

ГИБРИДНЫЙ АЛГОРИТМ ИДЕНТИФИКАЦИИ МОДЕЛИ ГАММЕРШТЕЙНА, ЛИНЕЙНОЙ ПО СОСТОЯНИЯМ

Введение. Задача идентификации объектов составляет один из основных этапов создания систем управления и принятия решений. Реальные объекты обычно характеризуются нелинейной сложной структурой, а также неполнотой математического описания и информации как о самих объектах, так и о сигналах и помехах, действующих на них. Поэтому хорошо развитые методы идентификации линейных систем либо вообще непригодны, либо имеют ограниченное применение для идентификации нелинейных систем. Именно поэтому не прекращается интенсивный поиск эффективных подходов и методов для идентификации нелинейных систем. Одним из них является блок-ориентированный подход, который в сочетании с методами биологического происхождения (генетические алгоритмы, интеллект роя, нейронные сети и т.п.) может существенно расширить класс нелинейных динамических систем, идентификация которых станет возможной. Суть этого подхода заключается в том, что система известной структуры разбивается на относительно простые линейные и нелинейные подсистемы, которые определенным образом связаны между собой некоторыми сигналами. Каждая подсистема идентифицируется на основе измеряемых входных и выходных сигналов полной системы и априорной информации о ней. При этом сигналы, передаваемые от одной подсистемы к другой, нельзя измерить.

Под системой типа Гаммерштейна понимают систему, которую можно представить в виде двух подсистем: статической нелинейной подсистемы, предшествующей линейной динамической подсистеме. Модели таких систем образуют класс моделей Гаммерштейна. Все модели этого класса имеют общую структуру и отличаются между собой составными частями и методами их идентификации.

Несмотря на кажущуюся простоту, модели Гаммерштейна находят широкое практическое применение, в частности для моделирования ректификационных колонн и теплообменников [1], электрических приводов [2], нелинейных фильтров [3], биологических систем [4], водонагревателей [5], процесса нейтрализации рН [6, 7], для решения задачи идентификации объектов в автоматизированной системе управления технологическими процессами рудоподготовки [8], для идентификации нелинейного динамического процесса обогащения железной руды [9] и т.п.

В теоретическом плане одной из первых публикаций по исследованию модели Гаммерштейна была работа [10]. В ней предложен итерационный метод для идентификации нелинейных систем по входным и выходным данным при наличии шума. Модель состояла из нелинейного статического многочлена и линейной дискретной системы. Параметры импульсной передаточной функции линейной системы и коэффициенты полиномиальной нелинейности оценивались итерационным методом наименьших квадратов так, чтобы минимизировать критерий среднеквадратичной погрешности.

В работе [11] для идентификации системы Гаммерштейна предложен расширенный алгоритм наименьших квадратов. Нелинейная статическая функция была представлена в виде линейной комбинации базисных функций с неизвестными коэффициентами. Установлена сильная состоятельность оценок, а также получены их скорости сходимости.

Интересный метод идентификации модели Гаммерштейна, основанный на методе функциональных преобразований и идеях статистической линеаризации, предложен в [12]. Он представляет собой нелинейный аналог метода статистической линеаризации. Его частными случаями являются традиционные методы статистической линеаризации и методы дисперсионной идентификации. Приведены примеры решения задачи идентификации в классе систем, описываемых уравнениями Гаммерштейна.

В работе [13] построены модели Гаммерштейна с учетом препятствий на выходе объекта типа мартингальной последовательности и скользящего среднего. Для стохастических градиентных алгоритмов приведены необходимые и достаточные условия сильной состоятельности оценки параметров. Оценена скорость их сходимости. Полученные результаты использованы в задаче адаптивного слежения за выходом объекта.

Исследованию метода статистической линеаризации нелинейных стохастических объектов на основе дисперсионной теории идентификации для класса моделей Гаммерштейна посвящена работа [14]. Построены модели статистической линеаризации с учетом препятствий на выходе объекта типа белого шума и мартингальной последовательности. Решение получено в классе градиентных алгоритмов рекуррентной идентификации. Приведены необходимые и достаточные условия сильной состоятельности оценки параметров этими алгоритмами.

