

第十三章 量子信息论

§13.1, 经典 Shannon 理论简介

1, Shannon 熵和数据压缩

i, C.Shannon 于 1948 年建立了两个定理。一条是“**无噪声编码定理**”。这涉及一条信息能被压缩多少？就是说，这条信息有多少冗余？另一条是“**噪声通道编码定理**”。涉及在一个噪声通道上，能以多大的速率来可靠地进行传递？就是说，需要添加多少冗余度到信息中去以防止误差？这两个问题都涉及“冗余度”——平均而言信息的相邻字符有多少是不需要的。

Shannon 的关键观点之一是：**熵提供了量化冗余度的合适方法。**

一条信息是从共计 K 个字符中（可以重复）选出来的 n 个字符的一种序列。这里通常是 10 个阿拉伯数字序列、2 个二进制数序列、以及 26 个英文字母序列组成的文章等等。比如一条英语新闻报导，其 $K=26$ 字母+空格+全部标点符号种类， n 则是这条报导所含字母、空格和标点符号的总数目。现在假定：1) 在信息中各个字符的出现彼此统计无关；2) 每个字符 $(a_x, x=1,2,\dots,K)$ 以先验的（当然也就是已知的）概率分布 $p(a_x)$ 出现，这里 $\sum_{x=1}^K p(a_x)=1$ 。比如，双字符中 1 出现的先验概率为 p ，而 0 出现的先验概率就为 $(1-p), 0 \leq p \leq 1$ 。

【定义】 如果序列中各字符均以先验的概率出现，称这种序列为“典型序列”。

考虑一个很长的信息 ($n \gg 1$)。现在提一个问题：可以将这个很长的信息压缩为一个较短的（字符序列较短而又实质上传递相同信息的）信息吗？

以 n 个双字符为例。典型序列是这样一类序列，其中 0 个数为 $n(1-p)$ ，1 个数为 np 。不同典型序列的数目，它们数量级为二项式系数 $\binom{n}{np}$ 。下面为了二进制编码方便，规定对数 $\log$ 以 2 为底。当 n 很大时 *Stirling* 公式 ($\log n! = n \log n - n + O(\log n)$) 给出：


$$\begin{aligned} \log \binom{n}{np} &= \log \left(\frac{n!}{(np)! [n(1-p)]!} \right) \\ &\approx n \log n - n - \{np \log(np) - np\} - \{n(1-p) \log[n(1-p)] - n(1-p)\} \quad (13.1) \\ &= n \{-p \log p - (1-p) \log(1-p)\} \equiv nH(p) \end{aligned}$$

$$\boxed{H(p) = -p \log p - (1-p) \log(1-p)} \quad (13.2)$$

$H(p)$ 称为 *Shannon 熵函数*。它满足

$0 \leq H(p) \leq 1$ ，当 $H(p=1/2) = \max = 1$ 。

它的图形如右图。



由此，对 n 个双字符情况，典型序列数目的量级是

$$\binom{n}{np} = 2^{nH(p)}。于是，若只限于考虑字符出现概率符合先验概率$$

分布的那一类序列，则 n 个双字符序列的总数大大下降，成为：

$$\boxed{2^n \rightarrow 2^{nH(p)}} \quad (13.3)$$

为了基本上传递全体（由 n 个二进制位的序列所荷载的）

信息，并不需要对全部 n 位序列分别指定一个正整数的编码办

法（码块），只需要选定一种对全部典型序列分别指定一个正

整数的编码办法就够了。这类码块（每个字符出现概率都符合先验概率分布）有 $2^{nH(p)}$ 个字符。于是可以用一个长度为 $nH(n)$ 的二进制序列来规定任一给定的长度为 n 字符的信息。

