

Распознавание образов

12.02.14

Классификация или отнесение объектов к одному из классов

Объекты, кот. классиф-ся на образы

Хар-ки объекта — это признаки

Несомн. по признакам отнести объект к одному из классов на основе алгоритма — этот процесс наз. классификацией

Литература:

1. Местечкий "Классификация"
2. Воронцов → МАЛ (исход. анализ данных) → лекции (есть сессия на конспекты)
3. Филанов (ПОМИ) — кафедра мат. логики уделяет внимание алгоритмической стороне вопроса — см. курс лекций.

Признаки бывают:

1. Двоичные (0 или 1) (да или нет)
2. Номинальные — конечное число непоряд. значений
3. Порядковые (ординальные) — их можно упорядочить, но они не числового характера
4. Числовые

Классиф-ция → с обучением — дано несколько объектов проклассиф-их заранее
→ без обучения — на основе тех же признаков даны результаты классиф-ции заранее

Базисовские методы классификации

$(x_1, y_1) \dots (x_n, y_n) \leftarrow \text{с. б. в.}$
 $\sim F(x, y)$ где y принимает конечное число значений.

x_i — признаки
В действ-ти, мы наблюдаем $x_1, \dots, x_n$

Прогнозирование Y .

Бинарная классификация

$Y = 0$ или 1 .

Классификатор

$$g(x) = \begin{cases} 0 & \text{или} \\ 1 \end{cases}$$

$$\eta(x) = P(Y=1|X=x)$$

$$Y = \begin{cases} 0, & \text{с вероятностью } 1 - \eta(x) \\ 1, & \text{с вероятностью } \eta(x) \end{cases}$$

$$0 \leq \eta(x) \leq 1$$

(при фикс. x , и. заданы Y)

Ошибка классифицирования: $P(g(x) \neq Y) = P(g(X) \neq Y)$

Байесовский классификатор

$$g(x) = \begin{cases} 1, & \eta(x) \geq \frac{1}{2} \\ 0, & \eta(x) < \frac{1}{2} \end{cases} \quad g = g^*$$

$$\boxed{\text{Т}} \quad P(g^*(X) \neq Y) \leq P(g(X) \neq Y)$$

$$\text{Доказ-во: } P(g(X) \neq Y) = E_x E(\mathbb{1}_{g(X) \neq Y} | X=x) \Rightarrow$$

$\Rightarrow$ Достаточно минимизировать ошибку классификатора

$$E(\mathbb{1}_{g(X) \neq Y} | X=x) =$$

$$= 1 - E(\mathbb{1}_{g(X)=Y} | X=x) =$$

$$= 1 - (P(g(X)=1, Y=1 | X=x) + P(g(X)=0, Y=0 | X=x)) =$$

$$= 1 - (\mathbb{1}_{g(X)=0} P(Y=0 | X=x) + \mathbb{1}_{g(X)=1} P(Y=1 | X=x)) =$$

$$= 1 - (\mathbb{1}_{g(X)=0} (1 - \eta(x)) + \mathbb{1}_{g(X)=1} \eta(x)) =$$

$$= P(g^*(X) \neq Y | X=x) - P(g(X) \neq Y | X=x) =$$

$$= (\mathbb{1}_{g(X)=0} - \mathbb{1}_{g^*(X)=0}) (1 - \eta(x)) +$$

$$+ (\mathbb{1}_{g(X)=1} - \mathbb{1}_{g^*(X)=1}) \eta(x)$$

$$\text{Заметим, } \mathbb{1}_{g(X)=1} = 1 - \mathbb{1}_{g(X)=0}$$

$$= (\mathbb{1}_{g^*(X)=1} - \mathbb{1}_{g(X)=1}) (1 - \eta(x)) + (\mathbb{1}_{g(X)=1} - \mathbb{1}_{g^*(X)=1}) \eta(x) =$$

$$= (\mathbb{1}_{g^*(X)=1} - \mathbb{1}_{g(X)=1}) (1 - 2\eta(x)) \leq 0$$

$$1 - 2\eta(x) > 0 \Rightarrow \mathbb{1}_{g^*(X)=1} = 1$$

$\square$

Общий случай:

$$(x_1, y_1), \dots, (x_k, y_k) \quad y_i = \begin{cases} 1 \\ \vdots \\ k \end{cases}$$

$$P(Y_i = c | X_i = x) = \eta_c(x) \quad \sum_c \eta_c(x) = 1$$

а) $\min P(g(X) = Y)$

Оптимальный классиф-ор: $\hat{c} = \arg \max_c \eta_c(x)$

Рассечение смеси вероятностных распределений:

$$p(x) = \sum_{c=1}^k \eta_c \cdot p_c(x)$$

Ответ: $P(Y = c | X = x) = \frac{\eta_c p_c(x)}{\sum \eta_c p_c(x)}$

$$\hat{c} = \arg \max_c \eta_c p_c(x)$$

Классификация для смеси нормальных распределений. Дискриминантный анализ.

