

04104-106通信原理II第二讲

March 6, 2007

1 互信息

信息量是不确定性，就是你不可能猜出来的那些东西。对于随机变量 X ，平均信息量是 $H(X)$ 。

对于两个随机变量，已经知道 X 后，对于 Y 我们仍然有一些猜不出来的地方。平均猜不出的程度就是条件熵 $H(Y|X)$ ，它必然小于等于 $H(Y)$ 。也就是说，如果不知道 X 的具体内容，猜 Y 猜不出的程度会更大一些。

换言之，已知 X 使我们对 Y 多少知道了一些，这个程度是 $H(Y) - H(Y|X)$ ，它叫互信息 (mutal information, MI)，记为 $I(X;Y)$ 。因此，互信息就是已知 X 后，我们能依据 X 而猜出的关于 Y 的信息。

注意记号，我们有时候把自信息 $I[P(X = x_i)]$ 写成 $I(X)$ ，如同我们会把概率 $P(X = x_i)$ 写成 $P(X)$ 一样。因此需要注意自信息和互信息的符号差别， $I(X, Y)$ 是自信息，它是 $I[P(X = x, Y = y)]$ 的简写。互信息是 $I(X;Y)$ 。这里一个是分号“;”，一个是逗号“,”。

有如下关系：

$$\begin{aligned} I(X;Y) = I(Y;X) &= H(X) - H(X|Y) \\ &= H(Y) - H(Y|X) \\ &= H(X) + H(Y) - H(X,Y) \end{aligned} \tag{1}$$

证明：若 A 、 B 独立，则 $P(A,B) = P(A)P(B)$ ， $H(A,B) = H(A) + H(B)$ 。由于 $P(X,Y) = P(X)P(Y|X) = P(Y)P(X|Y)$ ，因此， Y 和 $X|Y$ 是独立的， X 和 $Y|X$ 是独立的。因此 $H(X,Y) = H(X) + H(Y|X) = H(Y) + H(X|Y)$ ，代入上式即可得证。#

式(1)表明，已知 X 猜 Y 能猜出多少，已知 Y 猜 X 也能猜出同样多。课本301页的图7.4.1以文式图 (Venn diagram) 的方式示出了有关量值的关系。两个圆分别表示 $H(X)$ 、 $H(Y)$ ，是我们对单独的 X 、 Y 而言所不知道的东西； X 、 Y 之间有一些共同的东西，这就是互信息 $I(X;Y)$ 。如果知道了 X ，那么 Y 中与 X 共同的这部分信息就知道了，余下的就是条件熵 $H(Y|X)$ 。就整体而言，我们不确定的程度不是 $H(X) + H(Y)$ ，因为这两个不确定中有共同的部分，所以总的确定程度是 $H(X,Y) = H(X) + H(Y) - I(X;Y)$ 。

2 信源的表达方式、信源的效率

同样的信息可以有不同的表达方式，比如母亲对孩子说“看我不揍你”，其含义是“我要揍你”；某个小伙子A听B说了某句话后，愤怒地说“你再说一遍试试”，意思是禁止B再这样说。再比如，传送掷筛子的结果{6 6 4 1 2}时，如果改变为{000 000 111 101 110}并无不妥，只要收发都约定好：000 → 6, 111 → 4, …, 即可。

通信中，要把信源的输出 $\{X_1, X_2, \dots, X_L\}$ 传递到信宿，我们也有多种表达方式可选。当然要选最有效率的方式。因此，实际传送的可能是另外一个序列 $\{Y_1, Y_2, \dots, Y_M\}$ 。比方说Y是二进制符号，则传送它需要M个bit。

若序列 $\{X_i\}$ 是n进制，则 $\{X_1, X_2, \dots, X_L\}$ 有 n^L 种不同结果。顺序编号为 $0, 1, \dots, n^L - 1$ ，再转为二进制，则需要 $\log_2 n^L = L \log_2 n$ bit。若序列 $\{Y_i\}$ 是m进制，则 $\{Y_1, Y_2, \dots, Y_M\}$ 有 m^M 种不同结果，顺序编号为 $0, 1, \dots, m^M - 1$ ，再转为二进制，则需要 $M \log_2 m$ bit。只要 $M \log_2 m < L \log_2 n$ ，那么传送（或存储）序列 $\{Y_k\}$ 显然更有效率。这就是信源编码的基本思想。

