

УДК 681.515: 519.7: 62-52

В.И. Корниенко, канд. техн. наук, А.В. Пивоварова
(Украина, Днепропетровск, Национальный горный университет)

**ИНТЕЛЛЕКТУАЛЬНЫЕ МЕТОДЫ
СТРУКТУРНО-ПАРАМЕТРИЧЕСКОЙ ИДЕНТИФИКАЦИИ
ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ РУДОПОДГОТОВКИ**

Введение

Рудоподготовка включает процессы дробления и измельчения, которые с позиций управления представляют собой сложные динамические объекты управления (ОУ) с нестационарными параметрами, нелинейными зависимостями и стохастическими переменными [1].

Системы оптимизации такими процессами требуют использования имеющейся априорной информации в виде математической модели ОУ и на стадии проектирования, и в процессе функционирования системы. Поэтому важной проблемой создания систем управления является идентификация ОУ.

Исследования проводились в рамках выполнения госбюджетной темы ГП-407 “Интеллектуальные компьютерные технологии обработки данных, прогнозирования и управления” (государственная регистрация № 0108U000538) по заказу Министерства образования и науки Украины (приказ № 1044 от 27.11.2007р.).

Постановка задачи

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) и вектор параметров a модели вида [2]:

$$\hat{Y}[k+n] = \Phi\{Y[k], u[k], c[k], x[k], a[k], k\}, \quad (1)$$

что достаточно точно (в смысле некоторого критерия) аппроксимируют ОУ в отношении входных и выходных величин во всем функциональном пространстве. Здесь $Y[k], u[k], c[k], x[k]$ – соответственно векторы (матрицы) выхода процесса, его управлений, возмущений и помех к текущему времени k с соответствующими глубинами памяти; n – глубина прогноза (для компенсации чистого запаздывания и времени на синтез и реализацию управления).

Как меру точности идентификации можно выделить два класса критериев [3]: критерии, определяемые через апостериорную вероятность, и функционалы ошибок. Примером последних является критерий минимума ошибки между экспериментальными $Y[k + n]$ и модельными значениями выхода:

$$e = \|Y[k + n] - \hat{Y}[k + n]\| \rightarrow \min \quad (2)$$

при соблюдении ограничений на функциональное пространство.

Поскольку технологические процессы рудоподготовки являются сложными нелинейными динамическими ОУ, то для решения задач их идентификации целесообразно применять методы интеллектуальной обработки информации, которые являются универсальными и эффективными аппроксиматорами, легко настраиваются (адаптируются) под изменяющиеся свойства ОУ и, соответственно, представляют собой эффективное средство изучения и моделирования сложных систем. К этим методам относятся: эволюционный метод группового учета аргументов (МГУА), искусственные нейронные сети (НС), модели с нечеткой логикой, гибридные НС и др.[4-6].

Цель статьи

Исследование методов структурно-параметрической идентификации технологических процессов рудоподготовки в классе интеллектуальных прогнозирующих моделей.

Интеллектуальные методы

Алгоритмы МГУА реализуют схему массовой селекции путем генерирования моделей – частных описаний (скрещивание) и отбора лучших из них (селекция). В них на первом ряду по экспериментальным данным строятся частные описания для всех попарных комбинаций исходных аргументов (с определением параметров по методу наименьших квадратов).

Из этих частных описаний отбирается некоторое количество P_1 лучших по внешнему критерию моделей, которые на втором ряду принимаются в качестве аргументов и по ним строятся новые частные описания. Далее отбираются P_2 лучших моделей в качестве аргументов следующего ряда и т.д. Ряды наращиваются, пока снижается значение внешнего критерия.

Специальные теоремы теории МГУА определяют условия, при которых результат селекции не отличается от результата полного перебора моделей.

НС – это вычислительные структуры, моделирующие процессы мозга и состоящие из множества одинаковых элементов — нейронов [5]. На их вход поступает множество сигналов $X = \{x_1, x_2, \dots, x_p\}$, являющиеся выходами других нейронов. Каждый вход умножается на соответствующий вес $W = \{w_1, w_2, \dots, w_p\}$ и все произведения суммируются, определяя уровень активации нейрона:

$$Z = \sum_i x_i w_i = XW. \quad (3)$$

Далее сигнал Z превращается активационной функцией F в выходной нейронный сигнал $Y = F(Z)$.

