

1. 随机变量的熵

信息是对不确定性的消除，不确定性越高，消除反而包含的信息量越大，概率越小则信息量越大。根据单点的信噪比越大，同样如果事件的概率为1，则该事件无信息量。如果概率趋近于0，则该事件的信噪比无穷大。

那么，假如有两个独立事件，设为 a_1, a_2 。

(1) 若 $P(a_1) > P(a_2)$, 则 $f(a_1) < f(a_2)$

(2) 若 $P(a_1) = 1$, 则 $f(a_1) = 0$

(3) 若 $P(a_1) = 0$, 则 $f(a_1) = \infty$

(4) 若 a_1, a_2 相互独立，则 $f(a_1, a_2) = f(a_1) + f(a_2)$

通过上述数据递推值的分析，可以发现，对数函数可以满足上述要求，可以设 $I(a_i) = -\log P(a_i) = \log \frac{1}{P(a_i)}$
我们可以从数学上解释一下，该函数为 k 。

即

$$k \cdot \frac{1}{P(a_i)} = I(a_i)$$

可以认为是，用 k 进制的二进制表示，共需要 $\frac{1}{P(a_i)}$ 位。那么这与进制和对应，例如 k 取2时，则可以理解为bit。
以 e 为底，单位称为nat (nature unit)，以 10 为底，单位为hart (Hartley)

$1 \text{ nat} = 1.44 \text{ bit}$, $1 \text{ Hart} = 3.32 \text{ bit}$

$$= \log_2 e \text{ bit} \quad = \log_2 10 \text{ bit} \quad \log_a b = \frac{\log_e b}{\log_e a}, \quad \log_e e = \frac{\log_2 e}{\log_2 2}.$$

那么，我们现在还需要证明他的唯一性。即仅有这种形式可以满足需求。

2. 唯一性证明

对于单一变量，不存在信息量的准确数学形式，但对于一个随机变量 X ，它的信息量的度量却提出了两个外在条件。这也为我们对信息论模型建立所带来条件。

(1) 连续性条件： $f(p_1, p_2, \dots, p_m)$ 应是 p_n 的连续函数。当 p_n 稍微变化时， $f(p_1, \dots, p_m)$ 也应稍微变化。

(2) 线性时为单调增加函数： $f(\frac{1}{n}, \dots, \frac{1}{n}) = g(N)$ 应是 N 的单调函数。

(3) 可加性条件：当随机变量的取值不是通过一次试验，而是若干试验才获得得到时，随机变量在各次试验中不确定应该可加且不影响原有结果。即

$$f(p_1, p_2, \dots, p_N) = f((p_1 + p_2 + \dots + p_K), p_{K+1}, \dots, p_N) + (p_1 + p_2 + \dots + p_K) f(p'_1, p'_2, \dots, p'_K)$$

其中 $p'_i = \frac{p_i}{p_1 + p_2 + \dots + p_K}$ ，即归一化后的 p'_i 。这个等式也适合我们之前觉得一个便于理解的例子。

举个例子，可以将1, 2, 3看做一个整体。那么整个概率分布信息量为 $g(\frac{1}{3})$ ，等于 $-\left(\frac{1}{3}, \frac{1}{6}, \frac{1}{6}, \frac{1}{6}\right)$ 外加“1, 2, 3”的不确定度以及他们作为整体所发生的相关性。这个相关性可以理解为他们归一化的代价。那么总共有 $\frac{1}{2} f(\frac{1}{3}, \frac{1}{3}, \frac{1}{3})$ 。

下面我们开始证明唯一性。首先，假设一个 MN 均匀分布。

$$g(MN) = f(\frac{1}{MN}, \frac{1}{MN}, \dots, \frac{1}{MN})$$

我们利用可加性

$$g(MN) = \underbrace{f(\frac{1}{M}, \frac{1}{M}, \dots, \frac{1}{M})}_{MN} + \sum_{i=1}^M \frac{1}{M} \underbrace{f(\frac{1}{N}, \frac{1}{N}, \dots, \frac{1}{N})}_{N \uparrow} = g(M) + g(N)$$

$$g(s^m) = g(s \cdot s^{m-1}) = g(s) + g(s^{m-1}) \Rightarrow m g(s)$$

那么我们继续假设取 $s, t, n \in \mathbb{N}$. 使 $s^m \leq t^n \leq s^{m+1}$.