由于熵函数 $H(n)$ 的性质，对任何 $p \neq \frac{1}{2}$ 情况，这类码块的码长都会短于原来的信息。这便是 *Shannon* 的结果。这里关键是：当 $n \rightarrow \infty$ 时，实际信息不是典型序列的概率将渐近地忽略不计。所以无须对字符所组成的每个顺序都赋予编码的字码，只需对典型顺序做这种编码。这正表明了常说的，信息就是对未知的某种否定。对某个系统的信息，就是对该系统不确定性的认知，同时也是存储该系统熵所需的比特数。例子见下。

ii) 推广到 k 个字符情况。

推广到多个字符的情况。设有系综 $X: \{x = (x_1, x_2, \dots, x_k), p(x)\}$, $p(x)$ 是出现字符 x 的“先验”概率。在总长为 n 个字符的一个序列中， x 发生的概率是 $np(x)$ 次。典型序列的数目在量级上为（再次使用 *Stirling* 公式）

$$\frac{n!}{\prod_x (np(x))!} \approx 2^{nH(x)} \quad (13.4)$$

这里

$$H(x) \equiv \sum_x -p(x) \log p(x) \equiv \langle -\log p(x) \rangle \quad (13.5)$$

这就是系综 X 的 *Shannon* 熵，或简称为经典系综的经典熵【习题 1】。选定编码：给每个典型序列指定一个正整数。一个有 n 位字符序列的信息便可以压缩成 $nH(x)$ 位。在这个意义上，系综 X

中所用的一个字符 x 荷载着 $H(x)$ 位信息。

【例 1】太阳从东方升起，这是 $p=1, 1-p=0$ 的确定分布。此“系统”没有不确定性，熵为零，所需存储比特数 $H(p=1)=0$ 为零。现在你告诉我信息：明天太阳从东方升起。此信息不再减少关于这件事的无知，存储此信息所需比特数也为零。

【例 2】向地上抛钱币，这是 $p=1-p=1/2$ 完全随机的分布。此“系统”完全不确定，熵达最大，需用 $H(1/2)=1$ 比特来存储关于它的“无知”。现在你告诉我信息：这次是“花”朝上。此猜测消除了 1 比特的不确定性，相应信息含量为 1 比特内容。

【例 3】掷骰子中 6 个点数等概率出现。此系统是 $X=\{x_i, p_i=1/6, i=1,2,\dots,6\}$ 。按典型序列来考虑，此系统熵为 $H(X)=\log 6=2.42$ 比特。即，需用此比特数来存储关于投掷结果的“无知”。现在你猜说：这次结果是个 5。此猜测所提供的信息消除了此比特数的熵，信息含量也是此比特数。【例 4】已知 7 人中有一人要出差，但不知是哪一位。这需用 3 比特来存储此“系统”的无知。你告诉我信息：是张三出差。此信息消除了 3 比特的不确定性，相应的信息量含有 3 比特的内容，需用 3 比特来存储。这些例子说明，为什么熵既是系统不确定性的量度，又是信息含量的量度。

2, Shannon 无噪声编码定理

i) 将上面叙述换一种稍稍不同的等价方式来表述。

“由 k 种字符排列组成的一条 n 个字符的信息

$$x_1 x_2 \cdots x_n; \quad x \in X \equiv \{x, p(x); k\} \quad (13.6a)$$

但由于 n 是有限的，字符 x 在此条信息中出现的次数 $n(x)$ 并不正

比于先验概率 $p(x)$ ，而体现作为频度 $p'_n(x) = n(x)/n$ 。但显然有，

$$\begin{aligned} \lim_{n \rightarrow \infty} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p'_n(x_i) \right\} &= \lim_{n \rightarrow \infty} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(x_i) \right\} \\ &= \sum_{j=1}^k -p(x_j) \log p(x_j) \equiv \langle -\log p(x) \rangle \end{aligned} \quad (13.7)''$$

这里 $p(x_i)$ 是字符 x_i 的先验概率

$$\begin{cases} P(x_1 x_2 \cdots x_n) = p(x_1) p(x_2) \cdots p(x_n) \\ \log P(x_1 x_2 \cdots x_n) = \sum_{i=1}^n \log p(x_i) \end{cases} \quad (13.6b)$$

由此得到两条结论：

a) 一方面，对单个典型序列，有

$$\lim_{n \rightarrow \infty} \left\{ -\frac{1}{n} \sum_{i=1}^n \log p(x_i) \right\} = H(X) \quad (13.8)$$

假如是足够长而有限的序列，可采用 δ, ε 极限语言，将之精确地表述为

$$\left| -\frac{1}{n} \sum_{i=1}^n \log p(x_i) - H(X) \right| < \delta \quad (13.9)$$

两边乘 n ，取 2 指数，即得

$$2^{-n(H(X)-\delta)} \geq P(x_1 \cdots x_n) \geq 2^{-n(H(X)+\delta)} \quad (13.10)$$

