

第 3 章 经典检测理论

本章提要

本章简要介绍信号检测理论的基本概念,分析在经典检测理论中常用的检测准则,例如最大后验概率准则、Bayes(贝叶斯)准则、最小错误概率准则、极大极小准则和 Neyman-Pearson(奈曼-皮尔逊)准则等。

在许多实际问题中,经常会遇到在几种可能发生的情况中做出判断的问题。如在雷达系统中要观测雷达回波,根据观测到的被各种干扰淹没了的随机信号波形,做出目标是否存在判断。在数字通信系统中,信号在传输过程中,可能会受到工业噪声、交流噪声、随机脉冲噪声、宇宙噪声以及元器件内部热噪声的污染,同时还会受到符号间干扰、同信道干扰、邻信道干扰的影响,波形会产生畸变。因此,接收机要根据接收到的、畸变了波形来判断发送波形是几种可能波形中的哪一种。

以上所列举的判断问题就是需要利用检测理论来解决的问题。检测理论就是在噪声和干扰环境下,根据有限的观测数据来识别信号有无或判断信号类别的理论。

在检测过程中,每次判决得到的结论并不都是正确的,而是尽可能使判决结论满足某种准则。这里的准则是指在特定条件下具有不同含义的最优准则,检测理论中常用的准则有 Bayes 准则、最大后验概率准则、最小错误概率准则、极大极小准则、Neyman-Pearson 准则等。因此,信号检测是一种基于某种最优准则,对观测数据的概率统计特性进行分析,最终做出判决的过程,它属于统计判决的范畴,其理论基础是统计判决理论和假设检验理论。

3.1 检测理论的基本概念

本节先从最简单的二元检测问题入手,讨论检测理论的基本概念。

二元检测又称为双择检测,其理论模型如图 3.1 所示。




图 3.1 二元检测模型

在二元检测模型中,第一部分是信号空间 s ,即发射端发送的信号,只有 $s_0(t)$ 和 $s_1(t)$ 两种状态。如在数字通信系统中, $s_1(t)$ 可以代表 1 码的波形, $s_0(t)$ 代表 0 码的波形。在雷达中, $s_1(t)$ 代表有雷达回波信号的波形, $s_0(t)$ 代表无回波信号的波形。

第二部分是干扰空间 n ,是指信号在信道上传输时所叠加的噪声。一般假设为均值为

0, 方差为 σ^2 的高斯白噪声。

第三部分为接收空间, 或称为输入空间 \mathbf{x} , 它既是接收端接收到的受到干扰的信号, 也是需要判决处理的信号, 即判决处理单元的输入信号。对于二元检测系统, $x(t) = s_i(t) + n(t) (i=0, 1)$ 。

第四部分为判决规则, 是对输入空间的受噪信号按照某种准则进行判决归类, 判断发送端发送的是 $s_1(t)$ 还是 $s_0(t)$ 。

第五部分为判决空间 \mathbf{D} , 在二元检测中, \mathbf{D} 分为 D_0 区域和 D_1 区域两部分。如果输入空间的信号落在 D_1 区域, 则判决发送端发送的是 $s_1(t)$; 如果落在 D_0 区域, 则判决发送端发送的是 $s_0(t)$ 。这样, 二元检测就有两种可能的判决结果, 对应两种假设 H_0 和 H_1 。即

$$H_0: x(t) = s_0(t) + n(t) \quad (3.1)$$

$$H_1: x(t) = s_1(t) + n(t) \quad (3.2)$$

其中, $x(t)$ 为观测到的信号, 即输入空间的元素; $n(t)$ 为干扰信号, 即干扰空间的元素。

因此, 二元检测就是将判决空间 \mathbf{D} 按照某种准则划分为 D_1 和 D_0 两个区域。若输入信号 $x(t)$ 落在 D_1 区域, 则判定 H_1 假设为真; 反之, 则判定 H_0 假设为真, 如图 3.2 所示。




图 3.2 双择检测示意图

这样会出现 4 种可能的判决结果:

- (1) 实际是 H_0 假设为真, 而判决为 H_0 假设为真;
- (2) 实际是 H_0 假设为真, 而判决为 H_1 假设为真;
- (3) 实际是 H_1 假设为真, 而判决为 H_0 假设为真;
- (4) 实际是 H_1 假设为真, 而判决为 H_1 假设为真。

显然, (1)、(4) 两种判决是正确的, (2)、(3) 两种判决是错误的。

设代价函数 C_{ij} 表示实际是 H_j 假设为真, 而判决为 H_i 假设为真所付出的代价, 也称为风险函数。第一个下标表示选择哪一种假设为真, 第二个下标表示哪一种假设实际为真。

当 H_0 假设为真, 而判决为 H_1 假设为真, 即本来无信号而判决为有信号, 称为虚警, 也称为第一类错误。虚警发生的概率表示为 $P(D_1 | H_0)$, 称为虚警概率。虚警引入的代价称为虚警代价, 记作 C_{10} 。

当 H_1 假设为真, 而判决为 H_0 假设为真, 即本来有信号而判决为无信号, 称为漏报, 也称为第二类错误。漏报发生的概率表示为 $P(D_0 | H_1)$, 称为漏报概率。漏报引入的代价称为漏报代价, 记作 C_{01} 。

正确判决应无代价, 一般记作 $C_{00} = C_{11} = 0$ 。正确判决的概率分别表示为 $P(D_1 | H_1)$ 和 $P(D_0 | H_0)$, 称为检测概率。

双择检测的本质是如何决定判决区间的划分, 使判决在某种意义上为最佳。即如何设计信号处理系统, 以便能够最佳地从干扰背景中发现信号和提取信号所携带的信息, 这也是设计各种条件下的最佳接收机(又称理想接收机, 是指在检测时能够使错误判决为最小的接

收机,或是能够从信号加噪声的波形中提取最多有用信息的接收机),并根据其输入做出有无信号或信号参量取值的决策。

3.2 最大后验概率准则

3.2.1 接收机结构形式

在二元检测中,信源的输出有 $s_0(t)$ 和 $s_1(t)$ 两种状态,对应 H_0 和 H_1 两种假设。两个输出发生的概率 $P(H_0)$ 和 $P(H_1)$ 称为先验概率。先验概率表示实验进行之前,观察者关于源的知识。

H_0 和 H_1 两个假设总有一个要发生,因此有

$$P(H_0) + P(H_1) = 1 \quad (3.3)$$

用条件概率 $P(H_0|x)$ 表示在得到样本 x 的条件下, H_0 假设为真的概率。用 $P(H_1|x)$ 表示在得到样本 x 的条件下, H_1 假设为真的概率。这两种条件概率都称为后验概率。

二元检测就是根据观测到的样本值 x , 选择或判决 H_0 假设为真还是 H_1 假设为真。

判决必须遵循一定的原则或准则。一种直观上合理的准则就是最大后验概率准则,按照这个准则就是要选择最可能出现的信号为最终的判决结果。也就是,若 $P(H_0|x) > P(H_1|x)$, 则判决 H_0 假设为真;反之,判决 H_1 假设为真。记作

$$\frac{P(H_1|x)}{P(H_0|x)} \underset{H_0}{\overset{H_1}{\gtrless}} 1 \quad (3.4)$$

