

И.Г. Гулина, А.А. Мартыненко, А.А. Гулин

Государственное высшее учебное заведение «Национальный горный университет», Днепр

ПОСТРОЕНИЕ ИНТЕЛЛЕКТУАЛЬНЫХ ПРОГНОЗИРУЮЩИХ СИСТЕМ УПРАВЛЕНИЯ НЕЛИНЕЙНЫМИ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ

Выполнен анализ и обоснование методологии построения алгоритмов оценки, идентификации, синтеза оптимального управления и адаптации для создания высокоэффективных систем автоматического управления нелинейными технологическими процессами с интеллектуальным прогнозированием.

Ключевые слова: система управления, адаптация, идентификация, интеллектуальные прогнозирующие модели, нелинейный технологический процесс.

Введение

Расходы на технологические процессы различных производств составляют значительную часть себестоимости всего комплекса. Поэтому актуальным является повышение эффективности этих процессов путем создания систем автоматического управления (САУ) ними. Вместе с тем, эти процессы с позиции управления представляют собой сложные динамические объекты управления (ОУ) с нестационарными параметрами, нелинейными зависимостями и стохастическими переменными [1; 2].

Состояние вопроса. Ведущая концепция современной теории автоматического управления состоит [3] в достижении главной цели на каждом этапе функционирования системы и обеспечивается путем оптимизации ОУ в реальном масштабе времени с использованием имеющейся априорной информации на этапах:

- оценки (фильтрации) динамических процессов в ОУ;
- идентификации структуры и параметров модели ОУ;
- синтеза оптимального управления циклами функционирования системы;
- адаптации (настройке оптимального управления при неполной информации).

Трудности решения задач оптимизации управления нелинейными динамическими объектами путем минимизации классических функционалов обусловили появление функционалов нового типа – функционалов обобщенной работы (ФОР). Примером стохастического ФОР с аддитивными функциями расходов на управление и дискретным временем является [3]:

$$J = E\{V_3(x[k_{j+1}]) + \sum_{k=k_j}^{k_{j+1}-1} Q_3(x[k], k) + \sum_{k=k_j}^{k_{j+1}-1} U_3(u[k], k) + \sum_{k=k_j}^{k_{j+1}-1} U_3^*(u_{opt}[k], k)\}, \quad (1)$$

где E – математическое ожидание; V_3 – терминальная функция конечного состояния этапа управления (целевая функция); Q_3 – положительно определенная функция; U_3, U_3^* – положительно определенные функции, принимают минимальное значение при; $u = u_{opt}$; x, u – векторы состояния и управления; u_{opt} – искомое оптимальное управление, что достигает минимум функционала; k_j, k_{j+1} – начальные такты последовательных интервалов (циклов) управления; k – текущий такт времени.

Наиболее универсальным способом синтеза оптимального по ФОР управления является [4] использование прогнозирующей модели ОУ, может быть представлен в виде:

$$Y_{[k+n]} = \Phi\{Y_{[k]}, u_{[k]}, w_{[k]}, \xi_{[k]}, a, k\}, \quad (2)$$

Где $\{Y_{[k]}, w_{[k]}\} \subset x[k]$; $Y_{[k+n]}$ – прогнозируемый на n тактов вперед вектор состояния выхода ОУ (для компенсации чистого запоздания и времени на синтез и реализацию оптимального управления в системе); $Y_{[k]}, u_{[k]}, w_{[k]}$ – векторы (матрицы) состояний выхода, управлений и возмущений; a – вектор параметров модели; Φ – обобщенная функция (метод, алгоритм) структуры модели; ξ – вектор ошибок измерений.

Сейчас для сложных, нелинейных ОУ стремительно развиваются интеллектуальные методы управления, рассматривают объект, не как абсолютно известную точку в пространстве признаков, а как некоторую информацию о ней. При таком подходе стараются воссоздать принципы природных систем управления – нервных систем живых организмов, реализующих универсальные принципы обработки эмпирической информации и поисковые алгоритмы адаптации [5].

Следовательно, актуальным направлением в дальнейшем развитии этой теории управления является разработка принципов построения эффективных систем управления, в частности, интеллектуальных прогнозирующих моделей.

