

机器学习：监督学习(Supervised Learning)之分类(Perceptron, Logistic, Softmax, Bayes)

Copyright: Jingmin Wei, Automation - Pattern Recognition and Intelligent System, School of Artificial Intelligence and Automation, Huazhong University of Science and Technology

Copyright: Jingmin Wei, Computer Science - Artificial Intelligence, Department of Computer Science, Viterbi School of Engineering, University of Southern California

机器学习：监督学习(Supervised Learning)之分类(Perceptron, Logistic, Softmax, Bayes)

1. 分类问题
2. 感知机(*Perceptron*)
3. *Fisher* 线性判别分析(*LDA*)与有监督降维
 - 3.1. 矩阵的特征值与特征向量(*Eigvalue&Eigvector*)
 - 3.1.1 矩阵变换
 - 3.2. 广义特征值与广义特征向量
 - 3.3. 拉格朗日乘数法
 - 3.4. 瑞利商(*Rayleigh Quotient*)
 - 3.5. 广义瑞利商
 - 3.6. *LDA* 的二分类问题求解
 - 3.7. 算法过程
 - 3.8. 多分类 *LDA* 与有监督降维算法
4. 逻辑斯蒂回归(*Logistic Regression*)
 - 4.1. *Sigmoid* 函数的推导
 - 4.2. 交叉熵损失的推导(最大似然估计)
 - 4.3. 交叉熵和均方误差的随机梯度下降优化
 - 4.4. *Logistic* 回归中的分治法
5. *Softmax* 回归
 - 5.1. 交叉熵损失的推导(最大似然估计)
 - 5.2. 交叉熵的随机梯度下降优化
6. 贝叶斯决策(*Bayes*)
 - 6.1. 朴素贝叶斯分类器原理
 - 6.2. 最大化后验概率
 - 6.3. 新冠患者死亡率预测
 - 6.4. 高斯贝叶斯分类模型

1. 分类问题

结果输出为离散化的类别，而不是连续的值。

例：预测一个用户是否点击特定商品，是否会购买给定的品类，评论是正面还是负面等。

模型：输入 x ，标记结果： $y = \{0, 1\}$ 。

预测输出： $0 \leq h(x) \leq 1$

$$\begin{aligned} \text{if } h(x_i) > 0.5, \quad y_i &= 1 \\ \text{if } h(x_i) \leq 0.5, \quad y_i &= 0 \end{aligned}$$

2. 感知机(*Perceptron*)

模型： $h(x) = g(w^T x + b)$ 。 $g(x)$ 为 *sign* 符号函数。

$$g(x) = \begin{cases} +1, & x > 0 \\ -1, & x < 0 \end{cases}$$

感知机的目标是优化如下损失函数：

$$\min_{w,b} \sum_{i=1}^m -y_i(w^T x_i + b)$$

对它求梯度，之后可以用梯度下降方法更新：

```
while(until 所有样本正确分类 ∨ 迭代次数到  $n$ ):  
    if  $\text{sign}(w^T x_i + b) \neq y_i$   
        then  $w_{t+1} \leftarrow w_t + y_i x_i$   
    else : continue
```

3. Fisher 线性判别分析(LDA)与有监督降维

LDA 的优化目标是求广义瑞利商的极大值。

3.1. 矩阵的特征值与特征向量(Eigvalue&Eigvector)

在[Lesson 1 解方程](#)一章中，我们已经了解了基本的矩阵特征值和特征向量求解，这里给出更详细的过程。对于 n 阶矩阵 A ，其特征向量 x 表示，用 x 对 A 做线性变换后的向量，还是和 A 在同一条直线上。变化的比例是特征值 λ ，表示新向量的方向和长度都可能会改变。数学上表示为，存在一个数 λ 和非 0 向量 x ，使得：

$$\begin{aligned} Ax &= \lambda x \\ \Leftrightarrow (A - \lambda I)x &= 0 \end{aligned}$$

则称 λ 为矩阵 A 的特征值， x 为对应的特征向量。

根据[Lesson 3 优化方法基础](#)的基本概念部分，上面齐次方程有解的条件是方程的系数矩阵的行列式必须为 0 (或者系数矩阵不可逆，即其秩 $r(A - \lambda I) < n$)。

$$|A - \lambda I| = 0$$

先求特征值： $|A - \lambda I| = 0$ ，代回齐次方程求对应的特征向量，属于不同特征值的特征向量线性无关。[Lesson 7 信息论与决策树](#)会讲矩阵的特征值分解和奇异值分解算法。

对角矩阵，上三角矩阵，下三角矩阵的特征值为其主对角线元素。

n_i ：代数重数，对应于特征多项式 $(\lambda - \lambda_1)^{n_1} \cdots (\lambda - \lambda_i)^{n_i} = 0$ 的 λ_i 的阶数。

m_i ：几何重数，对应于 $(A - \lambda_i I)x = 0$ 的其次方程的线性无关的解的个数。

3.1.1 矩阵变换

****相似变换：**对于 A, B 和可逆矩阵 P ，满足：

$$P^{-1}AP = B$$

$A \sim B$ ，这一变换不改变矩阵的特征值，且 $r(A) = r(B), |A| = |B|$ 。

这一性质可用来求特征值，将其相似化为对角阵或三角阵，特征值即为主对角线上的元素。

矩阵相似对角化：

$$P^{-1}AP = \Lambda$$

前提是 P 可逆，即 A 有 n 个线性无关的特征向量。

****正交变换：**对于正交矩阵 P ($P^{-1} = P^T$, 即 $P^T P = I$)，满足：

$$P^T AP = \Lambda$$

通过正交变换可以构建对角阵。

实现时需要同时对一个特征值的不同特征向量正交化，然后将所有正交化后的特征向量标准化即可。

3.2. 广义特征值与广义特征向量

广义特征值定义于矩阵 A, B 之上，对于方阵 A, B 存在一个数 λ 和非 0 向量 x ，使得：

$$Ax = \lambda Bx$$

称 λ 为广义特征值， x 为对应的广义特征向量。类似有：

$$|A - \lambda B| = 0$$

如果矩阵 B 可逆，上述问题也可以转为基本的特征值问题：

$$B^{-1}Ax = \lambda x$$

广义特征值在线性判别分析，以及[Lesson 7 信息论与决策树](#)的流形学习都会用到。

3.3. 拉格朗日乘数法

拉格朗日乘数法被广泛用于求解带约束条件的最优化问题，在[Lesson 6 支撑向量机](#)求解中有广泛应用。以一阶线性的优化函数为例，对于优化问题：

$$\begin{cases} \min_x f(x) \\ s.t. \quad h_i(x) = 0 \quad i = 1, \dots, p \end{cases}$$

