

第 1 讲 熵

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

- ▶ T. M. Cover and J. A. Thomas, Elements of Information Theory, 2.1-2.5.
- ▶ R. W. Yeung, Information and Network Coding, 2.2-2.4.
- ▶ F. Alajaji, P. Chen, An Introduction to Single-User Information Theory, 2.1-2.3.
- ▶ Y. Polyanskiy, Y. Wu, Information Theory: from Coding to Learning, 1.1, 2.1, 3.1.

熵

联合熵与条件熵

相对熵与互信息


熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

课本 P25 习题 2.7

- ▶ 假定有 n 枚硬币, 可能有一枚或者没有假币.
- ▶ 如果是假币, 那么它的重量要么重于其它的硬币, 要么轻于其它的硬币.
- ▶ 我们有一个没有砝码的天平, 希望借助它能够找出假币.

12 枚硬币的情形



熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

- ▶ 熵是随机变量不确定度的度量.
- ▶ 设 X 是一个离散型的随机变量, 其字母表 (即概率论中的取值空间) 为 $\mathcal{X}$, 概率密度函数 $p(x) = \Pr(X = x)$, $x \in \mathcal{X}$.
- ▶ 为方便起见, 记概率密度函数为 $p(x)$ 以代替 $p_X(x)$.
- ▶ 由此, $p(x)$ 和 $p(y)$ 指两个不同的随机变量, 实际上分别表示两个不同的概率密度函数 $p_X(x)$ 和 $p_Y(y)$.

定义 1.1

一个离散型随机变量 X 的熵 $H(X)$ 定义为

$$H(X) = - \sum_{x \in \mathcal{X}} p(x) \log p(x).$$

有时也将上面的量记为 $H(p)$. 其中对数的底是 2, 熵的单位用比特表示. 由于当 $x \rightarrow 0$ 时, $x \log x \rightarrow 0$, 今后我们约定 $0 \log 0 = 0$.

- ▶ 熵 (entropy) 一词源自于希腊语中的 entropia, 其意思为转折点, 变化. 熵的概念是由德国物理学家克劳修斯于 1865 年所提出.
- ▶ 物理学家玻尔兹曼于 1870 年将熵的概念引入统计力学.
- ▶ 1923 年, 德国科学家普朗克来中国讲学. 讲学时用到 “entropy” 一词, 胡刚复先生在翻译时灵机一动, 把 “商” 字加火旁来意译此词, 创造了 “熵” 字.
- ▶ 胡刚复先生说, 此名词的物理含意深奥须多字翻译, 又不合汉字规范, 于是他建议译成一个汉字 “熵”. 火代表与热学有关, 含义为温度 T 与热量 Q 之商, 熵读如商.
- ▶ 在 1948 年, 克劳德·艾尔伍德·香农将热力学的熵, 引入到信息论, 因此它又被称为香农熵 (Shannon entropy).

熵

联合熵与条件熵


相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

克劳德·艾尔伍德·香农（英语：Claude Elwood Shannon, 1916 年 4 月 30 日—2001 年 2 月 24 日），美国数学家、电子工程师和密码学家。香农 1936 年于密歇根大学获学士学位，1940 年于麻省理工学院获得博士学位。其在 1948 年发表了划时代的论文——《通信的数学理论》，这篇论文奠定了现代信息论的基础。香农还被认为是数字计算机理论和数字电路设计理论的创始人。

推荐读物：Jimmy Soni and Rob Goodman, A Mind at Play: How Claude Shannon Invented the Information Age, Simon and Schuster, 2017. (有中译本, 香农传, 中信出版社, 2019.)



熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

- ▶ 如果使用底为 b 的对数, 则相应的熵记为 $H_b(X)$. 当对数底为 e 时, 熵的单位用**奈特** (nat) 表示.
- ▶ 如无特别声明, 一般选取对数底为 2.
- ▶ 注意, 熵实际上是随机变量 X 的分布的泛函, 并不依赖于 X 的实际取值, 而仅依赖于其概率分布.
- ▶ 用 E 表示数学期望. 如果 $X \sim p(x)$, 则随机变量 $g(X)$ 的期望值可以表示为

$$E_p g(X) = \sum_{x \in \mathcal{X}} g(x) p(x).$$

- ▶ 特别地, 当 $g(X) = \log \frac{1}{p(X)}$ 时, $E_p g(X)$ 就是 X 的熵.

