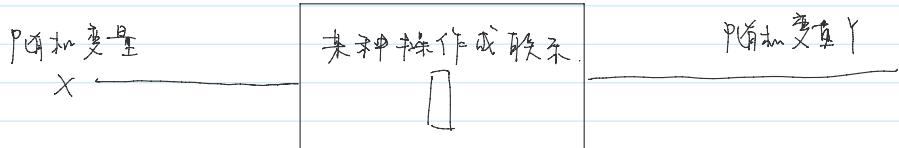


互信息

2020年3月30日 16:39

1. 定义

事物是普遍存在的联系。作为通信工程，我们也很关心当一组信号通过系统后，信息量被消除了多少。



- 单独观察 X ，得到的信息量是 $H(X)$
- 已知 Y 后，观察 X ，得到的信息量是 $H(X|Y)$
- $H(X) - H(X|Y)$ 就是信息的减少量，定义为互信息

定义离散随机变量 X 与 Y 之间的互信息为 $I(X;Y) = H(X) - H(X|Y)$ ，那么 X 和 Y 之间的互信息理应是一种对称公理，因为这 X 和 Y 之间的关系是一致的。

也即 $I(X;Y) = H(X) - H(X|Y) = H(Y) - H(Y|X)$
我们可以简单地推导一下：

$$\begin{aligned} I(X;Y) &= H(X) - H(X|Y) = -\sum_{x \in X} p_x \log p_x + \sum_{x \in X} \sum_{y \in Y} p(x,y) \log p(x,y) \\ &= \sum_{x \in X} \sum_{y \in Y} p(x,y) \log \frac{p(x,y)}{p(x)} = \sum_{x \in X} \sum_{y \in Y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)} \end{aligned}$$

从数学表达形式上来说，互信息也相对精确，这也间接证明了信息论在数学模型上的正确性。

或者说 $I(X;Y) = H(X) - H(X|Y) = H(X) - [H(X+Y) - H(Y)] = H(Y) + H(X) - H(X+Y)$

即互信息是两个信息熵之和减去两个的联合信息熵：

(这是结论从直觉上是比较直观且重要的。 $H(X+Y)$ 代表了我们不知道 X 和 Y 之间的关联的信息量，而 $H(X+Y)$ 是指我们知道 X 和 Y 之间的关联信息量。两者左侧都是信息的减少量，所以进一步分析会发现，在直觉上也是成立的。

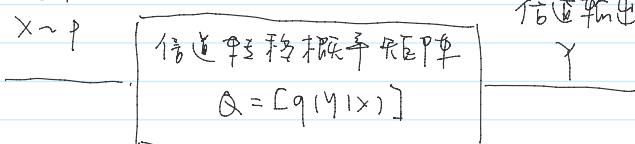
我们还可以举个例子。

若 X, Y 独立，则互信息为 0。

若 X, Y 一脉同分布，则 $I(X;Y) = H(X)$ 因为 $H(X) = H(Y)$ ，知道了 X 的话， Y 对我们而言无信息量。

我们也可以从通信的角度观察互信息。

信道输入。



$$I(X;Y) = \sum_{x \in X} \sum_{y \in Y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)}$$

$$= \sum_{x \in X} \sum_{y \in Y} p(x,y) q(y|x) \log \frac{q(y|x)}{\sum_{y \in Y} p(x,y) q(y|x)}$$

$I(X;Y)$ 也可以代表信道的传输能力，若误码率较低，互信息则较大，那就越大则为 $H(X)$ ，也就是说信道是有容量的。 $H(X)$ 是一个上凸函数，有最大值。

换句话说，我们在信道给定的情况下，可以通过设计 $P(X)$ 达到最大的互信息。那么我们考虑的问题就是互信息的凸优化问题。

对于多变量的情况，例如：

$$I(X;Y,Z) = H(X) - H(X|Y,Z) = H(Y,Z) - H(Y,Z|X)$$
，这是从定义出发的。

也可以展开计算

$$\begin{aligned} I(X;Y,Z) &= \sum_{x \in X} \sum_{y \in Y} \sum_{z \in Z} p(x,y,z) \log \frac{p(x,y,z)}{p(x)p(y)p(z)} \\ &= H(Y,Z) + H(X) - H(X|Y,Z) = H(Y) + H(Z|Y) + H(X) - H(X|Y,Z) \end{aligned}$$

我们还可以定义条件互信息. 例如:

$$I(X;Y|Z) = H(X|Z) - H(X|Y,Z) = H(Y|Z) - H(Y|X,Z)$$

或

$$I(X;Y|Z) = \sum_{x \in X} \sum_{y \in Y} \sum_{z \in Z} P(x,y,z) \log \frac{P(x,y|z)}{P(x|z)P(y|z)}.$$

即

$$\begin{aligned} I(X;Y|Z) &= H(X|Z) + H(Y|Z) - H(X,Y|Z) \\ &= H(X|Z) - H(Z) + H(Y|Z) - H(Z) - H(X,Y|Z) + H(Z) \\ &= H(X|Z) + H(Y|Z) - H(X,Y|Z) - H(Z) \end{aligned}$$

即 X, Y 在已知 Z 时互信息减少, 或者说信息熵减小, 从而得到条件下互信息.

