

**Методы идентификации и оптимизации в интеллектуальных системах**

к.т.н. Крыжановская Т.Г., д.т.н. проф. Пупков К.А.  
 Университет машиностроения, МГТУ им. Н.Э. Баумана,  
 Ipk2@mail.ru

**Аннотация.** В статье приведены несколько алгоритмов методов идентификации, описывающих сложные объекты или системы управления, в том числе: алгоритм идентификации линейных переменных во времени систем управления, многоядный алгоритм принятия решения методом группового учета аргументов и нейронные пакеты для решения задачи аппроксимации функций.

**Ключевые слова:** алгоритм идентификации линейных систем управления, метод группового учета аргументов, нейросетевое моделирование.

Процесс разработки системы управления начинается с создания конструктором концептуальной модели этой системы, при этом ключевая информация при решении задач анализа, синтеза и оптимизации САУ сосредоточена в математической модели (ММ) объекта управления[1].

Существует достаточно много сложных объектов, для которых протекающие физические процессы мало изучены, а значит, применение фундаментальных законов физики для построения ММ неэффективно. В этом случае проблема построения ММ относится к проблеме идентификации математических моделей объектов управления.

Рассмотрим следующие примеры алгоритмов и методов идентификации: алгоритм идентификации линейных переменных во времени систем управления, метод Группового Учета Аргументов (МГУА) на примере Байесовского алгоритма принятия решения и нейросетевая аппроксимация функций.

**Алгоритм идентификации линейных переменных во времени систем управления  
 (алгоритм разработан К.А. Пупковым и описан в [1])**

Если динамику системы управления описать с помощью обыкновенного линейного дифференциального уравнения и если в этом уравнении хотя бы один коэффициент (параметр) является функцией времени, то такую систему будем называть переменной во времени. Физически это означает, что в процессе функционирования некоторые элементы системы изменяют свойства под воздействием внешних факторов или каких-либо внутренних эффектов.

Рассмотрим блок схему устройства, приведенную на рисунке 1.



Рисунок 1

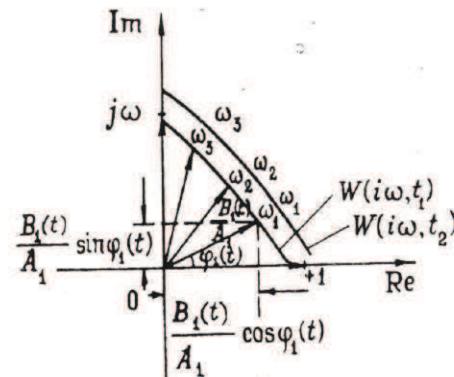


Рисунок 2

На этом рисунке показано, что на вход системы подается сигнал  $r(t) = \sum_{i=1}^n A_i \sin \omega_i t$ ,

представляющий собой сумму синусоидальных гармоник с частотой  $\omega_i$  ( $i = 1, 2, 3, \dots$ ) и произвольной амплитудой  $A_i$ .

На выходе получаем некоторый сигнал:  $m(t) = \sum_{i=1}^n B_i(t) \sin[\omega_i t + \phi_i(t)]$ , в структуре которого сказалась переменность параметров системы, так как амплитуда  $B_i$  и фаза  $\phi_i$  являются функцией времени.

На входы устройств умножения (в общем случае их может быть  $2n$ ) подается выходной сигнал  $m(t)$  и соответственно сигналы:

$$\left( \frac{2}{A_i} \right) \sin \omega_i t \text{ и } \left( \frac{2}{A_i} \right) \cos \omega_i t.$$

Такой прием называется синхронным детектирование. На выходе фильтров низких частот будем получать соответственно мгновенные значения вещественной  $RW_m(\omega_k)$  и минимум  $IW_m(\omega_k)$  составляющих вектора частотной характеристики системы управления, переменной во времени. Покажем это для случая частоты  $\omega_1$  и амплитуды  $A_1$

$$\begin{aligned} R_1(t) &= \frac{1}{A_1} (2 \sin \omega_1 t) m(t) = \frac{1}{A_1} 2 \sin \omega_1 t \sum_{i=1}^n B_i(t) \sin[\omega_i t + \phi_i(t)] = \\ &= \frac{B_1(t)}{A_1} 2 \sin \omega_1 t \sin[\omega_1 t + \phi_1(t)] + \frac{2}{A_1} \sin \omega_1 t \sum_{i=2}^n B_i(t) \sin[\omega_i t + \phi_i(t)] = \end{aligned} \quad (1)$$

