

А.М. Алексеев, С.М. Мацюк

**СТРУКТУРНО-ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ  
НЕЛИНЕЙНЫХ ДИНАМИЧЕСКИХ ПРОЦЕССОВ  
НА ОСНОВЕ АЛГОРИТМОВ ГЛОБАЛЬНОЙ  
И ЛОКАЛЬНОЙ ОПТИМИЗАЦИИ**

*Аннотация.* Предложена структурно-параметрической идентификации нелинейных динамических процессов, включающая процедуры генерирования структур, селекцию моделей и оптимизацию их параметров на основе алгоритмов глобальной и локальной оптимизации, что позволяет получить интеллектуальные прогнозирующие модели нелинейных динамических процессов повышенной точности.

*Ключевые слова:* идентификация, динамический процесс, точность, алгоритм, оптимизация.

**Введение.** Сложные динамические объекты управления (ОУ) имеют нестационарные параметры, нелинейные зависимости и стохастические переменные, что обуславливает наличие у них разных динамических режимов функционирования. К таким ОУ относятся, например, подвижные объекты, технологические процессы рудоподготовки (дробление и измельчение) и др. Для управления ими используется априорная информация в виде математической модели ОУ, как на стадии проектирования, так и в процессе функционирования. Поэтому важной проблемой создания эффективных систем управления является идентификация ОУ.

**Актуальность исследований.** Процесс структурно-параметрической идентификации включает операции определения структуры, оценки и оптимизации параметров модели ОУ [1]. Первые две операции решаются путем генерирования (с помощью базисных функций) моделей-претендентов разной сложности и настройки их параметров с последующей селекцией лучших из них по избранным критериям (результат – оптимальная структура). Операция определения оптимальных параметров решается методами параметрической оптимизации путем уточнения полученных ранее значений парамет-

ров по критериям регулярности на всей выборке исходных данных (результат – оптимальная модель).

При этом актуальными проблемами является выбор базисных функций, в терминах которых осуществляется идентификация, выбор способа генерирования и селекции структур разной сложности (метод структурной оптимизации), а также выбор метода параметрической оптимизации и эффективных критериев селекции и оптимизации.

Традиционно для аппроксимации базисных функций используются полиномы Лежандра, Колмогорова-Габора и др. [2-3]. Коэффициенты этих полиномов образуют неизвестные параметры, значения которых выбираются так, чтобы наилучше отвечать наблюдаемым временным реализациям.

Более продуктивным является использование нейронных сетей (НС) или гибридных НС с нечеткой логикой, которые являются универсальными и эффективными аппроксиматорами.

Эффективным методом структурно параметрической идентификации является метод группового учета аргументов (МГУА) [2-3]. Его алгоритмы реализуют схему массовой селекции путем генерирования моделей – частных описаний (скрещивание) и отбора лучших из них (селекция). Но значительной проблемой применения МГУА является правильное соотношение сложности модели с объемом обучающей выборки. Синтезированная модель ОУ, которая правильно передает динамику одного режима функционирования, может быть неадекватной к описанию другого режима. Поэтому необходима реализация адаптивной идентификации ОУ в процессе функционирования системы управления. Таким образом, нерешенной задачей является разработка малозатратных и эффективных методик структурно-параметрической идентификации нелинейных динамических ОУ, которые имеют переменные режимы функционирования.

**Постановка задачи.** Целью статьи является разработка методики структурно-параметрической идентификации нелинейных динамических ОУ в классе прогнозирующих нейросетевых моделей на базе композиции методов глобальной и локальной оптимизации, а также оценка эффективности применения этой методики на примере технологического процесса рудоподготовки.

**Результаты исследований.** Жесткие требования к знанию статистических свойств временных рядов экспериментальных сигналов в

системах управления ограничивают возможности методов математической статистики, теории распознавания образов, теории случайных процессов и др.