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

引理 1.2

$$H(X) \geq 0.$$

证明.

由 $0 \leq p(x) \leq 1$ 知 $\log\left(\frac{1}{p(x)}\right) \geq 0$.

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的
关系熵, 相对熵与互信
息的链式法则

引理 1.3

$$H_b(X) = (\log_b a) H_a(X).$$

证明.

由 $\log_b p = (\log_b a) \log_a p$ 即可得到.

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

例 1.4

设

$$X = \begin{cases} 1 & \text{概率为 } p \\ 0 & \text{概率为 } 1 - p. \end{cases}$$

于是

$$H(X) = -p \log p - (1 - p) \log(1 - p) =: H(p).$$

例 1.5

设

$$X = \begin{cases} a & \text{概率为 } \frac{1}{2} \\ b & \text{概率为 } \frac{1}{4} \\ c & \text{概率为 } \frac{1}{8} \\ d & \text{概率为 } \frac{1}{8} \end{cases}$$

则 X 的熵为

$$H(X) = -\frac{1}{2} \log \frac{1}{2} - \frac{1}{4} \log \frac{1}{4} - \frac{1}{8} \log \frac{1}{8} - \frac{1}{8} \log \frac{1}{8} = \frac{7}{4} \text{ 比特.}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

下面例子说明随机变量的熵可以是无穷的.

例 1.6: 课本习题 2.19

设 $A = \sum_{n=2}^{\infty} (n \log^2 n)^{-1}$. 定义随机变量 X 满足 $\Pr(X = n) = (An \log^2 n)^{-1}$, 其中 $n = 2, 3, \dots$, 则 $H(X) = +\infty$.

证明.

由定义, $p_n = \Pr(X = n) = 1/An \log^2 n$, $n \geq 2$. 于是

$$\begin{aligned}
 H(X) &= - \sum_{n=2}^{\infty} p(n) \log p(n) \\
 &= - \sum_{n=2}^{\infty} (1/An \log^2 n) \log(1/An \log^2 n) \\
 &= \sum_{n=2}^{\infty} \frac{\log(An \log^2 n)}{An \log^2 n} \\
 &= \sum_{n=2}^{\infty} \frac{\log A + \log n + 2 \log \log n}{An \log^2 n} \\
 &= \log A + \sum_{n=2}^{\infty} \frac{1}{An \log n} + \sum_{n=2}^{\infty} \frac{2 \log \log n}{An \log^2 n}.
 \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

证明.

和式中第一项是有限的. 由于我们考虑对数以 2 为底, 最后一项中每一项均是非负的. 对于中间项, 我们有

$$\sum_{n=2}^{+\infty} \frac{1}{An \log n} > \int_2^{\infty} \frac{1}{Ax \log x} dx = K \ln \ln 2 \Big|_2^{\infty} = +\infty,$$

其中 $K = \frac{\ln 2}{A}$. 从而我们有 $H(X) = +\infty$. □

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

定义 2.1

对于服从联合分布为 $p(x, y)$ 的一对离散随机变量 (X, Y) , 其**联合熵** $H(X, Y)$ (joint entropy) 定义为

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

上式亦可表示为

$$H(X, Y) = -E \log p(X, Y).$$

一般地, 对于 n 个随机变量 $X_1, \dots, X_n$, 它们的联合熵定义为

$$H(X^n) = \sum_{x_1} \cdots \sum_{x_n} p(x_1, \dots, x_n) \log \frac{1}{p(x_1, \dots, x_n)}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定义 2.2

若 $(X, Y) \sim p(x, y)$, 条件熵 $H(Y|X)$ 定义为:

$$H(Y|X) = \sum_{x \in \mathcal{X}} p(x) H(Y|X = x)$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定义 2.3

若 $(X, Y) \sim p(x, y)$, 条件熵 $H(Y|X)$ 定义为:

$$\begin{aligned} H(Y|X) &= \sum_{x \in \mathcal{X}} p(x) H(Y|X = x) \\ &= - \sum_{x \in \mathcal{X}} p(x) \sum_{y \in \mathcal{Y}} p(y|x) \log p(y|x) \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定义 2.4

