

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ УКРАИНЫ
ГОСУДАРСТВЕННОЕ ВЫСШЕЕ УЧЕБНОЕ ЗАВЕДЕНИЕ
«НАЦИОНАЛЬНЫЙ ГОРНЫЙ УНИВЕРСИТЕТ»



А.В. Герасина, В.И. Корниенко

**СТРУКТУРНО-ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ
ПРОЦЕССОВ ДРОБЛЕНИЯ И ИЗМЕЛЬЧЕНИЯ РУД**

Монография

Днепропетровск

НГУ

2013

УДК 681.5.015: 62-52
ББК 33.4
Г 37

*Рекомендовано до друку вченою радою Державного ВНЗ «НГУ»
(протокол № 6 від 02.07.2013).*

Рецензенти:

О.В. Поркуян, д-р техн. наук, професор (Технологічний інститут Східноукраїнського національного університету ім. В. Даля, м. Северодонецьк, директор);

А.М. Сільвестров, д-р техн. наук, професор (Національний технічний університет України «Київський політехнічний інститут», професор кафедри теоретичної електротехніки).

Герасина А.В.

Г 37 Структурно-параметрическая идентификация процессов дробления и измельчения руд: монография / А.В. Герасина, В.И. Корниенко. – Д.: Национальный горный университет, 2013. – 101 с.

ISBN 978-966-350-438-4

Приведены результаты исследований, которые позволили снизить ошибки идентификации процессов дробления и измельчения руд путем вариации структур их интеллектуальных прогнозирующих моделей в условиях изменения динамических режимов работы. Решение задачи обеспечивает повышение качества управления технологическими процессами в адаптивных системах управления за счет снижения ошибок их интеллектуальных прогнозирующих моделей, имеющих оптимальную структуру для текущего режима функционирования. При этом идентификацию управляемых процессов для снижения вычислительных затрат предложено проводить в зависимости от изменения их режимов работы. Разработаны методика, алгоритмы и программы идентификации управляемых процессов, обеспечивающие повышение качества управления ними за счет снижения ошибок их интеллектуальных прогнозирующих моделей.

Для специалистов в области теории и систем управления, аспирантов и студентов старших курсов технических вузов.

УДК 681.5.015: 62-52
ББК 33.4

ISBN 978-966-350-438-4

© О.В. Герасина, В.И. Корниенко, 2013
© Державний ВНЗ «НГУ», 2013

СОДЕРЖАНИЕ

ПЕРЕЧЕНЬ УСЛОВНЫХ СОКРАЩЕНИЙ	5
ВВЕДЕНИЕ	6
РАЗДЕЛ 1. АНАЛИЗ МЕТОДОВ РЕШЕНИЯ ЗАДАЧ ИДЕНТИФИКАЦИИ В АСУТП РУДОПОДГОТОВКИ	7
1.1. Технологии дробления и измельчения руд	7
1.2. Анализ существующих систем управления процессами дробления и измельчения	8
1.2.1. Системы управления процессами дробления и измельчения	8
1.2.2. Математические модели процессов дробления и измельчения	10
1.3. Анализ методов идентификации процессов дробления и измельчения	15
1.4. Анализ методов идентификации сложных объектов управления	18
1.5. Выводы и постановка задачи	21
РАЗДЕЛ 2. ОБОСНОВАНИЕ И ИССЛЕДОВАНИЕ КОМПЛЕКСНОГО МЕТОДА ИДЕНТИФИКАЦИИ НЕЛИНЕЙНЫХ ДИНАМИЧЕСКИХ ПРОЦЕССОВ РУДОПОДГОТОВКИ	23
2.1. Задача структурно-параметрической идентификации	23
2.1.1. Параметрическая идентификация	23
2.1.2. Структурно-параметрическая идентификация	24
2.2. Исследование режимов работы технологических процессов дробления и измельчения руд	25
2.2.1. Идентификация режимов работы нелинейных процессов дробления и измельчения руд	26
2.2.2. Идентификация состояния стохастических динамических процессов дробления и измельчения	28
2.3. Комплексный метод идентификации нелинейных динамических процессов дробления и измельчения руд	31
2.3.1. Определение характеристик состояния ОУ	31
2.3.2. Структурно-параметрическая идентификация ОУ	35
Выводы к разделу	43
РАЗДЕЛ 3. РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНЫХ ПРОГНОЗИРУЮЩИХ МОДЕЛЕЙ НЕЛИНЕЙНЫХ ДИНАМИЧЕСКИХ ПРОЦЕССОВ КРУПНОГО ДРОБЛЕНИЯ И САМОИЗМЕЛЬЧЕНИЯ РУД	45
3.1. Методика структурно-параметрической идентификации	45
3.1.1. Определение характеристик состояния ОУ	45
3.1.2. Структурно-параметрическая идентификация ОУ	46
3.2. Алгоритм определения изменения режимов работы технологических процессов	47
3.3. Разработка алгоритмов структурно-параметрической идентификации нелинейных процессов дробления и измельчения	49
3.3.1. Алгоритмы глобальной оптимизации моделей	49
3.3.2. Алгоритмы локальной оптимизации моделей	52

3.4. Исследование эффективности структурно-параметрической идентификации	54
3.4.1. Идентификация характеристик процессов крупного дробления и самоизмельчения	54
3.4.2. Разработка интеллектуальной прогнозирующей модели процесса ККД	57
3.4.3. Разработка интеллектуальной прогнозирующей модели процесса МСИ	65
Выводы к разделу	72
РАЗДЕЛ 4. ТЕХНИЧЕСКАЯ РЕАЛИЗАЦИЯ РЕЗУЛЬТАТОВ ИССЛЕДОВАНИЙ	75
4.1. Разработка алгоритмического и программного обеспечений АСУТП рудоподготовки	75
4.2. Экспериментальные исследования	78
4.2.1. Идентификация характеристик процесса ККД по экспериментальным данным	78
4.2.2. Оценка эффективности управления процессом ККД по разработанной модели	81
Выводы к разделу	86
ЗАКЛЮЧЕНИЕ	87
СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ	89
Приложение А.	95
Приложение Б.	98

ПЕРЕЧЕНЬ УСЛОВНЫХ СОКРАЩЕНИЙ

АО – алгоритмическое обеспечение
БМ – барабанная мельница
ГА – генетический алгоритм
ГОК – горно-обогатительный комбинат
ИД – исходные данные
ИО – информационное обеспечение
КД – конусная дробилка
ККД – крупнокусковое дробление
ЛДБ – линейный динамический блок
МГУА – метод группового учета аргументов
МИО – метод имитации отжига
ММС – мельница мокрого самоизмельчения
МСИ – мокрое самоизмельчение
НС – нейронная сеть
НСБ – нелинейный статический блок
НСПР – нейронная сеть прямого распространения
ОУ – объект управления
ПИТ – апериодическое звено первого порядка с запаздыванием
ПИТ2 – последовательно соединенные апериодическое звено первого порядка с запаздыванием с безинерционным квадратичным звеном
ПО – программное обеспечение
ПСП – прямой случайный поиск
РБФ – радиальная базисная функция
СК – спиральный классификатор
ТО – техническое обеспечение
ЭА – эволюционный алгоритм
Anfis – адаптивная нейронная система нечеткого вывода
ARX – авторегрессия с дополнительным входным сигналом

ВВЕДЕНИЕ

Рудоподготовка включает процессы дробления и измельчения и является одной из наиболее энерго- и материалоемких технологических циклов обогащения руд, поэтому актуальным является снижения затрат на эти процессы путем создания АСУ этими процессами.

Известно, что наиболее эффективными системами управления процессами дробления и измельчения руд являются адаптивные системы. В них принцип управления основан на включении математической модели объекта в контур управления и определении управляющих воздействий по прогнозу в реальном времени результатов процесса. Для реализации этих систем необходима разработка динамических моделей управляемых процессов, которая осуществляется с помощью процедуры их идентификации.

В качестве моделей сложных процессов большое развитие получили нейронные сети и системы нечеткого вывода, которые являются универсальными и эффективными аппроксиматорами и способны адаптироваться под изменяемые свойства (режимы работы) управляемых процессов.

Крупное дробление и самоизмельчение руд являются начальными процессами технологических линий переработки и обогащения руды. Поэтому актуальным является повышение качества управления этими процессами для уменьшения дисперсии технологических параметров, что приводит к улучшению качества продуктов обогащения.

Таким образом, обоснование, разработка и внедрение методов идентификации процессов крупного дробления и самоизмельчения руд с целью снижения ошибок их моделей, предназначенных для построения адаптивных систем управления этими процессами, является актуальным.

Целью работы является решение актуальной научной задачи снижения ошибок идентификации процессов крупного дробления и самоизмельчения руд путем вариации структур их интеллектуальных прогнозирующих моделей в условиях изменения динамических режимов работы.

Объектом исследования являются технологические процессы крупного дробления и самоизмельчения руд на горно-обогатительных комбинатах.

Предметом исследования являются методы идентификации процессов крупного дробления и самоизмельчения руд как объектов управления.

В основу исследований положены методы систем искусственного интеллекта (нейронные сети, системы нечеткой логики) для синтеза прогнозирующих моделей процессов крупного дробления и самоизмельчения руд; методы нелинейной динамики для определения характеристик управляемых процессов; структурные (эволюционные, поисковые) и параметрические (градиентные, квазиньютоновские) методы оптимизации для получения оптимальных структуры и параметров моделей; статистические методы обработки модельных и экспериментальных данных.

РАЗДЕЛ 1

АНАЛИЗ МЕТОДОВ РЕШЕНИЯ ЗАДАЧ ИДЕНТИФИКАЦИИ В АСУТП РУДОПОДГОТОВКИ

1.1. Технология дробления и измельчения руд

Рудоподготовка на горно-обогатительном комбинате (ГОК) включает процессы дробления и измельчения руды (рис. 1.1), а также грохочение, классификацию и т.п., задачей которых является подготовка руды к последующему процессу ее обогащения [1-7]. Таким образом, чем полнее раскрываются минералы при дроблении и измельчении, тем успешнее последующее обогащение полезного ископаемого.

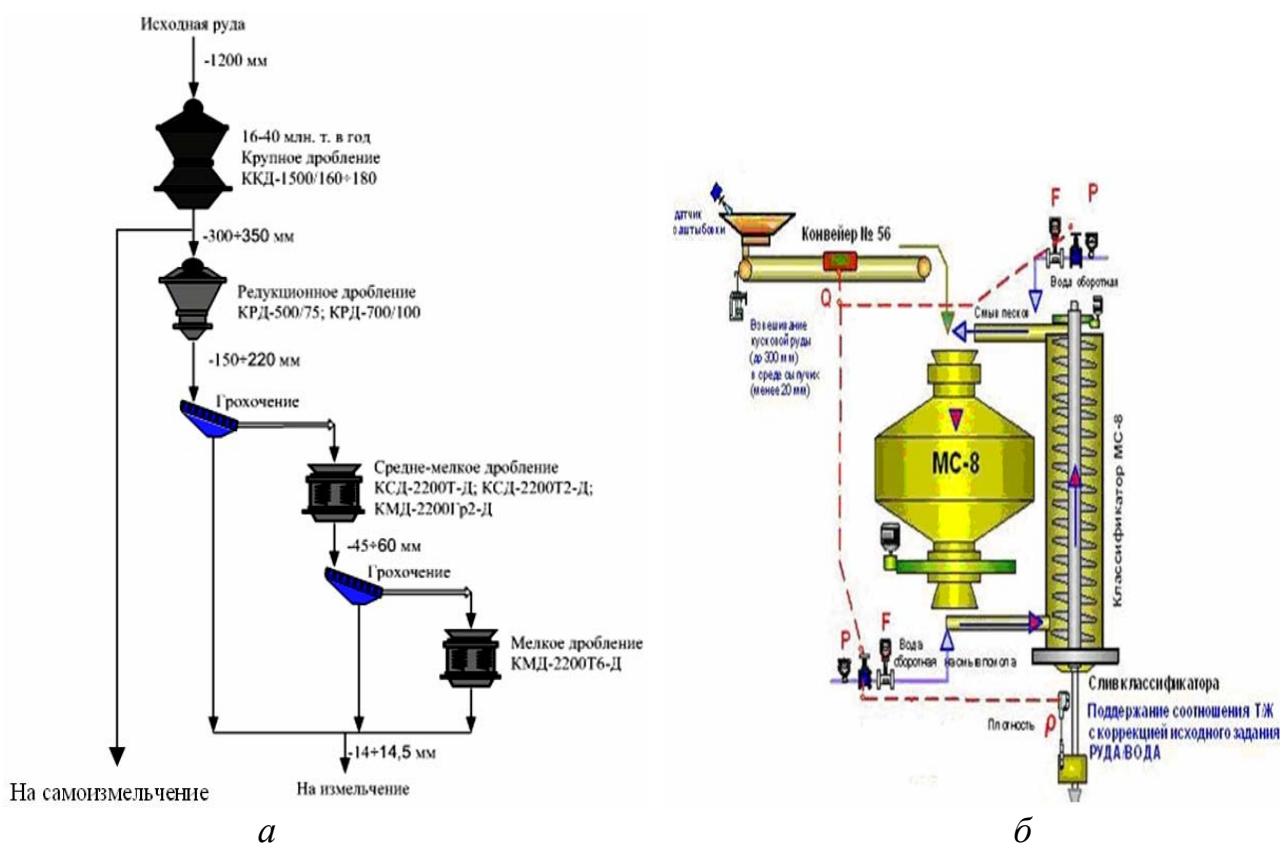


Рис. 1.1. Технологические схемы процессов дробления (а) и измельчения (б) руд

Дробление – процесс разрушения материала (крупностью ≥ 5 мм), осуществляемый в дробилках, а измельчение материала (крупностью < 5 мм) – в мельницах. На ГОКах процесс крупнокускового дробления (ККД) осуществляется, обычно, в конусных дробилках (КД) ККД-1500, а процесс мокрого самоизмельчения (МСИ) – в барабанных мельницах (БМ) мокрого самоизмельчения (ММС) ММС 70x23 (или ММС 90x30).

Рудоподготовка в значительной степени предопределяет технологические и экономические показатели работы предприятия: затраты на дробление и из-

мельчение составляют 51,0–51,5 %; перекачивание хвостов – 22,0–24,0 %; магнитную сепарацию – 10,0–11,0 %; обезвоживание концентрата – 6,5–8,0 %. С рудоподготовкой связаны также и основные затраты (до 85-87%) на электроэнергию. Таким образом, главным направлением повышения рентабельности ГОКов является повышение эффективности работы переделов дробления и измельчения, что позволит уменьшить расход электроэнергии и других ресурсов.

Процесс ККД находится в начале технологической линии дробления, а процесс МСИ – в начале технологической линии переработки и обогащения руды. При этом актуальным является повышение качества управления этими процессами для уменьшения дисперсии технологических параметров, что приводит к улучшению качества продуктов обогащения.

1.2. Анализ существующих систем управления процессами дробления и измельчения руд

1.2.1. Системы управления процессами дробления и измельчения.

При создании систем автоматизированного управления процессом дробления руководствуются следующими принципами [8, 9, 10-14]:

- повышение производительности при обеспечении гранулометрического состава продукта дробления на уровне заданного значения;
- снижение энергозатрат при обеспечении гранулометрического состава продукта дробления и производительности на уровне заданного значения;
- обеспечение заданного гранулометрического состава продукта дробления с поддержкой производительности на уровне не ниже допустимого значения.

Для построения систем автоматического управления мельницами и агрегатами на их основе выделяют следующие системы и методы [15-22]:

- поисковые системы с непосредственным измерением характеристик готовой продукции;
- системы управления, использующие регрессионные статические зависимости;
- экстремальные системы управления по средней мощности двигателя и шума мельницы;
- системы управления контуром регулирования ступени внутримельничного заполнения;
- адаптивные системы на основе структурных моделей объектов управления (ОУ) с параметрической идентификацией в процессе управления.

Наиболее эффективными из вышеперечисленных систем являются адаптивные системы, основанные на структурных моделях ОУ с параметрической идентификацией в процессе управления. Такие системы характеризуются сложными алгоритмами обработки информации в управляющей части и появились благодаря развитию современных средств вычислительной техники. К недостаткам этих систем относят использование линейных моделей для прогноза нелинейных процессов измельчения, а также неоптимальность управления. Однако использование оперативных данных о внутреннем состоянии объекта и

априорной информации о закономерностях измельчения в сочетании с современными методами адаптивной идентификации и управления является наиболее перспективным методом, базирующемся на контроле переменных состояния ОУ [15-18].

Основная особенность адаптивных систем управления – возможность получения информации в процессе функционирования и использования ее для управления, что позволяет повысить качество управления при наличии помех. Это достигается за счет того, что в данных системах стратегия управления основана на включении математической модели в контур управления и прогнозе в режиме реального времени результатов процесса.

Примером адаптивной системы является автоматизированная система управления технологическим процессом (АСУ ТП) рудоподготовки MineOOCad компании National Steel Pellet Company (США, штат Миннесота) [18, 20, 21]. Данная система выполняет процедуры идентификации и прогнозирования процессов дробления и измельчения (рис. 1.2).

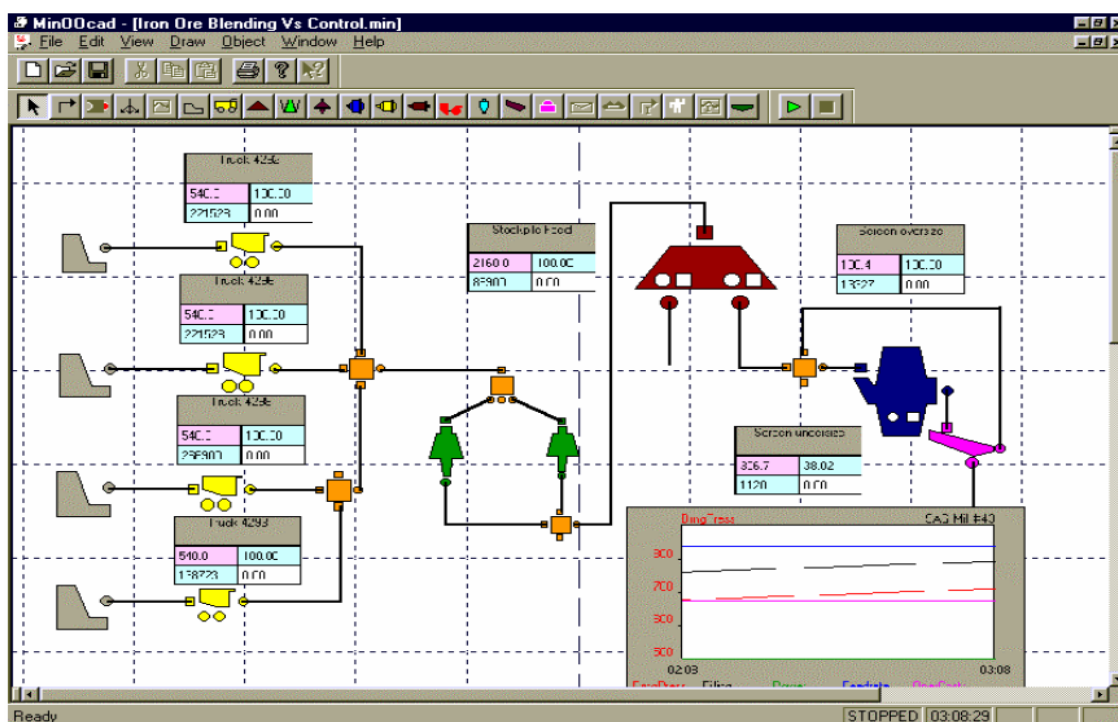


Рис. 1.2. Интерфейс АСУ MineOOCad

Использование данной АСУ позволяет:

- рассчитывать расходы по эксплуатации для всего технологического процесса;
- интегрировать системы управления в масштабах предприятия в АСУ MineOOCad;
- вести учет воздействия обслуживания, используя реальный износ оборудования и корректировку моделей;
- использовать программное обеспечение АСУ для работы в реальном режиме времени.

Внедрение данной системы позволило увеличить производительность за счет улучшения измельчения руды на 15% и уменьшить время разгрузки грузовиков на 25%, а также уменьшить складские запасы.

К достоинствам системы также следует отнести: сокращение расходов электроэнергии и других ресурсов; система работает с любым числом элементов технологического процесса; полученные модели достаточно точно аппроксимируют все элементы технологических процессов дробления и измельчения руд.

В работе [21] предложены адаптивные системы управления, работающие в режиме реального времени и основанные на различных стратегиях:

- стратегия для мельницы измельчения, в которой используется фильтр Калмана для оценки загрузки мельницы, а также твердости руды;
- стратегия с обратной связью, для поддержания определенного значения объема пульпы в ванне классификатора и размеров частиц продукта в мельнице измельчения;
- стратегия, которая динамически оптимизирует скорость подачи и размер частиц в одной стадии измельчения технологической цепи аппаратов.

Ключевые элементы, требуемые для этих АСУ – адекватные модели, точные процедуры оценки, основанные на измерениях, а также недорогие распределенные аппаратные средства управления для реализации функций стабилизации и оптимизации.

Примером реализации в Украине адаптивной системы является АСУ ТП секций обогащения руды, реализованной ОАО «Северный ГОК» и разработанной на базе SCADA-системы TRACE MODE 6 [22].

Основные функции этой АСУ ТП включают:

- автоматизированное и автоматическое управление процессами измельчения;
- автоматическое управление загрузкой мельниц;
- управление подачей воды в мельницы, классификаторы и зумпфы;
- использование математической модели процесса для выбора оптимальных режимов работы агрегатов;
- мониторинг состояния агрегатов.

Недостатком данной АСУ ТП является неэффективность реализации линейных законов регулирования нелинейным нестационарным процессом измельчения.

Следует отметить, что главным недостатком всех адаптивных систем управления является отсутствие в них структурной идентификации, что важно, учитывая наличие различных режимов работы процессов рудоподготовки.

Для реализации адаптивных систем управления необходимо наличие динамических моделей управляемых процессов, для получения которых используются процедуры их идентификации.

1.2.2. Математические модели процессов дробления и измельчения.

Для процесса крупного дробления в КД выходными переменными являются гранулометрический состав дробленого продукта $G_{вых}$, производитель-

ность процесса $Q_{\partial p}$ и потребляемая мощность $P_{\partial p}$ (рис. 1.3.а). Управляющими воздействиями являются производительность рудного питания (подача) $Q_{\text{вх}}$ и размер разгрузочной щели дробилки g . К возмущениям относят гранулометрический состав входной руды $\Gamma_{\text{вх}}$ и ее крепость ρ , состояние футеровок ξ и т.п. [10-14, 23, 24].

Основными выходными переменными процесса самоизмельчения в ММС являются содержание готового класса крупности в выходном продукте $\Gamma_{\text{м}}$, производительность по готовому классу $Q_{\text{гот}}$, потребляемая мощность $P_{\text{м}}$ и степень внутримельничного заполнения φ (рис. 1.3.б). Его управляющими воздействиями являются производительность по входной руде $Q_{\text{р}}$ и расходы воды $B_{\text{м}}$. К возмущениям относят гранулометрический состав входной руды $\Gamma_{\text{р}}$, ее физико-механические и вещественные свойства q , пески Π , состояние футеровок и лифтеров ξ и др. [10-14, 23-26].

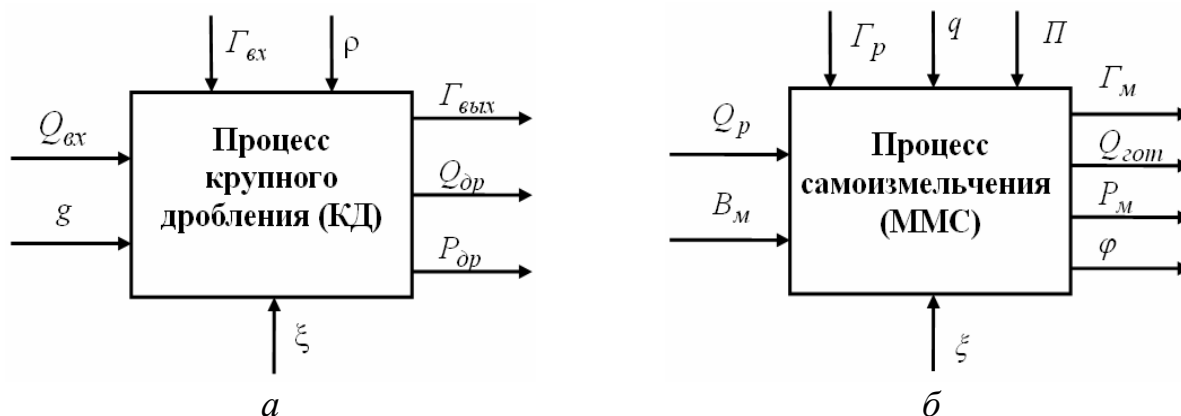


Рис. 1.3. Процессы крупного дробления в КД (а) и самоизмельчения в ММС (б) как объекты управления

Наиболее трудоемким и важным в оптимизации процессами крупного дробления и самоизмельчения руд является выбор критерия оптимальности (цели управления) и математической модели технологического процесса [26]. Так как процессы ККД и МСИ относят к подготовительным процессам, то для их управления используют технологические критерии [10].

Производительность процесса дробления в значительной степени зависит от свойств дробимой руды, поскольку данный процесс выполняет две функции: дробление и транспортирование руды. Поэтому при проектировании ГОКов дробильное оборудование выбирают с большим запасом по производительности, что обеспечивает хорошие условия для согласования процессов дробления и измельчения без необходимости достижения максимально возможной производительности процесса дробления. Выбор целью управления снижение энергозатрат процесса дробления является нерациональным, поскольку они значительно ниже энергозатрат процесса измельчения [1, 2, 5-7].

Управление процессом ККД осуществляют по заданному $\Gamma_{вых}^{зад}$ гранулометрическому составу продукта дробления [12, 27]:

$$\left\| \Gamma_{вых} - \Gamma_{вых}^{зад} \right\| \rightarrow \min \quad (1.1)$$

при ограничениях на допустимые мощность $P_{др} \leq P_{др\max}$ и производительность $Q_{др} \geq Q_{др\min}$. При этом, заданный гранулометрический состав $\Gamma_{вых}^{зад}$ отвечает максимальной производительности по входной руде следующего в технологической линии процесса МСИ.

Управление процессом МСИ можно осуществлять, например, с целью максимизации производительности по готовому классу:

$$Q_{гот} \rightarrow \max \quad (1.2)$$

при ограничениях на допустимую мощность $P_m \leq P_{m\max}$. Эта цель управления отвечает минимизации эксплуатационных затрат технологической линии обогащения [3, 10, 12-14, 26, 27].

Целями управления процессом МСИ также могут быть [13]:

- обеспечение требуемого качества (гранулометрического состава продукта измельчения) $\Gamma_m = \Gamma_m^{зад}$ при ограничениях на производительность цикла по входной руде $Q_p \geq Q_p^{don}$;

- минимизация энергозатрат (отношения допустимой мощности к производительности по готовому классу) $P_m/Q_{гот} \rightarrow \min$ при ограничениях на гранулометрический состав продукта измельчения $\Gamma_m \leq \Gamma_m^{зад}$.

Процессы дробления и измельчения являются сложными динамическими ОУ, модели которых имеют нестационарные параметры, нелинейные зависимости и стохастические переменные. Кроме того, процессы ККД и МСИ имеют значительные транспортные запаздывания и очень чувствительны к качеству руды [10-14, 15-17, 24-26, 28, 29].

В системах управления процессами дробления и измельчения [20, 21] используются модели идеального перемешивания, основанные на матричной модели Линча А.Дж. [24]. Уравнения первого порядка, описывающие кинетику в агрегатах, связывают продукт разрушения с питанием. Однако, эти модели не позволяют достаточно точно описать переходные режимы, так как не учитывают конструктивных особенностей дробилок и мельниц (профиль камеры разрушения, уровень материала в ней, частоту вращения и т.п.).

Развитием моделей [24] являются тактово-имитационная модель процесса дробления [30, 31], учитывающая конструктивные и технологические особенности конкретного дробильного аппарата, а также модели пространства состоя-

ний, описывающие динамику процессов дробления, измельчения и классификации.

Динамические свойства процесса ККД могут быть представлены передаточной функцией в виде апериодического звена первого порядка с запаздыванием (ПИТ) [10-14, 24]:

$$W = \frac{k_y \cdot e^{-\tau p}}{Tp + 1}, \quad (1.3)$$

где k_y – коэффициент усиления; τ – запаздывание; p – оператор Лапласа; T – постоянная времени.

Динамические свойства процесса ККД могут быть представлены нелинейным конечно-разностным уравнением [29, 32]:

$$\begin{aligned} \Gamma_{\text{вых}}^{m+1} = & a_0 + (a_1 + a_7 \cdot \Gamma_{\text{вх}}^m \cdot \rho^m) \cdot \Gamma_{\text{вых}}^m - a_2 \cdot \Gamma_{\text{вых}}^{m-1} + \\ & + a_3 \cdot g^{m+1} + a_4 \cdot \Gamma_{\text{вх}}^m + a_5 \cdot \rho^m + a_6 \cdot \Gamma_{\text{вх}}^m \cdot g^m \end{aligned}, \quad (1.4)$$

где m – такт времени; a_0, \dots, a_7 – коэффициенты; $\Gamma_{\text{вых}}$ – содержание класса +100 мм в дробленой руде; $\Gamma_{\text{вх}}$ – средневзвешенная крупность входной руды.

Динамическая структура ММС может быть представлена схемой, состоящей из последовательно соединенных линейной инерционной части и безинерционного нелинейного звена (ПИТ2) [10, 11, 26, 27]. Подобную динамическую структуру имеют также дробилки, сушильные барабаны и другие аппараты. На рис. 1.4. представлена модель измельчительных агрегатов (мельница-классификатор) в виде последовательно включенных линейного инерционного звена W_M и нелинейного безинерционного звена, линейного инерционного звена классификатора W_K , обратной связи по пескам $\Pi(t)$. Здесь $Q_M(t)$ и $Q_K(t)$ – производительности мельницы и в сливе классификатора, соответственно, а W_M и W_K – расходы воды в мельницу и классификатор в виде передаточных функций (1.3). Нелинейное инерционное звено для большинства технологических аппаратов описывают, например, с помощью уравнения параболы.




Рис. 1.4. Динамическая структура измельчительных агрегатов (мельница-классификатор) с замкнутым циклом

Динамическая модель, представленная на рис. 1.4. является блочно-ориентированной моделью Винера-Гаммерштейна (Wiener-Hammerstein) [33, 34]. Еще одним подходом к таким моделям являются модели Гаммерштейна [15] и Гаммерштейна-Винера [8].

Одним из примеров моделей процессов ККД и МСИ являются отображения Эно (Enon), описывающие движение частиц в условиях трения и импульсных воздействий (столкновений) [35-37]:

$$x_1[m+1] = 1 - cx_1^2[m] - bx_2[m]; \quad x_2[m+1] = x_1[m], \quad (1.5)$$

где c, b – параметры порядка ($\lambda = \{c, b\}$); x_1, x_2 – координаты; m – такт времени.

В зависимости от значений параметров порядка система может находиться в режиме равновесия, периодическом и квазипериодическом режимах, а также в режиме хаоса. Причем параметр c характеризует пространственное распределение взаимодействия (столкновений) частиц, а параметр b – затухание в системе.