这就是当 n 足够大（ δ 就足够小）时，每个典型序列出现的概率范围。

b) 另一方面，就所有典型序列总体而言，当 $n \rightarrow \infty$ 时典型序列出现的总概率趋近于 1。由此结合 (13.10) 式，可知

$$n \text{ 字符典型序列总概率} = P(x_1 \cdots x_n) \times 2^{nH(X)} = 2^{-nH(X)} \times 2^{nH(X)} \Rightarrow 1$$

或

$$P(x_1 \cdots x_n) = 2^{-nH(X)} (1 - \varepsilon(n))$$

或者说, n 字符全体典型序列出现的总概率为 $(1 - \varepsilon(n))$,

$$\sum_{\text{all}} P(x_1 \cdots x_n) = 1 - \varepsilon(n) \quad (13.11)$$

ii) Shannon 无噪声编码定理

总之, 上面说明了, 当信息序列的字符数目 $n \rightarrow \infty$ 时, 信息序列呈现为非典型序列的概率 $\rightarrow 0$, 从而只需要考虑此时的典型序列。对每一种典型序列指定一个正整数的编码方案即可应付, 而不必对所有序列都进行编码, 即不必对非典型序列也编码。这时如此做法所带来的误差不大于 $\varepsilon(n) \xrightarrow{n \rightarrow \infty} 0$ 。

下面说明: 对任何系综 $X = \{x_i, p_i\}$, 每个字符的信息不能被压缩到 $H(X)$ 位以下。因为这时已不能对全部典型序列的每一个典型序列指定唯一的码符。

这就是【Shannon 第一定理——Shannon 无噪声编码定理】

“如果想进一步将信息中每位字符的信息压缩到 $H - \delta'$, 即使 δ' 为任一给定的小量, 则当 $n \rightarrow \infty$ 时也不能达到足够小的误差 $\varepsilon(n)$ 。最佳编码只可以渐近 ($n \rightarrow \infty$) 地将每个字符压缩到 $H(X)$ 位。”

【论证如下】

这时对信息 (包括非典型序列信息, 添 ε' , 见下) 成功编码的概率为:

$P_{\text{Success}} \leq (H - \delta')$ 决定的典型序列总数 $\times$ 每个典型序列出现概率上

$$\text{限} + \varepsilon' = 2^{n(H-\delta')} \cdot 2^{-n(H-\delta)} + \varepsilon' = 2^{-n(\delta'-\delta)} + \varepsilon' \xrightarrow{n \rightarrow \infty} 0 \quad (13.12)$$

此式意思是，这时能够对 $2^{n(H-\delta')}$ 个典型序列信息进行编码，这里每个典型序列信息出现的概率要小于 $2^{-n(H-\delta)}$ （见前面(13.10)式）。添加 ε' 是考虑到有限字符时也需要对非典型序列进行编码（ $\varepsilon' \xrightarrow{n \rightarrow \infty} 0$ ）。于是，对任一选定的小量 δ' ，当 $n \rightarrow \infty$ 时 δ 逐渐减小，终将有 $(\delta' - \delta) > 0$ ，这使成功的概率趋于零。

3, 互信息

在 $n \rightarrow \infty$ 的渐近过程中，*Shannon* 熵表示从系综 X 取出单个字符所传递的平均信息量。因为它告诉我们，为了对那个信息编码需要多少位数。

互信息 $I(X, Y)$ 表示两个信息之间有多少关联。即，我们从所获得的 Y^n 序列信息中，能推知多少关于 X^n 序列信息？

例如，假定从一个传送者发送一条信息给一个接受者。但讯道有噪声，以致于收到的信息 y 可能不同于送出的信息 x 。噪声通道可以用条件概率 $p(y|x)$ （发送 x 时收到 y 的概率）来表征。我们假设，字符 x 将以先验的概率 $p(x)$ 发送。下面来定量研究：当我们收到 y 时能对 x 知道多少，也即获得了多少信息？

如同已经看到的，熵 $H(X)$ 表示，所收到的每个字符能消除我们在收到信息之前的无知。就是说，传送者传递 $nH(X)$ 位（不带噪声的）字符给接受者，以完整地表达（渐近地）一个特定的 n 字符的信息。假如了解了这条噪声通道的特性，也即知道条件概率 $p(y|x)$ ，而先验概率分布也是事先知道的，于是接受者在