由上述条件③，我们可知

$$g(s^m) \leq g(t^n) \leq g(s^{m+1})$$

再根据上述的推导

$$m g(s) \leq n g(t) \leq (m+1) g(s)$$

即除 $m, n, g(s)$ 外

$$\frac{m}{n} \leq \frac{g(t)}{g(s)} \leq \frac{m+1}{n}$$

上下公式变形(可根据概率平理解) $\frac{m}{n} - \frac{g(t)}{g(s)} \leq \frac{m+1}{n} - \frac{g(t)}{g(s)}$

$$\left| \frac{m}{n} - \frac{g(t)}{g(s)} \right| \leq \frac{1}{n} \implies 0 \leq \frac{g(t)}{g(s)} - \frac{m}{n} \leq \frac{1}{n}$$

$$\left| \frac{m}{n} - \frac{g(t)}{g(s)} \right| < \frac{1}{n} \implies 0 \leq \frac{g(t)}{g(s)} - \frac{m}{n} < \frac{1}{n}$$

对于底数大于1的对数函数，我们有：

$$m \log s \leq n \log t < (m+1) \log s,$$

那么同理，我们也可得到不等式

$$\left| \frac{m}{n} - \frac{\log t}{\log s} \right| < \frac{1}{n} \implies 0 \leq \frac{\log t}{\log s} - \frac{m}{n} < \frac{1}{n}$$

将上式缩放。

$$\left| \frac{m}{n} - \frac{g(t)}{g(s)} \right| + \left| \frac{m}{n} - \frac{\log t}{\log s} \right| < \frac{2}{n} \implies \left| \frac{\log t}{\log s} - \frac{g(t)}{g(s)} \right| < \frac{2}{n}. \text{ (这里利用了 } |a \pm b| \leq |a| + |b|).$$

考虑到 n 可以任意大，那么 n 为充分大时，上面不等式也得满足。

$$\lim_{n \rightarrow \infty} \left| \frac{g(t)}{g(s)} - \frac{\log t}{\log s} \right| = 0 \implies g(t) \approx C \log t.$$

上面我们考虑了均匀分布，下面考察 X 是非均匀分布，但是是有理数取值的情况。即 $X = P_X(x)$ ，这里可以简写为 $P(x)$

$$\text{令 } P(m) = \frac{m}{\sum_{i=1}^N m_i} = \frac{m}{N}. \quad (\text{有理数可以用分数表示}) \text{，那么 } g(m) = f\left(\frac{1}{m_1}, \dots, \frac{1}{m_N}\right), \text{ 从个}$$

因为是有限数，可以将 $g(m)$ 用分母 m 表示 $g(m) = f\left(\underbrace{\frac{1}{m_1}, \dots, \frac{1}{m_1}}_{m_1 \uparrow}, \underbrace{\frac{1}{m_2}, \dots, \frac{1}{m_2}}_{m_2 \uparrow}, \dots, \underbrace{\frac{1}{m_N}, \dots, \frac{1}{m_N}}_{m_N \uparrow}\right)$

根据可积性条件。

$$g(m) = f\left(\frac{m_1}{m}, \frac{m_2}{m}, \dots, \frac{m_N}{m}\right) + \sum_{i=1}^N \frac{m_i}{m} g(m_i)$$

$$\Rightarrow f\left(\frac{m}{m_1}, \dots, \frac{m}{m_N}\right) = g(m) - \sum_{i=1}^N \frac{m_i}{m} g(m_i)$$

$$= \log m - \sum_{i=1}^N \frac{m_i}{m} \log m_i$$

$$= c \left[\sum_{i=1}^N \frac{m_i}{m} (\log \frac{m}{m_i}) \right] = -c \sum_{i=1}^N p_i \log p_i,$$