Процессы ККД и МСИ также могут быть представлены с помощью нелинейных диссипативных осцилляторов с силовым или параметрическим возбуждениями, которые в пространстве параметров также имеют периодические и хаотические режимы [35, 38]:

$$\ddot{x} + K_t \dot{x} + f(x) = A \sin \omega t; \quad (1.6)$$

$$\ddot{x} + K_t \dot{x} + (1 + A \sin \omega t) f(x) = 0, \quad (1.7)$$

где K_t – коэффициент трения; $f(x)$ – возвращающая сила; A – амплитуда возбуждения; ω – частота возбуждения.

В исследованиях [39, 40] процессы, происходящие в ММС, представлены в виде упрощенных моделей осцилляторов (1.6)-(1.7), в которых возвращающая сила представлена в виде линейной функции [41]:

$$\frac{d^2 x}{dt^2} + (a - 2q \cos 2t)x = 0, \quad (1.8)$$

где a и q – постоянные; x – функция с периодом π .

В зависимости от значений параметров a и q , уравнение Матье (1.8) может быть как устойчивым, так и неустойчивым, что отображается на диаграмме Айнса-Стретта. Выполненные исследования позволили рассмотреть устойчивые параметрические резонансы внутримельничного заполнения и обосновать эффективные технологические режимы и способы управления процессом измельчения.

Динамические режимы работы КД и ММС изменяются при изменении технологических параметров, например, в ММС при изменении крепости и

гранулометрического состава входной руды, заполнения и соотношения твердое/жидкое в мельнице.

Следует также отметить, что процессы крупного дробления и самоизмельчения руд являются мультифрактальными, то есть подобны на разных масштабах крупности [42-44].

Сигналы, порождаемые процессами ККД и МСИ, представляют собой полигармонические и полосовые авторегрессионные сигналы с нормальной функцией распределения [10, 11, 25, 29, 45].

1.3. Анализ методов идентификации процессов дробления и измельчения

Рассмотрим существующие методы и алгоритмы идентификации процессов дробления и измельчения, а также способы использования моделей для целей управления этими процессами.

В работе [16] разработан алгоритм адаптации процессов измельчения-классификации руд, который предусматривает предварительную идентификацию статических и динамических характеристик ОУ с последующей коррекцией параметров регулятора в соответствии с полученными оценками. При этом, повышение помехозащищенности результатов коррекции осуществляется за счет фильтрации контролируемого сигнала, которая построена на использовании многочленов Чебышева и цифрового фильтра Калмана. К тому же, фильтр Калмана дает прогнозирующие свойства разработанной модели.

Повышение эффективности управления в таких САУ достигается за счет предложенных технических способов ультразвукового контроля концентрации и плотности частиц твердой фазы пульпы, содержания контрольного класса крупности измельченного материала в потоке пульпы, степени раскрытия полезного компонента при измельчении руд, количественных характеристик рудо- и пульпопотоков.

Однако, в таких системах используется только параметрическая, и не предусмотрено выполнение структурной идентификации.

В работе [46] предложена адаптивная СУ процессом магнитной сепарации руд на базе способов ультразвукового контроля. В качестве базисных функций использовались системы с нечеткой логикой, что позволило повысить эффективность систем управления инерционными объектами с запаздыванием в случае нечеткой и неполной информации об объекте и неконтролируемых возмущений. При этом управляющие влияния формируются на базе измеренных значений регулируемой координаты через промежутки времени между шагами исполнительного механизма, согласно текущим значениям статических и динамических характеристик объекта, которые определяются как нечеткие множества, степень принадлежности к которым задается предикатами отношений.

Таким образом, применение нечеткой логики позволило решить проблему помехоустойчивости и прогнозирования. Однако проблемы обоснования типа идентификации и выбора структуры модели остались нерешенными.

В работе [47] предложен способ активной идентификации нелинейных динамических объектов, позволяющий определять не только параметры, но и структуру математической модели БМ по каналу «степень заполнения барабана – интенсивность колебаний внутримельничной нагрузки».

БМ по каналу «подача исходного материала Q – степень заполнения φ – интенсивность колебаний A » упрощенно можно представить в виде соединения инерционных линейных звеньев W_1 и W_2 и нелинейного безинерционного, расположенного между ними (рис. 1.5). Задача идентификации при этом состоит в определении нелинейной характеристики $A = f(\varphi)$ и оценке параметров W_1 .




Рис. 1.5. Структура барабанной мельницы

Данная модель БМ является блочно-ориентированной моделью Винера-Гаммерштейна. Однако, в отличие от модели, предложенной на рис. 1.4, где мельница-классификатор являются ОУ, в данном случае ОУ – это только мельница.

Преимуществом такого способа идентификации является существенное повышение оперативности отбора информации об объекте, что для инерционных ОУ с возмущениями имеет существенное значение.

Недостатками такого подхода также является отсутствие обоснования структуры ОУ и невозможность ее изменения при вариации режимов работы БМ.

Математическая модель КД, предложенная в [29-31], синтезируется на основе допущения Эпстайна о разделении процесса дробления на два субпроцесса, и принятого в известной модели дробления предположения о том, что камера дробилки может быть представлена в виде расположенных друг под другом элементарных камер.

Это допущение использовал также А.Дж. Линч [24] в своих матричных моделях, связывая продукт дробления с питанием:

$$\bar{p} = (1 - C)(1 - BC)^{-1} \cdot \bar{f}, \quad (1.9)$$

где B – матрица разрушения; C – матрица отбора; \bar{f} и \bar{p} – векторы-столбцы, характеризующие массовые расходы каждого выделенного класса крупности, и представляющие собой кусочно-линейные аппроксимации кривых распределения.

Структура модели процесса дробления в КД, предложенная проф. Качаном Ю.Г., представлена на рис. 1.6. Поток материала на выходе j -й элементарной камеры на i -м такте и продукт дробления в ней на том же такте определяются с помощью матричных соотношений:

$$\bar{p}_{ji} = (I - C_j)\bar{x}_{ji}, \quad (1.10)$$

$$\bar{y}_{ji} = B_j C_j \bar{x}_{ji}. \quad (1.11)$$

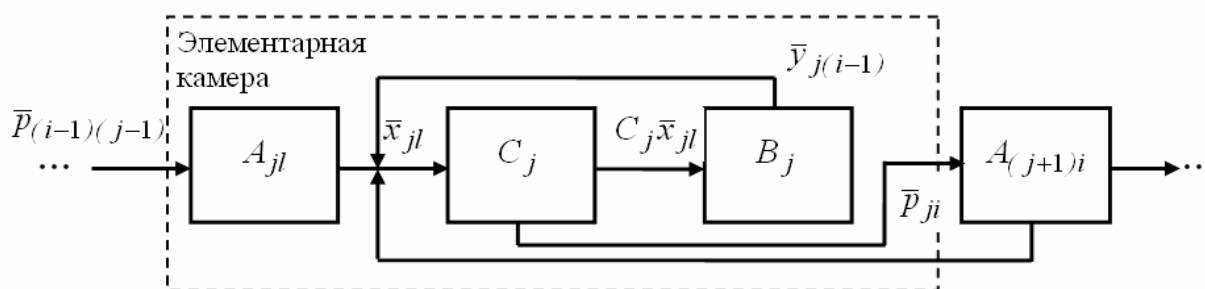


Рис. 1.6. Структура конусной гирационной дробилки

Параметрическая идентификация полученной тактово-имитационной модели КД выполнялась локальным методом скользящего допуска, имеющего осцилляции решений относительно границы области допустимых значений.

Выполненная идентификация КД с позиций управления с помощью МГУА для получения статической и динамической моделей [29] оказалась недостаточно эффективной (качество системы автоматической оптимизации, использующей эти модели, повысилось незначительно).

Другим направлением реализации управления процессов ККД и другими ОУ обогащения, предложенным в [48], является использование математической модели процесса в виде логической суммы предикатных уравнений, которые однозначно определяют подобласти пространства состояний ОУ. При этом идентификация параметров такой логико-предикатной модели основывается на методах распознавания образов, а синтез управления осуществляется с помощью алгоритмов статической оптимизации.

Недостатком такого подхода является статическое управление, что предполагает потери в динамических режимах.

В работах [17, 19] для идентификации технологического процесса обогащения железной руды предложена искусственная нейронная сеть, которую можно применять при идентификации в составе интеллектуальной системы управления. Однако, недостатком такого подхода является отсутствие структурной идентификации объектов управления.

В работе [49] предложена модель пятиуровневого представления информации о координатах процесса, что позволяет повысить информативность обучающей выборки данных и обрабатывать аварийные ситуации «зависания» данных путем фильтрации возмущенной исходной координаты. При этом, анализ структуры предложенной модели показывает, что она представляет собой

общее неоднородное диофантовое уравнение второго порядка с двумя неизвестными.

Недостатками предложенного подхода идентификации является использование метода наименьших квадратов, который требует независимости входных переменных. Кроме того, задача нахождения оптимальной структуры модели ОУ для конкретного режима работы ОУ не рассматривается.

В работе [15] предложен метод идентификации технологических процессов обогащения руд на основе моделей Гаммерштейна.

Для идентификации и управления в условиях неполной и нечеткой информации объекты магнитного обогащения железных руд аппроксимировались гибридными моделями структуры Гаммерштейна, в которых нелинейный блок представлен нечеткой моделью типа Такаги-Сугэно и последовательно объединен с динамическим блоком, построенным на основе авторегрессионных уравнений. Это позволило учесть информацию разных математических классов для осуществления адекватной структурно-параметрической идентификации.

Также для управления нелинейными динамическими объектами обогатительных производств предложены ортогональные модели структуры Гаммерштейна, в которых нелинейность аппроксимирована тремя функциями Эрмита, что позволило повысить точность идентификации ОУ.

Несомненным достоинством такого подхода является исследование разных типов моделей структуры Гаммерштейна для идентификации объектов обогатительных производств посредством аналитических методов и метода имитационного моделирования.

При этом, недостатком является отсутствие обоснования выбора типа структуры в виде блочно-ориентированной модели Гаммерштейна.

В композиционном методе идентификации процессов ККД и МСИ, предложенном в [8], выполняется идентификация данных процессов в реальном режиме времени, что позволило получить их динамические интеллектуальные прогнозирующие модели, учитывающие размерность порождающих процессов.

Однако, при данном подходе не обоснован выбор типа структуры моделей процессов ККД и МСИ в виде модели Винера-Гаммерштейна. Кроме того, рассмотрено ограниченное количество методов глобальной и локальной оптимизаций моделей (причем, методы локальной оптимизации ограничены выбором базисных функций). Это не позволяет выявить преимущества алгоритмов друг перед другом, а также сужает поиск оптимальных структурных характеристик и параметров модели исследуемых процессов. Исходя из этого, можно предполагать, что композиционный метод идентификации процессов ККД и МСИ руд имеет недостаточную точность вследствие неоптимальности структур интеллектуальных прогнозирующих моделей этих процессов для конкретных режимов работы оборудования.

1.4. Анализ методов идентификации сложных объектов управления

В качестве методов идентификации сложных объектов управления большее распространение получили интеллектуальные методы.

Алгоритмы метода группового учета аргументов (МГУА) реализуют принцип самоорганизации моделей и воспроизводят схему массовой селекции [50-53]. МГУА фактически является методом поиска закономерностей с автоматическим выбором структуры и параметров модели, то есть реализует как параметрическую, так и структурную идентификацию, что является его основным преимуществом. Метод эффективен в условиях малого объема экспериментальных данных и высокого уровня шумов [54].

Недостатком МГУА является то, что принцип свободы выбора, который реализуется при определении параметров метода, приводит к его неадекватному применению.

Алгоритм МГУА относят к эволюционным алгоритмам (ЭА), общим для которых является то, что они моделируют процесс биологической эволюции: мутации структуры и параметров, их скрещивание (размножение) и правило отбора. Это позволяет обнаруживать их благоприятные вариации, с помощью которых строится последовательность улучшенных решений [55-60].

ЭА (последовательный перебор и случайный поиск) являются методами глобальной оптимизации, которые целесообразно использовать при структурной идентификации сложных ОУ с различными динамическими режимами [10].

Среди ЭА наибольшее распространение получили генетические алгоритмы (ГА) [60-62], представляющие собой адаптивные методы поиска, основанные на механизмах естественного отбора и наследования на уровне генов. В них используется эволюционный принцип выживания наиболее приспособленных особей (генов): размножение наиболее адаптированных к внешней среде генов, а также производство генов с характеристиками, которые отсутствовали у генов предыдущих поколений. При этом, основными операторами ГА являются кроссинговер, мутация, выбор родителей и селекция.

К преимуществам ГА относят способность нахождения глобального экстремума, высокое быстродействие при многопроцессорной обработке и производительность. К недостаткам – потребность в большом объеме памяти и относительно низкое быстродействие на фон-неймановских ЭВМ.

Для параметрической идентификации важным является вопрос выбора типа базисных функций. В МГУА, например, в качестве базисных функций используются, как правило, полиномы Колмогорова-Габора. Развитием полиномиального представления функций являются нейронные сети (НС) – вычислительные структуры, моделирующие процессы мозга и состоящие из множества одинаковых элементов – искусственных нейронов [63-68].

Обоснованием эффективности использования НС является доказательство возможности представления функции нескольких переменных через суперпозицию функций одного переменного, а также операций их сложения и умножения. Кроме того, для НС было доказано, что при нелинейной функции активации нейронов можно так построить сеть связей и подобрать коэффициенты w , чтобы НС как угодно точно вычисляла любую непрерывную функцию Y от своих входов X (рис. 1.7). Таким образом, НС являются универсальными и эффективными аппроксиматорами.

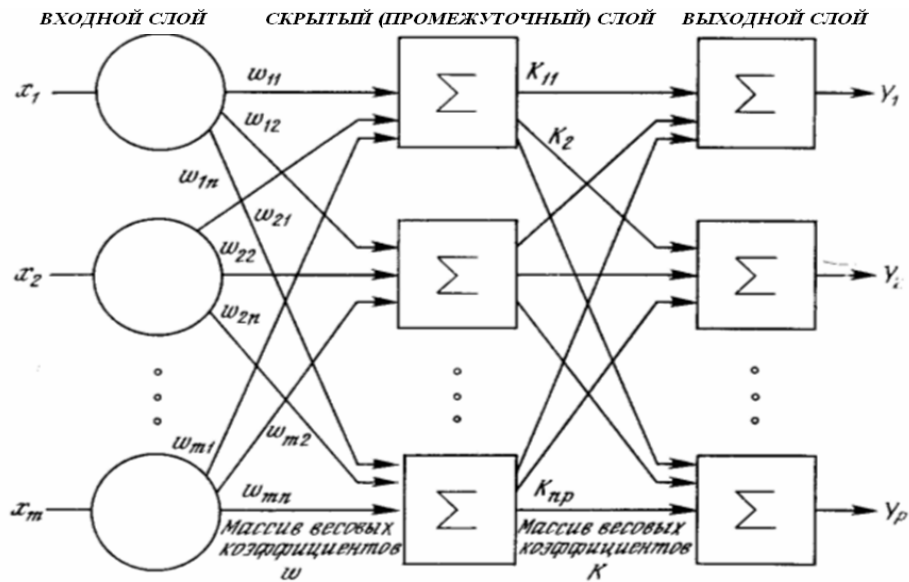


Рис. 1.7. Двухслойная нейронная сеть прямого распространения

Архитектура НС зависит от конкретной решаемой задачи и характеризуется количеством слоев НС, количеством нейронов в каждом слое и их функциями активации, алгоритмами обучения сети и т.д. Архитектура многослойной НС прямого распространения (НСПР) состоит из последовательно соединенных слоев, где нейрон каждого слоя своими входами связан со всеми нейронами предыдущего слоя, а выходами – следующего (см. рис. 1.7).

Обучаются многослойные НС с помощью алгоритма обратного распространения ошибки, который является разновидностью градиентного спуска в пространстве весов с целью минимизации суммарной ошибки сети.

НС с радиальными базисными функциями (РБФ) – это двухслойная сеть без обратных связей [63, 69], которая содержит скрытый (шаблонный) слой радиально симметричных нейронов и выходной линейный слой (рис. 1.8).




Рис. 1.8. Нейронная сеть с радиальными базисными функциями

Обучение НС с РБФ происходит в два этапа. На первом этапе определяются центры и отклонения для радиальных элементов, на втором – оптимизируются параметры линейного выходного слоя.

Преимуществом сетей с РБФ является то, что они моделируют произвольную нелинейную функцию с помощью всего одного промежуточного слоя, тем самым, снимая проблему выбора числа слоев. Кроме того, параметры линейной комбинации в выходном слое можно оптимизировать с помощью методов линейной оптимизации, которые быстро сходятся. К недостаткам следует отнести плохие экстраполирующие свойства сети.

Наряду с НС широкое распространение также получили системы с нечеткой логикой, которые позволяют построить модель объекта, основываясь на нечетких рассуждениях и правилах [63, 70-72].

Для устранения недостатков НС и систем с нечеткой логикой предложены гибридные НС, вариантом которых является адаптивная нейронная система нечеткого вывода (Anfis – Adaptive neuro-fuzzy inference system), реализующая систему нечеткого вывода Сугено в виде пятислойной НСПР сигнала (рис. 1.9).




Рис.1.9. Структура гибридной нейронной системы нечеткого вывода

Назначения слоев следующие: слой 1 – термы входных переменных (x); слой 2 – antecedentes (посылки) нечетких правил; слой 3 – нормализация степеней выполнения правил; слой 4 – заключения правил; слой 5 – агрегирование результата (y), полученного по различным правилам.

Обучение гибридной сети проводится или с помощью алгоритма обратного распространения ошибки, или комбинированным методом, разработанным для гибридных сетей.

1.5. Выводы и постановка задачи

Обобщая вышеизложенное можно сделать следующие выводы:

1. Рудоподготовка включает технологические процессы дробления и измельчения, затраты на которые составляют больше половины себестоимости

горно-обогатительного производства. Поэтому актуальным является проведение исследований с целью снижения затрат на эти процессы путем создания систем автоматизированного управления ними.

2. Для автоматического управления процессами дробления и измельчения наиболее эффективными являются адаптивные системы, в которых стратегия управления основана на включении математической модели в контур управления и прогнозе по ней в режиме реального времени результатов процесса.

3. Процессы ККД и МСИ с позиций управления являются сложными динамическими объектами, модели которых имеют нестационарные параметры, нелинейные зависимости и стохастичные переменные. Эти процессы имеют различные режимы работы (переменную структуру), значительные транспортные запаздывания и чувствительны к качеству руды.

4. Анализ методов и алгоритмов идентификации технологических процессов рудоподготовки показал, что развитие получили параметрические методы идентификации ОУ. При этом, выбор структур этих моделей, как правило, осуществляется эвристически. Проведение структурно-параметрической идентификации ОУ было ориентировано на использование определенной структуры моделей, что при изменении режимов работы оборудования приводит к увеличению ошибок идентификации.

5. Для идентификации процессов ККД и МСИ перспективными являются методы систем искусственного интеллекта, в частности нейронные сети и системы с нечеткой логикой, которые являются универсальными и эффективными аппроксиматорами.

Таким образом, нерешенной актуальной научной задачей является снижение ошибок идентификации процессов крупного дробления и самоизмельчения руд путем вариации структур их интеллектуальных прогнозирующих моделей в условиях изменения динамических режимов работы.

Для решения этой научной задачи необходимо:

- исследовать точность идентификации процессов крупного дробления и самоизмельчения руд при изменении их режимов работы;
- предложить метод идентификации процессов ККД и МСИ руд, который учитывает вариацию структур моделей и не приводит к существенному увеличению вычислительных затрат;
- разработать методику, алгоритмы и программное обеспечение для решения задач идентификации процессов крупного дробления и самоизмельчения руд;
- исследовать эффективность идентификации процессов ККД и МСИ руд в классе их интеллектуальных прогнозирующих моделей;
- выполнить оценку эффективности управления процессами рудоподготовки с использованием разработанных интеллектуальных прогнозирующих моделей.

РАЗДЕЛ 2

ОБОСНОВАНИЕ И ИССЛЕДОВАНИЕ КОМПЛЕКСНОГО МЕТОДА ИДЕНТИФИКАЦИИ НЕЛИНЕЙНЫХ ДИНАМИЧЕСКИХ ПРОЦЕССОВ РУДОПОДГОТОВКИ

2.1. Задача структурно-параметрической идентификации

Сформулируем задачу идентификации ОУ следующим образом. На основании экспериментально полученных множеств функций (временных рядов) возмущений, управлений и выходов в условиях помех определить структуру (обобщенную функцию Φ) (структурная идентификация) и вектор параметров a (параметрическая идентификация) модели [73]:

$$\hat{Y}[m+n] = \Phi\{Y[m], \xi[m], a[m], m\}, m = \overline{1, M} \quad (2.1)$$

которая достаточно точно (в смысле некоторого критерия) аппроксимирует ОУ в отношении входных и выходных величин во всем функциональном пространстве. Здесь $Y[m]$ – вектор (матрица) состояния процесса; $\xi[m]$ – вектор (матрица) помех; m – текущий такт времени ($m = t/T$); t – непрерывное время; T – период дискретизации; M – время наблюдения; n – глубина прогноза.

Установлено, что для решения задач идентификации технологических процессов рудоподготовки целесообразно применять методы интеллектуальной обработки информации [73].

2.1.1. Параметрическая идентификация.

В прямых методах параметрической идентификации неизвестные параметры a модели (2.1) определяются на основе решения системы уравнений, получаемых путем подстановки в модель (2.1) последовательностей экспериментальных значений входных и выходных величин ОУ [73].

При использовании в качестве прогнозирующей модели ОУ рекуррентной гибридной или четкой НС для решения задачи параметрической идентификации (обучения) широко используется, например, градиентный метод обратного распространения ошибки [63, 65]. Процесс обучения при этом (рис. 2.1) заключается в подстройке параметров НС по величине ошибки между откликом модели и требуемым по экспериментальным исходным данным (ИД) выходом.

Такая идентификация предполагает известным структуру модели (или же диапазона ее рациональных значений), то есть требует выполнения значительных объемов предварительных исследований ОУ.

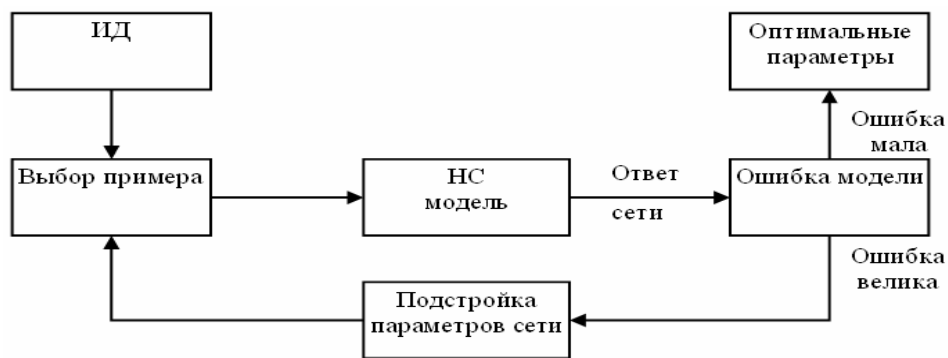


Рис. 2.1. Процесс параметрической идентификации (обучения) НС

2.1.2. Структурно-параметрическая идентификация.

Процесс структурно-параметрической идентификации (рис. 2.2) включает определение структуры, оценку и оптимизацию параметров модели ОУ (2.1). Первые две операции выполняются путем генерирования (с помощью базисных функций) моделей-претендентов различной сложности и настройки их параметров с последующей селекцией лучших из них по выбранным критериям. Результат – оптимальная структура модели ОУ. Операция определения оптимальных параметров решается известными методами оптимизации путем уточнения полученных ранее значений параметров по критериям параметрической оптимизации на всей выборке ИД [73].



Рис. 2.2. Процесс структурно-параметрической идентификации

При структурной идентификации актуальными проблемами являются выбор базисных функций, в терминах которых осуществляется идентификация, а также выбор эффективного для конкретного случая критерия селекции.

Методы глобальной оптимизации позволяют решить структурно-параметрическую идентификацию ОУ в виде НС, как единого набора характеристик (параметров). Использование комбинации методов глобальной и локальной оптимизации для задач структурно-параметрической идентификации ОУ, например НС и ГА, представляется наиболее перспективным.

При этом, открытым является вопрос целесообразности проведения параметрической или структурно-параметрической идентификации для конкретного ОУ.

2.2. Исследования режимов работы технологических процессов дробления и измельчения руд

Особенностью нелинейных процессов дробления и измельчения руд является наличие в них различных динамических режимов работы. Это обуславливает необходимость решения задачи идентификации управляемых процессов не только на стадии проектирования их АСУ ТП, но и в процессе функционирования этих систем [9, 74].

Нелинейный процесс (динамическая система) описывается с помощью векторного уравнения потока [9]:

$$\dot{x} = F(x, \lambda), \quad (2.2)$$

или дискретного отображения Пуанкаре:

$$x[m+1] = F\{x[m], \lambda\}; \quad x[m] = \{x_1[m], \dots, x_{d-1}[m]\}, \quad (2.3)$$

где F – нелинейная вектор-функция размерности d ; x – вектор координат; λ – вектор параметров порядка системы; m – такт времени ($t = m \cdot T$); T – период дискретизации.

Динамические системы (2.2)-(2.3) имеют в зависимости от значений параметров порядка λ четыре типа решения [35-37, 74]: равновесие, когда после переходного процесса система достигает стационарного состояния, периодическое и квазипериодическое решения, а также хаос. Этим решениям соответствуют аттракторы системы в виде устойчивого равновесия, предельного цикла, квазипериодического и хаотического (странного) аттрактора.

Система (2.2)-(2.3) при изменении параметра λ теряет устойчивость своего состояния (режима функционирования) и переходит в другое, отличное от первого, состояние. Этот переход называют бифуркацией, а значения параметров, при котором оно происходит – точкой бифуркации [36].

Такой формальный подход хорошо согласуется с результатами теоретических и экспериментальных исследований процессов крупного дробления и самоизмельчения руд, как нелинейных динамических ОУ с переменными структурой (размерностью, режимом динамики) и параметрами, которые зависят от свойств руды, конструктивных и технологических переменных [74].

Процессы крупного дробления и самоизмельчения руд могут быть представлены с помощью отображения Эно (1.5). Очевидно, что для разрушения материалов наилучшим является хаотический режим, так как в нем из-за экспоненциального разбегания все частицы взаимодействуют со всеми, что соответствует минимуму подводимой внешней энергии [74].

Идентификация таких сложных ОУ традиционными способами требует больших затрат на экспериментальные исследования, поэтому целесообразно использовать методы нелинейной динамики.

В работах [8, 75, 76] предложена методика идентификации нелинейных процессов рудоподготовки, которая включает определение характеристик состояния данных процессов и их структурно-параметрическую идентификацию. Эта методика позволяет в реальном режиме времени определять режим функционирования динамической системы, ее размерность, а затем определять структуру и параметры модели ОУ.

Вместе с тем, в этих работах отсутствуют исследования идентификации различных режимов работы ОУ и не определены критерии перехода от процедуры определения характеристик состояния ОУ к процедуре его структурно-параметрической идентификации.

2.2.1. Идентификация режимов работы нелинейных процессов дробления и измельчения руд.

Модель сложного ОУ, которая правильно передает динамику одного его режима функционирования, может быть неадекватной к описанию другого его режима. Проведем исследования точности идентификации различных режимов работы процессов крупного дробления и самоизмельчения руд на основе их модели в виде структуры Гаммерштейна-Винера [33, 34] с нелинейным звеном в виде отображения Эно и линейным апериодическим звеном первого порядка с запаздыванием. При этом из особенностей этих процессов глубина прогноза принята в 1 такт, а глубина памяти по входам – 3 такта.

Моделирование выполнялось с помощью разработанной программы в среде Matlab.

На первом этапе исследований [9, 74] выполнялась структурно-параметрическая идентификация одного из режимов функционирования ОУ: периодического (режим 2), квазипериодического (режим 3) и хаоса (режим 4). При этом режим 1 – режим равновесия. В качестве базисной функции использовалась каскадная НСПР [63, 65, 69].


На втором этапе для оптимальной структуры одного режима выполнялась параметрическая адаптация модели во всех режимах функционирования.

За меру точности прогноза выхода модели использовался критерий минимума относительной среднеквадратической ошибки, результаты расчета которого приведены на рис. 2.3 и в табл. 2.1. При этом в табл. 2.1 введены следующие обозначения: $\varepsilon_1 - \varepsilon_4$ – ошибки в режимах 1-4, $\bar{\varepsilon}$ – средняя ошибка модели.


Таблица 2.1

Ошибка моделей по режимам идентификации


Идентифицированный режим	Ошибка по режимам				Средняя ошибка $\bar{\varepsilon}$ (%)
	ε_1 (%)	ε_2 (%)	ε_3 (%)	ε_4 (%)	
Режим 2	13,09	8,96	10,59	29,00	15,69
Режим 3	11,73	8,28	5,65	24,65	12,44
Режим 4	10,13	14,83	13,49	9,78	12,07



a



б



в

Рис. 2.3. Изменение ошибки модели ОУ по режимам его функционирования при его идентификации в режимах 2 (*a*), 3 (*б*) и 4 (*в*)

Из рис. 2.3 и табл. 2.1 видно, что в режиме, для которого была определена оптимальная структура модели, ошибка существенно меньше, чем в других режимах, и меньше допустимой для рядовых массовых опробований в обогащении (10% [10]).

В результате моделирования установлено, что при идентификации в режимах 2 и 4 (рис. 2.3 *а* и *в*) ошибка только для идентифицированного режима меньше допустимой. При идентификации в режиме 3 (рис. 2.3 *б*) значения ошибок меньше допустимой не только в обученном режиме, но и в режиме 2.

Таким образом, в каком бы режиме не проводилась идентификация, ошибка в других режимах, как правило, больше допустимой. То есть, оптимальная структура модели для одного режима функционирования ОУ не является таковой для других режимов и ее точность, как правило, превышает допустимую точность. Тогда при изменении динамических режимов работы ОУ необходимо проводить его структурно-параметрическую идентификацию.

При этом открытым остается вопрос о времени ее проведения. Использование структурно-параметрической идентификации в реальном режиме времени не целесообразно, поскольку режимы работы изменяются нечасто, да и время ее проведения составляет несколько часов. Поэтому необходимо определить критерий (условия) перехода к структурно-параметрической идентификации, который будет характеризовать закономерности в изменении состоянии системы.

В этом случае использование только значений минимума относительной среднеквадратической ошибки недостаточно, поскольку по ее величине можно судить лишь о том, что точность модели ниже допустимой (например, из-за того, что режим работы ОУ уже изменился).

2.2.2. Идентификация состояния стохастических динамических процессов дробления и измельчения.

Основной проблемой определения состояния процессов дробления и измельчения является неопределенность их будущего поведения. Поскольку данные процессы являются мультифрактальными, то есть подобными на разных масштабах крупности, то определение тенденции к изменению их режимов функционирования описывает показатель Херста H [42, 77]. Показатель Херста H характеризует отношение уровня тренда (детерминированного фактора) к уровню шума (случайному фактору):

$$R(\tau) = \frac{R_0(\tau)}{S(\tau)} = (\alpha \cdot \tau)^H, \quad (2.4)$$

где $R_0(\tau)$ – разность максимального и минимального значений (размах) процесса $y(t)$ на интервале времени τ :

$$R_0(\tau) = \max_{1 \leq t \leq \tau} y(t, \tau) - \min_{1 \leq t \leq \tau} y(t, \tau), \quad (2.5)$$

а $S(\tau)$ – среднеквадратическое отклонение приращений случайного процесса на интервале τ :

$$S(\tau) = \sqrt{\frac{1}{\tau} \sum_{t=1}^{\tau} [\Delta y(t) - \bar{y}(\tau)]^2} \quad (2.6)$$

и $\Delta y(t)$ – элементарное приращение $y(t)$ на шаге t : $y(\tau) = \sum_{t=1}^{\tau} \Delta y(t)$; α – коэффициент пропорциональности.