收到 y 值之后，可以利用条件概率的 **Bayes 定理**

$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} \equiv \frac{p(x,y)}{p(y)} \quad (13.13)$$

$p(x,y)$ 是 x, y 的联合概率，假如 x, y 各自独立，则有 $p(x,y) = p(x)p(y)$ 。

按全概率公式（见习题 1）可得 $p(y)$ 如下

$$p(y) = \sum_x p(y|x)p(x) \quad (13.14)$$

鉴于已经获得这些知识，比起以前来，现在对 x 的知识是增加了（“无知”减少了些）。假定在收到这些 y 后，现在再采用最理想的码，就可以用每字符如下比特数

$$H(X|Y) = \langle -\log p(x|y) \rangle = -\sum_{xy} p(x,y) \log p(x|y) \quad (13.15)$$

发送某个 n 字符序列将关于 X 的信息再传给别人。 $H(X|Y)$ 称为条件熵，其意义是：一旦知道 y 的数值，平均而言的 X 的不确定性；或者说，知道 Y 后，为规定 x 每个字符所需要的附加位数。

【定义】联合熵：

$$H(X,Y) = -\sum_{x,y} p(x,y) \log p(x,y) \quad (13.16)$$

显然，联合熵关于 X 和 Y 为对称的。还可以

【定义】互熵——互信息：

$$\begin{cases} I(X;Y) = -\sum_{x,y} p(x,y) \log p(x,y) \\ p(x,y) = p(x)p(y)/p(x,y) \end{cases} \quad (13.17)$$

这里 $p(x,y)$ 为互概率。若 X 和 Y 无关，联合概率独立 $p(x,y) = p(x)p(y)$ ，得 $p(x,y) = 1$ ，于是 $I(X;Y) = 0$ 。由于互概率 ≤ 1 ，所以 $I(X;Y) \geq 0$ 。 $I(X;Y)$ 的物理意义是：当已知 Y 之后，为确定 X 所需每个字符的位数的减少数。或者说，通过已知 Y 所能获得的关

于 X 每个字符的比特数。又可以说，通过测量 Y 所得到的关于 X 的信息。

若有同一字符库的两种概率分布 $p(x)$ 和 $q(x)$ ，可以

【定义】 $p(x)$ 相对于 $q(x)$ 的相对熵：

$$H(p(x)\|q(x)) = \sum_x p(x) \log \frac{p(x)}{q(x)} = -H(X) - \sum_x p(x) \log q(x) \quad (13.18)$$

4, $H(X, Y), H(X|Y), I(X; Y)$ 性质总结

i, 联合熵的对称性 $H(X, Y) = H(Y, X)$;

ii, 条件熵非负性 $H(X|Y) \geq 0$ 。若 X, Y 相互独立，

$$H(X|Y) = H(X);$$

iii, 互信息的对称性 $I(X; Y) = I(Y; X)$ 。互信息的范围

$$0 \leq I(X; Y) \leq \min(H(X), H(Y))$$

证明：由于 $0 \leq p(x, y) \leq p(y) \leq 1$ ，所以

$$\log p(y) - \log p(x, y) \geq 0$$

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

同样可得 $I(X; Y) \leq H(Y)$ 。

iv, 条件熵、联合熵、子系统熵的关系

$$\begin{cases} H(X|Y) = H(X, Y) - H(Y) \\ H(Y|X) = H(X, Y) - H(X) \end{cases}$$

证明： $H(X|Y) = -\sum_{x, y} p(x, y) \log p(x|y) = -\sum_{x, y} p(x, y) \log \frac{p(x, y)}{p(y)} = H(X, Y) - H(Y)$ 。

由于 $0 \leq p(x, y) \leq p(y)$, 所以条件熵总是非负的 $H(X|Y) \geq 0$ 。

v, 互熵、联合熵、子系统熵的关系

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

vi, 条件熵、互熵、子系统熵的关系

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

vii, $H(X, Y) = H(X|Y) + H(Y|X) + I(X; Y)$

viii, 经典熵的基本不等式

$$\text{Max}(H(X), H(Y)) \leq H(X, Y) \leq H(X) + H(Y)$$

【证明】对于右边不等号 $H(X, Y) \leq H(X) + H(Y)$ 是因为, $H(X; Y) \geq 0$ 。

对于左边不等号, 是因为

$$-\log p(x, y) \geq -\log p(x)$$

$$\therefore -\sum_{x,y} p(x, y) \log p(x, y) \geq -\sum_{x,y} p(x, y) \log p(x) = -\sum_x p(x) \log p(x) = H(X)$$