Многие реальные процессы не могут адекватно быть описаны с помощью традиционных статистических моделей, поскольку являются существенно нелинейными и имеют или хаотичную, или квазипериодическую, или смешанную динамику [4].

Для построения и реализации структуры динамической прогнозирующей модели ОУ могут использоваться разные подходы. При этом известно [5], что нелинейная динамическая система (модель ОУ) может быть представлена путем композиции линейного динамического (ЛДЗ) и нелинейного статического (НСЗ) звеньев, например, в виде модели Винера-Гаммерштайна (Wiener-Hammerstein), которая приведена на рис. 1.

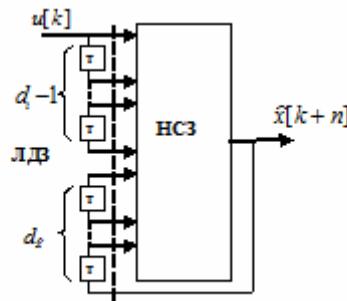


Рисунок 1 – Структура Винера-Гаммерштайна прогнозирующей модели нелинейного динамического ОУ

Здесь  $u[k]$ ,  $\hat{x}[k+n]$  – вход процесса и оценка прогноза его выхода;  $k, n$  – текущий такт времени и глубина прогноза. ЛДЗ является линиями задержки, величины которых (глубина памяти) определяются размерностью входных  $d_i-1$  и выходных  $d_{\hat{x}}$  переменных [6], а в качестве НСЗ могут использоваться как традиционные средства (полиномы Лежандра, Вольтерра, Колмогорова-Габора и др.), так и интеллектуальные (НС, гибридные НС с нечеткой логикой и др.).

Задача идентификации ОУ формулируется таким образом [7]: на основании экспериментального множества функций (временных рядов) возмущений, управлений и выходов в условиях помех определить структуру (обобщенную функцию  $F_{\hat{x}}$ ) и вектор параметров  $a_{\hat{x}}$  модели ОУ, которая достаточно точно (в смысле некоторого критерия)

аппроксимирует его относительно входных и выходных величин во всем функциональном пространстве.

Формирование оценки структуры  $F_{\hat{x}}$  (структурная идентификация) и параметров  $a_{\hat{x}}$  (параметрическая идентификация) модели ОУ осуществляется на основе векторов сигналов наблюдения путем минимизации принятого функционала  $J\{F_{\hat{x}}, a_{\hat{x}}\}$ .

В общем случае функционал  $J\{F_{\hat{x}}, a_{\hat{x}}\}$  полимодальный (имеет несколько локальных минимумов), что требует использования методов глобальной оптимизации, среди которых наиболее эффективными являются поисковые методы [8]. В них алгоритм поиска оптимального решения связывает следующие друг за другом решения таким образом, чтобы получить новое лучшее решение.

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

$$\Psi(j+1) = \Psi(j) - \omega\varsigma\{J[\Psi(j) - \gamma\varsigma] - J[\Psi(j) + \gamma\varsigma]\} \quad (1)$$

где  $\Psi(j) \subset \{F_j, a_j\}$  – значения функции и параметров на  $j$ -м шаге поиска;  $\omega, \varsigma, \gamma$  – параметры, которые определяют сферы принятия решения ( $\omega$ ), сбора информации ( $\gamma$ ) и единичное случайное направление ( $\varsigma$ ). В общем случае параметры в (1) могут изменяться – адаптироваться к процедуре поиска и виду гиперповерхности принятого функционала.

Развитием поисковых методов являются эволюционные алгоритмы, среди которых наиболее распространены генетические алгоритмы (ГА), моделирующие развитие биологической популяции на уровне геномов: мутации структуры и параметров  $\delta\Psi$ , их скрещивание (размножение) [9]:

$$\Psi(j+1) = \Psi(j) + \delta\Psi(j) \quad (2)$$

и правило отбора, что позволяет обнаруживать их благоприятные вариации, с помощью которых строится последовательность улучшенных решений.