即选择与最大后验概率相对应的那个假设作为判决结果,这个准则称为最大后验概率准则(maximum a posterior probability criterion, 简称 MAP 准则),或记作

$$P(H_1|x) \underset{H_0}{\overset{H_1}{\gtrless}} P(H_0|x) \quad (3.5)$$

也可表示为 $P(H_0|x)/P(H_1|x) > 1$, 判为 H_0 假设为真;反之,判为 H_1 假设为真。

根据贝叶斯(Bayes)公式,后验概率可以表示为

$$P(H_i|x) = \frac{P(H_i)P(x|H_i)}{P(x)} \quad (3.6)$$

其中, $P(H_i)$ 为 H_i 假设发生的先验概率。

若随机变量 X 的概率密度函数为 $f(x)$, 则

$$P(x) = P(x \leq X \leq x + dx) \approx f(x)dx \quad (3.7)$$

同理

$$P(x|H_i) = P(x \leq X \leq x + dx | H_i) \approx f(x|H_i)dx \quad (3.8)$$

式中, $f(x|H_i)$ 称为条件概率密度函数,在概率论中又称为似然函数。

将式(3.7)和式(3.8)代入式(3.6),得

$$P(H_i|x) = \frac{P(H_i)f(x|H_i)}{f(x)} \quad (3.9)$$

将上式代入最大后验概率准则公式(3.4),得

$$\frac{P(H_1|x)}{P(H_0|x)} = \frac{\frac{P(H_1)f(x|H_1)}{f(x)}}{\frac{P(H_0)f(x|H_0)}{f(x)}} = \frac{f(x|H_1)P(H_1)}{f(x|H_0)P(H_0)} \underset{H_0}{\overset{H_1}{\gtrless}} 1 \quad (3.10)$$

上式也可以等效为

$$l(x) = \frac{f(x | H_1)}{f(x | H_0)} \stackrel{H_1}{\underset{H_0}{\gtrless}} l_0 = \frac{P(H_0)}{P(H_1)} = \frac{P(H_0)}{1 - P(H_0)} \quad (3.11)$$

式中, $l(x)$ 称为似然比, $l_0 = P(H_0)/P(H_1)$ 称为门限值。

由上式可见, 判决过程变为求出在不同假设条件下似然函数的似然比, 然后与门限值相比, 如果大于门限值, 则判决 H_1 假设为真; 否则, 判决 H_0 假设为真。其接收机结构形式如图 3.3 所示。




图 3.3 最大后验概率准则下的接收机形式

【例 3.1】 设在某二元通信系统中, 有通信信号和无通信信号的先验概率分别为 $P(H_1)=0.9, P(H_0)=0.1$ 。若对某观测值 x 有条件概率分布 $f(x | H_1)=0.25$ 和 $f(x | H_0)=0.45$, 试用最大后验概率准则对该观测样本 x 进行分类。

解法 1: 利用 Bayes 公式, 分别计算 H_1 和 H_0 的后验概率为

$$P(H_1 | x) = \frac{f(x | H_1)P(H_1)}{\sum_{i=0}^1 f(x | H_i)P(H_i)} = \frac{0.25 \times 0.9}{0.25 \times 0.9 + 0.45 \times 0.1} \approx 0.833$$

$$P(H_0 | x) = \frac{f(x | H_0)P(H_0)}{\sum_{i=0}^1 f(x | H_i)P(H_i)} = \frac{0.45 \times 0.1}{0.25 \times 0.9 + 0.45 \times 0.1} \approx 0.167$$

根据最大后验概率准则可知

$$P(H_1 | x) > P(H_0 | x)$$

故合理的判决是把 x 归类于有信号状态, 即判决 H_1 假设为真。

解法 2:

$$\text{由于 } l(x) = \frac{f(x | H_1)}{f(x | H_0)} = \frac{0.25}{0.45} \approx 0.56$$

$$l_0 = \frac{P(H_0)}{P(H_1)} = \frac{0.1}{0.9} \approx 0.11$$

$$l(x) > l_0$$

所以判决 H_1 假设为真。

3.2.2 接收机性能评价

最大后验概率准则可以使平均错误概率为最小。下面予以证明。

虚警概率为

$$P(D_1 | H_0) = \int_{D_1} f(x | H_0) dx \quad (3.12)$$

漏报概率为

$$P(D_0 | H_1) = \int_{D_0} f(x | H_1) dx \quad (3.13)$$

总错误率(即平均错误概率)为

$$\begin{aligned} P_e &= P(H_1)P(D_0 | H_1) + P(H_0)P(D_1 | H_0) \\ &= P(H_1) \int_{D_0} f(x | H_1) dx + P(H_0) \int_{D_1} f(x | H_0) dx \end{aligned} \quad (3.14)$$

因为 D_0, D_1 覆盖了 x 的全部空间,故

$$\int_{D_0+D_1} f(x | H_1) dx = 1 \quad (3.15)$$

即

$$\int_{D_0} f(x | H_1) dx + \int_{D_1} f(x | H_1) dx = 1 \quad (3.16)$$

$$\begin{aligned} P(D_0 | H_1) &= \int_{D_0} f(x | H_1) dx = 1 - \int_{D_1} f(x | H_1) dx \\ &= 1 - P(D_1 | H_1) \end{aligned} \quad (3.17)$$

同理

$$P(D_1 | H_0) = 1 - P(D_0 | H_0) \quad (3.18)$$

利用式(3.17)消去式(3.14)中的 D_0 , 则有

$$\begin{aligned} P_e &= P(H_1) \left[1 - \int_{D_1} f(x | H_1) dx \right] + P(H_0) \int_{D_1} f(x | H_0) dx \\ &= P(H_1) + \int_{D_1} [P(H_0)f(x | H_0) - P(H_1)f(x | H_1)] dx \end{aligned} \quad (3.19)$$

为使总错误率最小,显然应该选择使第二项的被积函数在 D_1 区域不为正,即

$$P(H_1)f(x | H_1) > P(H_0)f(x | H_0) \quad (3.20)$$

$$\frac{f(x | H_1)}{f(x | H_0)} > \frac{P(H_0)}{P(H_1)} = l_0 \quad (3.21)$$

这恰好是最大后验概率准则,故最大后验概率准则又称为最小错误概率准则。

【例 3.2】 在存在加性噪声的情况下,测量只能为 1V 或 0V 的直流电压,设噪声服从均值为 0、方差为 σ^2 的正态分布,试对一次测量结果进行分类。

解: 根据正态分布的概率密度函数形式

$$\begin{aligned} f(x | H_0) &= \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \\ f(x | H_1) &= \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-1)^2}{2\sigma^2}} \end{aligned}$$

似然比为

$$l(x) = \frac{f(x | H_1)}{f(x | H_0)} = e^{-\frac{(x-1)^2}{2\sigma^2} + \frac{x^2}{2\sigma^2}} = e^{\frac{2x-1}{2\sigma^2}}$$

根据最大后验概率准则,判决规则为

$$l(x) = e^{\frac{2x-1}{2\sigma^2}} \underset{H_0}{\overset{H_1}{\geq}} l_0$$

由于 $\ln(x)$ 是 x 的单调函数,故对上式两边取对数不等式依然成立。

$$\frac{2x-1}{2\sigma^2} \underset{H_0}{\overset{H_1}{\geq}} \ln l_0$$

即

$$x \underset{H_0}{\overset{H_1}{\geq}} \frac{1}{2} + \sigma^2 \ln l_0 = \beta$$

可见,当观测值 x 大于 $\frac{1}{2} + \sigma^2 \ln l_0$ 时,判为被测直流电压为 1V;当观测值小于 $\frac{1}{2} + \sigma^2 \ln l_0$ 时,判为被测直流电压为 0V。

上述判决过程可以认为是以 β 为分界点,将 x 的样本空间 $(-\infty, \infty)$ 划分为 D_0 (区间范围为 $(-\infty, \beta)$) 和 D_1 (区间范围为 (β, ∞)) 两部分,如图 3.4 所示。若 x 落入 D_0 区域,判为 H_0 假设(0V)为真;若落入 D_1 区域,则判为 H_1 假设(1V)为真。




图 3.4 例 3.2 中似然函数及虚警和漏报概率图示

二元数字通信系统中,经常设定等概发送二元信号,即 $P(H_0) = P(H_1) = 0.5$ 。此时, $l_0 = 1, \beta = 0.5$,漏报概率和虚警概率相等。