同样有 $-\sum_{x,y} p(x, y) \log p(x, y) \geq H(Y)$ 。总之左边不等号成立。此式的

物理意义: 复合系统 $X+Y$ 的熵 $H(X, Y)$ 不可能小于任一子系统 X 或 Y 的熵。


$H(X, Y)$ 的上限是子系统 X 和 Y 互相独立; 下限相应于子系统 X 和 Y 之间有最大的经典关联。

xi, 相对熵 $H(p(x)||q(x))$ 的数值是非负的。注意对任意正数 X 有 $\ln X \geq 1 - X^{-1}$, 令 $p(x)/q(x) = X$, 换成以 2 为底的对数 $\log$, 得

$$\begin{aligned}
 H(p(x)||q(x)) &\equiv \sum_x p(x) \log \frac{p(x)}{q(x)} \geq \frac{1}{(\log e)} \sum_x p(x) \left(1 - \frac{q(x)}{p(x)}\right) \\
 &= \frac{1}{(\log e)} \sum_x (p(x) - q(x)) = 0
 \end{aligned}$$

等号当且仅当 $p(x)=q(x) \quad \forall x$ 时成立。

[关系示意图]



5, Shannon 噪声信道编码定理

i, 若要在一条噪声信道上传递信息，显然必须采用冗余度来增加传输的可靠性。比如，可以将每个比特多次发送，接收者可以采用多数选定制的办法去解比特。等等。

但是，给定一个噪声信道之后，总能找到一种编码，当 $n \rightarrow \infty$ 时确保有任意好的可靠性吗？关于这种编码的比率——每一信息的每个字母需要多少比特的问題，能得出些什么结论呢？

事实上，Shannon 证明了：只要在输入和输出之间有一定的关联，任何信道都可以在一个有限比率之下作任意可靠的通讯。此外，他发现了对于能够达到的最佳比率的一个有用表达式。这些结果便是噪声信道编码定理。下面分层次论述，并在最后给出这个定理。

为了具体，假定采用的是二进制字母表：0 和 1，各以一个

先验的概率发生。并且假定，讯道是“二进制对称通道”——它对每一个位的作用是独立的：以概率 p 翻转它的值，以 $(1-p)$ 的概率原封不动的保留它的值。就是说，条件概率是：

$$\begin{aligned} p(0|0) &= 1-p & p(0|1) &= p(1|0) = p \\ p(1|1) &= 1-p \end{aligned}$$

这时 $H(p) = -p \log p - (1-p) \log(1-p)$ 。现在打算针对增加着的块容积 n （因为信息长度在增加着）去构造、寻找各种编码方案，使得解码误差的概率当 $n \rightarrow \infty$ 时趋于零。假定编在块中的数据比特数是 $k(<n)$ ，于是码由 n 比特的 2^n 种可能弦中 2^k 个码符的某种选择所构成（即选择编码——如何用 2^n 弦荷载 2^k 弦，或用 n 位荷载 k 位的各种约定）。

【定义】 码的比率 R 等于每传送 1 比特所荷载的数据比特数，

$$R = \frac{k}{n} \quad (<1, \quad nR = k) \quad (13.19)$$

k 不能太大， $\because k$ 上升 $\rightarrow R$ 上升 $\rightarrow$ 传送信息的冗余度下降 $\rightarrow$ 造成误译。

应当这样设计好的码，使得码弦之间彼此尽可能的分开。就是说，对于给定的 R ，必须使从一个码符到另一个码符变化时，所必需翻转的位数尽可能的多（这个数被称作两个码符之间的 *Hamming* 距离）。

对于一条 n 位长的输入弦，一般性地说，误差将引起大约 np 位的误翻转——于是这一个输入一般将扩散到大约 $2^{nH(p)}$ 个典型输出弦中的一个。占据着以输入弦为中心的、以 *Hamming* 距离 np 为半径的一个“球”。 $\therefore 2^k \rightarrow 2^k \cdot 2^{nH(p)}$ 个典型序列，每个被编在 n 位