Общий подход к задаче идентификации нелинейных динамических объектов со структурой Гаммерштейна и двухуровневыми входными сигналами предлагается в [15]. Метод идентификации основан на возможности представления аналитической нелинейности в виде суммы четной и нечетной функций. При образовании интегральных уравнений, описывающих объект, четная и нечетная части разделяются, что существенно облегчает процедуру идентификации. Приводятся результаты численного моделирования.

В работе [16] рассматривалась модель Гаммерштейна, в которой динамическая часть представлена моделью авторегрессионного скользящего среднего, а статическая нелинейная часть моделировалась нейронной сетью радиальных базисных функций (НСРБФ). Определение оптимальной структуры и обучения НСРБФ осуществлялись с помощью генетического алгоритма.

В данной работе для обучения НСРБФ предлагается задействовать интеллект роя, а линейную динамическую часть представить моделью пространства состояний, что позволит охватить более широкий круг реальных систем. Для оценки параметров подсистем модели Гаммерштейна разработан рекурсивный гибридный алгоритм.

Постановка задачи и подход к ее решению. Рассмотрим дискретную нелинейную динамическую систему с одним входом и одним выходом, которую можно описать моделью Гаммерштейна следующего вида (рис. 1):

$$\begin{cases} v(t) = f(u(t)), \\ \mathbf{x}(t+1) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}v(t) + \boldsymbol{\eta}(t), \\ y(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}v(t) + \zeta(t), \end{cases} \quad (1)$$

где $u(t)$ — входной сигнал; $f(\cdot)$ — неизвестная нелинейная функция; $y(t)$ — выходной сигнал; $v(t)$ — промежуточный неизмеряемый сигнал; $x(t)$ — состояние системы; $\zeta(t)$ и $\eta(t)$ — независимые белые гауссовские шумы измерения и процесса соответственно; $\mathbf{A} \in \mathcal{R}^{n \times n}$, $\mathbf{B} \in \mathcal{R}^{n \times 1}$, $\mathbf{C} \in \mathcal{R}^{1 \times n}$, $\mathbf{D} \in \mathcal{R}^{1 \times 1}$ — неизвестные матрицы.




Рис. 1

Задача идентификации данной модели заключается в следующем: имеем N последовательных измерений входного и выходного сигналов системы: $\{u(t)\}_{t=1}^N$ и $\{y(t)\}_{t=1}^N$. Необходимо найти такие матрицы \mathbf{A} , \mathbf{B} , \mathbf{C} и \mathbf{D} линейной динамической части и параметры модели нелинейной статической функции $f(\cdot)$, чтобы суммарная квадратичная погрешность выходного сигнала (или индекс погрешности)

$$I = \sum_{t=1}^N [y(t) - \hat{y}(t)]^2 \quad (2)$$

достигала заданной точности, где $\hat{y}(t)$ — выходной сигнал оцениваемой модели в дискретный момент времени t .

Поскольку в моделях Гаммерштейна выход $y(t)$ находится в нелинейной зависимости от входа $u(t)$, то задача их идентификации нетривиальна. Успех ее решения во многом зависит как от выбранной модели нелинейной части, так и от метода оценки ее параметров. В данной работе нелинейная статическая функция $f(\cdot)$ моделируется НСРБФ. Для оценки параметров этой сети, каковыми являются веса ее выходного слоя, предлагается применить алгоритм оптимизации роя частиц (ОРЧ). И, наконец, для оценки матриц пространства состояний \mathbf{A} , \mathbf{B} , \mathbf{C} , \mathbf{D} будем использовать численный алгоритм идентификации подпространства N4SID.

На рис. 2 представлена структура данного подхода к идентификации модели Гаммерштейна.




Рис. 2

Остановимся кратко на каждой из составляющих данного подхода.