Значение показателя Херста $H > 0,5$ характеризует сохранение имеющейся тенденции развития процесса [74]: если некоторое время τ наблюдался в среднем рост отклонений вектора состояний, то и впредь в среднем сохранится тенденция к их увеличению. Аналогично сохраняется тенденция к уменьшению. Эта ситуация соответствует уходу из одного режима функционирования ОУ и переходу его в другой режим. При этом возникает необходимость определения структуры модели (проведения структурно-параметрической идентификации ОУ [163]).

При $H < 0,5$ рост значений вектора состояний процесса в прошлом означает их вероятное уменьшение в будущем, а тенденция к уменьшению отклонений в прошлом делает вероятным их увеличение в будущем [74]. Этому свойству можно поставить в соответствие свойство «стабилизированности», то есть ОУ работает в одном режиме функционирования, структура его модели не меняется, и нет необходимости выполнять структурно-параметрическую идентификацию ОУ.

При $H < 0,5$ рост значений вектора состояний процесса в прошлом означает их вероятное уменьшение в будущем, а тенденция к уменьшению отклонений в прошлом делает вероятным их увеличение в будущем [74]. Этому свойству можно поставить в соответствие свойство «стабилизированности», то есть ОУ работает в одном режиме функционирования, структура его модели не меняется, и нет необходимости выполнять структурно-параметрическую идентификацию ОУ.

Таким образом, задача идентификации состояния стохастических процессов может быть сформулирована как задача определения показателя Херста. Алгоритм вычисления показателя Херста имеет следующий вид [77]:

1) вычисление среднего значения временного ряда:

$$\bar{y}(\tau) = \frac{1}{\tau} \sum_{t=1}^{\tau} \Delta y(t) \quad \text{или} \quad \bar{y}(\tau) = \frac{y(\tau)}{\tau}; \quad (2.7)$$

2) вычисление накопившегося отклонения ряда измерений $\Delta y(t)$ от среднего $\bar{y}(\tau)$:

$$y(t, \tau) = \sum_{i=1}^t (\Delta y(i) - \bar{y}(\tau)); \quad (2.8)$$

3) определение размаха процесса $R_0(\tau)$ (2.5);

4) определение отклонения $S(\tau)$ (2.6);

5) по текущим значениям $R_0(\tau)$ и $S(\tau)$ вычисление размаха $R(\tau)$ (2.4);

Полученные значения логарифмируются:

$$\ln \frac{R_0(\tau)}{S(\tau)} = H \ln(\alpha\tau) = H[\ln(\tau) + \ln(\alpha)], \quad (2.9)$$

после чего, используя замену $\ln(\tau) = \varphi$, массив аппроксимируется линейной зависимостью $f(\varphi) = \hat{H} \cdot \varphi + q$, дающей искомую оценку показателя Херста \hat{H} , где q – константа.

Моделирование идентификации состояния стохастических процессов проводилось с помощью стандартных [79] программ. В качестве идентифицируемых процессов использовались временные реализации содержания класса +100 мм в крупнодробленой руде Γ_{+100}^1 и Γ_{+100}^2 , полученные в условиях Ингулецкого ГОКа в различные периоды работы фабрики.

В результате расчетов определены значения показателя Херста для сигналов Γ_{+100}^1 и Γ_{+100}^2 (рис. 2.4): $H_1 = 0,2639 \pm 0,1879$ и $H_2 = 0,7604 \pm 0,1865$, а также значения их фрактальной размерности: $D_1 = 2 - H_1 = 1,7361 \pm 0,1879$ и $D_2 = 2 - H_2 = 1,2396 \pm 0,1865$.





Рис. 2.4 Результаты расчета параметра Херста для сигналов Γ_{+100}^1 (*a*) и Γ_{+100}^2 (*б*)

Показатель Херста сигнала Γ_{+100}^1 составил: $H_1 < 0,5$, а это определяет, что порождающая система (процесс крупнокускового дробления) работает в одном режиме функционирования, и нет необходимости выполнять ее структурно-параметрическую идентификацию. Параметр Херста сигнала $\Gamma_{+100}^2 - H_2 > 0,5$, то есть процесс крупнокускового дробления имеет тенденцию к уходу из текущего режима функционирования и, соответственно, необходимо планировать выполнение его структурно-параметрической идентификации.

2.3. Комплексный метод идентификации нелинейных динамических процессов дробления и измельчения руд

2.3.1. Определение характеристик состояния ОУ.

Рассмотрим динамические системы (2.2)-(2.3), описанные в пункте 2.2.

В работах [36, 37] показано, что по одной временной реализации можно определить: корреляционную размерность аттрактора, которая характеризует нижнюю границу фрактальной размерности Хаусдорфа [35], а также корреляционную энтропию (нижнюю границу энтропии Колмогорова [37]), которая характеризует насколько хаотичен сигнал.

Корреляционная размерность аттрактора характеризует сложность аттрактора динамической системы [80], то есть позволяет дать ответ на вопрос, какое минимальное количество отсчетов (глубину памяти) переменных должна включать соответствующая математическая модель (в виде оценки этой величины снизу). Корреляционная размерность – одна из фундаментальных характеристик аттрактора.

Расстояние между ближайшими точками аттрактора до и после бифуркаций находится в универсальном отношении [35]. Самоподобие такого явления описывает фрактальная размерность Хаусдорфа D , которая является числом, характеризующим скорость роста числа ячеек покрытия данного множества при уменьшении размера ячеек:

$$D = - \lim_{\sigma \rightarrow 0} \frac{\log N(\sigma)}{\log(\sigma)}, \quad (2.10)$$

где σ – размер ячейки; $N(\sigma)$ – количество ячеек. При этом, основание логарифма произвольное.

Оценку снизу размерности Хаусдорфа D_{ng} можно получить непосредственно из измерений в соответствии с теоремой Такенса [37], которая утверждает, что размерность D_{ng} можно восстановить по измерениям лишь одной реализации (наблюдаемой).

Рассмотрим траекторию $x(t) = [x_1(t), \dots, x_d(t)]$ динамической системы на странном аттракторе и предположим, что d -мерное фазовое пространство раз-

делено на ячейки размера σ^d . Преобразуем траекторию в последовательность точек $x(t=0)$, $x(t=\Delta t)$, ... $x(t+m\Delta t)$. Вероятность попадания точки, принадлежащей аттрактору, в i -ю ячейку ($i=1, 2, \dots, M(\sigma)$) вычисляется следующим образом:

$$p_i = \lim_{N \rightarrow \infty} \frac{N_i}{N}, \quad (2.11)$$

где N_i – число точек в этой ячейке $\{x(t = j(\Delta t))\}$.

Численная оценка размерности D_{ng} [37]:

$$D_{ng} = \lim_{\sigma \rightarrow 0} \frac{\log(\sum_{i=0}^{M(\sigma)} p_i^2)}{\log \sigma} = \lim_{\sigma \rightarrow 0} \frac{\log J(\sigma)}{\log \sigma} \quad (2.12)$$

определяется из корреляционного интеграла:

$$J(\sigma) = \lim_{N \rightarrow \infty} \frac{1}{N^2} \sum_{i,j} \varpi[\sigma - |x_i - x_j|], \quad (2.13)$$

где $\sum_{i=0}^{M(\sigma)} p_i^2$ – вероятность того, что две точки на аттракторе лежат внутри ячейки σ^d (вероятность того, что две точки аттрактора разделены расстоянием, меньшим σ); $\sum_{i,j} \varpi[\sigma - |x_i - x_j|]$ – число пар i и j , для которых расстояние

$|x_i - x_j| < \sigma$; ϖ – ступенчатая функция Хэвисайда: $\varpi(x) = \begin{cases} 0, & x < 0, \\ 1, & x \geq 0. \end{cases}$; $x_i = x[i\Delta t]$.

Для определения D_{ng} строят зависимость $\log J(\sigma)$ от $\log \sigma$ и ищут на ней линейный участок, наклон которого и определяет искомое значение корреляционной размерности D_{ng} , которое далее используется для определения размерности аттрактора.

Размерность странного аттрактора в общем случае дробная [81], что используется как характерный признак «странности» аттрактора.

Таким образом, вычисление размерности D_{ng} позволяет реконструировать аттрактор [36], а также определить размерность переменных математической модели ОУ.

Энтропия Колмогорова K описывает динамическое поведение на странном аттракторе и является важнейшей характеристикой хаотического движения в фазовом пространстве произвольной размерности, наряду с корреляционной размерностью [35, 37, 75].

Энтропия K пропорциональна скорости потери информации о состоянии динамической системы во времени и показывает насколько динамическая система хаотична. Колмогоровым было строго обосновано [82], что для регулярного движения K -энтропия равна нулю, для систем с детерминированным хаосом – положительна и постоянна. Энтропия K бесконечна в случае поведения системы как белого шума, что говорит об отсутствии предсказуемости процесса.

Предположим, что d -мерное фазовое пространство разделено на ячейки размера σ^d аналогично (2.11), а состояние системы измеряется через интервалы времени Δt . Пусть $P_{i_0 \dots i_m}$ – совместная вероятность того, что $x(t=0)$ находится в ячейке i_0 , $x(t=\Delta t)$ – в ячейке i_1 , ..., $x(t+m\Delta t)$ – в ячейке i_m . Тогда величина

$$K_m = - \sum_{i_0 \dots i_m} P_{i_0 \dots i_m} \ln P_{i_0 \dots i_m} \quad (2.14)$$

пропорциональна информации, необходимой для определения положения системы на заданной траектории $i_1 \dots i_m$ с точностью σ (если априори известны только вероятности $p_{i_0 \dots i_m}$). То есть, разность $K_{m+1} - K_m$ является дополнительной информацией, которая необходима для предсказания, в какой ячейке i_{m+1} будет система. Причем известно, что прежде система находилась в ячейках $i_1 \dots i_m$. Таким образом, величина $K_{m+1} - K_m$ на интервале времени от t до $t + \Delta t$ описывает потерю информации о системе.

K -энтропия определяется как средняя скорость потери информации о состоянии динамической системы [37]:

$$\begin{aligned} K &= - \lim_{\Delta t \rightarrow 0} \lim_{\sigma \rightarrow 0} \lim_{N \rightarrow \infty} \frac{1}{N\Delta t} \sum_{m=0}^{N-1} (K_{m+1} - K_m) = \\ &= - \lim_{\Delta t \rightarrow 0} \lim_{\sigma \rightarrow 0} \lim_{N \rightarrow \infty} \frac{1}{N\Delta t} \sum_{i_0 \dots i_N} P_{i_0 \dots i_N} \ln P_{i_0 \dots i_N}. \end{aligned} \quad (2.15)$$

Предел $\sigma \rightarrow 0$ (который берется после $N \rightarrow \infty$) делает величину K независимой от частного вида разбиения.

Непосредственный расчет K -энтропии не представляется возможным, поэтому на практике используются различные методы ее оценки. Одной из них является нижняя граница колмогоровской энтропии $K_{ng} < K$, которая равна:

$$K_{ng} = - \lim_{\sigma \rightarrow 0} \lim_{m \rightarrow \infty} \frac{1}{m} \ln \sum_{i_1 \dots i_m} P_{i_1 \dots i_m}^2. \quad (2.16)$$

Обобщая корреляционный интеграл (2.13):

$$J_m(\sigma) = \lim_{N \rightarrow \infty} \frac{1}{N^2} \sum_{i,j} \varpi[\sigma - \|x_i - x_j\|_m] = \sum_{i_1 \dots i_m} P_{i_1 \dots i_m}^2, \quad (2.17)$$

получим выражения для определения K_{ng} [78]:

$$K_{ng} = \lim_{\sigma \rightarrow 0} \lim_{m \rightarrow \infty} \ln \left[\frac{J_m(\sigma)}{J_{m+1}(\sigma)} \right] \leq K. \quad (2.18)$$

Обобщенный корреляционный интеграл $J_m(\sigma)$ вычисляется по измеренному сигналу (наблюдаемой) и значения $K_{ng} > 0$ являются достаточным условием существования хаоса.

Из вышеизложенного следует, что значения K -энтропии характеризуют хаотичность, регулярность или случайность движения ОУ, то есть его режим функционирования.

Кроме того, K -энтропия определяет среднее время, на которое можно предсказать состояние системы с динамическим хаосом. При этом, точное предсказание возможно только на интервале времени T_{pr} таком, что $\sigma \cdot e^{KT_{pr}} = 1$.

Для одномерных отображений K -энтропия равна показателю Ляпунова. Для систем большей размерности K -энтропия является мерой средней деформации ячейки в фазовом пространстве и равна усредненной по фазовому пространству сумме положительных показателей Ляпунова. То есть, для динамических систем большой размерности время точного предсказания равно [37]:

$$T_{pr} \cong \frac{1}{K} \ln \left(\frac{1}{\sigma} \right); \quad (2.19)$$

Для одномерных отображений – $K = \lambda$, где λ – показатель Ляпунова. Следует отметить, что точность σ , с которой определяется положение начального состояния ОУ, влияет на T_{pr} логарифмически.

Оценка (сверху) интервала предсказуемости выполняется аналогично выражению (2.19):

$$T_{vg} \sim \frac{1}{K_{ng}} \ln \left(\frac{1}{\sigma} \right) \geq T_{pr} \quad (2.20)$$

Таким образом, по значению корреляционного интервала предсказуемости T_{vg} определяется глубина точного прогноза ОУ.

Размерность d в фазовом пространстве, начиная с которой корреляционная размерность D_{ng} перестает изменяться, является минимальной размерностью вложения аттрактора, то есть наименьшей целой размерностью фазового пространства, которая содержит весь аттрактор. То есть, размерность фазового пространства d определяется по зависимости $D_{ng}(d)$. Вместе с тем, из теоремы про вложение [37] вытекает, что оценка размерности фазового пространства d определяется через оценку размерности аттрактора D_{ng} реальной динамической системы (формула Мане):

$$d \geq 2D_{ng} + 1. \quad (2.21)$$

На практике значения d для отображений оказываются завышенными, поэтому часто ограничиваются пространством размерности $d \geq D_{ng}$.

Таким образом, размерность вложения аттрактора d определяет размерность модели динамической системы (глубина памяти входных и выходных переменных модели ОУ).

Большинство природных процессов являются «смещенными случайными блужданиями» – трендами с шумом [37, 42]. Показатель Херста H , описанный в пункте 2.2.2, является критерием состояния динамической стохастической системы. Он показывает тенденцию к изменению режима работы ОУ и используется как критерий необходимости проведения его структурно-параметрической идентификации [163].

2.3.2. Структурно-параметрическая идентификация ОУ.

Задача идентификации ОУ формулируется таким образом [75, 78, 83-85]: на основании экспериментального множества функций (временных рядов) возмущений, управлений и выходов в условиях помех определить структуру (обобщенную функцию Φ) и вектор параметров a модели вида:

$$\hat{Y}[m+n] = \Phi\{Y[m], u[m], \chi[m], \xi[m], a[m], m\}, m = \overline{1, M} \quad (2.22)$$

которая достаточно точно (в смысле некоторого критерия) аппроксимирует ОУ относительно входных и выходных величин во всем функциональном пространстве. Здесь $Y[m], u[m], \chi[m], \xi[m]$ – соответственно, векторы (матрицы) выхода процесса, его управлений, возмущений и помех к текущему такту времени m ($m = t/T$) с соответствующими глубинами памяти; t – непрерывное время; T – период дискретизации; M – время наблюдения; n – глубина прогноза (для компенсации чистого запаздывания и времени на синтез и реализацию управления).

Считаем, что оценка состояния $\hat{Z}[m]$ ОУ (2.22) выполняется с помощью соответствующих фильтров наблюдения:

$$\{Y[m], u[m], \chi[m]\} \subset \hat{Z}[m]. \quad (2.23)$$

Таким образом, формирование вектора $\Psi_s = \{\Phi, a\}$ оценки структуры Φ (структурная идентификация) и параметров a (параметрическая идентификация) модели ОУ (2.22) осуществляется на основе векторов сигналов наблюдения $\hat{Z}[m]$ (2.23) путем минимизации принятого функционала:

$$C[\Psi_s] \rightarrow \min_{\Psi_s \in \theta} C \Rightarrow \Psi_{\theta}^{opt} = \{\Phi_{opt}, a_{opt}\}, \quad (2.24)$$

где θ – ограничения, в общем виде, равны:

$$\theta = \begin{cases} \{h(\Psi_s) \geq 0\} \subseteq \theta_h; \\ \{g(\Psi_s) = 0\} \subseteq \theta_g; \\ \{\phi_i, i = \overline{1, D}\} \subseteq \theta_D. \end{cases} \quad (2.25)$$

Здесь h, g – непрерывные дифференцируемые функции; ϕ_i – элементы дискретного вектора D возможных значений структурной функции $\Phi = \{\phi_i\}$.

Поскольку выражения (2.24)-(2.25) являются полимодальными [33, 83-85] (комбинацией непрерывного и дискретного программирования), то это требует использования методов глобальной оптимизации, среди которых наиболее эффективными являются поисковые методы. В них алгоритм поиска оптимального решения связывает следующие друг за другом решения $\Psi_s(j+1) = F[\Psi_s(j)]$, где F – алгоритм поиска, который показывает какие операции следует произвести на шаге j при решении $\Psi_s(j)$, чтобы получить новое решение $\Psi_s(j+1) \succ \Psi_s(j)$. Здесь знак преимущества \succ при минимизации функционала имеет смысл:

$$C[\Psi_s(j+1)] < C[\Psi_s(j)]. \quad (2.26)$$

В алгоритмах прямого случайного поиска (ПСП) задаются направления поиска и определяются значения функционала C в точках $\Psi_s(j) \pm \gamma\zeta$. Решение состоит в выборе шага в направлении уменьшения этого функционала:

$$\Psi_s(j+1) = \Psi_s(j) - \omega\zeta \{C[\Psi_s(j) + \gamma\zeta] - C[\Psi_s(j) - \gamma\zeta]\}, \quad (2.27)$$

где ω, ζ, γ – параметры, которые определяют сферы принятия решения (ω), сбора информации (γ) и единичное случайное направление (ζ). В общем случае параметры в (2.27) могут изменяться (адаптироваться) к процедуре поиска и виду гиперповерхности принятого функционала.

Развитием метода ПСП является метод имитации отжига (МИО), который основан на идее, заимствованной из статистической механики, и отражает по-

ведение расплавленного материала при отверждении с применением процедуры управляемого охлаждения (отжига).

В процессе отжига кристаллизация расплава сопровождается глобальным уменьшением его энергии, однако допускаются ее возрастание на некоторое время, например, при подогреве расплава для предотвращения слишком быстрого его остывания. Благодаря допустимости кратковременного повышения энергетического уровня, возможен выход из ловушек локальных минимумов энергии, которые возникают при реализации процесса.

В алгоритмах МИО задаются направления поиска и определяются значения функционала C в точках $\Psi_s(j) \pm \nu\tau$. Решение состоит в выборе шага в направлении уменьшения этого функционала:

$$\Psi_s(j+1) = \Psi_s(j) - \omega\nu\{C[\Psi_s(j) + \nu\tau] - C[\Psi_s(j) - \nu\tau]\}, \quad (2.28)$$

где ω, ν, τ – параметры, которые определяют сферы принятия решения (ω), изменение текущего решения (ν) и уменьшение температуры (τ). В общем случае эти параметры могут изменяться (адаптироваться) к процедуре алгоритма и виду гиперповерхности принятого функционала. Таким образом, в (2.28), в отличие от (2.27), выбор случайного направления ζ заменен на выбор направления уменьшения температуры τ .

Развитием поисковых методов являются ЭА, среди которых наиболее распространены ГА [33, 78, 84, 85], которые моделируют развитие биологической популяции на уровне геномов: мутации структуры и параметров $\delta\Psi_s$, их скрещивание (размножение):

$$\Psi_s(j+1) = \Psi_s(j) + \delta\Psi_s(j), \quad (2.29)$$

и правило отбора, что позволяет обнаруживать их благоприятные вариации, с помощью которых строится последовательность улучшенных по свойству (2.25) решений.

При решении задач (2.24)-(2.25) актуальным является выбор критериев качества модели (функционала C) [84]. Для структурной идентификации эффективными считаются внешние критерии, которые адекватны задаче построения моделей с минимальной дисперсией ошибки прогноза и делятся на критерии регулярности и критерии несмещенности (минимума смещения) [51].

К критериям регулярности относится критерий минимума относительной ошибки пошагового интегрирования:

$$C_{рег} = \frac{\|Y^*[m+n] - \hat{Y}[m+n]\|}{\|Y^*[m+n]\|}, \quad (2.30)$$

который вычисляется на всей выборке экспериментальных данных N , а также критерий минимума выборочной относительной ошибки:

$$C_{регB} = \frac{\|Y^*[m+n] - \hat{Y}_A[m+n]\|_B}{\|Y^*[m+n]\|_B}. \quad (2.31)$$

Критерий регулярности $C_{регB}$ основан на разделении данных на две последовательности: обучающую A (выход модели $\hat{Y}_A[m+n]$), и проверочную B , что отмечено в (2.31) индексом внизу. Оптимизация модели осуществляется на обучающей, а проверка ее эффективности (величины ошибки) на проверочной последовательности. Вся выборка $N = A + B$.

Физический смысл критерия регулярности состоит в том, что он ориентирован на выбор модели, которая будет наиболее точной на множестве точек, которых еще нет в таблице, но которые появятся там в ближайшем будущем. То есть, критерии (2.30) и (2.31) могут быть рекомендованы для идентификации и прогнозирования процессов с глубиной прогноза не более 2 шагов. Кроме того, эти критерии чувствительны к уровню шума в начальных данных, и при увеличении помех их минимум смещается в область простейших моделей [75, 84].

Более стойкие к помехам критерии минимума смещения (несмещенности). Например, критерий несмещенности, основанный на анализе решений, имеет вид:

$$C_{см} = \frac{\|\hat{Y}_A[m+n] - \hat{Y}_B[m+n]\|}{\|Y^*[m+n]\|}, \quad (2.32)$$

где $\hat{Y}_A[m+n]$ и $\hat{Y}_B[m+n]$ – выходы моделей, которые обучены на выборках A и B , соответственно. Вычисление критерия $C_{см}$ осуществляется на всей выборке N .

Критерий минимума смещения позволяет выбрать модель наименее чувствительную к изменению множества точек, по которым она получена. Такая модель должна давать одинаковые результаты на выборках A и B . Поэтому, этот критерий рекомендуется для решения задачи идентификации [86].

Наряду с критериями (2.30)-(2.32) используются различные виды комбинированных критериев, которые объединяют в себе различные требования, предъявляемые к выбору модели. Например, в качестве критерия структурной оптимизации может быть предложен комбинированный критерий вида:

$$C_{комб} = \mu C_{рег} + (1 - \mu) C_{см}; \quad (2.33)$$

где $0 \leq \mu \leq 1$ – так называемый коэффициент веса.

Преимуществами комбинированного критерия (2.33) является глобальность результата (то есть однозначный выбор структуры модели) и повышенная помехоустойчивость.

Ограничения $\Psi_s(j) + \delta\Psi_s(j) \in \theta$, которые накладываются при решении задачи (2.24)-(2.25), допускают $\Phi + \delta\Phi \in \theta$ и $a + \delta a \in \theta$ [83, 84]. Ограничения $\theta_1 = \theta_h \cap \theta_g$ формируют непрерывную задачу математического программирования, а $\theta_2 = \theta_h \cap \theta_D$ – задачу дискретного программирования. При этом ограничения $\theta = \{\theta_1, \theta_2\}$ можно учитывать следующим образом:

- при ограничениях $\theta \neq \theta_h$ удачным считается шаг, когда выполняется условие (2.28) и $\Psi_s(j) \in \theta$, иначе шаг неудачный и необходимо вернуться в предыдущее состояние с последующим новым шагом из него;

- при ограничениях $\theta = \theta_g$ вводится коридор $\|g(\Psi_s)\| < \varepsilon_{don}$, ограниченный допустимой ошибкой ε_{don} ;

- при ограничениях на дискретность структурных функций $\theta = \theta_D$ осуществляется случайный выбор новой точки около начальной: $\|\Psi_{si}(j+1) - \Psi_{si}(j)\| < \varepsilon$, где Ψ_{si} – вектор структурно-параметрических факторов со значением структурной функции ϕ_i . Если $\Omega_\varepsilon(j)$ – множество векторов Ψ_{si} , которое удовлетворяет вышеприведенному условию, то на шаге $j+1$ из $\Omega_\varepsilon(j)$ выбирают точку (значение Ψ_{si}), которое удовлетворяет условиям $C[\Psi_{si}(j+1)] < C[\Psi_{si}(j)]$ и $\Psi_{sz}(j+1) \in \Omega_\varepsilon(j)$;

- ограничения $\theta = \theta_h \cap \theta_g$ являются комбинация первых двух случаев.

При этом, дополнительно необходимо, чтобы $\Psi_{si}(j+1) \in \theta_h$.

Одной из основных проблем при решении задачи идентификации ОУ является выбор типа структуры модели [9, 87]. Обычно структуру определяют, исходя из физических законов, реализуемых в системе. Однако, такая модель, зачастую, имеет высокую размерность, что затрудняет ее практическое использование.

Более продуктивным представляется определение структуры модели ОУ на основе наблюдений его входных и выходных переменных с использованием аппроксимаций в виде функциональных рядов Вольтерра, полиномов Колмогорова-Габора, блочно-ориентированных моделей и др. [33, 34].

В блочно-ориентированных моделях нелинейные динамические ОУ представляются путем композиции линейного динамического (ЛДБ) и нелинейного статического (НСБ) блоков, например, в виде моделей Винера, Гаммерштейна или их комбинаций [78, 84, 87, 88].

Модель Винера содержит последовательно соединенные линейный динамический и нелинейный статический блоки (рис. 2.5,а), а в модели Гаммерштейна, наоборот, линейный блок приведен к выходу (рис. 2.5,б) [87].

Модель Винера-Гаммерштейна образуется путем объединения блоков моделей Винера и Гаммерштейна, для чего вводится обратная связь (рис. 2.6,а), а модель Гаммерштейна-Винера – последовательным соединением моделей

Гаммерштейна и Винера, при этом в центре соединения оказываются два линейных динамических блока, которые объединяются в один (рис. 2.6,б).

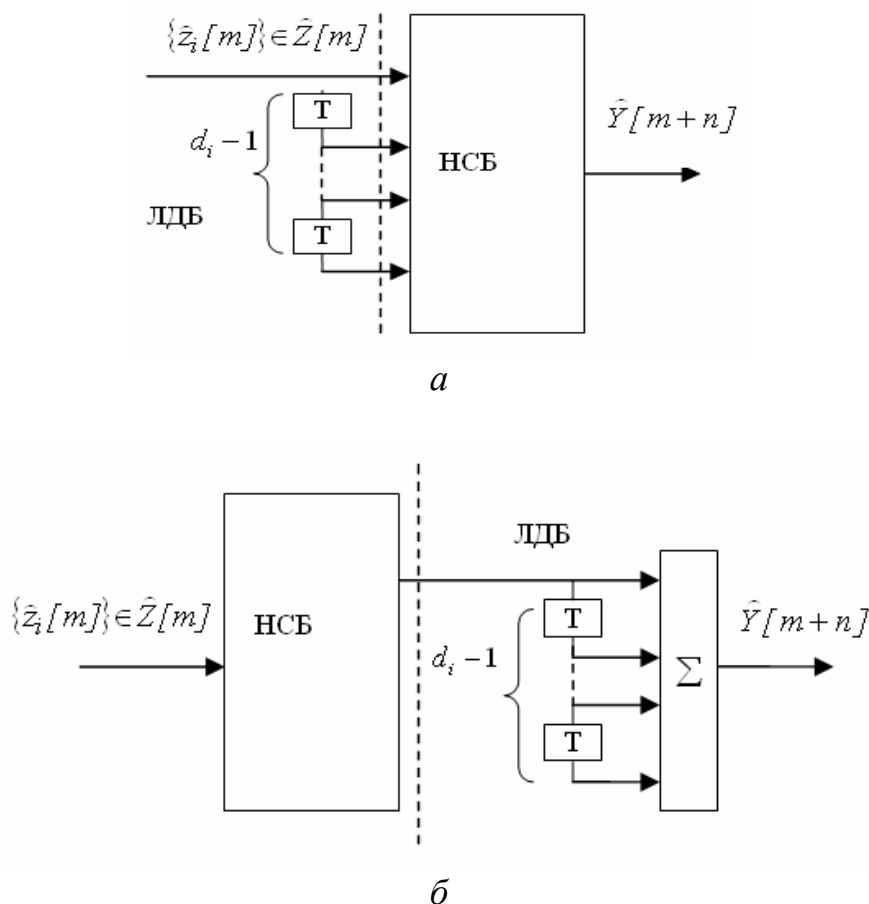


Рис. 2.5. Структура Винера (а) и Гаммерштейна (б) прогнозирующей модели нелинейного динамического ОУ

На рис. 2.5 и 2.6 в качестве ЛДБ используются линии задержки T , величины которых (глубина памяти) определяются размерностью входных d_i и выходных $d_{\hat{Y}}$ переменных, а в качестве НСБ – как традиционные средства: полиномы Лежандра или Колмогорова-Габора, так и интеллектуальные – НС, гибридные НС с нечеткой логикой и др. Входом моделей являются векторы наблюдений $\{z_i[m]\} \in \hat{Z}[m]$ для моментов времени m , а выходом – его прогноз на n тактов ($\hat{Y}[m+n]$).

Кроме моделей Винера, Гаммерштейна и их комбинаций к блочно-ориентированным моделям относятся также модели авторегрессии с дополнительным входным сигналом – ARX-модели [33, 34, 88], которые описывают нелинейные структуры, используя параллельную комбинацию нелинейных и линейных блоков.