中的 k 位码字符都扩散成为“球”。于是，要求各个球之间不重合就必须要求

$$2^k \text{ 个球的总体积} \leq 2^n \quad (13.20)$$

为了可靠地解码，就必须选择我们的输入码符，使得两个不同的码符的误差球不产生交叠。否则两个不同的输入会有同样的输出，解码误差就不可避免了。如果要避免这样的解码不确定性，（包含在总数为 2^{nR} 个误差球内的）弦的总数不能超过输出信息总数 2^n 。即需要

$$2^{nH(p)} \cdot 2^{nR} \leq 2^n \quad (13.21)$$

即： 2^k 码符数 $\times n$ 序列压缩为典型序列数 $\leq n$ 序列总数。或为

$$0 \leq R \leq 1 - H(p) \equiv C(p) \quad (13.22)$$

（若无噪声，则 $p = 0$ 或 $p = 1 \rightarrow H(p) = 0 \rightarrow C(0) = C(1) = 1$ ；若最大噪声， $p = \frac{1}{2} \rightarrow H\left(\frac{1}{2}\right) = 1 \rightarrow R = 0$ ，不能传信息）。若要传送是高度可靠的，就不能指望码比率 R 超过 $C(p)$ 。但比率 $R = C(p)$ 在实际上是否能够渐近地达到的呢？就是说，平均而言，在可靠传送下，当 $n \rightarrow \infty$ 时， R 可以 $\rightarrow C$ 吗？事实上，以任意接近 C 和任意小误差概率的 R 比率的传送是可能的。也许 *Shannon* 最富创造性的思想就是说明了：通过考虑在“随机码”上的平均，可以达到 C 。显然，随机地选择一个码并不是可能办法中最巧妙的。但结果却让人惊讶：随机编码和任何其它编码方案一样，在大 n 下也能渐近地获得高的比率。由于 C 是数据沿噪声通道可靠传送的最佳比率，所以被称作讯道的容量。

假设 2^{nR} 个码符用随机地从系综 X^n 中取样来选定。在传送一个信息（码符中的一个）时，为了解读这个信息码，画出一个围绕着所收到信息的“**Hamming 球**”，这个收到的信息将包含

$$2^{n(H(p)+\delta)}$$

个典型弦。假定包含在这个球中的这样一个码符存在并且是唯一的，信息就被解码成为这个码符；如果这样的码符不存在，或是码符不唯一，就假设发生了一个解码错误。

一个解码错误多半是怎样的呢？已经选定解码球足够大，使得出现在球中的一个适当码符错误是非典型的，所以只需要关心占据球的多个适当的码符。因为总共存在 2^n 个可能的弦，围绕这个输出，一个 **Hamming** 球中的典型弦占全部弦中的份额为

$$\left(\frac{2^{n(H(p)+\delta)}}{2^n} = 2^{-n(C(p)-\delta)} \right)$$

于是， 2^{nR} 个随机选择码符中的一个码符以偶然的方式占据这个球的概率是

$$2^k \cdot 2^{-n(C(p)-\delta)} = 2^{-n(C(p)-R-\delta)}$$

鉴于可以选择 δ 为任意小， R 可以被选为任意接近 C （但要在 C 的下方），于是这个失误概率当 $n \rightarrow \infty$ 时，将仍旧按指数减小。

迄今证明了，平均失误概率是小的。这里对所选择的随机码作平均，并且对每一个规定的码作平均，也对全部码作平均。于是必定存在一个具体的编码，这时对此码符平均的失误概率小于 ε 。

ii, 进一步，愿意有一个更强的结果——失误概率对于每个码符都小。为了建立起这个更强的结果，令 p_i 表示传送码

符 i 时解码失误的概率。已经说明存在一个码，使得

$$\frac{1}{2^{nR}} \sum_{i=1}^{2^{nR}} p_i < \varepsilon$$

令 $N_{2\varepsilon}$ 表示 $p_i > 2\varepsilon$ 的码符的数目。于是我们推断

$$\frac{1}{2^{nR}} (N_{2\varepsilon}) 2\varepsilon < \varepsilon, \text{ 或 } N_{2\varepsilon} < 2^{nR-1} = 2^{n\left(R-\frac{1}{n}\right)}$$