Нейронные сети радиальных базисных функций. Нейронную сеть радиальных базисных функций (РБФ), как одну из искусственных нейронных сетей, предложили Д.С. Брумхид (D.S. Broomhead) и Д. Лоув (D. Lowe) в 1988 г. [17]. В общем случае она представляет собой трехслойную нейронную сеть прямого распространения сигнала. Эта сеть привлекла к себе особое внимание после того, как было доказано, что радиальными базисными функциями можно приблизить любую непрерывную функцию с произвольно заданной точностью при условии, что РБФ выбраны правильно и сеть хорошо обученная [18].

В данной работе для аппроксимации нелинейной функции $f(\cdot)$ используется НСРБФ с одним входом и одним выходом (рис. 3).




Рис. 3

Данная НСРБФ имеет m нейронов в скрытом слое и базисный вектор

$$\Phi(t) = [\phi_1(t), \phi_2(t), \dots, \phi_m(t)],$$

где $\phi_i(t) = \exp\left(-\frac{\|u(t) - c_i\|^2}{2\sigma_i^2}\right)$ — функция Гаусса, c_i — центр i -й РБФ, параметр σ_i определяет радиус влияния i -й РБФ и скорость ее стремления к нулю при удалении от центра, символ $\|\cdot\|$ обозначает евклидову норму.

Если набор весов выходного слоя НСРБФ представить в виде вектора

$$\mathbf{W} = [w_1, w_2, \dots, w_m],$$

то на выходе этой сети получим

$$v(t) \equiv f(u(t)) = \mathbf{W}\Phi^T(t). \quad (3)$$

Алгоритм оптимизации роя частиц. В 1995 г. Джеймс Кеннеди (James Kennedy) и Рассел Эберхарт (Russel Eberhart), позаимствовав идею у биологических систем, предложили метод для оптимизации непрерывных нелинейных функций, названный ими алгоритмом оптимизации роя частиц (ОРЧ) [19]. Этот алгоритм является эвристическим и имитирует поведение животных, живущих роем и совместно действующих для обеспечения безопасности, нахождения пищи или места жительства и т.п.

В настоящее время алгоритм ОРЧ широко применяется, наряду с другими, в задачах машинного обучения (в частности, для обучения нейросетей и распознавания изображений), параметрической и структурной оптимизации (форм, размеров и топологий) в области проектирования, в областях биохимии и биомеханики и т.д. По эффективности он может соперничать с другими методами глобальной оптимизации, а низкая алгоритмическая сложность способствует простоте его реализации. Этот алгоритм может надежно и быстро решать сложные нелинейные задачи и демонстрирует стабильные характеристики сходимости. В нем поиск является направленным, так как каждая позиция частицы обновляется в направлении оптимального решения.

В данной работе каждая частица роя представляет собой значения возможных весов выходного слоя НСРБФ и является точкой в m -мерном пространстве. Целевой функцией (ЦФ) частицы является величина, обратная индексу погрешности (2). Чем этот индекс больше, тем более пригодной является частица. Основываясь на этом принципе, алгоритм ОРЧ обновляет позиции всех частиц таким образом, чтобы они перемещались в направлении оптимальных весов для НСРБФ.

Скорость и позиция (или координаты) i -й частицы обновляются в дискретные моменты времени по формулам

$$\mathbf{V}_i(t+1) = \mathbf{K}\{\omega \cdot \mathbf{V}_i(t) + d_1 r_{i1}[\mathbf{Pbest}_i(t) - \mathbf{Z}_i(t)] + d_2 r_{i2}[\mathbf{Gbest}(t) - \mathbf{Z}_i(t)]\};$$

$$\mathbf{Z}_i(t+1) = \mathbf{Z}_i(t) + \mathbf{V}_i(t+1),$$

где $\mathbf{Z}_i(t)=[z_{i1}(t),\dots,z_{im}(t)]$ — позиция i -й частицы в момент времени t (т.е. в течение t -й итерации), m — количество параметров оптимизации; $\mathbf{V}_i(t)=[v_{i1}(t),\dots,v_{im}(t)]$ — скорость i -й частицы в момент времени t (в течение t -й итерации); $\mathbf{Pbest}_i(t)=[p_{i1}(t),\dots,p_{im}(t)]$ — позиция, при которой i -я частица достигла своего лучшего значения ЦФ в течение времени t (за t итераций); $\mathbf{Gbest}(t)=[g_1(t),\dots,g_m(t)]$ — позиция, при которой достигнуто глобально наилучшее значение ЦФ (т.е. всеми частицами) в течение времени t (за t итераций); K, ω — коэффициенты сжатия и инерции; d_1, d_2 — когнитивный и социальный параметры; r_{i1}, r_{i2} — случайные числа от 0 до 1.