3.3 最小风险 Bayes 准则

3.3.1 接收机结构形式

最大后验概率准则只能使平均错误概率最小,并未考虑两类错误判决所造成的损失大小。Bayes 准则是使平均风险(也称为平均代价或平均损失)最小的准则。

风险函数 C_{ij} 表示实际是 H_j 假设为真,而判决为 H_i 假设为真所引起的风险。

从理论上讲,正确判决的风险小于错误判决的风险,因此

$$\begin{cases} C_{01} - C_{11} > 0 \\ C_{10} - C_{00} > 0 \end{cases} \quad (3.22)$$

在已知 H_1 假设为真的条件下,做出判决的平均代价称为 H_1 假设下的条件风险,记作 γ_1 ,即

$$\gamma_1 = P(D_0 | H_1)C_{01} + P(D_1 | H_1)C_{11} \quad (3.23)$$

在已知 H_0 假设为真的条件下,做出判决的平均代价称为 H_0 假设下的条件风险,记作 γ_0 ,即

$$\gamma_0 = P(D_0 | H_0)C_{00} + P(D_1 | H_0)C_{10} \quad (3.24)$$

由于事先并不知道是 H_1 假设还是 H_0 假设为真,因而总的平均代价,即平均风险应为各条件风险按其先验概率进行平均。

$$\begin{aligned}
R &= P(H_0)\gamma_0 + P(H_1)\gamma_1 \\
&= P(H_0)[P(D_0 | H_0)C_{00} + P(D_1 | H_0)C_{10}] + \\
&\quad P(H_1)[P(D_0 | H_1)C_{01} + P(D_1 | H_1)C_{11}]
\end{aligned} \tag{3.25}$$

Bayes 准则就是按照使 R 为最小的原则来划分 D_0 和 D_1 区域。

将 $P(D_0 | H_1) = 1 - P(D_1 | H_1)$, $P(D_0 | H_0) = 1 - P(D_1 | H_0)$ 代入上式, 得

$$\begin{aligned}
R &= P(H_0)\{[1 - P(D_1 | H_0)]C_{00} + P(D_1 | H_0)C_{10}\} + \\
&\quad P(H_1)\{[1 - P(D_1 | H_1)]C_{01} + P(D_1 | H_1)C_{11}\} \\
&= P(H_0)C_{00} + P(H_1)C_{01} + P(H_0)(C_{10} - C_{00})P(D_1 | H_0) - \\
&\quad P(H_1)(C_{01} - C_{11})P(D_1 | H_1)
\end{aligned} \tag{3.26}$$

将虚警概率及检测概率的计算公式代入上式, 得

$$\begin{aligned}
R &= P(H_0)C_{00} + P(H_1)C_{01} + \int_{D_1} [P(H_0)(C_{10} - C_{00})f(x | H_0) - \\
&\quad P(H_1)(C_{01} - C_{11})f(x | H_1)] dx
\end{aligned} \tag{3.27}$$

上式中, 由于第一项、第二项为常数项, $P(H_0)(C_{10} - C_{00})f(x | H_0)$ 和 $P(H_1)(C_{01} - C_{11})f(x | H_1)$ 均为正, 故欲使 R 为最小, 必须把第三项的被积函数不为正的点分配到 D_1 域, 即

$$P(H_0)(C_{10} - C_{00})f(x | H_0) < P(H_1)(C_{01} - C_{11})f(x | H_1) \tag{3.28}$$

$$\frac{f(x | H_1)}{f(x | H_0)} > \frac{C_{10} - C_{00}}{C_{01} - C_{11}} \cdot \frac{P(H_0)}{P(H_1)} \tag{3.29}$$

因此, 最小风险 Bayes 准则叙述为, 若

$$l(x) = \frac{f(x | H_1)}{f(x | H_0)} > \frac{(C_{10} - C_{00})P(H_0)}{(C_{01} - C_{11})P(H_1)} \tag{3.30}$$

则判决 $x \in H_1$, 反之 $x \in H_0$ 。也可以等效为 $l(x) = \frac{f(x | H_1)}{f(x | H_0)} \underset{H_0}{\overset{H_1}{\gtrless}} l_0 = \frac{(C_{10} - C_{00})P(H_0)}{(C_{01} - C_{11})P(H_1)}$ 。

若将 $l_0 = (C_{10} - C_{00})P(H_0) / (C_{01} - C_{11})P(H_1)$ 也视为一个门限值, 则 Bayes 准则也是一种似然比检验, 即将似然函数 $l(x)$ 与门限值 l_0 比较。若 $l(x) > l_0$, 判决 H_1 假设为真; 反之, 则判决 H_0 假设为真, 其接收机结构形式如图 3.5 所示。




图 3.5 Bayes 准则下的接收机形式

下面是 Bayes 准则的另一种推导方法。

设判决区间 D_0 、 D_1 的分界点为 β , 则区域 D_0 和 D_1 的区间范围分别为 $(-\infty, \beta)$ 和 (β, ∞) 。

平均风险为

$$\begin{aligned}
R &= P(H_0)[C_{00}P(D_0 | H_0) + C_{10}P(D_1 | H_0)] + \\
&\quad P(H_1)[C_{01}P(D_0 | H_1) + C_{11}P(D_1 | H_1)]
\end{aligned}$$

$$= P(H_0) \left[C_{00} \int_{-\infty}^{\beta} f(x | H_0) dx + C_{10} \int_{\beta}^{\infty} f(x | H_0) dx \right] + P(H_1) \left[C_{01} \int_{-\infty}^{\beta} f(x | H_1) dx + C_{11} \int_{\beta}^{\infty} f(x | H_1) dx \right] \quad (3.31)$$

要使平均风险 R 为最小,可令 $\frac{dR}{d\beta} = 0$,得

$$\frac{dR}{d\beta} = P(H_0)[C_{00}f(\beta | H_0) - C_{10}f(\beta | H_0)] + P(H_1)[C_{01}f(\beta | H_1) - C_{11}f(\beta | H_1)] = 0 \quad (3.32)$$

得

$$l_0 = \frac{f(\beta | H_1)}{f(\beta | H_0)} = \frac{P(H_0)(C_{10} - C_{00})}{P(H_1)(C_{01} - C_{11})}$$

因此, Bayes 准则可表示为

$$l(x) = \frac{f(x | H_1)}{f(x | H_0)} \underset{H_0}{\overset{H_1}{\gtrless}} l_0 = \frac{(C_{10} - C_{00})P(H_0)}{(C_{01} - C_{11})P(H_1)} \quad (3.33)$$

3.3.2 Bayes 准则与最大后验概率准则的关系

(1) Bayes 准则与最大后验概率准则均属于似然比检验,只是门限值不同而已。

(2) 最小风险 Bayes 准则的门限值不仅与先验概率 $P(H_0)$ 和 $P(H_1)$ 有关,而且还与代价函数 C_{10} 、 C_{00} 、 C_{01} 、 C_{11} 有关。最大后验概率准则的门限值仅与先验概率有关。

(3) 最大后验概率准则是最小风险 Bayes 准则中取 $C_{10} - C_{00} = C_{01} - C_{11}$ 时的一种特例。一般地, $C_{00} = C_{11} = 0$, $C_{10} = C_{01}$, 即最大后验概率准则中两类错误判决的代价是相同的,故又将最大后验概率准则称为理想观测者准则,理想指最少主观偏见。

3.4 最小错误概率准则

在二元假设检验的情况下,判决的平均错误概率为

$$P_e = P(H_1)P(D_0 | H_1) + P(H_0)P(D_1 | H_0) \quad (3.34)$$

最小错误概率准则就是使上述平均错误概率为最小的准则。

比较上式与 Bayes 准则中的平均风险表达式(3.25),可以看到,当 $C_{00} = C_{11} = 0$ 、 $C_{10} = C_{01} = 1$ 时,平均风险等于平均错误概率,平均风险最小等价于平均错误概率最小,即

$$\begin{aligned} R &= P(H_0)[P(D_0 | H_0)C_{00} + P(D_1 | H_0)C_{10}] + \\ &P(H_1)[P(D_1 | H_1)C_{11} + P(D_0 | H_1)C_{01}] \\ &= P(H_0)P(D_1 | H_0) + P(H_1)P(D_0 | H_1) = P_e \end{aligned} \quad (3.35)$$