我们看到，至多能抛弃掉码符的一半，以达到对每一个码符有 $p_i < 2\varepsilon$ 。构造出的新码有比率，

$$rate = R - \frac{1}{n}; \quad \left(\frac{1}{2} 2^k = 2^{nR-1} = 2^{n\left(R-\frac{1}{n}\right)} \right)$$

它当 $n \rightarrow \infty$ 时趋于 R 。

于是看到，

$$C(p) = 1 - H(p)$$

这是能渐近达到的、有任意小失误概率的最大传输比率。

iii) 现在考虑怎样将这些论证推广到更一般的字符表和噪声道。给定一个由 $p(y|x)$ 等等所规定的通道，并为输入字符规定一个概率分布 $X = \{x, p(x)\}$ 。设发送 n 个字符的一个弦，并假定通道对每个字符独立的作用（一个按如此方式工作的通道称为无记忆通道）。自然，一旦 $p(y|x)$ 和 $X = \{x, p(x)\}$ 给定了，则 $p(x|y)$ 和 $Y = \{y, p(y)\}$ 也就确定了。

为了建立一个可达到的比率，再次考虑对随机码的平均。那里码符是以先验概率（由 X^n 支配的）选择的。于是，这些码符将以高的概率从字符弦的典型弦序列中选定。那里大约有 $2^{nH(X)}$ 个这样的典型弦。

对于 Y^n 中一个典型的接受信息，存在着大约 $2^{nH(X|Y)}$ 个能够送出来的信息。可以将收到的信息和一个包含 $2^{n(H(X|Y)+\delta)}$ 个可能输入的一个球相联系的办法来解码。如果在这个球中存在唯一的码符，就从这个码符中解码出信息。

和前面一样，球中不可能不存在码符，但必须排除多于一个码符的概率。每个解码球包含典型输入的一个份额

$$\frac{2^{n(H(X|Y)+\delta)}}{2^{nH(X)}} = 2^{-n[H(X)-H(X|Y)-\delta]} = 2^{-n[I(X;Y)-\delta]}$$

这里 $I(X;Y) = H(X) - H(X|Y)$ 为前面的互信息。假如存在 2^{nR} 个码符，任一个偶然落入解码球中的概率是

$$2^{nR} 2^{-n[I(X;Y)-\delta]} = 2^{-n[I(X;Y)-R-\delta]}$$

由于 δ 可选作任意小，可以选择 R 尽量接近 I （但要小于 I ），并仍然使解码失误概率当 $n \rightarrow \infty$ 时呈指数减少。

这个论证表明，对随机码和码符作平均时，一次失误的概率对于任意比率 $R < I$ 来说变得很小。和前面同样的理由，说明对于每个码符以失误概率 $< \varepsilon$ 的一个特殊码的存在性。这是一个满意的结果，因为它与对 I 的解释是一致的，将 I 解释作为这样的信息：当获得信号 Y 时，所得到的输入 X 的信息——就是说， I 是能够沿通道传送的每个字母的信息。

互信息 $I(X;Y)$ 不仅依赖于讯道的条件概率 $p(y|x)$ ，而且也依赖于字符的先验概率分布 $p(x)$ 。上面的随机编码论证能应用于 $p(x)$ 的任意选择，所以就说明了，对于任何小于

$$C \equiv \max_{\{p(x)\}} I(X;Y) \quad (13.23)$$

比率 R 作无失误的传送都是可能的。 C 被称作讯道的容量，它现在只决定于讯道的条件概率 $p(y|x)$ 。

iv)至此已经证明了，任何 $R < C$ 的比率是可以达到的。但是，还必须回答：当 R 超过 C 的情况下，当 $n \rightarrow \infty$ 时失误概率仍然趋于零吗？在一般情况下 C 是比率 R 的上限的证明，考虑到对不同字符失误概率会有不同，比起利用双对称通道来作的证明看来需要更细緻一些，在设计码的时候并没有考察这一点，现在推究如下：

假设已选 2^{nR} 个字符的弦作为码符。考虑一个概率分布（记为 $\tilde{X}^n$ ），在这个分布中每个码符以等概率（ $=2^{-nR}$ ）发生。显然有

$$H(\tilde{X}^n) = nR \quad \left(\text{左边} = - \sum_{i=1}^{2^{nR}} (2^{-nR}) \log(2^{-nR}) = \frac{1}{2^{nR}} \cdot nR \cdot 2^{nR} = nR \right)$$

