

Отбор признаков в задаче обучения распознаванию образов при смешении решающего правила

Турков П.А. Красоткина О.В.

Тульский государственный университет

10-я Международная конференция
«Интеллектуализация обработки информации»

Крит 2014

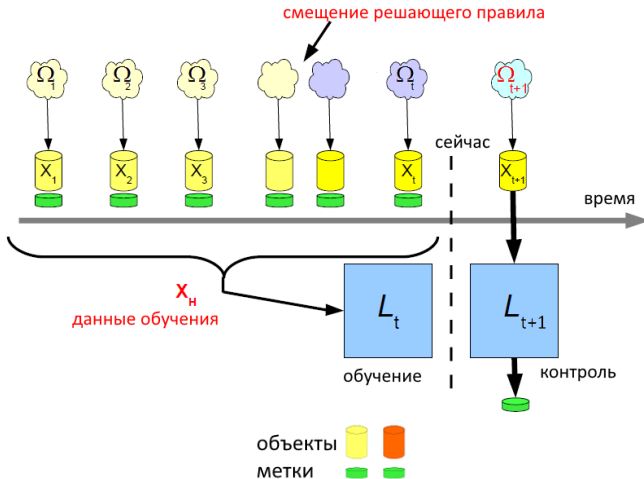
- Пусть каждый объект генеральной совокупности $\omega \in \Omega$ имеет скрытую характеристику $y \in \{1, -1\}$ и представлен точкой в линейном признаковом пространстве $\mathbf{x}(\omega) = (x^1(\omega), \dots, x^n(\omega)) \in \mathbb{R}^n$.
- Поточковый характер данных требует рассмотрения каждого объекта ω вместе с моментом времени t , когда он поступает. В результате обучающее множество приобретает вид

$$\{(\mathbf{X}_t, \mathbf{Y}_t, t)\}_{t=1}^T,$$

$(\mathbf{X}_t, \mathbf{Y}_t) = \{(\mathbf{x}_{k,t}, y_{k,t})\}_{k=1}^{N_t}$ - подмножество объектов, поступивших в момент времени t .

Обучение при смещении решающего правила


Постановка задачи [1]



Модель генеральной совокупности будем понимать как дискриминантную функцию следующего вида:

$$f(\mathbf{x}(\omega)) = \mathbf{w}^T \mathbf{x} > 0 \text{ если } y(\omega) = 1, \text{ и } < 0 \text{ если } y(\omega) = -1.$$

Апостериорные вероятности принадлежности объекта к одному из двух классов описываются как:



$$\varphi_1(\mathbf{x}|\mathbf{w}) = \begin{cases} 1, & \mathbf{w}^T \mathbf{x} > 1, \\ \exp[-c(1 - \mathbf{w}^T \mathbf{x})], & \mathbf{w}^T \mathbf{x} < 1, \end{cases}$$
$$\varphi_{-1}(\mathbf{x}|\mathbf{w}) = \begin{cases} 1, & \mathbf{w}^T \mathbf{x} < -1, \\ \exp[-c(1 + \mathbf{w}^T \mathbf{x})], & \mathbf{w}^T \mathbf{x} > -1. \end{cases}$$

Выберем совместное распределение параметров разделяющей гиперплоскости и их дисперсии в виде

$$\psi(w_i|r_i) = \frac{1}{\sqrt{2\pi r_i}} \exp(-w_i^2/r_i)$$

В качестве совместного распределения для дисперсий используем гамма-распределение:

$$\begin{aligned} \gamma(1/r_i|\alpha, 1/\beta) &= \frac{\beta^\alpha}{\Gamma(\alpha)} \cdot \left(\frac{1}{r_i}\right)^{\alpha-1} \cdot \exp\left(-\frac{\beta}{r_i}\right) \\ &\propto \left(\frac{1}{r_i}\right)^{\alpha-1} \cdot \exp\left(-\frac{\beta}{r_i}\right) \end{aligned}$$