事实上,风险函数的确定是非常困难的。在雷达系统中漏报的风险就很难确定;二元数字通信系统中,“0”“1”码误判的风险也很难确定。因此,在许多应用场合,常常假定正确判决的风险为零,错误判决的风险为 1。在此条件下, Bayes 准则就转化为最小错误概率准则。

将 $C_{00} = C_{11} = 0$ 、 $C_{10} = C_{01} = 1$ 代入 Bayes 准则的判决公式(3.33)中,得到最小错误概率准则的判决公式,为

$$l(x) = \frac{f(x | H_1)}{f(x | H_0)} \underset{H_0}{\overset{H_1}{\gtrless}} \frac{P(H_0)}{P(H_1)} \quad (3.36)$$

最小错误概率准则下的接收机结构形式如图 3.6 所示。




图 3.6 最小错误概率准则下的接收机结构形式

由此可见,最小错误概率准则与最大后验概率准则的判决公式相同,均称为理想观测者准则。

【例 3.3】 设 x_1, x_2, \dots, x_n 是统计独立的方差为 σ^2 的高斯随机变量,在 H_1 假设下均值为 a_1 , H_0 假设下均值为 a_0 ($a_1 > a_0$), 试对其进行判决,并证明随着观测次数 n 的增加,判决的错误概率减小。

解: 在 H_1 假设下, x_1, x_2, \dots, x_n 的联合概率密度函数为

$$f(\mathbf{x} | H_1) = f(x_1, x_2, \dots, x_n | H_1) \\ = f(x_1 | H_1) f(x_2 | H_1) \cdots f(x_n | H_1) = \left(\frac{1}{\sqrt{2\pi}\sigma} \right)^n e^{-\frac{\sum_{i=1}^n (x_i - a_1)^2}{2\sigma^2}}$$

在 H_0 假设下, x_1, x_2, \dots, x_n 的联合概率密度函数为

$$f(\mathbf{x} | H_0) = \left(\frac{1}{\sqrt{2\pi}\sigma} \right)^n e^{-\frac{\sum_{i=1}^n (x_i - a_0)^2}{2\sigma^2}}$$

似然比为

$$l(\mathbf{x}) = \frac{f(\mathbf{x} | H_1)}{f(\mathbf{x} | H_0)} = e^{-\frac{\sum_{i=1}^n (x_i - a_1)^2}{2\sigma^2} + \frac{\sum_{i=1}^n (x_i - a_0)^2}{2\sigma^2}}$$

指数部分可以进行如下简化:

$$-\frac{\sum_{i=1}^n (x_i - a_1)^2}{2\sigma^2} + \frac{\sum_{i=1}^n (x_i - a_0)^2}{2\sigma^2} \\ = \frac{1}{2\sigma^2} \left(\sum_{i=1}^n x_i^2 - \sum_{i=1}^n 2a_0 x_i + na_0^2 - \sum_{i=1}^n x_i^2 + \sum_{i=1}^n 2a_1 x_i - na_1^2 \right) \\ = \frac{a_1 - a_0}{\sigma^2} \sum_{i=1}^n x_i - \frac{n(a_1^2 - a_0^2)}{2\sigma^2} = \frac{n(a_1 - a_0)}{\sigma^2} \bar{x} - \frac{n(a_1^2 - a_0^2)}{2\sigma^2}$$

根据判决公式得

$$l(\mathbf{x}) = e^{\frac{n(a_1 - a_0)}{\sigma^2} \bar{x} - \frac{n(a_1^2 - a_0^2)}{2\sigma^2}} \underset{H_0}{\overset{H_1}{\geq}} l_0$$

即

$$\bar{x} \underset{H_0}{\overset{H_1}{\geq}} \frac{a_1 + a_0}{2} + \frac{\sigma^2}{n(a_1 - a_0)} \ln l_0 = \beta$$

根据算术平均值的分布,写出其概率密度函数

$$f(\bar{x} | H_1) = \frac{\sqrt{n}}{\sqrt{2\pi}\sigma} e^{-\frac{n(\bar{x}-a_1)^2}{2\sigma^2}}$$

$$f(\bar{x} | H_0) = \frac{\sqrt{n}}{\sqrt{2\pi}\sigma} e^{-\frac{n(\bar{x}-a_0)^2}{2\sigma^2}}$$

两种错误概率分别为

$$P(D_1 | H_0) = \int_{\beta}^{\infty} f(\bar{x} | H_0) d\bar{x} = \int_{\beta}^{\infty} \frac{\sqrt{n}}{\sqrt{2\pi}\sigma} e^{-\frac{n(\bar{x}-a_0)^2}{2\sigma^2}} d\bar{x}$$

$$P(D_0 | H_1) = \int_{-\infty}^{\beta} f(\bar{x} | H_1) d\bar{x} = 1 - \int_{\beta}^{\infty} \frac{\sqrt{n}}{\sqrt{2\pi}\sigma} e^{-\frac{n(\bar{x}-a_1)^2}{2\sigma^2}} d\bar{x}$$

根据误差函数的计算公式

$$\operatorname{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt$$

令 $t = \frac{\sqrt{n}(\bar{x}-a_0)}{\sqrt{2}\sigma}$, 得 $dt = \frac{\sqrt{n}}{\sqrt{2}\sigma} d\bar{x}$, $d\bar{x} = \frac{\sqrt{2}\sigma}{\sqrt{n}} dt$, 代入上式得

$$P(D_1 | H_0) = \frac{1}{\sqrt{\pi}} \int_{\frac{\sqrt{n}(\beta-a_0)}{\sqrt{2}\sigma}}^{\infty} e^{-t^2} dt = \frac{1}{2} \left[\frac{2}{\sqrt{\pi}} \int_0^{\infty} e^{-t^2} dt - \frac{2}{\sqrt{\pi}} \int_0^{\frac{\sqrt{n}(\beta-a_0)}{\sqrt{2}\sigma}} e^{-t^2} dt \right]$$

$$= \frac{1}{2} \left[1 - \operatorname{erf}\left(\frac{\sqrt{n}(\beta-a_0)}{\sqrt{2}\sigma}\right) \right]$$

同理

$$P(D_0 | H_1) = 1 - \frac{1}{\sqrt{\pi}} \int_{\frac{\sqrt{n}(\beta-a_1)}{\sqrt{2}\sigma}}^{\infty} e^{-t^2} dt = 1 - \frac{1}{2} \left[\frac{2}{\sqrt{\pi}} \int_0^{\infty} e^{-t^2} dt - \frac{2}{\sqrt{\pi}} \int_0^{\frac{\sqrt{n}(\beta-a_1)}{\sqrt{2}\sigma}} e^{-t^2} dt \right]$$

$$= 1 - \frac{1}{2} \left[1 - \operatorname{erf}\left(\frac{\sqrt{n}(\beta-a_1)}{\sqrt{2}\sigma}\right) \right] = \frac{1}{2} - \frac{1}{2} \operatorname{erf}\left(\frac{\sqrt{n}(a_1-\beta)}{\sqrt{2}\sigma}\right)$$

当观测次数 $n \rightarrow \infty$ 时, $\operatorname{erf}\left(\frac{\sqrt{n}(\beta-a_0)}{\sqrt{2}\sigma}\right) \rightarrow 1$, $\operatorname{erf}\left(\frac{\sqrt{n}(a_1-\beta)}{\sqrt{2}\sigma}\right) \rightarrow 1$, 故 $P(D_1 | H_0) \rightarrow 0$,

$P(D_0 | H_1) \rightarrow 0$ 。

可见, 随着观测次数的增加, 判决的错误概率降低。

3.5 极大极小准则

在使用 Bayes 准则时, 必须事先知道各个代价因子 C_{ij} (i, j 为 0 或 1) 和先验概率 $P(H_0)$ 及 $P(H_1)$ 。在有些情况下, 这些参数难以确定。如在雷达观测中, 敌机出现与不出现的先验概率很难确定, 虚警与漏报的代价也无法估计。在博弈时, 对手出某牌的先验概率也很难知道。