$p(x) = \sum \eta_c N(x | \mu_c, \Sigma_c)$ берем произведение того или иного класса
 коррел. matr.

Нужн. найти: параметры норм. распредел.

$$\arg \max_c \eta_c N(x | \mu_c, \Sigma_c)$$

Если есть обучающая выборка, то оцениваем μ_c и Σ_c если нет, то есть эм-анормити //

$$\hat{c} = \arg \max_c \ln \eta_c + \ln N_c(x, \mu_c, \Sigma_c)$$

(*) $\ln \eta_c - \frac{1}{2} \ln 2\pi - \frac{1}{2} \ln |\Sigma_c| - \frac{1}{2} (x - \mu_c)^T \Sigma_c^{-1} (x - \mu_c)$
 ln (exp...)
 учитываем

$$-\frac{1}{2} (x - \mu_c)^T \Sigma_c^{-1} (x - \mu_c) \rightarrow \arg \max$$

$\uparrow$ оценка μ_c
 $\uparrow$ оценка Σ_c

расстояние Махаланобиса

Дискриминант Фишера

7 $\Sigma_1 = \Sigma_2 = \dots = \Sigma_n$

Тогда и построить фигуру охотку где где-перси \$.

$$(x): \ln \eta_e - \frac{d}{2} \ln 2\pi - \frac{1}{2} \ln |\Sigma| - \frac{1}{2} (x - \bar{x}_e)' S_e^{-1} (x - \bar{x}_e)$$

Тогда $X S^{-1} X$ сокращается т.к не зависит от v

Tогда $x^T S^{-1} x$ сокращается т.к не зависит от ℓ
argmax $C_\ell + \bar{x}_\ell^T S^{-1} \bar{x}_\ell - \frac{1}{2} \bar{x}_\ell^T S^{-1} \bar{x}_\ell = \text{const}$
 $x^T S^{-1} x$

Дискриминант Формы от x .
// Нахождение корней по формуле
все так и там сразу же классификация //

0.02.14.
$$p(x) = \sum_{i=1}^K \omega_i p_i(x, \theta_i)$$
 — модель, где K — число классов, где ω_i — распределение внутри класса.

Предположение, что обучающейся выборке нет. $\Rightarrow$ предположение EM-алгоритма (expectation, maximization) — состоит из этих 2^k исходов.

Задача моделирования
распределения:

1. Ullar $\mathcal{V}_1$: $P(\mathcal{V}_1 = \bar{v}) = \omega_{\bar{v}}$

2. Моделируем x_i с помощью распределения

✓ Разбираем номер, после $p: (x)$ к нему с. в.

$$(z_1, x_1), \dots, (z_n, x_n)$$

$$\hat{w}_i = \frac{1}{n} \sum_{s=1}^n \mathbb{1}_{\{z_s = i\}} \quad \text{оценка } w_i \quad (*)$$

$\mathbb{I} \{x_1, \dots, x_n\}$ — см. величины $x_1, \dots, x_n$ не наблюдаются
хотим преобразовать их в $z_1, \dots, z_n$ как построить

$$P(z=i | X=x) \quad \text{по г. Байеса} = \frac{w_i p_i(x)}{\sum_{j=1}^K w_j p_j(x)} = g_i(x) \quad \text{оценку}$$

После того как z_i ^{по модели} оценены z_i , $i=1, \dots, n$
и оценить $\hat{w}_i$ $(*)$

↑ дисперсия оценки $\Rightarrow$
индикаторы $\mathbb{I}\{z_s=i\}$ $\Rightarrow$ уменьшение дисперсии $\Rightarrow$ $\hat{w}_i$ $\Rightarrow$ $\hat{v}(x)$

$$E(\hat{w}_i | x_1, \dots, x_n) = \frac{1}{n} \sum_{s=1}^n g_{si}(x_s) =: \hat{w}_i \quad \text{оценка}$$

$$\approx \frac{1}{n} \sum_{s=1}^n E(\mathbb{I}_{\{z_s=i\}} | x_s) =: g_i(x_s) \quad \text{т.о. научиться}$$