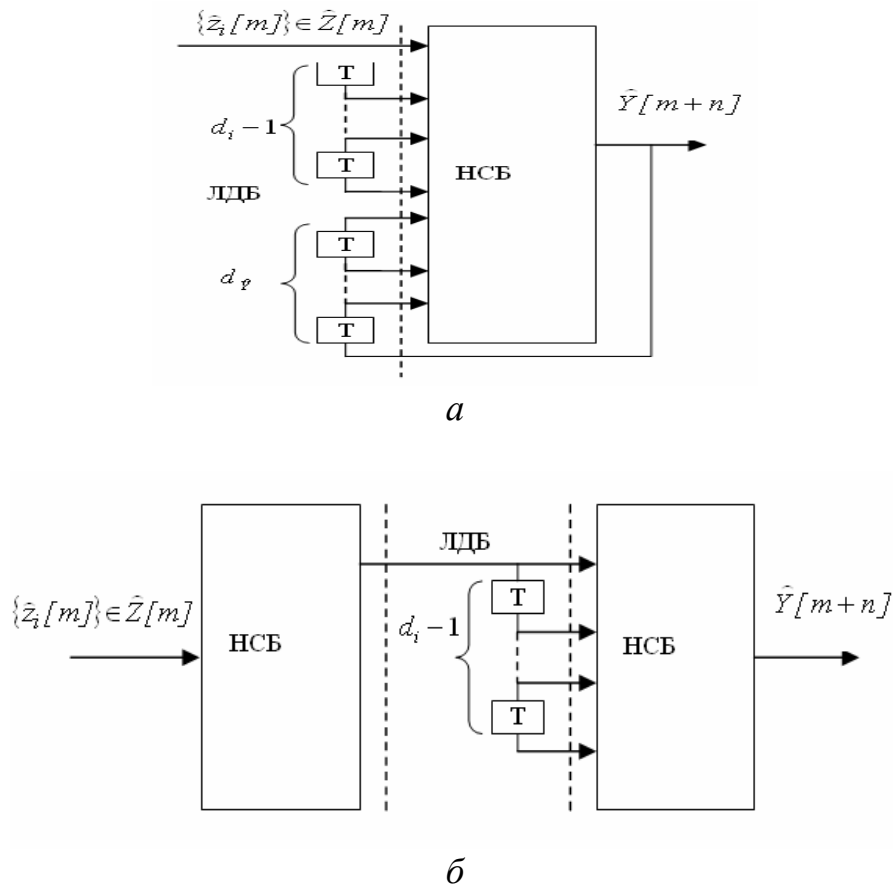


Рис. 2.6. Структура Винера-Гаммерштейна (а) и Гаммерштейна-Винера (б) прогнозирующей модели нелинейного динамического ОУ

Выбор метода локальной (параметрической) оптимизации ограничен выбором типа базисных функций, в качестве которых целесообразно выбирать НС и системы нечеткой логики, являющиеся универсальными и эффективными аппроксиматорами.

Уравнение ОУ (2.22) на основе НСПР со скрытым слоем предлагается приводить в виде [84]:

$$\hat{Y}[m+n] = \sum_{\tau \in P} F_{\hat{Y}} \left\{ \sum_{l \in Q} w_l[\tau] \cdot F_l \left(\sum_{m \in Q} w_{l,k}[\tau] \cdot y_k[m-\tau] \right) \right\}, \quad (2.34)$$

где P – множество глубин памяти соответствующих входов; $F_{\hat{Y}}$ – функция активации выходного слоя НС; Q – множество входов нейронов; l – порядковый номер входа выходного слоя НС; w_l – весовые коэффициенты выходного слоя; F_l – функция активации нейронов скрытого слоя; k – порядковый номер входа НС; $w_{l,k}$ – весовые коэффициенты связи k -го входа и l -го нейрона; y_k – вход НС.

В общем случае входами НС (2.34) согласно (2.22) и (2.23), а также рис. 2.5 и 2.6 являются $\{\hat{Y}[m], \hat{Z}[m]\} \subset \{y_k[m-\tau]\}$, а ее структурными характери-

стиками – $\{T_s, P, P_{pr}, F_{\hat{Y}}, F_l, r_s, M_{po}\} \subset \Phi$, где T_s – тип структуры, $r_s \subset Q$ – размер скрытого слоя, M_{po} – метод параметрической оптимизации (функция обучения НС), P_{pr} – глубина прогноза. При этом параметрами НСПР являются $\{w_l, w_{l,k}\} \subset a$.

К НСПР относятся перцептроны, каскадные НС, вейвнеты (НС с функциями активации в виде вейвлет) и др.

Прогнозирование с помощью НС РБФ выполняется согласно уравнению [84]:

$$\hat{Y}[m+n] = \sum_{\tau \in P} F_{\hat{Y}} \left\{ \sum_{l,k \in Q} w_l \cdot F_l(\mathcal{G}_l, \|y_k[m-\tau] - \nu_l\|) \right\}, \quad (2.35)$$

где \mathcal{G}_l, ν_l – параметры РБФ l -го нейрона скрытого слоя.

При этом, структурными характеристиками НС (2.35) являются – $\{T_s, P, P_{pr}, F_{\hat{Y}}, F_l, r_s, M_{po}\} \subset \Phi$, а ее параметрами – $\{w_l, \mathcal{G}_l, \nu_l\} \subset a$.

Уравнение ОУ на основе гибридной НС Anfis предлагается приводить в виде:

$$\hat{Y}[m+n] = \sum_{\tau \in P} \sum_{k \in Q} \beta_k[\tau] \cdot \alpha_k[m-\tau], \quad (2.36)$$

где $\beta_k[\tau] = U_k^{-1}(\alpha_k[\tau] / \sum_k \alpha_k[\tau]); \quad \alpha_k[m-\tau] = T_{norm} \{L_{l,k}(y_k[m-\tau])\};$

$U = U(a_U); L = L(a_L).$

Здесь U_k^{-1} – функция, обратная функции принадлежности промежуточного выхода k сети с параметрами a_U ; α_k – значение промежуточного выхода; T_{norm} – произвольная t-норма моделирования логической операции «I»; $L_{l,k}$ – функция принадлежности нечеткого правила l входа k с параметрами a_L .

Структурные характеристики НС (2.36) – $\{T_s, P, P_{pr}, U_k, L_{l,k}, r_p, M_{po}\} \subset \Phi$, где $r_p \subset Q$ – количество правил разложения по входам, а ее параметры – $\{a_U, a_L\} \subset a$.

Идентификация параметров (обучение) НСПР (2.34) осуществляется [84] с помощью градиентных алгоритмов обучения: алгоритмов метода сопряженных градиентов, алгоритмов обратного распространения ошибки или квазиньютоновских алгоритмов [63, 69]. При этом в пространстве параметров $\{w_l, w_{l,k}\} \subset a$ при выбранных структурных характеристиках ОУ Φ минимизируется функционал (2.25).

При обучении НС с РБФ (2.35) сначала определяются центры и отклонения для радиальных элементов, после чего оптимизируются параметры линейного выходного слоя: $\{w_l, \theta_l, v_l\} \subset a$.

Обучение гибридной НС (2.36) выполняется аналогично НСПР (2.34) путем оптимизации параметров функций принадлежности $\{a_U, a_L\} \subset a$ с помощью гибридного алгоритма или алгоритма обратного распространения ошибки [63, 69].

Преимуществом этих алгоритмов параметрического обучения НС является их простота и быстроедействие, а недостатком – их локальность (высокая вероятность «застревания» в локальном экстремуме).

В качестве критерия параметрической оптимизации используется либо критерий минимума среднеквадратической ошибки между экспериментальными и модельными значениями выхода:

$$C_{sred} = M_o \left\{ \left\| Y^* [m+n] - \hat{Y} [m+n] \right\| \right\}, \quad (2.37)$$

где M_o – математическое ожидание; либо критерий регулярности (2.30), определяемый на всей (либо проверочной) выборке данных.

Поскольку задача (2.24)-(2.25) имеет большую размерность (количество структурных характеристик и параметров в реальности составляют сотни, тысячи и десятки тысяч), то целесообразно использовать композицию алгоритмов глобальной и локальной оптимизации [75, 76, 84] (для структурной и параметрической идентификации модели соответственно).

Выводы к разделу

1. На основе формулировки задачи идентификации ОУ установлены условия выполнения параметрической или структурно-параметрической идентификации для конкретного ОУ.

2. В результате исследований точности идентификации различных режимов работы технологических процессов дробления и измельчения руд установлено, что оптимальная структура модели для одного режима функционирования не является таковой для других режимов. То есть при изменении динамических режимов работы ОУ необходимо проводить его структурно-параметрическую идентификацию.

3. В результате исследований идентификации состояния стохастических динамических процессов дробления и измельчения руд, закономерности в изменении которых характеризует параметр Херста, для различных экспериментальных данных определены его значения.

4. В результате исследования метода [8, 84], позволяющего определить режим функционирования ОУ, его размерность, а затем с помощью процедуры идентификации определить структурные характеристики и параметры модели ОУ, установлено, что в методе не обоснован выбор типа структуры моделей процессов ККД и МСИ при изменении их режимов работы. Также выполнение

процедуры идентификации в режиме реального времени, как предполагает данный метод, может быть нецелесообразно, поскольку для процессов ККД и МСИ руд она процедура проводится несколько часов.

5. Впервые предложено обосновать выбор типа структур моделей процессов ККД и МСИ руд путем исследования вариации их типов, что позволяет, в отличие от известного, повысить точность идентификации для разных режимов функционирования со снижением ошибок интеллектуальных прогнозирующих моделей.

6. Предложено модифицировать композиционный метод идентификации процессов ККД и МСИ [8, 84], включив в него критерий перехода к процедуре структурно-параметрической идентификации ОУ путем определения параметра Херста. При этом параметрическую идентификацию целесообразно проводить в режиме реального времени, а структурно-параметрическую – планировать, то есть выполнять ее в периоды небольшой нагрузки на вычислительные устройства и распределять между ними, и таким образом, снизить требования к их производительности и вычислительные затраты. Таким образом, комплексный метод идентификации процессов ККД и МСИ руд позволяет повысить точность идентификации этих процессов в условиях изменения их динамических режимов работы, параметров, и наличия помех, а также снизить вычислительные затраты на идентификацию.

РАЗДЕЛ 3

РАЗРАБОТКА ИНТЕЛЛЕКТУАЛЬНЫХ ПРОГНОЗИРУЮЩИХ МОДЕЛЕЙ НЕЛИНЕЙНЫХ ДИНАМИЧЕСКИХ ПРОЦЕССОВ КРУПНОГО ДРОБЛЕНИЯ И САМОИЗМЕЛЬЧЕНИЯ РУД

3.1. Методика структурно-параметрической идентификации

На основе исследований, изложенных в разделе 2, предложена методика идентификации нелинейных динамических процессов крупного дробления и самоизмельчения руд, схема которой приведена на рис. 3.1 [9, 89].

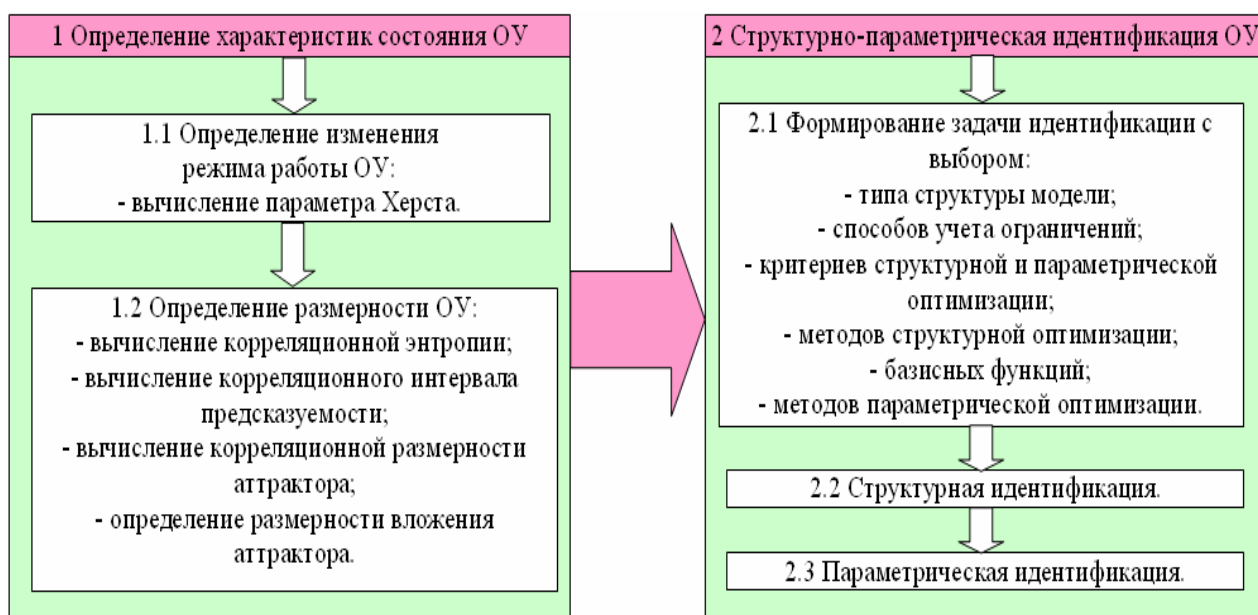


Рис. 3.1. Схема идентификации нелинейных динамических процессов крупного дробления и самоизмельчения руд

Данная методика состоит из процедур определения характеристик состояния ОУ и его структурно-параметрической идентификации.

3.1.1. Определение характеристик состояния ОУ.

Данная процедура включает вычисление показателя Херста H согласно выражениям (2.4)-(2.9) в соответствии с алгоритмом его вычисления, изложенным в п. 2.2.2.

Параметр Херста определяется для выявления тенденции ОУ к переходу в другой, отличный от текущего, режим функционирования. Если показатель Херста $H > 0,5$, то целесообразно планировать выполнение структурно-параметрической идентификации ОУ с текущим выполнением в реальном времени параметрической адаптации модели ОУ.

При переходе к структурно-параметрической идентификации необходимо выполнить п. 1.2 методики (см. рис. 3.1), чтобы оценить размерности переменных модели ОУ. После этого выполняется пункт 2 методики, включающий формирование задачи идентификации с выбором характеристик идентифика-

ции (п. 2.1 методики). Далее выполняется процедура структурно-параметрической идентификации ОУ согласно п.п. 2.2 и 2.3 методики.

Если значение показателя Херста $H < 0,5$, то в реальном режиме времени достаточно использовать параметрическую идентификацию согласно п. 2.3 методики, а планировать выполнение структурно-параметрической идентификации согласно п.п. 1.2, 2.1 и 2.2 методики нет необходимости.

Определение размерности (порядка) ОУ включает следующие этапы:

- вычисление корреляционной энтропии K_{ng} согласно выражениям (2.16)-(2-18);

- вычисление корреляционного интервала предсказуемости (глубины точного прогноза) процесса T_{vg} согласно выражению (2.20);

- вычисление корреляционной размерности аттрактора D_{ng} согласно выражениям (2.12), (2.13);

- определение размерности вложения аттрактора d согласно выражению (2.21) и по графику зависимости $D_{ng}(d)$ (глубины памяти входных и выходных переменных модели ОУ).

Размерность переменных ОУ определяет размерность его модели, которая синтезируется с помощью процедуры структурно-параметрической идентификации ОУ.

3.1.2. Структурно-параметрическая идентификация ОУ.

Формирование задачи структурно-параметрической идентификации осуществляется с выбором:

- типа структуры модели (Винера, Гаммерштейна, Винера-Гаммерштейна, Гаммерштейна-Винера (см. рис. 2.5 и 2.6, соответственно), или ARX);

- способов учета ограничений;

- метода структурной (глобальной) оптимизации (метода ПСП согласно выражению (2.27), либо МИО согласно (2.28), либо ГА согласно (2.29));

- критериев структурной и параметрической оптимизации (2.33) и (2.30);

- базисных функций (НСПР согласно выражению (2.34), НС РБФ согласно (2.35), или НС Anfis согласно (2.36));

- методов параметрической оптимизации, которые ограничены выбором базисных функций.

Вышеописанный выбор осуществляется на этапе проектирования АСУ ТП и базируется на априорных (теоретических и экспериментальных) данных, а при необходимости может быть откорректирован.

Структурная идентификация осуществляется следующим образом: сначала находится оптимальная структура модели для текущего режима функционирования ОУ по критериям (2.30), (2.33) или (2.37) путем исследования вариации их типов. Затем с помощью композиции методов глобальной ((2.27), (2.28) или (2.29)) и локальной оптимизации [84] осуществляется генерирование структур моделей-претендентов (базисных функций (2.34)-(2.36) со своими структурны-

ми характеристиками) и отбор лучших из них по критерию структурной оптимизации (2.31), (2.32) или (2.33). Результатом структурной идентификации является модель ОУ оптимальной структуры в смысле вышеназванных критериев.

Параметрическая идентификация заключается в определении параметров модели оптимальной структуры путем ее обучения методом локальной параметрической оптимизации по критериям (2.30) или (2.37).

3.2. Алгоритм определения изменения режимов работы технологических процессов

Ошибка ε является критерием параметрической адаптации модели ОУ и вычисляется согласно выражений (2.37) или (2.30) [9, 89]. Ее физический смысл состоит в том, что она определяет разницу между значениями выхода модели ОУ оптимальной структуры и реального выхода ОУ. Таким образом, в реальном времени происходит переопределение (перерасчет) оптимальных параметров модели ОУ оптимальной структуры. Если значение ошибки ε для оптимальных значений параметров оказывается больше допустимой ($\varepsilon > \varepsilon_{don}$), то это значит, что определенная ранее оптимальная структура модели ОУ уже не является таковой (например, из-за смены режима функционирования ОУ). Поэтому ошибку ε , наряду с параметром Херста, целесообразно учитывать при принятии решения о необходимости перехода к выполнению структурно-параметрической идентификации ОУ (см. п. 2.2.2).

Таким образом, алгоритм определения изменения режимов работы технологических процессов ККД и МСИ руд (рис. 3.2) предусматривает переход к планированию выполнения их структурно-параметрической идентификации при соблюдении следующих условий [9, 89]:

- ошибка $\varepsilon > \varepsilon_{don}$ и параметр Херста $H > 0,5$;
- ошибка $\varepsilon \leq \varepsilon_{don}$ и параметр Херста $H > 0,5$;
- ошибка $\varepsilon > \varepsilon_{don}$ и параметр Херста $H < 0,5$.

В противном случае (если ошибка $\varepsilon \leq \varepsilon_{don}$ и параметр Херста $H < 0,5$) продолжает выполняться параметрическая адаптация модели ОУ в режиме реального времени.

При этом под планированием структурно-параметрической идентификации подразумевается ее выполнение в периоды небольшой нагрузки на вычислительные устройства, что позволяет снизить вычислительные затраты.

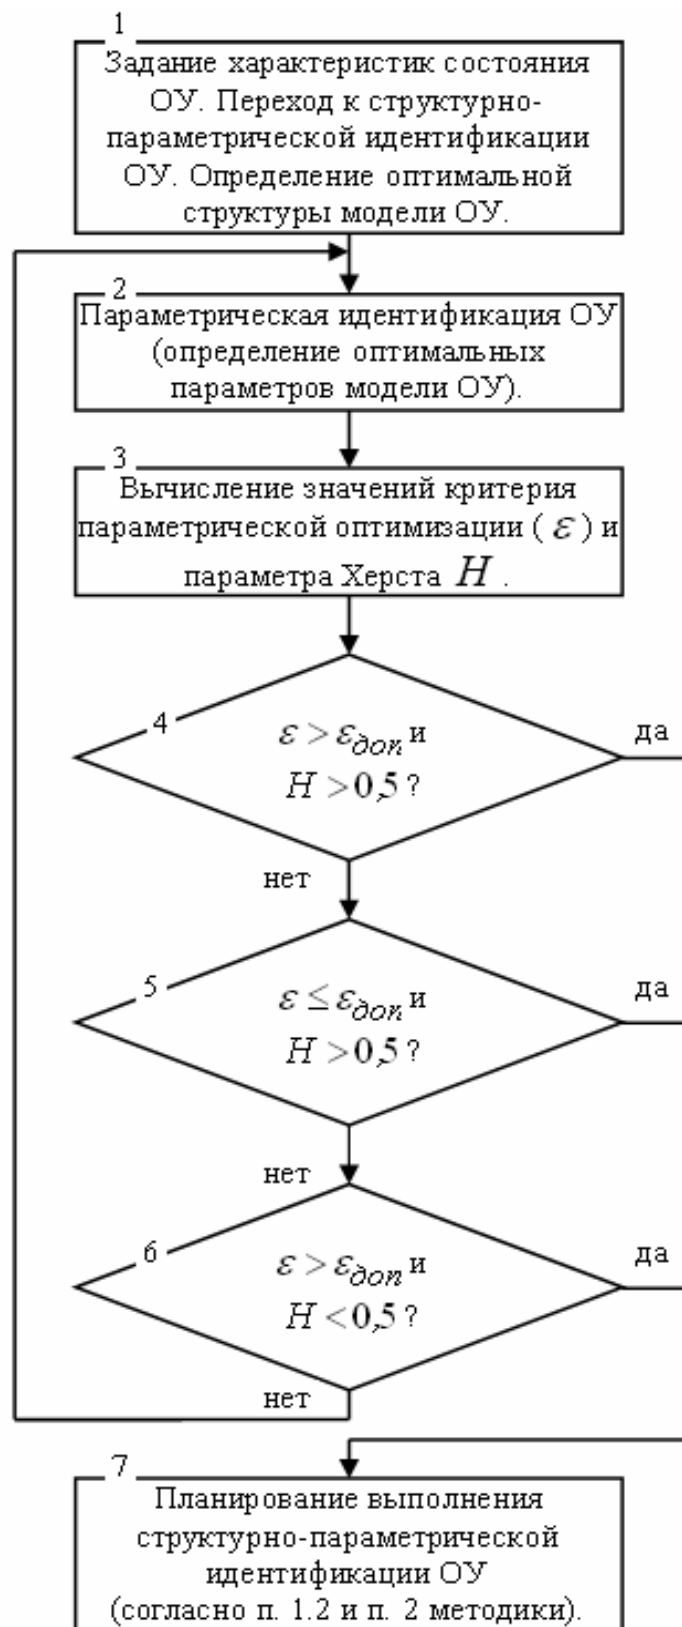


Рис. 3.2. Алгоритм определения изменения режимов работы технологических процессов крупного дробления и самоизмельчения руд

3.3. Разработка алгоритмов структурно-параметрической идентификации нелинейных процессов дробления и измельчения руд

3.3.1. Алгоритмы глобальной оптимизации моделей.

Обобщенная схема глобальной оптимизации для решения задачи структурно-параметрической идентификации с использованием ГА, ПСП и МПО приведена на рис. 3.3 [9, 85].

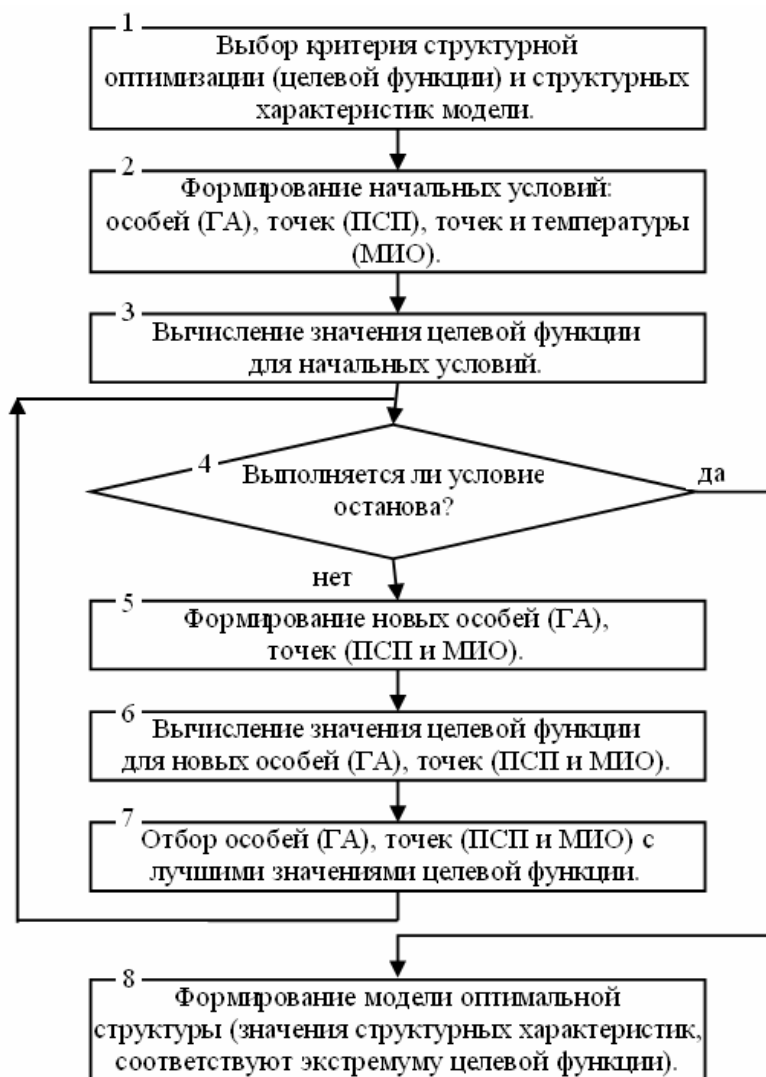


Рис. 3.3. Обобщенная схема глобальной оптимизации

Алгоритм глобальной оптимизации с использованием ГА согласно выражению (2.29) осуществляется следующим образом (см. рис. 3.3):

Шаг 1. Определение целевой функции (критерия структурной оптимизации). Выполняется определение структурных характеристик модели: типа базисных функций, количества нейронов в скрытом слое, типа функций активации (принадлежности) скрытого слоя, а также типа алгоритма параметрической оптимизации.

Шаг 2. Формирование начальных особей. Каждая особь представляет собой вектор с элементами в виде структурных характеристик. На этом этапе осуществляется настройка опций ГА: условия останова, размера популяции, а также формирование генетических операторов (мутации, отбора, кроссинговера, миграции и др.)

Шаг 3. Вычисление значения целевой функции для начальных условий. С помощью алгоритмов локальной оптимизации, базисных функций определяются значения выхода модели ОУ, по которым вычисляется значение критерия структурной оптимизации (целевой функции).

Шаг 4. Выполняется ли условие останова алгоритма? Если да, то осуществляется переход к шагу 8, иначе – переход к шагу 5. При этом, условия останова ГА следующие:

- число поколений достигает заданного значения;
- истекло заданное время работы алгоритма;
- значение целевой функции лучшей особи текущей популяции достигает экстремума;
- нет улучшения целевой функции в последовательности следующих друг за другом поколений, длина которой задана на шаге 2;
- нет улучшения для целевой функции в течение заданного интервала времени.

Шаг 5. Формирование новых особей происходит с помощью генетических операторов, настроенных на шаге 2. Сначала происходит отбор родителей, затем кроссинговер родителей, скрещивание и вероятностная мутация потомков. Здесь также устанавливается доля мигрирующих особей из одной популяции в другую.

Шаг 6. Вычисление значения целевой функции для новых особей происходит аналогично вычислениям на шаге 3.

Шаг 7. Отбор особей с лучшими значениями целевой функции. В новую популяцию особи отбираются в зависимости от значений их функций пригодности (целевых функций). Далее выполняется переход к шагу 4.

Шаг 8. Формирование модели оптимальной структуры. С помощью ГА определяются значения лучших особей (структурных характеристик), соответствующих экстремуму целевой функции. Формируется модель оптимальной структуры.

Алгоритм глобальной оптимизации с использованием метода ПСП в соответствии с (2.27) осуществляется следующим образом (см. рис. 3.3):

Шаг 1. Определение целевой функции (критерия структурной оптимизации). Выполняется определение структурных характеристик модели: типа базисной функции, количества нейронов в скрытом слое, типа функций активации (принадлежности) скрытого слоя, а также типа алгоритма параметрической оптимизации.

Шаг 2. Формирование начальных точек. Каждая точка представляет собой вектор структурных характеристик. При этом настраиваются опции для работы ПСП: условия останова алгоритма ПСП, выбор методов, способов и свойств поиска.

Шаг 3. Вычисление значения целевой функции для начальных условий. С помощью алгоритмов локальной оптимизации, базисных функций определяются значения выхода модели ОУ, по которым вычисляются значения критерия структурной оптимизации (целевой функции).

Шаг 4. Выполняется ли условие останова алгоритма? Если да, то осуществляется переход к шагу 8, иначе – переход к шагу 5. При этом, условия останова ПСП следующие:

- число итераций достигает заданного максимального значения;
- размер ячейки меньше заданного значения;
- общее число расчетов значений целевой функции достигло максимального заданного значения;
- расстояние между точкой, найденной в успешном опросе, и точкой, найденном в неудачном опросе будет меньше заданного значения;
- изменения в целевой функции для одного успешного опроса и последующего успешного опроса будут меньше заданной величины.

Шаг 5. Формирование новых точек происходит с помощью методов поиска, настроенных шаге 2.

Шаг 6. Вычисление значения целевой функции для новых точек происходит аналогично вычислениям на шаге 3.

Шаг 7. Отбор точек с лучшими значениями целевой функции, которые заносятся в новую последовательность поиска в зависимости от значений их целевых функций (пригодности). Далее выполняется переход к шагу 4.

Шаг 8. Формирование модели оптимальной структуры. С помощью алгоритма ПСП определяются значения лучших точек (структурных характеристик), соответствующих экстремуму целевой функции. Формируется модель оптимальной структуры.

Алгоритм глобальной оптимизации с использованием МИО в соответствии с (2.28) осуществляется следующим образом (см. рис. 3.3):

Шаг 1. Определение целевой функции (критерия структурной оптимизации). Выполняется определение структурных характеристик модели: типа базисной функции, количества нейронов в скрытом слое, типа функций активации (принадлежности) скрытого слоя, а также типа алгоритма параметрической оптимизации.

Шаг 2. Формирование начальных точек и температуры. Каждая точка представляет собой вектор структурных характеристик. На этом этапе осуществляется настройка опций МИО: условия останова алгоритма МИО, способы и свойства метода.

Шаг 3. Вычисление значения целевой функции для начальных условий. С помощью алгоритмов локальной оптимизации, базисных функций, определяются значения выхода модели ОУ, по которым вычисляются значения критерия структурной оптимизации (целевой функции).

Шаг 4. Выполняется ли условие останова алгоритма? Если да, то осуществляется переход к шагу 8, иначе – переход к шагу 5. При этом, условия останова МИО следующие:

- число итераций достигает заданного максимального значения;

- число оценок целевой функции достигнет заданного значения;
- истекло заданное время работы метода;
- значение целевой функции достигло экстремума;
- среднее изменение в целевой функции (после заданного количества итераций) меньше заданной величины.

Шаг 5. Формирование новых точек происходит с помощью способов метода, настроенных на шаге 2.

Шаг 6. Вычисление значения целевой функции для новых точек происходит аналогично вычислениям на шаге 3.

Шаг 7. Отбор точек с лучшими значениями целевой функции, которые заносятся в новую последовательность поиска в зависимости от значений их функций пригодности (целевых функций). Далее выполняется уменьшение значения температуры и осуществляется переход к шагу 4.

Шаг 8. Формирование модели оптимальной структуры. С помощью алгоритма МИО определяются значения лучших точек (структурных характеристик), соответствующих экстремуму целевой функции. Формируется модель оптимальной структуры.

3.3.2. Алгоритмы локальной оптимизации моделей.

Обобщенная схема алгоритма локальной оптимизации для решения задачи структурно-параметрической идентификации с использованием базисных функций в виде НСПР (2.34), НС РБФ (2.35) и НС Anfis (2.36) приведена на рис. 3.4 [9, 85].

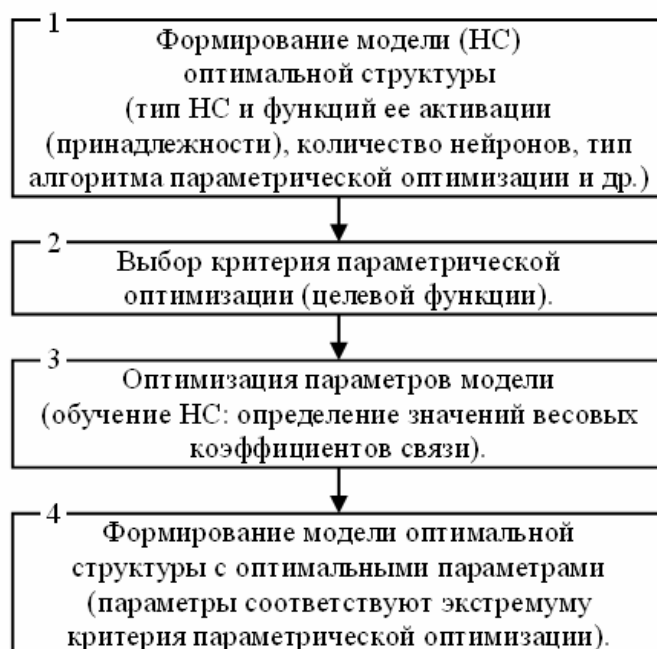


Рис. 3.4. Обобщенная схема алгоритма локальной оптимизации

Алгоритм локальной оптимизации с использованием в качестве базисной функции НСПР осуществляется следующим образом (см. рис. 3.4):

Шаг 1. Формирование модели оптимальной структуры. Создание НСПР (2.34) со следующими структурными характеристиками: типом структуры, глубинами памяти и прогноза, размером скрытого слоя, функцией активации нейронов скрытого и выходного слоя, а также методом параметрической оптимизации. Выполняется настройка опций для обучения НС: условий останова обучения, формирование массивов проверочных и тестовых данных, функций одномерного поиска и др.