Для НС доказано [7], что при нелинейной функции активации F можно так построить сеть связей и подобрать коэффициенты, чтобы НС как угодно точно вычисляла любую непрерывную функцию от своих входов. Таким образом, НС являются универсальными и эффективными аппроксиматорами.

Нечеткая логика эффективна для построения моделей в задачах принятия решений в условиях неопределенности, классификации и анализа данных [6].

Развитием нечетких моделей и НС являются гибридные (нечеткие) НС, в которых выводы делаются на основе аппарата нечеткой логики, но параметры настраиваются с использованием алгоритмов обучения НС. Доказано [6], что такие НС также есть универсальные и эффективные аппроксиматоры.

Быстрота обучения и интерпретируемость результатов делают гибридные НС одними из перспективных и эффективных инструментов интеллектуальной обработки информации.

Параметрическая идентификация

В прямых методах параметрической идентификации неизвестные параметры a модели (1) определяются на основе решения системы уравнений, получающихся путем подстановки в модель (1) последовательностей экспериментальных значений входных и выходных величин ОУ.

Алгоритмы прямой параметрической идентификации на практике обычно оказываются неприемлемыми из-за плохой обусловленности матрицы связей (ввиду наличия ошибок измерения). Поэтому широкое распространение получили беспоисковые алгоритмы параметрической идентификации с адаптивной моделью, ориентированные на функционирование в реальном масштабе времени, к которым относятся градиентные алгоритмы [3]. Их идея состоит в том, что скорость изменения вектора параметров a пропорциональна градиенту выбранного критерия (2) в пространстве этих параметров:

$$\hat{a}[k_{j+1}] = \hat{a}[k_j] - K_1 \cdot \nabla_a Q_3 \{Y[k_j], \hat{Y}[k_j], k\}, \quad (4)$$

где $\hat{a}[k_{j+1}]$ – оценка вектора параметров модели (1) на новый цикл управления; $\nabla_a = (\partial / \partial \hat{a})^T$ – символ градиента; K_1 – заданная матрица коэффициентов; $Q_3 \{Y[k_j], \hat{Y}[k_j], k\} = \|Y[k+n] - \hat{Y}[k+n]\|$ – функция затрат, соответствующая (2).

Развитием градиентных методов для стохастических процессов с дискретным временем является алгоритм стохастической аппроксимации:

$$\hat{a}[k_{j+1}] = \hat{a}[k_j] - g[k] \cdot \nabla_a Q_3 \{Y[k_j], \hat{Y}[k_j], k\}, \quad (5)$$

где $g[k]$ – матрица коэффициентов, которая определяет свойства алгоритма. В общем случае она зависит не только от времени k , но и от других переменных.

Для идентификации (обучения) параметров многослойных НС (весов и параметров функций принадлежности гибридных НС) широко используется градиентный метод обратного распространения ошибки [5, 6]. Процесс обучения НС (см. рис. 1) заключается в подстройке их параметров по величине ошибки между откликом модели и требуемым по экспериментальным исходным данным (ИД) выходом (например, согласно (2)).

Такая идентификация предполагает известность структуры модели (или же диапазона ее рациональных значений), т.е. требует выполнения значительных объемов предварительных исследований ОУ.