В общих чертах алгоритм ОРЧ выглядит так.

1. Задать количество итераций (L_{\max}), размер популяции Q , ограничения на скорость частиц \mathbf{V}^{\max} , коэффициенты d_1, d_2, K и ω .
2. Сгенерировать случайным образом скорости $\mathbf{V}_i(0)$ всех частиц, удовлетворяющих условию $\mathbf{V}_i(0) < \mathbf{V}^{\max}$.
3. Сгенерировать случайным образом позиции всех частиц роя.
4. Положить $t = 1$.
5. Оценить значение целевой функции $F_i(t)$ i -й частицы.
6. Если $F_i(t) > F_i^{\text{best}}$, то $\mathbf{Pbest}_i(t) = \mathbf{Z}_i(t)$.
7. Если $F_i(t) > F_g^{\text{best}}$, то $\mathbf{Gbest}(t) = \mathbf{Z}_i(t)$.
8. Обновить скорости всех частиц $\mathbf{V}_i(t)$.
9. Обновить позиции всех частиц $\mathbf{Z}_i(t)$.
10. Условие завершения выполняется?
 - а) да: вывести результаты и завершить работу;
 - б) нет: увеличить i .
11. Проверить условие: i меньше общего количества частиц?
 - а) да: положить $i = 1$, увеличить t и перейти к п. 5;
 - б) нет: перейти к п. 5.

Идентификация подпространства дискретной модели пространства состояний. В дискретной модели пространства состояний связь между входными сигналами, шумами и выходными сигналами записывается в виде разностных уравнений первого порядка путем введения вспомогательного вектора состояний $\mathbf{x}(t)$. Такой способ описания линейных динамических систем стал преобладающим с момента появления первой работы Р. Калмана [20], посвященной вопросам прогнозирования и линейно-квадратичного управления. Он привлек к себе внимание тем, что имеющиеся физические представления о механизмах работы системы, как правило, гораздо проще учесть в моделях пространства состояний, чем в других моделях. В частности, эти модели больше всего подходят для описания систем со многими входами и выходами [21].

В общем случае дискретную линейную динамическую систему можно задать моделью пространства состояний:

$$\begin{cases} \mathbf{x}(t+1) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{v}(t) + \boldsymbol{\eta}(t), \\ \mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}\mathbf{v}(t) + \boldsymbol{\zeta}(t). \end{cases} \quad (4)$$

Сигналы $\mathbf{v}(t) \in \mathfrak{R}^m$ и $\mathbf{y}(t) \in \mathfrak{R}^l$ — векторы для m входов и l выходов системы, которые наблюдаются в дискретные моменты времени t . Вектор $\mathbf{x}(t) \in \mathfrak{R}^n$ являет-

ся вектором состояния процесса в дискретный момент времени t и содержит численные значения n состояний, $\zeta(t) \in \mathcal{R}^{l \times 1}$ и $\eta(t) \in \mathcal{R}^{n \times 1}$ — векторы ненаблюдаемых сигналов, которые обычно называют шумом измерения и шумом процесса соответственно. Считается, что они имеют нулевое среднее и являются стационарными последовательностями белого шума. Влияние процесса $\eta(t)$ отличается от воздействия $\zeta(t)$: $\eta(t)$, как вход, будет иметь динамический эффект на состояние $\mathbf{x}(t)$ и выход $\mathbf{y}(t)$, в то время как $\zeta(t)$ влияет только на выход $\mathbf{y}(t)$.

