

Yakov Zalmanovitch Tsyarkin

Обучающиеся модели

Kybernetika, Vol. 7 (1971), No. 2, (92)--108

Persistent URL: <http://dml.cz/dmlcz/124253>

Terms of use:

© Institute of Information Theory and Automation AS CR, 1971

Institute of Mathematics of the Academy of Sciences of the Czech Republic provides access to digitized documents strictly for personal use. Each copy of any part of this document must contain these

Terms of use.



This paper has been digitized, optimized for electronic delivery and stamped with digital signature within the project *DML-CZ: The Czech Digital Mathematics Library*
<http://project.dml.cz>

Обучающиеся модели

Я. З. Цыпкин

Изложены принципы построения обучающихся моделей, способных с течением времени изменять свою структуру и параметры так, чтобы их свойства приближались к свойствам изучаемых объектов.

ВВЕДЕНИЕ

Обучающиеся модели, способные с течением времени изменять свою структуру и параметры так, чтобы по своим свойствам приблизиться к изучаемым системам, могут быть использованы как технические средства для идентификации последних. Задача идентификации неизвестных систем по существу очень близка к задаче опознавания. Но если в задаче опознавания обучающаяся система восстанавливала решающие функции, чтобы затем по знакам их определить, к какому классу относится данная ситуация, то в задаче идентификации сама восстанавливающая решающая функция и представляет собой искомую характеристику системы.

Цель настоящей работы состоит в развитии общего адаптивного подхода [1] решения задачи идентификации на основе обучающихся моделей. Задача идентификации довольно широка. Это связано с разнообразными возможностями описания исследуемых систем с помощью дифференциальных, разностных, интегральных уравнений различных видов [2]. Мы здесь ограничимся одной, но довольно общей возможностью — описания систем при помощи операторных уравнений как линейных, так и нелинейных систем.

Динамические системы можно описывать операторными уравнениями двух видов:

$$(1.1) \quad y(t) = A[y(t), x(t)]$$

либо

$$(1.2) \quad y(t) = A^0[x(t)],$$

где $A[y, x]$, $A^0[x]$ — некоторые операторы; $x(t)$ — входная величина системы, $y(t)$ — выходная величина системы (рис. 1).

Операторное уравнение (1.2) представляет собой уравнение явно разрешенное относительно y . Поэтому его можно рассматривать как решение уравнения




Рис. 1.

(1.1). Далее предполагается, что система находится в режиме нормальной работы, т. е. $x(t)$ и $y(t)$ — стационарные случайные процессы. Для линейных систем:

$$(1.3) \quad y(t) = A[y(t), x(t)] = \\ = \int_0^{\infty} K_y(\tau) y(t - \tau) d\tau + \int_0^{\infty} K_x(\tau) x(t - \tau) d\tau$$

и

$$(1.4) \quad y(t) = A^0[x(t)] = \int_0^{\infty} K(\tau) x(t - \tau) d\tau,$$

где $K_y(\tau)$, $K_x(\tau)$, $K(\tau)$ — импульсные характеристики, причем, $K(\tau)$ зависит, вообще говоря, сложным образом от $K_y(\tau)$ и $K_x(\tau)$. Уравнения (1.3) и (1.4) представляют собой уравнения типа свертки. Причем, (1.4) представляет собой явную зависимость выходной величины системы от входной, т. е. решение уравнения (1.3).

Для нелинейных систем:

$$(1.5) \quad \begin{aligned} y(t) &= A[y(t), x(t)] = \\ &= \sum_{m=1}^{\infty} \int_0^{\infty} \dots \int_0^{\infty} K_y(\tau_1, \dots, \tau_m) y(t - \tau_1) \dots y(t - \tau_m) d\tau_1 \dots d\tau_m + \\ &+ \sum_{m=1}^{\infty} \int_0^{\infty} \dots \int_0^{\infty} K_x(\tau_1, \dots, \tau_m) x(t - \tau_1) \dots x(t - \tau_m) d\tau_1 \dots d\tau_m \end{aligned}$$

и

$$(1.6) \quad \begin{aligned} y(t) &= A^0[x(t)] = \\ &= \sum_{m=1}^{\infty} \int_0^{\infty} \dots \int_0^{\infty} K(\tau_1, \dots, \tau_m) x(t - \tau_1) \dots x(t - \tau_m) d\tau_1 \dots d\tau_m. \end{aligned}$$

Последний оператор уместно назвать вольтерровским. Он определяет решение нелинейных уравнений типа (1.5). Практически число слагаемых в (1.5) и (1.6), естественно, ограничено. К анализу нелинейных систем такого рода разложения применялись в работах [3, 4]. Для этой же цели возможно использование так называемых ортогональных разложений нелинейных операторов [5]. Интересным приложением общих видов разложения посвящена работа [6].