可以构造拉格朗日乘子函数：

$$\mathcal{L}(x, \lambda) = f(x) + \sum_{i=1}^p \lambda_i h_i(x)$$

对优化变量 $x, y, \dots$ ，乘子变量 λ 分别求偏导并令其为 0，可以得到候选极值点。再求黑塞矩阵，判别它是否正定，判断该候选极值点是否是极值点。

3.4. 瑞利商(Rayleigh Quotient)

瑞利商部分，在 LDA, PCA, LLE, SNE, LE 等降维算法中都需要应用它的一些结论和推导过程，所以理解瑞利商及其性质，对于降维算法的学习非常重要(更多降维算法在[Lesson 7 信息论与决策树](#))。

方阵 A 和非 0 向量 x 的瑞利商定义为如下比值：

$$R(A, x) = \frac{x^T A x}{x^T x}$$

对于任意的非 0 实数 k ，有 $R(A, kx) = R(A, x)$ ，表明向量缩放后瑞利商不变，存在冗余。假设 $\lambda_{\min}, \lambda_{\max}$ 是矩阵 A 的最小和最大特征值，则有：

$$\lambda_{\min} \leq R(A, x) \leq \lambda_{\max}$$

当 x 分别为最小和最大特征值对应的特征向量时， $R(A, x)$ 取这两个值。

关注瑞利商的极大值求解的优化问题。这里首先和[Lesson 6 支撑向量机](#) $primal SVM$ 的思路一样，我们添加约束来保证解的唯一性，即限定分母为 1 (x 为单位向量， $x^T x = 1$)，瑞利商变为： $R(A, x) = x^T A x$ 。

使用拉格朗日乘子法，构造拉格朗日乘子函数：

$$L(x, \lambda) = x^T A x + \lambda(x^T x - 1)$$

对 x 求梯度并令梯度为 0： $2Ax + 2\lambda x = 0$ ，即 $Ax = -\lambda x$ ，这表示瑞利商的所有极值在矩阵 A 的特征值和特征向量处取得。假设 λ_i, x_i 带入瑞利商：

$$R(A, x_i) = \frac{x_i^T (Ax_i)}{x_i^T x_i} = \frac{x_i^T (\lambda_i x_i)}{x_i^T x_i} = \lambda_i$$

因此，在最大的特征值处，瑞利商有最大值，在最小的特征值处，瑞利商有最小值。[Lesson 8 无监督学习\(聚类、信号分解、流形降维\)](#)的主成分分析用到了这一结论。

3.5. 广义瑞利商

对瑞利商推广得到广义瑞利商：

$$R(A, B, x) = \frac{x^T A x}{x^T B x}$$

广义瑞利商也存在冗余， $R(A, B, kx) = R(A, B, x)$ 。如果对矩阵 B 做楚列斯基分解，即 $B = CC^T$ ，并令 $x = (C^T)^{-1}y$ ，可将广义瑞利商转为瑞利商形式：

$$\frac{x^T A x}{x^T B x} = \frac{((C^T)^{-1}y)^T A ((C^T)^{-1}y)}{((C^T)^{-1}y)^T B ((C^T)^{-1}y)} = \frac{y^T C^{-1} A (C^T)^{-1} y}{y^T y}$$

根据瑞利商的结论，广义瑞利商的最大值为矩阵 $C^{-1}A(C^T)^{-1}$ 的最大特征值，最小值为矩阵 $C^{-1}A(C^T)^{-1}$ 的最小特征值。也可以通过广义特征值直接求广义瑞利商的极大值，同样添加约束： $x^T Bx = 1$ ，构造拉格朗日乘子函数：

$$R(A, B, x) = x^T A x + \lambda(x^T B x - 1)$$

对 x 求梯度并令梯度为 0： $2Ax + 2\lambda Bx = 0$ ，即 $Ax = \lambda Bx$ ，这是广义特征值问题。如果 B 可逆，则 $B^{-1}Ax = \lambda x$ 。这表示瑞利商的所有极值在矩阵 $B^{-1}A$ 的特征值和特征向量处取得。假设 λ_i, x_i 带入瑞利商：

$$R(A, B, x_i) = \frac{x_i^T (Ax_i)}{x_i^T B x_i} = \frac{x_i^T (\lambda_i B x_i)}{x_i^T B x_i} = \lambda_i$$

因此，在最大的广义特征值处，瑞利商有最大值，在最小的广义特征值处，瑞利商有最小值。最大化广义瑞利商也是线性判别分析的优化目标。

3.6. LDA 的二分类问题求解

菲谢尔线性判别算法的核心思想是：设法将样本点投影到一条直线 w 上，使得同类的样本投影点尽可能接近，异类的样本投影点尽可能远离。对于新加入的样本，先投影到这条直线上，再根据投影点的位置来确定新样本的类别。

给定数据集 $D = \{(x_i, y_i)\}_{i=1}^m, y_i \in \{0, 1\}$ 。令 X_i, μ_i, Σ_i 分别表示第 $i \in \{0, 1\}$ 类示例的集合，均值向量，协方差矩阵。若将数据投影到直线 w 上，则两类样本的中心在直线的投影 $E[w^T x | y = y_i]$ 分别为 $w^T \mu_0, w^T \mu_1$ ，由此推导出，两类样本的协方差 $E[(w^T x - E[w^T x | y = y_i])^2]$ 分别为 $w^T \Sigma_0 w, w^T \Sigma_1 w$ 。

欲使同类样本投影点尽可能接近，可让同类样本投影点的协方差，即 $w^T \Sigma_0 w + w^T \Sigma_1 w$ 尽可能小。欲使异类样本投影店尽可能远离，可让类中心距离，即 $\|w^T \mu_0 - w^T \mu_1\|_2^2$ 尽可能大，可得优化函数为：

$$\begin{aligned} J(w) &= \frac{\|w^T \mu_0 - w^T \mu_1\|_2^2}{w^T \Sigma_0 w + w^T \Sigma_1 w} \\ &= \frac{w^T (\mu_0 - \mu_1)(\mu_0 - \mu_1)^T w}{w^T (\Sigma_0 + \Sigma_1) w} \\ w^* &= \arg \max_w J(w) \end{aligned}$$