Входная матрица $\mathbf{B} \in \mathcal{R}^{n \times m}$ представляет собой линейное преобразование, с помощью которого детерминированные входы влияют на следующее состояние, $\mathbf{A} \in \mathcal{R}^{n \times n}$ — матрица динамики линейной системы порядка n , $\mathbf{C} \in \mathcal{R}^{l \times n}$ — выходная матрица, описывающая, как внутреннее состояние передается внешней среде в наблюдениях $\mathbf{y}(t)$, $\mathbf{D} \in \mathcal{R}^{l \times m}$ — матрица прямой связи. Считается, что все режимы системы могут быть нарушены любым детерминированным входом $\mathbf{v}(t)$ и/или стохастическим входом $\eta(t)$.

Идентификация модели пространства состояний (4) заключается в оценке ее параметров, т.е. порядка n и матриц \mathbf{A} , \mathbf{B} , \mathbf{C} , \mathbf{D} , имея только данные S последовательных наблюдений входа $\mathbf{v}(1), \dots, \mathbf{v}(S)$ и выхода $\mathbf{y}(1), \dots, \mathbf{y}(S)$.

Для решения этой сложной задачи на основе различных идей, фактов и алгоритмов из теории систем, статистики, теории оптимизации и линейной алгебры были разработаны методы «идентификации подпространства», название которых отражает тот факт, что линейные модели могут быть получены из пространств строк и столбцов некоторых матриц, вычисленных по входным и выходным данным. Как правило, пространство столбцов таких матриц данных содержит информацию о модели, в то время как пространство строк позволяет получить последовательности состояний фильтра Калмана непосредственно из входных и выходных данных (не зная модели априори). Идентификация подпространства направлена на построение нужной модели пространства состояний по входным и выходным данным.

Алгоритмы идентификации подпространства прекрасно подходят для больших наборов данных и крупномасштабных систем. Эти алгоритмы значительно быстрее «классических» методов идентификации, таких как методы прогноза погрешности [21], поскольку они не являются итерационными и для них отсутствуют проблемы конвергенции. Как следствие, пользователь никогда не столкнется с такими недоразумениями, как полное отсутствие или медленная сходимость, или нестабильность вычислений. Кроме того, в алгоритмах идентификации подпространства нет никакой необходимости в явной параметризации модели. В них единственным параметром является порядок модели n . В то время как для классических алгоритмических подходов необходимо провести исследования для определения так называемой канонической модели, т.е. модели с минимальным числом параметров. Во многих случаях это сделать непросто.

Важно отметить, что в алгоритмах идентификации подпространства вся динамика сосредоточена в одной матрице \mathbf{A} , т.е. можно сказать, что собственные значения матрицы \mathbf{A} будут описывать все динамические режимы, которые были измерены, неважно исходят они от реальной системы, от стохастических динамических возмущений и т.п. Поэтому для линейной подсистемы модели Гаммерштейна дополнительный способ проверки качества ее идентификации заключается в сравнении собственных значений матрицы \mathbf{A} идентифицированной и фактической подсистем.

В настоящее время существует несколько алгоритмов идентификации подпространства, наиболее известным из них является алгоритм N4SID (Numerical

algorithm for Subspace State Space System IDentification), предложенный В. Оверши (V. Overschee) и Б. Муром (B. Moor) в 1994 г. Для большого количества входных и выходных измерений, порожденных неизвестной системой уравнений (4), этот алгоритм может определить порядок системы n , матрицы системы \mathbf{A} , \mathbf{B} , \mathbf{C} , \mathbf{D} и, если необходимо, получить матрицу Калмана без каких-либо предварительных знаний о структуре системы. Это достигается выполнением двух основных шагов.

- Определение порядка модели n и оценок $\hat{x}_i, \hat{x}_{i+1}, \dots, \hat{x}_{i+j}$ последовательно-сти состояний фильтра Калмана, сначала проектируя пространства строк блочных матриц Ганкеля для данных, а затем применяя сингулярное разложение.

- Получение матриц пространства состояний \mathbf{A} , \mathbf{B} , \mathbf{C} и \mathbf{D} с помощью метода наименьших квадратов.

Математические детали алгоритма N4SID приведены в работе [22]. Программная реализация этого алгоритма представлена в пакете System Identification Toolbox, который является одним из расширений MATLAB.