просто оценивать $\hat{w}_i \rightarrow$ и написать алгоритм

Алгоритм:

1°. Берем нач. приближение $w_{i0}, p_{i0}, i=0$

2°. ^{Е-шаг} Оцениваем $\hat{w}_{i\ell} = \frac{1}{n} \sum_{s=1}^n \frac{\hat{w}_{i\ell-1} p_i(x_s; \hat{\theta}_{i\ell-1})}{\sum_{j=1}^K \hat{w}_{j\ell-1} p_j(x_s; \hat{\theta}_{j\ell-1})}$
делаем оценку некоей $\hat{\theta}_{i\ell}$ $\Rightarrow$ $\hat{w}_{i\ell}$

3°. И-шаг $\hat{\theta}_{i\ell}$
Находим оценку $\hat{\theta}_{i\ell}$ $\vee$ max правдоподобия $\hat{\theta}_{i\ell}$ при условии, что $w_i = \hat{w}_{i\ell}$ — известны.

p.s. Оц. max правд. написаны не совсем в очевидной форме, обходим ее позже

$$(*) \sum g_{i\ell}(x_s) \frac{p_i(x_s; \theta_i)}{p_i(x_s; \theta_i)} = 0 \quad \text{решаем отдельно}$$

$$g_{i\ell}(x) = \frac{w_{i\ell} p_i(x; \theta_{i\ell-1})}{\sum_{j=1}^K \hat{w}_{j\ell} p_j(x; \theta_{j\ell-1})} \quad \text{при фикс. } i \text{ — ждем 60 методов}$$

Целью это нам нужно сейчас обосн.
Общее обоснование (*):

$$\max \sum_{s=1}^n \ln \left(\sum_{j=1}^K \hat{w}_j p_j(x, \theta_j) \right) - \text{приэф. по } \theta_i$$

$$\text{Получение: } \sum_{s=1}^n \left(\hat{w}_{i,t-1} / \sum_{j=1}^K \hat{w}_{j,t-1} p_j(x_s, \theta_{j,t-1}) \right) \cdot p_{i,t}(x_s, \theta_{i,t}) = 0$$

// Потом выведем это для $N(a, \sigma^2)$ //

Умножим на $p_i(x_s, \theta_{i,t-1}) / p_i(x_s, \theta_{i,t})$, тогда:

$$\sum \frac{\hat{w}_{i,t-1} \cdot p_i(x_s, \theta_{i,t-1})}{\sum_{j=1}^K \hat{w}_{j,t-1} p_j(x_s, \theta_{j,t-1})} \cdot \frac{p_{i,t}(x_s, \theta_{i,t})}{p_i(x_s, \theta_{i,t-1})}$$

$$0 = \sum_{s=1}^n g_{i,t-1}(x_s) - \frac{p_{i,t}(x_s, \hat{\theta}_{i,t})}{p_i(x_s, \hat{\theta}_{i,t})} = 0$$

Замечание: и показать, что оценки E-
ская явл. су. max правд-ие w_i при
факт, что θ_i - фиксер. Таким образом
мы можем ОМП попарно параметр θ_i и фиксировать
и все хорошо алгоритм? один из них



Можно взять для
каждого класса смесь
нормальных распреде-
лений. - это повлияет
на границу

Вставка (см. после Каштанова)

Смесь нормальных распределений

$$p(x) = \sum w_i N(\mu_i, R_i)$$

↑ плотности норм. распр.

Шаг 1: нач. приближение w_{i0}, μ_{i0}, R_{i0}

6

$$\text{Шаг 2: } g_{i,t}(x) = \frac{\hat{w}_{i,t} N(\hat{\mu}_{i,t-1}, \hat{R}_{i,t-1})}{\sum_{j=1}^K \hat{w}_{j,t} N(\hat{\mu}_{j,t-1}, \hat{R}_{j,t-1})}$$

$$w_{i,t} = \frac{1}{n} \sum g_{i,t-1}(x_s)$$

Множ 3: $\hat{\mu}_{ce} = \sum g_{ce}(x_s) \cdot \vec{x}_s$ // μ_{ce} и x_s - вектора

$$\hat{R}_{ce} = \sum_{s=1}^n g_{ce}(x_s) (\vec{x}_s - \hat{\mu}_{ce}) (\vec{x}_s - \hat{\mu}_{ce})^T$$

$\hat{\mu}_{ce} = \frac{1}{n} \sum_{s=1}^n g_{ce}(x_s) \vec{x}_s$ берется в общем смысле и все нормировано