2. СТРУКТУРА МОДЕЛИ

Уравнения обучающейся модели примем следующими

$$(2.1) \quad \hat{y}(t) = B[y(t), x(t), \mathbf{c}]$$

либо

$$(2.2) \quad \hat{y}(t) = B^0[x(t), \mathbf{c}],$$

где $B[y, x, \mathbf{c}]$ и $B^0[x, \mathbf{c}]$ — известные операторы, зависящие от неизвестного вектора параметров

$$(2.3) \quad \mathbf{c} = (c_1, \dots, c_N).$$

В уравнениях (2.1) и (2.2) $\hat{y}(t)$ — выходная величина модели, а $y(t)$ и $x(t)$ — входные величины модели. Предположим далее, что операторы представимы в виде линейной комбинации простейших операторов, т. е.

$$(2.4) \quad B[y, x, \mathbf{c}] = \mathbf{c}^T \mathbf{B}[y, x],$$

где символ T — означает транспонирование, либо

$$(2.5) \quad B^0[x, \mathbf{c}] = \mathbf{c}^T \mathbf{B}^0[x].$$

В (2.4) и (2.5)

$$(2.6) \quad \mathbf{B}[y, x] = (B_1[y, x], \dots, B_N[y, x]),$$

$$(2.7) \quad \mathbf{B}^0[x] = (B_1^0[x], \dots, B_N^0[x])$$

— векторы-операторы, компоненты которых — простейшие линейно-независимые операторы. Тогда уравнения обучающихся моделей (2.1), (2.2) можно представить в форме

$$(2.8) \quad \hat{y}(t) = \mathbf{c}^T \mathbf{B}[y(t), x(t)]$$

либо

$$(2.9) \quad \hat{y}(t) = \mathbf{c}^T \mathbf{B}^0[x(t)].$$

Согласно этим уравнениям структура обучающейся системы может быть пред-




Рис. 2.

ставлена, как показано на рис. 2. В первом случае модель имеет два входа, а во втором случае — один. Подобного рода модели рассматривались в работах [7] и [6].

3. ЦЕЛЬ ОБУЧЕНИЯ

Подадим на вход обучающейся модели входную $x(t)$ (и при необходимости, выходную $y(t)$) величину системы, и будем сравнивать выходные величины системы $y(t)$ и модели $\hat{y}(t)$. Разность их характеризует мгновенную ошибку

$$(3.1) \quad \varepsilon(t) = y(t) - \hat{y}(t).$$

Образует функционал

$$(3.2) \quad I(\mathbf{c}) = \mathbf{E}\{F(y(t) - \mathbf{c}^T \mathbf{B}[y(t), x(t)])\}$$

либо

$$(3.3) \quad I(\mathbf{c}) = \mathbf{E}\{F(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)])\},$$

96 где $F(\cdot)$ — выпуклая функция, обычно квадратичная, а E — символ математического ожидания.

Поскольку плотность распределения переменной, по которой берется математическое ожидание, неизвестна, то функционалы (3.2), (3.3) полностью не определены, и поэтому возникает необходимость в обучении.

Цель обучения представляет собой минимум функционала (3.2) либо (3.3), — и задача обучения модели состоит в таком выборе вектора $\mathbf{c} = \mathbf{c}^*$, по имеющимся в нашем распоряжении реализациям $y(t)$ и $x(t)$, при котором достигается цель обучения.

4. АЛГОРИТМЫ ОБУЧЕНИЯ

Условие минимума функционалов (3.2) имеет вид

$$(4.1) \quad \nabla I(\mathbf{c}) = -E\{F'(y(t) - \mathbf{c}^T \mathbf{B}[y(t), x(t)]) \mathbf{B}[y(t), x(t)]\} = 0.$$

Мы можем измерить и сформировать лишь выражение, стоящее под знаком математического ожидания.