Гибридный алгоритм ОРЧ/ИП идентификации модели Гаммерштейна.

Входными данными для рассматриваемого алгоритма является N последовательных измерений входных и выходных сигналов системы: $\{u(t)\}_{t=1}^N$ и $\{y(t)\}_{t=1}^N$. Алгоритм реализует предложенный подход к идентификации модели Гаммерштейна (см. рис. 2) и может быть представлен следующими шагами.

1. Нахождение первичной оценки матриц пространства состояний \mathbf{A}_0 , \mathbf{B}_0 , \mathbf{C}_0 , \mathbf{D}_0 по исходным нелинейным данным с использованием идентификации подпространства.

2. Определение базисных векторов НСРБФ $\Phi(t) = [\phi_1(t), \phi_2(t), \dots, \phi_m(t)]$, $t = \overline{1, N}$.

3. Инициализация алгоритма ОРЧ для получения начальной популяции случайных частиц (или весов НСРБФ).

4. Вычисление целевой функции частиц популяции и нахождение глобально лучшего набора весов, который минимизирует индекс погрешности, заданный равенством (2).

5. Оценка выходной последовательности НСРБФ $\{v(t)\}_{t=1}^N$ при оптимальных весах.

6. Переоценка матриц пространства состояния \mathbf{A} , \mathbf{B} , \mathbf{C} и \mathbf{D} по новому выходу нейронной сети $\{v(t)\}_{t=1}^N$ (который также является входом в линейную систему) и фактическому выходу системы $\{y(t)\}_{t=1}^N$. Эта оценка модели пространства состояний будет лучшей по сравнению с предыдущей.

7. Переоценка выходной последовательности $\{\hat{y}(t)\}_{t=1}^N$ модели по новым матрицам \mathbf{A} , \mathbf{B} , \mathbf{C} , \mathbf{D} и выходу нейронной сети $\{v(t)\}_{t=1}^N$.

8. Если индекс погрешности между $\{y(t)\}_{t=1}^N$ и $\{\hat{y}(t)\}_{t=1}^N$ не меньше заданного, то обновить популяцию частиц и повторить шаги 4–8. В противном случае — вывести результаты решения задачи.

Численное моделирование. Проверим работу предложенного алгоритма на простом примере. Рассмотрим тестовую систему Гаммерштейна:

$$\begin{cases} v(t) = f(u(t)) = \text{sign}(u(t))\sqrt{|u(t)|}, \\ \mathbf{x}(t+1) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}v(t), \\ y(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}v(t), \end{cases}$$

где

$$\mathbf{A} = \begin{bmatrix} 1,80 & 1 & 0 \\ -1,07 & 0 & 1 \\ 0,21 & 0 & 0 \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} 4,80 \\ 1,93 \\ 1,21 \end{bmatrix}, \quad \mathbf{x}(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ x_3(t) \end{bmatrix}, \quad \mathbf{C} = [1 \ 0 \ 0], \quad \mathbf{D} = [0],$$

т.е. в данном примере динамическая линейная часть модели Гаммерштейна задана дискретной моделью пространства состояний третьего порядка, а статическая нелинейная часть представлена квадратным корнем от входа. Для простоты будем считать, что $u(t) = t$.

Желаемые выходы генерируются запуском модели процесса с большим количеством (не менее 1000) равномерно распределенных случайных чисел во входном интервале $[-1,75; 1,75]$. НСРБФ имеет 10 нейронов, которые инициализируются со случайными весами, равномерно распределенными во входном интервале. Центры для РБФ выбираются с использованием метода кластеризации по К-средним. Каждая частица роя представляет собой 10-мерный вектор. Размер популяции роя частиц равен 50, а процесс оптимизации продолжается до 100 итераций. В соответствии с рекомендациями работы [23] социальный и когнитивный параметры алгоритма ОРЧ d_1 и d_2 взяты такими, что $d_1 + d_2 \geq 4$, и при этом d_1 немного больше d_2 .

