

Zdeněk Častorál

Некоторые общие алгоритмы обучения

Kybernetika, Vol. 7 (1971), No. 5, (377)--385

Persistent URL: <http://dml.cz/dmlcz/125149>

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>

Некоторые общие алгоритмы обучения

Зденек Часторал

Рассматриваются общие алгоритмы обучения, которые позволяют по мере поступления информации асимптотически приближаться к цели обучения.

1. ВВЕДЕНИЕ

В последнее время значительное внимание уделяется адаптивным обучающимся системам [1]. Эти системы по мере поступления информации могут улучшать свое функционирование вплоть до оптимального.

Проблема обучения может быть сформулирована как задача последовательных приближений к некоторым неизвестным параметрам. Для оценки неизвестных параметров могут быть применены вероятностные итеративные алгоритмы.

Обратим сначала внимание на аппроксимирующую функцию. Правила формирования функции строятся так, чтобы по мере увеличения числа предъявляемых в процессе обучения входных векторов аппроксимирующая функция стремилась к некоторой разделяющей функции. В основу положено построение так называемых потенциальных функций. Выбор аппроксимирующих функций зависит от ограничений первого рода, т. е. законов природы выражаемых в виде алгебраических, дифференциальных или интегральных уравнений [2].

Для различных задач обучения часто используется аппроксимирующая функция $\hat{f}_0(\mathbf{x}, \mathbf{c})$ в виде конечной суммы

$$\hat{f}_0(\mathbf{x}, \mathbf{c}) = \sum_{i=1}^N c_i \varphi_i(\mathbf{x})$$

или

$$\hat{f}_0(\mathbf{x}, \mathbf{c}) = \mathbf{c}^T \boldsymbol{\varphi}(\mathbf{x}),$$

где $\mathbf{c} = (c_1, \dots, c_N)$ — N -мерный вектор весовых коэффициентов, $\boldsymbol{\varphi}(\mathbf{x})$ — N -

мерный вектор линейно независимых функций от случайного вектора $\mathbf{x} = (x_1, \dots, x_M)$.

Реализация аппроксимирующих функций осуществляется с помощью весового вектора. Для умножения на весовой коэффициент на входе каждой составляющей входного вектора включается сопротивление переменной величины. Переменное значение сопротивления достигается использованием сопротивления с двигателем, мемисторов, трансфлекторов и т. п. В последних двух случаях не обеспечивается линейный характер изменения величины сопротивления в зависимости от управляющего тока. Медленное изменение сопротивления весов во времени вызывает нежелательные замедления в реакциях на входные векторы.

С целью упрощения реализации обучающихся систем выгоднее использовать аппроксимирующую функцию вида

$$(1) \quad \hat{f}_1(\mathbf{x}, \mathbf{c}) = \prod_{i=1}^N (x_i + c_i) + c_0,$$

или

$$(2) \quad \hat{f}_1(\mathbf{x}, \mathbf{c}) = \prod_{i=1}^N [\varphi_i(\mathbf{x}) + c_i] + c_0,$$

аппроксимирующую функцию вида

$$(3) \quad \hat{f}_2(\mathbf{x}, \mathbf{c}) = \prod_{i=1}^{m_1} [x_i + c_i] + \dots + \prod_{i=m_{l-1}+1}^{m_l} [x_i + c_i] + c_0 = \\ = \sum_{j=1}^l \prod_{i=m_{j-1}+1}^{m_j} (x_i + c_i) + c_0,$$

или

$$(4) \quad \hat{f}_2(\mathbf{x}, \mathbf{c}) = \prod_{i=1}^{m_1} [\varphi_i(\mathbf{x}) + c_i] + \dots + \prod_{i=m_{l-1}+1}^{m_l} [\varphi_i(\mathbf{x}) + c_i] + c_0 = \\ = \sum_{j=1}^l \prod_{i=m_{j-1}+1}^{m_j} (\varphi_i(\mathbf{x}) + c_i) + c_0, \\ m_l = N, \quad \{m_0 = 0; j = (1 \dots l)\}$$

где c_0 — компенсирующая составляющая.

Эти аппроксимации были впервые предложены автором. Их можно назвать „неклассическими“ или „нелинейными“. Детальный анализ этих аппроксимаций и условия для выбора функций $\varphi_i(\mathbf{x})$ будут приведены автором в последующих работах.