Для достижения цели обучения воспользуемся непрерывными алгоритмами обучения [1], которые как раз оперируют с доступными для измерения и формирования выражениями. Эти алгоритмы обучения имеют вид

$$(4.2) \quad \frac{d\mathbf{c}(t)}{dt} = \gamma(t) F'(y(t) - \mathbf{c}^T(t) \mathbf{B}[y(t), x(t)]) \mathbf{B}[y(t), x(t)],$$

или короче

$$(4.3) \quad \frac{d\mathbf{c}(t)}{dt} = \gamma(t) F'(y(t) - \hat{y}(t, t)) \mathbf{B}[y(t), x(t)],$$

где

$$(4.4) \quad \hat{y}(t, t) = \mathbf{c}^T(t) \mathbf{B}[y(t), x(t)].$$

Структурная схема обучающейся модели, реализующая эти алгоритмы, изображена на рис. 3. Подобную обучающуюся модель мы будем называть двухвходной. Аналогичным образом для функционала (3.3) имеем

$$(4.5) \quad \nabla I(\mathbf{c}) = E\{F'(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)]) \mathbf{B}^0[x(t)]\} = 0.$$

В этом случае алгоритмы обучения принимают вид

$$(4.6) \quad \frac{d\mathbf{c}(t)}{dt} = \gamma(t) F'(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)]) \mathbf{B}^0[x(t)]$$

или короче

$$(4.7) \quad \frac{d\mathbf{c}(t)}{dt} = \gamma(t) F'(y(t) - \hat{y}(t, t)) \mathbf{B}^0[x(t)],$$

где

$$(4.8) \quad \hat{y}(t, t) = \mathbf{c}^T(t) \mathbf{B}^0[x(t)].$$

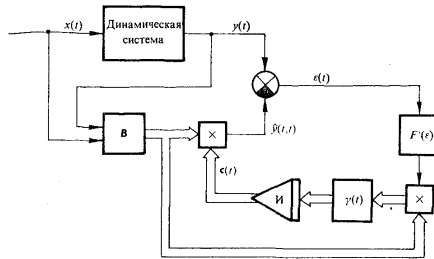


Рис. 3.

Коэффициент $\gamma(t)$ должен удовлетворять условиям

$$(4.9) \quad \gamma(t) > 0, \quad \int_0^{\infty} \gamma(t) dt = \infty, \quad \int_0^{\infty} \gamma^2(t) dt < \infty,$$

которые обеспечивают сходимость непрерывного алгоритма обучения при надлежащем выборе функции $F(\cdot)$.




Рис. 4.

Структурная схема обучающейся модели, соответствующая этим алгоритмам, изображена на рис. 4. Подобную обучающуюся модель мы будем называть одноходной. В ряде случаев может оказаться удобным в алгоритмах

98 (4.2) вместо $y(t)$ использовать оценку $\hat{y}(t, t)$, вырабатываемую самой моделью, т. е. заменить алгоритм (4.2) алгоритмом

$$(4.10) \quad \frac{dc(t)}{dt} = \gamma(t) F'(y(t) - c^T B[\hat{y}(t, t), x(t)]) B[\hat{y}(t, t), x(t)].$$

где

$$(4.11) \quad \hat{y}(t, t) = c^T(t) B[\hat{y}(t, t), x(t)].$$

Очевидно, что эта замена законна лишь тогда, когда $\hat{y}(t, t)$ близко, в каком-то смысле, к $y(t)$. Структурная схема такой обучающейся системы отличается от изображенной на рис. 4 только заменой входной величины модели $y(t)$ на

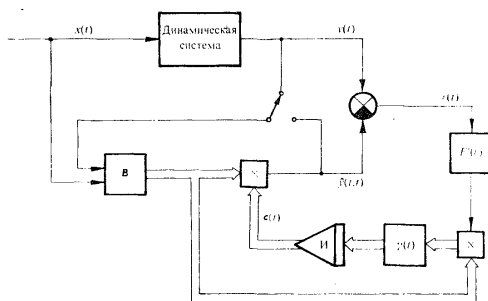


Рис. 5.

$\hat{y}(t, t)$. Это достигается простым переключением в схеме, приведенной на рис. 5. При первом положении ключа реализуется алгоритм (4.3), а при втором — алгоритм (4.10). Подобная схема впервые была предложена в работе [7]. Таким образом, обучаемая модель, получив данные о входной и выходной величинах системы, вырабатывает оценку $\hat{y}(t, t)$, которая, благодаря надлежащему изменению вектора параметров, приближается к $y(t)$. Иначе говоря, обучаемая модель после обучения наилучшим образом приближается к исследуемой системе. Это и дает основание принять ее в качестве модели системы.