若 $(X, Y) \sim p(x, y)$, 条件熵 $H(Y|X)$ 定义为:

$$\begin{aligned} H(Y|X) &= \sum_{x \in \mathcal{X}} p(x) H(Y|X = x) \\ &= - \sum_{x \in \mathcal{X}} p(x) \sum_{y \in \mathcal{Y}} p(y|x) \log p(y|x) \\ &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(y|x) \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定义 2.5

若 $(X, Y) \sim p(x, y)$, 条件熵 $H(Y|X)$ 定义为:

$$\begin{aligned}
 H(Y|X) &= \sum_{x \in \mathcal{X}} p(x) H(Y|X = x) \\
 &= - \sum_{x \in \mathcal{X}} p(x) \sum_{y \in \mathcal{Y}} p(y|x) \log p(y|x) \\
 &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(y|x) \\
 &= -E \log p(Y|X).
 \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的
关系熵，相对熵与互信
息的链式法则**定理 2.6: 链式法则**

$$H(X, Y) = H(X) + H(Y|X).$$

证明.
我们有

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

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的
关系熵, 相对熵与互信
息的链式法则

证明.
我们有

$$\begin{aligned} H(X, Y) &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(x, y) \\ &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log(p(x)p(y|x)) \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的
关系熵, 相对熵与互信
息的链式法则

证明.
我们有

$$\begin{aligned}
 H(X, Y) &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(x, y) \\
 &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log(p(x)p(y|x)) \\
 &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(x) - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(y|x)
 \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

证明.
我们有

$$\begin{aligned}
 H(X, Y) &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(x, y) \\
 &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log(p(x)p(y|x)) \\
 &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(x) - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(y|x) \\
 &= - \sum_{x \in \mathcal{X}} p(x) \log p(x) - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log p(y|x)
 \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

证明.
我们有

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

从而得证. □

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

例 2.7

设 (X, Y) 服从如下的联合分布:

$\begin{array}{c} X \\ \backslash \\ Y \end{array}$	1	2	3	4
1	$\frac{1}{8}$	$\frac{1}{16}$	$\frac{1}{32}$	$\frac{1}{32}$
2	$\frac{1}{16}$	$\frac{1}{8}$	$\frac{1}{32}$	$\frac{1}{32}$
3	$\frac{1}{16}$	$\frac{1}{16}$	$\frac{1}{16}$	$\frac{1}{16}$
4	$\frac{1}{4}$	0	0	0

X 的边际分布为 $(1/2, 1/4, 1/8, 1/8)$, Y 的边际分布为 $(1/4, 1/4, 1/4, 1/4)$, 因而 $H(X) = \frac{7}{4}$ 比特, $H(Y) = 2$ 比特. 同样地我们可以求得 $H(X|Y) = \sum_{i=1}^4 p(Y = i)H(X|Y = i) = \frac{11}{8}$ 比特, $H(Y|X) = \frac{13}{8}$ 比特, 以及 $H(X, Y) = \frac{27}{8}$ 比特.

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的
关系熵, 相对熵与互信
息的链式法则

注记 2.8

注意 $H(Y|X) \neq H(X|Y)$, 但 $H(X) - H(X|Y) = H(Y) - H(Y|X)$, 稍后会用到这个性质.

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

- ▶ 相对熵是两个随机分布之间距离的度量.
- ▶ 在统计学中, 它对应的是似然比的对数期望.
- ▶ 相对熵 $D(p\|q)$ 度量当真实分布为 p 而假定分布为 q 时的无效性.
- ▶ 例如, 已知随机变量的真实分布为 p , 可以构造平均长度为 $H(p)$ 的码.
- ▶ 但是, 如果使用针对分布 q 的编码, 那么在平均意义上就需要 $H(p) + D(p\|q)$ 比特来描述这个随机变量.

定义 3.1

两个概率密度函数为 $p(x)$ 和 $q(x)$ 之间的**相对熵**或 **Kullback-Leibler 距离**定义为

$$D(p \parallel q) = \sum_{x \in \mathcal{X}} p(x) \log \frac{p(x)}{q(x)} = E_p \log \frac{p(x)}{q(x)}. \quad (3.1)$$

在上述定义中, 我们采用约定 $0 \log \frac{0}{0} = 0$, 约定 $0 \log \frac{0}{q} = 0$, $p \log \frac{p}{0} = \infty$ (基于连续性). 因此, 若存在字符 $x \in \mathcal{X}$ 使得 $p(x) > 0$, $q(x) = 0$, 则有 $D(p \parallel q) = \infty$.

