

Метрические методы классификации

К. В. Воронцов
vokov@forecsys.ru

Этот курс доступен на странице вики-ресурса
<http://www.MachineLearning.ru/wiki>
«Машинное обучение (курс лекций, К.В.Воронцов)»

26 февраля 2009

Содержание

1 Метрические алгоритмы классификации

- Гипотеза компактности
- Методы типа ближайших соседей
- Снова метод парзеновского окна
- Метод потенциальных функций

2 Отбор эталонных объектов

- Понятие отступа
- Алгоритм отбора эталонных объектов

Гипотеза компактности

Задача классификации:

X — объекты, Y — ответы (идентификаторы классов);

$X^\ell = (x_i, y_i)_{i=1}^\ell$ — обучающая выборка;

Гипотеза компактности:

Схожие объекты, как правило, лежат в одном классе.

Формализация:

Задана функция расстояния $\rho: X \times X \rightarrow [0, \infty)$.

Выборка задана $\ell \times \ell$ матрицей попарных расстояний
(признаков вообще может не быть!)

Обобщённый метрический классификатор

Для произвольного $u \in X$ отсортируем объекты x_1, \dots, x_ℓ :

$$\rho(u, x_u^{(1)}) \leq \rho(u, x_u^{(2)}) \leq \dots \leq \rho(u, x_u^{(\ell)}),$$

$x_u^{(i)}$ — i -й сосед объекта u среди x_1, \dots, x_ℓ ;

$y_u^{(i)}$ — ответ на i -м соседе объекта u .

Метрический алгоритм классификации:

$$a(u; X^\ell) = \arg \max_{y \in Y} \underbrace{\sum_{i=1}^{\ell} [y_u^{(i)} = y] w(i, u)}_{\Gamma_y(u, X^\ell)},$$

$w(i, u)$ — вес (степень важности) i -го соседа объекта u , неотрицателен, не возрастает по i .

$\Gamma_y(u, X^\ell)$ — оценка близости объекта u к классу y .

Метод ближайшего соседа

$$w(i, u) = [i=1].$$

Преимущества:

- простота реализации;
- интерпретируемость решений,
вывод на основе прецедентов (case-based reasoning, CBR)

Недостатки:

- неустойчивость к погрешностям (шуму, выбросам);
- отсутствие настраиваемых параметров;
- низкое качество классификации;
- приходится хранить всю выборку целиком.

Метод k ближайших соседей

$$w(i, u) = [i \leq k].$$

Преимущества:

- менее чувствителен к шуму;
- появился параметр k .

Оптимизация числа соседей k :

функционал скользящего контроля leave-one-out

$$\text{LOO}(k, X^\ell) = \sum_{i=1}^{\ell} [a(x_i; X^\ell \setminus \{x_i\}, k) \neq y_i] \rightarrow \min_k.$$

Проблема:

- неоднозначность классификации при $\Gamma_y(u, X^\ell) = \Gamma_s(u, X^\ell)$, $y \neq s$.

Метод k взвешенных ближайших соседей

$$w(i, u) = [i \leq k]w_i,$$

где w_i — вес, зависящий только от номера соседа;

Возможные эвристики:

$w_i = \frac{k+1-i}{k}$ — линейные убывающие веса;

$w_i = q^i$ — экспоненциально убывающие веса, $0 < q < 1$;

Проблемы:

- как более обоснованно задать веса?
- как сделать, чтобы вес $w(i, u)$ зависел не от порядкового номера соседа i , а от расстояния до него $\rho(u, x_u^{(i)})$?

Снова метод парзеновского окна

$$w(i, u) = K\left(\frac{\rho(u, x_u^{(i)})}{h}\right),$$

где $K(r)$ — ядро, невозрастающее, положительное на $[0, 1]$.

Метод парзеновского окна фиксированной ширины:


$$a(u; X^\ell, h, K) = \arg \max_{y \in Y} \sum_{i=1}^{\ell} [y_u^{(i)} = y] \underbrace{K\left(\frac{\rho(u, x_u^{(i)})}{h}\right)}_{w(i, u)}.$$

Метод парзеновского окна переменной ширины:

$$a(u; X^\ell, k, K) = \arg \max_{y \in Y} \sum_{i=1}^{\ell} [y_u^{(i)} = y] \underbrace{K\left(\frac{\rho(u, x_u^{(i)})}{\rho(u, x_u^{(k+1)})}\right)}_{w(i, u)}.$$

Метод парзеновского окна

Пример: классификация двумерной выборки.



Метод потенциальных функций

$$w(i, u) = \gamma_u^{(i)} K\left(\frac{\rho(u, x_u^{(i)})}{h_u^{(i)}}\right)$$

Более простая запись:

$$a(u; X^\ell) = \arg \max_{y \in Y} \sum_{i=1}^{\ell} [y_i = y] \gamma_i K\left(\frac{\rho(u, x_i)}{h_i}\right),$$

где γ_i — веса объектов, $\gamma_i \geq 0$, $h_i > 0$.