在先验概率未知的情况下, 要想使用 Bayes 准则就必须首先推测一个先验概率 $P(H_0) = q$ (如在一些二元数字通信系统中, 都假定先验概率相等, 即 $q = 0.5$)。但采用推测的先验概率进行判决可能会产生很大的风险。

极大极小准则是在先验概率未知的情况下,使可能出现的最大风险达到极小的一种判决准则,也称为极小化极大准则。其关键是确定一个能使最大风险达到极小的先验概率。再将此先验概率应用到 Bayes 准则的判决公式中,就得到了极大极小准则的判决公式。

3.5.1 不同 $P(H_0)$ 下的 Bayes 风险

假定 $P(H_0)=q$, 则 $P(H_1)=1-q$ 。

显然判决区间 D_0 、 D_1 的划分与先验概率 q 有关,使得第一、第二类错误概率也与 q 有关。

令

$$P(D_1 | H_0) = \int_{D_1} f(x | H_0) dx = \alpha(q) \quad (3.37)$$

$$P(D_0 | H_1) = \int_{D_0} f(x | H_1) dx = \beta(q) \quad (3.38)$$

则 $P(D_0 | H_0)=1-\alpha(q)$, $P(D_1 | H_1)=1-\beta(q)$ 。当 $P(H_1)\rightarrow 0, \alpha(1)\rightarrow 0; P(H_0)\rightarrow 0, \beta(0)\rightarrow 0$ 。

对于未知的 q 值, Bayes 风险为

$$\begin{aligned} R(q) &= P(H_0)[P(D_0 | H_0)C_{00} + P(D_1 | H_0)C_{10}] + \\ &\quad P(H_1)[P(D_0 | H_1)C_{01} + P(D_1 | H_1)C_{11}] \\ &= q[(1-\alpha(q))C_{00} + \alpha(q)C_{10}] + (1-q)[\beta(q)C_{01} + (1-\beta(q))C_{11}] \\ &= C_{00}q + C_{11}(1-q) + (C_{10}-C_{00})\alpha(q)q + (C_{01}-C_{11})\beta(q)(1-q) \end{aligned} \quad (3.39)$$

由于

$$R(0) = C_{11} + (C_{01} - C_{11})\beta(0) \rightarrow C_{11} \quad (3.40)$$

$$R(1) = C_{00} + (C_{10} - C_{00})\alpha(1) \rightarrow C_{00} \quad (3.41)$$

因此, $R(q)$ 与 q 之间的关系如图 3.7 中的曲线 A 所示。

3.5.2 假定 $P(H_0)=q_1$, 实际 $P(H_0)$ 不一定是 q_1 时的平均风险

当先验概率未知时,只能按照推测的先验概率如 q_1 来设计 Bayes 检测,相对应于 q_1 ,把观测区间划分成 D'_0 和 D'_1 区间,于是虚警和漏报概率都是 q_1 的函数,分别为

$$P(D_1 | H_0) = \int_{D'_1} f(x | H_0) dx = \alpha(q_1) \quad (3.42)$$

$$P(D_0 | H_1) = \int_{D'_0} f(x | H_1) dx = \beta(q_1) \quad (3.43)$$

如果真实的先验概率为 $P(H_0)=q$ (其中 $0 \leq q \leq 1$), 则 Bayes 风险为

$$\begin{aligned} R(q, q_1) &= P(H_0)[P(D_0 | H_0)C_{00} + P(D_1 | H_0)C_{10}] + \\ &\quad P(H_1)[P(D_0 | H_1)C_{01} + P(D_1 | H_1)C_{11}] \\ &= q\{[1-\alpha(q_1)]C_{00} + \alpha(q_1)C_{10}\} + (1-q)\{\beta(q_1)C_{01} + [1-\beta(q_1)]C_{11}\} \\ &= \{C_{00} + (C_{10} - C_{00})\alpha(q_1) - C_{11} - (C_{01} - C_{11})\beta(q_1)\}q + \end{aligned}$$




图 3.7 Bayes 风险与极大极小风险

$$C_{11} + (C_{01} - C_{11})\beta(q_1) \quad (3.44)$$

若令 $G(q_1) = (C_{10} - C_{00})\alpha(q_1)$, $Q(q_1) = (C_{01} - C_{11})\beta(q_1)$, 则上式变为

$$R(q, q_1) = [C_{00} - C_{11} + G(q_1) - Q(q_1)]q + Q(q_1) + C_{11} \quad (3.45)$$

可见, $R(q, q_1)$ 与 q 构成线性关系, 其关系曲线如图 3.7 中的直线 B 所示。当真实的先验概率 q 等于推测的先验概率 q_1 时, $R(q, q_1) = R(q_1)$; 当 q 不等于 q_1 时, $R(q, q_1) > R(q)$ 。因此, 直线 B 在点 $[q_1, R(q_1)]$ 与曲线 A 相切, 且达到最小值。

由图可知, 当真实的 $q \in [q_0, 1]$ 时, 使用 $R(q, q_1)$ 进行 Bayes 检验, 其风险不仅大于 $R(q_1)$, 而且总大于曲线 $R(q)$ 的极大值 $R(q)_{\max}$, q 越接近 1, 其风险越大。

同理, 直线 C 为用 $R(q, q_2)$ 设计的 Bayes 检验。由图可见, 对于 $q \in [0, q_0]$ 所冒风险均比 $R(q)_{\max}$ 大。

若选择使 Bayes 风险为最大的先验概率 q_0 来设计 Bayes 检验, 这时 $R(q, q_0)$ 是一条在点 $[q_0, R(q_0)]$ 与曲线 A 相切的直线 D , 且该直线平行于横坐标轴。此时, 无论实际的 q 为多大, 其风险均等于最大 Bayes 风险, 这样就可以避免引起太大的风险, 即使最大可能的风险极小化, 这就满足了极大极小准则。极大极小准则等效于选择最不利的先验概率 q_0 , 使 Bayes 风险极大化。虽然这种做法是保守的, 但它避免了错误估计 q 而带来的更大风险。

当用 q_0 来设计 Bayes 检验时, $R(q, q_0)$ 与曲线 A 相切, $R(q, q_0)$ 的斜率为 0, 即

$$\frac{dR(q, q_0)}{dq} = C_{00} - C_{11} + (C_{10} - C_{00})\alpha(q_0) - (C_{01} - C_{11})\beta(q_0) = 0 \quad (3.46)$$

将上式变形, 可以得到

$$C_{00} + (C_{10} - C_{00})\alpha(q_0) = C_{11} + (C_{01} - C_{11})\beta(q_0) \quad (3.47)$$

将上式代入式 (3.39), 得到极大极小风险, 为

$$\begin{aligned} R(q_0) &= C_{00}q_0 + C_{11}(1 - q_0) + (C_{10} - C_{00})\alpha(q_0)q_0 + (C_{01} - C_{11})\beta(q_0)(1 - q_0) \\ &= [C_{00} + (C_{10} - C_{00})\alpha(q_0)]q_0 - [C_{11} + (C_{01} - C_{11})\beta(q_0)]q_0 + \\ &\quad C_{11} + (C_{01} - C_{11})\beta(q_0) \\ &= C_{11} + (C_{01} - C_{11})\beta(q_0) \\ &= C_{00} + (C_{10} - C_{00})\alpha(q_0) \end{aligned} \quad (3.48)$$

根据上式可求得的 q_0 , 将 q_0 代入 Bayes 准则的判决公式即可得到极大极小准则的判决公式, 为

$$l(x) = \frac{f(x | H_1)}{f(x | H_0)} \underset{H_0}{\overset{H_1}{\geq}} l_0 = \frac{(C_{10} - C_{00})q_0}{(C_{01} - C_{11})(1 - q_0)} \quad (3.49)$$

极大极小准则下的接收机结构形式如图 3.8 所示。




图 3.8 极大极小准则下的接收机结构形式

【例 3.4】 在二元数字通信系统中, 时间间隔 T 秒内, 发送一个幅度为 d 的脉冲信号, 即 $s_1 = d$, 代表 1; 或者不发送信号, 即 $s_0 = 0$, 代表 0。加性噪声服从零均值和单位方差的高

斯分布,当先验概率未知,正确判决不花代价,错误判决代价相等且等于 1 时,采用极大极小准则计算一次测量结果的极大极小风险为多大? 相应的 q_0 为多少?

