секционном концентрате

На рис. 4.39 – 4.40 приведены графики сравнения значений лабораторных анализов и ВА разных типов по содержанию железа в секционном концентрате. В таблице 4.6 приведены соответствующие количественные показатели качества работы ВА двух типов.

Формула линейного ВА содержания железа в секционном концентрате:

$$F = 76,34 - 0,00545 D, \quad (73)$$

где:

- F – содержание железа в секционном концентрате,
- D – плотность слива в гидроциклонах ($S1D154$).




Рис. 4.39 Сравнение значений ВА (множественная линейная регрессия) с данными лабораторного контроля




Рис. 4.40 Сравнение значений ВА (модель ассоциативного поиска) с данными лабораторного контроля

Таблица 4.6 Сводная таблица оценочных параметров

Параметр	Линейная модель	Ассоциативная модель
Средняя абсолютная ошибка (MAE)	0,416	0,282
Среднеквадратическая ошибка (MSE)	0,285	0,129
Коэффициент корреляции Пирсона	0,479	0,803

Из таблицы 4.6 видно, что ошибки MAE и MSE для ассоциативной модели меньше, а коэффициент корреляции Пирсона больше по сравнению с ВА на основе линейной модели: ассоциативная модель дает более точный прогноз, чем линейная регрессия.

4.4. Выводы

Описан пример практического применения разработанных алгоритмов; их работоспособность и эффективность подтверждена численными экспериментами. Применение данных методов в управлении ТП на фабрике обогащения железорудного концентрата АО «Стойленский ГОК» обеспечило технико-экономический эффект в виде увеличения загрузки руды на вход головных мельниц на 2,3 % и снижение дисперсии лабораторных значений показателей качества железорудного концентрата на 34%.

Основные результаты работы

1. Проведен анализ существующих алгоритмов управления с прогнозирующей моделью.
2. На основе метода ассоциативного поиска разработаны виртуальные анализаторы качества продукции для различных технологических процессов (ТП) промышленного производства.
3. Разработан алгоритм МРС с использованием ассоциативных идентификационных моделей («ассоциативный МРС»);
4. Сформулирован критерий выбора глубины горизонта прогнозирования для «ассоциативного МРС», при котором сохраняется управляемость системы управления;
5. Предложен метод создания программно-алгоритмических комплексов, реализующих управление в схеме МРС на основе цифровых идентификационных моделей; проведены вычислительные эксперименты, подтвердившие эффективность алгоритмов;
6. Результаты проведенных исследований использованы при внедрении системы усовершенствованного управления ТП на обогатительной фабрике акционерного общества «Стойленский горно-обогатительный комбинат» (АО «Стойленский ГОК»). Эффект от внедрения подтвержден АО «Стойленский ГОК». Удалось на 2,3% увеличить загрузку руды на вход головных мельниц обогатительной фабрики, а также на 34% уменьшить дисперсию лабораторных значений показателей качества железорудного концентрата.

Список литературы

1. Вапник В.Н. Восстановление зависимостей по эмпирическим данным. – М.: Наука, 1979. – 448 с.
2. Bakhtadze N.N., Kulba V.V., Lototsky V.A. and Maximov E.M. Identification-based approach to soft sensors design // Proceedings of IFAC Workshop of Intelligent Manufacturing Systems (Alicante, Spain). 2007. P. 86-92.
3. Туз А.А., Браун-Аквей В., Лемпного Ф., Кулаков А.Г., Богатилов В.Н. Управление с прогнозирующими моделями // Труды Кольского научного центра РАН. 2015. №3(29). С.151-161.
4. Дозорцев В.М., Ицкович Э.Л., Кнеллер Д.В. Усовершенствованное управление технологическими процессами (APC): 10 лет в России // Автоматизация в промышленности. 2013. №1. С.12-19.
5. Торгашов А.Ю., Гончаров А.А., Самотылова С.А. Современные методы построения систем усовершенствованного управления технологическими процессами // Вестник Дальневосточного Отделения Российской Академии Наук. 2016. №4. С.102-107.
6. Я.З. Цыпкин Синтез робастно оптимальных систем управления объектами в условиях ограниченной неопределенности // Автоматика и телемеханика. 1992. №9. С. 139-159.
7. Albin T., Ritter D., Abel D., Liberda N., Quirynen R. and Diehl M. Nonlinear MPC for a two-stage turbocharged gasoline engine airpath // IEEE 54th Annual Conference on Decision and Control (Osaka, Japan). 2015. P. 849-856.
8. Allgower F., Badgwell T., Qin J., Rawlings J.B. and Wright S.J. Nonlinear Predictive Control and Moving Horizon Estimation – An Introductory Overview // Advances in Control. 1999. P.391–449.
9. Arefi M., Montazeri A., Poshtan J. and Jahed-Motlagh M. Nonlinear model predictive control of chemical processes with a wiener identification approach // IEEE International Conference on Industrial Technology. 2006. P. 1735–1740.
10. Razvan C. and Livint G. Nonlinear model predictive control of autonomous vehicle steering // 19th International Conference on System Theory and Computing. 2015. P. 466–471.