Шаг 2. Выбор критерия параметрической оптимизации (2.30) или (2.37).

Шаг 3. Оптимизация параметров модели (обучение НС) путем определения значений весовых коэффициентов в соответствии с выбранным на шаге 1 методом параметрической оптимизации. Условия останова обучения [69]:

- количество циклов (эпох) обучения достигло максимально заданного значения;

- ошибка уменьшилась до заданного уровня;

- время обучения достигло максимально заданного значения;

- уровень превышения ошибки проверочной выборки по сравнению с обучающей достиг максимально заданного значения.

Шаг 4. Формирование модели оптимальной структуры с оптимальными значениями параметров, соответствующих минимуму критерия параметрической оптимизации (весовых коэффициентов связи входного и выходного слоев согласно выражению (2.34)).

Алгоритм локальной оптимизации с использованием в качестве базисной функции НС РБФ осуществляется следующим образом (см. рис. 3.4):

Шаг 1. Формирование модели оптимальной структуры. Выбор структурных характеристик НС РБФ (2.35): типа структуры, глубин памяти и прогноза, максимального размера скрытого слоя, функции активации нейронов скрытого (РБФ) слоя, функции активации нейронов выходного слоя, а также метода параметрической оптимизации. Выполняется настройка опций для обучения НС: условий останова обучения, выбор значения отклонения (параметра влияния) и др.

Шаг 2. Выбор критерия параметрической оптимизации (2.30) или (2.37).

Шаг 3. Оптимизация параметров модели (обучение НС) путем определения значений весовых коэффициентов в соответствии с выбранным на шаге 1 методом параметрической оптимизации. Условия останова обучения:

- ошибка уменьшилась до заданного уровня;

- количество нейронов скрытого слоя достигло максимального заданного значения.

Шаг 4. Формирование модели оптимальной структуры с оптимальными значениями параметров, соответствующими минимуму критерия параметрической оптимизации (параметров РБФ нейронов скрытого слоя и весовых коэффициентов выходного слоя согласно выражению (2.35)).

Алгоритм локальной оптимизации с использованием базисной функции – НС Anfis осуществляется следующим образом (см. рис. 3.4):

Шаг 1. Формирование модели оптимальной структуры. Генерация структуры типа Sugeno с выбором следующих структурных характеристик (2.36): ти-

па структуры, глубин памяти и прогноза, функций принадлежности и количества правил разложения по входам.

Шаг 2. Выбор критерия параметрической оптимизации (2.30) или (2.37).

Шаг 3. Оптимизация параметров модели (обучение НС) путем определения значений весовых коэффициентов в соответствии с выбранным на шаге 1 методом параметрической оптимизации. Условия останова обучения:

- количество циклов (эпох) обучения достигло максимально заданного значения;

- ошибка уменьшилась до заданного уровня.

Шаг 4. Формирование модели оптимальной структуры с оптимальными значениями параметров, соответствующих минимуму критерия параметрической оптимизации (параметров функций принадлежности согласно выражению (2.36)).

3.4. Исследование эффективности структурно-параметрической идентификации

3.4.1. Идентификация характеристик процессов крупного дробления и самоизмельчения.

Моделирование процедуры определения характеристик состояния процессов ККД и МСИ проводилось в соответствии с предложенной методикой и с помощью стандартных [79] и разработанных программ в среде Matlab. В качестве идентифицируемых процессов использовались временные реализации содержания класса +100 мм в крупнодробленой руде Γ_{+100}^1 и Γ_{+100}^2 (рис. 3.5), полученные в условиях Ингулецкого ГОКа в различные периоды работы фабрики.




Рис. 3.5. Временные реализации сигналов Γ_{+100}^1 (а) и Γ_{+100}^2 (б)

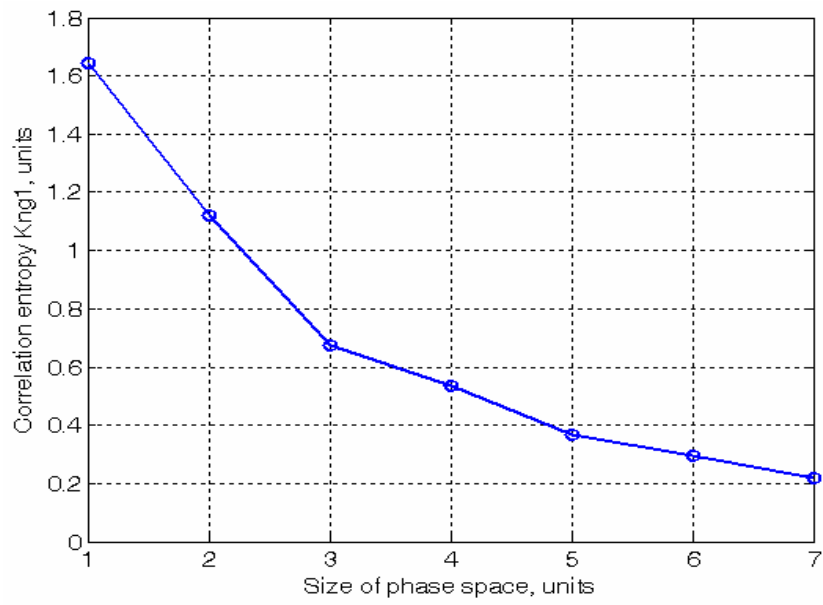
В результате расчетов с помощью программы Fractan [79] определены значения показателя Херста сигналов Γ_{+100}^1 и Γ_{+100}^2 , приведенные на рис. 2.4. Согласно полученным результатам для процесса, порождающего сигнал Γ_{+100}^2 рекомендуется определить оптимальную структуру его модели, а для процесса, порождающего сигнал Γ_{+100}^1 такой необходимости нет. Однако, поскольку для сигналов еще не определены оптимальные структуры моделей, то согласно алгоритму (см. рис. 3.2), вне зависимости от значений показателей Херста, для последовательностей Γ_{+100}^1 и Γ_{+100}^2 необходимо провести все процедуры согласно методике идентификации.

В результате расчетов для сигналов Γ_{+100}^1 и Γ_{+100}^2 определены значения корреляционной энтропии (рис. 3.6) и корреляционной размерности (рис. 3.7) [9, 89]. Значения корреляционной энтропии составили: $K_{ng1}=0,220$ и $K_{ng2}=0,404$, а корреляционной размерности: $D_{ng1}=2,353$ и $D_{ng2}=3,798$, соответственно.

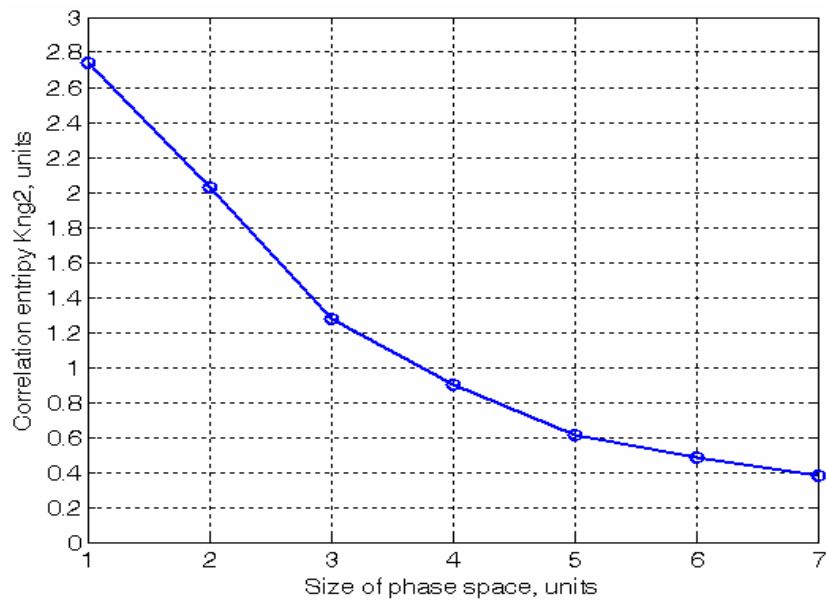
При этом корреляционные интервалы предсказуемости (глубины прогноза) процессов порождающих сигналы Γ_{+100}^1 и Γ_{+100}^2 в соответствии с выражением (2.20) составили: $T_{vg1}=7,27$ такта и $T_{vg2}=3,96$ такта, что подтверждает плохую прогнозируемость сигнала Γ_{+100}^2 , и соответственно, необходимость планирования выполнения структурно-параметрической идентификации процесса, его порождающего.

Для определения размерности фазового пространства вложения аттрактора (режима работы порождающего процесса) вычислялась ее оценка сверху по выражению (2.21). Для сигналов Γ_{+100}^1 и Γ_{+100}^2 ее значения составили $d_1 \leq 5,7$ и $d_2 \leq 8,6$. Оценка значения d снизу определялась по рис. 3.7. Из анализа рис. 3.7 видно, что размерности D_{ng1} и D_{ng2} практически перестают возрастать (входят в насыщение) при размерностях фазового пространства $d_1 \geq 3$ и $d_2 \geq 4$, соответственно. С учетом вышеизложенного, получим, что $D_{ng1} \cong 1,849$ и $D_{ng2} \cong 3,008$, а также $3 \leq d_1 \leq 5$ и $4 \leq d_2 \leq 8$.

Таким образом, для решения задачи идентификации процессов, порождающих сигналы Γ_{+100}^1 и Γ_{+100}^2 , глубина точного прогноза для них составляет 7 и 4 такта соответственно, а глубина памяти по разным входам – от 3 до 5 для сигнала Γ_{+100}^1 , и от 4 до 8 для сигнала Γ_{+100}^2 [9, 89].




a

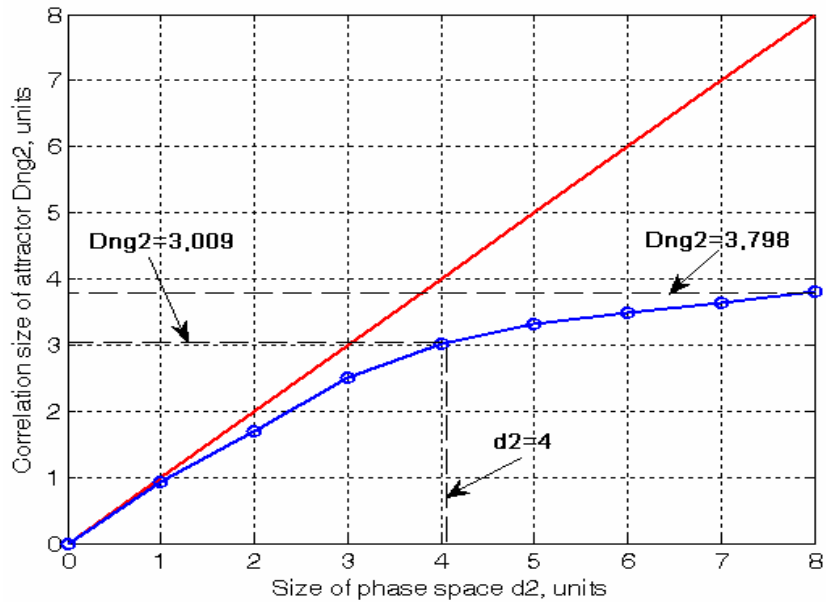


b

Рис. 3.6. Корреляционная энтропия для сигналов Γ_{+100}^1 (а) и Γ_{+100}^2 (б)



a



b

Рис. 3.7. Корреляционная размерность для сигналов Γ_{+100}^1 (а) и Γ_{+100}^2 (б)

3.4.2. Разработка интеллектуальной прогнозирующей модели процесса ККД.

Пусть прогнозирующая модель ОУ процесса ККД (согласно рис. 1.3.а) имеет вид:

$$\hat{\Gamma}_{\text{внх}}[m+n] = \Phi_{\hat{f}}\{\Gamma_{\text{внх}}[m], g[m], \Gamma_{\text{ex}}[m], \rho[m], \xi[m], a_{\hat{f}}[m], m\}, \quad (3.1)$$

где m – текущий такт времени с соответствующими глубинами памяти; n – глубина прогноза.

В качестве критерия параметрической оптимизации использовался критерий регулярности вида (в соответствии с (2.30), вычисляемый на проверочной выборке):

$$C_{\text{регККД}} = \frac{\|G_{\text{вых}B}[m+n] - \hat{G}_{\text{вых}B}[m+n]\|}{\|G_{\text{вых}B}[m+n]\|}, \quad (3.2)$$

где $G_{\text{вых}B}[m+n]$ – гранулометрический состав продукта дробления, вычисленный на выборке B , а $\hat{G}_{\text{вых}B}[m+n]$ – выходы моделей, которые обучены на выборке B .

В качестве критерия структурной оптимизации использовался комбинированный критерий вида (в соответствии с (2.33)):

$$C_{\text{комбККД}} = 0,2 \cdot C_{\text{регККД}} + 0,8 \cdot C_{\text{смККД}}, \quad (3.3)$$

где $C_{\text{смККД}}$ – критерий несмещенности (2.32), который для процесса ККД имеет вид:

$$C_{\text{смККД}} = \frac{\|\hat{G}_{\text{вых}A}[m+n] - \hat{G}_{\text{вых}B}[m+n]\|}{\|G_{\text{вых}}[m+n]\|}, \quad (3.4)$$

где $\hat{G}_{\text{вых}A}[m+n]$ – выходы моделей, которые обучены на выборке A . Вычисление критерия $C_{\text{смККД}}$ осуществляется на всей выборке N .

Поскольку одной из основных проблем при решении задачи идентификации ОУ является выбор структуры модели, то нами была оценена эффективность модели процесса ККД при вариации типов структур [9, 78].

Моделирование решения задачи структурно-параметрической идентификации выполнялось с помощью разработанной программы в среде Matlab [90].

Для моделирования процесса ККД в качестве входных сигналов использовался полосовой авторегрессионный сигнал с гауссовским шумом амплитудой 10% от уровня сигнала, а сам процесс моделировался адекватным нелинейным конечно-разностным уравнением (1.4). При этом, в соответствии с динамическими свойствами процесса ККД глубина прогноза составляла $n = 3$ такта, а глубина памяти – 4 такта. Размер реализации составлял $N = 1024$.

В качестве критерия оценки моделей выбран критерий регулярности (3.2), а в качестве типов структур применялись модели Винера, Гаммерштейна, Гаммерштейна-Винера и ARX с базисными функциями в виде каскадной НС, вейвнета и полинома Колмогорова-Габора.

Результаты идентификации ОУ со структурой модели ARX и базисными функциями в виде вейвнета и каскадной НС (2.34) приведены на рис. 3.8,а. При

этом значения критерия (3.2) составили 0,0644 для вейвнета и 0,0995 для каскадной НС.

Результаты идентификации ОУ со структурой модели Гаммерштейна-Винера и базисными функциями в виде вейвнета и полинома Колмогорова-Габора приведены на рис. 3.8,б. При этом значения критерия (3.2) составили 0,0334 для вейвнета и 0,0370 для полинома Колмогорова-Габора.

Результаты идентификации ОУ с базисными функциями в виде вейвнет и со структурами моделей Винера и Гаммерштейна приведены на рис. 3.9, а со структурами Гаммерштейна-Винера и ARX – на рис. 3.10. Значения критерия регулярности (3.2) составили: для моделей Винера – 0,0336, Гаммерштейна – 0,0723 (см. рис. 3.9,а-б, соответственно), для моделей Гаммерштейна-Винера – 0,0334, ARX – 0,0644 (см. рис. 3.10,а-б, соответственно).

Время вычислений на компьютере с процессором Pentium IV по моделям со структурами Винера, Гаммерштейна и Гаммерштейна-Винера составило 7-10 мс на цикл прогноза, а по модели ARX – 0,2 мс, что не вносит временных ограничений на применение этих моделей в АСУТП рудоподготовки.

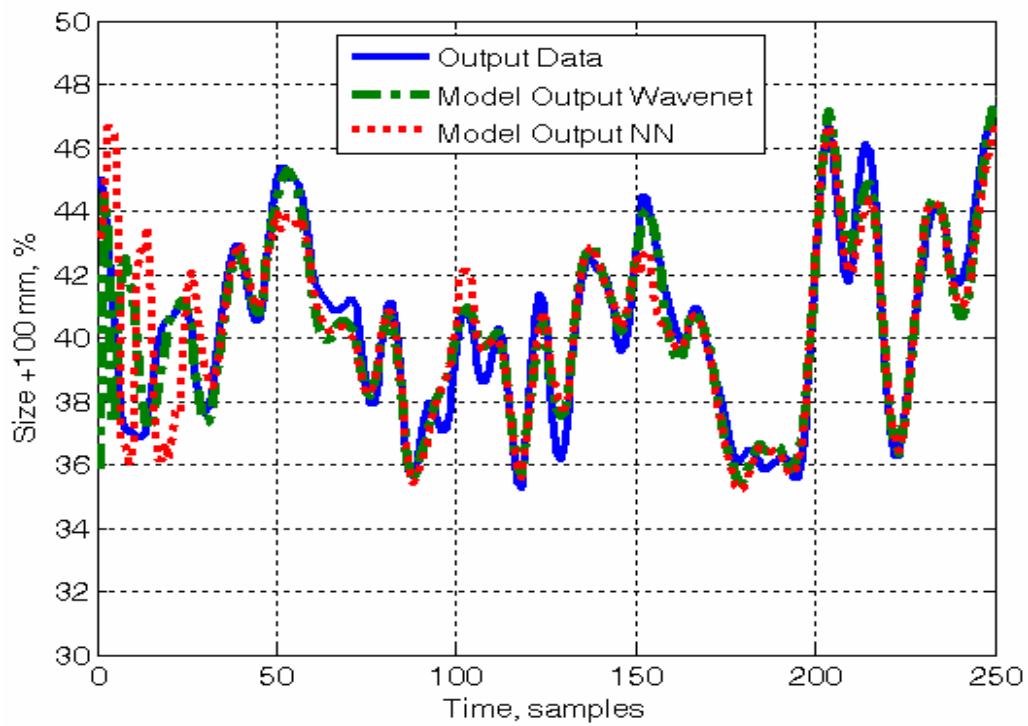
Таким образом, в результате проведенных исследований установлено, что в качестве структуры модели процесса ККД предпочтительной является структура Гаммерштейна-Винера, поскольку она дает меньшие значения критерия регулярности (3.2) при различных базисных функциях [9, 78].

Нами была разработана интеллектуальная прогнозирующая модель процесса ККД, в ходе чего было исследовано влияние различных методов (алгоритмов) структурной и параметрической оптимизации и типов базисных функций на точность идентификации динамических режимов нелинейного процесса ККД.

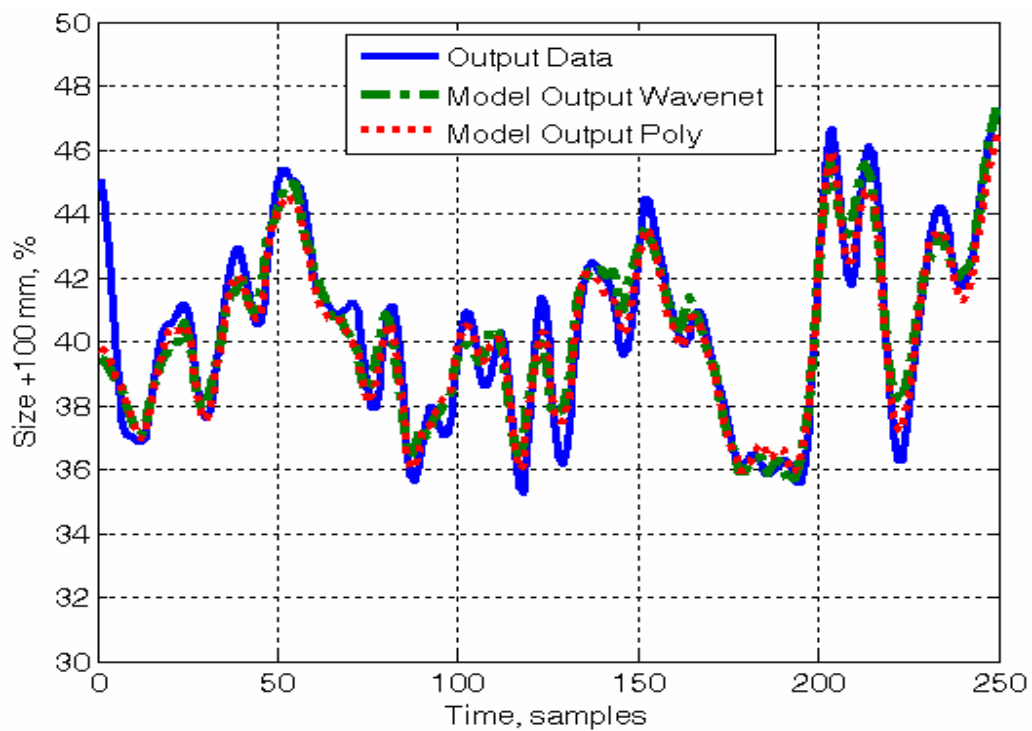
Решение этой задачи структурно-параметрической идентификации выполнялось в среде Matlab на основе экспериментальных реализаций значений технологических переменных процесса ККД, полученных в условиях Ингулецкого ГОКа. Структура программы идентификации показана на рис. 4.2.

Возмущениями процесса ККД являлась средневзвешенная крупность и крепость входной руды, управляющим воздействием – ширина разгрузочной щели дробилки, а выходом процесса – содержание класса +100 мм в дробленой руде. Из особенностей этого процесса глубина прогноза была принята $n = 3$ такта, а глубина памяти по разным входам от 1 до 4 в соответствии с размерностями входных $d_i - 1$ переменных на рис. 2.6,б. Погрешность измерения переменных процесса ККД не превышала 10%, а размер экспериментальных реализаций составлял $N = 58$.

В качестве критерия структурной оптимизации выбран комбинированный критерий (3.3), который имеет малую чувствительность к вариации шума и глубины прогноза (малый сдвиг глобального минимума в пространстве признаков).

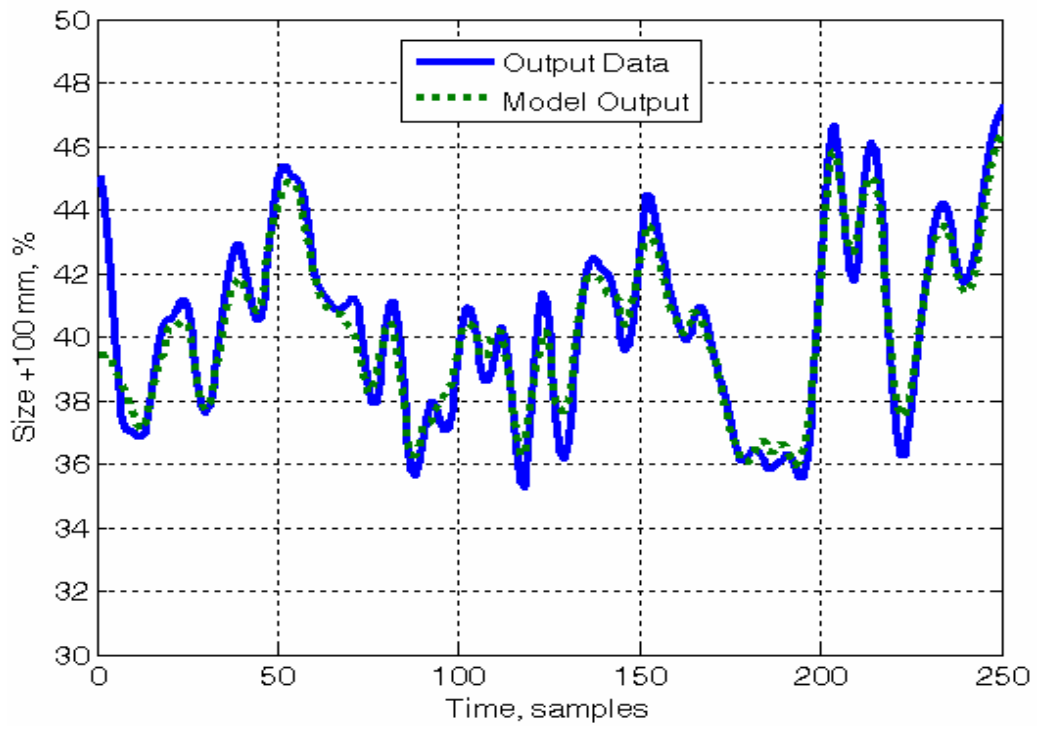


a




b

Рис. 3.8. Результаты идентификации процесса ККД в виде моделей ARX (*a*) и Гаммерштейна-Винера (*b*)

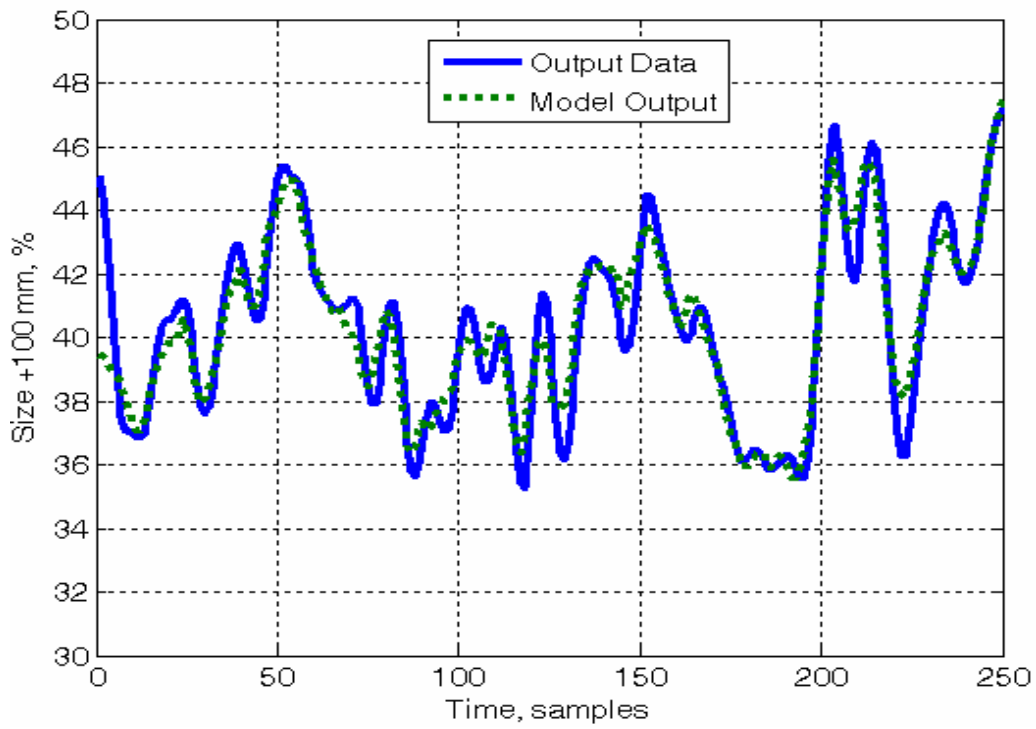


a

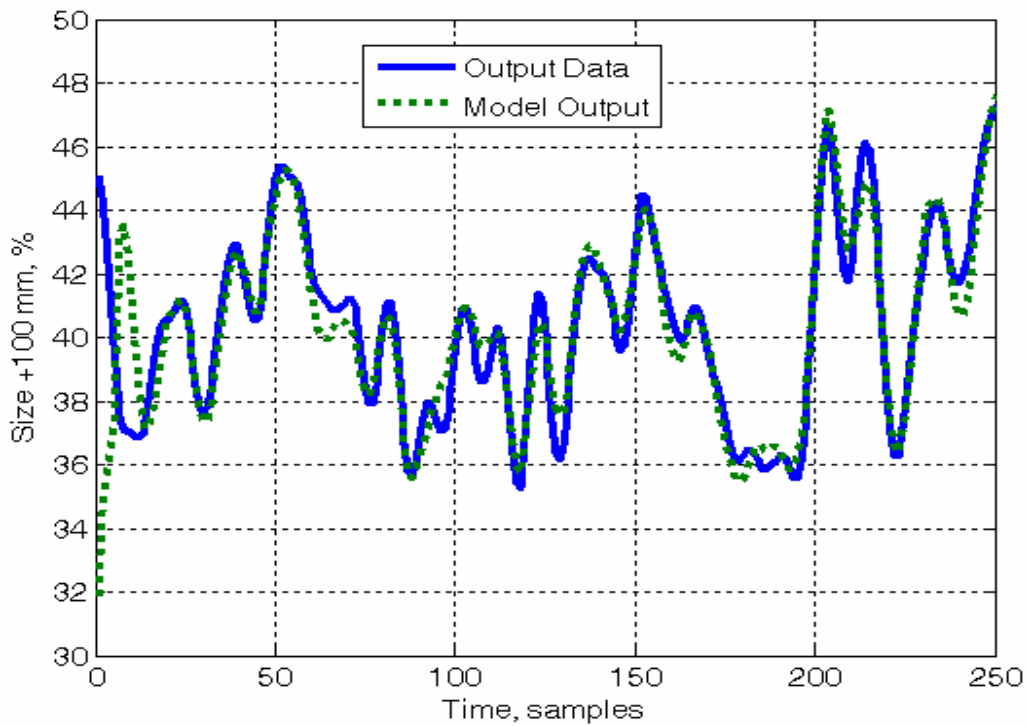


b

Рис. 3.9. Результаты идентификации процесса ККД в виде моделей Винера (*a*) и Гаммерштейна (*b*)



a



б

Рис. 3.10. Результаты идентификации процесса ККД в виде моделей Гаммерштейна-Винера (*a*) и ARX (*б*)

При идентификации в качестве глобальных методов оптимизации применялись ГА, ПСП и МИО. При этом использовалась структура моделей Гаммерштейна-Винера с базисными функциями в виде НС: НСПР (каскадной НС и вейвнет) (2.34), НС РБФ (2.35) и НС Anfis (2.36).

Результаты глобальной оптимизации структуры модели процесса ККД [9, 85] приведены на рис. 3.11.

ГА имел одноточечное скрещивание, селективный выбор родителей и формирование новой популяции с вытеснением, алгоритм ПСП – адаптивный шаг поиска и полный поиск вокруг текущей итерации, а алгоритм МИО – ограниченную область переотжига. Количество итераций для ПСП и МИО (для ГА поколений) ограничивалось на уровне 100, а размер пространства поиска для ПСП (для ГА размер популяции, для МИО размер области переотжига) – 30.