5. ЛИНЕЙНАЯ ОБУЧАЮЩАЯСЯ МОДЕЛЬ

Рассмотрим линейную обучающуюся модель. Уравнение этой модели (2.1) представим в виде

$$(5.1) \quad \hat{y}(t) = B[y(t), x(t), c] = c_1^T \varphi_1(t) + c_2^T \varphi_2(t),$$

где вектор-функции определяются как

$$(5.2) \quad \begin{aligned} \varphi_y(t) &= \int_0^{\infty} K_y(\tau) y(t - \tau) d\tau, \\ \varphi_x(t) &= \int_0^{\infty} K_x(\tau) x(t - \tau) d\tau. \end{aligned}$$

В этих выражениях

$$(5.3) \quad \begin{aligned} K_y(\tau) &= (K_{y_1}(\tau), \dots, K_{yN_y}(\tau)), \\ K_x(\tau) &= (K_{x_1}(\tau), \dots, K_{xN_x}(\tau)) \end{aligned}$$

— векторы импульсных характеристик.

Если в качестве цели обучения выбрать минимум функционала

$$(5.4) \quad I(\mathbf{c}_y, \mathbf{c}_x) = E\{F(y(t) - \mathbf{c}_y^T \varphi_y(t) - \mathbf{c}_x^T \varphi_x(t))\},$$

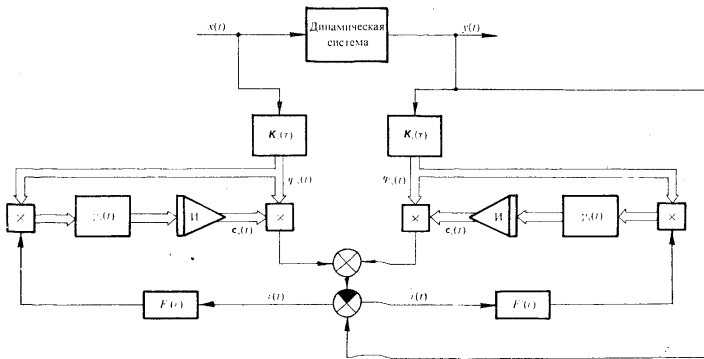


Рис. 6.

то непрерывные алгоритмы обучения будут иметь вид

$$(5.5) \quad \begin{aligned} \frac{dc_y(t)}{dt} &= \gamma_y(t) F'(y(t) - \hat{y}(t, t)) \varphi_y(t), \\ \frac{dc_x(t)}{dt} &= \gamma_x(t) F'(y(t) - \hat{y}(t, t)) \varphi_x(t), \end{aligned}$$

100 где

$$(5.6) \quad \hat{y}(t, t) = \mathbf{c}_y^T(t) \varphi_y(t) + \mathbf{c}_x^T(t) \varphi_x(t).$$

Структурная схема двухходной линейной обучающейся модели вместе с исследуемой системой приведена на рис. 6.

Если воспользоваться вместо (5.1) уравнением

$$(5.7) \quad \hat{y}(t) = \mathbf{B}^0[x(t), \mathbf{c}] = \mathbf{c}^T \varphi(x),$$

где

$$(5.8) \quad \varphi(t) = \int_0^\infty \mathbf{K}(\tau) x(t - \tau) d\tau$$

и

$$(5.9) \quad \mathbf{K}(\tau) = (K_1(\tau), \dots, K_N(\tau)),$$

то полагая в прежних результатах

$$(5.10) \quad \varphi_y(t) \equiv 0, \quad \varphi_x(t) \equiv \varphi(t), \quad \mathbf{c}_x \equiv \mathbf{c},$$

получим

$$(5.11) \quad \frac{d\mathbf{c}(t)}{dt} = \gamma(t) F'(y(t) - \hat{y}(t, t)) \varphi(t),$$

где

$$(5.12) \quad \hat{y}(t, t) = \mathbf{c}^T(t) \varphi(t).$$

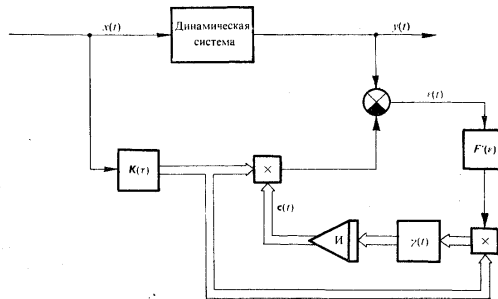


Рис. 7.