所罗门·库尔巴克 (Solomon Kullback, 1907 年 4 月 3 日 - 1994 年 8 月 5 日) 是一位美国密码学家和数学家, 在信息论和统计学领域做出了重要贡献. 他最为人熟知的是与理查德·莱布勒 (Richard Leibler) 共同提出了库尔巴克-莱布勒散度 (Kullback-Leibler divergence, 简称 KL 散度). 这一概念在信息论、统计学、机器学习和数据科学中被广泛使用.



熵


联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

理查德·莱布勒 (Richard A. Leibler, 1914 年 3 月 18 日 - 2003 年 10 月 25 日) 是一位美国密码学家和数学家, 在信息论和统计学领域做出了重要贡献. 1962-1977 年, 他是美国国防分析研究所通信研究部的负责人.



熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

- ▶ 稍后我们将证明相对熵总是非负的, 并且当且仅当 $p = q$ 时其为零.
- ▶ 但是, 由于相对熵并不对称, 也不满足三角不等式, 因此相对熵实际上并非两个分布之间的真正距离.
- ▶ 然而, 将相对熵视作分布之间的“距离”往往会很有用.

定义 3.2

考虑两个随机变量 X 和 Y , 它们的联合概率密度函数为 $p(x, y)$, 其边缘概率密度函数分别是 $p(x)$ 和 $q(x)$. 互信息 $I(X; Y)$ 为联合分布 $p(x, y)$ 和乘积分布 $p(x)p(y)$ 之间的相对熵, 即:

$$\begin{aligned}
 I(X; Y) &= \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \\
 &= D(p(x, y) \parallel p(x)p(y)) \\
 &= E_{p(x, y)} \log \frac{p(X, Y)}{p(X)p(Y)}.
 \end{aligned} \tag{3.2}$$

例 3.3

设 $\mathcal{X} = \{0, 1\}$, 考虑 $\mathcal{X}$ 上的两个分布 p 和 q . 设 $p(0) = 1 - r$, $p(1) = r$ 及 $q(0) = 1 - s$, $q(1) = s$, 则有

$$D(p\|q) = (1 - r) \log \frac{1 - r}{1 - s} + r \log \frac{r}{s}$$

以及

$$D(q\|p) = (1 - s) \log \frac{1 - s}{1 - r} + s \log \frac{s}{r}.$$

如果 $r = s$, 则 $D(p\|q) = D(q\|p) = 0$. 一般地, $D(p\|q) \neq D(q\|p)$. 例如, 若 $r = \frac{1}{2}$, $s = \frac{1}{4}$, 我们有

$$D(p\|q) = 0.2075 \text{ 比特}, D(q\|p) = 0.1887 \text{ 比特}.$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的
关系

熵，相对熵与互信
息的链式法则

可将互信息 $I(X;Y)$ 重新写为:

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

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

可将互信息 $I(X;Y)$ 重新写为:

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

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

可将互信息 $I(X;Y)$ 重新写为:

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

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

可将互信息 $I(X;Y)$ 重新写为:

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

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

可将互信息 $I(X;Y)$ 重新写为:

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

由此知互信息 $I(X;Y)$ 是在给定 Y 知识的条件下 X 的不确定度的缩减量.

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

对称地, 我们亦可以得到

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

因而, X 含有 Y 的信息量等同于 Y 含有 X 的信息量. 又由定理 2.6, 可得

$$I(X; Y) = H(X) + H(Y) - H(X, Y).$$

最后, 注意到

$$I(X; X) = H(X) - H(X|X) = H(X).$$

因此, 随机变量与自身的互信息为该随机变量的熵.

我们将前面关于熵和互信息的关系做一个总结如下.

定理 4.1

$$I(X;Y) = H(X) - H(X|Y) \quad (4.1)$$

$$I(X;Y) = H(Y) - H(Y|X) \quad (4.2)$$

$$I(X;Y) = H(X) + H(Y) - H(X,Y) \quad (4.3)$$

$$I(X;Y) = I(Y;X) \quad (4.4)$$

$$I(X;X) = H(X) \quad (4.5)$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵，相对熵与互信息的链式法则

熵，相对熵与互信息的链式法则

息的链式法则

定理 5.1: 熵的链式法则

设随机变量 $X_1, X_2, \dots, X_n$ 服从 $p(x_1, x_2, \dots, x_n)$, 则

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

证明.