我们可以发现，在均匀分布中也符合这个结论。

最后，我们考虑无理数的情况，无理数的证明，可以利用有理数逼近，然后利用连续性即可得证。

于是，我们已经讨论了所有情况下数学形式，从而证明了不确定度的唯一性。即

$$f(P_X(x)) = - \sum_{i=1}^N p_i \log p_i$$

3. 信息熵

不确定度的数学形式和热力学熵的数学形式是一致的，因为不确定度也被定义为信息熵。在信号下一分布中（固体物理初步知识的一部分），我们简单地到了熵的表达式：热量从有序到无序的，也就是熵增加。而我们所处理的信息也是由外界一部分，从无噪声逐渐变为有噪声（这也符合熵增原理论）。所以用熵来定义也很合理。数学上我们证明了这一点。

在热力学中有一个著名的谬论即麦克斯韦佯谬。Landau 提出：“麦克斯韦妖在减少绝对系统熵的时候所需要的能量输出不少于热力学熵的减少量”，从而引发了这个谬论。这个例子也说明了信息熵和热力学熵的一致性。

3.1 定义

我们这里用较为严格地数学语言定义它。

高斯随机变量 X 的信息熵 $H(X)$ 定义为

$$H(X) = - \sum_{x \in X} P(x) \log P(x)$$

对于 $\log 0$ ， $\lim_{x \rightarrow 0} x \log x = 0$. 零概率不影响力的熵为零。均匀分布时，信息熵最大。

3.2 联合熵

对于一个随机变量 X ，我们定义 $H(X)$ ，很自然的我们可以推广到两个随机事件。那么就得到了联合熵。例如对于一对高斯随机变量 (X, Y) 的联合熵定义为

$$H(X, Y) = - \sum_{x \in X} \sum_{y \in Y} P(x, y) \log P(x, y)$$

信息熵的大小与两个随机变量的信息熵之和不一定是相等的。如果两个事件相互独立，那么则相等。即

$$H(X, Y) = -\sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y)$$

联合熵的大小与两个随机变量的信息熵之和不一定是相等的。如果两个事件相互独立，那么则相等。即

$$H(X, Y) = H(X) + H(Y) \quad (\text{这个在数学上由概率论证明。只要将 } p(x, y) = p(x)p(y) \text{ 代入即可。})$$

如果两个事件不独立的话，则存在一定的相关性（需要注意的是这与相关系数没有关系，相关系数表示的是线性相关），那么

$$H(X, Y) < H(X) + H(Y)，因为当我知道到X时，就已经获取到了部分Y，相当于减少了Y的信息量，所以联合熵会偏小。$$

如果我们想划等号的话 $p(x, y) = p(x) \cdot p(y|x)$ 或 $p(x, y) = p(y) \cdot p(x|y)$ 则一直成立。这时我们可以引出条件熵的概念。

3.3 条件熵

我们希望得到 $H(X, Y) = H(X) + H(Y|X) = H(Y) + H(X|Y)$ 这样的结果。那么我们可以根据条件概率来推导条件熵的数学形式。

$$\begin{aligned} H(X, Y) &= -\sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y) \quad (\text{代入 } p(x, y) = p(x) \cdot p(y|x)) \\ &= -\sum_{x \in X} \sum_{y \in Y} p(x, y) [\log p(x) + \log p(y|x)] \\ &= -\sum_{x \in X} \sum_{y \in Y} p(x) \cdot p(y|x) \cdot \log p(x) - \sum_{x \in X} \sum_{y \in Y} p(x) \cdot p(y|x) \log p(y|x) \\ &= \sum_{x \in X} p(x) \log p(x) \left[\sum_{y \in Y} p(y|x) \right] - \sum_{x \in X} \sum_{y \in Y} p(x) p(y|x) \log p(y|x), \quad \sum_{y \in Y} p(y|x) = 1. \end{aligned}$$