11. Диго Г.Б., Диго Н.Б., Можаровский И.С., Торгашов А.Ю. Метод разработки виртуальных анализаторов для нелинейных технологических объектов // Информатика и системы управления. 2013. № 3(37). С. 13-23.
12. Торгашов А.Ю., Гончаров А.А., Диго Г.Б., Диго Н.Б. Идентификация параметров моделей динамических виртуальных анализаторов технологических объектов управления // Автоматизация в промышленности. 2014. №7. С. 31-33.
13. Торгашов А.Ю., Диго Г.Б., Диго Н.Б., Можаровский И.С. Проблемы построения моделей виртуальных анализаторов слабо формализованных технологических объектов // Труды X международной конференции "Идентификация систем и задачи управления" (Москва, 26-29 января 2015, Институт проблем управления им. В.А. Трапезникова) Научное электронное издание. М.: ИПУ РАН. 2015. С.438-445.
14. Goncharov A., Torgashov A. Application of active set method for soft sensor model identification of crude oil distillation process // Proc. DOOR 2016, (Vladivostok, Russia, September 19-23, CEUR-WS). 2016. Vol. 1623. P. 723–732.
15. Gavrilov A.V. The model of associative memory of intelligent system // In: Preprints of the 6-th Russian-Korean International Symposium on Science and Technology. 2002. Vol. 1, P. 174–177.
16. Ang K.H., Chong G., Li Y. PID control system analysis, design, and technology // IEEE Transactions on Control Systems Technology. 2005. Vol. 13. No. 4. P. 559-576.
17. Никифоров В. О. Адаптивное и робастное управление с компенсацией возмущений. — СПб: Наука. — 282 с.
18. Kothare, M. V., V. Balakrishnan, and M. Morari, Robust constrained model predictive control using linear matrix inequalities // Automatica. 1996. Vol. 32. No. 10. P. 1361-1379.
19. Zheng, Z. Q. and Morari M. Robust Stability of Constrained Model Predictive Control // Proceedings of the American Control Conference, session WM7(San Francisco). 1993. P.379-383.
20. Дозорцев В.М., Кнеллер Д.В. APC – Усовершенствованное управление технологическими процессами // ИКА – Выпуск 10. 2005. С. 56-62.

21. Skogestad S. and Postlethwaite I. Multivariate Feedback Control. – John Wiley and Sons, 2005. – 608 p.
22. Ротач В.Я. Теория автоматического управления. – М.: Изд-во МЭИ, 2004. – 400 с.
23. Torgashov A., Zmeu K. Nonparametric soft sensor evaluation for industrial distillation plant // Computer Aided Chemical Engineering. 2015. Vol. 37. P. 1487-1492.
24. Parisio A., Rikos E., Glielmo L. Stochastic model predictive control for economic/environmental operation management of microgrids: An experimental case study // Journal of Process Control. 2016. Vol. 43. P. 24-37.
25. Grosso J.M., Ocampo-Martínez C, Puig V., et al. Chance-constrained model predictive control for drinking water networks // Journal of Process Control. 2014. Vol. 24. No. 5. P.504-516.
26. O'Dwyer E., Tommasi L.D., Kouramas K., et al. Prioritised objectives for model predictive control of building heating systems // Control Engineering Practice. 2017. Vol.63. P.57-68.
27. Formentin S., Guanetti J., Savaresi S.M. Least costly energy management for series hybrid electric vehicles // Control Engineering Practice. 2016. Vol. 48. P. 37-51.
28. Hartley E.N., Trodden P.A., Richards A.G., et al. Model predictive control system design and implementation for spacecraft rendezvous // Control Engineering Practice. 2012. Vol. 20. No.7. P.695–713.
29. Бельков Ю.Н., Файрузов Д.Х., Кнеллер Д.В., Торгашов А.Ю. Система усовершенствованного управления установкой первичной переработки нефти: создание, внедрение, сопровождение // Автоматизация в промышленности. 2013. № 8. С. 3–10.
30. Поляк Б.Т., Хлебников М.В., Рапопорт Л.Б. Математическая теория автоматического управления: учебное пособие. – М.: ЛЕНАНД, 2019. – 500 с.
31. Tatjevsky P. Advanced Control of Industrial Processes: Structures and Algorithms. – L.: Springer, 2010 – 348 p.
32. Черешко А.А., Шундерюк М.М. Границы применимости алгоритмов усовершенствованного управления с прогнозирующей моделью в условиях