Цель статьи. Разработка и обоснование методологии построения алгоритмов оценки, идентификации, синтеза оптимального управления и адаптации для создания высокоэффективных систем автоматического управления нелинейными технологическими процессами с интеллектуальным прогнозированием.

Интеллектуальная оценка состояния ОУ

Проблема оперативности контроля в рамках создания систем автоматизации может быть решена путем прогнозирования (на необходимый интервал упреждения) значений технологических переменных по их полученным в прошлом значениями, осуществляется с помощью прогнозирующих фильтров (ПФ).

Сформулируем задачу прогнозирования значений технологической переменной в общем виде для дискретного времени:

$$Z_{[k+n]}^* = \Phi_Z \{Z_{[k-m]}, \phi(Z_{[k]}), V_{[k]}, a^*, k\}, \quad (3)$$

где $\{Y_{[k]}, u_{[k]}, w_{[k]}\} \subset Z_{[k]}$; $Z_{[k+n]}^*$ – вектор прогнозируемых значений технологической переменной на интервале упреждения n ; $Z_{[k-m]}$ – вектор значений временного ряда параметра с глубиной памяти m ; $Z_{[k]}$ – вектор значений предыстории параметра; ϕ – линейно независимые функции, характеризующие свойства временного ряда; $V_{[k]}$ – белая гауссова последовательность; Φ_Z – обобщенная функция преобразования (метод, алгоритм); a – вектор параметров.

Прогнозирование может выполняться, например, по критерию минимума погрешности прогноза:

$$\varepsilon = \left\| Z_{[k+n]}^* - Z_{[k+n]} \right\| \rightarrow \min \text{ при } n = n_{\text{зад}}, \quad (4)$$

где $Z_{[k+n]}$ – реальные значения технологической переменной; $n_{\text{зад}}$ – заданное значение интервала упреждения.

Решение задачи прогнозирования (нахождения обобщенной функции Φ_Z и параметров a^*) состоит в интерполяции временного ряда (с помощью аппроксимирующих функций) и экстраполяции значений ряда на будущее по его предыдущим значениям согласно характеристических функций $\phi(Z_{[k]})$ с целью обеспечения выбранного критерия эффективности.

Рассмотрим процесс синтеза ПФ с использованием методов искусственного интеллекта. Фильтры, синтезированные по принципу самоорганизации, воспроизводят схему массовой селекции и реализуют алгоритмы метода группового учета аргументов (МГУА) [6]. Они имеют генераторы комбинаций, усложняются от ряда к ряду, и предельные устройства отбора лучших из них. Полное описание подается в виде рядов частных описаний. Временной ряд аппроксимируется, например, полиномиальными частичными описаниями, которые при представле-

нии значений временного ряда $Z_{[k]}$ в виде отдельных переменных представляют собой конечно-разностные уравнения.

Другим подходом для создания ПФ является использование нейронных сетей, большинство моделей которых требуют обучения, представляет собой задачу многомерной оптимизации. Для ее решения используется несколько алгоритмов [7].

В качестве примера оценим эффективность ПФ таких технологических переменных доменного производства, как уровень расплава домы и содержание кремния в чугуна по их временным реализациям, полученными в условиях металлургического комбината «Азовсталь».

Для каждой технологической переменной с помощью стандартных программных средств были рассчитаны следующие ПФ:

- 1) линейный адаптивный ПФ, рекурсивный со скользящим сглаживанием;
- 2) нейросетевой ПФ на основе вейвлет (нейронной сети с функцией активации в виде вейвлета)
- 3) гибридный ПФ в виде адаптивной нейронной системы нечеткого вывода структуры Сугено и колоколообразных функцией принадлежности.

Результаты расчета погрешностей прогноза ε (4), нормированных по диапазон соответствующих переменных, показали, что интеллектуальные ПФ имеют меньшую погрешность прогнозирования (на 10 тактов вперед) технологических переменных (0,072 ... 0,205 отн. ед.), чем линейный ПФ (0,075 ... 0,344 отн. ед.), и не требуют значительных затрат времени на исследование прогнозируемых процессов.

Идентификация ОУ в классе интеллектуальных прогнозирующих моделей

Сформулируем задачу идентификации ОУ следующим образом. На основе экспериментально полученных множеств функций (временных рядов) возмущений $w_{[k]}$, управлений $u_{[k]}$ и выходов $Y_{[k]}$ в условиях помех $\xi_{[k]}$ определить структуру (обобщенную функцию Φ) и вектор параметров a модели (2), которые достаточно точно (в смысле некоторого критерия) аппроксимируют ОУ относительно входных и выходных величин во всем функциональном пространстве.