Большинство задач, решаемых при помощи ГА, имеют один критерий оптимизации. Многокритериальная оптимизация (МО) основана на отыскании решения, одновременно оптимизирующего более чем одну функцию. В этом случае ищется некоторый компромисс, в роли которого выступает решение, оптимальное в смысле Парето. При МО, использующей ГА выбирается не одна хромосома, представляющая собой оптимальное решение в обычном смысле, а множество хромосом, оптимальных в смысле Парето. Пользователь имеет возможность выбрать оптимальное решение из этого множества:

$$m \cdot \Psi(j+1) = m \cdot [\Psi(j) + \delta\Psi(j)], \quad (3)$$

где  $m \geq 2$  – число рассматриваемых критериев.

Для идентификации эффективны внешние критерии, адекватные задаче построения моделей с минимальной дисперсией ошибки прогноза, которые делятся на критерии регулярности и критерии несмещенности [2].

Критерий регулярности основан на разделении данных на обучающую  $A$  и проверочную  $B$  выборки:

$$J_{pe} = \frac{\|x_A^*[d+n] - \hat{x}_A[d+n]\|}{\|x_B^*[d+n]\|}, \quad (4)$$

где  $x_A^*, \hat{x}_A$  – экспериментальные и полученные по модели значения выхода ОУ;  $d$  – глубина памяти,  $n$  – глубина прогноза. Оптимизация модели осуществляется на обучающей, а проверка ее эффективности (величины ошибки) на проверочной выборке. Вся выборка  $N = A + B$ .

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

$$J_{cm} = \frac{\|\hat{x}_A[d+n] - \hat{x}_B[d+n]\|}{\|x^*[d+n]\|}, \quad (5)$$

где  $\hat{x}_A, \hat{x}_B$  – выходы моделей ОУ, которые обучены на выборках  $A$  и  $B$ , соответственно. Вычисление критерия  $J_{cm}$  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 задач структурной идентификации.

Выбор метода локальной (параметрической) оптимизации определяется выбором типа базисных функций.

Для прогнозирующих систем на базе НС наилучшие качества показывает гетерогенная сеть, которая состоит из скрытых слоев с нелинейной функцией активации нейронов и выходного линейного нейрона [10].

Базисная функция в виде НС прямого распространения (НСПР) со скрытым слоем представляется как [10]:

$$\hat{x}[k+n] = \sum_{\theta \in P} F_l \left\{ \sum_{l \in Q} v_l[\theta] \cdot F_y \left( \sum_{m \in Q} v_{l,m}[\theta] \cdot y_m[k-\theta] \right) \right\}, \quad (6)$$

где  $P$  – множество глубин памяти соответствующих входов;  $F_l$  – активационная функция выходного слоя НС;  $Q$  – множество входов нейронов;  $l$  – порядковый номер входа выходного слоя НС;  $v_l$  – весовые коэффициенты выходного слоя;  $F_y$  – активационная функция нейронов скрытого слоя;  $m$  – порядковый номер входа НС;  $v_{l,m}$  – весовые коэффициенты связи  $m$ -го входа и  $l$ -го нейрона;  $y_m$  – вход НС.

Параметрами настройки (обучения) этой НС являются  $\{v_l, v_{l,m}\} \subset a_{\hat{x}}$ . В общем случае структурными характеристиками НС (6) являются  $\{T_s, P, F_y, F_l, r_s, M_{po}\} \subset F_{\hat{x}}$ , где  $T_s$  – тип структуры,  $r_s \subset Q$  – размер скрытого слоя,  $M_{po}$  – метод параметрической оптимизации (функция обучения НС).

Базисная функция в виде НС с радиальными базисными функциями (РБФ) представляется как [10]:

$$\hat{x}[k+n] = \sum_{\theta \in P} F_l \left\{ \sum_{l,m \in Q} v_l \cdot F_y(\vartheta_l, \|y_m[k-\theta] - v_l\|) \right\}, \quad (7)$$

где  $\vartheta_l, v_l$  – параметры РБФ -го нейрона скрытого слоя.