可以定义类内散度矩阵(*within - class scatter matrix*):

$$S_w = \Sigma_0 + \Sigma_1 = \sum_{x \in X_0} (x - \mu_0)(x - \mu_0)^T + \sum_{x \in X_1} (x - \mu_1)(x - \mu_1)^T$$

以及定义类间散度矩阵(*between - class scatter matrix*):

$$S_b = (\mu_0 - \mu_1)(\mu_0 - \mu_1)^T$$

则 $J(w)$ 可以写为如下广义瑞利商形式：

$$\begin{aligned} J(w) &= \frac{w^T S_b w}{w^T S_w w} \\ w^* &= \arg \max_w J(w) \end{aligned}$$

因此，LDA 线性判别分析的目标就是最大化这个广义瑞利商。上面我们说过，可以根据冗余添加约束条件，变号转为求最小值的最优化问题：

$$\begin{cases} \min_w & -w^T S_b w \\ \text{s.t.} & w^T S_w w = 1 \end{cases}$$

并使用拉格朗日乘子法，对 x 求梯度并令梯度为 0：

$$\begin{aligned} L(w, \lambda) &= -w^T S_b w + \lambda(w^T S_w w - 1) \\ 2S_b w + 2\lambda S_w w &= 0 \end{aligned}$$

等价于 $S_b w = \lambda S_w w$ 。注意到 $S_b w$ 的方向恒为 $\mu_0 - \mu_1$ ，只关注投影的方向，令 $S_b w = \lambda(\mu_0 - \mu_1)$ ，可得：

$$w^* = S_w^{-1}(\mu_0 - \mu_1)$$

对于 S_w^{-1} 的求解，考虑数值解的稳定性，实际中通常是先对 S_w 做奇异值分解($S_w = U \Sigma V^T$)， Σ 是一个实对角矩阵，其对角线上的元素是 S_w 的奇异值，然后再由 $S_w^{-1} = V \Sigma^{-1} U^T$ 得到 S_w^{-1} 。

3.7. 算法过程

首先获取带标签的训练集，并计算两类样本的 μ_0, μ_1 和 Σ_0, Σ_1 。

计算类内散度矩阵：

$$S_w = \Sigma_0 + \Sigma_1$$

通过奇异值分解计算 S_w 的逆，然后计算最佳投影向量：

$$w^* = S_w^{-1}(\mu_0 - \mu_1)$$

找到投影向量后，对测试集的任意样本 x ，定义 s ：

$$s = w^{*T}x = (S_w^{-1}(\mu_0 - \mu_1))^T x$$

设判别门限 s' 为：

$$s' = \frac{w^{*T}(\mu_0 + \mu_1)}{2}$$

计算判别门限后，对测试集的任意样本 x 分类：

$$\begin{cases} y = 1, & \text{if } s = w^{*T}x > s' \\ y = 0, & \text{if } s = w^{*T}x < s' \end{cases}$$

3.8. 多分类 LDA 与有监督降维算法

假设存在 N 个类别，且第 i 类的样本数为 m_i ，定义全局散度矩阵：

$$S_t = S_b + S_w = \sum_{i=1}^m (x_i - \mu)(x_i - \mu)^T$$

其中 μ 是所有样本的均值向量，将 S_w 重定义为每个类别的散度矩阵之和：

$$S_w = \sum_{i=1}^N S_{w_i}$$

其中， $S_{w_i} = \sum_{x \in X_i} (x - \mu_0)(x - \mu_0)^T$ 。因此可以得到：

$$S_b = S_t - S_w = \sum_{i=1}^N m_i (\mu_i - \mu)(\mu_i - \mu)^T$$

显然多分类有多种实现方法，使用 S_b, S_w, S_t 中的任意两个即可，常见的一种为：

$$\max_W \frac{\text{tr}(W^T S_b W)}{\text{tr}(W^T S_w W)}$$

其中 $W \in \mathbb{R}^{d \times (N-1)}$ ， $\text{tr}(\cdot)$ 表示矩阵的迹。同样根据瑞利商最大的推导，上式可以通过如下的广义特征值求解：

$$S_b W = \lambda S_w W$$

W 的闭式解为 $S_w^{-1} S_b$ 的 d' 个最大非零广义特征值对应的特征向量所组成的矩阵， $d' \leq N - 1$ 。

降维：在上面的二分类问题中， w^*x 实际上是将一个二维的样本点投影到了一条一维的直线上，因此 LDA 可以被用来线性降维。

对于多分类 LDA 也是同样的思路。若将 W 看为投影矩阵，则多分类 LDA 通过 $W^T X$ 将样本从 d 维空间投影到了 d' 维空间， d' 通常远小于样本本有的特征列数 d 。

因此，可以通过这个投影将样本从 $d \rightarrow d'$ ，从而减小样本点的维数。

投影过程中用到了类别信息，因此这也是一种典型的监督降维技术。

4. 逻辑斯蒂回归(Logistic Regression)

其与感知机，线性回归的区别在于，激活函数不同。感知机是符号函数 $\text{sign}(w^T x + b)$ ，线性回归是线性映射 $w^T x + b$ ，而逻辑回归模型如下：

前向模型： $h(x) = \sigma(w^T x + b)$ ：

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \quad \sigma(x) \in (0, 1)$$
$$\sigma'(x) = \sigma(x)(1 - \sigma(x))$$

最终分类器的分类结果为： $y_{\text{pred}} = \text{sign}(h(x) - 0.5)$ 。

其中 $\sigma(x)$ 为 Sigmoid 函数， sign 为符号函数。

$h(x)$ 表示概率的信息： $h(x) = p(y = 1|x; w; b)$ ，且满足 $p(y = 1|x; w; b) + p(y = 0|x; w; b) = 1$ ，即随机变量 y 服从 $p = 0.5$ 伯努利分布(0 - 1 分布)。