Алгоритм показывает хорошие результаты. В среднем за 14 итераций среднеквадратичная погрешность между нормированными значениями фактических и модельных выходов стремится к конечному значению 4×10^{-4} .

На рис. 4 и 5 приведены графики оценки статической нелинейности и динамической линейности соответственно. Как видим, предложенный алгоритм оценивает форму нелинейности и линейности с хорошей точностью.

Собственными значениями матрицы \mathbf{A} линейной динамической части тестовой модели являются:

$$\lambda_1 = 0,7, \quad \lambda_2 = 0,6 \quad \text{и} \quad \lambda_3 = 0,5.$$

Матрица динамики линейной части идентифицированной модели имеет следующие собственные значения:

$$\hat{\lambda}_1 = 0,6841, \quad \hat{\lambda}_2 = 0,6312 \quad \text{и} \quad \hat{\lambda}_3 = 0,4697,$$

которые достаточно близки к собственным значениям тестовой модели.

На рис. 6 приведен график сходимости среднеквадратичной погрешности, а на рис. 7 — кривые зависимости выхода от времени полной модели Гаммерштейна.

Заметим, что на рис. 4, 5 и 7 непрерывная линия соответствует тестовой системе, а пунктирная — ее идентифицированной модели.




Рис. 4




Рис. 5




Рис. 6




Рис. 7

Заключение. В настоящей работе предложен гибридный алгоритм идентификации модели Гаммерштейна. Структура идентификации состоит из НСРБФ и модели пространства состояний. Разработан рекурсивный алгоритм, который использует метод оптимизации роя частиц для оценки весов нейронной сети и идентификацию подпространства для оценки модели пространства состояний. Алгоритм проверен на численном примере и показал хорошие результаты идентификации. Его свойства конвергенции непосредственно связаны со свойствами конвергенции алгоритма ОРЧ и подпространственным алгоритмом N4SID. Математический анализ конвергенции является достаточно трудной задачей из-за нелинейной природы нейронной сети.

Ф.Г. Гаращенко, О.Г. Мороз

ГІБРИДНИЙ АЛГОРИТМ ІДЕНТИФІКАЦІЇ МОДЕЛІ ГАММЕРШТЕЙНА, ЛІНІЙНОЇ ЗА СТАНАМИ

Запропоновано гібридний алгоритм ідентифікації нелінійної динамічної моделі Гаммерштейна, в якій статична нелінійність моделюється нейронною мережею радіальних базисних функцій (НМРБФ), а лінійна динамічна частина — моделлю простору станів. Алгоритм використовує оптимізацію рою частинок (ОРЧ) для оцінки параметрів НМРБФ та ідентифікацію підпростору (ІП) для оцінки параметрів лінійної частини. Чисельний приклад демонструє ефективність запропонованого алгоритму ОРЧ/ІП.

F.G. Garashchenko, O.G. Moroz

HYBRID ALGORITHM FOR IDENTIFICATION OF LINEAR BY STATES HAMMERSTEIN MODEL

Hybrid algorithm is proposed for identification of nonlinear dynamic Hammerstein model where static nonlinearity is modelled with radial basis functions neural network (RBFNN) and linear dynamic part — with state-space model. The algorithm uses particle swarm optimization (PSO) for RBFNN parameters estimating and subspace identification (SI) — for linear part parameters. Numerical example demonstrates the effectiveness of the PSO/SI algorithm proposed.

1. *Eskinat B., Johnson S.H.* Use of Hammerstein models in identification of nonlinear systems // *AIChE Journal*. — 1991. — **37**, N 2. — P. 255–268.
2. *Balesinno A., Landi A., Ould-Zmirli M., Sani L.* Automatic nonlinear auto-tuning method for Hammerstein modeling of electrical drives // *IEEE Trans. on Industrial Electronics*. — 2001. — **48**, N 3. — P. 645–655.