2. ВЕРОЯТНОСТНЫЕ ИТЕРАТИВНЫЕ АЛГОРИТМЫ

Как правило, в основу обучающихся систем заложены вероятностные итеративные алгоритмы с помощью которых достигается цель обучения. Цель обу-

чения можно представить как экстремум функционала

$$(5) \quad J(\mathbf{c}) = \int_{\mathbf{x}} Q(\mathbf{x}, \mathbf{c}) p(\mathbf{x}) d\mathbf{x}.$$

где $\mathbf{c} = (c_1, \dots, c_N)$ — вектор неизвестных параметров, $\mathbf{x} = (x_1, \dots, x_M)$ — вектор входного случайного процесса, плотность распределения которого равна $p(\mathbf{x})$, $Q(\mathbf{x}, \mathbf{c})$ — заданная функция.

Условия экстремума можно записать как

$$\nabla J(\mathbf{c}) = E_{\mathbf{x}}\{\nabla_{\mathbf{c}} Q(\mathbf{x}, \mathbf{c})\} = 0.$$

С помощью вероятностных итеративных алгоритмов (на базе стохастических аппроксимаций) можно на каждом шаге n по значениям $\mathbf{x}[n]$ и предыдущего значения $\mathbf{c}[n-1]$ и $\nabla_{\mathbf{c}} Q(\mathbf{x}[n], \mathbf{c}[n-1])$ определить вектор $\mathbf{c}[n]$ так, чтобы этот вектор по мере увеличения информации стремился к такому значению \mathbf{c}^* для которого функционал (5) достигает экстремума.

Дискретный алгоритм обучения может быть представлен в виде разностного уравнения [1]

$$(6) \quad \mathbf{c}[n] = \mathbf{c}[n-1] - \Gamma[n] \nabla J(\mathbf{x}[n], \mathbf{c}[n-1]),$$

где

$$\Gamma[n] = \begin{pmatrix} \gamma_1[n], 0 & \dots & 0 \\ 0, & \gamma_2[n] & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \gamma_N[n] \end{pmatrix}.$$

Для разнообразных задач обучения прежде всего выбирается класс аппроксимирующих функций и мера уклонения, которая характеризует точность аппроксимации. Случайную меру уклонения определяем как некоторую выпуклую функцию от $y = f(\mathbf{x})$ и $\hat{f}(\mathbf{x}, \mathbf{c})$.

Обычно мера уклонения определяется как функция F разности $y - \hat{f}(\mathbf{x}, \mathbf{c})$ и в качестве меры аппроксимации выбирается функционал [1] в виде математического ожидания

$$(7) \quad J(\mathbf{c}) = E_{\mathbf{x}}\{F(y - \hat{f}(\mathbf{x}, \mathbf{c}))\} = E_{\mathbf{x}}\{Q(\mathbf{x}, \mathbf{c})\},$$

где за $\hat{f}(\mathbf{x}, \mathbf{c})$ можно подставлять аппроксимирующую функцию $\hat{f}_1(\mathbf{x}, \mathbf{c})$ или $\hat{f}_2(\mathbf{x}, \mathbf{c})$.

Напомним, что задача об аппроксимации в стохастическом смысле возникла в связи с развитием регрессионного анализа. Эта задача и заключается в построении итерационного процесса, который предполагается сходящимся в вероятностном смысле.

Минимум функционала (7) будем искать (учитывая аппроксимацию (2)) по измеренным градиентным реализациям

$$\begin{aligned}\frac{\partial J(\mathbf{c})}{\partial c_0} &= -F'[y - (\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0)] \cdot 1, \\ \frac{\partial J(\mathbf{c})}{\partial c_1} &= -F'[y - (\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0)] \prod_{\substack{i=1 \\ i \neq 1}}^N (\varphi_i(\mathbf{x}) + c_i), \\ &\dots\dots\dots \\ \frac{\partial J(\mathbf{c})}{\partial c_j} &= -F'[y - (\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0)] \prod_{\substack{i=1 \\ i \neq j}}^N (\varphi_i(\mathbf{x}) + c_i), \\ &\dots\dots\dots \\ \frac{\partial J(\mathbf{c})}{\partial c_N} &= -F'[y - (\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0)] \prod_{\substack{i=1 \\ i \neq N}}^N (\varphi_i(\mathbf{x}) + c_i).\end{aligned}$$