那么第一项即为 $H(X)$ ，第二项即为 $H(Y|X)$ 。

我们给出他们的精确定义：

若 $(X, Y) \sim P(x, y)$ ，则条件熵定义为 $H(Y|X) = -\sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(y|x) = -\sum_{x \in X} p(x) \sum_{y \in Y} p(y|x) \log p(y|x)$ 。

我们同样把 $-\sum_{y \in Y} p(y|x) \log p(y|x)$ 记做 $H(Y|X=x)$ 。

而 $H(Y|X)$ 并不是 $H(Y|X=x)$ ，需要注意。

有了基础的条件熵的精确定义，我们可以继续深入进行推广。

$$(1) \quad H(X, Y|Z) = H(X|Z) + H(Y|X, Z)$$

简单证明一下。 $H(X) = -E[\log p(x)]$

$$P(X, Y|Z) = P(X|Z) \cdot P(Y|X, Z)$$

$$\log P(X, Y|Z) = \log P(X|Z) + \log P(Y|X, Z)$$

$$\Rightarrow H(X, Y|Z) = H(X|Z) + H(Y|X, Z)$$

[说明] 通过对数函数的性质分布的数学结论从乘法变为加法。而信息熵则可以认为是对真平均数平均。

这个加权平均都可以认为是联合真平均数加权平均，所以类似以上结论都成立，这样就满足了可加性。联合观察必须等于逐次观察。

(2) 离散型变量 X_1, X_2, \dots, X_n 满足分布 $P(X_1, X_2, \dots, X_n)$ ，则

$$H(X_1, X_2, \dots, X_n) = \sum_{i=1}^n H(X_i | X_{i-1}, X_{i-2}, \dots, X_1)$$

这也叫互加性。

在通信中， X_1, \dots, X_n 通常也是依次到达的。我们也可以根据可加性做次序性的检测。每次只观察最新的一个信号即可。

若 X, Y 相互独立。那么 $p(x, y) = p(x)p(y)$ 有 $H(X, Y) = H(X) + H(Y)$ ，之后也证明过。

3.4 信息熵的性质

1). 对称性。

$$H(p_1, p_2, \dots, p_n) = H(p_{k(1)}, p_{k(2)}, \dots, p_{k(n)})$$

信息熵是关于平均分布的对称性，并不关于信息源本身。这也是经典信息论的核心思路。

2). 非负性

熵的最小值为0，即为概率为1的时候

3). 可加性

$$H(X, Y) = H(X) + H(Y|X) \quad (\text{即为上述的(1)})$$

4). 条件减小性。

$$H(X|Y) \leq H(X)$$

对于两个不相关的事件，由于它们的相关性，事件的可加性不再成立。这对单向信道和双工信道都有影响。

4. 条件减小熵

$$H(X|Y) \leq H(X)$$

这蕴含两个直觉：知道了统计相关性的变量，就可以减少不确定度。统计平均意义上减少不确定度但是有时某一个取值不一定。从哲学上来说，事物是广泛关联的。但是不要求着 $H(X|Y) \leq H(X)$
因为对于具体的信息来说，有可能使 $P(X|Y)$ 在既定系统减小从而使信息量增大。例如不可能事件。

若设 P 为概率分布时，熵取得最大值，也是熵增加，之所以叫热力学，那 p_m 是一定满足这个结论的。
我们是要在数学上证明。即：

$$H(P_1, P_2, \dots, P_N) \leq H\left(\frac{1}{N}, \frac{1}{N}, \dots, \frac{1}{N}\right) = \log N = \log |X| = G(N)$$