这里稍微思考一下可以直接受出. 我们对于他的理解并不深刻.

我们还可以发现条件互信息非负, 且 $I(X;Y)$ 和 $I(X;Y|Z)$ 没有确定的不等式关系. 条件减少熵, 但不能减少熵的差值.

2. 性质.

首先总结一下简单性质. 介绍定义时也已经推导过.

i). 对称性.

$$I(X;Y) = I(Y;X)$$

2). 非负性

$$I(X;Y) \geq 0$$

3). 极值性.

$$I(X;Y) \leq \min(H(X), H(Y))$$

4). 可加性

$$I(X_1, X_2, \dots, X_n; Y) = \sum_{i=1}^n I(X_i; Y | X_1, \dots, X_{i-1})$$

简单证明:

设没有一定信息熵的可加性.

$$H(X_1, X_2, \dots, X_n) = \sum_{i=1}^n H(X_i | X_1, \dots, X_{i-1})$$

从定义出发.

$$\begin{aligned} I(X_1, \dots, X_n; Y) &= H(X_1, \dots, X_n) - H(X_1, \dots, X_n | Y) \\ &= \sum_{i=1}^n H(X_i | X_1, \dots, X_{i-1}) - \sum_{i=1}^n H(X_i | X_1, \dots, X_{i-1}, Y) \\ &= \sum_{i=1}^n H(X_i | X_1, \dots, X_{i-1}) - H(X_i | X_1, \dots, X_{i-1}, Y) \\ &= \sum_{i=1}^n I(X_i; Y | X_1, \dots, X_{i-1}) \end{aligned}$$

通俗的语言来说, 互信息可以分步积累.

3. 互信息的凸性.

之前我们得出适用于通信模型的互信息数学结果, 指出了其在语言和信息优化方向, 这里我们尝试用凸优化来解决一下这个问题.

$$I(X;Y) = I(P;Q) = \sum_{x \in X} \sum_{y \in Y} P(x) Q(y|x) \log \frac{Q(y|x)}{\sum_{y \in Y} P(x) Q(y|x)}$$

我们分两种情况讨论.

① 讨论语言: 即固定 $Q(y|x)$

我们分两种情况讨论。

① 讨论信道：即固定 $q(y|x)$

$$I(x;Y) = H(Y) - H(Y|X) = H(Y) - \sum_{x \in X} P(x) H(Y|X=x)$$

第一项 $H(Y)$ 我们在讨论信息熵时已经讨论过是 $P(Y)$ 上的凸函数，由于 $q(y|x)$ 给定，也是 $P(x)$ 上的凸函数。

第二项 $H(Y|X) = \sum_{x \in X} P(x) \sum_{y \in Y} q(y|x) \log \frac{1}{q(y|x)}$ 而 $q(y|x)$ 是给定的，那么 $H(Y|X)$ 是关于 $P(x)$ 的线性组合，线性并不算凸函数。

所以，我们证明了 $I(x;Y)$ 也是关于 $P(x)$ 上凸的。那么我们还需要找到 $I(x;Y)$ 的取大值。而这也就被证明了这个凸优化问题，我们在介绍香农第二定律时再详谈。

② 讨论信道，即固定 $P(x)$ ，

$$I(x;Y) = \sum_{x \in X} \sum_{y \in Y} P(x) q(y|x) \log \frac{P(x,y)}{P(x)P(y)}$$

利用对数不等式

$$I(x;Y) = \sum_{x \in X} P(x) \sum_{y \in Y} q(y|x) \log \frac{q(y|x)}{P(y)} \geq \sum_{x \in X} P(x) \log \frac{\sum_{y \in Y} q(y|x)}{1} = 0.$$

所以这是一个下凸函数，我们在证明对数不等式时也证明了。

下凸函数的最优点互信息。即我们可以找到一个单参数矩阵，在下界给定的情况下，设计一个取下界的矩阵矩阵。那么，我们可以当单参数矩阵有成倍数增长时，而互信息最小，而 X 和 Y 未联接起来，即分离很大。我们可以在矩阵中取大失重的情况下，利用下凸特性找到极小化的编码。这也算是香农第三定律，后面会详细展开。

4. 连续随机变量的互信息。

我们采用类似离散分布上推广的方法来计算连续变量的互信息。

$$\begin{aligned} I(X;Y) &= \lim_{\Delta x \rightarrow 0} \sum_{i=-\infty}^{+\infty} \sum_{j=-\infty}^{+\infty} P(x_i, y_j) \Delta x_i \Delta y_j \log \frac{P(x_i, y_j) \Delta x_i \Delta y_j}{P(x_i) \Delta x_i P(y_j) \Delta y_j} \\ &= \iint P(x, y) \log \frac{P(x, y)}{P(x)P(y)} dx dy. \end{aligned}$$

于是我们定义连续随机变量 X, Y 之间的互信息为

$$I(X;Y) = \iint P(x, y) \log \frac{P(x, y)}{P(x)P(y)} dx dy.$$

历史背景说明：

最早的信息熵由 Shannon 在 1948 年的论文中给出。

严格反对子微分熵和连续变量互信息的定义由 Kolmogorov 和 Pinsker 给出。

这使得连续互信息的信道容量有了理论基础。