Структурная схема одноходной линейной обучающейся модели вместе с исследуемой системой приведена на рис. 7. К построению подобных моделей по существу сводятся задачи идентификации, рассмотренные в работах [8–11].

Если исследуемая система линейна, то линейная обучающаяся модель после периода обучения позволит определить характеристики системы. Если же исследуемая система нелинейна, то в этом случае линейная обучающаяся модель определить линейный статистический эквивалент нелинейной системы, т. е. иначе говоря, будет осуществлена статистическая линеаризация нелинейной системы.

Статистическая линеаризация всей динамической системы в целом, а не отдельно нелинейных элементов при достаточной априорной информации, описана в работе [12] и в наиболее общей форме в работе [6].

6. НЕЛИНЕЙНЫЕ ОБУЧАЮЩИЕСЯ МОДЕЛИ

Для нелинейной двухходной обучающейся модели в общем случае уравнение можно представить в виде

$$(6.1) \quad \hat{y}(t) = \mathbf{B}[y(t), x(t), \mathbf{c}] = \sum_{m=1}^{N_y} \mathbf{c}_{m_y}^T \varphi_{m_y}(t) + \sum_{m=1}^{N_x} \mathbf{c}_{m_x}^T \varphi_{m_x}(t),$$

где

$$(6.2) \quad \varphi_{m_y}(t) = \int_0^\infty \dots \int_0^\infty \mathbf{K}_y(\tau_1, \dots, \tau_m) y(t - \tau_1) \dots y(t - \tau_m) d\tau_1 \dots d\tau_m,$$

$$\varphi_{m_x}(t) = \int_0^\infty \dots \int_0^\infty \mathbf{K}_x(\tau_1, \dots, \tau_m) x(t - \tau_1) \dots x(t - \tau_m) d\tau_1 \dots d\tau_m,$$

и

$$(6.3) \quad \mathbf{K}_y(\tau_1, \dots, \tau_m) = (K_{y_1}(\tau_1, \dots, \tau_m), \dots, K_{y_{N_y}}(\tau_1, \dots, \tau_m)),$$

$$\mathbf{K}_x(\tau_1, \dots, \tau_m) = (K_{x_1}(\tau_1, \dots, \tau_m), \dots, K_{x_{N_x}}(\tau_1, \dots, \tau_m))$$

— векторы вольтерровских ядер.

Вводя составные векторы параметров

$$(6.4) \quad \begin{aligned} * \mathbf{c}_y &= (\mathbf{c}_{1y}, \dots, \mathbf{c}_{N_y y}), \\ * \mathbf{c}_x &= (\mathbf{c}_{1x}, \dots, \mathbf{c}_{N_x x}) \end{aligned}$$

и составные векторы функций

$$(6.5) \quad \begin{aligned} * \varphi_y(t) &= (\varphi_{1y}(t), \dots, \varphi_{N_y y}(t)), \\ * \varphi_x(t) &= (\varphi_{1x}(t), \dots, \varphi_{N_x x}(t)), \end{aligned}$$

запишем уравнение (6.1) в компактной форме

$$(6.6) \quad \hat{y}(t) = * \mathbf{c}_y^T * \varphi_y(t) + * \mathbf{c}_x^T * \varphi_x(t),$$

которая отличается от (5.1) только тем, что теперь фигурируют не просто векторы, а составные векторы. Выбирая в качестве цели обучения минимум функционала

$$(6.7) \quad I(*c_y, *c_x) = E\{F(y(t) - *c_y^T * \varphi_y(t) - *c_x^T * \varphi_x(t))\}.$$

Соответствующие непрерывные алгоритмы обучения принимают вид

$$(6.8) \quad \frac{d*c_y(t)}{dt} = \Gamma_y(t) F'(y(t) - \hat{y}(t, t)) * \varphi_y(t),$$

$$\frac{d*c_x(t)}{dt} = \Gamma_x(t) F'(y(t) - \hat{y}(t, t)) * \varphi_x(t),$$

где

$$(6.9) \quad \hat{y}(t, t) = *c_y^T(t) * \varphi_y(t) + *c_x^T(t) * \varphi_x(t)$$

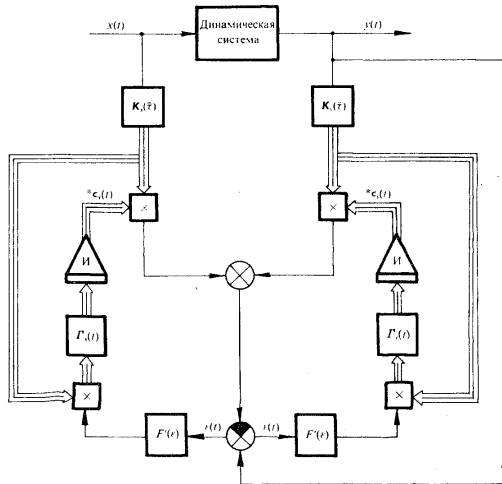


Рис. 8.