$$\begin{aligned} &\frac{B_1(t)}{A_1} \cos \phi_1(t) - \frac{B_1(t)}{A_1} \cos[2\omega_1 t + \phi_1(t)] + \sum_{i=2}^n \frac{B_i(t)}{A_1} \cos[(\omega_1 - \omega_i)t - \phi_i(t)] - \\ &\phi_i(t)] - \sum_{i=2}^n \frac{B_i(t)}{A_1} \cos[(\omega_1 + \omega_i)t + \phi_i(t)] \end{aligned}$$

$$\begin{aligned} I_1(t) &= \frac{2 \cos \omega_1 t}{A_1} m(t) = \\ &= \frac{2 \cos \omega_1 t}{A_1} \sum_{i=1}^n B_i(t) \sin[\omega_i t + \phi_i(t)] = \frac{B_1(t)}{A_1} 2 \cos \omega_1 t \sin[\omega_1 t + \phi_1(t)] + \\ &+ \frac{2}{A_1} \cos \omega_1 t \sum_{i=2}^n B_i(t) \sin[\omega_i t + \phi_i(t)] = \frac{B_1(t)}{A_1} \sin \phi_1(t) + \frac{B_1(t)}{A_1} \sin[\omega_1 t + \phi_1(t)] - \end{aligned} \quad (2)$$

$$- \sum_{i=2}^n \frac{B_i(t)}{A_1} \sin[(\omega_1 - \omega_i)t - \phi_i(t)] + \sum_{i=2}^n \frac{B_i(t)}{A_1} \sin[(\omega_1 + \omega_i)t + \phi_i(t)].$$

Чтобы определить амплитуду и фазу на всех частотах входного сигнала, необходимо провести одновременно  $2n$  операций умножения. Если входной сигнал состоит из  $n$  синусоидальных компонентов, то в каждом из приведенных выше выражений содержится  $n$  членов с частотой  $\omega_i$  (плюс частота каждого компонента входного сигнала  $\omega_i$  и  $n$  членов с частотами  $(\omega_1 - \omega_i)$ ,  $i = 1, 2, \dots$ ).

Если параметры системы не меняются во времени, то член  $\frac{B_1(t)}{A_1} \cos \phi_1(t)$  в (1) и со-

ответствующий член  $\frac{B_1(t)}{A_1} \sin \phi_1(t)$  в (2) будут постоянными.

Если происходит медленное по отношению к изменениям входного и выходного сигна-

лов изменение параметров системы, то эти члены будут характеризоваться существенно более низкой частотой, чем остальные ( $2n-1$ ) членов каждого уравнения. Физически выделение компонентов отражающих переменность во времени системы, достигается применением фильтров низких частот (рисунок 3.1).

Обозначим эти члены  $R_{mi}(t)$  и  $I_{mi}(t)$  соответственно, причем в рассмотренном случае  $i=1$ . Интересующая нас информация содержится именно в указанных членах, так как  $R_{mi}(t)$  является мгновенным значением действительной части вектора частотной характеристики на частоте  $\omega_1$ ,  $I_{mi}(t)$  – его мнимой части. Непрерывное определение действительной и мнимой частей вектора эквивалентно непрерывному определению амплитуды и фазы на частоте  $\omega_1$ .

На рисунке 2 показано, каким образом на основе измерений  $R$  и  $I$  можно построить комплексную вектор-функцию для переменных во времени систем в текущие моменты времени  $t_1, t_2, \dots$ .

### **Метод Группового Учета Аргументов (МГУА) теории эвристической самоорганизации [2]**

Автор этого метода А.Г. Ивахненко пишет: «Осуществляется целенаправленный перебор многих моделей-претендентов различной сложности по ряду критериев. В результате находится модель оптимальной структуры в виде одного уравнения или системы уравнений. Минимум критерия селекции определяет модель оптимальной структуры».

Рассмотрим технологию МГУА [3] на примере работы многорядного алгоритма принятия решения для формулы Байеса из теории статистических решений:

$$p(d_j) = \sum_i P(R_i) \times L[R_i, d_j(X_1, X_2, \dots, X_n)] \times P(X_1, X_2, \dots, X_n / R_i), \quad (1)$$

где:  $d_j$  – решение в пользу  $j$ -го класса;  $R_i$  – класс распознавания ( где  $i=1,2$ );  $P(R_i)$  – априорная вероятность класса;  $X_1, X_2, \dots, X_n$  – дискретные аргументы ( где  $X_i=1,2,\dots,q$ , где  $q$  – число уровней дискретизации);  $P(X_1, X_2, \dots, X_n / R_i)$  – экспериментальная матрица, представляющая собой вероятностные распределения по классам;  $L[R_i, d_j(X_1, X_2, \dots, X_n)]$  – матрица потерь.