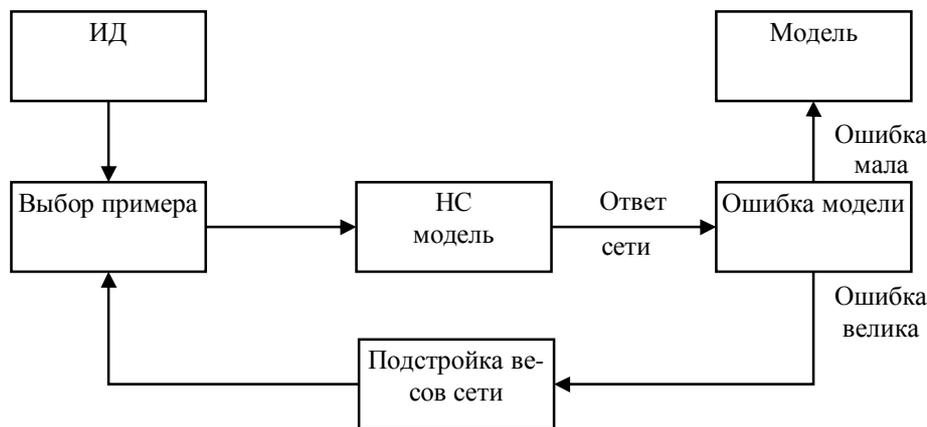


Рис. 1. Процесс обучения НС

Структурно-параметрическая идентификация

Процесс структурно-параметрической идентификации (см. рис. 2) включает определение структуры, оценку и оптимизацию параметров модели ОУ. Первые две операции решаются путем генерирования (с помощью базовых функций) моделей-претендентов различной сложности и настройки их параметров с последующей селекцией лучших из них по выбранным критериям (оптимальная структура). Операция определения оптимальных параметров решается известными методами оптимизации путем уточнения полученных ранее значений параметров по критериям регулярности на всей выборке ИД.

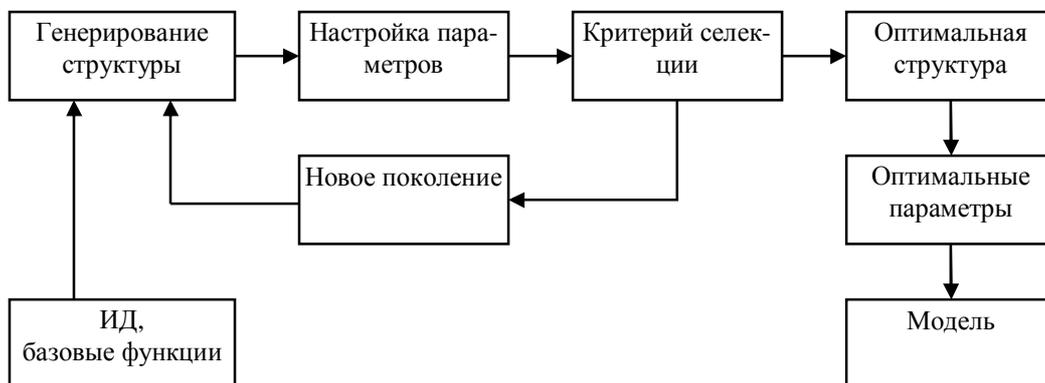


Рис. 2. Процесс структурно-параметрической идентификации

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

Основное достоинство МГУА – реализация как параметрической, так и структурной идентификации ОУ. Выбор же структуры НС моделей решается эвристически из-за отсутствия теоретически обоснованных универсальных процедур минимизации перебора вариантов (формального способа создания сетевой структуры в функции сложности решаемой задачи). При этом известны [8] алгоритмы локальной оптимизации структуры НС, реализующие конструктивный (с усложнением модели) и деструктивный (с упрощением модели) подходы.

Конструирование многослойных наращиваемых НС с использованием градиентного алгоритма обратного распространения ошибки осуществляется так. Пусть НС имеет r слоев с сигмоидальной функцией активации F :

$$Y = F(W_r Z_{r-1}); Z_{r-1} = F(W_{r-1} Z_{r-2}); Z_1 = F(W_1 X), \quad (6)$$

где X – входной набор; W_1 – матрица весовых коэффициентов между входным и первым слоями; W_{r-1} – матрица весовых коэффициентов между $r-2$ и $r-1$ слоями; W_r – матрица между $r-1$ и выходным слоем.

Целью настройки весов (параметров) НС является минимизация функции ошибки (2), а соответствующая рекуррентная коррекция весов имеет вид:

$$w_{ij}(t+1) = w_{ij}(t) + \nabla w_{ij}(t+1), \quad (7)$$

где $\nabla w_{ij}(t+1)$ – градиент веса между нейронами i и j .