反复应用定理2.6.



定义 5.2

随机变量 X 和 Y 在给定随机变量 Z 时的条件互信息定义为

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

注意到 $I(X; Y|Z)$ 关于 X 和 Y 对称.

定理 5.3: 互信息的链式法则

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

证明.

$$\begin{aligned} & I(X_1, X_2, \dots, X_n; Y) \\ = & H(X_1, X_2, \dots, X_n) - H(X_1, X_2, \dots, X_n | Y) \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定理 5.4: 互信息的链式法则

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

证明.

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

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定理 5.5: 互信息的链式法则

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

证明.

$$\begin{aligned}
 & I(X_1, X_2, \dots, X_n; Y) \\
 = & H(X_1, X_2, \dots, X_n) - H(X_1, X_2, \dots, X_n | Y) \\
 = & \sum_{i=1}^n H(X_i | X_{i-1}, \dots, X_1) - \sum_{i=1}^n H(X_i | X_{i-1}, \dots, X_1, Y) \\
 = & \sum_{i=1}^n I(X_i; Y | X_{i-1}, X_{i-2}, \dots, X_1). \quad \square
 \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定义 5.6

对于联合概率密度函数 $p(x, y)$ 和 $q(x, y)$, 条件相对熵 $D(p(y|x)||q(y|x))$ 定义为条件概率密度函数 $p(y|x)$ 和 $q(y|x)$ 之间的平均相对熵, 其中取平均是关于概率密度函数 $p(x)$ 而言的. 更确切地,

$$\begin{aligned} D(p(y|x)||q(y|x)) &= \sum_x p(x) \sum_y p(y|x) \log \frac{p(y|x)}{q(y|x)} \\ &= E_{p(x,y)} \log \frac{p(Y|X)}{q(Y|X)}. \end{aligned}$$

定理 5.7: 相对熵的链式法则

$$D(p(x, y) \| q(x, y)) = D(p(x) \| q(x)) + D(p(y|x) \| q(y|x)).$$

证明.

$$D(p(x, y) \| q(x, y)) = \sum_x \sum_y p(x, y) \log \frac{p(x, y)}{q(x, y)}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定理 5.8: 相对熵的链式法则

$$D(p(x, y) \| q(x, y)) = D(p(x) \| q(x)) + D(p(y|x) \| q(y|x)).$$

证明.

$$\begin{aligned} D(p(x, y) \| q(x, y)) &= \sum_x \sum_y p(x, y) \log \frac{p(x, y)}{q(x, y)} \\ &= \sum_x \sum_y p(x, y) \log \frac{p(x)p(y|x)}{q(x)q(y|x)} \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定理 5.9: 相对熵的链式法则

$$D(p(x, y) \| q(x, y)) = D(p(x) \| q(x)) + D(p(y|x) \| q(y|x)).$$

证明.

$$\begin{aligned}
 D(p(x, y) \| q(x, y)) &= \sum_x \sum_y p(x, y) \log \frac{p(x, y)}{q(x, y)} \\
 &= \sum_x \sum_y p(x, y) \log \frac{p(x)p(y|x)}{q(x)q(y|x)} \\
 &= \sum_x \sum_y p(x, y) \log \frac{p(x)}{q(x)} + \sum_x \sum_y p(x, y) \log \frac{p(y|x)}{q(y|x)}
 \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则

定理 5.10: 相对熵的链式法则

$$D(p(x, y) \| q(x, y)) = D(p(x) \| q(x)) + D(p(y|x) \| q(y|x)).$$

证明.

$$\begin{aligned}
 D(p(x, y) \| q(x, y)) &= \sum_x \sum_y p(x, y) \log \frac{p(x, y)}{q(x, y)} \\
 &= \sum_x \sum_y p(x, y) \log \frac{p(x)p(y|x)}{q(x)q(y|x)} \\
 &= \sum_x \sum_y p(x, y) \log \frac{p(x)}{q(x)} + \sum_x \sum_y p(x, y) \log \frac{p(y|x)}{q(y|x)} \\
 &= D(p(x) \| q(x)) + D(p(y|x) \| q(y|x)). \quad \square
 \end{aligned}$$

熵

联合熵与条件熵

相对熵与互信息

熵与互信息之间的关系

熵, 相对熵与互信息的链式法则