乍一看，这个思想是有问题的：如果 $n^L > m^M$ ，那么序列 $\{Y_i\}$ 的全部结果只能表示序列 $\{X_i\}$ 的一部分结果。正如：原序列是6次掷筛子的结果，总共有 $6^6 = 46656$ 种不同的结果，而我们打算用7张不同花色的扑克牌来表达原序列，后者只能表达 $4^7 = 16384$ 种结果。

奥妙就在于熵这个概念。Shannon说，别看序列 $\{X_1, \dots, X_L\}$ 有 n^L 种不同的结果，但因为符号不等概、序列也可能前后相关，所以它的全部信息量只有 $H(X_1, X_2, \dots, X_L) < \sum_{i=1}^L H(X_i) = LH(X) < L \log_2 n$ ，其中 $H(X)$ 是单个符号的熵（假设平稳，则每个符号的熵都一样大）。设 $H(X_1, X_2, \dots, X_L)$ 的数值为 a bit，那么用 a 个YES/No问题就能确定出具体 $\{X_1, \dots, X_L\}$ 的结果，因此实际只需要传 a 个bit（ a 个YES/NO问题的答案），它要比 $L \log_2 n$ 小得多。

这里的原因在于“典型”“非典型”序列这样的概念。Shannon说，如果 $L \rightarrow \infty$ ，那么所有 $\{X_i\}$ 的结果可分为两类，“典型序列”和“非典型序列”，根本不用考虑非典型序列，而典型序列只有 $2^{H(X_1, \dots, X_L)}$ 个。

例如：考虑1万个掷硬币的结果。所有可能结果有 2^{10000} 种。如果正反面出现机会不等，比如反面出现机会是 $2/3$ ，如果你设计的系统压根不打算传送某些结果，比如正面占90%的结果，那么你的系统基本上不会有什么风险。因为正面出现的机会少，所以1万个硬币有9000个正面这种情况虽然有可能，但比起其他“典型”结果来说，可能性可以忽略。信息论对这种风险有具体的估算办法，如课本上的例7.6.2。我们对此不作特别要求，只是再次重申一下信息论的观点：

传输（或存储）序列 $\{X_1, X_2, \dots, X_L\}$ （ L 非常大）所需要的比特数最少是 $H(X_1, X_2, \dots, X_L)$ ，折合到每个符号仅为：

$$H_\infty(X) \triangleq \lim_{L \rightarrow \infty} \frac{H(X_1, X_2, \dots, X_L)}{L} \quad (2)$$

对于序列 $\{X_i\}$ ，传送 X_1 的信息量是 $H(X_1) = H(X)$ ，是单符号的熵；再传送 X_2 时，只需传送新增的不确定性 $H(X_2|X_1)$ 。依此类推，传送第 L 个符号 X_L 时，只需传送 $H(X_L|X_{L-1}, \dots, X_1)$ 。当 L 非常大时，以后每出现的一个符号新增的信息量 $\lim_{L \rightarrow \infty} H(X_L|X_{L-1}, \dots, X_1)$ 并不大。这个增量自然就是序列的总信息量平均到每个符号的结果：

$$\lim_{L \rightarrow \infty} H(X_L | X_{L-1}, \dots, X_1) = \lim_{L \rightarrow \infty} \frac{H(X_1, X_2, \dots, X_L)}{L} \triangleq H_\infty(X) \quad (3)$$

这个结果不仅符合直觉，也是可以证明的。首先

$$\begin{aligned} \lim_{L \rightarrow \infty} \frac{H(X_1, X_2, \dots, X_L)}{L} &= \lim_{L \rightarrow \infty} \frac{H(X_1) + H(X_2 | X_1) \cdots H(X_L | X_{L-1}, \dots, X_1)}{L} \\ &= \lim_{L \rightarrow \infty} \frac{H(X_L) + H(X_L | X_{L-1}), \dots, H(X_L | X_{L-1}, \dots, X_1)}{L} \\ &\geq \lim_{L \rightarrow \infty} \frac{H(X_L | X_{L-1}, \dots, X_1) + H(X_L | X_{L-1}, \dots, X_1), \dots, H(X_L | X_{L-1}, \dots, X_1)}{L} \\ &= \lim_{L \rightarrow \infty} \frac{1}{L} H(X_L | X_{L-1}, \dots, X_1) \end{aligned}$$