Возможность преобразования к многорядному представлению функции, заданной выражением (1), заключается прежде всего в наличии сомножителя  $P(X_1, X_2, \dots, X_n / R_i)$ . Заменяя полное описание (1) системой «частных» описаний, составленных для всевозможных пар аргументов, в первом ряду селекции получим следующие выражения:

$$\begin{aligned} p_{12}(d_j) &= \sum_i P(R_i) \times L[R_i, d_j(X_1, X_2)] \times P(X_1, X_2 / R_i) \\ p_{13}(d_j) &= \sum_i P(R_i) \times L[R_i, d_j(X_1, X_3)] \times P(X_1, X_3 / R_i) \\ &\dots \\ p_{1m}(d_j) &= \sum_i P(R_i) \times L[R_i, d_j(X_1, X_{1m})] \times P(X_1, X_{1m} / R_i) \\ &\dots \\ p_{n=1,n}(d_j) &= \sum_i P(R_i) \times L[R_i, d_j(X_{n-1}, X_n)] \times P(X_{n-1}, X_n / R_i) \end{aligned} \quad (2)$$

Лучшие решения, отобранные из всех решений системы (2) на первом ряду селекции, принимаются в качестве аргументов второго ряда; лучшие решения, отобранные на втором ряду – в качестве аргументов для третьего ряда селекции и т.д. Таким образом реализуется многорядная вероятность модель принятия решения с иерархической структурой – для принятия решения предыдущего ряда.

В рассмотренном алгоритме решение о классе  $R_i$ , к которому следует относить пару дискретных переменных  $a_1 a_m$  К-го ряда селекции, принимается по минимуму риска:

$$d = \arg \min_{d_j} p^k(d_j) = \arg \min_{d_j} \times \left\{ \sum_i P(R_i) \times L[R_i, d_i(a_l^k, a_m^k)] \times P(a_l^k, a_m^k / R_i) \right\},$$

определеному на отдельной проверочной последовательности данных. Как видно из выражения (3), адаптация (изменение) матрицы потерь  $L[\bullet]$  позволяет ускорить процесс достижения максимальной точности принятия решений по малому числу рядов селекции.

С помощью математической модели осуществляется прогноз состояния системы на некотором интервале времени, который выбирается из практических соображений в соответствии с режимом функционирования объекта.

### Нейросетевое моделирование

В области нейрокибернетики развиваются три основных направления, первое из которых связано с построением и применением искусственных нейронных сетей. Далее для их программной реализации разрабатываются нейропакеты, а для их физической реализации создаются нейрокомпьютеры [4].

Задача аппроксимации функции заключается в определении по экспериментальным данным функции, наилучшим образом приближающейся к неизвестной и удовлетворяющей определенным критериям. Эта задача актуальна при моделировании сложных динамических систем, при решении многочисленных инженерных и научных задач моделирования. Одной из таких задач является аппроксимация (подгонка) выборки входного сигнала полиномом.

В нейропакете Neural Network Toolbox for Matlab для решения аппроксимации функции можно использовать обобщенно-регрессионную нейронную сеть (НС), сеть с радиальными базисными элементами и линейную НС. [5]. Результаты эксперимента показали, что при использовании сетей с радиальными базисными элементами качество аппроксимации улучшено, а при использовании линейных НС результаты моделирования почти такие же. Однако при использовании альтернативной полиномиальной сети по архитектуре МГУА (Group Method of Data Handling, GMDH) из пакета NeuroShell2 качество аппроксимации может быть улучшено.

### Выводы

В статье рассмотрены несколько алгоритмов методов идентификации, описывающих сложные объекты или системы (в том числе интеллектуальные). К ним относятся разработанный [1] частотный метод анализа нелинейной динамической системы управления и на примере метода МГУА [3] показано эффективное использование селекционного процесса самоорганизации для определения модели оптимальной структуры [4].

### Литература

- Пупков К.А., Серов В.А. Автоматизированная разработка систем управления: Учебное пособие по курсу «Моделирование и испытания систем управления». Ч. 2. – М.: Изд-во МГТУ им. Н.Э. Баумана, 2000.-52с.
- Ивахненко А.Г. «Теория эвристической самоорганизации». -Киев: Техника, 1978.-377 с.
- Крыжановская Т.Г. «Математическая модель на основе самоорганизации для управления процессом термообработки шинного корда». – канд. диссертация по специальности 05.13.07 – Автоматизация технологических процессов и производств. – Киев, 1990г.
- Башмаков А.И., Башмаков И.А. Интеллектуальные информационные технологии: Учеб. пособие.- М.: Изд-во МГТУ им. Н.Э. Баумана, 2005.-304с.
- Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB6/ Под общ. ред. к.т.н. В.Г. Потемкина.-М.: ДИАЛОГ – МИФИ, 2002.-496 с.