и $\Gamma_y(t), \Gamma_x(t)$ — диагональные матрицы, элементы которых удовлетворяют условиям (4.9). Структурная схема нелинейной обучающейся системы изображена на рис. 8. Здесь использованы обозначения для составных векторных связей в виде тройных линий.

Для одноходовой нелинейной обучающейся системы уравнение (6.6) заменяется уравнением

$$(6.10) \quad \hat{y}(t) = {}^*c^T {}^*\varphi(t),$$

где

$$(6.11) \quad {}^*\varphi(t) = (\varphi_1(t), \dots, \varphi_N(t)),$$

$$(6.12) \quad \varphi_m(t) = \int_0^\infty \dots \int_0^\infty K(\tau_1, \dots, \tau_m) x(t - \tau_1), \dots, x(t - \tau_m) d\tau_1 \dots d\tau_m$$

и

$$(6.13) \quad K(\tau_1, \dots, \tau_m) = (K_1(\tau_1, \dots, \tau_m), \dots, K_N(\tau_1, \dots, \tau_m)).$$

Для получения алгоритмов обучения положим в (6.6)–(6.9)

$$(6.14) \quad {}^*\varphi_y(t) \equiv 0, \quad {}^*\varphi_x(t) \equiv {}^*\varphi(t), \quad \Gamma_x(t) \equiv \Gamma(t).$$

Тогда из (6.8) и (6.9) получим

$$(6.15) \quad \frac{d{}^*c(t)}{dt} = \Gamma(t) F'(y(t)) - \hat{y}(t, t) {}^*\varphi(t),$$

где

$$(6.16) \quad \hat{y}(t, t) = {}^*c^T(t) {}^*\varphi(t).$$

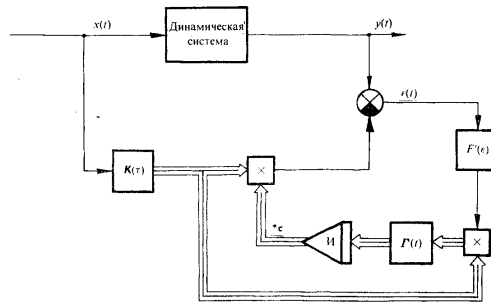


Рис. 9.

Структурная схема такой одноходовой нелинейной обучающейся модели изображена на рис. 9.

Отметим, что к построению рассмотренных выше нелинейных обучающихся моделей, сводятся задачи идентификации нелинейных объектов, рассмотренные в работах [13, 14].

Простота структурных схем нелинейных обучающихся моделей (рис. 8, рис. 9), их внешнее сходство со структурными схемами линейных обучающихся моделей (рис. 6, рис. 7) может привести к ложному мнению, что линейные и нелинейные модели мало отличаются друг от друга. Это мнение тотчас же рассеивается, если подсчитать число компонент векторов, определяемых алгоритмами обучения. Для линейной одноходовой обучающейся модели число компонент вектора \mathbf{c} равно N .

Для нелинейной одноходовой обучающейся модели число компонент составного вектора \mathbf{c} равно $N \sum_{m=1}^N N_m$.

Для двухходовых обучающихся систем число компонент еще увеличивается и возникает опасность, что „проклятие размерности“ не позволит практически определить все эти коэффициенты. Поэтому, чрезвычайно важным является изыскание способов преодоления этой трудности. Наиболее заманчивые способы, вероятно, связаны с декомпозицией, т. е. с разделением сложной задачи большой размерности на более простые задачи значительно меньшей размерности, допускающие не зависящие друг от друга решения. Пока эти способы не будут найдены, нам придется довольствоваться относительно простыми нелинейными обучающимися моделями.

7. ВЛИЯНИЕ ПОМЕХ

Рассмотрим вначале наиболее простой случай, когда помехи действуют на выходе объекта (рис. 10).

В этом случае функционал (3.3) заменится на

$$(7.1) \quad I(\mathbf{c}) = \{F(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)] + \xi(t))\},$$

Рис. 10.