- неопределенности динамики объекта // Проблемы управления. 2020. № 1. С.17–23.
33. Faulwasser T., Grüne L., Müller M.A. Economic Nonlinear Model Predictive Control // *Found. Trends Syst. Control*. 2017. Vol. 5. No. 1. P. 224–409.
 34. Li J., Wu C., Li S., et al. Optimal disturbance rejection control approach based on a compound neural network prediction method // *Journal of Process Control*. 2014. Vol. 24. No.10. P. 1516–1526.
 35. Feng X., Patton R. Active fault tolerant control of a wind turbine via fuzzy MPC and moving horizon estimation // *IFAC Proceedings Volumes*. 2014. Vol.47. No.3. P. 3633–3638.
 36. Gorges D. Relations between Model Predictive Control and Reinforcement Learning // *IFAC-PapersOnLine*. 2017. Vol.50. No.1. P. 4920–4928.
 37. Zhang J. Design of a new PID controller using predictive functional control optimization for chamber pressure in a coke furnace // *Isa Transactions*. 2016. Vol. 67. P.208-214.
 38. Killian M., Mayer B., Kozek M. Cooperative fuzzy model predictive control for heating and cooling of buildings // *Energy & Buildings*. 2016. Vol. 112. P.130–140.
 39. Chikasha P.N., Dube C. Adaptive Model Predictive Control of a Quadrotor // *IFAC PapersOnLine*. 2017. Vol.50. No.2. P.157–162.
 40. Vasičkaninova A., Bakosova M., Mészáros A., et al. Neural network predictive control of a heat exchanger // *Applied Thermal Engineering*. 2011. Vol. 31. No.13. P. 2094–2100.
 41. Morari, M., and E. Zafiriou, *Robust Process Control*. – Prentice Hall, 1989. – 512p.
 42. Henson M.A. Nonlinear model predictive control: current status and future directions // *Computers and Chemical Eng.* 1998. Vol.23. P.187–202.
 43. Babuska R., Sousa J.M. and H.B. Verbruggen Predictive control of nonlinear systems based on fuzzy and neural models // In *Proc. 5th European Control Conference ECC'99(Karlsruhe)*. 1999.
 44. Marusak P. and Tatjewski P. Fuzzy Dynamic Matrix Control algorithms for nonlinear plants // In *Proc. 6th Int. Conf. Methods and Models in Automation and Robotics MMAR'00 (Miedzyzdroje, Poland)*. 2000. P. 749–754.