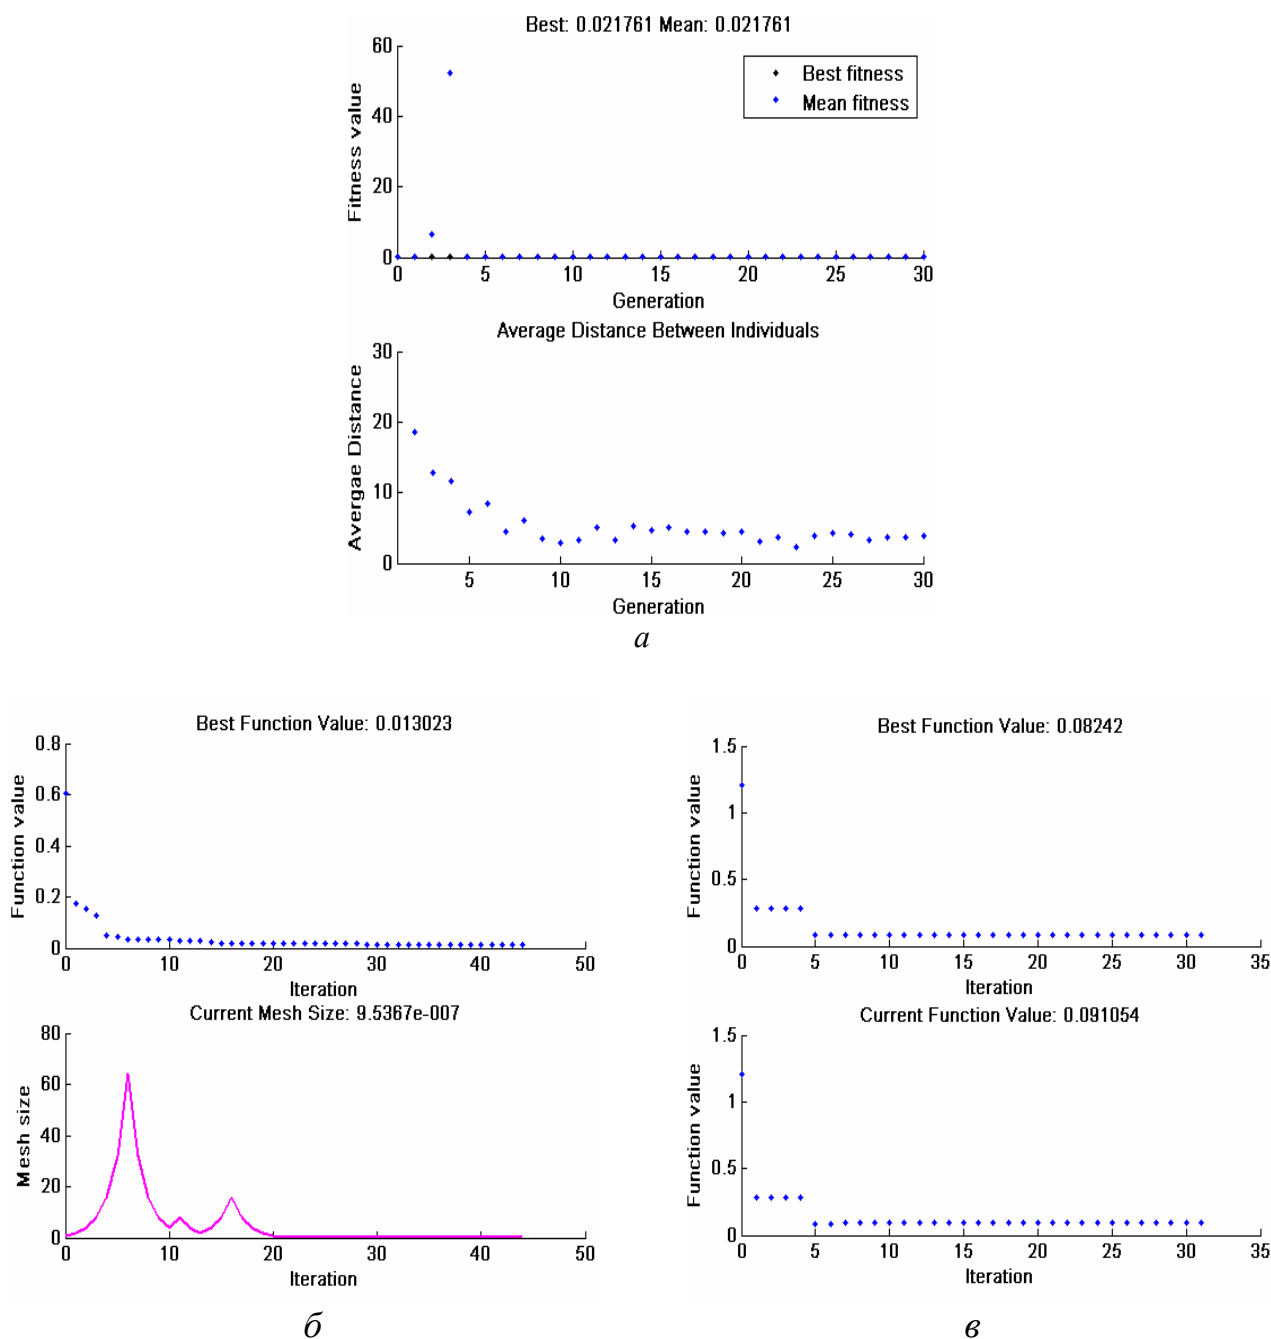


Рис. 3.11. Результаты глобальной оптимизации структуры модели процесса ККД с помощью ГА (a), ПСП (b) и МИО (v)

При глобальной оптимизации использовались (варьировались) следующие структурные характеристики модели:

- 1) тип базисной функции – НСПР (каскадная НС и вейвнет), НС РБФ и НС Anfis;
- 2) количество нейронов в скрытом слое;
- 3) тип функций активации (для НСПР) и принадлежности (для НС Anfis) скрытого слоя;
- 4) тип алгоритма параметрической оптимизации (для НСПР и НС Anfis).

В результате моделирования (см. рис. 3.11) установлено [9, 85], что ГА имеет самую высокую скорость сходимости (ГА выходит в область оптимальных решений на первых поколениях, МИО – в среднем после 5 итераций, а ПСП – после 15 итераций). Алгоритм МИО выявил самое высокое быстродействие (0,2 с на итерацию при 9,2 с на итерацию в ПСП и 16 с на поколение в ГА). При этом алгоритм ПСП выявил наилучшую сходимость (значения комбинированного критерия (3.3) при его использовании составили 0,013, в отличие от 0,022 при ГА и 0,082 при МИО).

Результат структурно-параметрической идентификации процесса ККД приведен на рис. 3.12.




Рис. 3.12. Результат идентификации процесса ККД

В целом установлено, что минимуму комбинированного критерия для процесса ККД отвечают базисные функции в виде каскадной НСПР. При этом количество нейронов в скрытом слое составляет 28, функция активации скрытого слоя – логистическая сигмоидальная, выходного слоя – линейная, алгоритм обучения НС – метод Флетчера-Ривса [69].

За меру точности параметрической идентификации модели оптимальной структуры использовался критерий регулярности (3.2), значение которого составило для модели процесса ККД – 0,0311, что существенно меньше, чем ошибка идентификация по принципу самоорганизации (0,0653 [10]), а также меньше ошибки модели процесса ККД, полученной с помощью композиционного метода идентификации (0,365 [8]).

Адекватность полученной интеллектуальной прогнозирующей модели процесса ККД проверялась по непараметрическому критерию знаков [91]. Было установлено, что для уровня значимости 0,01 разработанная модель с идентифицированными структурой и параметрами адекватна динамике рассматриваемых процессов.

Время поиска оптимальных решений при глобальной оптимизации процесса ККД на компьютере с процессором Pentium IV составило 2...16 минут, а время вычислений по модели этого процесса при ее параметрической оптимизации составило 7...10 мс на цикл прогноза, что значительно меньше периодичности изменения режимов функционирования процессов рудоподготовки, которые составляют несколько часов.

Общее время проведения структурно-параметрической идентификации для процесса ККД на компьютере с процессором Pentium IV с учетом всех характеристик согласно методике составляет 1,5...2 часа, что предполагает значительные затраты вычислительных ресурсов для структурно-параметрической идентификации в автоматизированных системах управления этими процессами. Поэтому нецелесообразно проводить процесс структурно-параметрической идентификации постоянно, в режиме реального времени, а целесообразно планирование ее выполнения. Данные исследования являются обоснованием предложенного комплексного метода идентификации процессов крупного дробления и самоизмельчения руд, рассмотренного в разделе 2.

Полученные оптимальные значения структурных характеристик и параметров разработанной интеллектуальной прогнозирующей модели процесса ККД приведены в приложении А.

3.4.3. Разработка интеллектуальной прогнозирующей модели процесса МСИ.

Пусть прогнозирующая модель ОУ процесса МСИ (согласно рис. 1.3.б) имеет вид:

$$\hat{Q}_{zom}[m+n] = \Phi_{\hat{Q}}\{Q_{zom}[m], \rho_k[m], \varphi[m], \Delta_m[m], \Gamma_p[m], q[m], \xi[m], a_Q[m], m\}, \quad (3.5)$$

где $\rho_k[m]$ – плотность слива классификатора; $\Delta_m[m]$ – отношение твердое/жидкое в мельнице; m – текущий такт времени с соответствующими глубинами памяти; n – глубина прогноза.

В качестве критерия параметрической оптимизации для процесса МСИ использовался критерий регулярности вида (в соответствии с (2.30), вычисляемый на проверочной выборке):

$$C_{регМСИ} = \frac{\|Q_{zomB}[m+n] - \hat{Q}_{zomB}[m+n]\|}{\|Q_{zomB}[m+n]\|}, \quad (3.6)$$

где $Q_{zomB}[m+n]$ – производительность по готовому классу, вычисляемая на выборке B , $\hat{Q}_{zomB}[m+n]$ – выходы моделей, которые обучены на выборке B .

В качестве критерия структурной оптимизации для процесса МСИ использовался комбинированный критерий вида:

$$C_{комбМСИ} = 0,2 \cdot C_{регМСИ} + 0,8 \cdot C_{смМСИ}, \quad (3.7)$$

где $C_{смМСИ}$ – критерий несмещенности, который для процесса МСИ имеет вид:

$$C_{смМСИ} = \frac{\|\hat{Q}_{zomA}[m+n] - \hat{Q}_{zomB}[m+n]\|}{\|Q_{zom}[m+n]\|}, \quad (3.8)$$

где $\hat{Q}_{zomA}[m+n]$ – выходы моделей, которые обучены на выборке A . Вычисление критерия $C_{смМСИ}$ осуществляется на всей выборке N .


Исследования эффективности типов структур модели процесса МСИ выполнялось [9, 87] с помощью разработанной программы в среде Matlab.

Для моделирования процесса МСИ в качестве входного сигнала использовался полигармонический корреляционный нормированный сигнал с гауссовским шумом амплитудой 10% от уровня сигнала, а сам процесс МСИ моделировался ПИТ2 звеном (см. рис. 1.4). При этом, глубины памяти и прогноза, а также размер реализации аналогичны данным для процесса ККД при исследовании вариации типа структур моделей.


В качестве критерия оценки моделей выбран критерий регулярности (3.6), а в качестве типов структур применялись модели Винера, Гаммерштейна, Гаммерштейна-Винера и ARX с базисными функциями в виде каскадной НС прямого распространения, вейвнета (НС с функциями активации в виде вейвлет) и полинома Колмогорова-Габора.

Результаты идентификации ОУ со структурой модели ARX и базисными функциями в виде вейвнета и каскадной НС (2.34) приведены на рис. 3.13,а. При этом значения критерия (3.6) составили 0,1279 для вейвнета и 0,089 для каскадной НС.

Результаты идентификации ОУ со структурой модели Гаммерштейна-Винера и базисными функциями в виде вейвнета и полинома Колмогорова-Габора приведены на рис. 3.13,б. При этом значения критерия (3.6) составили 0,0862 для вейвнета и 0,1734 для полинома Колмогорова-Габора.



a

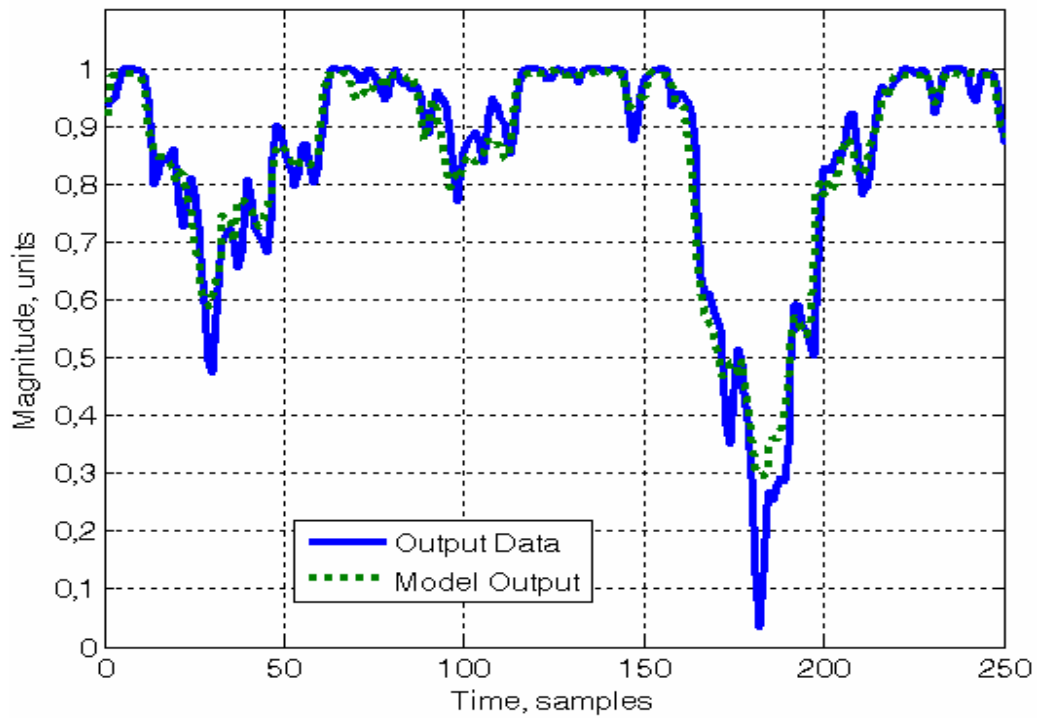


б


Рис. 3.13. Результаты идентификации процесса МСИ в виде моделей ARX (*a*) и Гаммерштейна-Винера (*б*)

Результаты идентификации ОУ с базисными функциями в виде вейвнет и со структурами моделей Винера и Гаммерштейна приведены на рис. 3.14, а для моделей Гаммерштейна-Винера и ARX – на рис. 3.15. Значения критерия регулярности (3.6) составили: для моделей Винера – 0,0871, Гаммерштейна – 0,1862

(см. рис. 3.14,*а-б*, соответственно), для моделей Гаммерштейна-Винера – 0,0862, ARX – 0,1279 (см. рис. 3.15,*а-б*, соответственно).




а




б

Рис. 3.14. Результаты идентификации процесса МСИ в виде моделей Винера (*а*) и Гаммерштейна (*б*)



a



б

Рис. 3.15. Результаты идентификации процесса МСИ в виде моделей Гаммерштейна-Винера (*a*) и ARX (*б*)

Время вычислений на компьютере с процессором Pentium IV по моделям со структурами Винера, Гаммерштейна и Гаммерштейна-Винера составило 7-10 мс на цикл прогноза, а по модели ARX – 0,2 мс [87], что не вносит временных ограничений на применение этих моделей в АСУТП рудоподготовки.

Таким образом, в результате проведенных исследований установлено, что в качестве структуры модели процесса МСИ предпочтительной является структура Гаммерштейна-Винера, поскольку она дает меньшие значения критерия регулярности (3.6) при различных базисных функциях [9, 87].

При разработке прогнозирующей модели процесса МСИ были проведены исследования, аналогичные исследованиям для процесса ККД (см. п. 3.4.2), с помощью разработанной программы в среде Matlab. Структура программы идентификации показана на рис. 4.2. ИД для решения этой задачи аналогичны описанным выше ИД для процесса МСИ при исследовании вариации типа структур моделей. Из особенностей этого процесса глубина прогноза была принята $n = 3$ такта, а глубина памяти по разным входам от 1 до 4.

В качестве критерия структурной оптимизации выбран комбинированный критерий (3.7), который имеет малую чувствительность к вариации шума и глубины прогноза (малый сдвиг глобального минимума в пространстве признаков).

При идентификации в качестве глобальных методов оптимизации применялись ГА, ПСП и МИО. При этом использовалась структура моделей Гаммерштейна-Винера с базисными функциями в виде НС: НСПР (каскадной НС и вейвнет) (2.34), НС РБФ (2.35) и НС Anfis (2.36).

Результаты глобальной оптимизации структуры модели процесса МСИ [9, 85] приведены на рис. 3.16.

Особенности алгоритмов глобальной оптимизации, а также структурные характеристики модели для их работы аналогичны процессу ККД (см. п. 3.4.2).

В результате моделирования (см. рис. 3.16) установлены характеристики алгоритмов глобальной оптимизации по скорости сходимости, быстродействию и наилучшей сходимости, которые аналогичны моделированию для процесса ККД (см. п. 3.4.2). При этом значения комбинированного критерия (3.7) при использовании алгоритма ПСП составили 0,009 в отличие от 0,042 при ГА и 0,047 при МИО.

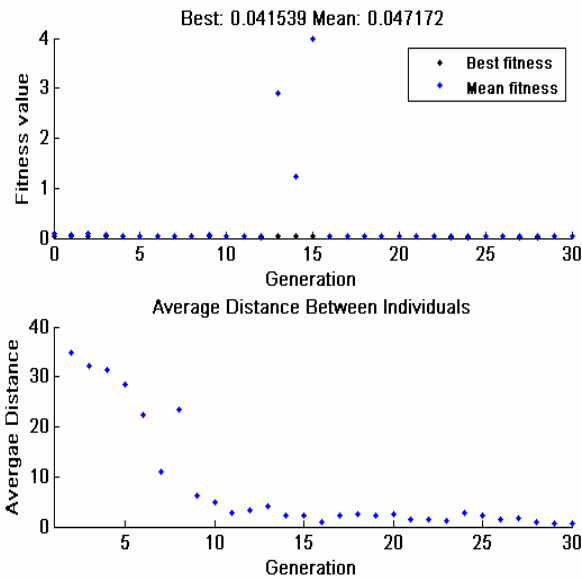
Результат структурно-параметрической идентификации процесса МСИ приведен на рис. 3.17.

В целом установлено, что минимуму комбинированного критерия для процесса МСИ отвечают базисные функции в виде каскадной НСПР. При этом количество нейронов в скрытом слое составляет 58, функция активации скрытого слоя – логистическая сигмоидальная, выходного слоя – линейная, алгоритм обучения НС – алгоритм Биеле-Пауэлла [69].


За меру точности параметрической идентификации моделей оптимальной структуры использовался критерий регулярности (3.6), значение которого составило для модели процесса МСИ – 0,0302, что меньше ошибки модели процесса МСИ, полученной с помощью композиционного метода идентификации (0,348 [8]).

Адекватность полученной интеллектуальной прогнозирующей модели процесса МСИ проверялась по непараметрическому критерию знаков [91]. Было установлено, что для уровня значимости 0,01 разработанная модель с иден-

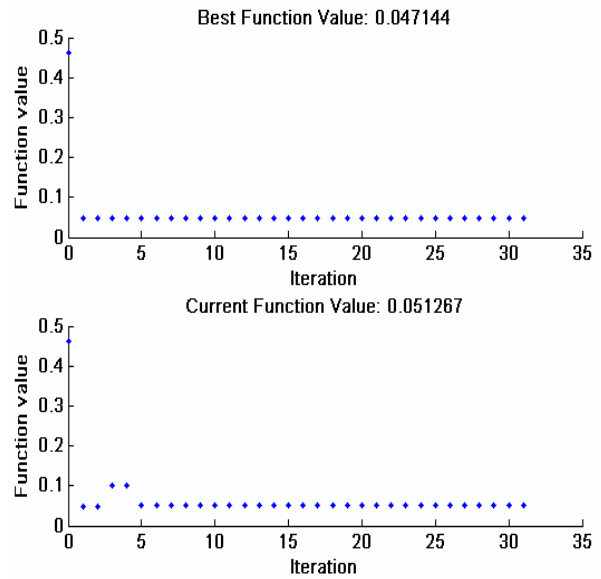
тифицированными структурой и параметрами адекватна динамике рассматриваемых процессов.



a



б



в

Рис. 3.16. Результаты глобальной оптимизации структуры модели процесса МСИ с помощью ГА (*a*), ПСП (*б*) и МИО (*в*)




Рис. 3.17. Результат идентификации процесса МСИ

Общее время поиска оптимальных решений при глобальной оптимизации, а также по модели процесса МСИ аналогично времени для процесса ККД, и также значительно меньше периодичности изменения режимов функционирования процессов рудоподготовки, которые составляют несколько часов.

Общее время проведения структурно-параметрической идентификации для процесса МСИ на компьютере с процессором Pentium IV с учетом всех характеристик согласно методике составляет 1,5...2 часа, что предполагает значительные затраты вычислительных ресурсов для структурно-параметрической идентификации в автоматизированных системах управления этими процессами. Поэтому нецелесообразно проводить процесс структурно-параметрической идентификации постоянно, в режиме реального времени, а целесообразно планирование его выполнения. Данные исследования являются обоснованием предложенного комплексного метода идентификации процессов крупного дробления и самоизмельчения руд, рассмотренного в разделе 2.

Полученные оптимальные значения структурных характеристик и параметров разработанной интеллектуальной прогнозирующей модели процесса МСИ приведены в приложении Б.

Выводы к разделу

1. Предложена методика структурно-параметрической идентификации нелинейных динамических процессов крупного дробления и самоизмельчения руд, которая состоит из процедур определения состояния этих процессов и их структурно-параметрической идентификации. Это позволяет, в отличие от известных методик, осуществлять идентификацию этих процессов в пакетном

режиме путем структурно-параметрической, а в режиме реального времени – параметрической оптимизации их моделей.

2. Разработан алгоритм определения изменения режимов работы процессов ККД и МСИ руд, который позволяет автоматизированно планировать выполнение их структурно-параметрической идентификации в случае, когда режим работы уже изменился или возникла тенденция к его изменению.

3. Разработаны алгоритмы глобальной и локальной оптимизации моделей процессов ККД и МСИ руд, которые реализуют процедуру структурно-параметрической идентификации путем их структурной и параметрической оптимизации.

3. В результате исследований эффективности идентификации характеристик процессов крупного дробления и самоизмельчения руд согласно предложенной методике, получены значения параметра Херста, глубины точного прогноза (корреляционного интервала предсказуемости) для них, а также глубины памяти по разным входам (размерности вложения аттрактора) для их моделей.

4. В результате исследований обоснована структура модели процесса ККД и установлено, что предпочтительной является структура Гаммерштейна-Винера, поскольку она дает меньшие значения критерия регулярности при различных базисных функциях (0,0334 для вейвнета и 0,0370 для полинома Колмогорова-Габора). Для структуры модели ARX значения критерия регулярности – 0,0644 для вейвнета и 0,0995 для каскадной НС, для структуры модели Винера – 0,0644 для вейвнета, а для структуры модели Гамерштейна – 0,0723 для вейвнета (рис. 6.2).

5. При глобальной оптимизации процесса ККД установлено, что ГА имеет самую высокую скорость сходимости (выходит в область оптимальных решений на первых поколениях, в то время как МИО – в среднем после 5 итераций, а ПСП – после 15 итераций); МИО выявил самое высокое быстроедействие (0,2 с на итерацию при 9,2 с на итерацию в ПСП и 16 с на поколение в ГА); ПСП выявил наилучшую сходимость в смысле комбинированного критерия (0,013, в то время для ГА – 0,022 и для МИО – 0,082).

6. Разработана интеллектуальная прогнозирующая модель процесса ККД, точность которой (значение критерия регулярности) 0,0311, а структурные характеристики – базисные функции в виде каскадной НСПР с 28 нейронами в скрытом слое, логистической сигмоидальной функцией активации скрытого слоя, линейной – выходного, алгоритмом обучения НС – метод Флетчера-Ривса.

7. В результате исследований обоснована структура модели процесса МСИ и установлено, что предпочтительной является структура модели Гамерштейна-Винера, поскольку она дает меньшие значения критерия регулярности при различных базисных функциях (0,0862 для вейвнета и 0,1734 для полинома Колмогорова-Габора). Для структуры модели ARX значения критерия регулярности – 0,1279 для вейвнета и 0,089 для каскадной НС, для структуры модели Винера – 0,0871 для вейвнета, а для Гамерштейна – 0,1862 для вейвнета.

8. При глобальной оптимизации процесса МСИ установлено, что ГА имеет самую высокую скорость сходимости (выходит в область оптимальных ре-

шений на первых поколениях, в то время как МИО – в среднем после 5 итераций, а ПСП – после 15 итераций); МИО выявил самое высокое быстродействие (0,2 с на итерацию при 9,2 с на итерацию в ПСП и 16 с на поколение в ГА); ПСП выявил наилучшую сходимость в смысле комбинированного критерия (0,009, в то время для ГА – 0,042 и для МИО – 0,047).

9. Разработана интеллектуальная прогнозирующая модель процесса МСИ, точность которой (значение критерия регулярности) 0,0302, а структурные характеристики – базисные функции в виде каскадной НСПР с 58 нейронами в скрытом слое, логистической сигмоидальной функцией активации скрытого слоя, линейной – выходного, алгоритмом обучения НС – метод Биеле-Пауэлла.

10. Установлено, что общее время проведения структурно-параметрической идентификации для процессов ККД и МСИ на компьютере с процессором Pentium IV учетом всех характеристик согласно методике составляет 1,5...2 часа, что предполагает значительные затраты вычислительных ресурсов для структурно-параметрической идентификации в автоматизированных системах управления этими процессами. Поэтому нецелесообразно проводить процесс структурно-параметрической идентификации постоянно, в режиме реального времени, а целесообразно его планирование. Данные исследования являются обоснованием предложенного комплексного метода идентификации процессов крупного дробления и самоизмельчения руд, использование которого позволяет снизить вычислительные затраты на идентификацию этих процессов, а также повысить точность моделей путем их своевременной адаптации для конкретного режима функционирования.

РАЗДЕЛ 4

ТЕХНИЧЕСКАЯ РЕАЛИЗАЦИЯ РЕЗУЛЬТАТОВ ИССЛЕДОВАНИЙ

4.1. Разработка алгоритмического и программного обеспечений АСУТП рудоподготовки

АСУ ТП реализуется посредством: информационного (ИО), алгоритмического (АО), программного (ПО), технического (ТО) и других видов обеспечений, которые представляют собой комплекс методов и средств, объединенных в соответствии со спецификой решаемых ими задач.

Решение задачи структурно-параметрической идентификации выполняется в АСУТП [9, 87] с использованием совокупностей:

- экспериментальных и справочных данных о состоянии ОУ (ИО);
- математических методов и алгоритмов решения задачи структурно-параметрической идентификации (АО);
- системных и прикладных программ решения задачи структурно-параметрической идентификации (ПО);
- технических средств получения, обработки, отображения и хранения информации (ТО).

Структура АО и ПО для решения задачи структурно-параметрической идентификации процессов рудоподготовки [87, 92] приведена на рис. 4.1.

АО и ПО для решения задачи структурно-параметрической идентификации процессов рудоподготовки (см. рис. 4.1) реализуют операции методики структурно-параметрической идентификации (см. п. 3.1), результатами которой являются интеллектуальные прогнозирующие модели управляемых процессов, а также алгоритмы и программы.

АО включает алгоритм определения изменения режима работы ОУ (см. п. 3.2), алгоритмы выбора и реализации методов глобальной оптимизации (см. п. 3.3.1), а также алгоритмы локальной оптимизации (выбора и реализации базисных функций и методов параметрической оптимизации (см. п. 3.3.2)).

Программа реализации структурно-параметрической идентификации ОУ в АСУ ТП рудоподготовки имеет структуру, показанную на рис. 4.2 [9, 78, 93].



Рис. 4.1. Структура АО и ПО для решения задачи идентификации ОУ в АСУТП рудоподготовки

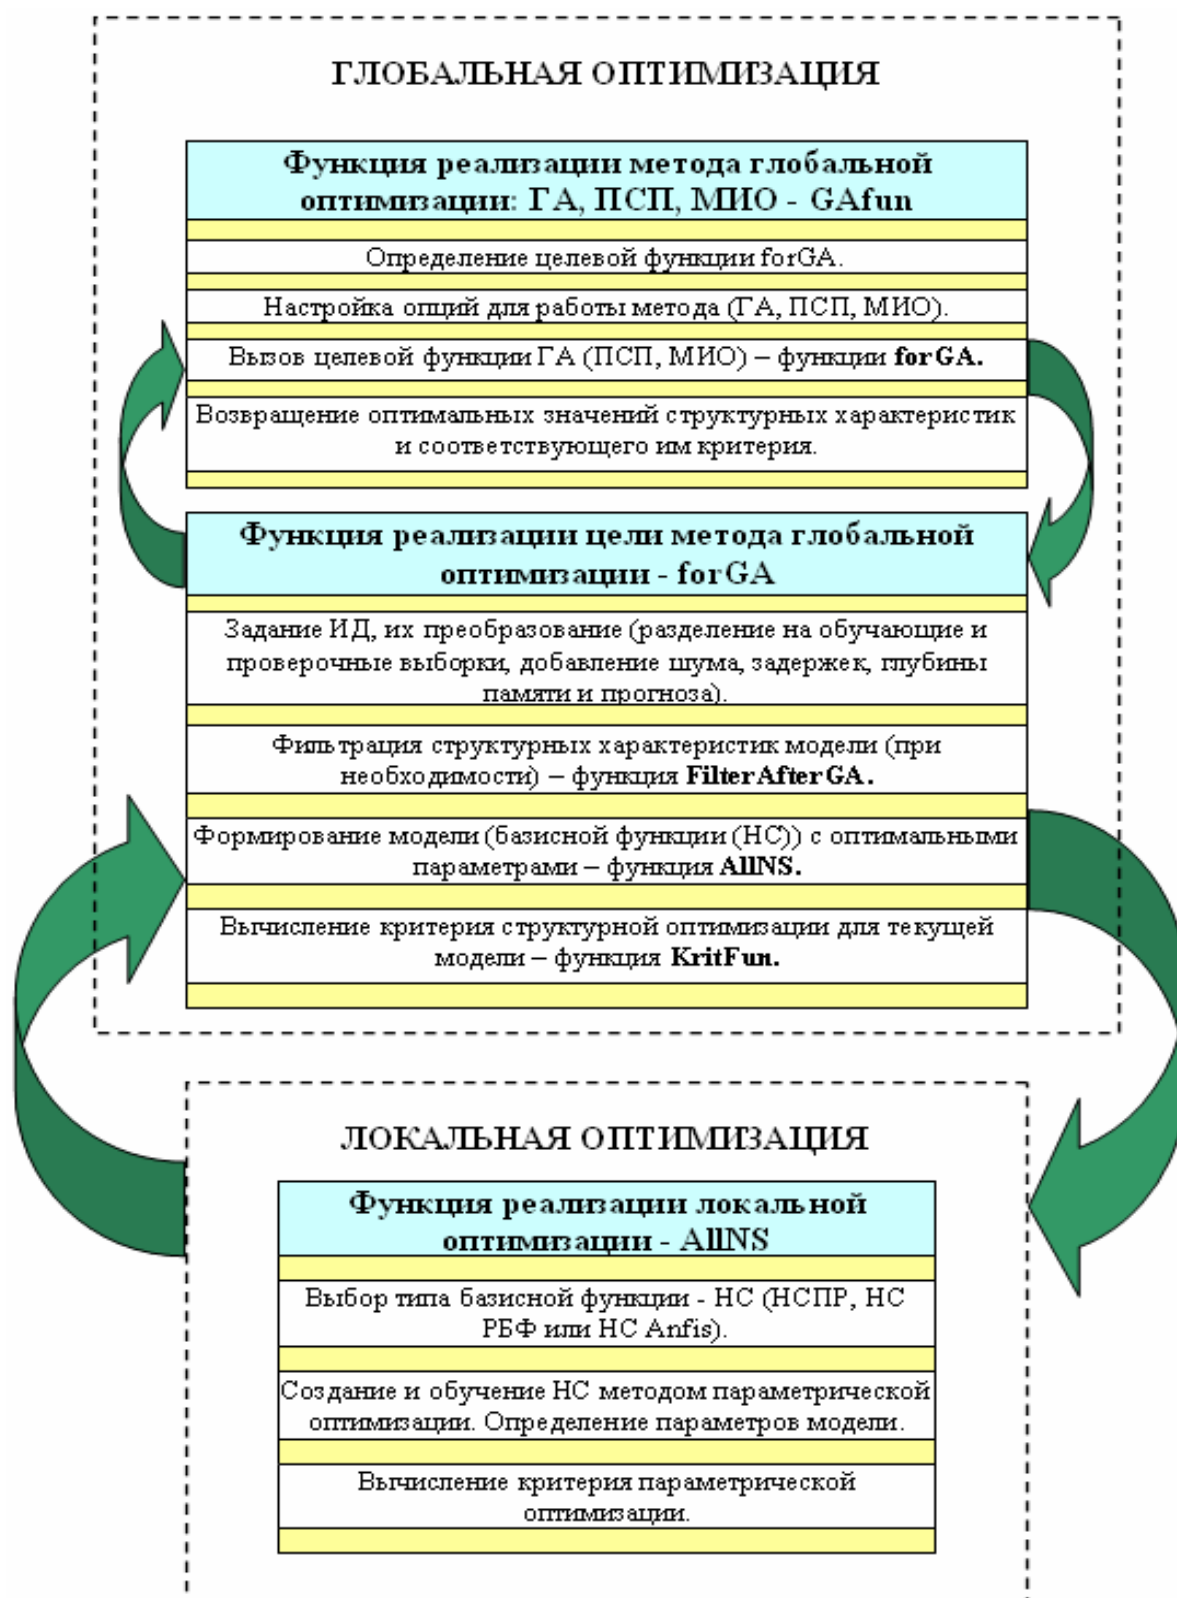


Рис. 4.2. Обобщенная структура программы реализации структурно-параметрической идентификации ОУ в АСУТП рудоподготовки

4.2. Экспериментальные исследования

4.2.1. Идентификация характеристик процесса ККД по экспериментальным данным.