а условие минимума функционала (4.5) сводится к

$$(7.2) \quad \nabla I(\mathbf{c}) = -E\{F'(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)] + \xi(t)) \mathbf{B}^0[x(t)]\} = 0.$$

Для квадратичного функционала из (7.2) получаем

$$(7.3) \quad -E\{(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)] + \xi(t)) \mathbf{B}^0[x(t)]\} = 0.$$

Если помеха $\xi(t)$ и входной сигнал $x(t)$ не коррелированы, то

$$(7.4) \quad E\{\xi(t) \mathbf{B}^0[x(t)]\} = 0$$

и условие (7.3) переходит в условие

$$(7.5) \quad E\{(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)]) \mathbf{B}^0[x(t)]\} = 0,$$

совпадающее с (4.5) при квадратичном функционале. Отсюда следует, что в этом случае получаемая алгоритмами обучения оценка не зависит от помех, т. е. она будет несмещенной. Это очень важная особенность квадратичного функционала.

Предположим, что помеха действует на входе объекта (рис. 11). Тогда вместо (7.1) и (7.2) получаем соответственно

$$(7.6) \quad I(\mathbf{c}) = E\{F(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t) + \xi(t)])\}$$

и

$$(7.7) \quad \nabla I(\mathbf{c}) = -E\{F'(y(t) - \mathbf{c}^T \mathbf{B}^0[x(t) + \xi(t)]) \mathbf{B}^0[x(t) + \xi(t)]\} = 0.$$



Рис. 11.

Для квадратичного функционала и линейной системы получаем

$$(7.8) \quad \nabla I(\mathbf{c}) = -E\{[y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)] - \mathbf{c}^T \mathbf{B}^0[\xi(t)]] [\mathbf{B}^0[x(t)] + \mathbf{B}^0[\xi(t)]]\} = 0.$$

Если помеха $\xi(t)$ и сигнал $x(t)$ независимы, то

$$(7.9) \quad E\{\mathbf{B}[x(t)] \mathbf{B}^{0T}[\xi(t)]\} = 0.$$

Обозначая матрицу

$$(7.10) \quad E\{\mathbf{B}[\xi(t)] \mathbf{B}^{0T}[\xi(t)]\} = D,$$

упростим условие (7.8)

$$(7.11) \quad \nabla I(\mathbf{c}) = -E\{[y(t) - \mathbf{c}^T \mathbf{B}^0[x(t)]] \mathbf{B}^0[x(t)] - D\mathbf{c}\} = 0.$$

В этом случае (7.11) отличается от (7.3), и поэтому оценка получается смещенной, она зависит от D .

Нелинейную систему можно рассмотреть аналогичным образом, если

$$(7.12) \quad \mathbf{B}^0[x(t) + \xi(t)]$$

106 разложить по произведениям степеней простейших операторов $\mathbf{B}^0 \gamma[x(t)]$. $\mathbf{B}^0 \gamma[\xi(t)]$. Подобным же образом рассматривается и тот случай, когда функции потерь не квадратичны.

Чтобы устранить влияние помех в тех случаях, когда они вызывают смещение оценок, необходима априорная информация о помехах. Допустим, что нам известна матрица D . Из (7.11) следует, что при несмещенной оценке

$$(7.13) \quad \nabla I(\mathbf{c}^*) = D\mathbf{c}^* \neq 0.$$

Составим теперь разность [15]

$$(7.14) \quad \nabla I(\mathbf{c}) - D\mathbf{c} = E\{[y(t) - \mathbf{c}^T \mathbf{B}^0[x(t) + \xi(t)]] \mathbf{B}^0[x(t) + \xi(t)] - D\mathbf{c}\}.$$

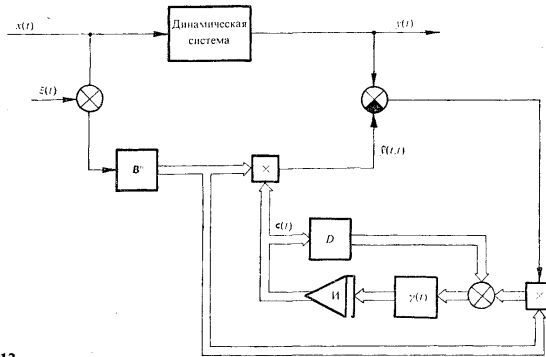


Рис. 12.