Параметрами настройки НС (7) являются  $\{\vartheta_l, v_l\} \subset a_{\hat{x}}$ , а ее структурными характеристиками –  $\{T_s, P, F_y, F_l, r_s, M_{po}\} \subset F_{\hat{x}}$ .

Теоретически, системы с нечеткой логикой и НС эквивалентны друг другу, однако на практике у них есть свои преимущества и недостатки. В связи с этим получили развитие гибридные НС, в которых выводы делаются на основе аппарата нечеткой логики, а функции принадлежности подстраиваются с использованием алгоритмов обучения НС. Такие системы не только используют априорную информацию, но могут приобретать новые знания и для пользователя являются логически прозрачными [11].

Базисная функция в виде гибридной НС с нечеткой логикой (Anfis) представляется как [10]:

$$\hat{x}[k+n] = \sum_{\theta \in P} \sum_{m \in Q} \beta_m[\theta] \cdot \alpha_m[k-\theta], \quad (8)$$

$$\beta_m[\theta] = U_m^{-1}(\alpha_m[\theta] / \sum_m \alpha_m[\theta]); \quad \alpha_m[k-\theta] = Tn \{L_{l,m}(y_m[k-\theta])\}$$

где ;

$$U = U(a_u); \quad L = L(a_l).$$

Здесь  $U_m^{-1}$  – функция, обратная функции принадлежности промежуточного выхода  $m$  сети с параметрами  $a_u$ ;  $\alpha_m$  – значение промежуточного выхода;  $Tn$  – произвольная  $t$ -норма моделирования логической операции «И»;  $L_{l,m}$  – функция принадлежности нечеткого правила  $l$  входа  $m$  с параметрами  $a_l$ .

Параметрами настройки НС (8) являются  $\{a_u, a_l\} \subset a_{\bar{x}}$ , а структурными характеристиками –  $\{T_s, P, F_y, F_l, r_s, M_{po}\} \subset F_{\bar{x}}$ , где  $r_p \subset Q$  – количество правил разложения по входам.

Идентификация параметров (обучение) НСПР (6) осуществляется с помощью градиентных алгоритмов обучения: алгоритмов метода сопряженных градиентов, алгоритмов обратного распространения ошибки или квазиньютоновских алгоритмов. При обучении НС с РБФ (7) сначала определяются центры и отклонения для радиальных элементов, после чего оптимизируются параметры линейного выходного слоя. Обучение гибридной НС (8) выполняется аналогично НСПР (6) путем оптимизации параметров функций принадлежности с помощью гибридного алгоритма или алгоритма обратного распространения ошибки [12]. Преимуществом этих алгоритмов параметрического обу-

чения НС является их простота и быстродействие, а недостатком – их локальность.

Рассмотрим разработку интеллектуальной прогнозирующей модели процесса крупнокускового дробления руд (ККД), выходной координатой которого является содержание в дробленой руде класса  $+100$  мм  $\Gamma_{+100}$ .

Для идентификации процесса ККД в качестве входных сигналов использовались экспериментальные временные последовательности средневзвешенной крупности  $\Gamma_{av}$  и крепости  $Kp$  входной руды, а также управляющего воздействия – размера разгрузочной щели дробилки  $W$ .

При этом, в соответствии с динамическими свойствами процесса ККД глубина прогноза составляла  $n = 3$  такта (для компенсации запаздывания и времени на выработку и реализацию управляющего воздействия), а глубина памяти – 4 такта. Погрешность измерения переменных процесса ККД не превышала 10%, а размер реализаций составил  $N = 60$  тактов (порций руды).

При идентификации в качестве глобальных методов оптимизации применялись ПСП и ГА. При этом использовалась структура моделей Винера-Гаммерштейна (см. рис. 1) с базисными функциями в виде НС: каскадной НСПР (6), НС РБФ (7) и НС Anfis (8).