解: 由题意可知,在两种假设情况下,其似然函数分别为

$$f(x | H_0) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$$

$$f(x | H_1) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-d)^2}{2}}$$

根据式(3.48)得,极大极小风险为

$$R(q_0) = C_{00} + (C_{10} - C_{00})\alpha(q_0) = C_{11} + (C_{01} - C_{11})\beta(q_0)$$

代入 $C_{00} = C_{11} = 0, C_{01} = C_{10} = 1$, 得

$$R(q_0) = \alpha(q_0) = \beta(q_0)$$

由于

$$\alpha(q_0) = \int_{\beta}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx = \int_{\frac{\beta}{\sqrt{2}}}^{\infty} \frac{1}{\sqrt{\pi}} e^{-t^2} dt = \frac{1}{2} \frac{2}{\sqrt{\pi}} \int_{\frac{\beta}{\sqrt{2}}}^{\infty} e^{-t^2} dt = \frac{1}{2} \left[1 - \operatorname{erf}\left(\frac{\beta}{\sqrt{2}}\right) \right]$$

$$\beta(q_0) = \int_{-\infty}^{\beta} \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-d)^2}{2}} dx = 1 - \int_{\beta}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-d)^2}{2}} dx = 1 - \frac{1}{2} \left(\frac{2}{\sqrt{\pi}} \int_{\frac{\beta-d}{\sqrt{2}}}^{\infty} e^{-t^2} dt \right)$$

$$= 1 - \frac{1}{2} \left[1 - \operatorname{erf}\left(\frac{\beta-d}{\sqrt{2}}\right) \right] = \frac{1}{2} \left[1 + \operatorname{erf}\left(\frac{\beta-d}{\sqrt{2}}\right) \right] = \frac{1}{2} \left[1 - \operatorname{erf}\left(\frac{d-\beta}{\sqrt{2}}\right) \right]$$

可以得到

$$\beta = d - \beta, \quad \beta = \frac{d}{2}$$

得到极大极小风险为

$$R(q_0) = \frac{1}{2} \left[1 - \operatorname{erf}\left(\frac{d}{2\sqrt{2}}\right) \right]$$

根据极大极小准则,得

$$l(x) = \frac{f(x | H_1)}{f(x | H_0)} = e^{\frac{2dx-d^2}{2}} \underset{H_0}{\overset{H_1}{\geq}} \frac{q_0}{1-q_0}$$

即

$$2dx - d^2 \underset{H_0}{\overset{H_1}{\geq}} 2 \ln \frac{q_0}{1-q_0}, \quad x \underset{H_0}{\overset{H_1}{\geq}} \frac{d}{2} + \frac{1}{d} \ln \frac{q_0}{1-q_0} = \beta = \frac{d}{2}$$

得

$$\frac{q_0}{1-q_0} = 1, \quad q_0 = P(H_0) = \frac{1}{2}$$

即二元数字通信系统采用等概发送。

3.6 Neyman-Pearson 准则

使用 Bayes 准则需要知道先验概率和代价函数。在先验概率未知情况下,可以使用极大极小准则。但在许多情况下,如雷达检测中,要指定代价函数和先验概率都很困难,上述

准则无法使用。运用 Neyman-Pearson(奈曼-皮尔逊)准则不需要知道代价函数和先验概率。它假定有一类错误较其他错误更为重要,因而对这一类错误出现的概率进行严格限制,然后再去确定能使其他错误概率最小的判决门限。

Neyman-Pearson 准则是在给定虚警概率的情况下,使检测概率尽可能大,即漏报概率尽可能小,但漏报概率的减小又会使虚警概率增大,因此在实际中要统筹兼顾、辩证分析、折中处理,漏报概率尽可能小是最低要求。

Neyman-Pearson 准则限定 $P(D_1 | H_0) = \alpha$ (α 为常数),根据这个限定设计一个检验,使得 $P(D_1 | H_1)$ 最大或 $P(D_0 | H_1)$ 最小。应用拉格朗日(Lagrange)乘子 λ 构造下述目标函数。

$$\begin{aligned}
 J &= P(D_0 | H_1) + \lambda [P(D_1 | H_0) - \alpha] \\
 &= \int_{D_0} f(x | H_1) dx + \lambda \left[\int_{D_1} f(x | H_0) dx - \alpha \right] \\
 &= \int_{D_0} f(x | H_1) dx + \lambda \left[1 - \int_{D_0} f(x | H_0) dx - \alpha \right] \\
 &= \lambda(1 - \alpha) + \int_{D_0} [f(x | H_1) - \lambda f(x | H_0)] dx \quad (3.50)
 \end{aligned}$$

要使 J 达到最小,只有把上式中被积函数不为正的点分配到 D_0 域,即 $x \in D_0$ 时

$$f(x | H_1) < \lambda f(x | H_0) \quad (3.51)$$

或将式(3.50)变换为

$$\begin{aligned}
 J &= \int_{D_0} f(x | H_1) dx + \lambda \left[\int_{D_1} f(x | H_0) dx - \alpha \right] \\
 &= 1 - \int_{D_1} f(x | H_1) dx + \lambda \left[\int_{D_1} f(x | H_0) dx - \alpha \right] \\
 &= 1 - \alpha \lambda + \int_{D_1} [\lambda f(x | H_0) - f(x | H_1)] dx \quad (3.52)
 \end{aligned}$$

要使 J 达到最小,只有把上式中被积函数不为正的点分配到 D_1 域,即 $x \in D_1$ 时

$$f(x | H_1) > \lambda f(x | H_0) \quad (3.53)$$

由式(3.51)和式(3.53)得到判决公式为

$$\frac{f(x | H_1)}{f(x | H_0)} \underset{H_0}{\overset{H_1}{\gtrless}} \lambda \quad (3.54)$$

显然也是一种似然比检验,门限值为拉格朗日乘子 λ ,其值由给定条件 $P(D_1 | H_0) = \alpha$ 来确定。其接收机结构形式如图 3.9 所示。




图 3.9 Neyman-Pearson 准则下的接收机结构形式

在最小风险 Bayes 判决准则中,若令

$$C_{00} = C_{11} = 0, \quad C_{10}P(H_0) = \lambda, \quad C_{01}P(H_1) = 1 \quad (3.55)$$

则

$$\frac{f(x | H_1)}{f(x | H_0)} \underset{H_0}{\overset{H_1}{\geq}} \frac{(C_{10} - C_{00})P(H_0)}{(C_{01} - C_{11})P(H_1)} = \lambda \quad (3.56)$$

Bayes 判决准则即变为 Neyman-Pearson 准则。

【例 3.5】 在加性噪声背景下,测量 0V 和 1V 的直流电压,在 $P(D_1 | H_0) = 0.1$ 的条件下,采用 Neyman-Pearson 准则,对一次观测数据进行判决。假定加性噪声服从均值为 0,方差为 2 的正态分布。

解: 根据正态分布的概率密度函数得

$$f(x | H_0) = \frac{1}{2\sqrt{\pi}} e^{-\frac{x^2}{4}}$$

$$f(x | H_1) = \frac{1}{2\sqrt{\pi}} e^{-\frac{(x-1)^2}{4}}$$

根据 Neyman-Pearson 准则的判决规则,可得

$$\frac{f(x | H_1)}{f(x | H_0)} = e^{\frac{x-1}{2}} \underset{H_0}{\overset{H_1}{\geq}} \lambda$$