通过讯道送出码符时，得到输出态的一个概率分布 $\tilde{Y}^n$ 。

因为假设讯道对每个字符的作用是独立的，一条 n 字符的弦的条件概率可以因式化为

$$p(y_1 y_2 \cdots y_n | x_1 x_2 \cdots x_n) = p(y_1 | x_1) p(y_2 | x_2) \cdots p(y_n | x_n)$$

于是可得条件熵满足

$$H(\tilde{Y}^n | \tilde{X}^n) = \langle -\log p(y^n | x^n) \rangle = \sum_i \langle -\log p(y_i | x_i) \rangle = \sum_i H(\tilde{Y}_i | \tilde{X}_i)$$

这里 $\tilde{X}_i$ 和 $\tilde{Y}_i$ 是在码符上的分布所决定的第 i 个字符的边缘概率

（*marginal probability*）分布。回忆起 $H(X, Y) \leq H(X) + H(Y)$ ，或

$$H(\tilde{Y}^n) \leq \sum_i H(\tilde{Y}_i)$$

可得

$$\begin{aligned} I(\tilde{Y}^n; \tilde{X}^n) &= H(\tilde{Y}^n) - H(\tilde{Y}^n | \tilde{X}^n) \\ &= \sum_i \{H(\tilde{Y}_i) - H(\tilde{Y}_i | \tilde{X}_i)\} = \sum_i I(\tilde{Y}_i; \tilde{X}_i) \leq nC \end{aligned}$$

送出和收到（ n 个字母的）一条信息的互信息的上限不超过每个字母的互信息之和；而每个字符的互信息上限不超过容量 C （ $\because C$ 被定义为 $I(X;Y)$ 的最大值）。

忆及互信息的对称性，有

$$I(\tilde{X}^n; \tilde{Y}^n) = H(\tilde{X}^n) - H(\tilde{X}^n | \tilde{Y}^n) = nR - H(\tilde{X}^n | \tilde{Y}^n) \leq nC$$

现在，如果无失误传送是可能的，也即我们能当 $n \rightarrow \infty$ 时可靠地解码，就意味着，输入的码符完全由所收到的信号所决定，或是每个字符的输入条件熵必定很小

$$\frac{1}{n} H(\tilde{X}^n | \tilde{Y}^n) \rightarrow 0$$

于是由上面 $I(\tilde{X}^n; \tilde{Y}^n)$ 第二式即得

$$R \leq C \quad (13.24)$$

等号当 $n \rightarrow \infty$ 极限时成立。比率不能超过容量（回忆起条件熵是不对称的，不像互信息）。（实际上， $\frac{1}{n} H(\tilde{Y}^n | \tilde{X}^n)$ 并不变小，因为讯道引入了对于将接受的信息的不确定性。但是假如我们能精确地解码，只要信息被接收到了，就不存在关于被传送码符的不确定性。）

到此，我们就证明了 **Shannon 噪声讯道编码定理——Shannon 第二定理：“容量 $C \equiv \max_{\{p(x)\}} I(X;Y)$ 是通过噪声讯道通讯时所能达到的最高比率。这时，当信息字符数趋于无穷时，失误概率趋于零”。也可以换一种说法：“没有噪声离散无记忆**

讯道，其容量为 C 。只要信息传输率 $R < C$ ，则总存在编码方法，可使译码错误概率渐近地任意小；若 $R > C$ ，则不存在这样的编码方法”。

自然，上面用以证明 $R = C$ 的方法是在渐近下获得的（沿随机码平均）。这并不是一个十分肯定和积极的证明，因为一个随机码没有结构和型式，编码和解码会是相当笨重和不合用的（显然它需要一本指数增大的码书）。尽管如此，定理是十分重要和有用的。因为它告诉我们：什么是原则上可以达到的，什么是原则上不可能达到的。并且，因为 $I(X;Y)$ 是 $X = \{x, p(x)\}$ （ $p(y|x)$ 固定）的一个凸函数（*concave function*——实际含意为向外凸性，但按数学定义是如此用字）。它有唯一的一个局域极大值。于是对感兴趣的讯道， C 是可以算出来的（至少可以数值计算出来）。