Моделирование определения характеристик состояния процесса ККД проводилось в соответствии с предложенной методикой и с помощью стандартных [79] и разработанных программ в среде Matlab. В качестве идентифицируемых процессов использовались временные реализации крупности d_{ex} и крепости входной руды ρ (рис. 4.3) процесса ККД, полученные в условиях Ингулецкого ГОКа.




Рис. 4.3. Временные реализации сигналов d_{ex} (а) и ρ (б)

В результате расчетов [9, 94] определены значения показателя Херста для сигналов d_{ex} и ρ (рис. 4.4): $H_d = 0,0941 \pm 0,1144$ и $H_\rho = 0,2527 \pm 0,1712$, а также значения их фрактальной размерности: $D_d = 2 - H_d = 1,9059 \pm 0,1144$ и $D_\rho = 2 - H_\rho = 1,7473 \pm 0,1712$.

Согласно полученным результатам для процессов, порождающих сигналы d_{ex} и ρ нет необходимости в проведении структурно-параметрической идентификации, достаточно параметрической. Однако, поскольку для них еще не определены оптимальные структуры моделей для текущего режима работы, то согласно алгоритму (см. рис. 3.2), вне зависимости от значений показателей Херста, для последовательностей d_{ex} и ρ необходимо провести их структурно-параметрическую идентификацию.




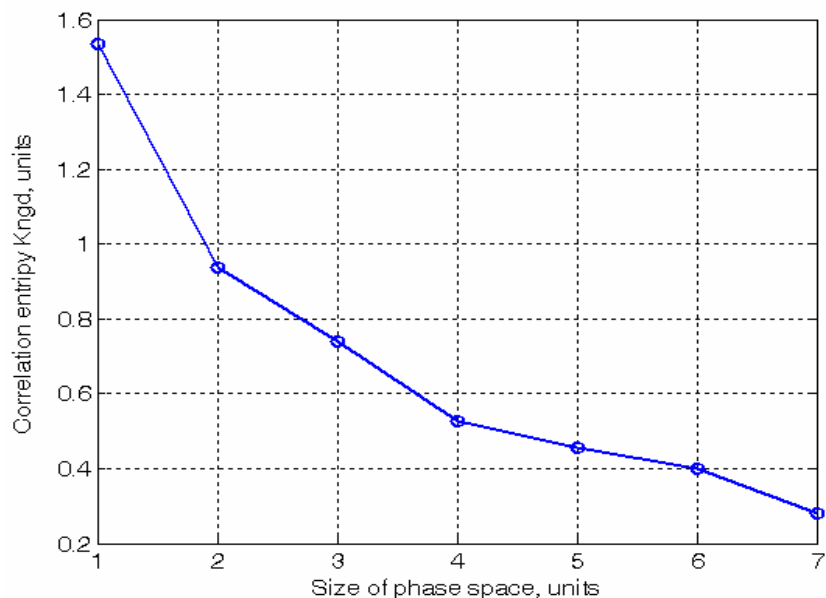
Рис. 4.4. Параметр Херста сигналов d_{ex} (а) и ρ (б)

В результате расчетов для сигналов d_{ex} и ρ определены значения корреляционной энтропии (рис. 4.5) и корреляционной размерности (рис. 4.6). Значения корреляционной энтропии составили: $K_{ngd}=0,280$ и $K_{ng\rho}=0,261$, а корреляционной размерности: $D_{ngd}=2,358$ и $D_{ng\rho}=2,499$, соответственно [94].


При этом корреляционные интервалы предсказуемости (глубины прогноза) процессов порождающих сигналы d_{ex} и ρ в соответствии с выражением (2.20) составили: $T_{vgd}=5,71$ такта и $T_{vg\rho}=6,13$ такта, что подтверждает хорошую прогнозируемость исследуемых сигналов, и соответственно, отсутствие необходимости выполнения структурно-параметрической идентификации процессов, их порождающих.

Для определения размерности фазового пространства вложения аттрактора (режима работы порождающего процесса) вычислялась ее оценка сверху по выражению (2.21). Для сигналов d_{ex} и ρ_{ex} ее значения составили $d_d \leq 5,7$ и

$d_\rho \leq 6$. Оценка значения d снизу определялась по рис. 4.6. Из анализа рис. 4.6 видно, что размерности D_{ngd} и $D_{ng\rho}$ практически перестают возрастать (входят в насыщение) при размерностях фазового пространства $d_d \geq 4$ и $d_\rho \geq 4$, соответственно. С учетом вышеизложенного, получим, что $D_{ngd} \cong 2,062$ и $D_{ng\rho} \cong 1,939$, а также $4 \leq d_d \leq 6$ и $4 \leq d_\rho \leq 6$.




a




б

Рис. 4.5. Корреляционная энтропия для сигналов d_{ex} (а) и ρ (б)

Таким образом [9, 94], для решения задачи идентификации процессов, порождающих сигналы d_{ex} и ρ , глубина прогноза для них составляет 6 тактов, а глубина памяти по разным входам – от 4 до 6.



a



б

Рис. 4.6. Корреляционная размерность для сигналов d_{ex} (а) и ρ (б)

4.2.2. Оценка эффективности управления процессом ККД по разработанной модели.

В работах [8, 32] предложены системы управления процессом ККД (рис. 4.7), которые используют прогнозирующую модель в контуре управления. В таких системах входная руда после дробления в КД через промежуточный бункер (ПБ) с помощью пластинчатых питателей поступает на конвейер 1 и далее в накопительный бункер (НБ). Из НБ руда затем подается в мельницу самоизмельчения (МС), готовый продукт которой в сливе спирального классификатора (СК) подается на обогащение.

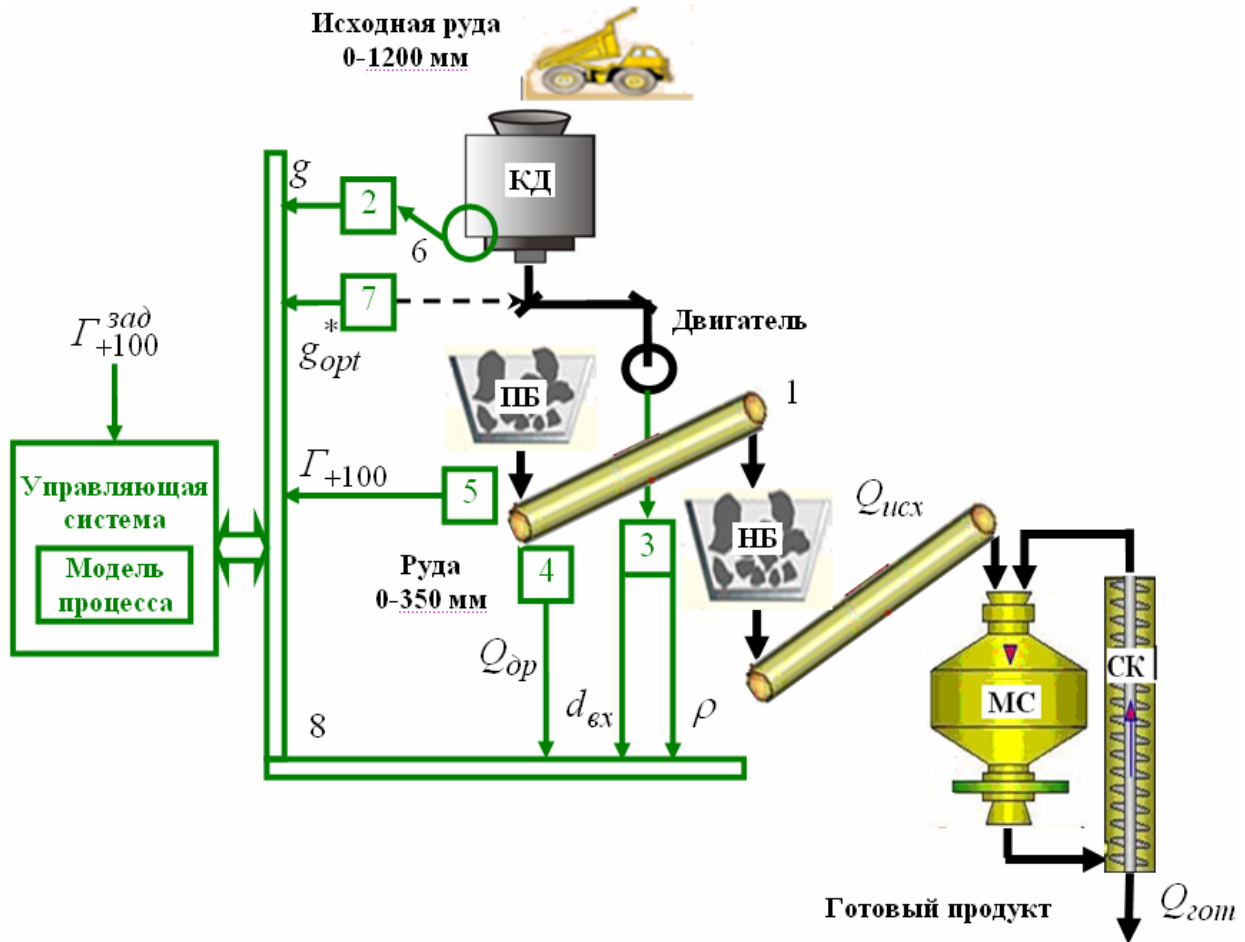


Рис. 4.7. Схема системы адаптивного управления процессом ККД

В качестве МК на первой обогатительной фабрике Лебединского ГОКа используются мельницы типа ММС 70x23. При этом порция руды, загружаемая в отдельный накопительный бункер, превышает количество руды, продраблываемой за такт управления. Время измельчения руды, продрабленной за один такт управления (2 думпкара) с учетом проектной загрузки думпкаров $P_{\partial}^n = 105$ т и проектной производительности мельницы по исходной руде $Q_{исх}^n = 188$ т/час, равно $T_{изм} = 2 \cdot P_{\partial}^n / Q_{исх}^n = 210 / 118 = 1,8$ час.

Поскольку постоянные времени мельницы ММС 70x23 не превышают десятков минут, то такту управления процессом крупнокускового дробления соответствует период работы мельницы, за который ее можно считать статическим объектом [10]. Это позволяет воспользоваться статической зависимостью производительности мельницы по исходной руде от содержания в ней класса +100 мм $Q_{исх}(\Gamma_{+100})$ [95], экспериментально полученной в условиях Лебединского ГОКа для работающей в замкнутом цикле мельницы ММС 70x23, которая представлена на рис. 4.8, и аппроксимируется уравнением параболы:

$$Q_{исх} = -7,96 \cdot 10^{-2} \cdot \Gamma_{+100}^2 + 9,07 \cdot \Gamma_{+100} - 130,6. \quad (4.1)$$

Тогда средняя производительность по исходной руде за время наблюдения определяется как:

$$\bar{Q}_{ucx} = 1/m \sum_{i=1}^m Q_{ucx,i}; \quad (4.2)$$

$$Q_{ucx,i} = -7,96 \cdot 10^{-2} \cdot (\Gamma_i)^2 + 9,07 \cdot \Gamma_i - 130,6, \quad (4.3)$$

где m – количество тактов за время наблюдения; Γ_i – усредненное за такт управления значение содержания класса +100 мм в дробленой руде.




Рис. 4.8. Зависимость производительности мельницы ММС 70x23 по входной руде от содержания в ней класса +100 мм

Управляющая система выполняет оценку текущего состояния процесса ККД до момента начала очередного интервала управления. Для этого осуществляется опрос и усреднение за предыдущий интервал показания устройства 2 контроля ширины щели (g), устройства 3 контроля крупности и крепости входной руды (d_{ex}, ρ), конвейерных весов 4 (Q_{op}), а также гранулометра 5 (Γ_{+100}).

Целью управления является стабилизация содержания класса +100 мм в дробленой руде:

$$\bar{\varepsilon} = \left\| \Gamma_{+100} - \Gamma_{+100}^{зад} \right\| \rightarrow \min . \quad (4.4)$$

Далее выполняется идентификация прогнозирующей модели процесса ККД согласно алгоритмам, приведенным в п. 3.2, 3.3. Сначала выполняется структурно-параметрическая оптимизация модели процесса ККД (выбор оптимальной структуры модели для текущего режима функционирования КД, а за-

тем обучение модели). Далее, в текущем режиме выполняется адаптация параметров модели процесса ККД с вычислением ее погрешности и параметра Херста. Если погрешность модели меньше некоторого допустимого значения ($\varepsilon \leq \varepsilon_{don}$) и параметр Херста $H < 0,5$, то переходят к прогнозированию процесса ККД на заданный интервал управления. А если нет, то планируется выполнение структурно-параметрической идентификации [9].

По оценкам и прогнозу процесса ККД определяется значение изменения ширины разгрузочной щели дробилки $6 g_{opt}^*$ на следующий интервал, которое обрабатывается гидравлической системой 7 регулирования щели. Устройства 2-7 связаны с управляющей системой с помощью информационной шины 8.

Глубина прогноза модели выбирается из условия ее превышения суммы времени транспортирования руды (времени запаздывания) через конусную дробилку ККД-1500, бункер ПБ и конвейер 1 к месту контроля гранулометра 5, а также времени поиска управления g_{opt}^* и времени его отработки исполнительным механизмом 7.

Оценка эффективности системы управления технологическим процессом ККД с разработанной в разделе 3 интеллектуальной прогнозирующей моделью процесса выполнялась путем ее имитационного моделирования в среде Matlab с помощью разработанной программы [9].

В качестве характеристики гранулометрического состава входной руды использовалась средневзвешенная крупность d_{ex} , а в качестве характеристики выходной руды $\Gamma_{вых}$ – содержание класса +100 мм Γ_{+100} . Качество входной руды (ее крупность d_{ex} и крепость ρ) моделировалось генераторами возмущений с корреляционными функциями и статистическими характеристиками, определенными по экспериментальным последовательностям, а процесс ККД моделировался нелинейным конечно-разностным уравнением [29]. Ошибки измерения качества входной руды принимались на уровне 10% (гауссовская модель шума с уровнем 0,1 от уровня сигналов). Нестационарность ОУ принималась на уровне 20% от номинальных значений его параметров за время наблюдения в 256 тактов (продолжительность цикла управления равнялась одному такту).

В системе управления для прогнозирования ОУ использовалась модель (ModelKKD) в виде каскадной НСПР с 28 нейронами в скрытом слое, логистической сигмоидальной функцией активации скрытого слоя, линейной – выходного, алгоритмом обучения НС – методом Флетчера-Ривса (см. п. 3.4.2).

Из особенностей процесса ККД глубина прогноза принималась $n = 3$ такта, а глубина памяти по разным входам от 1 до 4 тактов. Диапазоны значений входных (d_{ex} [130...330 мм], ρ [4...19 ед.]) и выходных (Γ_{+100} [30...70%]) переменных были занормированы в сигналы с уровнем 0...1. При этом значения ширины разгрузочной щели дробилки g ограничивались значениями $g_{min} = 160$ мм и $g_{max} = 240$ мм.

В качестве задания (Γ_{+100}) использовались значения $\Gamma_{+100}^{зад} = 57\%$, что соответствует оптимальному значению для Лебединского ГОКа [95]. Точность

идентификации и управления оценивались с помощью среднеквадратических ошибок $\bar{\varepsilon}$ и $\bar{\varepsilon}$ соответственно.

Результаты моделирования работы СУ процессом ККД в управляемом (Control) и неуправляемом (notControl) режимах приведены на рис. 4.9 [9].




Рис. 4.9. Результаты управления процессом ККД с разработанной моделью

Значения ошибок составили $\bar{\varepsilon}_{Control} = 0,036$ и $\bar{\varepsilon}_{notControl} = 0,108$, что определяет снижение среднеквадратичной ошибки в управляемом режиме в 3 раза. При этом ошибка прогнозирующей модели составила $\bar{\varepsilon}_{ModelKKD} = 0,021$. Следует отметить, что ошибки управления определяются ошибками прогнозирования.

Полученное повышение качества управления процессом ККД позволяет, согласно зависимости (рис. 4.8), повысить производительность по входной руде мельниц самоизмельчения типа ММС 70x23 на 6,45 т/ч. или на 5,3 % (что существенно лучше, чем в системах оптимизации, которые имеют в контуре управления известные модели [8], где снижение ошибки управления составляет в 2,5 раза, а повышение производительности – на 5,5 т/ч.).

Таким образом, система управления с разработанной интеллектуальной прогнозирующей моделью в контуре управления обеспечивает по сравнению с системами, которые имеют в контуре управления известные модели [8], снизить в 1,2 раза ошибку управления и повысить на 0,8 % или 0,95 т/ч производительность процесса мокрого самоизмельчения за счет стабилизации содержания класса +100 мм в его входной руде [9].

Выводы к разделу

1. Разработана структура алгоритмического и программного обеспечений для решения задачи идентификации ОУ в АСУТП рудоподготовки, которые реализуют процедуры методики структурно-параметрической идентификации (п. 3.1). Результатами реализации процедур этой методики являются интеллектуальные прогнозирующие модели данных процессов, алгоритмы и программы.

2. На основании предложенной структуры разработаны программы для решения задач идентификации нелинейных процессов дробления и измельчения руд.

3. С помощью разработанных программ проведены экспериментальные исследования эффективности идентификации характеристик процессов крупного дробления (крупности и крепости исходной руды, полученные в условиях Ингулецкого ГОКа), получены значения параметра Херста, глубины точного прогноза (корреляционного интервала предсказуемости) для них, а также глубины памяти (размерности вложения аттрактора) по разным входам для их моделей.

4. В результате оценки эффективности управления процессом ККД по разработанной модели установлено, что система управления с предложенной прогнозирующей моделью в контуре управления обеспечивает по сравнению с системами, которые имеют в контуре управления известные модели, снижение в 1,2 раза ошибки управления и повышения на 0,8 % или 0,95 т/ч производительности процесса самоизмельчения за счет стабилизации содержания класса +100 мм в его входной руде. Прогнозируемый годовой экономический эффект составляет 210,21 тыс. грн. с окупаемостью капитальных затрат 0,59 года.

ЗАКЛЮЧЕНИЕ

Предложенная работа является завершенным научным исследованием, в котором решена актуальная научная задача снижения ошибок идентификации процессов крупного дробления и самоизмельчения руд за счет вариации структур интеллектуальных прогнозирующих моделей в условиях изменения динамических режимов работы этих процессов, их параметров и наличия помех.

Установлено, что:

1. Вариация структур интеллектуальных прогнозирующих моделей при идентификации процессов крупного дробления и самоизмельчения руд, которая осуществляется путем определения их типов в условиях изменения динамических режимов работы управляемых процессов, обеспечивает выбор лучшей из них для текущего режима функционирования и позволяет, в отличие от известных подходов, получить модели со сниженными ошибками.

2. Определение тенденции к изменению режимов функционирования процессов крупного дробления и самоизмельчения руд, которое осуществляется путем анализа параметра Херста, указывает на необходимость проведения структурно-параметрической либо параметрической оптимизации интеллектуальных прогнозирующих моделей этих процессов, и позволяет, в отличие от известного, снизить требования к производительности вычислительных устройств и уменьшить вычислительные затраты на идентификацию.

Основные научные и практические результаты состоят в следующем:

1. Впервые исследованы различные динамические режимы работы процессов крупного дробления и самоизмельчения руд, и установлено, что оптимальная структура модели для одного режима функционирования не обеспечивает допустимую ошибку для других режимов. Это определяет, в отличие от известного, необходимость проведения структурно-параметрической идентификации управляемых процессов при изменении их режимов работы.

2. Впервые обоснован выбор типа структур моделей процессов крупного дробления и самоизмельчения руд путем исследования вариации их типов, и установлено, что лучшей для них в смысле критерия регулярности является структура Гаммерштейна-Винера (установлено, что для процесса крупного дробления его значения составляют 0,0334 для вейвнета и 0,0370 для полинома Колмогорова-Габора, а для процесса самоизмельчения – 0,0862 для вейвнета и 0,1734 для полинома Колмогорова-Габора). Это позволяет, в отличие от известного, повысить точность идентификации для разных режимов функционирования со снижением ошибок интеллектуальных прогнозирующих моделей. Установлено, что общее время проведения структурно-параметрической идентификации этих процессов составляет 1,5...2 часа.

3. Получил дальнейшее развитие композиционный метод идентификации процессов крупного дробления и самоизмельчения руд путем включения в него определения тенденции перехода этих процессов из одного режима функционирования в другой с помощью анализа параметра Херста. Это позволяет сни-

зять вычислительные затраты на процедуру идентификации путем планирования выполнения структурной оптимизации моделей.

4. Впервые получены интеллектуальные прогнозирующие модели процессов крупного дробления и самоизмельчения руд, которые, в отличие от известных, имеют оптимальную структуру для текущего режима работы, что позволяет снизить ошибки моделей и повысить качество управления этими процессами. Установлено, что ошибки моделей (значение критерия регулярности) процессов крупного дробления и самоизмельчения руд составляют 0,0311 и 0,0302, соответственно.

5. Установлено, что система адаптивного управления процессом ККД с разработанной моделью в контуре управления обеспечивает по сравнению с системами, имеющими в контуре управления известные модели, снижение в 1,2 раза ошибки управления и повышения на 0,8 % или 0,95 т/ч производительности процесса самоизмельчения за счет стабилизации содержания класса +100 мм в его входной руде. Прогнозируемый годовой экономический эффект составляет 210,21 тыс. грн. с окупаемостью капитальных затрат 0,59 года.

6. Разработана методика идентификации процессов крупного дробления и самоизмельчения руд, которая включает процедуры определения изменения режимов работы этих процессов и вычисления их размерностей, а также структурно-параметрическую идентификацию. Это позволяет, в отличие от известного, выполнять идентификацию управляемых процессов в режиме реального времени путем параметрической, а в пакетном режиме – структурно-параметрической оптимизации их моделей.

7. Разработан алгоритм определения изменения режимов работы процессов крупного дробления и самоизмельчения руд, который реализует переход к выполнению их структурно-параметрической идентификации по критерию тенденции перехода из одного режима функционирования в другой (параметром Херста) и погрешностью параметрической адаптации. Это позволяет выполнять структурно-параметрическую идентификацию в случае, когда возникла тенденция к изменению режима работы (при $H > 0,5$) или когда он уже изменился (при $\varepsilon > 10\%$).

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Справочник по обогащению руд. Подготовительные процессы / Под ред. О.С. Богданова, В.А. Олевского. – М.: Недра, 1982. – 366 с.
2. Остапенко П.Е. Обогащение железных руд / Остапенко П.Е. – М.: Недра, 1977. – 272 с.
3. Яшин В.П. Теория и практика самоизмельчения / В.П. Яшин, А.В. Бортников. – М.: Недра, 1978. – 229 с.
4. Барский Л.М. Системный анализ в обогащении полезных ископаемых / Л.М. Барский, В.З. Козин. – М.: Недра, 1978. – 486 с.
5. Справочник по проектированию рудообогатительных фабрик: В 2-х кн. / Под ред. О.Н. Тихонова. – М.: Недра, 1988. – 1 кн. – 374 с. – 2 кн. – 341 с.
6. Андреев С.Е. Дробление, измельчение и грохочение полезных ископаемых / С.Е. Андреев, В.А. Перов, В.В. Зверевич. – М.: Недра, 1980. – 415 с.
7. Справочник по обогащению руд черных металлов / Под ред. С.Ф. Шинкоренко. – М.: Недра, 1980. – 527 с.
8. Корнієнко Валерій Іванович. Автоматизовані системи оптимального керування процесами крупного дроблення та самоздрібнювання руд : дис. ... д-ра. техн. наук : 05.13.07 / Корнієнко Валерій Іванович. – Дніпропетровськ, 2010. – 355 с.
9. Герасина Александра Владимировна. Идентификация технологических процессов крупного дробления и самоизмельчения руд с использованием вариации структур моделей : дис. ... к-та. техн. наук : 05.13.07 / Герасина Александра Владимировна. – Днепропетровск, 2012. – 198 с.
10. Марюта А.Н. Автоматическое управление технологическими процессами обогатительных фабрик / А.Н. Марюта, Ю.Г. Качан, В.А. Бунько. – М.: Недра, 1983. – 277 с.
11. Автоматизация технологических процессов на горнорудных предприятиях: Справочное пособие / Под ред. В.С. Виноградова. – М.: Недра, 1984. – 167 с.
12. Автоматизация управления обогатительными фабриками / Кошарский В.Д., Ситковский А.Я., Красномовец А.В. и др. – М.: Недра, 1977. – 527 с.
13. Троп А.Е. Автоматическое управление технологическими процессами обогатительных фабрик / А.Е. Троп, В.З. Козин, Е.В. Прокофьев. – М.: Недра, 1986. – 303 с.
14. Козин В.З. Автоматизация производственных процессов на обогатительных фабриках / В.З. Козин, А.Е. Троп, А.Я. Комаров. – М.: Недра, 1980. – 336 с.
15. Поркуян О.В. Идентификация объектов управления на основе моделей Гаммерштейна относительно к процессам магнитной сепарации / О.В. Поркуян // Вісник Криворізького технічного університету : зб. наук. праць. – № 19. – 2007. – С. 223-228.
16. Моркун В.С. Дискретный фильтр Калмана в алгоритме адаптивного управления процессами горного производства / В.С. Моркун // Разработка рудных месторождений. – Кривой Рог: КТУ. – 1996. – № 59. – С. 74-79.

17. Купін А.І. Інтелектуальна ідентифікація та керування в умовах процесів збагачувальної технології : Монографія / А.І. Купін. – Кривий Ріг: КТУ, 2008. – 204 с.
18. Herbst J. A. Modern Control Theory Applied to Crushing. Part 1 : Development of a Dynamic Model for a Cone Crusher and Optimal Estimation of Crusher Operating Variables / J. A. Herbst, A. E. Oblad // Proc. of the 1st IFAC Symposium on Automation for Mineral Resource Development. - Pergamon Press, Oxford, 1986. – P. 301-307.
19. Патент 51044 Україна, МПК В03В13/00. Система автоматичного керування процесом збагачення / В.М. Назаренко, М.В. Назаренко, Н.В. Смирнова, А.І. Купін. – Заявл. 19.12.2001; Опубл. 16.05.2005; Бюл. № 5. – 3 с.
20. Herbst J.A. Optimal Control of Comminution Operations / J.A. Herbst, F.A. Alba, W.T. Pate A.E. Oblad // International Journal of Mineral Processing. – 1988. – Vol. 22. – № 1-4. – P. 275-296.
21. Herbst J.A. Model-based control of mineral processing operations / J.A. Herbst, W.T. Pate, A.E. Oblad // Powder Technology. – 1992. – Vol. 69. P. 21-32. – ISSN 0032-5910.
22. SCADA TRACE MODE в АСУТП обогащення руди Северного ГОКа. – <http://www.tracemode.ua>.
23. Козин В.З. Опробование, контроль и автоматизация обогатительных процессов / В.З. Козин, О.Н. Тихонов. – М.: Недра, 1990. – 343 с.
24. Линч А. Дж. Циклы дробления и измельчения. Моделирование, оптимизация, проектирование и управление / Алан Джеймс Линч. – М.: Недра, 1981. – 343 с.
25. Марюта А.Н. Экспериментальное определение статических характеристик объектов управления обогатительных фабрик / А.Н. Марюта, В.А. Бунько. – М.: Недра, 1969. – 120 с.
26. Марюта А.Н. Автоматическая оптимизация процесса обогащения руд на магнитообогатительных фабриках / А.Н. Марюта. – М.: Недра, 1975. – 231 с.
27. Справочник по обогащению руд. Специальные и вспомогательные процессы, испытания обогатимости, контроль и автоматика / Под ред. О.С. Богданова, В.И. Ревнивцева. – М.: Недра, 1983. – 376 с.
28. Теория управления. Терминология. – М.: Наука, 1988. – Вып. 107. – 56 с.
29. Качан Ю.Г. Результаты идентификации процесса дробления по принципу самоорганизации / Ю.Г. Качан, В.И. Корниенко // Горн. электромеханика и автоматика: Респ. межвед. науч.-техн. сб. – 1988. – Вып. 53. – С. 32-38.
30. Качан Ю.Г. Алгоритмы расчета конструктивных параметров элементарных камер, матриц разрушения и классификации для тактовой имитационной модели конусной дробилки / Ю.Г. Качан // Обогащение полезных ископаемых. – Киев. 1985. – Вып. 35. – С. 34-41.
31. Качан Ю.Г. Обоснование тактово-имитационной модели дробления / Ю.Г. Качан. – Днепропетровск, 1983. – Деп. в УкрНИИНТИ, № 1294-Ук-83Деп.
32. Корниенко Валерий Иванович. Разработка средств автоматического контроля крупности и крепости исходной руды для системы оптимизации про-

цесса крупнокускового дробления: дисс. канд. техн. наук : 05.13.07 / Корниенко Валерий Иванович. – Днепропетровск, 1987. – 195 с.