Непараметрические методы непараметрического оценивания (классификация с обучением) в задачах классификации

$$p(x) = \sum w_j p_j(x)$$

Если есть обучающая выборка: $(x_1, y_1), \dots, (x_n, y_n)$, то мы берем относительные частоты $\hat{w}_j = \frac{1}{n} \sum$

$$\hat{w}_j = \frac{1}{n} \sum_{s=1}^n \mathbb{1}_{\{y_s=j\}}$$

как оценки w_j после введения подвыборки $x_{s_1}, \dots, x_{s_{t,z}}$ т.е. $y_{s_{t,z}} = j$ и для них непараметрически оценить плотность $p_j(x)$ и задача будет решена

P.S. основная проблема - вектор признаков X многомерный, а мы его в задачку добавляем на кусочки

Выход:
Ближайшая оценка: $\hat{f}_n(x) = \frac{1}{n} \sum_{s=1}^n K\left(\frac{p(x_s, x)}{h}\right)$

где $p(x_s, x)$ - расстояние между x_s и x .

Возникает вопрос выбора h .

Идея: выбрать h т.ч. что $\# \{x_s : p(x_s, x) \leq h\} = k$ - фикс.

Если $K(x) = \mathbb{1}_{\{|x| \leq 1\}}$, то мы получаем в качестве оценки:

$$\hat{f}_n(x) = \frac{k}{n} p(x, x^{(k)})$$

где $x^{(k)}$ - это k -ое удаление от x .
 $p(x, x^{(1)}) \leq p(x, x^{(2)}) \leq \dots \leq p(x, x^{(k)})$

На основе такой оценки построен алгоритм k-ближ. соседей

Алгоритм k-ближайших соседей.

У нас есть наблюдение: $(x_1, y_1), \dots, (x_n, y_n)$
Хотим найти классификацию для x_{new} .
Берем для него k ближайших $x^{(1)}, \dots, x^{(k)}$
$$\rho(x_{new}, x^{(1)}) \leq \dots \leq \rho(x_{new}, x^{(k)})$$

$y^{(i)}$ - категория $x^{(i)}$

$$\hat{y}_i = \sum_{j=1}^k \frac{1}{k} y^{(j)} \quad ; \quad \text{Категория } x_i = \arg \max \hat{y}_i$$

// т.е. берем то, что чаще всего встречается //

Критерий от сильно зависит от выбора расстояний и от k. (чаще $k=1$)

27.02.14. Параметрические методы классиф.

$(x_1, y_1), \dots, (x_n, y_n)$ - обучающая выборка
 $\{x_i\}$ - признаки, $\{y_i\}$ - образы (объекты)

$$y_i = \begin{cases} 1 \\ -1 \end{cases}$$

2) Ф-ция дискриминации $f(x, w)$ параметры $w \in \mathbb{R}^d$ (*)

2) Дискриминатор $a(x) = \int \text{sign } f(x, w)$

поценка

и построить линейный дискр: $R(x^{(n)})$

+ ввести функцию $a(x, w) = \text{sign } f(x, w)$. Тогда:

$$x^{(n)} = (x^{(1)}, \dots, x^{(n)}) : R(x^{(n)}) = \sum_{i=1}^n \frac{1}{n} \{ a f(x_i, w) y_i \geq 0 \} (*)$$

→ минимизация риска

Наша задача найти w т.ч. (*) $\rightarrow$ min.

проблема (1) Ф-ция, кот. мин-се нелинейна -

2) и не от данных свойства параметров

тогда хорошо min линейный дискр, но ф-ция

// - проблема переобучения (переобученности) //

$f(x, w)$ и иметь переопределенный биг Λ

Поэтому в реальных задачах бутылочная горловина разбивается на 2 части: ~~на~~ первая строится $f(x)$, но 2-ой проверим, не произойдет ли эффект переподготовки.

Т.е. в задачах классификации не только строится классификатор, но и проверяется.