4.1. Sigmoid 函数的推导

为什么加上 Sigmoid 函数后，模型就能从回归问题变为分类问题？这和 Sigmoid 本身的推导过程有关。

首先构造分类规则，使用 $\ln$ 可以简化计算：下式大于 0 则分为第一类，小于 0 则分为第二类：

$$\ln \frac{p(y = +1|x)}{p(y = -1|x)} > 0$$

还是通过贝叶斯规则来定义 $p(y|x)$ ：

$$p(y|x) = \frac{p(x|y)p(y)}{p(x)}$$

其中， $p(y)$ 服从伯努利分布， $p(x|y)$ 定义为任何我们想要的分布，比如说正态分布。

对于 $y \sim \text{Bern}(\pi)$ 和 $x|y \sim N(\mu_y, \Sigma)$ ， y 被分类为 1 如果：

$$\ln \frac{p(y = +1|x)}{p(y = -1|x)} > 0$$

以二维正态分布为例，则可以将式子转乘法为加法：

$$\ln \frac{p(x|y = +1)p(y = +1)}{p(x|y = -1)p(y = -1)}$$
$$= \ln \frac{\pi_1}{\pi_0} - \frac{1}{2}(\mu_1 + \mu_0)^T \Sigma^{-1}(\mu_1 - \mu_0) + x^T \Sigma^{-1}(\mu_1 - \mu_0)$$

令 $\ln \frac{\pi_1}{\pi_0} - \frac{1}{2}(\mu_1 + \mu_0)^T \Sigma^{-1}(\mu_1 - \mu_0)$ 表示偏置 b ， $\Sigma^{-1}(\mu_1 - \mu_0)$ 表示权重 w 。

则分类面为如下函数：

$$L = \ln \frac{p(y = +1|x)}{p(y = -1|x)} = w^T x + b$$

$L > 0 \rightarrow y = +1$; $L < 0 \rightarrow y = -1$ ，注意 $L = 0$ 能分给任何一类。

根据伯努利分布规则，有 $p(y = -1|x) = 1 - p(y = +1|x)$ 。又因为 $\ln \frac{p(y=+1|x)}{p(y=-1|x)} = w^T x + b$ ，则可通过如下求解 $p(y = +1|x)$ ，并推导出 Sigmoid 函数：

$$p(y = +1|x) = \frac{\exp\{wx^T + b\}}{1 + \exp\{wx^T + b\}} = \sigma(wx^T + b)$$

4.2. 交叉熵损失的推导(最大似然估计)

在[Lesson 7 信息论与决策树](#)我们将会对交叉熵有更深入的了解。首先定义模型训练的标签为：

$$y_i \in R \Rightarrow y_i \in \{0, 1\}$$

Logistic 回归拟合的就是伯努利分布，即 $P(y_i = 1) = p, P(y_i = 0) = 1 - p$ 。

设 y_i 满足伯努利分布, μ_i 满足高斯分布。

根据伯努利分布, 假设有 n 个样本, 每个样本属于每个类的概率可以写成:

$$p(y_i|x_i, w) = \sigma(x_i)^{y_i}(1 - \sigma(x_i))^{1-y_i}$$

$$\text{其中, } \sigma(x) = \frac{1}{1 + \exp(-w^T x + b)}$$

由于样本独立同分布, 根据[Lesson 3.5 参数估计\(MLE, MAP, Bayes, KNN, Parzen, GMM, EM算法\)](#)似然函数参数估计, 训练集的似然函数为:

$$\begin{aligned} p(y|X, w) &= \text{Ber}(y|\mu(X, w)) \\ &= \prod_{i=1}^n \text{Ber}(y_i|\sigma(w^T x_i + b)) \\ &= \prod_{i=1}^n (\sigma(x_i)^{y_i}(1 - \sigma(x_i))^{1-y_i}) \end{aligned}$$

而逻辑回归算法的目标就是最大化这个似然函数, 取对数得到:

$$\begin{aligned} L(w) &\triangleq \ln p(y|X, w) \\ &= \sum_{i=1}^n [y_i \ln \sigma(x_i) + (1 - y_i) \ln(1 - \sigma(x_i))] \\ &= \sum_{i=1}^n [\ln(\mu_i)^{C(y_i=1)}(1 - \mu_i^{C(y_i=0)})] \end{aligned}$$

其中, $\mu_i \triangleq \sigma(x_i)$ 。定义随机变量 y 和 μ 之间的关系为:

$$C(y_i = 1) = \begin{cases} 1, & y_i = 1 \\ 0, & \mu_i = 0 \end{cases}$$

$$C(y_i = 0) = \begin{cases} 1, & y_i = 0 \\ 0, & \mu_i = 1 \end{cases}$$

因此, 原式 =

$$\begin{aligned} &= \max \sum_{i=1}^n [y_i \ln \mu_i + (1 - y_i) \ln(1 - \mu_i)] \\ &= \min \sum_{i=1}^n -[y_i \ln \mu_i + (1 - y_i) \ln(1 - \mu_i)] \end{aligned}$$

其中, $-\sum_{i=1}^n [y_i \ln \mu_i + (1 - y_i) \ln(1 - \mu_i)]$ 也就是交叉熵损失 $J(w)$, 衡量的是变量 y_i 和 μ_i (即 $\sigma(x_i)$) 之间的差异, 如果值越大, 说明两个概率分布的差异越大。越小, 说明两个概率分布的差异越小, 即样本集的预测结果和标签之间的误差越小。当两个的概率分布相等时($y_{pred} = y_{label}$), 交叉熵有极小值, 而 *Logistic* 回归的目标函数, 就是求这个损失的极小值。

在[Lesson 7 信息论与决策树](#)中会详细讨论这个部分。

我们对标签 y_i 从 $0, 1$ 推广到 $-1, 1$, 则交叉熵损失可以表示如下:

$$y_i \in \{0, 1\} \rightarrow \tilde{y}_i \in \{-1, 1\}$$

$$\therefore -\min \sum_{i=1}^n [y_i \ln \mu_i + (1 - y_i) \ln(1 - \mu_i)] = \min \sum_{i=1}^n \ln(1 + \exp(-\tilde{y}_i w^T x_i))$$

因此:

$$\begin{aligned} J(w) &\triangleq \sum_{i=1}^n \ln(1 + \exp(-\tilde{y}_i w^T x_i)) \\ \nabla J(w) &= X^T(\mu - \tilde{y}) \\ \nabla^2 J(w) &= X^T \text{diag}(\mu_i(1 - \mu_i)) \end{aligned}$$

这样, 我们就把最大似然估计转为了解最小化交叉熵损失的优化问题。之后就可以用常规的随机梯度下降方法求解。

4.3. 交叉熵和均方误差的随机梯度下降优化

注意：根据[Lesson 9 凸优化](#)内容，交叉熵误差可以确保最优优化问题为凸优化问题，找到全局最优解；而均方误差(欧氏距离)不一定是凸函数，可能存在多个局部极小值，寻找全局最优解存在困难。