33. Nelles O. Nonlinear System Identification: From Classical Approaches to Neural and Fuzzy Models / O. Nelles. – Berlin: Springer, 2001. – 785 p.

34. Ljung L. Identification of Nonlinear Systems / L. Ljung // Proceeding of the IEEE. – 2006. – № 6. – P. 1-10.

35. Кузнецов С.П. Динамический хаос / С.П. Кузнецов – М.: Физматлит, 2002. – 296 с.

36. Анищенко В.С. Знакомство с нелинейной динамикой / В.С. Анищенко // М.-Ижевск: ИКИ, 2002. – 172 с.

37. Шустер Г. Детерминированный хаос. Введение / Г. Шустер – М.: Мир, 1988. – 256 с.

38. Марюта А.Н. Теория моделирования колебаний рабочих органов механизмов и ее приложения / А.Н. Марюта. – Днепропетровск: Изд-во ДГУ, 1991. – 146 с.

39. Авторское свидетельство 856557 СССР, МКИ В 02 С 25/00 Способ управления процессом измельчения в промышленных барабанных мельницах / А.Н. Марюта (СССР). – № 3779909/29-33; заявл. 13.08.84; опубл. 23.06.86, Бюл. №23.

40. Авторское свидетельство 1238793 СССР, МКИ В 02 С 25/00 Способ управления технологией самоизмельчения руд в промышленных барабанных мельницах / А.Н. Марюта (СССР). – № 4059056/31-33; заявл. 22.04.86; опубл. 30.12.88, Бюл. №48.

41. Пановко Я.Г. Устойчивость и колебания упругих систем / Я.Г. Пановко, И.И. Губанова – М.: Наука, 1987. – 352 с.

42. Федер Е. Фракталы / Е. Федер. – М.: Мир, 1991. – 254 с.

43. Шелухин О.И. Фрактальные процессы. Монография / О.И. Шелухин, А.М. Тенякшев, А.В. Осин. – Под ред. О.И. Шелухина. – М.: Радиотехника, 2003. – 480 с.

44. Короленко П.В. Новационные методы анализа стохастических процессов и структур в оптике. Фрактальные и мультифрактальные методы, вейвлет-преобразования / П.В. Короленко, М.С. Маганова, А.В. Меснянкин. – М.: МГУ, НИИ ядерной физики, 2004. – 82 с.

45. Гольдин М.Л. Контроль и автоматизация процессов дробления и измельчения руд / М.Л. Гольдин. – М.: Атомиздат, 1971. – 387 с.

46. Моркун Н.В. Адаптивная система управления процессом магнитной сепарации железных руд / Н.В. Моркун // Вісник Криворізького технічного університету. – Кривий Ріг: КТУ. – 2004. - №3. – С.113-115.

47. Новицкий И.В. Идентификация барабанных мельниц самоизмельчения как объектов автоматической оптимизации / И.В. Новицкий // Металлургическая и горнорудная промышленность. – 1992. – № 3. – С. 52-53.

48. Воронов В.А. Многоуровневая оптимизация процессов обогащения / В.А. Воронов – М.: Недра, 1991. – 154 с. – ISBN 5-247-01454-5.

49. Зубов Д.А. Дискретные математические модели управления производственными процессами углеобогащительной фабрики / Д.А. Зубов // Вісник

Східноукраїнського національного університету ім. В.Даля. – 2002. – №2(48). – С. 206-209.

50. Ивахненко А.Г. Предсказание случайных процессов / А.Г. Ивахненко, В.Г. Лапа. – К.: Наукова думка, 1971. – 416 с.

51. Ивахненко А.Г. Долгосрочное прогнозирование и управление сложными системами / А.Г. Ивахненко. – К.: Техніка, 1975. – 312 с.

52. Mueller J.-A. Self-Organising Data Mining. An Intelligent Approach To Extract Knowledge From Data / J.-A. Mueller, F. Lemke. – Berlin, Dresden, 1999. – 225 p.

53. Ивахненко А.Г. Самоорганизация прогнозирующих моделей / А.Г. Ивахненко, Й.А. Мюллер. – К.: Техніка, 1985; Берлин: ФЕБ Ферлаг Техник, 1984. – 223 с.

54. Ивахненко А.Г. Помехоустойчивость моделирования / А.Г. Ивахненко, В.С. Степашко. – К.: Наук. думка, 1985. – 214 с.

55. Искусственный интеллект: применение в интегрированных производственных системах / Под ред. Э. Кьюсака. – М.: Машиностроение, 1991. – 544 с.

56. Фогель Л. Искусственный интеллект и эволюционное моделирование / Л. Фогель, А. Оуэнс, М. Уолш. – М.: Мир, 1969. – 230 с.

57. Букатова И.Л. Эволюционное моделирование и его приложения / И.Л. Букатова. – М.: Наука, 1979. – 232 с.

58. Дюк В. Интеллектуальный анализ данных: Data Mining / В. Дюк, А. Самойленко. – СПб.: Питер, 2001. – 368 с.

59. Букатова И.Л. Эвоинформатика: теория и практика эволюционного моделирования / И.Л. Букатова, Ю.И. Михасев, А.М. Шаров. – М.: Наука, 1991. – 206 с.

60. Емельянов В.В. Теория и практика эволюционного моделирования / В.В. Емельянов, В.В. Курейчик, В.М. Курейчик. – М.: ФИЗМАТЛИТ, 2003. – 432 с. – ISBN 5-9221-0337-7.

61. Генетические алгоритмы, искусственные нейронные сети и проблемы виртуальной реальности / Вороновский Г.К., Махотило К.В., Петрашев С.Н., Сергеев С.Н. – Харьков: Основа, 1997. – 112 с.

62. Holland J.H. Adaptation in natural and artificial systems. An introductory analysis with application to biology, control and artificial intelligence / J.H. Holland. – London: Bradford book edition, 1994. – 211 p.

63. Круглов В.В. Нечеткая логика и искусственные нейронные сети / В.В. Круглов, М.И. Дли, Р.Ю. Голунов. – М.: Физматлит, 2001. – 224 с.

64. Розенблатт Ф. Принципы нейродинамики. Перцептрон и теория механизмов мозга / Ф. Розенблатт. – М.: Мир, 1965. – 480 с.

65. Уоссермен Ф. Нейрокомпьютерная техника: теория и практика / Ф. Уоссермен – М.: Мир, 1992. – 237 с.

66. Фогель Л. Искусственный интеллект и эволюционное моделирование / Л. Фогель, А. Оуэнс, М. Уолш. – М.: Мир, 1969. – 230 с.

67. Тархов Д.А. Нейронные сети: модели и алгоритмы / Д.А. Тархов. – М.: Радиотехника, 2005. – 256 с.

68. Головкин В.А. Нейронные сети: обучение, организация и применение / В.А. Головкин. – М.: ИПРЖР, 2001. – 256 с.
69. Нейронные сети. MATLAB 6 / Под общ. ред. В.Г. Потемкина. – М.: ДИАЛОГ-МИФИ, 2002. – 496с.
70. Прикладные нечеткие системы / Под ред. Т.Тэрано, К.Асаи, М.Сугэно. – М.: Мир, 1993. – 368 с.
71. Змитрович А.И. Интеллектуальные информационные системы / А.И. Змитрович. – Минск: НТОО «Тетри Системз», 1997. – 368 с.
72. Штовба С.Д. Проектирование нечетких систем средствами Matlab / С.Д. Штовба. – М.: Горячая линия – Телеком, 2007. – 288 с. – ISBN 5-93517-359-X.
73. Корниенко В.И. Интеллектуальные методы структурно-параметрической идентификации технологических процессов рудоподготовки / В.И. Корниенко, А.В. Пивоварова // Гірнична електромеханіка та автоматика. – 2008. – Вип. 80. – С. 71-77. – ISSN 0201-7814.
74. Герасина А.В. Идентификация режимов работы нелинейных процессов рудоподготовки / А.В. Герасина, В.И. Корниенко // Гірнична електромеханіка та автоматика: Наук.-техн. зб. – 2010. – Вип. 85. – С. 82-90. – ISSN 0201-7814.
75. Корнієнко В.І. Методика ідентифікації нелінійних процесів рудопідготовки / В.І. Корнієнко, О.В. Герасіна // Гірнична електромеханіка та автоматика: Наук.-техн. зб. – 2009. – Вип. 82. – С. 77-85. – ISSN 0201-7814.
76. Засоби інтелектуальної ідентифікації і прогнозування нелінійних динамічних об'єктів керування / Г.В. Кузнецов, В.І. Корнієнко, Т.О. Бубнова, О.В. Герасіна // Системний аналіз та інформаційні технології – 2009: XI міжнародна науково-технічна конференція, 26-30 травня 2009, НТУУ «КПІ». – К.: 2009. – С. 332.
77. Ткалич С.А. Идентификация состояния стохастических систем / С.А. Ткалич, Е.М. Васильев // Электротехнические комплексы и системы управления. – 2008. – № 1. – С. 44-46.
78. Герасина А.В. Комплексный метод идентификации нелинейных процессов крупного дробления и самоизмельчения руд / А.В. Герасина // Збірник наукових праць НГУ – 2011. – №. 36, т. 1 – С. 150-157.
79. Сычев В. Фрактальный анализ. Программа Fractan 4.4. – <http://impb.ru/~sychyov/>
80. Малинецкий Г.Г. Современные проблемы нелинейной динамики / Г.Г. Малинецкий, А.Б. Потапов // М.: Эдиториал УРСС, 2000. – 336 с. – ISBN 5-8360-0110-3.
81. Анищенко В.С. Сложные колебания в простых системах: Механизмы возникновения, структура и свойства динамического хаоса в радиофизических системах / В.С. Анищенко // М.: Наука, 1990. – 312 с. – ISBN 5-02-014168-2.
82. Колмогоров А.Н. // ДАН СССР. 1959. Т. 124. С. 754.
83. Справочник по теории автоматического управления / Под ред. А.А. Красовского, – М.: Наука, 1987. – 712 с.

84. Кузнецов Г.В. Композиційна структурно-параметрична ідентифікація нелінійних динамічних об'єктів керування / Г.В. Кузнецов, В.І. Корнієнко, О.В. Герасіна // Наукові вісті НТУУ КПІ. – 2009. – № 5. – С.69-75. – ISSN 1810-0546.
85. Герасіна О.В. Алгоритми глобальної і локальної оптимізації в задачі ідентифікації складних динамічних систем / О.В. Герасіна, В.І. Корнієнко // Системи обробки інформації – 2010. – № 6(87). – С. 73-77. – ISSN 1681-7710.
86. Ивахненко А.Г. Индуктивный метод самоорганизации моделей сложных систем / А.Г. Ивахненко – Киев: Наук. думка, 1981. – 296 с.
87. Герасина А.В. Идентификация объектов управления в АСУТП рудо-подготовки / А.В. Герасина, В.И. Корниенко // Науковий вісник Національного гірничого університету. – 2010. – № 10. – С. 102-106. – ISSN 2071-2227.
88. Льюнг Л. Идентификация систем. Теория для пользователя / Л. Льюнг; [Под ред. Я.З. Цыпкина]. – М.: Наука, 1991. – 432 с. – ISBN 5-02-014511-4.
89. Герасина А.В. Методика идентификации и алгоритм определения состояния нелинейных динамических объектов управления / А.В. Герасина // Системи управління, навігації та зв'язку – 2011. – № 2(18). – С. 78-82. – ISSN 2073-7394.
90. Дьяконов В.П. MATLAB. Анализ, идентификация и моделирование систем. Специальный справочник / В.П. Дьяконов, В.В. Круглов – С.-Пб.: Питер, 2001. – 448 с.
91. Ван дер Варден Б.Л. Математическая статистика / Б.Л. ван дер Варден – М: Иностранная литература, 1960 – 450 с.
92. Герасина А.В. Исследование точности идентификации объектов управления в АСУТП рудоподготовки / А.В. Герасина, В.И. Корниенко // Сборник научных трудов по материалам международной научно-практической конференции «Научные исследования и их практическое применение. Современное состояние и пути развития '2010», т. 2 «Технические науки», 04-15 октября 2010. – Одесса: Черноморье, 2010. – С. 46-48. – ISBN 966-555-152-3.
93. Герасина А.В. Программная реализация структурно-параметрической идентификации процессов рудоподготовки / А.В. Герасина // Materialy VII miedzynarodowej naukowo-praktycznej konferencji «Strategiczne pytania swiatowej nauki – 2011», t. 13, 07-15 lutego 2011. – Przemysl: «Nauka i studia», 2011. – S. 22-23. – ISBN 978-966-8736-05-6.
94. Герасина А.В. Идентификация характеристик нелинейных динамических процессов рудоподготовки / А.В. Герасина // Материали за VII международна научна практична конференция «Найновите научни постижения - 2011», т. 17 «Технологии», 17-25 март 2011. – София: «Бял ГРАД-БГ», 2011. – С. 58-59. – ISBN 978-966-8736-05-6.
95. Семунькин М.Б. Влияние кусковатости руды на производительность мельниц самоизмельчения / М.Б. Семунькин // Комплексное развитие КМА. – Губкин: НИИКМА им. Л.Д.Шевякова, 1978. – Вып. 2. – С. 84-90.

Приложение А

Интеллектуальная прогнозирующая модель процесса ККД

А.1. Структура интеллектуальной прогнозирующей модели процесса ККД

Структурные характеристики интеллектуальной прогнозирующей модели процесса ККД приведены в табл. А.1.

Таблица А.1

Структурные характеристики модели процесса ККД

T_s	P	P_{pr}	$F_{\bar{y}}$	F_l	r_s	M_{po}
Гаммерштейна-Винера	1 - 4	3	Линейная	Логистическая сигмоидальная	28	Метод Флетчера-Ривса

В табл. А.1 использовались следующие обозначения (согласно выражению (2.35)): T_s – тип структуры модели, P – глубина памяти, P_{pr} – глубина прогноза, $F_{\bar{y}}$ – функция активации выходного слоя, F_l – функция активации скрытого слоя, r_s – размер скрытого слоя, M_{po} – метод параметрической оптимизации.

Развернутая информация о структуре нейросетевой модели процесса ККД представлена на рис. А.1- А.3.



Рис. А.1. Структура модели процесса ККД

На рис. А.1 использовались следующие обозначения: $x\{1\}$ – вход сети, $y\{1\}$ – выход сети, Neural Network – НСПР (2.35). Блок Neural Network представляет собой НС, структура которой показана на рис. А.2.




Рис. А.2. Структура НС модели процесса ККД

Структуры слоев Layer 1 и Layer 2 показаны на рис. А.3 (слой Layer 1 – скрытый слой).

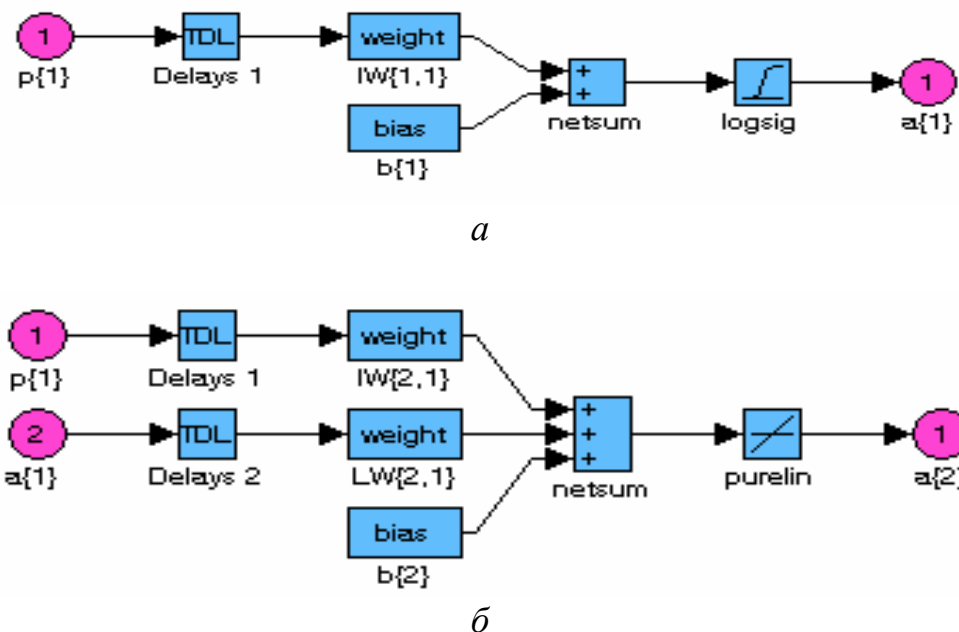


Рис. А.3. Структура слоев Layer 1 (а) и Layer 2 (б) НС модели процесса ККД

На рис. А.2 и А.3 использовались следующие обозначения: $p\{1\}$ – вход 1 на слой 1 и 2; $a\{1\}$ и $a\{2\}$ – выход слоя 1 и 2; Delays 1, 2 – линии задержки для входов 1 и 2 соответственно; IW – матрица весов входов; LW – матрица весов связей слоев 1 и 2; b – вектор смещения для слоев 1 и 2; netsum – сумматор; logsig и purelin – функции активации слоев 1 и 2.

А.2. Параметры интеллектуальной прогнозирующей модели процесса ККД

Параметрами НС модели процесса ККД являются матрицы весов IW и LW , вектор смещений b , а также задержки Delays (см. рис. А.3,а и б).

Матрица весов входного слоя IW состоит из двух матриц: $IW\{1,1\}$ размером $[28 \times 3]$ – матрицы весов связей трех входов со слоем 1 сети, состоящим из 28 нейронов, и $IW\{2,1\}$ размером $[1 \times 3]$ – матрицы весов связей входов сети со слоем 2 сети, состоящим из 1 нейрона. Каждый вход сети соответствует входным параметрам процесса ККД: средневзвешенная крупность и крепость исходной руды, а также ширина разгрузочной щели дробилки. Значение матрицы $IW\{1,1\}$ представлено в табл. А.2, а значение матрицы $IW\{2,1\}$ – в табл. А.3.

Матрица весов промежуточного слоя LW (см. рис. А.3,б) состоит из матрицы: $LW\{2,1\}$ размером $[1 \times 28]$ – матрицы весов связей слоя 1 с слоем 2 сети. Значение матрицы $LW\{2,1\}$ представлено в табл. А.4.

Вектор смещений b (см. рис. А.3,а и б) состоит из двух векторов: $b\{1\}$ размером $[28 \times 1]$ – вектора смещений для слоя 1 сети, и $b\{2\}$ размером $[1 \times 1]$ –

вектора смещений для слоя 2 сети. Значение вектора $b\{1\}$ представлено в табл. А.5. Значение вектора $b\{2\} = -0.1860$.

Таблица А.2

Весовые коэффициенты $IW\{1,1\}$ НС модели процесса ККД

$IW[1:14x1]$	$IW[15:28x1]$	$IW[1:14x2]$	$IW[15:28x2]$	$IW[1:14x3]$	$IW[15:28x3]$
-6.9387	4.0903	4.7578	-4.0169	1.4272	6.2622
-6.8885	-6.0241	0.7037	-4.8787	-4.8676	3.4166
5.3564	7.1381	-5.2893	-4.5834	3.7258	-0.1631
3.5633	7.9610	6.7888	-1.9283	3.2914	2.2993
2.5508	-0.2604	6.4921	-4.9172	-4.8368	-6.8819
-1.0811	-1.3152	1.1093	8.3252	-8.3287	-0.7812
1.6656	-0.9668	4.3160	-1.2774	-7.1097	8.3468
-6.0285	-4.4099	2.4917	-7.1810	-5.2694	1.0712
5.2781	0.1594	-6.5690	8.5394	-1.6025	0.3437
-7.0713	0.1725	-4.5937	7.3778	-0.1117	-4.1319
3.4802	8.3449	-0.5480	-1.6051	-7.7368	-0.2919
-5.6319	4.9781	-4.7985	-6.5668	-4.2249	2.0950
-2.4410	3.6768	6.0968	-6.1595	5.3936	4.5637
1.7463	-5.6044	-4.5961	-4.2073	-6.9320	-4.7136

Таблица А.3

Весовые коэффициенты $IW\{2,1\}$ НС модели процесса ККД

$IW[1x1]$	$IW[1x2]$	$IW[1x3]$
-0.4350	0.8467	-0.7748

Таблица А.4

Весовые коэффициенты $LW\{2,1\}$ НС модели процесса ККД

$LW [1x1:6]$	0.5238	0.3492	0.0951	0.0010	-0.2387	-0.4389
$LW [1x7:12]$	0.2075	-0.6030	0.2359	-0.9488	-0.4386	0.6201
$LW [1x13:18]$	0.0428	0.0133	0.5206	0.3191	0.1467	0.3826
$LW [1x19:24]$	-0.1515	-0.2897	0.1356	-0.0413	-0.3715	0.3457
$LW [1x25:28]$	-0.0965	-0.1067	0.3779	0.4615		

Таблица А.5

Вектор смещений $b\{1\}$ НС модели процесса ККД

$b[1:5x1]$	$b[6:10x1]$	$b[11:15x1]$	$b[16:20x1]$	$b[21:25x1]$	$b[26:28x1]$
8.4583	5.3996	-2.2011	-0.9756	-4.0747	7.2426
7.9123	-4.7605	1.4570	1.5469	-4.7215	7.8731
-7.3520	4.2496	0.8239	2.2033	5.2369	-8.5588
-6.7731	-3.3013	-0.3886	-2.9009	6.0668	
-5.9961	2.8407	0.2566	-3.3832	6.6125	

Задержки Delays 1 и Delays 2 (см. рис. А.3,а и б) равны нулю.

Приложение Б

Интеллектуальная прогнозирующая модель процесса МСИ

Б.1. Структура интеллектуальной прогнозирующей модели процесса МСИ

Структурные характеристики интеллектуальной прогнозирующей модели процесса МСИ приведены в табл. Б.1.

Таблица Б.1

Структурные характеристики модели процесса МСИ

T_s	P	P_{pr}	$F_{\hat{y}}$	F_l	r_s	M_{po}
Гаммерштейна-Винера-	1 - 4	3	Линейная	Логистическая сигмоидальная	58	Алгоритм Биеле-Пауэлла

В табл. Б.1 использовались следующие обозначения (согласно выражению (2.35)): T_s – тип структуры модели, P – глубина памяти, P_{pr} – глубина прогноза, $F_{\hat{y}}$ – функция активации выходного слоя, F_l – функция активации скрытого слоя, r_s – размер скрытого слоя, M_{po} – метод параметрической оптимизации.

Развернутая информация о структуре нейросетевой модели процесса МСИ представлена на рис. Б.1-Б.3.




Рис. Б.1. Структура модели процесса МСИ

На рис. Б.1 использовались следующие обозначения: $x\{1\}$ – вход сети, $y\{1\}$ – выход сети, Neural Network – НСПР (2.35). Блок Neural Network представляет собой НС, структура которой показана на рис. Б.2.




Рис. Б.2. Структура НС модели процесса МСИ

Структуры слоев Layer 1 и Layer 2 показаны на рис. Б.3 (слой Layer 1 – скрытый слой).

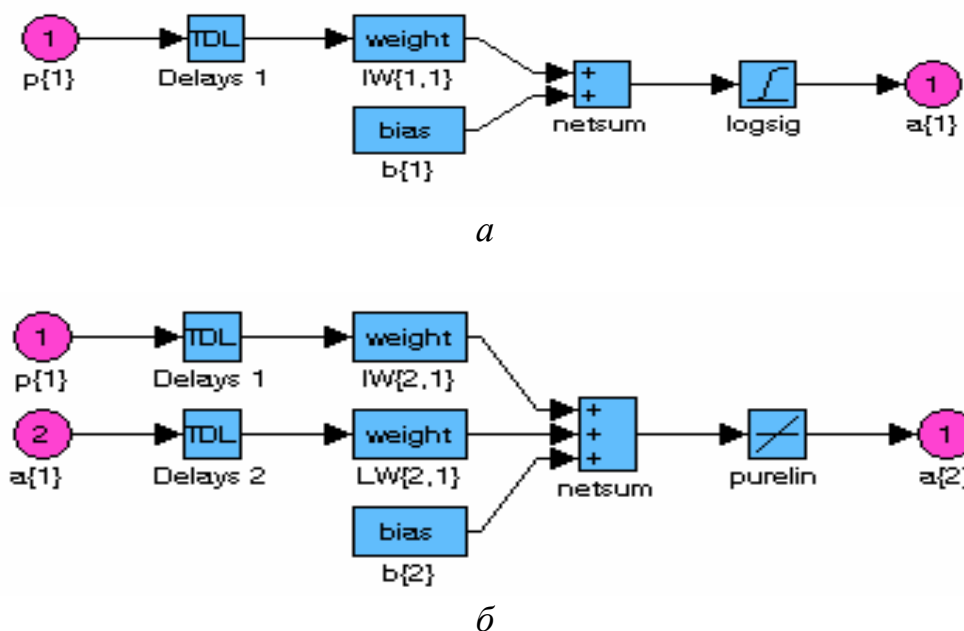


Рис. Б.3. Структура слоев Layer 1 (а) и Layer 2 (б) НС модели процесса МСИ

На рис. Б.2 и Б.3 использовались следующие обозначения: $p\{1\}$ – вход 1 на слой 1 и 2; $a\{1\}$ и $a\{2\}$ – выход слоя 1 и 2; Delays 1, 2 – линии задержки для входов 1 и 2 соответственно; IW – матрица весов входов; LW – матрица весов связей слоев 1 и 2; b – вектор смещений для слоев 1 и 2; netsum – сумматор; logsig и purelin – функции активации слоев 1 и 2.

Б.2. Параметры интеллектуальной прогнозирующей модели процесса МСИ

Параметрами НС модели процесса МСИ являются матрицы весов IW и LW , вектор смещений b , а также задержки Delays (см. рис. Б.3,а и б).

Матрица весов входного слоя IW состоит из двух матриц: $IW\{1,1\}$ размером $[58 \times 1]$ – матрицы весов связей входа со слоем 1 сети, состоящим из 58 нейронов, и $IW\{2,1\}$ размером $[1 \times 1]$ – матрицы весов связей входа со слоем 2 сети, состоящим из одного нейрона. Значение матрицы $IW\{1,1\}$ представлено в табл. Б.2. Значение матрицы $IW\{2,1\}$ $[1 \times 1] = 0.5544$.

Матрица весов промежуточного слоя LW (см. рис. Б.3,б) состоит из матрицы: $LW\{2,1\}$ размером $[1 \times 58]$ – матрицы весов связей слоя 1 с слоем 2 сети. Значение матрицы $LW\{2,1\}$ представлено в табл. Б.3.

Вектор смещений b (см. рис. Б.3,а и б) состоит из двух векторов: $b\{1\}$ размером $[58 \times 1]$ – вектора смещений для слоя 1 сети, и $b\{2\}$ размером $[1 \times 1]$ – вектора смещений для слоя 2 сети. Значение вектора $b\{1\}$ представлено в табл. Б.4. Значение вектора $b\{2\} = -0.4857$.

Таблица Б.2

Весовые коэффициенты $IW\{1,1\}$ НС модели процесса МСИ

$IW[1:12x1]$	$IW[13:24x1]$	$IW[25:36x1]$	$IW[37:48x1]$	$IW[49:58x1]$
162.3912	162.4064	162.3993	162.4003	-162.3785
-162.3999	162.4356	-162.4013	162.4002	-162.4054
-162.3983	-162.3998	162.3982	162.3988	-162.4179
162.4004	-162.4031	-162.4000	-162.3828	-162.3529
162.3993	162.3987	162.4002	-162.4254	162.4003
162.4008	-162.3943	162.3991	-162.4012	162.3791
162.3999	-162.4029	-162.4000	162.3809	-162.3992
-162.3994	162.4005	-162.4002	162.3861	-162.3947
162.3994	162.4007	-162.4004	162.4113	162.4174
-162.4050	162.3990	162.4063	162.3998	-162.4000
162.4224	162.3983	-162.3936	-162.3991	
-162.3975	162.3992	-162.4085	-162.3945	

Таблица Б.3

Весовые коэффициенты $LW\{2,1\}$ НС модели процесса МСИ

$LW [1x1:12]$	$LW [1x13:24]$	$LW [1x25:36]$	$LW [1x37:48]$	$LW [1x49:58]$
0.3170	0.0081	-0.1457	0.1034	-0.5119
-0.1733	-0.2081	0.1144	-0.1078	0.2059
0.2961	0.2345	0.0765	0.0805	0.4210
0.2120	-0.3310	0.1880	0.1781	-1.0729
0.0622	-0.2695	0.1078	-0.1981	-0.2522
-0.4888	0.1584	-0.1278	0.2497	-0.2007
0.1360	-0.1208	0.0133	0.2536	-0.0304
0.2806	-0.1304	-0.0128	-0.2091	0.2139
0.0750	-0.0607	0.2007	0.0334	0.2478
0.1751	-0.0621	0.1606	0.0929	-0.0711
0.4178	-0.0696	0.0609	0.0740	
0.3169	0.0009	0.2028	0.0905	

Таблица Б.4

Вектор смещений $b\{1\}$ НС модели процесса МСИ

$b[1:12x1]$	$b[13:24x1]$	$b[25:36x1]$	$b[37:48x1]$	$b[49:58x1]$
-162.4088	-94.0100	-25.6467	42.7358	-111.1472
156.7018	-88.2567	19.9313	48.4343	-116.8065
151.0053	82.6250	-14.2632	54.1368	-122.4883
-145.3048	76.9193	8.5477	-59.8751	-128.2698
-139.6078	-71.2310	-2.8383	-65.4645	133.9084
-133.9077	65.5433	2.8735	-71.2251	139.6313
-128.2107	59.8236	-8.5468	76.9662	-145.3062
122.5131	-54.1315	-14.2414	82.6494	-151.0092
-116.8149	-48.4327	-19.9369	88.3019	156.6837

Продолжение таблицы Б.4

Вектор смещений $b\{1\}$ НС модели процесса МСИ

$b[1:12 \times 1]$	$b[13:24 \times 1]$	$b[25:36 \times 1]$	$b[37:48 \times 1]$	$b[49:58 \times 1]$
111.1085	-42.7405	25.6022	94.0212	-162.4001
-105.3822	-37.0458	-31.3721	-99.7208	
99.7229	-31.3442	-37.0002	-105.4259	

Задержки Delays 1 и Delays 2 (см. рис. Б.3,*а* и *б*) равны нулю.

Наукове видання

Герасіна Олександра Володимирівна

Корнієнко Валерій Іванович

**СТРУКТУРНО-ПАРАМЕТРИЧНА ІДЕНТИФІКАЦІЯ ПРОЦЕСІВ
ДРОБЛЕННЯ І ЗДРІБНЮВАННЯ РУД**

Монографія

(Російською мовою)

Видано в авторській редакції

Підп. до друку 02.07.2013. Формат 30x42/4.
Папір офсет. Ризографія. Ум. друк. арк. 5,6.
Обл.-вид. акр.5,6. Тираж 300 пр. Зам. №

Підготовлено до друку та видруковано
у Державному вищому навчальному закладі
«Національний гірничий університет».

Свідоцтво про внесення до Державного реєстру ДК №1842 від 11.06.2004.
49027, м. Дніпропетровськ, просп. К. Маркса, 19.