Опр: Величина $f(x_i, w) y_i$ наз. отступом.
 $M := f(x_i, w) y_i$

Как бороться с $\downarrow$ в формуле (*)?
 (?) : $\downarrow$ заменяем на $\mathcal{L}(f(x_i, w) y_i)$ — непрерывная функция. $\mathcal{L}(M)$

Пр: $\mathcal{L}(M) = \frac{1}{1 + e^{-M}}$ — логистическая регрессия ✓

$(1-M)_+ = \max(1-M, 0)$
 $\uparrow$ SVM — support vector machines

e^{-M} — ADA boosting

(*) заменяем на

это отступ M

R^d (**): $\bar{Q} = \sum \mathcal{L}(M_i) = \sum_{i=1}^n \mathcal{L}(y_i f(x_i, w))$ — макс
 // хотим получить $\bar{Q}$ мин //

$\mathcal{L}(y_i f(x_i, w)) = -\ln p(x_i, y_i, w)$ где p — плотность распределения x_i, y_i

Плюс задача (**) эквивалентна задаче нахождение мин где $p(x, y, w)$

(*)
 Т.е. $Q = - \sum_{i=1}^n \ln p(x_i, y_i, w)$

е-функции. аналогично для смеси распределений и логист. регрессии допускают также более интерпретацию

Классификация на основе логистической регрессии

Есть наблюдения $(x_1, y_1), \dots, (x_n, y_n)$ $y_i = \pm 1$
и написать совместную плотность распредел.

$$p(x, y) = p(y|x) \cdot p(x) \quad y = \pm 1$$

Предположим, что $p(+1|x) = \exp \{ c(\delta) \langle w, x \rangle + h(\delta, x) + \tau(\delta, w) \}$

$$p(-1|x) = \exp \{ c(\delta) \langle w_{-1}, x \rangle + h(\delta, x) + \tau(\delta, w_{-1}) \}$$

Они δ имеют сред. вид $\prod p(y_i, x_i, w_i)$

$$\sum \ln p(y_i, x_i, w_i) = \sum \ln p(y_i|x_i) + \sum \ln p(x_i) \rightarrow \max$$

не зависит от $w \Rightarrow$

$\Rightarrow$ нужно, остается найти $\sum \ln p(y_i|x_i)$ —
зависит на $p(y_i|x_i)$

и значение не зависит от параметра и
может быть взято из $p(x)$

$$\textcircled{4} \sum \ln \frac{p(y_i|x_i)}{p(+1|x_i) + p(-1|x_i)} \rightarrow \max$$

$$y=1: \frac{\exp \{ c(\delta) \langle w_1, x \rangle + \tau(\delta, w_1) \}}{\exp \{ c(\delta) \langle w_1, x \rangle + \tau(\delta, w_1) \} + \exp \{ c(\delta) \langle w_{-1}, x \rangle + \tau(\delta, w_{-1}) \}} =$$

$$= \frac{1}{1 + \exp \{ -y c(\delta) \langle w_1 - w_{-1}, x \rangle + \tau(\delta, w_{-1}) - \tau(\delta, w_1) \}} =$$

Добавим к x еще одну координату $(x, 1)$

$$= \frac{1}{1 + \exp \{ -y c(\delta) \langle w_1 - w_{-1}, x \rangle \}} \quad (*)$$

В случае $y = -1$ $\frac{p(-1|x)}{p(+1|x) + p(-1|x)} = \text{дугерн} = (*)$

$\sigma(t) = \frac{1}{1+e^{-t}}$ - сигмоидальная функция

$Q = \sum \ln \sigma(y_i < w, x_i >)$ $\rightarrow$ минимизация $w = w_1, w_2, \dots$
/ метод, найти экстремум //

$\sigma(t)$ присутствует во всех нейронных сетях.
Она гарантирует то, что $\sigma'(t) = \sigma(t)(1 - \sigma(t)) = \sigma(t)\sigma(-t)$

Градиентный метод:

$w_k = w_{k-1} - \eta \nabla Q$ // метод оценки w //

$$\nabla Q = \sum_{i=1}^n \sigma(-y_i < w, x_i >) y_i x_i$$

Метод стохастического градиента

1. Берем нач. приближение $w_1, \dots, w_d$
2. Вычисляем Q
3. Выбираем случайное $i = 1 \dots n$
($p_i = 1/n$) (т.е. равные)
4. Обновляем $w := w - \eta \sigma(-y_i < w, x_i >) y_i x_i$
5. Вычисляем $\varepsilon = \ln \sigma(-y_i < w, x_i >)$
6. Берем $Q = \frac{n-1}{n} Q + \varepsilon$ // посчитать Q //
7. Останавливаемся, если знаем w и Q стабильно, иначе до 3?

Проблемы, связанные со сходимостью метода;
(Когда возникают?)

1. Число параметров (w) м.б. $>$, т.е. не сопоставимо с размером обучающей выборки
2. x_i м.б. сильно коррелированы между собой
3. Некот. признаки м.б. имеют мало инф-ции
 $\Rightarrow$ коэф-ты w и b оцениваются плохо