Обозначим

$$\begin{aligned}\nabla_{\mathbf{c}}[\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0] &= \\ = (1, \prod_{\substack{i=1 \\ i \neq 1}}^N (\varphi_i(\mathbf{x}) + c_i), \dots, \prod_{\substack{i=1 \\ i \neq j}}^N (\varphi_i(\mathbf{x}) + c_i), \dots, \prod_{\substack{i=1 \\ i \neq N}}^N (\varphi_i(\mathbf{x}) + c_i)).\end{aligned}$$

Потом

$$\begin{aligned}\nabla_{\mathbf{c}} F[y - (\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0)] &= \\ = -F'[y - (\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0)] \nabla_{\mathbf{c}}[\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0].\end{aligned}$$

С учетом предыдущего вероятностный итеративный алгоритм обучения в дискретной форме принимает вид

$$\begin{aligned}\mathbf{c}[n] &= \mathbf{c}[n-1] + \gamma[n] F'[y[n] - (\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1])] \times \\ &\times \nabla_{\mathbf{c}} \{ \prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \},\end{aligned}$$

или в непрерывной форме

$$\begin{aligned}\frac{d\mathbf{c}(t)}{dt} &= \gamma(t) F'[y(t) - (\prod_{i=1}^N [\varphi_i(\mathbf{x}(t)) + c_i(t)] + c_0(t))] \times \\ &\times \nabla_{\mathbf{c}} [\prod_{i=1}^N [\varphi_i(\mathbf{x}(t)) + c_i(t)] + c_0(t)].\end{aligned}$$

Упрощенная схема реализации этого алгоритма в дискретной форме показана на рис. 1. В блочную схему включены функции $\varphi_i(\mathbf{x})$ и $F'(\cdot)$. Для трех составляющих входного вектора получим схему на рис. 2.




Рис. 1.

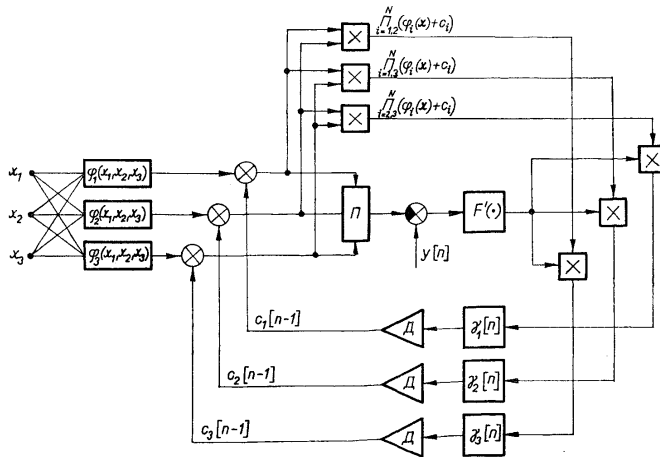


Рис. 2.

3. ДИСКРЕТНЫЕ АЛГОРИТМЫ РАСПОЗНАВАНИЯ И КЛАССИФИКАЦИИ ДО ДВУХ ГРУПП

При классификации до двух групп можно аппроксимирующую функцию записать в виде

$$\hat{f}_1(\mathbf{x}[n], \mathbf{c}[n-1]) = \prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1],$$

или

$$\hat{f}_2(\mathbf{x}[n], \mathbf{c}[n-1]) = \sum_{j=1}^I \prod_{i=m_{j-1}+1}^{m_j} (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1].$$

На основании первой аппроксимации и разных критериев качества можно составить алгоритмы которые будут эти функционалы минимизировать:

Критерий

$$J(\mathbf{c}) = E_x \{ \{ \text{sign } y - \text{sign} \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0 \right) \} \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0 \right) \}.$$

Алгоритм

$$\begin{aligned} \mathbf{c}[n] &= \mathbf{c}[n-1] + \\ &+ \gamma[n] \{ \text{sign } y[n] - \text{sign} \left[\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right] \} \times \\ &\times \nabla_{\mathbf{c}} \left[\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right]. \end{aligned}$$

Критерий

$$J(\mathbf{c}) = E_x \{ \left| y - \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0 \right) \right|^2 \}.$$

Алгоритм

$$\begin{aligned} \mathbf{c}[n] &= \mathbf{c}[n-1] + \\ &+ \gamma[n] \text{sign} \{ y[n] - \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right) \} \times \\ &\times \nabla_{\mathbf{c}} \left[\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right]. \end{aligned}$$