45. Gattu G. and Zafiriou E. Nonlinear quadratic dynamic matrix control with state estimation // *Ind. Eng. Chem. Res.* 1992. Vol. 31. P. 1096–1104.
46. Simeoni F., Casalino L., Zavoli A. and Colasurdo G. Indirect optimization of satellite deployment into a highly elliptic orbit // *International Journal of Aerospace Engineering*. 2012. Vol. 2012. 14 p.
47. Wachter A. and Biegler L. On the implementation of an interiorpoint filter line-search algorithm for large-scale nonlinear programming // *Mathematical programming*. 2006. Vol. 106. P. 25–57.
48. Bock H. and Plitt K.J. A multiple shooting algorithm for direct solution of optimal control problems // *IFAC Proceedings Volumes*. 1984. Vol. 17. P. 242–247.
49. Jones C. and Morari M. Polytopic approximation of explicit model predictive controllers // *IEEE Transactions on Automatic Control*. 2010. Vol. 55. P. 2542–2553.
50. Kirches C., Wirsching L., Sager S. and Bock H. Efficient Numerics for Nonlinear Model Predictive Control // *Recent Advances in Optimization and its Applications in Engineering*. 2010. P. 339–357.
51. Grosso J., Velarde Rueda P., Ocampo-Martinez C., Maestre J.M. and Vicenc. P. Stochastic model predictive control approaches applied to drinking water networks // *Optimal Control Applications and Methods*. 2016. Vol. 38. No. 4. P. 1-17.
52. Mayne D.Q. Competing methods for robust and stochastic MPC // *IFAC-PapersOnLine*. 2018. Vol. 51. No. 20. P. 169-174.
53. Cannon M., Kouvaritakis B., Wu X. Probabilistic constrained MPC for multiplicative and additive stochastic uncertainty // *IEEE Trans. Autom. Contr.* 2009. Vol.54. No. 7. P. 1626–1632.
54. Cannon M., Kouvaritakis B., Wu X. Model predictive control for systems with stochastic multiplicative uncertainty and probabilistic constraints // *Automatica*. 2009. Vol.45, 167–172.
55. Cannon M., Kouvaritakis B., Ng D. Probabilistic tubes in linear stochastic model predictive control // *Syst. Control Lett.* 2009. Vol. 58. P. 747–753.
56. Cannon M., Kouvaritakis B., Raković S.V., Cheng Q. Stochastic tubes in model predictive control with probabilistic constraints // *IEEE Trans. Autom. Contr.* 2011. Vol. 56, 194–200.

57. Calafiore G.C., Fagiano L. Stochastic model predictive control of LPV systems via scenario optimization // *Automatica*. 2013. Vol.49. P.1861–1866.
58. Calafiore G.C., Campi M.C. The scenario approach to robust control design // *IEEE Trans. Autom. Contr.* 2006. Vol.51. P. 742–753.
59. Garifi K., Baker K., Touri B. and Christensen D. Stochastic model predictive control for demand response in a home energy management system // *IEEE Power & Energy Society General Meeting (PESGM)*. 2018. P. 1–5.
60. Oldewurtel F., Parisio A., Jones C.N., et al. Use of model predictive control and weather forecast for energy efficient building climate control // *Energy and Buildings*. 2012. Vol.45. P. 15–27.
61. Ziegler J., Nichols N. Optimum settings for automatic controllers // *64 Trans. ASME*. 1942. P. 759-68.
62. Cohen G.H., Coon G.A. Theoretical investigation of retarded control // *Trans ASME*. 1953. Vol.75. P. 827-834.
63. Tyreus B.D., Luyben W.L. Tuning PI controllers for integrator/dead time processes // *Trans ASME*. 1992. Vol. 31. No.11. P. 2628-2631.
64. Bequette B.W. *Process control: modeling, design and simulation* – Upper Saddle River, N.J.: Prentice Hall, 2003 – 800 p.
65. Palmor Z. Stability properties of Smith dead-time compensator controllers // *International Journal of Control*. 1980. Vol. 32. No.6. P. 937-949.
66. Vanavil B., Uma S., Rao A.S. Smith predictor based parallel cascade control strategy for unstable processes with application to a continuous bioreactor // *Chemical Product and Process Modeling*. 2012. Vol.7. No.1. 20 p.
67. Zhang J. Design of a new PID controller using predictive functional control optimization for chamber pressure in a coke furnace // *ISA Transactions*. 2017. Vol. 67. P. 208–214.
68. Zadeh L.A. Fuzzy sets // *Information and Control*. 1965. Vol. 8. P.338-353.
69. Nakamori Y., Suzuki K. and Yamanaka T. Model predictive control using fuzzy dynamic models // in *Proc. IFSA'91(Brussels, Belgium)*. 1991. Vol. 135. P. 138.
70. Takagi T. and Sugeno M. Fuzzy identification of systems and its application to modeling and control // *IEEE Trans. Syst., Man, Cybern.*, vol. SMC-15. 1985. P. 116–132.