即 $H_\infty(X) \geq \lim_{L \rightarrow \infty} \frac{1}{L} H(X_L | X_{L-1}, \dots, X_1)$ 。上面用到了平稳性和增加条件将使熵变小这两个性质。其次

$$\begin{aligned} \frac{H(X_1, X_2, \dots, X_L)}{L} &= \frac{H(X_1) + H(X_2 | X_1) \cdots H(X_L | X_{L-1} \cdots X_1)}{L} \\ &= \frac{H(X_1) + \cdots + H(X_M | X_{M-1} \cdots X_1) + H(X_{M+1} | X_M \cdots X_1) + \cdots + H(X_L | X_{L-1} \cdots X_1)}{L} \\ &\leq \frac{H(X_1) \cdots H(X_M | X_{M-1} \cdots X_1) + H(X_{M+1} | X_M \cdots X_2) + \cdots + H(X_L | X_{L-1} \cdots X_{L-M+1})}{L} \\ &= \frac{H(X_1) + \cdots + H(X_{M-1} | X_{M-2} \cdots X_1) + (L - M + 1)H(X_M | X_{M-1} \cdots X_1)}{L} \end{aligned}$$

先固定 M , 令 $L \rightarrow \infty$, 再令 $M \rightarrow \infty$, 上式结果就是 $H_\infty(X) \leq \lim_{L \rightarrow \infty} \frac{1}{L} H(X_L | X_{L-1}, \dots, X_1)$ 。因此必然有 $H_\infty(X) = \lim_{L \rightarrow \infty} \frac{1}{L} H(X_L | X_{L-1}, \dots, X_1)$

综上所述, 对于信源 $\{X_i\}$, 如果不采用任何压缩技术, 平均每个符号需要 $\log_2 n \triangleq H_0(X)$ 比特。如果采用高效的压缩技术, 最好情况下有望每个符号平均只需要 $H_\infty(X)$ 比特。压缩比极限可达到 $\frac{H_\infty(X)}{H_0(X)}$ 。这个比值也叫信源的效率 η , 相应定义信源的冗余度为

$$R = 1 - \eta = \frac{H_0(X) - H_\infty(X)}{H_0(X)} = 1 - \frac{H_\infty(X)}{H_0(X)}$$

实际信源的特征往往是: 符号不等概, 符号之间有很强的相关性。因此它一定可以压缩, 具体方法的压缩能力或许有区别, 最大的压缩程度可由 η 或 R 衡量。计算 $H_\infty(X)$ 需要用到无限维的概率分布 (因为计算熵 $H(X_1, \dots, X_L)$ 或者条件熵 $H(X_L | X_{L-1}, \dots, X_1)$ 都需要 L 维概率 $P(X_1, X_2, \dots, X_L)$)。这些概率可以用统计方法获得。表 7.3.4 是统计得到的 H_∞ 。

上述最好的方法充分利用了信源序列的相关性。对于第 L 个符号, 它充分扣除了过去所有符号在 X_L 上的贡献, 只传送纯新的增量信息。如果我们只考虑 A 个符号, 即对于第 L 个输出符号, 只扣除前 $A-1$ 个符号的贡献, 那么效率就会低一些, 平均每符号最少需要的比特数将是 $H_A(X) \triangleq H(X_L | X_{L-1}, \dots, X_{L-A+1})$ 。

$H_2(X) = H(X_L|X_{L-1})$ 只考虑前一个符号的贡献; $H_1(X) \triangleq H(X)$ 只考虑单个符号, 不考虑相关性, 但考虑了不等概特性; $H_0(X)$ 则连不等概都不考虑, 即不进行压缩。下面的不等式是显而易见的

$$0 \leq H_\infty(X) \leq \dots \leq H_2(X) \leq H_1(X) \leq H_0(X) = \log_2 n \quad (4)$$