上式判决等效于

$$x \underset{H_0}{\overset{H_1}{\geq}} \frac{1}{2} + 2\ln\lambda = \beta$$

对于 Neyman-Pearson 准则,门限 λ 应满足 $P(D_1 | H_0) = \alpha$ 的约束条件,即

$$\begin{aligned} P(D_1 | H_0) = 0.1 &= \int_{D_1} f(x | H_0) dx = \int_{\beta}^{\infty} \frac{1}{2\sqrt{\pi}} e^{-\frac{x^2}{4}} dx \\ &= \frac{1}{2} \left[\frac{2}{\sqrt{\pi}} \int_0^{\infty} e^{-\left(\frac{x}{2}\right)^2} d\frac{x}{2} - \frac{2}{\sqrt{\pi}} \int_0^{\beta} e^{-\left(\frac{x}{2}\right)^2} d\frac{x}{2} \right] \\ &= \frac{1}{2} \left[1 - \frac{2}{\sqrt{\pi}} \int_0^{\frac{\beta}{2}} e^{-t^2} dt \right] = \frac{1}{2} \left[1 - \operatorname{erf}\left(\frac{\beta}{2}\right) \right] \end{aligned}$$

得

$$\operatorname{erf}\left(\frac{\beta}{2}\right) = 1 - 0.2 = 0.8$$

查误差函数表得 $\operatorname{erf}(0.9) = 0.796915$

因此

$$\frac{\beta}{2} = 0.9, \quad \beta = 1.8$$

得到判决规则,为

$$x \underset{H_0}{\overset{H_1}{\geq}} 1.8$$

由于 $\frac{1}{2} + 2\ln\lambda = 1.8, \ln\lambda = 0.65, \lambda = e^{0.65} = 1.92$ 。

3.7 M 元 检 测

前面讨论的二元信号检测问题,是在 H_0 和 H_1 两个假设之间进行选择。在实际应用中,还会遇到多元信号检测问题。如在数字通信系统中,常常通过传输 M 个信号来传递信息,这种情况就属于 M 元检测问题。

假设发送端有 M 个可能的输出 $s_1(t), s_2(t), \dots, s_M(t)$, 对应有 M 个假设, 记作

$$\begin{cases} H_1: x(t) = s_1(t) + n(t) \\ H_2: x(t) = s_2(t) + n(t) \\ \vdots \\ H_M: x(t) = s_M(t) + n(t) \end{cases} \quad (3.57)$$

从中选择一个并假设为真,即为 M 择 1 假设检验,或称为 M 元检测。

3.7.1 M 元检测的 Bayes 准则

Bayes 准则是使判决的平均风险达到极小的准则。要利用 Bayes 准则,各类假设的先验概率和各种判决的代价函数必须已知。设 C_{ij} 为 H_j 假设为真而选择了 H_i 假设的代价, $P(H_j)$ 为 H_j 假设的先验概率,则平均风险为

$$R = \sum_{i=1}^M \sum_{j=1}^M C_{ij} P(D_i | H_j) P(H_j) \quad (3.58)$$

Bayes 准则是使平均风险 R 最小,即在给定样本 x 的情况下,选择 H_i 假设为真所产生的风险比选择 $H_j (j \neq i)$ 假设为真所产生的风险小。

在观测样本为 x 的条件下,选择 H_i 假设为真的条件代价为

$$C_i = \sum_{j=1}^M C_{ij} P(H_j | x) \quad (3.59)$$

其中, $P(H_j | x)$ 表示给定观测样本 x 后, H_j 假设为真的概率,亦称 H_j 假设的后验概率。

如在二元检测中

$$C_0 = C_{00} P(H_0 | x) + C_{01} P(H_1 | x) \quad (3.60)$$

$$C_1 = C_{10} P(H_0 | x) + C_{11} P(H_1 | x) \quad (3.61)$$

Bayes 准则的判决规则是选择最小 C_k 所对应的那个 H_k 假设为真,即若有

$$C_k < C_i, \quad i = 1, 2, \dots, k-1, k+1, \dots, M \quad (3.62)$$

则选择 H_k 假设为真。

根据条件概率乘法公式,有

$$P(H_j | x) = \frac{f(x | H_j) P(H_j)}{f(x)} \quad (3.63)$$

式中, $f(x)$ 为输入样本 x 的先验概率密度函数。

有

$$C_i = \sum_{j=1}^M C_{ij} \frac{f(x | H_j) P(H_j)}{f(x)} \quad (3.64)$$

令

$$L_i = \sum_{j=1}^M C_{ij} f(x | H_j) P(H_j)$$

则

$$C_i = \frac{L_i}{f(x)} \quad (3.65)$$

由于 $f(x)$ 与假设无关, 因而选择 C_i 最小等价于选择 L_i 最小。即 Bayes 检验变为计算 L_i , 并判决 L_i 为最小 L_k 对应的那个 H_k 假设为真, 其接收机结构形式如图 3.10 所示。




图 3.10 Bayes 准则下的 M 元检测接收机形式

3.7.2 M 元检测的最大后验概率准则

采用 Bayes 准则, 必须同时知道各假设的先验概率和各种错误代价。当代价函数未知时, 一般假定正确判决无代价, 错误判决代价相等且为 1, 即 $C_{ii} = 0, C_{ij} = 1 (i \neq j)$, 在此情况下, Bayes 准则等效为最大后验概率准则。

将 $C_{ii} = 0, C_{ij} = 1 (i \neq j)$ 代入式 (3.59) 中, 得

$$C_i = \sum_{\substack{j=1 \\ j \neq i}}^M P(H_j | x) \quad (3.66)$$

由于 C_i 的和式中恰好缺少 $P(H_i | x)$, 因而有

$$C_k - C_i = \sum_{\substack{j=1 \\ j \neq k}}^M P(H_j | x) - \sum_{\substack{j=1 \\ j \neq i}}^M P(H_j | x) = P(H_i | x) - P(H_k | x) \quad (3.67)$$

因此, 选择所有 C_i 中最小者 C_k , 等价于选择所有 $P(H_i | x)$ 中的最大者 $P(H_k | x)$, 即选择与最大后验概率 $P(H_k | x)$ 所对应的那个 H_k 假设为真, 则为最大后验概率准则。其接收机结构形式如图 3.11 所示。



图 3.11 最大后验概率准则下的 M 元检测接收机形式

3.7.3 M 元检测的最大似然检验准则

根据条件概率乘法公式 (3.63) 可知, $P(H_k | x) > P(H_i | x)$ 等价于

$$P(H_k) f(x | H_k) > P(H_i) f(x | H_i) \quad (3.68)$$

当先验概率 $P(H_i)$ 未知时, 无法使用最大后验概率准则, 一般假定各假设的先验概率相等, 即 $P(H_i) = 1/M$, 此时, $P(H_i) f(x | H_i)$ 最大等效于 $f(x | H_i)$ 最大, 称为最大似然准则。相应的判决设备称为最大似然处理器, 或称为最大似然准则的接收机, 如图 3.12 所示。

【例 3.6】 根据 n 维输入矢量 $\mathbf{x} = [x_1, x_2, \dots, x_n]$ 设计一种最佳检测器, n 维输入矢量 $\mathbf{x} = [x_1, x_2, \dots, x_n]$ 中的任意两个元素 x_i 和 x_j 是独立的, 对下述 4 种假设做出判决: H_1



图 3.12 最大似然准则下的 M 元检测接收机形式

表示均值为 1, H_2 表示均值为 2, H_3 表示均值为 3, H_4 表示均值为 4, 各假设下的条件概率密度函数是高斯的, 方差为 σ^2 , 假定所有假设的先验概率相等, 且 $C_{ij}=1(i \neq j), C_{ii}=0$ 。