Logistic 回归的目标是优化如下交叉熵损失函数(损失表达公式的推导在前文)。

$$L = \min_{w,b} \sum_{i=1}^n \ln(1 + \frac{1}{-y_i w^T x_i}) = \min_{w,b} \sum_{i=1}^n \ln(1 + \exp(-y_i w^T x_i))$$

对 w 求梯度：

$$\nabla L(w) = \frac{\partial \sigma(w, x)}{\partial w_i} = \frac{\exp(y_i w^T x_i)}{1 + \exp(y_i w^T x_i)} (-y_i x_i) = \sigma(-y_i w^T x_i) (-y_i x_i)$$

则随机梯度下降算法过程如下：

$$\begin{aligned} & \text{while}(\text{until } \nabla L(w) = 0 \vee \text{迭代次数到 } n) : \\ & \quad \text{for batch in dataloader(shuffle)} : \\ & \quad \quad \nabla L(w) = \frac{1}{\text{batch_size}} \sum_{i=1}^{\text{batch_size}} \sigma(-y_i w_i^T x_i) (-y_i x_i) \\ & \quad \quad w_{t+1} = w_t - \eta \cdot \nabla L(w) \end{aligned}$$

如果是均方误差，其目标是优化如下损失函数：

$$L = \min_{w,b} \sum_{i=1}^n \left(\frac{1}{1 + e^{-y_i w^T x_i}} - y_i \right)^2$$

对 w 求梯度：

$$\nabla L(w) = \frac{\partial \sigma(w, x)}{\partial w_i} = 2(\sigma(y_i w^T x_i) - 1) \sigma(y_i w^T x_i) (1 - \sigma(y_i w^T x_i)) y_i x_i$$

则随机梯度下降算法过程如下：

$$\begin{aligned} & \text{while}(\text{until } \nabla L(w) = 0 \vee \text{迭代次数到 } n) : \\ & \quad \text{for batch in dataloader(shuffle)} : \\ & \quad \quad \nabla L(w) = \frac{2}{\text{batch_size}} \sum_{i=1}^{\text{batch_size}} (\sigma(y_i w_i^T x_i) - 1) \sigma(y_i w_i^T x_i) (1 - \sigma(y_i w_i^T x_i)) y_i x_i \\ & \quad \quad w_{t+1} = w_t - \eta \cdot \nabla L(w) \end{aligned}$$

4.4. *Logistic* 回归中的分治法

这里主要是用了[Lesson 3 优化方法基础](#)介绍的分治法中的坐标下降法的思想。

给定了 l 个训练样本 $(x_i, y_i), i = 1, \dots, l$ ，其中 $x_i \in \mathbb{R}^n$ 为特征向量， $y_i = \pm 1$ 为标签。根据[Lesson 4 监督学习之回归\(Linear, NonLinear, Lasso, Ridge, Generalization\)](#)和[Lesson 6 支撑向量机](#)的内容，类比定义带 L_2 正则化的 *Logistic* 的拉格朗日对偶问题为：

$$\min_{\alpha} D_{LR}(\alpha) = \frac{1}{2} \alpha^T Q \alpha + \sum_{i: \alpha_i > 0} \alpha_i \ln \alpha_i + \sum_{i: \alpha_i < C} (C - \alpha_i) \ln(C - \alpha_i)$$

其中 C 为惩罚因子，矩阵 Q 定义为：

$$Q_{ij} = y_i y_j x_i^T x_j$$

如果定义 $0 \log 0 = 0$ ，它与该极限是一致的： $\lim_{x \rightarrow 0^+} x \ln x = 0$ 。

上式可以简化为：

$$\begin{aligned} \min_{\alpha} D_{LR}(\alpha) &= \frac{1}{2} \alpha^T Q \alpha + \sum_{i=1}^l \alpha_i \ln \alpha_i + (C - \alpha_i) \ln(C - \alpha_i) \\ 0 &\leq \alpha_i \leq C, i = 1, \dots, l \end{aligned}$$

目标函数中带有对数函数可以采用坐标下降法求解，即每次只针对一个分量进行优化，而让其他的分量固定不定，算法依次优化每一个变量，直至收敛。与[Lesson 3 优化方法基础](#)中的其他最优化方法相比，坐标下降法有更快的迭代速度，更适合大规模问题的求解。

在用坐标下降法求解时，一个技巧是，不直接优化一个分量，而是优化该分量的增量，这和 *ResNet* 中的残差思想其实是一致的。假设本次迭代时要优化 α_i ，其他的 $\alpha_j, j \neq i$ 固定不动。假设本次迭代后的 α_i 的值为 $\alpha_i + z$ ，即 $\alpha_{i+1} = \alpha_i + z$ ，则上式中的目标函数和不等式约束可以写成 z 的优化函数：

$$\begin{aligned} \min_z g(z) &= (c_1 + z) \ln(c_1 + z) + (c_2 - z) \ln(c_2 - z) + \frac{a}{2} z^2 + bz \\ &- c_1 \leq z \leq c_2 \end{aligned}$$

其中所有常数定义为：

$$c_1 = \alpha_i, c_2 = C - \alpha_i, a = Q_{ii}, b = (Q\alpha)_i$$

因为目标函数有对数函数，该优化函数是一个超越函数，无法给出极值的解析解。因此，采用[Lesson 3 优化方法基础](#)的牛顿法解决上面问题，迭代公式为：

```

init  $z_0, k = 0$ 
while  $k < N$  :
    if  $\|g'(x_k)\| < \text{eps}$  then
        break
    end if
     $d_k = -\frac{g'(z_k)}{g''(z_k)}$ 
     $z_{k+1} = z_k + d_k$ 
     $k = k + 1$ 
end while

```

梯度为一阶导数，黑塞矩阵为二阶导数，在上面的算法中，它们分别为：

$$\begin{aligned} g'(z) &= az + b + \ln \frac{c_1 + z}{c_2 - z} \\ g''(z) &= a + \frac{c_1 + c_2}{(c_1 + z)(c_2 - z)} \end{aligned}$$

为了保证牛顿法收敛，还需要利用[Lesson 3 优化方法基础](#)讲述的直线搜索技术，检查迭代之后的函数值是否充分下降。

5. Softmax 回归

Softmax 回归是 *Logistic* 回归的拓展，实际上就是把逻辑回归的思想扩展到多分类问题上。它是一个多分类的算法，也常用来作为深度神经网络的最后一层分类层。