В целом установлено, что минимуму критерия несмещенности для процесса ККД отвечают базисные функции в виде каскадной НСПР. При этом количество нейронов в скрытом слое составляет 26, функция активации скрытого слоя – сигмоидальная, выходного слоя – линейная, алгоритм обучения НС – метод Флетчера-Ривса (Fletcher-Reeves).

Модели в виде НС с РБФ (7) требуют гораздо меньше вычислений, но их значение критерия (5) существенно выше, что можно объяснить плохой прогностической способностью этих НС.

Модели в виде НС с нечеткой логикой Anfis (8) имеют достаточную точность, но у них очень низкое быстродействие при размерностях вектора входов больше 5 (суммарное количество входов модели ККД составляет 10).

В качестве меры точности параметрической идентификации модели оптимальной структуры использовался критерий регулярно-

сти (4), значение которого для модели процесса ККД составило 0,0357.

Адекватность полученной интеллектуальной прогнозирующей модели процесса ККД проверялась по непараметрическому критерию знаков [13]. Установлено, что разработанная модель с идентифицированными структурой и параметрами адекватна с уровнем значимости 0,01 динамике процесса ККД.

**Выводы.** Предложена методика структурно-параметрической идентификации нелинейных динамических процессов, включающая процедуры генерирования структур, селекцию моделей и оптимизацию их параметров. При этом для решения задачи идентификации используются алгоритмы глобальной и локальной оптимизации. В целом это позволяет получить интеллектуальные прогнозирующие модели нелинейных динамических процессов повышенной точности.

Дальнейшие исследования должны быть направлены на разработку алгоритмов управления сложными процессами с использованием предложенной методики структурно-параметрической идентификации.

#### ЛИТЕРАТУРА

1. Корниенко В.И. Интеллектуальные методы структурно-параметрической идентификации технологических процессов рудоподготовки / В.И. Корниенко, А.В. Пивоварова // Гірнича електромеханіка та автоматика: Наук.-техн. зб. – 2008. – Вип. 80.– С. 71-77.
2. Ивахненко А.Г. Долгосрочное прогнозирование и управление сложными системами / А.Г. Ивахненко. – К.: Техніка, 1975. – 312 с.
3. Mueller J.-A, Lemke F. Self-Organising Data Mining. An Intelligent Approach To Extract Knowledge From Data. – Berlin, Dresden, 1999. – 225 р.
4. Кузнецов С.П. Динамический хаос / С.П. Кузнецов – М.: Физматлит, 2002. – 296 с.
5. Nelles O. Nonlinear System Identification: From Classical Approaches to Neural and Fuzzy Models / O. Nelles. – Berlin: Springer, 2001. – 785 р.
6. Малинецкий Г.Г. Современные проблемы нелинейной динамики / Г.Г. Малинецкий, А.Б. Потапов // М.: Эдиториал УРСС, 2000. – 336 с. – ISBN 5-8360-0110-3.

7. Справочник по теории автоматического управления / Под ред. А.А. Красовского. – М.: Наука, 1987. – 712 с.
8. 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 р.
9. 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.
10. Кузнецов Г.В. Композиційна структурно-параметрична ідентифікація нелінійних динамічних об'єктів керування / Г.В. Кузнечов, В.І. Корніенко, О.В. Герасіна // Наукові вісті НТУУ КПІ. – 2009. – № 5. – С. 69-75.
11. Круглов В.В. Нечеткая логика и искусственные нейронные сети / В.В. Круглов, М.И. Дли, Р.Ю. Голунов. – М.: Физматлит, 2001. – 224 с.
12. Нейронные сети. MATLAB 6 / Под ред. В.Г. Потемкина. – М.: ДІАЛОГ-МИФІ, 2002. – 496с.
13. Ван дер Варден Б.Л. Математическая статистика / Б.Л. Ван дер Варден. – М.: Изд-во иностр. лит., 1960. – 436 с.