71. Huang Y.L., Helen H.L., Gong J.P. and Edgar T.F. Fuzzy Model Predictive Control // IEEE Transactions on Fuzzy Systems. 2000. Vol. 8, No.6. P. 665-678.
72. Killian M., Mayer B., Kozek M. Effective fuzzy black-box modeling for building heating dynamics // Energy Build. 2015. Vol.96. P. 175-186.
73. Killian M., Mayer B., Kozek M. Cooperative fuzzy model predictive control for heating and cooling of buildings // Energy and Buildings. 2016. Vol. 112. P. 130-140.
74. Fukushima H., Kim T. Adaptive model predictive control for a class of constrained linear systems based on the comparison model // Automatica. 2007. Vol. 43, No. 2. P. 301–308.
75. Tanaskovic M., Fagiano L., et al. Adaptive receding horizon control for constrained MIMO systems // Automatica. 2014. Vol.50, No. 12, P. 3019–3029.
76. Adetola V., DeHan D. and Guay M. Robust adaptive MPC for constrained uncertain nonlinear systems // International Journal of Adaptive Control and Signal Processing. 2011. Vol. 25. P. 155–168.
77. Vasickaninova A., Bakosova M., Mészáros A., Klemes J.J. Neural network predictive control of a heat exchanger // Applied Thermal Engineering. 2011. Vol. 31. P. 2094–2100.
78. Kittisupakorn P., Thitiyasook P., Hussain M.A., Daosud W. Neural network based model predictive control for a steel pickling process // Process Control. 2009. Vol. 19. No. 4. P. 579–590.
79. Piche S., Keeler J.D., Martin G., Boe G., Johnson D. and Gerules M. (2000). Neural network-based model predictive control // In Advances in Neural Information Processing Systems. 2000. P. 1029–1035.
80. Spielberg S., Kumar P., Tulsyan A., et al. A Deep Learning Architecture for Predictive Control // IFAC 2018. Vol. 51, No.18. P. 512–517.
81. Воронцов К.В. Точные оценки вероятности переобучения // Доклады РАН. 2009. Т. 429, № 1. С. 15–18
82. Ильин И.В., Гудков К.В. Анализ недостатков искусственных нейронных сетей и методов их минимизации // Материалы X Международной студенческой научной конференции «Студенческий научный форум». 2022.

83. Гафаров Ф.М., Галимянов А.Ф. Искусственные нейронные сети и их приложения. Учебное пособие – Издательство Казанского университета, Казань, 2018. – 121 с.
84. Zhou Z.-H. Rule Extraction: Using Neural Networks or For Neural Networks? // Journal of Computer Science & Technology. 2004. Vol.19. No.2. P. 249–253.
85. Бахтадзе Н.Н. Виртуальные анализаторы (идентификационный подход) // Автоматика и телемеханика. 2004. №11. С. 3–24.
86. Лотоцкий В.А., Чадеев В.М., Максимов Е.А., Бахтадзе Н.Н. Перспективы применения виртуальных анализаторов в системах управления производством // Автоматизация в промышленности. 2004. № 5. С. 23–29.
87. Черешко А.А., Виртуальные анализаторы качества на основе цифровых моделей // Автоматизация в промышленности. 2022. № 7. С. 33–38.
88. Самотылова С.А., Торгашов А.Ю. Разработка виртуального анализатора для производства метил-трет-бутилового эфира в условиях ограниченного объема обучающей выборки // Автоматизация в промышленности. 2019. № 6. С. 35-41.
89. Бахтадзе Н.Н., Сакрутина Е.А., Пятецкий В.Е. Predicting Oil Product Properties with Intelligent Soft Sensors // IFAC-PapersOnLine. 2017. Vol. 50, No.1. P. 14632–14637.
90. Snegirev O. Yu., Torgashov A. Yu. Development of Clustering-Based Adaptive Soft Sensors for Industrial Distillation Columns // Automation and remote control. 2021. Vol. 82, No.10. P. 1763–1773.
91. Гончаров А.А., Торгашов А.Ю. Разработка динамических виртуальных анализаторов атмосферной колонны фракционирования нефти с учетом параметрических ограничений // Математические методы в технике и технологиях ММТТ –29: сб. трудов XXIX Международ. науч. конф. 2016. Т. 3. С. 114 – 115.
92. Bakhtadze N., Sakrutina E., Pavlov B., Lototsky V., Zaikin O. Knowledge-based prediction in process control systems under limited measurement data // KES2017 (Marseille, France. Science Direct. Procedia Computer Science 112). 2017. P. 1225–1237.
93. Bakhtadze N., Belenkiy M., Pyatetsky V., Sakrutina E., Nikulina I. Intelligent Screening for Diagnostic and Treatment of Cancer Diseases // KES2017 (Marseille, France. Science Direct. Procedia Computer Science 112). 2017. P. 1238–1245.