Физическая аналогия:

γ_i — величина «заряда» в точке x_i ;

h_i — «радиус действия» потенциала с центром в точке x_i ;

y_i — знак «заряда» (предполагается, что $Y = \{-1, +1\}$);

в электростатике $K(r) = \frac{1}{r}$ или $\frac{1}{r+a}$.

Алгоритм настройки весов объектов

Простой эвристический алгоритм настройки γ_i .

Вход:

X^ℓ — обучающая выборка;

Выход:

Коэффициенты γ_i , $i = 1, \dots, \ell$;

- 1: Инициализация: $\gamma_i = 0$ для всех $i = 1, \dots, \ell$;
- 2: **повторять**
- 3: выбрать объект $x_i \in X^\ell$;
- 4: **если** $a(x_i) \neq y_i$ **то**
- 5: $\gamma_i := \gamma_i + 1$;
- 6: **пока** число ошибок на выборке $Q(a, X^\ell) > \varepsilon$.

Анализ преимуществ и недостатков

Преимущества:

- простота реализации;
- не надо хранить выборку (поточковый алгоритм обучения);
- разреженность: не все обучающие объекты учитываются.

Недостатки:

- медленная сходимость;
- результат обучения зависит от порядка просмотра объектов;
- слишком грубо настраиваются веса γ_i ;
- вообще не настраиваются параметры h_i ;
- вообще не настраиваются центры потенциалов;
- может, некоторые γ_i можно было бы обнулить?

Вывод: EM-RBF, конечно, круче...

Понятие отступа

Рассмотрим классификатор $a: X \rightarrow Y$ вида

$$a(u) = \arg \max_{y \in Y} \Gamma_y(u), \quad u \in X.$$

Отступом (margin) объекта $x_i \in X^\ell$ относительно классификатора $a(u)$ называется величина

$$M(x_i) = \Gamma_{y_i}(x_i) - \max_{y \in Y \setminus y_i} \Gamma_y(x_i).$$

- Отступ показывает *степень типичности* объекта;
- $M(x_i) < 0 \Leftrightarrow a(x_i) \neq y_i$;

Типы объектов, в зависимости от отступа

- *эталонные* (можно оставить только их);
- *неинформативные* (можно удалить из выборки);
- *пограничные* (их классификация неустойчива);
- *ошибочные* (причина — плохая модель);
- *шумовые* (выбросы; причина — плохие данные).

Идея: шумовые и неинформативные удалить из выборки.

Алгоритм STOLP: основная идея

- исключить выбросы;
- найти по одному эталону в каждом классе;
- добавлять эталоны, пока есть отрицательные отступы;

Алгоритм STOLP

Вход:

- X^ℓ — обучающая выборка;
- δ — порог фильтрации выбросов;
- ℓ_0 — допустимая доля ошибок;

Выход:

Множество опорных объектов $\Omega \subseteq X^\ell$;

Классификатор будет иметь вид:

$$a(u; \Omega) = \arg \max_{y \in Y} \sum_{x_i \in \Omega} [y_u^{(i)} = y] w(i, u),$$

- $x_u^{(i)}$ — i -й сосед объекта u среди Ω ;
- $y_u^{(i)}$ — ответ на i -м соседе объекта u .

Алгоритм STOLP

- 1: **для всех** $x_i \in X^\ell$ проверить, является ли x_i выбросом:
- 2: **если** $M(x_i, X^\ell) < \delta$ **то**
- 3: $X^{\ell-1} := X^\ell \setminus \{x_i\}; \quad \ell := \ell - 1;$
- 4: Инициализация: взять по одному эталону от каждого класса:
 $\Omega := \left\{ \arg \max_{x_i \in X_y^\ell} M(x_i, X^\ell) \mid y \in Y \right\};$
- 5: **пока** $\Omega \neq X^\ell;$
- 6: Выделить множество объектов с ошибкой $a(u; \Omega):$
 $E := \{x_i \in X^\ell \setminus \Omega : M(x_i, \Omega) < 0\};$
- 7: **если** $|E| < \ell_0$ **то**
- 8: **выход;**
- 9: Присоединить к Ω объект с наименьшим отступом:
 $x_i := \arg \min_{x \in E} M(x, \Omega); \quad \Omega := \Omega \cup \{x_i\};$

Алгоритм STOLP: преимущества и недостатки

Преимущества:

- универсальность (для любой функции $w(i, u)$);
- параметр δ управляет «шумоподавлением»;
- сокращается число хранимых объектов;
- сокращается время классификации;
- объекты распределяются по величине отступов;

Недостатки:

- относительно низкая эффективность $O(|\Omega|^2\ell)$.