Критерий

$$J(\mathbf{c}) = E_x \{ (y - \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0 \right))^2 \}.$$

Алгоритм

$$\begin{aligned} \mathbf{c}[n] &= \mathbf{c}[n-1] + \\ &+ G[n] \{ y[n] - \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right) \} \times \\ &\times \nabla_{\mathbf{c}} \left[\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right]. \end{aligned}$$

4. АЛГОРИТМЫ ОСНОВАННЫЕ НА СОВПАДЕНИИ ЗНАКОВ y
И $\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0$ И ОПРЕДЕЛЕНИИ \mathbf{c} ИЗ СИСТЕМЫ
НЕРАВЕНСТВ

383

Тождество знаков выполняется если

$$y[n] \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right) > 0.$$

$$y[n] \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right) = \xi[n-1], \quad \xi > 0.$$

Критерий качества запишем в виде

$$J(\mathbf{c}, \xi) = E_x \left\{ F \left[y \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}) + c_i) + c_0 \right) - \xi \right] \right\}.$$

Для решения применим алгоритмы

$$\begin{aligned} \mathbf{c}[n] &= \mathbf{c}[n-1] - \\ &- \gamma_1[n] F' \left\{ y[n] \left[\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right] - \xi[n-1] \right\} \times \\ &\times \nabla_{\mathbf{c}} \left\{ \left[\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right] y[n] \right\}, \end{aligned}$$




Рис. 3.

$$\begin{aligned} \xi[n] &= \xi[n-1] + \\ &+ \gamma_2[n] \left\{ F' \left[y[n] \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right) - \xi[n-1] \right] \right\} + \\ &+ \left| F' \left[y[n] \left(\prod_{i=1}^N (\varphi_i(\mathbf{x}[n]) + c_i[n-1]) + c_0[n-1] \right) - \xi[n-1] \right] \right\}, \\ \xi(0) &> 0. \end{aligned}$$

Реализация этих алгоритмов показана на рис. 3.

Обучение можно ускорить выбором (в предыдущих алгоритмах) оптимальной величины $\gamma_{\text{опт}}[n]$. Это можно сделать для каждого входного вектора аналитическим способом. Ускорить процесс обучения можно также использованием

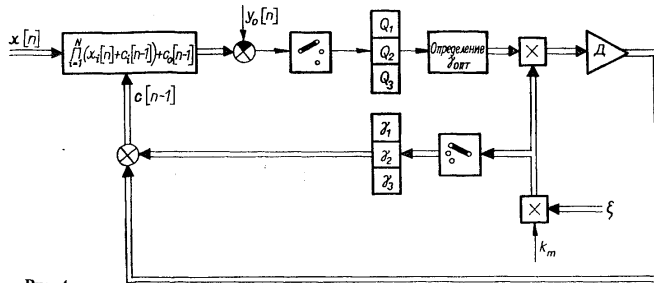


Рис. 4.




Рис. 5.

алгоритмов с параболической интерполяцией или алгоритмов со случайными векторами и параболической интерполяцией. Блочная схема реализации алгоритмов обучения с параболической интерполяцией показана на рис. 4 и схема алгоритма с вспомогательными случайными векторами и параболической интерполяцией на рис. 5.

Доказательство сходимости приведенных алгоритмов и связь „классических“ и „неклассических“ аппроксимаций будут опубликованы в последующих номерах журнала.

Новая аппроксимация была проверена на АВМ а ЦВМ в алгоритмах классификации и распознавания образов.

(Поступила 26. июня 1970.)

ЛИТЕРАТУРА

- [1] Цыпкин Я. З.: Основы теории обучающихся систем. Изд. „Наука“, Москва 1970.
- [2] Цыпкин Я. З.: Адаптация и обучение в автоматических системах. Изд. „Наука“, Москва 1968.

ВЪТАН

Нěkteré obecné algoritmy učení

ZDENĚK ČASTORÁL

Článek je věnován obecným algoritmům učení, které je možné využít jak pro klasifikaci a rozeznávání obrazů, tak i pro identifikaci, adaptivní filtraci a vlastní řízení. Vychází se z nové aproximační funkce a ta se využívá v diskrétních i spojitéch algoritmech. Posuzují se metody zrychlení konvergence.

Ing. Zdeněk Častorál, CSc., Fakulta elektrotechnická ČVUT (Политехнический институт — электротехнический факультет), Karlovo nám. 13, Praha 2.