94. Bakhtadze N., Dolgui, A., Sabitov, R., Elpashev D., Smirnova, G. Identification and simulation models in logistics control systems for production processes and freighting // IFAC-PapersOnLine. 2017. Vol. 50, No. 1. C. 14638–14643.
95. Bakhtadze N., Yadykin I., Pyatetsky V., Lototsky V., Maximov E., Sakrutina E.; Vershinin Y. Stability Analysis of Discrete Power Supply Systems in Industry // International Journal of Production Research. 2016. Vol.49. No. 12. P. 355-359.
96. Bakhtadze N., Pyatetsky E., Lototsky V. Knowledge-Based Models of Nonlinear Systems Based on Inductive Learning // New Frontiers in Information and Production Systems Modeling and Analysis: Incentive Mechanisms, Competence Management, Knowledge-based Production. Heidelberg: Springer. 2016. P. 85–104
97. Bakhtadze N., Maximov E., Valiakhmetov R. Fuzzy soft sensors for chemical and oil refining processes // in Pr. of 17 IFAC World Congress (Seul, Korea). IFAC Proceedings Volumes. 2008. Vol. 41. No. 2. P. 46–50.
98. Bakhtadze N., Lototsky V., Valiakhmetov R. Associative Search Models in Trading // in Pr. of 17 IFAC World Congress (Seul, Korea). 2008. P. 4280-4284.
99. Bakhtadze N., Cheresenko A., Elpashev D., Suleykin A., Purtov A. Predictive associative models of processes and situations // IFAC-PapersOnLine. 2022. Vol. 55, No. 2, P. 19–24.
100. Бунич А.Л., Бахтадзе Н.Н. Синтез и применение дискретных систем управления с идентификатором. – М.: Наука, 2003. – 232 с.
101. Черешко А.А., Титкина М.С. Применение алгоритмов ассоциативного поиска в системах управления с прогнозирующей моделью // Автоматизация в промышленности. 2022. №6. с.58-62.
102. Larichev O.I., Asanov A., Naryzhny Y. and Strahov S. Expert system for the diagnostics of acute drug poisonings // In: Preprints of the 21th SGES International Conference on Knowledge Based Systems and Applied Artificial Intelligence. 2001. P. 159–168.
103. Patel V.L. and Ramoni M.F. (1997). Cognitive models of directional inference in expert medical reasoning // In: Feltovich P., Ford K., Hofman R. (ed.), Expertise in Context: Human and Machine. AAAI Press, Menlo Parc, CA. 1997. P. 67-99.
104. Разумков М.С. Методы вербального анализа: исследование и сравнение // Фундаментальные исследования. 2016. № 10(3). С. 642-646.