我们可以借助数学分析来——凸集，这部分内容会放在数学部分。这里就直接应用其数学结论了。

证明过程如下：

我们已经推导了概率分布具有凸性，那仅需证明 $H(x)$ 是下凸函数即可。

$$\begin{aligned} & H(\vec{P}_1 + (\lambda - \lambda)\vec{P}_2) = \lambda H(\vec{P}_1) + (1 - \lambda)H(\vec{P}_2) \\ &= -\sum_{n=1}^N \left\{ [x p_{1n} + (1 - \lambda)p_{2n}] \log [x p_{1n} + (1 - \lambda)p_{2n}] + \lambda \sum_{n=1}^N p_{1n} \log p_{1n} + (1 - \lambda) \sum_{n=1}^N p_{2n} \log p_{2n} \right\} \\ &= \sum_{n=1}^N x p_{1n} \log \frac{p_{1n}}{\lambda p_{1n} + (1 - \lambda)p_{2n}} + \sum_{n=1}^N (1 - \lambda)p_{2n} \log \frac{p_{2n}}{\lambda p_{1n} + (1 - \lambda)p_{2n}}. \end{aligned}$$

$$\text{由 } \lim_{x \rightarrow 0^+} \frac{\log a^{1+x}}{x} = \lim_{x \rightarrow 0^+} \log a^{(1+x)^{\frac{1}{x}}} = \log a^e = 1/\ln a \Rightarrow \log x \sim \frac{1}{\ln^2(x-1)} \Rightarrow \log x \leq \frac{1}{\ln^2(x-1)}$$

$$\text{代入上式} \quad \geq \sum_{n=1}^N x p_{1n} \cdot \frac{1}{\ln^2} \left[1 - \frac{\lambda p_{1n} + (1 - \lambda)p_{2n}}{p_{1n}} \right] + \sum_{n=1}^N (1 - \lambda)p_{2n} \cdot \frac{1}{\ln^2} \left[1 - \frac{\lambda p_{1n} + (1 - \lambda)p_{2n}}{p_{2n}} \right]$$

$$\geq -\frac{1}{\ln^2} \sum_{n=1}^N x p_{1n} + (1 - \lambda)p_{2n} - (\lambda + 1 - \lambda) \left[x p_{1n} + (1 - \lambda)p_{2n} \right]$$

$$\log \frac{1}{x} \geq \frac{1}{\ln^2(1-x)}$$

∴ 0.

于是我们证明了熵函数具有凸性。即 $H(p)$ 是上凸函数，那我们可以直接利用上凸函数 Jensen 不等式

$$H(E[X]) \geq E[H(x)]$$

等于在等概率时取到最大值

3.5 从离散到连续

这件事我们在概率论与数理统计已经帮我们完成了。就运用黎曼积分无穷小法求解。那下面将用定积分

$$H(X) = -\sum_k p(x_k) \Delta x \log p(x_k) \Delta x = -\sum_k p(x_k) \log p(x_k) \cdot \Delta x = -\int_{-\infty}^{+\infty} [p(x_k) \log \Delta x]. \Delta x.$$

$$= -\int p(x) \log p(x) dx - \int_{x \rightarrow -\infty}^{x \rightarrow +\infty} \log \Delta x dx = h(x) + \infty$$

这也与直觉一致，例如又的信息量无穷大。无论用多少个比特我们都无法表示清楚。

看概率论对这一问题提出了一个公理化的概念

$$\text{微分熵} \quad h(x) = \int_{-\infty}^{+\infty} p(x) \log p(x) dx.$$

从这个定义还可以推广于广义：

$$\text{联合熵} \quad h(x, y) = -\iint p(x, y) \log p(x, y) dx dy.$$

$$\text{条件熵} \quad h(x|y) = -\iint p(x, y) \log p(x|y) dx dy = -\int p(y) \int p(x|y) \log p(x|y) dx dy.$$

以及一些制关系。

$$h(x, y) = h(x) + h(y|x) = h(y) + h(x|y)$$

$$h(x|y) \leq h(x), \quad h(y|x) \leq h(y), \quad h(x, y) \leq h(x) + h(y)$$

但互信息可能为负值。因为他并不是信息熵。例如。

$$h(X|Y) \leq h(X), \quad h(Y|X) \leq h(Y), \quad h(X,Y) \leq h(X) + h(Y)$$

但是随机熵可能为负值. 因为他并不是信息熵. 例如.