解: 根据先验概率相等, 且 $C_{ij}=1(i \neq j), C_{ii}=0$ 的条件, 四元假设检验可按最大似然准则来设计。

4 种假设可表示为

$$H_1: x_i = 1 + n_i \quad i = 1, 2, \dots, n$$

$$H_2: x_i = 2 + n_i \quad i = 1, 2, \dots, n$$

$$H_3: x_i = 3 + n_i \quad i = 1, 2, \dots, n$$

$$H_4: x_i = 4 + n_i \quad i = 1, 2, \dots, n$$

n 维输入矢量 $\mathbf{x} = (x_1, x_2, \dots, x_n)$ 中的任意两个元素 x_i 和 x_j 是独立的, 因此在各种假设下的似然函数可表示为

$$f(\mathbf{x} | H_k) = \left(\frac{1}{\sqrt{2\pi}\sigma} \right)^n e^{-\sum_{i=1}^n \frac{(x_i - k)^2}{2\sigma^2}}, \quad k = 1, 2, 3, 4$$

选择 $f(\mathbf{x} | H_k)$ 最大等效为选择 $\sum_{i=1}^n \frac{(x_i - k)^2}{2\sigma^2}$ 最小, 由于

$$\begin{aligned} \sum_{i=1}^n \frac{(x_i - k)^2}{2\sigma^2} &= \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 - \frac{1}{\sigma^2} \sum_{i=1}^n kx_i + \frac{n}{2\sigma^2} k^2 \\ &= \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 - \frac{n}{2\sigma^2} \left[\frac{2}{n} \sum_{i=1}^n kx_i - k^2 \right] \\ &= \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 - \frac{n}{2\sigma^2} [2k\bar{x} - k^2] \end{aligned}$$

上式中, $\frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$, \bar{x} 表示 x 的算术平均值。上式中的第一项与选择何种假设无关, 所以选择

以选择 $\sum_{i=1}^n \frac{(x_i - k)^2}{2\sigma^2}$ 最小, 又等效为选择 $2k\bar{x} - k^2$ 最大。

即判决准则变为比较 $2\bar{x} - 1, 4\bar{x} - 4, 6\bar{x} - 9, 8\bar{x} - 16$, 并选择其中最大者所对应的假设 H_k 为真。

假定 $f(\mathbf{x} | H_1)$ 最大, 则必有

$$\begin{cases} 2\bar{x} - 1 \geq 4\bar{x} - 4 \\ 2\bar{x} - 1 \geq 6\bar{x} - 9 \\ 2\bar{x} - 1 \geq 8\bar{x} - 16 \end{cases}$$

等价于选择 H_1 的区域 D_1 满足条件

$$\bar{x} \leq 1.5$$

假定 $f(\mathbf{x} | H_2)$ 最大, 则必有

$$\begin{cases} 4\bar{x} - 4 \geq 2\bar{x} - 1 \\ 4\bar{x} - 4 \geq 6\bar{x} - 9 \\ 4\bar{x} - 4 \geq 8\bar{x} - 16 \end{cases}$$

等价于选择 H_2 的区域 D_2 满足条件

$$1.5 \leq \bar{x} \leq 2.5$$

假设 $f(x|H_3)$ 最大, 则必有

$$\begin{cases} 6\bar{x} - 9 \geq 2\bar{x} - 1 \\ 6\bar{x} - 9 \geq 4\bar{x} - 4 \\ 6\bar{x} - 9 \geq 8\bar{x} - 16 \end{cases}$$

等价于选择 H_3 的区域 D_3 满足条件

$$2.5 \leq \bar{x} \leq 3.5$$

假设 $f(x|H_4)$ 最大, 则必有

$$\begin{cases} 8\bar{x} - 16 \geq 2\bar{x} - 1 \\ 8\bar{x} - 16 \geq 4\bar{x} - 4 \\ 8\bar{x} - 16 \geq 6\bar{x} - 9 \end{cases}$$

等价于选择 H_4 的区域 D_4 满足条件

$$\bar{x} \geq 3.5$$

\bar{x} 服从高斯分布, 其方差为 σ^2/n , 均值分别为 1, 2, 3, 4, 即 \bar{x} 的条件分布密度函数为

$$f(\bar{x} | H_k) = \frac{\sqrt{n}}{\sqrt{2\pi}\sigma} e^{-\frac{n(\bar{x}-k)^2}{2\sigma^2}}$$

如图 3.13 所示。




图 3.13 \bar{x} 的条件概率密度函数及判决域的划分

从图可以看出, M 元假设检验的实质是把输入空间划分成 M 个区域, 并在各个区域判决相应的假设为真。

本章小结

本章主要介绍 5 种判决准则, 它们都属于似然比检验, 表达式均为

$$l(x) = \frac{f(x | H_1)}{f(x | H_0)} \underset{H_0}{\overset{H_1}{\geq}} l_0$$

只是所取门限值 l_0 不同而已。

(1) 最大后验概率准则和最小错误概率准则的门限值 $l_0 = \frac{P(H_0)}{P(H_1)}$;

(2) 最小风险 Bayes 准则的门限值 $l_0 = \frac{(C_{10} - C_{00})P(H_0)}{(C_{01} - C_{11})P(H_1)}$;

(3) 极大极小准则的门限值 $l_0 = \frac{(C_{10} - C_{00})q_0}{(C_{01} - C_{11})(1 - q_0)}$;

(4) Neyman-Pearson 准则的门限值 $l_0 = \lambda$, 即拉格朗日乘数。

其中, 除 Bayes 准则外, 其余 4 种准则都可以看作 Bayes 准则的派生准则或特例。

(1) 最大后验概率准则是从信息论观点出发, 后验概率谁大谁为真的准则, 等效为 $C_{10} - C_{00} = C_{01} - C_{11}$ 条件下的 Bayes 准则。

(2) 最小错误概率准则是假设正确判决不花代价 ($C_{00} = C_{11} = 0$), 错误判决代价相等 ($C_{01} = C_{10} = 1$) 条件下的 Bayes 准则, 也称为理想观测者准则。

(3) 极大极小准则是使可能出现的最大风险极小化的一种判决准则, 是选择最不利先验概率的 Bayes 准则。

(4) Neyman-Pearson 准则是给定虚警概率情况下, 使漏报概率尽可能小的判决准则, 等效为 $C_{00} = C_{11} = 0, C_{10}P(H_0) = \lambda, C_{01}P(H_1) = 1$ 条件下的 Bayes 准则。

另外, 这 5 种判决准则的适用范围不同。

(1) 当先验概率和代价函数均已知时, 使用 Bayes 准则;

(2) 当先验概率已知, 代价函数未知时, 使用最大后验概率准则或最小错误概率准则;

(3) 当先验概率未知, 代价函数已知时, 使用极大极小准则;

(4) 当先验概率和代价函数均未知时, 使用 Neyman-Pearson 准则。

因此, 在使用过程中, 要根据实际情况和给定条件, 综合分析, 选择使用。

思考题

1. 最大后验概率准则和最小错误概率准则为何称为理想观测者准则?
2. 极大极小准则中的 q_0 如何求得?
3. 如何确定 Neyman-Pearson 准则中的拉格朗日乘数 λ ?
4. 试述最大后验概率准则、Bayes 准则、最小错误概率准则、极大极小准则和 Neyman-Pearson 准则的异同点。
5. 如何理解最大后验概率准则、最小错误概率准则、极大极小准则和 Neyman-Pearson 准则都是 Bayes 准则的特例?

习题

1. 在二元数字通信系统中, 发送端等概发送 2V 和 0V 的脉冲信号, 信道上叠加的噪声服从均值为零, 方差为 σ^2 的正态分布, 试用最大后验概率准则对接收信号进行判决。

2. 在存在加性噪声的情况下, 测量只能为 1V 或 0V 的直流电压。设噪声均值为 0, 均方根电压为 $\sigma = 2V$, 代价函数为 $C_{01} = 2, C_{10} = 1, C_{00} = C_{11} = 0$ 。信号存在的先验概率 $P =$