105. Bakhtadze N., Lototsky V., Vlasov S., Sakrutina E. Associative Search and Wavelet Analysis Techniques in System Identification // Proceedings of the 16th IFAC Symposium on System Identification (Brussels, Belgium). 2012. Vol.16. No.1. P.1227–1232.
106. Daubechies I. and Lagarias J. Two-scale difference equations I. Existence and global regularity of solutions // SIAM J. Mathematical Analysis. 1991. Vol. 22, No.5, P. 1388–1410.
107. Bakhtadze N., Lototsky V. Knowledge-Based Models of Nonlinear Systems Based on Inductive Learning // In: New Frontiers in Information and Production Systems Modelling and Analysis Incentive Mechanisms, Competence Management, Knowledge-based Production. 2016. P.85–104.
108. Мандель И. Д. Кластерный анализ. — М.: Финансы и Статистика, 1988. — 177с.
109. Mallat S.G. Wavelet Tour of Signal Processing. — Academic Press (san Diego, CA.), 1999. — 635 p.
110. Moore E. On the reciprocal of the general algebraic matrix // Bulletin of the American Mathematical Society. 1920. Vol. 26. P. 394–395.
111. Penrose R. A generalized inverse for matrices // Proceedings of the Cambridge Philosophical Society. 1955. Vol. 51. P. 406–413.
112. Albert A. Regression and the Moore–Penrouse Pseudoinverse // Academic Press, New York-London. 1972. Vol. 94. P.1-180.
113. Старовойтов В.В., Голуб Ю. И. Нормализация данных в машинном обучении // Информатика. 2021. Том 18, № 3. С. 83-96.
114. Wong A.K.C. and Chiu D.K.Y. Synthesizing statistical knowledge from incomplete mixed-mode data // IEEE Transactions on Pattern Analysis and Machine Intelligence. 1987. Vol. 9. No.6. P.796-805.
115. Hall M. A. Correlation-based Feature Selection for Machine Learning – Ph.D diss. Dept. of Computer Science, Waikato Univ, 1998. – 178 p.
116. Leskovec J., Rajaraman A., Ullman J. Mining of Massive Datasets (3rd ed.). — Cambridge: Cambridge University Press, 2020. — 565 p.
117. Bakhtadze, N., Yadykin, I., Maximov, E., Maximova, N., Cheresenko, A., Vershinin, Y. Forecasting the Risks of Stability Loss for Nonlinear Supply Energy Systems // IFAC-PapersOnLine. 2021. Vol. 54. No. 1. P. 478-483.

- 118.Бунич А.Л. Вырожденные задачи синтеза систем управления линейными дискретными объектами // Проблемы управления. 2009. №5. С. 2 – 8.
- 119.Bakhtadze, N., Beginyuk, V., Elpashev, D., Zakharov, E., Salikhov, Z., Cheresenko, A. Intelligent Decision Support System Based on Video Recognition of Tuyere Hearth in a Blast Furnace // IFAC-PapersOnLine. 2022, in press.
- 120.Qin S.J. and Badgwell T.A. A Survey of Industrial Model Predictive Control Technology // Control Engineering Practice. 2003. Vol. 11. P.733-764.
- 121.Лайнер А.И. Производство глинозема – Учебное пособие, М., 1961. – 620 с.
- 122.Персиц В.З. Обоганительная фабрика – М.: Советская энциклопедия, 1985. – С. 530.

ПРИЛОЖЕНИЕ



Группа НЛМК

Акционерное общество
«СТОЙЛЕНСКИЙ ГОРНО-ОБОГАТИТЕЛЬНЫЙ КОМБИНАТ»

АО «Стойленский ГОК», площадь Фабричная пр-д-4 (ЮЗ п/р промзона),
г. Старый Оскол, область Белгородская, 309504
тел.: +7 (4725) 417 209, 449 435 | факс: +7 (4725) 416 562
e-mail: info.sgok@nlmk.com | www.sgok.nlmk.com

12.05.2022 № 40/93-56-408
от _____

АКТ

о внедрении результатов диссертационной работы
«Управление технологическими процессами
на основе интеллектуальных прогнозирующих моделей»
на соискание ученой степени кандидата технических наук
Черешко Алексея Анатольевича

Результаты диссертационной работы А.А. Черешко были использованы при внедрении системы усовершенствованного управления технологическим процессом (СУУТП) Обоганительной фабрики Стойленского горно-обогатительного комбината (АО «Стойленский ГОК»).

Разработанные А.А. Черешко динамические идентификационные модели были использованы в контуре управления с обратной связью, что обеспечило стабилизацию технологического режима обоганительной фабрики по ряду ключевых параметров: мощности шаровых мельниц, плотности слива классификаторов, тока спиралей классификаторов, уровней пульпы в зумпфах, содержания железа и класса крупности «0,045 мм» в секционном концентрате.

За счет более точного управления увеличилась загрузка руды на вход головных мельниц на 2,3%. Дисперсия лабораторных значений показателей качества железорудного концентрата уменьшилась на 34%.

Разработанные А.А. Черешко виртуальные анализаторы содержания железа и класса крупности «0,045 мм» в железорудном концентрате используются в замкнутом контуре управления СУУТП.

Начальник Управления автоматизации и метрологии



А.И. Татьяна

Татьянин А.И.
+7 (4725) 44-94-68
tatyannin_aid@nlmk.com