

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.

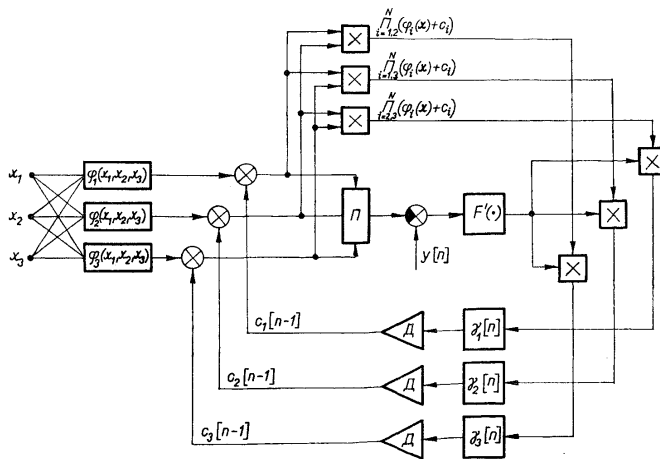


Рис. 2.

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

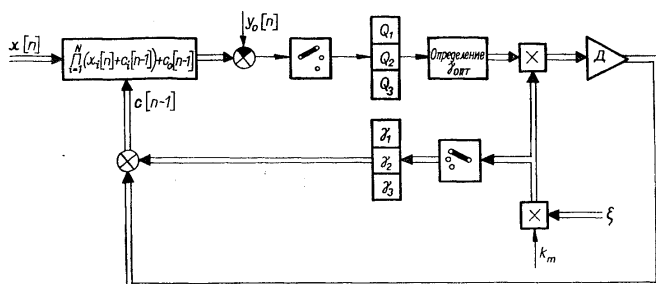


Рис. 4.




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.