假设有 l 个训练样本 (x_i, y_i) ，其中 x_i 为 n 维特征向量， y_i 为类别标签，其取值为 $1 - k$ 之间的整数。*Softmax* 回归用下式来求样本 x 属于每个类别的概率：

$$h_{\theta}(x) = \frac{1}{\sum_{i=1}^k e^{\theta_i^T x}} \begin{pmatrix} e^{\theta_1^T x} \\ \vdots \\ e^{\theta_k^T x} \end{pmatrix}$$

其中， k 个向量 θ_i 为模型要学习的参数。简化概率表示，令 $S_i = \theta_i^T x$ ，得到 k 个标量，然后用 *Softmax* 对它们归一化，就得到了概率值：

$$p_i = \frac{e^{S_i}}{\sum_k e^{S_k}}$$

模型的输出就是 $p_1 - p_k$ 组成的 k 维的概率向量 $\hat{y} = (p_1, \dots, p_k)$ ，元素之和为 1，每个分量就是样本被判为该类的概率，是一个多项分布。使用指数变换是因为指数函数值大于 0，能保证概率非负。

最终分类就是求概率向量中，最大的概率对应的下标值，即： $y_{pred} = \arg \max(\hat{y})$ 。

5.1. 交叉熵损失的推导(最大似然估计)

Softmax 回归要优化的参数为：

$$\theta = (\theta_1 \quad \theta_2 \quad \cdots \quad \theta_k)$$

θ_i 是一个列向量，因此 θ 是个 $n \times k$ 的矩阵。根据上面算法的定义，预测概率图 $\hat{y}$ 可以写为：

$$\hat{y} = \frac{1}{\sum_{i=1}^k e^{\theta_i^T x}} \begin{pmatrix} e^{\theta_1^T x} \\ \vdots \\ e^{\theta_k^T x} \end{pmatrix}$$

训练集的真实标签向量 y 使用 *One - Hot* 独热编码编码为向量。如果样本属于第 j 类，则向量的第 j 个分量为 1，其他为 0。比如说，如果 y 是第二类，则其表示为 $(0, 1, 0, \cdots, 0)_{1 \times k}$ 。

根据最大似然估计，样本的概率质量函数可以写成：

$$p_1^{y_1} \cdot p_2^{y_2} \cdots p_k^{y_k} = \prod_{i=1}^k (\hat{y}_i)^{y_i}$$

当矩阵 y 的取值确定属于第 j 类，即只有 y_j 为 1，其他都是 0，则上式的值为 $\hat{y}_j$ 。训练集的大小为 l ，则似然函数可以写成：

$$J(\theta) = \prod_{i=1}^l \left(\prod_{j=1}^k \left(\frac{\exp(\theta_j^T x_i)}{\sum_{t=1}^k \exp(\theta_t^T x_i)} \right)^{y_{ij}} \right)$$

其中 y_{ij} 为第 i 个训练样本标签向量的第 j 个分量。取对数得到对数似然函数为：

$$\ln J(\theta) = \sum_{i=1}^l \sum_{j=1}^k \left(y_{ij} \ln \frac{\exp(\theta_j^T x_i)}{\sum_{t=1}^k \exp(\theta_t^T x_i)} \right)$$

Softmax 回归目标是让这个对数似然函数极大化，转为最优化问题，等价于下面的损失函数取最小值：

$$L(\theta) = - \sum_{i=1}^l \sum_{j=1}^k \left(y_{ij} \ln \frac{\exp(\theta_j^T x_i)}{\sum_{t=1}^k \exp(\theta_t^T x_i)} \right) = - \sum_{i=1}^l \sum_{j=1}^k \left(y_{ij} \ln \hat{y}_{ij} \right)$$

而对于单个样本 (x_i, y_i) ，其损失为：

$$L(\theta) = - \sum_{j=1}^k y_j \ln \hat{y}_j$$

这就是多类别的交叉熵损失，反映了预测值 $\hat{y}$ 和标签值之间的差距，二者均为多项分布。在随机梯度下降法中，可以不对所有样本的交叉熵求和，而是对部分的样本求均值。

最大化对数似然函数就是最小化交叉熵损失函数，这也是 *Softmax* 回归的目标，可以证明这个交叉熵损失函数是凸函数。

5.2. 交叉熵的随机梯度下降优化

对于单个样本 (x_i, y_i) ，定义 k 为单个样本的特征维数， $\hat{y}_j$ 表示经过模型前向过程中，计算样本属于第 j 类的概率。

$$\hat{y}_j = \frac{\exp(\theta_j^T x_i)}{\sum_{t=1}^k \exp(\theta_t^T x_i)}$$

假设样本 (x_i, y_i) 的实际标签是属于第 t 类，根据上文可以列出损失函数表达式：

$$L(\theta) = - \sum_{j=1}^k y_j \ln \hat{y}_j = - \ln \hat{y}_t$$

最后一步中去掉了 $\sum$ ，原因是根据独热编码，只有 y_t 标为 1，其余的 y_j 都是 0。

令 $s_j = \theta_j^T x_i$ 简化计算, 则 $\hat{y}_j = \frac{\exp(s_j)}{\sum_{t=1}^k \exp(s_t)}$ 。为了使用梯度下降, 需要求 L 关于 θ 的偏导。

因此, 将损失函数对 θ_j 求偏导, 根据复合函数的偏导得到:

$$\frac{\partial L}{\partial \theta_j} = \frac{\partial L}{\partial \hat{y}_t} \frac{\partial \hat{y}_t}{\partial s_j} \frac{\partial s_j}{\partial \theta_j} = -\frac{1}{\hat{y}_k} \frac{\partial \hat{y}_t}{\partial s_j} x_i^T$$

因此只需要求解 $\frac{\partial \hat{y}_t}{\partial s_j}$ 即可, 需要分情况讨论, 因为只有 y 的第 t 个元素为 1, 其他的都是 0。

$$\begin{aligned} \hat{y}_t &= \frac{\exp(s_t)}{\sum_{t=1}^k \exp(s_t)} \quad \therefore \frac{\partial \hat{y}_t}{\partial s_j} = \frac{(e^{s_t})' \sum_k e^{s_t} - e^{s_t} (\sum_k e^{s_t})'}{(\sum_k e^{s_t})^2} \\ &= \begin{cases} \frac{e^{s_j} \sum_k e^{s_t} - e^{s_j} e^{s_j}}{(\sum_k e^{s_t})^2} = \frac{e^{s_j}}{\sum_k e^{s_t}} - (\frac{e^{s_j}}{\sum_k e^{s_t}})^2 = \hat{y}_j(1 - \hat{y}_j) & j = t \\ \frac{0 \sum_k e^{s_t} - e^{s_t} e^{s_j}}{(\sum_k e^{s_t})^2} = 0 - \frac{e^{s_j}}{\sum_k e^{s_t}} \frac{e^{s_t}}{\sum_k e^{s_t}} = -\hat{y}_j \hat{y}_t & j \neq t \end{cases} \end{aligned}$$

