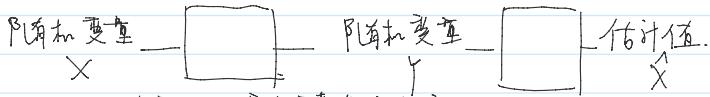


信息论与数据估计

2020年4月3日 0:09

1. 故障模型的建立.

通信中，我们进行数据估计通常走在信道中。一般是编码、传输、译码。那么由于无线信道环境一般会引起误码。通信框图。一般如下。



那么我们通过这个模型可以定义错误概率

$$P_e = \Pr\{Y \neq X\}$$

2. Fano 不等式

我们希望通过信息化对错误进行度量，因此我们有一个非常经典的不等式。Fano不等式。原理如下：

对于任意估计 \hat{X} ，满足 $X \rightarrow Y \rightarrow \hat{X}$ 且 $P_e = \Pr\{X \neq \hat{X}\}$

$$H(P_e) + P_e \log |X| \geq H(X|\hat{X}) \geq H(X|Y)$$

这个原理的证明也是非常巧妙的。

证明如下：

① 首先我们定义一个针对二进制的差分码 $E = \begin{cases} 0, & X = \hat{X} \\ 1, & X \neq \hat{X} \end{cases}$

$$\text{那么 } H(E) = H(P_e) = P_e \log \frac{1}{P_e} + (1-P_e) \log \frac{1}{1-P_e}$$

$$H(E, X|\hat{X}) = H(X|\hat{X}) + H(E|\hat{X}, X), \quad \text{已知 } X \text{ 和 } \hat{X} \text{ 已知，那么 } E \text{ 也已知。} \quad \text{且 } H(E|\hat{X}, X) = 0.$$

已知 X , E 不知道 \hat{X} . 因为 X 有很多个。

$$H(E, X|\hat{X}) = H(E|\hat{X}) + H(X|\hat{X}, E) = H(E|\hat{X}) + P_e H(X|\hat{X}, X \neq \hat{X}) + (1-P_e) H(X|\hat{X}, X = \hat{X})$$
$$\leq H(P_e) + P_e H(X|\hat{X}, X \neq \hat{X}) \leq H(P_e) + P_e \log |X|. \quad \text{于是第一部分得证}$$

② $H(X|\hat{X}) = H(X) - I(X; \hat{X}) \quad H(X|Y) = H(X) - I(X; Y)$

要证 $I(X; \hat{X}) \geq I(X; Y)$ 即证 $I(X; Y) \leq I(X; \hat{X})$

对此我们也有一个很巧妙的证明，利用互信息不可加性

$$I(X; Y, \hat{X}) = I(X; Y) + I(X; \hat{X}|Y) \quad \text{且 } I(X; Y, \hat{X}) = I(X; \hat{X}) + I(X; Y|\hat{X})$$

那么互信息是大于等于0的。但 $I(X; \hat{X}|Y) = 0$ 。因为在 Y 已知的前提下， X 和 \hat{X} 是两个独立的事情。所以有 $I(X; \hat{X}) \geq I(X; Y)$ ，因为 $I(X; Y) \geq I(X; \hat{X})$

那么整个 Fano 不等式证明了这样一件事，数据越处理，互信息只会减少。信息熵会增大。而我们面对的也有一个上界即 $H(P_e) + P_e \log |X|$ 。