$$X: p(x) = \begin{cases} \frac{1}{b-a} & a \leq x \leq b, \quad b-a < 1. \\ 0, & x > b, \quad x < a. \end{cases}$$

$$H(h(X)) = - \int_a^b \frac{1}{b-a} \log \frac{1}{b-a} dx = \log(b-a) < 0.$$

我们可以发现连续随机变量 $p(x)$ 不一定大于等于 1.

还有一个重要的分布是高斯分布.

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

那么我们直接代入公式计算.

$$\begin{aligned} h(X) &= - \int_{-\infty}^{+\infty} p(x) \log \left[\frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] \right] dx. \\ &= - \int_{-\infty}^{+\infty} p(x) \log \frac{1}{\sqrt{2\pi\sigma^2}} dx - \int_{-\infty}^{+\infty} p(x) \log \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right] dx. \\ &= \log \sqrt{2\pi\sigma^2} + \log e \int_{-\infty}^{+\infty} p(x) \frac{(x-\mu)^2}{2\sigma^2} dx. \\ &= \log \sqrt{2\pi\sigma^2} + \frac{1}{2} \log e^2 = \frac{1}{2} \log 2\pi e^{\sigma^2} \end{aligned}$$

这个公式的重难点在于第二项的计算. 连续变量是高斯分布, 那么应取常数正态分布的均值无关. 只有方差有关. 在通信系统中, 方差和功率谱密度是紧密相关的. 那么一个连续的高斯分布的随机变量只与他的功率有关.

由此我们还有一个定理

若给定连续随机变量 X 的均值 μ 与方差 σ^2 , 则当其服从高斯分布时. 互信息熵最大.

证明如下:

设 $p(x)$ 为满足均值为 μ . 方差为 σ^2 的高斯分布的概率密度函数 (PDF), 设为随机变量 Y .

$q(x)$ 为满足均值为 μ . 方差为 σ^2 的任意分布的 PDF. 设为随机变量 Z .

我们直接计算. 这里实际上也体现了信息论与概率论的密切关系. 冬雷凌写的能向多体论讲义

$$H(Z) = - \int_{-\infty}^{+\infty} q(z) \log q(z) dz = H(Y) - H(Y) + H(Z)$$

$$= H(Y) - [H(Y) - H(Z)]$$

$$H(Y) - H(Z) = - \int_{-\infty}^{+\infty} q(y) \log q(y) dy - \int_{-\infty}^{+\infty} p(y) \log p(y) dy.$$

对于高斯分布, 我们可以证明:

$$- \int_{-\infty}^{+\infty} q(y) \log p(y) dy = - \int_{-\infty}^{+\infty} q(y) \log \frac{1}{\sqrt{2\pi\sigma^2}} dy + \log e \int_{-\infty}^{+\infty} q(y) \frac{(y-\mu)^2}{2\sigma^2} dy = \frac{1}{2} \log 2\pi e^{\sigma^2} = H(Y)$$

于是,

$$H(Y) - H(Z) = \int_{-\infty}^{+\infty} q(y) \log \frac{p(y)}{q(y)} dy \leq \int_{-\infty}^{+\infty} q(y) \left(\frac{p(y)}{q(y)} - 1 \right) dy = 0.$$

得证.

我们称 $\int_{-\infty}^{+\infty} q(y) \log \frac{p(y)}{q(y)} dy = -D(q||p)$ 为相对熵或散度.

丁学进

我们有 $\int_{-\infty}^{+\infty} q(x) \log \frac{p(x)}{q(x)} dx$ 为 $-D(q||p)$ 即为嫡的定义.

这也说明了 $I(X) = \log |X| - D(p||q)$, 对于连续变量的推广。这个道理也与热力学第二定律有相同的地方，值得深思。