所以最后得到:

$$\frac{\partial L}{\partial \theta_j} = \frac{\partial L}{\partial \hat{y}_t} \frac{\partial \hat{y}_t}{\partial s_j} \frac{\partial s_j}{\partial \theta_j} = -\frac{1}{\hat{y}_t} \frac{\partial \hat{y}_t}{\partial s_j} x_i^T = \begin{cases} (\hat{y}_j - 1) x_i^T & j = t \\ \hat{y}_j x_i^T & j \neq t \end{cases}$$

即对于要求解的 θ_j 的梯度, 其下标 j (对应的 $\hat{y}_j$) 等于 y 对应类别标签的下标 t , 和 j 不等于对应类别标签 t 时, 梯度是不一样的。这也就是多分类的交叉熵推导, 其本质上衡量的就是, 第 j 个样本计算得到的 $\hat{y}_j$, 和实际标签下标 y_j 之间的差异。

算法过程可以表示为: 首先使用独热编码, 如果 y 属于第 t 类, 则让矩阵下标为 t 的元素对应的值为 1。之后正常使用随机梯度下降即可。

```
One - Hot Encoding : init y = (0, ..., 0, 1_t, 0, ..., 0)
while(until ∇L(w) = 0 ∨ 迭代次数到 n) :
    for batch in dataloader(shuffle) :
        ∇L(w) = 2 / batch_size * ∑_{i=1}^{batch_size} ∑_{j=1}^k { (ŷ_j - 1) x_i^T   j = t
        { ŷ_j x_i^T           j ≠ t
        w_{t+1} = w_t - η · ∇L(w)
```

6. 贝叶斯决策(Bayes)

它是一种基于统计学思想的方法, 由未知向已知, 由先验向后验转化的方法。

对于数据 x , 其最优的贝叶斯分类器为:

$$f^*(x) = \arg \max_{c \in [C]} p(c|x)$$

即预测具有最大条件概率的类别。 p 是未知的, 但我们可以估计它, 朴素贝叶斯本质上也是一个参数密度估计问题。

朴素贝叶斯常用来处理离散型的数据。如果是连续型的数据, 我们可以用 GMM 或者核密度估计 KDE 。

朴素贝叶斯思想: 先验概率 + 数据 = 后验概率。

设 (Ω, F, P) 是一个概率空间, $B \in F$, 且 $P(B) > 0$ 。对 $\forall A \in F$, 记:

$$P(B|A) = \frac{P(AB)}{P(A)} = \frac{P(A|B)P(B)}{P(A)}$$

这个公式可以看做, 事件 B 是因, 事件 A 是果。 $P(B)$ 为先验概率(*prior*), 是随机事件发生前观察/分析到的概率。 $P(B|A)$ 为后验概率(*posterior*), 事件发生后才知道。 $P(A|B)$ 为似然函数。

如果事件 $A_1, \dots, A_m$ 构成一个完备事件组, 且 $P(A_i), P(B) > 0$, 则根据全概率公式和贝叶斯公式:

$$P(A_m|B) = \frac{P(B|A_m)P(A_m)}{\sum_{i=1}^n P(A_i)P(B|A_i)}$$

根据贝叶斯公式和上述条件概率公式, 例如:

$$\begin{aligned}
P(Y = 1|X_1 = 0, X_2 = 1, X_3 = 1) \\
&= \frac{P(Y = 1, X_1 = 0, X_2 = 1, X_3 = 1)}{P(X_1 = 0, X_2 = 1, X_3 = 1)} \\
&= \frac{P(Y = 1)P(X_1 = 0, X_2 = 1, X_3 = 1|Y = 1)}{P(X_1 = 0, X_2 = 1, X_3 = 1)}
\end{aligned}$$

分母为全概率公式，分子为似然函数 $\times$ 先验概率。

朴素贝叶斯的朴素(Naive)体现在算法使用条件独立性假设，即假设 $P(A|B, Y) = P(A|Y)$ ， A, B 关于事件 Y 独立，可记为 $A \perp B|Y$ ，则根据条件概率公式可得：

$$\begin{aligned}
P(A, B|Y) &= P(A|B, Y)P(B|Y) = P(A|Y) \times P(B|Y) \\
\text{即 } P(X|y) &= \prod_{j=1}^P P(x_j|y)
\end{aligned}$$

因此原式 $P(Y = 1|X_1 = 0, X_2 = 1, X_3 = 1)$ 为：

$$\begin{aligned}
&\frac{P(Y = 1)P(X_1 = 0, X_2 = 1, X_3 = 1|Y = 1)}{P(X_1 = 0, X_2 = 1, X_3 = 1)} \\
&= \frac{P(Y = 1)P(X_1 = 0|Y = 1)P(X_2 = 1|Y = 1)P(X_3 = 1|Y = 1)}{P(X_1 = 0, X_2 = 1, X_3 = 1)} \\
&= \frac{P(Y = 1)P(X_1 = 0|Y = 1)P(X_2 = 1|Y = 1)P(X_3 = 1|Y = 1)}{P(Y = 1)P(X_1 = 0|Y = 1)P(X_2 = 1|Y = 1)P(X_3 = 1|Y = 1) + P(Y = 0)P(X_1 = 0|Y = 0)P(X_2 = 1|Y = 0)P(X_3 = 1|Y = 0)}
\end{aligned}$$

6.1. 朴素贝叶斯分类器原理

上面的贝叶斯公式可以变为如下形式：

$$p(y|x) = \frac{p(x|y)p(y)}{p(x)}$$

其中， x 为特征向量， y 为所属类别。 $p(x)$ 表示特征向量的概率分布， $p(y)$ 表示每个类别出现的概率，即类先验概率。 $p(x|y)$ 表示每个类样本的条件概率(类条件概率)，也被称为似然概率。通过这三个概率，就能计算出某样本 x_i 属于某类别 y_i 的后验概率 $p(y|x)$ 。