- Смещение решающего правила приводит к необходимости понимания параметра \mathbf{w} как функции времени:

$$\mathbf{w}_t : T \rightarrow \mathbb{R}^n$$

- Апостериорная плотность распределения классов $y_{j,t} = \pm 1$:

$$\varphi(y_{t,j} | \mathbf{x}_{t,j}, \mathbf{w}_t) = \begin{cases} 1, & y_{t,j} \mathbf{w}_t^T \mathbf{x}_{t,j} > 1, \\ \exp[-c(1 - y_{t,j} \mathbf{w}_t^T \mathbf{x}_{t,j})], & y_{t,j} \mathbf{w}_t^T \mathbf{x}_{t,j} < 1, \end{cases}$$

- Для обучающего подмножества $\mathbf{X}_t, \mathbf{Y}_t$, полученного в момент времени t совместная плотность распределения:

$$\Phi(\mathbf{Y}_t | \mathbf{X}_t, \mathbf{w}_t) = \prod_{j=1}^{N_t} \varphi(y_{t,j} | \mathbf{x}_{t,j}, \mathbf{w}_t).$$

- Будем понимать зависящие от времени параметры решающего правила, как случайные стационарные марковские процессы

$$\mathbf{w}_t = q\mathbf{w}_{t-1} + \boldsymbol{\xi}_t, M(\boldsymbol{\xi}_t) = \mathbf{0}, M(\boldsymbol{\xi}_t\boldsymbol{\xi}_t^T) = d\mathbf{I}$$

где дисперсия d определяет динамику изменений в генеральной совокупности.

- Априорная плотность распределения скрытой последовательности параметров решающего правила:

$$\Upsilon(\mathbf{w}_t, t = 2, \dots, T) = \prod_{t=2}^T \left[\mathcal{N}(\mathbf{w}_t | \sqrt{1-d}\mathbf{w}_{t-1}, d\mathbf{I}) \right]$$

Апостериорная плотность совместного распределения последовательности параметров решающего правила и обучающей совокупности:

$$\begin{aligned} P((\mathbf{w}_t, \hat{\mathbf{r}})_{t=1}^T | (\mathbf{X}_t, \mathbf{Y}_t)_{t=1}^T) &\propto \\ &\propto \Upsilon(\mathbf{w}_t, t = \overline{2, T}) \prod_{t=1}^T \Phi(\mathbf{Y}_t | \mathbf{X}_t, \mathbf{w}_t) \\ &\prod_{i=1}^n \gamma(1/r_i | \alpha, 1/\beta) \cdot \prod_{t=1}^T \prod_{i=1}^n \psi(w_{t,i} | r_i) \end{aligned}$$

Оценка оптимальных значений параметров решающего правила:

$$(\hat{\mathbf{w}}_t, \hat{\mathbf{r}})_{t=1}^T = \arg \max_{\mathbf{w}_t, t=1, \dots, T} P((\mathbf{w}_t, \hat{\mathbf{r}})_{t=1}^T | (\mathbf{X}_t, \mathbf{Y}_t)_{t=1}^T)$$

$$\begin{aligned}
 & \left(\hat{\mathbf{w}}_t, \hat{\mathbf{r}}, \hat{\delta}_t | (\mathbf{x}_j, y_j), \alpha, \beta, j = 1, \dots, N_t, t = 1, \dots, T \right) = \\
 & \arg \max_{\mathbf{w}, \mathbf{r}} \left[- \sum_{t=1}^T \sum_{i=1}^n w_{t,i}^2 / r_i - C \sum_{t=1}^T \sum_{i=1}^{N_t} \delta_{t,j} - \right. \\
 & \quad - \frac{1}{2} \sum_{i=1}^n \log r_i - (\alpha - 1) \sum_{i=1}^n \log r_i - \sum_{i=1}^n \frac{\beta}{r_i} - \\
 & \quad \left. - \frac{1}{2d} \sum_{t=2}^T (\mathbf{w}_t - \sqrt{1-d} \mathbf{w}_{t-1})^T (\mathbf{w}_t - \sqrt{1-d} \mathbf{w}_{t-1}) \right] \quad (1)
 \end{aligned}$$

при ограничениях

$$\begin{aligned}
 1 - y_{t,j} \mathbf{w}_t^T \mathbf{x}_{t,j} &< \delta_{t,j}, \\
 \delta_{t,j} &> 0, j = 1, \dots, N_t, t = 1, \dots, T
 \end{aligned}$$