3 信源编码

上面我们已经看到, 信息论的基本意思是, 对于信源我们只需要传送它的熵就可以了。信息论对此有更为严格和精确的表述。我们略讲一二。

3.1 等长无失真编码

对于不等概的独立序列信源, 每符号最少可以压缩到 $H_1(X)$ (因为独立, 所以没有相关性可利用, $H_\infty = H_1$)。一种做法是: 将信源序列分为等长的组, 每组长度比如是 L 。每组的可能结果有 n^L 种, 扣除非典型序列, 对剩下的进行编码(就是进行二进制整数编号)。虽着 L 趋于无限长, 这种方法可以趋向极限的效率: 每符号所用的比特数仅为 $H(X)$ 。

无失真的意思是, 用编码结果 $\{Y_i\}$ 能够完全复原出原序列 $\{X_i\}$ (不能复原出非典型序列结果, 但这个概率可以忽略)。也思就是说 $I(X; Y) = I(X)$ 。

3.2 变长无失真编码

如上的方法实际上是不现实的, 经过一番计算我们发现, 要使这种编码是保险的, 分组长度必须非常长。保险的意思是, 非典型序列的概率确实可以忽略。课本例7.6.2就是这种计算的一例, 虽然如何计算不在我们的要求之内, 但从这个例子的结果能看到分组长度到底需要多长。

一种简单, 而且有效的方法是采用变长编码。其思想是, 出现频率高的符号用短码, 出现概率低的用长码。理想状态下, 这样做效果非常不错。

变长编码的一个经典例子是Huffman编码。

3.3 限失真信源编码

前面谈论的是离散信源。对于连续信源, 要想精确表达信源, 熵是无穷大, 这当然是做不到的。例如, 对于均匀分布在 $[0, 1]$ 内的 X , 如果按间隔0.1量化, 结果有10种, 熵是 $1Det = \log_2 10bit$; 如果量化间隔是0.01, 熵就是 $\lg 100 = 2Det$ 。可见, 真要想无限精确地传送 X 的话, 信源的熵将是无限大。

好在对许多应用来说, 我们没有必要无限精确。比如一个听MP3的学生不可能抱怨说, 它听到的某个歌的某个抽样值比原音的电压值3.04V低了0.000001V, 人类的耳朵不可能有这么高的分辨率。因此, 我们退而寻求这样的编码, 它把原始信息 X 映射成 Y , 虽然 $I(X; Y) < H(Y)$ (就是说, 我们得知 Y 并不能完全精确的复原 X , 否则就是 $I(X; Y) = I(X)$), 但由 Y 复原的结果和 X 相比, “失真”完全可以满意。失真的意思是 $Y \neq X$, 失真的程度 D 是一个数, 我们用它来说 X 和 Y 不相等的程度。一般用均方失真(但也可以用其他定义): $D = E[(Y - X)^2]$ 。

对于可允许的失真度 D ，存在许多将 X 映射为 Y 的方法，其中的互信息 $I(X;Y)$ 就是该方法所需要的传输量，也称为信息率（单位一般是每符号多少bit）。如果数学模型齐备的话，信息论能算出所有这些失真符合要求的方法最小的互信息，这个值定义为“率失真函数”，记为 $R(D)$ ，它是给定可允许的失真为 D 的条件下，最少需要传送的信息量。它是一个函数，自变量是失真程度 D ，函数值是信息率 R ，所以叫率失真函数。

4 利用序列的相关性

实际信源都是有相关性的，如前所述，如果能够理性地扣除随机变量之间的关联，信源实际的熵要比看上去小得多。因此，实际应用中的压缩技术都在这方面花费了很大力气。

一种方法是预测编码，在发送样值 X_L 之前，它先预测一下这个值可能是多少，预测的结果当然不可能绝对准确（ X_L 毕竟会有新的信息），我们再把预测误差 $X_L - \hat{X}_L$ 传过去。因为误差毕竟比较小，所以传它的时候，量化比特就可以少一些。

另一种方法是变换编码。一个随机向量经过适当线性变换后，可以变得彼此不相关。这使我们能把相关信源改造成不相关信源。因为熵不大，所以变换后的表现是，某些值可能非常小，以致于忽略它影响不大。这样我们就能大大减少传输量。