公式化定义：

设定输入空间为 $x \subseteq R^n$ 为 n 维向量的集合，输出空间为 $y = \{c_1, c_2, \dots, c_k\}$ 一共 k 个类别。

训练数据集为： $T\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ 。并根据先验分布和条件分布可得联合概率分布。

公式化推导：

$$\begin{aligned}
P(Y = c_k|X = x) &= \frac{P(X = x|Y = c_k)P(Y = c_k)}{P(X = x)} \\
\text{其中, } P(X = x) &= \sum_k P(Y = c_k) \sum_j P(X^{(j)}|Y = c_k) \\
\text{其中, } P(X = x|Y = c_k) &= \sum_j P(X^{(j)}|Y = c_k) \\
\text{带入得, } P(Y = c_k|X = x) &= \frac{P(Y = c_k) \sum_j P(X^{(j)}|Y = c_k)}{\sum_k P(Y = c_k) \sum_j P(X^{(j)}|Y = c_k)}
\end{aligned}$$

目标函数可定义为：

$$\begin{aligned}
y &= \arg \max_{c_k} P(Y = c_k|X = x) \\
&= \arg \max_{c_k} \frac{P(Y = c_k) \prod_j P(X^{(j)} = x^{(j)}|Y = c_k)}{\sum_k P(Y = c_k) \prod_j P(X^{(j)} = x^{(j)}|Y = c_k)}
\end{aligned}$$

对于给出的待分类项，求解在此项出现的条件下各个类别出现的概率。哪个最大，就认为此分类项属于哪个类别。所以可以忽略分母的全概率项，简化判别函数。

所以原目标函数等价于：

$$y = \arg \max_{c_k} P(Y = c_k) \prod_j P(X^{(j)} = x^j | Y = c_k)$$

通过上面推导也能看出，实现贝叶斯分类器需要知道每类样本的特征向量所服从的概率分布，只要知道样本的概率分布，则可以通过贝叶斯分类器求解。

比如说，如果样本分布服从正态分布，则该朴素贝叶斯分类器被称为高斯贝叶斯分类器。

6.2. 最大化后验概率

Y 为标签， f 为模型， X 为特征。

假设 0-1 损失函数：

$$L(Y, f(X)) = \begin{cases} 1, Y \neq f(X) \\ 0, Y = f(X) \end{cases}$$

则期望损失函数为(希望尽可能对，故希望 R_{exp} 越小越好)：

$$\begin{aligned} R_{\text{exp}}(f) &= E[L(Y, f(X))] \\ &= E_X \sum_{k=1}^K [L(Y, f(X))] P(c_k | X) \\ &= \int_{X \times Y} L(y, f(x)) P(x, y) dx dy \\ &= \int_{X \times Y} L(y, f(x)) P(y|x) dy P(X) dx \\ &= \int_X \int_Y L(y, f(x)) P(y|x) dy P(X) dx \end{aligned}$$

后验概率最大化推导：

$$\begin{aligned} f(x) &= \arg \max_{y \in Y} \sum_{k=1}^K L(c_k, y) P(c_k | X = x) \\ &= \arg \min_{y \in Y} \sum_{k=1}^K P(y \neq c_k | X = x) \\ &= \arg \min_{y \in Y} (1 - P(y = c_k | X = x)) \\ &= \arg \max_{y \in Y} P(y = c_k | X = x) \end{aligned}$$

算法流程：

- 计算先验概率及其条件概率。

$$\begin{aligned} P(Y = c_k) &= \frac{\sum_{i=1}^N l(y_i = c_k)}{N}, \quad k = 1, 2, \dots, K \\ P(X^{(j)} = x^{(j)} | Y = c_k) &= \frac{\sum_{i=1}^N l(X^{(j)} = x^{(j)} | Y = c_k)}{\sum_{i=1}^N l(Y = c_k)} \end{aligned}$$

- 对于给定的实例 $x = (x^{(1)}, x^{(2)}, \dots, x^{(n)})^T$ ，计算目标函数的等价概率积

$$P(Y = c_k) \prod_j P(X^{(j)} = x^{(j)} | Y = c_k), \quad k = 1, 2, \dots, K$$

- 确定实例 x 的类别。

$$y = \arg \max_{c_k} P(Y = c_k) \prod_j P(X^{(j)} = x^{(j)} | Y = c_k)$$

性能分析：

优点：对小规模的数据表现很好，适合多分类任务，适合增量式训练。

缺点：对输入数据的表达形式很敏感。

6.3. 新冠患者死亡率预测

从朴素贝叶斯角度出发分析...

6.4. 高斯贝叶斯分类模型

假设每个类的样本的 n 维特征向量 x 都服从正态分布，此时的类条件概率密度函数为：

一维：

$$p(x|c) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

多维：

$$p(x|c) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma_c|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(x-\mu_c)^T \Sigma_c^{-1} (x-\mu_c)\right)$$

其中 $c = 1, 2, \dots, k$ 为类别标签， μ_c 为类别标签 c 的均值向量， Σ_c 为协方差矩阵，用每个类的训练样本通过最大似然得到。

$$p(c|x) = \frac{p(c)p(x|c)}{p(x)}$$

根据朴素贝叶斯中的推导，实际分类器为 $\arg \max_c p(c)p(x|c)$ 。如果每个类出现的概率 $p(c)$ 相等，则该分类器简化为：

$$\arg \max_c p(x|c)$$

即计算每个类的对数似然函数值 $\ln p(x|c)$ 并取其中极大值对应的类，作为分类结果。

接下来进一步简化，对 $p(x|c)$ 取对数，并变形后得到：

$$\begin{aligned} \ln(p(x|c)) &= \ln\left(\frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma_c|^{\frac{1}{2}}}\right) - \frac{1}{2}(x-\mu_c)^T \Sigma_c^{-1} (x-\mu_c) \\ &= -\frac{n}{2} \ln(2\pi) - \frac{1}{2} \ln |\Sigma_c| - \frac{1}{2} ((x-\mu_c)^T \Sigma_c^{-1} (x-\mu_c)) \end{aligned}$$

其中， $-\frac{n}{2} \ln(2\pi)$ 为一个常数。原问题 $\arg \max_c p(x|c)$ 实际上变为求下面的极小值：

$$\arg \min_c \frac{1}{2} \ln |\Sigma_c| + \frac{1}{2} ((x-\mu_c)^T \Sigma_c^{-1} (x-\mu_c))$$

该值最小的哪一类即为最后的分类结果。