Здесь алгоритм обратного распространения ошибки изменяет значения весов в направлении уменьшения ошибки e до ее нулевой нормы скорости:

$$\|\nabla_w e\| = \sqrt{\sum_i (\Delta w_i)^2} = 0, \quad (8)$$

где индекс i охватывает все веса в сети.

Однако использование градиентных алгоритмов зачастую не эффективно из-за полимодальности поверхности функции ошибки при идентификации нелинейных ОУ. Более эффективными представляются методы случайного поиска [9], реализующие процедуру последовательного улучшения решений. Развитием этих методов являются эволюционные алгоритмы, среди которых наиболее распространены генетические алгоритмы (ГА), основанные на моделировании развития биологической популяции на уровне геномов. Их высокая эффективность теоретически обоснована в фундаментальной теореме ГА [10]: при монотонной последовательности популяций вероятность нахождения глобального оптимума равна единице.

Динамические НС, используемые для решения задач идентификации, могут быть описаны с учетом [11] рекуррентными соотношениями вида:

$$z(k) = \sum_{t=0}^T W_{zx}(t)x(k-t) + \sum_{t=0}^T W_{zz}(t)f(z(k-t)) + \sum_{t=0}^T W_{zy}(t)y(k-t); \quad (9)$$

$$y(k) = \sum_{t=0}^T W_{yx}(t)x(k-t) + \sum_{t=0}^T W_{yz}(t)f(z(k-t)), \quad (10)$$

где $x(k)$ – вектор входов сети; $z(k)$ – вектор внутренних состояний, которые не являются ни входами, ни выходами; $y(k)$ – вектор выходов сети; f – активационная функция; W – матрицы весов; T – глубина памяти.

Такие описания, по сути, представляют собой уравнения состояния (9) и наблюдения (10) ОУ, что позволяет применять к ним стандартные методы и алгоритмы теории автоматического управления.

Выводы

Прогнозирующую модель ОУ целесообразно представлять в виде рекуррентной гибридной или четкой НС со структурно-параметрической идентификацией.

ГА способны осуществлять глобальную структурно-параметрическую оптимизацию НС как единого набора параметров. Использование НС и ГА для задач идентификации ОУ представляется наиболее перспективным.

Дальнейшие исследования должны быть направлены на разработку алгоритмов структурно-параметрической идентификации конкретных процессов дробления и измельчения.

Список литературы

1. Марюта А.Н., Качан Ю.Г., Бунько В.А. Автоматическое управление технологическими процессами обогатительных фабрик. – М.: Недра, 1983. – 277 с.
2. Корнієнко В.І. Принципи побудови оптимальних систем автоматичного керування гірничорудним виробництвом з інтелектуальним прогнозуванням// Наук. вісн. Національного гірничо-ун-ту. – 2006. – № 10. – С. 85-89.
3. Справочник по теории автоматического управления / Под ред. А.А. Красовского, – М.: Наука, 1987. – 712 с.
4. Ивахненко А.Г., Лапа В.Г. Предсказание случайных процессов. – К.: Наук. думка, 1971. – 416 с.
5. Уоссермен Ф. Нейрокомпьютерная техника. – М.: Мир, 1992. – 237 с.
6. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. – М.: Солон, 1996. – 348 с.
7. Горбань А.Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей// Сибирск. журн. вычислит. матем. – 1998. – № 1. – С. 12-24.
8. Тарек Н. Набхан, Альберт Зомая. О проблемах создания нейросетевых структур для оптимизации функционирования. – www.neuroschool.narod.ru.
9. Растрингин Л.А. Адаптация сложных систем. – Рига: Зинатне, 1981. – 375 с.

10. Holland J.H. Adaptation in natural and artificial systems. An introductory analysis with application to biology, control and artificial intelligence. – London: Bradford b.ed., 1994. – 211 p.
11. Тархов Д.А. Нейронные сети: модели и алгоритмы.– М.: Радиотехника, 2005.–256 с.