В качестве меры точности идентификации (критерия оптимизации оценки структуры и параметров модели) можно принять критерий минимума погрешности между экспериментальными $Y_{[k+n]}^*$ и реальными значениями вектора $Y_{[k+n]}$ выхода модели (2):

$$\varepsilon = \left\| Y_{[k+n]}^* - Y_{[k+n]} \right\| \rightarrow \min, \quad (5)$$

при соблюдении ограничений на значения функционального пространства.

Выполним идентификацию прогнозирующих моделей процесса крупнокускового дробления по экспериментальным данным. Возмущениями процесса являются: средневзвешенная крупность и прочность исходной руды, управлением – ширина разгрузочной шели дробилки КПД-1500/180, а выходом – содержание класса +100 мм в дробленой руде.

С помощью стандартных программных средств были рассчитаны такие прогнозирующие модели:

1) модель самоорганизации по МГУА с много-рядной селекцией и комбинаторным перебором ко-вариационных частных описаний;

2) нейросетевую модель на основе каскадной нейронной сети с сигмоидальной функцией активации;

3) гибридную модель структуры Сугено с колоколообразной функцией принадлежности.

Полученные значения относительной погрешности составили: для модели самоорганизации 6,5%, нейросетевой модели – 4,3% и гибридной модели с нечеткой логикой – 4,1%.

Синтез оптимального управления

Основным преимуществом метода синтеза оптимального управления по ФОР является возможность его эффективного использования для существенно нелинейных ОУ. При этом алгоритм синтеза оптимального управления с прогнозирующей моделью включает следующие операции:

1) оценку текущего состояния ОУ в дискретные моменты времени, которые отвечают началу очередного интервала формирования управления $[k_j]$;

2) прогнозирование свободного движения ОУ на интервале оптимизации управления $[k_j, k_{j+1}]$;

3) вычисления градиента изменения целевой функции $V(x[k], k)$ для текущего состояния ОУ;

4) формирование сигнала управления $u_{opt}[k_{j+1}]$.

Конкретные возможности и вычислительные затраты зависят от выбранного варианта алгоритма с прогнозирующей моделью.

Так, например, алгоритм с численным дифференцированием заключается [3] в вычислении целевой функции $V(x[k], k)$ на прогнозируемом с помощью модели (2) движении ОУ в ускоренном времени с последующим численным дифференцированием этой функции. На основе полученных прогнозов вычисляют функции:

$$V(k_j) = V_3(x[k_{j+1}]) + \sum_{k=k_j}^{k_j+r-1} Q_3(x[k], k); \{Y[k_j], w[k_j]\} \subset x[k_j], \quad (6)$$

и путем их численного дифференцирования определяют оптимальное управление:

$$u_{k_{j+1}} = u_{opt}(k_{j+1}) = -K\{\partial V(k_j) / \partial x[k_j]\}^T, \quad (7)$$

где K – положительно определенная матрица заданных коэффициентов.

В алгоритме с синхронным детектированием вариация начальных условий и прогнозирования по модели (2) заменяют быстросменными вариациями ортогональных функций Уолша $\delta x[k]$ в процессе прогнозирования с обработкой сигналов по принципу синхронного детектирования [3], что значительно сокращает количество вычислений.

Численное интегрирование модели (2) осуществляется при искусственно малых возмущениях каждого компонента состояния с помощью своих кодовых групп Уолша. Умножения на те же кодовые группы компонентов прогнозируемого свободного ($du / dt=0$) движения и усреднения обеспечивает определение главной части функционала (6) на прогнозируемом движении и формирования вектора оптимального управления (7) на очередной интервал оптимизации.

Адаптация в интеллектуальных системах оптимального управления

Нестационарность и стохастичность ОУ, а также отсутствие полной информации относительно режимов его работы требуют использования в системах управления сложными технологическими процессами алгоритмов адаптации моделей и законов управления в реальных условиях функционирования.

