

# 概率分类法

## 一. 生成模型与判别模型 (Generative Model and Discriminative Model)

### ① 生成模型

设特征为  $x$ , 类别为  $y$ , 生成模型估计的是概率  $p(x, y)$ , 用到数据为  $(x_1, y_1), (x_2, y_2) \dots (x_N, y_N)$

### ② 判别模型

判别模型估计的是  $p(y|x)$

例子: 语言识别, 识别猫和狗

③ 典型的生成模型: Gaussian, Mixture of Gaussians, Hidden Markov Models, Markov Random Fields  
典型的判别模型: SVM, Neural Networks (看情况), Nearest Neighbor, Conditional Random Field.

## 二. 概率密度估计

### ① Gaussian (生成模型)

设特征为  $x$ , 类别  $y=1$  与  $y=-1$ 。设

$$p(x|y=1) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_1|}} \exp\left\{-\frac{1}{2}(x-\mu_1)^T \Sigma_1^{-1}(x-\mu_1)\right\}$$

$$p(x|y=-1) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_{-1}|}} \exp\left\{-\frac{1}{2}(x-\mu_{-1})^T \Sigma_{-1}^{-1}(x-\mu_{-1})\right\}$$

注: 一般来说, 构造生成模型时, 我们假设

$p(x|y) = p(x|y, \theta)$ , 其中  $\theta$  为待确定的参数, 通过训练样本确定。在这个例子中,  $\theta = \{\mu, \Sigma\}$   
估计方法: 最大似然 (Maximum Likelihood)  
设有训练样本:  $(x_1, y_1), (x_2, y_2) \dots (x_N, y_N)$ , 以估计  $\mu_1, \Sigma_1$  为例。

① 挑选  $x_1, x_2, \dots, x_M$  都属于  $y_i=1$  那一类 ( $i=1 \sim M$ )  
 则有:

$$p(x_i | y_i=1) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_1|}} \exp\left\{-\frac{1}{2}(x_i - \mu_1)^T \Sigma_1^{-1} (x_i - \mu_1)\right\}$$

( $i=1 \sim M$ )

② 求  $\mu_1, \Sigma_1$ , 使

$$E(\mu_1, \Sigma_1) = \sum_{i=1}^M \ln p(x_i | y_i=1)$$

最大。(最大似然估计)  
 在这一特例中,

$$E(\mu_1, \Sigma_1) = -\frac{M}{2} \ln |\Sigma_1| - \frac{1}{2} \sum_{i=1}^M (x_i - \mu_1)^T \Sigma_1^{-1} (x_i - \mu_1) + \text{常数}$$

因此:

$$\frac{\partial E}{\partial \mu_1} = 0 \Rightarrow \mu_1 = \frac{1}{M} \sum_{i=1}^M x_i$$

$$\frac{\partial E}{\partial (\Sigma^{-1})} = 0 \Rightarrow \frac{M}{2} \Sigma_1^T - \frac{1}{2} \sum_{i=1}^M (x_i - \mu_1)(x_i - \mu_1)^T = 0$$

$$\Rightarrow \Sigma_1 = \frac{1}{M} \sum_{i=1}^M (x_i - \mu_1)(x_i - \mu_1)^T$$

② Gaussian Mixture Model (混合高斯模型)

$$p(x) = \sum_{k=1}^K \pi_k N(x | \mu_k, \Sigma_k)$$

其中:

$$\left\{ \begin{array}{l} N(x | \mu_k, \Sigma_k) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_k|}} \exp\left\{-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right\} \\ \sum_{k=1}^K \pi_k = 1 \end{array} \right.$$

已知  $N$  个  $X$  值 ( $x_1, x_2, \dots, x_N$ ), 需要求最大似然

$$E(\{\pi_k, \mu_k, \Sigma_k\}_{k=1 \sim K})$$

$$= \sum_{i=1}^N \ln p(x_i)$$

$$= \sum_{i=1}^N \ln \left( \sum_{k=1}^K \pi_k \frac{1}{\sqrt{(2\pi)^d |\Sigma_k|}} \exp\left\{-\frac{1}{2}(x_i - \mu_k)^T \Sigma_k^{-1} (x_i - \mu_k)\right\}\right)$$

此式难以用求导法直接获得  $\{\pi_k, \mu_k, \Sigma_k\}_{k=1 \sim K}$  的解析表达式, 需要用近似优化算法求解。  
 最常用的是 EM 算法 (Expectation Maximization) 算法。(参见讲义 EM 算法), 描绘如下。

Step 1: 随机选取  $\{\pi_k, \mu_k, \Sigma_k\}_{k=1 \sim K}$ 。

Step 2: (E step)

$$\text{求 } \cancel{z_{nk}}^{y_{nk}} = \frac{\pi_k N(x_n | \mu_k, \Sigma_k)}{\sum_{k=1}^K \pi_k N(x_n | \mu_k, \Sigma_k)}$$

Step 3: (M Step)

$$\left\{ \begin{aligned} \mu_k^{\text{new}} &= \frac{1}{N_k} \sum_{n=1}^N \cancel{z_{nk}}^{y_{nk}} x_n \\ \Sigma_k^{\text{new}} &= \frac{1}{N_k} \sum_{n=1}^N \cancel{z_{nk}}^{y_{nk}} (x_n - \mu_k^{\text{new}})(x_n - \mu_k^{\text{new}})^T \\ \pi_k^{\text{new}} &= \frac{N_k}{N} \end{aligned} \right.$$

其中  $N_k = \sum_{n=1}^N \cancel{z_{nk}}^{y_{nk}}$

Step 4: 计算  $F(\{\pi_k^{\text{new}}, \mu_k^{\text{new}}, \Sigma_k^{\text{new}}\})$

$E(\{\pi_k, \mu_k, \Sigma_k\}_{k=1 \sim K})$  比较, 重复 Step 2, Step 3 直至  $E$  收敛。

③ 朴素贝叶斯分类器 (Naive Bayesian Classifier)

Input: ① a document  $d$

② a fixed set of classes

$$C = \{c_1, c_2, \dots, c_N\}$$

output: a predicted class  $d \in c_j$  ( $j=1 \sim N$ )

Training set:

$$(d_1, c_1) \quad (d_2, c_2) \quad \dots \quad (d_m, c_m)$$

$$P(c|d) = \frac{P(d|c)P(c)}{P(d)}$$

$$C_{\text{map}} = \arg \max_{c \in C} P(d|c)P(c)$$

$$= \arg \max_{c \in C} P(w_1, w_2, \dots, w_n|c)P(c)$$

朴素贝叶斯假设, 特征之间相互独立! 即

$$\begin{aligned} P(w_1, w_2, \dots, w_n|c) &= P(w_1|c)P(w_2|c) \dots P(w_n|c) \\ &= \prod_{i=1}^n P(w_i|c) \end{aligned}$$

$$C_{\text{map}} = \arg \max_{c_j \in C} P(c_j) \prod_{i=\text{position}}^n P(x_i|c_j)$$

$$P(C_j) = \frac{\text{Num of Documents belonging to } C_j}{\text{Num of all documents}}$$

$$P(w_i|C_j) = \frac{\text{count}(w_i, C_j)}{\sum_{w \in V} \text{count}(w, C_j)}$$

改进

$$P(w_i|C) = \frac{\text{count}(w_i, C) + 1}{\sum_{w \in V} \text{count}(w, C) + |V|}$$