3. *Haddad A.H., Thomas J. B.* On optimal and suboptimal nonlinear filters for discrete inputs // IEEE Trans. on Information Theory. — 1968. — **14**, N 1. — P. 16–21.
4. *Hunter I.W., Korenberg M.J.* The identification of nonlinear biological systems: Wiener and Hammerstein cascade models // *Biolog. Cybernet.* — 1986. — **55**, N 2. — P. 135–144.
5. *Abonyi I., Nagy L., Szeifert E.* Hybrid fuzzy convolution modelling and identification of chemical process systems // *Intern. Journal Systems Science.* — 2000. — **31**, N 4. — P. 457–466.
6. *Kulkarni B.D., Tambe S.S., Shukla N.V., Deshpande P.B.* Nonlinear pH control // *Chem. Eng. Sci.* — 1991. — **46**, N 7. — P. 995–1003.
7. *Fruzzetti K.P., Palazoglu A., McDonald K.A.* Nonlinear model predictive control using Hammerstein models // *J. Proc. Control.* — 1997. — **7**, N 1. — P. 31–41.
8. *Герасина А.В., Корниенко В.И.* Идентификация объектов управления в АСУТП рудоподготовки // *Науковий вісник Національного гірничого університету.* — 2010. — № 9–10. — С. 102–106.
9. *Моркун В.С., Поркуян О.В., Проказа Е.И.* Идентификация технологических объектов обогащительного производства на основе ортогональных моделей Гаммерштейна // *Наукові праці ДонНТУ.* — 2007. — Вип. 15(131). — С. 109–114.
10. *Narendra K.S., Gallman P.* An iterative method for the identification of nonlinear systems using Hammerstein model // *IEEE Trans. on Automatic Control.* — 1966. — **11**, N 3. — P. 546–550.
11. *Wenxiao Z.* Identification for Hammerstein systems using extended least squares algorithm // *26th Chinese Control Conference.* — 2007. — P. 241–245.
12. *Пащенко А.Ф., Пащенко Е.Ф.* Идентификация нелинейных систем в классе блочно-ориентированных моделей // *Адаптивные и робастные системы.* — 2010. — № 4. — С. 149–159.
13. *Болквадзе Г.Р.* Класс моделей Гаммерштейна в задачах идентификации стохастических систем // *Автоматика и телемеханика.* — 2003. — №1. — С. 42–55.
14. *Болквадзе Г.* Метод дисперсионной статистической линеаризации нелинейных стохастических систем класса Гаммерштейна // *Там же.* — 2004. — № 7. — С. 12–26.
15. *Чостковский Б.Л., Юдашкин А.А.* Активная идентификация нелинейных динамических объектов типа Гаммерштейна // *Там же.* — 1992. — № 1. — С. 96–103.
16. *Гаращенко Ф.Г., Мороз О.Г.* Ідентифікація нелінійної системи Гаммерштейна за допомогою генетичного алгоритму // *Вісн. Київ. нац. ун-ту ім. Т. Шевченка. Сер.: фізико-математичні науки.* — 2012. — № 1. — С. 145–150.
17. *Broomhead D.S., Lowe D.* Multivariable functional interpolation and adaptive networks // *Complex Systems.* — 1988. — **2**, N 3. — P. 321–355.
18. *Park J., Sanberg I.W.* Universal approximation using radial-basis-function networks // *Neural Computation.* — 1991. — **2**, N 2. — P. 246–257.
19. *Kennedy J., Eberhart R.C.* Particle swarm optimization // *Proc. of IEEE International Conference on Neural Networks, Perth, Australia.* — 1995. — **4**. — P. 1942–1948.
20. *Kalman R.E.* On the general theory of control systems // *Proc. First IFAC Congress, Moscow. Butterworths, London.* — 1960. — **1**, N 1. — P. 481–492.
21. *Льюнг Л.* Идентификация систем. Теория для пользователя: Пер. с англ. / Под ред. Я.З. Цыпкина. — М.: Наука, 1991. — 432 с.
22. *Overschee V., Moor B.D.* N4SID: Subspace algorithms for the identification of combined deterministic-stochastic systems // *Automatica.* — 1994. — **30**, N 1. — P. 75–93.
23. *Carlisle A., Dozier G.* An off-the-shelf PSO // *Proceedings of the Particle Swarm Optimization Workshop.* — 2001. — P. 1–6.

Получено 09.07.2013