Структура адаптивных оптимальных САУ определяется принципом (теоремой) разделения [3; 4]. В соответствии с ним такие системы состоят из оптимальной подсистемы оценки и идентификации и подсистемы оптимального управления, построенной для условий точного измерения вектора состояния и вектора параметров, но при использовании оценки этих величин (выходных сигналов подсистемы оценивания и идентификации).

В адаптивной системе управления с прогнозирующей моделью на каждом цикле управления последовательно решаются две оптимизационные задачи:

1) определение оптимальных (в смысле выбранного критерия оценки и идентификации) коэффициентов a и структуры Φ модели (2);

2) синтез оптимального управления (в смысле выбранного функционала управления) по адаптированной модели (2).

При этом оптимальное в смысле ФОР (1) управление стохастическим процессом (2) в условиях некоррелированности целевой функции и погрешностей оценки ($\langle V_3; \xi_{[k]} \rangle \approx 0$) может быть при-

мерно полученное [3] как оптимальное управление детерминированным процессом с точным измерением вектора состояния $x[k]$ путем замены его действительного значения на оценку $\hat{x}[k]=E_y\{x[k]\}$.

Полученные таким путем приближенные решения тем точнее, чем выше точность оценки, т.е. чем меньше $\|x[k] - \hat{x}[k]\|$.

Адаптация является разновидностью управления и заключается в целенаправленном изменении управляющих факторов системы для поддержки экстремума заданного функционала. В нашем случае к множеству управляющих факторов адаптации согласно (1) и (2) следует отнести:

1) при параметрической адаптации:

$$A_p = \{a, u_{opt}\}; \quad (8)$$

2) при структурно-параметрической адаптации:

$$A_s = \{a, \Phi, u_{opt}\}. \quad (9)$$

Для алгоритмов параметрической адаптации вектора a параметров модели (2) (оценка и идентификация) и оптимального управления u_{opt} по этой модели в смысле минимума принятого функционала широко используют градиентные алгоритмы [3]. Их идея заключается в том, что скорость изменения параметров, которые адаптируют, пропорциональна градиенту главной части выбранного функционала в пространстве этих параметров:

$$\hat{a}[k_{j+1}] = \hat{a}[k_j] - K_1 \cdot \nabla_a Q_3 \{Y[k_j], \hat{Y}[k_j], k\}, \quad (10)$$

где $\hat{a}[k_{j+1}]$ – оценка вектора параметров, которые адаптируют на новый интервал управления; $\nabla_a = (\partial/\partial a)^T$ – символ градиента; K_1 – заданная матрица коэффициентов.

При реализации параметрической адаптации модели (2) согласно (10), оптимальные в смысле ФОР (1) управления по прогнозирующей модели (2) определяется как:

$$u_{opt}[k_{j+1}] = -K_2 \cdot \partial / \partial \bar{x}[k_j] \{V_3(\bar{x}[k_{j+1}]) + \sum_{k=k_j}^{k_{j+1}-1} Q_3(\bar{x}[k], k)\}^T, \quad (11)$$

где $\{\hat{Y}[k_j], \hat{w}[k_j]\} \subset \bar{x}[k_j]$; K_2 – заданная матрица коэффициентов.

Для числового дифференцирования главной части функционала в выражениях (10), (11) наиболее эффективны алгоритмы синхронного детектирования и π -алгоритмы, изложенные, например, в работе [3].

К достоинствам рассмотренных градиентных алгоритмов относят простоту и быстродействие, а к недостаткам – высокую вероятность зависания в локальных экстремумах при полимодальных функционалах.

Наиболее эффективным методом решения оптимизационных задач при адаптации структуры и параметров системы управления являются поисковые методы [5; 8]. В них процесс поиска состоит из повторяющихся этапов, каждый из которых представляет собой переход от одного решения к другому (лучшего), что и образует при минимизации функционала процедуру последовательного улучшения решений (9):

$$J[A_s(N+1)] < J[A_s(N)]. \quad (12)$$

Примерами реализации поисковых методов являются алгоритмы прямого случайного поиска, генетические алгоритмы и алгоритмы имитации отжига [9].

В качестве примера, рассмотрим параметрическую адаптацию прогнозирующей модели процесса крупнокускового дробление ранее идентифицирована нами по принципу самоорганизации.