Для оценки параметров воспользуемся методом покоординатного спуска, тогда при зафиксированном \mathbf{r} получаем следующую задачу оптимизации

$$\sum_{t=1}^T \sum_{i=1}^n \frac{w_{t,i}^2}{r_i} + C \sum_{t=1}^T \sum_{j=1}^{N_t} \delta_{t,j} + \\ + \frac{1}{2d} \sum_{t=2}^T (\mathbf{w}_t - \sqrt{1-d} \mathbf{w}_{t-1})^T (\mathbf{w}_t - \sqrt{1-d} \mathbf{w}_{t-1}) \rightarrow \min_{\mathbf{w}_t, \delta_t, t=1, \dots, T}$$

с ограничениями

$$1 - y_{t,j} \mathbf{w}_t^T \mathbf{x}_{t,j} < \delta_{t,j}, \\ \delta_{t,j} > 0, j = 1, \dots, N_t, t = 1, \dots, T$$

Для оценивания значения гиперпараметра \mathbf{r} запишем критерий (1) в двойственной форме:

$$\begin{aligned} L(\mathbf{w}_t, \mathbf{r}, \boldsymbol{\delta}_t, \lambda_t, \mu_t) = & \\ & \sum_{t=1}^T \sum_{i=1}^n \frac{w_{t,i}^2}{r_i} + C \sum_{t=1}^T \sum_{j=1}^{N_t} \delta_{t,j} + \left(\alpha - \frac{1}{2}\right) \sum_{i=1}^n \log r_i + \sum_{i=1}^n \frac{\beta}{r_i} + \\ & + \frac{1}{2d} \sum_{t=2}^T (\mathbf{w}_t - \sqrt{1-d}\mathbf{w}_{t-1})^T (\mathbf{w}_t - \sqrt{1-d}\mathbf{w}_{t-1}) + \\ & + \sum_{t=1}^T \sum_{j=1}^{N_t} \lambda_{t,j} (1 - y_{t,j} \mathbf{w}_t^T \mathbf{x}_{t,j} - \delta_{t,j}) - \sum_{t=1}^T \sum_{j=1}^{N_t} \mu_{t,j} \delta_{t,j} \end{aligned}$$

Частные производные по целевым переменным

Откуда следует

$$r_i = \frac{\sum_{t=1}^T w_{t,i}^2 + \beta}{\alpha - 1/2}$$

- Каждый момент времени двумя нормальными двумерными распределениями с математическими ожиданиями 1 и -1, соответственно, генерируется по 25 объектов каждого класса
- К каждому объекту добавляется еще 98 нормально распределенных значений с математическим ожиданием 0 и дисперсией 1;
- С течением времени центры генерирующих распределений поворачиваются на 0.0314 радиана.

Искусственные данные

Результат

Номер признака	1	2	3	...	100
Дисперсия	47,6407	48,1681	0,7355	...	0,0052



Zliobaite I., Learning under Concept Drift: an Overview,
http://zliobaite.googlepages.com/Zliobaite_CDoverview.pdf

$$\frac{\partial L(\mathbf{w}, \mathbf{r}, \delta, \lambda, \mu)}{\partial w_{t,i}} = 2 \sum_{t=1}^T w_{t,i}/r_i + \frac{1}{d} \sum_{t=1}^T w_{t,i} - \frac{\sqrt{1-d}}{d} \sum_{t=1}^T w_{t-1,i} - \sum_{t=1}^T \sum_{j=1}^{N_t} \lambda_{t,j} y_{t,j} \mathbf{x}_{t,j,i}$$

$$\frac{\partial L(\mathbf{w}, \mathbf{r}, \delta, \lambda, \mu)}{\partial r_i} = - \sum_{t=1}^T w_{t,i}^2 / r_i^2 + \left(\alpha - \frac{1}{2}\right) \frac{1}{r_i} - \frac{\beta}{r_i^2}$$

$$\frac{\partial L(\mathbf{w}, \mathbf{r}, \delta, \lambda, \mu)}{\partial \delta_{t,j}} = \lambda_{t,j} + \mu_{t,j} - C$$

Вернуться