При $\mathbf{c} = \mathbf{c}^*$ эта разность обращается в нуль. Поэтому, если известна матрица D , то алгоритм вида

$$(7.15) \quad \frac{d\mathbf{c}(t)}{dt} = \gamma(t) \{[y(t) - \hat{y}(t, t)] \mathbf{B}^0[x(t) + \xi(t)] - D\mathbf{c}\}$$

приводит к несмещенным оценкам.

Структурная схема такой обучающейся линейной модели изображена на рис. 12. Описанный случай обобщается и на случай нелинейной модели.

ЗАКЛЮЧЕНИЕ

Обучающиеся модели позволяют, обучаясь по данным исследуемого объекта, приблизиться к последнему наилучшим образом с точки зрения выбранного критерия. Достигая таким образом цели обучения, мы по обученным моделям

можем определять характеристики и свойства исследуемых объектов. Обучающиеся модели позволяют осуществить идентификацию исследуемых линейных и нелинейных систем в условиях нормальной работы. Более того, они дают возможность получать линейные эквивалентные системы существенно нелинейных систем, которые могут быть полезны при анализе последних.

(Поступила в редакцию 10 июля 1970 г.)

ЛИТЕРАТУРА

- [1] Цыпкин Я. З.: Адаптация и обучение в автоматических системах. „Наука“, 1968.
- [2] Eukhoff P.: Process parameter and state estimation. Identification in Automatic Control Systems. Preprints of the IFAC Symposium, Prague, Czechoslovakia, 12–17 June 1967. Academia, Prague 1967.
- [3] Винер Н.: Нелинейные задачи в теории случайных процессов (перевод с английского). ИЛ, 1961.
- [4] Ван Трис Г.: Синтез оптимальных нелинейных систем управления. Из-во „Мир“, 1964.
- [5] Cameron R. H., Martin W. T.: The orthogonal development of nonlinear functionals in series of Fourier-Hermite functionals. *Annales of Mathematic* 48 (1947), 2.
- [6] Попков Ю. С.: Статистические методы нелинейных систем. Автоматика и телемеханика (1967), 10.
- [7] Норкин К. В.: Поискные методы настройки управляемых моделей в задачах определения параметров объектов. Автоматика и телемеханика (1968), 11.
- [8] Нямура А. А., Арбачаускаене Н. А.: Скорость сходимости некоторых итерационных алгоритмов функционирования адаптивных моделей. Труды Академии наук Литовской ССР (1968) сер. Б, т. 2 (53).
- [9] Нямура А. А., Арбачаускаене: Увеличение скорости сходимости некоторых алгоритмов функционирования адаптивных моделей. Труды Академии наук Литовской ССР (1968) сер. Б, т. 2 (53).
- [10] Нямура А. А., Соркин Е. Д.: Устойчивость работы самонастраивающихся моделей. Труды Академии наук Литовской ССР (1968) сер. Б, т. 2 (53).
- [11] Sakrison D. J.: The use of stochastic approximation to solve the system identification problem. *IEEE Transactions on Automatic Control AC-12* (1967), 5.
- [12] Пятницкий Г. И.: Воздействие стационарных случайных процессов на системы автоматического регулирования, содержащие существенно нелинейные элементы. Автоматика и телемеханика (1960), 4.
- [13] Beisher H. M.: Recursive Bayesian method for estimation states of nonlinear systems from sequential indirect observations. *IEEE Transactions on System Science and Cybernetics SSC-3* (1967), 2.
- [14] Roy R. I., Sherman J.: A learning technique for Volterra series representation. *IEEE Transactions on Automatic Control AC-12* (1967), 6.
- [15] Zhivoglyadov V. P., Kaipov V. K.: Identification of Distributed Parameter Plants in the presence of noises. Identification in Automatic Control Systems. Preprints of the IFAC Symposium, Prague, Czechoslovakia, 12–17 June 1967. Academia, Prague 1967.

Učící se modely

JA. Z. CYPKIN

V článku se probírají principy konstrukce učících se modelů, které jsou schopné podle informace o časovém průběhu vstupní a výstupní veličiny objektů měnit svou strukturu a parametry tak, aby se svými vlastnostmi blížily vlastnostem modelovaného objektu. Takové modely se dají použít jako technické prostředky pro identifikaci objektů. Proces učení se probíhá na základě pravděpodobnostních iterací algoritmů spojitého typu. Rovněž se ukazuje vliv poruch na výsledky identifikace.

Профессор Яков Залманович Цыпкин, доктор технических наук, Институт проблем управления (ИАП), Профсоюзная 81, Москва, ГСП — 312. СССР.