С помощью программных средств была выполнена адаптация коэффициентов этой модели:

1) симплексным методом скользящего допуска с ограничениями;

2) генетическим алгоритмом с одноточечным скрещиванием, селективным выбором родителей и формированием новой популяции с вытеснением;

3) методом прямого случайного поиска с адаптацией (ускорителем) шага поиска.

Количество итераций (для ГА – поколений) ограничивалось до 150, а размер пространства поиска (популяции) – до 20. В качестве меры точности адаптации использовали критерий минимума относительной погрешности.

Полученные значения относительной погрешности модели составили: для метода скользящего допуска 6,5%, генетического алгоритма – 5,4% и метода прямого случайного поиска – 5,2%.

Статистическая проверка по непараметрическому критерию знаков показала, что для уровня значимости 0,05 прогнозирующие модели с коэффициентами, которые адаптированы тремя приведенными методами, адекватны динамике реального процесса.

Выводы

Выполненные исследования обосновывают предлагаемый подход к построению САУ со сложными технологическими процессами на базе интеллектуального прогнозирования.

Такой подход позволяет значительно снизить стоимость построения и повысить эффективность этих систем, так как не требует разработки точных моделей ОУ на этапе проектирования. Синтез управления осуществляется по интеллектуальным прогнозирующим моделям, которые адаптируют в процессе функционирования САУ.

Результаты расчетов, выполненных с применением пакетов прикладных программ синтеза интеллектуальных прогнозирующих систем управления, подтвердили эффективность предложенного подхода.

Вместе с тем, поскольку выбор алгоритмов адаптации должен осуществляться исходя из свойств выбранного функционала, то дальнейшие исследования должны быть направлены на определение особенностей гиперповерхности функционалов управления конкретных технологических процессов.

Список литературы

1. Каганов В.Ю. Автоматизация управления металлургическими процессами / В.Ю. Каганов, О.М. Блинов, А.М. Бельский. – М.: Металлургия, 1974. – 416 с.
2. Марюта А.Н. Автоматическое управление технологическими процессами обогатительных фабрик / А.Н. Марюта, Ю.Г. Качан, В.А. Бунько. – М.: Недра, 1983. – 277 с.
3. Справочник по теории автоматического управления / Под ред. А.А. Красовского. – М.: Наука, 1987. – 712 с.

4. Красовский А.А. Универсальные алгоритмы оптимального управления непрерывными процессами / А.А. Красовский, В.Н. Буков, В.С. Шендрок. – М.: Наука, 1977. – 272 с.

5. 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.

6. Справочник по типовым программам моделирования / под ред. А.Г. Ивахненко. – К.: Техніка, 1980. – 184 с.

7. Дьяконов В. Математические пакеты расширения Matlab. Специальный справочник / В. Дьяконов, В. Круглов. – СПб.: Солон, 1998. – 488 с.

8. Растринин Л.А. Адаптация сложных систем / Л.А. Растринин. – Рига: Зинатне, 1981. – 375 с.

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

Поступила в редколлегию 6.03.2017

Рецензент: д-р техн. наук проф. М.А. Алексеев, Государственное высшее учебное заведение «Национальный горный университет», Днепр.

ПОБУДОВА ІНТЕЛЕКТУАЛЬНИХ ПРОГНОЗУЮЧИХ СИСТЕМ КЕРУВАННЯ НЕЛІНІЙНИМИ ТЕХНОЛОГІЧНИМИ ПРОЦЕСАМИ

І.Г. Гуліна, А.А. Мартиненко, О.О. Гулін

Виконано аналіз і обґрунтування методології побудови алгоритмів оцінки, ідентифікації, синтезу оптимального керування і адаптації для створення високоефективних систем автоматичного керування нелінійними технологічними процесами з інтелектуальним прогнозуванням.

Ключові слова: система керування, адаптація, ідентифікація, інтелектуальні прогнозні моделі, нелінійний технологічний процес.

BUILDING INTELLIGENT PREDICTIVE NONLINEAR PROCESS CONTROL SYSTEMS

I. Gulina, A. Martynenko, A. Gulin

We performed an analysis and justification of the methodology of the evaluation algorithms, identification of optimal control synthesis and adaptation to the creation of highly nonlinear systems of automatic control of technological processes with intelligent forecasting.

Keywords: control system, adaptation, identification, intelligent predictive models, non-linear process.