

信源与信源无失真编码

2020年4月3日 21:59

0. 概述：

我们可以通过信息论来讨论无失真压缩的极限。这也是香农信息论的第一大定律：信息无失真压缩定理。基本思路就是在信息量不变的前提下，提高每个码字的信息量，从而降低码字长度。那么我们希望一是尽可能使分布均匀是同等概率分布下，我们可以通过渐进等同分割性质和模型序列表完成这一目标。下面来讨论一下。

1. 渐进等同分割性质

首先回顾一下概率论中的大数定律。伯努利在1713年首先给出了频率稳定性公理化表达，该结论是大数定律的第一个。

在一个“成功”概率为 P 的伯努利试验序列中

$$X_n = \begin{cases} 1, & \text{第一次试验A发生.} \\ 0, & \text{第一次试验A不发生.} \end{cases} \quad S_n = \sum_{i=1}^n X_i, \quad n=1, 2, \dots$$

对于任意正数 ϵ 和 δ ，存在正整数 N 。当 $n > N$ 时，有

$$P\left(\left|\frac{S_n}{n} - P\right| \geq \epsilon\right) < \delta \quad \text{或} \quad P\left(\left|\frac{S_n}{n} - P\right| < \epsilon\right) \geq 1 - \delta$$

通俗点讲就是频率等于概率，经验分布趋于统计分布。

那么渐进同等分割（Asymptotic Equipartition Property）就是对一段随机变量序列进行等同分割，让其从一维到无穷大。

由弱大数定律可知，当分段的长度无限大时，任何事件出现的概率都将趋于概率。那么差不多所有的事件都将等概率出现。对于数据压缩的应用也很清晰。（即每一个事件出现的概率 p_k ，有 $|p_k - P(k)| < \epsilon$ ）

○ 等同分割 \Rightarrow 等概率 \Rightarrow 表示高熵 \Rightarrow 定长编码原理。

○ 增添了一种定长编码方法。

下面我们对其进行严格的数学推导：

$$\text{如果 } X_1, X_2, \dots \text{ 是独立同分布的离散随机变量，分布服从 } p(x_1) \text{ 则 } -\frac{1}{n} \log p(X_1, X_2, \dots, X_n) \xrightarrow{P} H(X)$$

“ \xrightarrow{P} ”代表以概率 P 收敛于 $H(X)$ 。

对于这个数学表达可以这样理解。首先我们考虑正都是无记忆的平稳信源，即

$$P(w_1, w_2, \dots, w_{i+n} = A) = P(w_1, w_2, \dots, w_{i+n} = A)$$

其中 A 为固定的序列。这种是离散公平随机过程。那么对于某一个消息序列的信源率为 $-\log p(X_1, X_2, \dots, X_n)$ 。当 n 趋于无穷大时，则称等价大数定律，成为等概性情况。 $-\log p(X_1, X_2, \dots, X_n)$ 即为平均一个码元携带的信源率。那么即为信息熵。偏离这个等概率分布会损失很多。

由此我们可以给出一个模型序例，我们给出数学上的严格度量。

相对于分布 $p(x)$ 和序列 $(X_1, X_2, \dots, X_n) \in \mathcal{X}_n$ 。模型序例集合 $A_{\epsilon}^{(n)}$ 定义为满足下列不等式约束的子序列集

$$2^{-n(H(X)+\epsilon)} \leq p(x) = p(X_1, X_2, \dots, X_n) \leq 2^{-n(H(X)-\epsilon)}$$

这个其中也是由弱大数定律直接得来。

$$P\left(\left|\frac{S_n}{n} - P\right| \geq \epsilon\right) < \delta \rightarrow \log p(w) = \sum_{k=1}^n w_k \log p(w_k) \geq n \cdot \sum_{k=1}^n \frac{w_k}{n} p(w_k)$$

我们再构造证明过程，即得

$$2^{-n(H(X)+\epsilon)} \leq p(w) = p(X_1, X_2, \dots, X_n) \leq 2^{-n(H(X)-\epsilon)}$$

由上述证明过程和定义，我们发现模型序例满足以下性质。

1. 若 $x \in A_{\epsilon}^{(n)}$ ，则 $H(X) - \epsilon \leq -\frac{1}{n} \log p(x) \leq H(X) + \epsilon$ 。

2. 若 n 足够大。 $P(A_{\epsilon}^{(n)}) > 1 - \epsilon$ 。（这里我们给出一个证明方法，见附录）

$$2^{-n(H(X)-\epsilon)} < |A_{\epsilon}^{(n)}| < 2^{-n(H(X)+\epsilon)}$$

2. 若 ϵ 是够大. $\Pr\{A_{\epsilon}^{(n)}\} \geq 1 - \epsilon$. (这里我们给出一个证明方法, 见附录.)

$$3. (1 - \epsilon) 2^{n(H(x) - \epsilon)} \leq |A_{\epsilon}^{(n)}| \leq 2^{n(H(x) + \epsilon)}$$

性质1和性质2可以直接由定义得到. 简单证明一下性质3

$$1 = \sum_{x^n \in X^n} P(x^n) \geq \sum_{x^n \in A_{\epsilon}^{(n)}} P(x^n) \geq \sum_{x^n \in A_{\epsilon}^{(n)}} 2^{-n(H(n) + \epsilon)} = 2^{-n(H(n) + \epsilon)} |A_{\epsilon}^{(n)}|$$

$$1 - \epsilon \leq \Pr\{A_{\epsilon}^{(n)}\} \leq \sum_{x^n \in A_{\epsilon}^{(n)}} 2^{-n(H(n) - \epsilon)} = 2^{-n(H(n) - \epsilon)} |A_{\epsilon}^{(n)}|. \Rightarrow |A_{\epsilon}^{(n)}| \geq (1 - \epsilon) 2^{n(H(n) - \epsilon)}$$

由此性质3则证明完毕.

典型序列的个数大约有 $2^{n(H(x) + \epsilon)}$ 个. 而 $|X|^n$ 有很多. 非典型序列的集合只是所有可能序列的一个子集. 但好处是它几乎不会是空集. 因此. 我们完成了几乎没有失真. 从非典型序列等概率的过程. 我们可以基于这个达到无失真的定理来证明.

2. 编码原理.

编解码原理就是尽量把 n 取得很大. 从而使用的几乎都是典型序列. 从而在信噪比较小的情况下. 尽可能的压缩编码.

下面我们将省略.

设 X^n 是由独立同分布离散随机变量 $x \sim P(x)$ 构成的序列. 对于任意正数 ϵ . 也有足够大 n . 可以找到一个一一映射, 将 X^n 映射成二进制序列, 且满足.

$$E\left[\frac{1}{n} h(x^n)\right] \leq H(x) + \epsilon.$$

下面我们将简单的证明并给出一个例子. 故而省略一下.

我们编码的平均码长为 $E[h(x^n)]$

$$E[h(x^n)] = \sum_{x^n \in X^n} p(x^n) h(x^n) = \sum_{x^n \in A_{\epsilon}^{(n)}} p(x^n) h(x^n) + \sum_{x^n \in A_{\epsilon}^{(n)}} p(x^n) h(x^n)$$

$$\leq \sum_{x^n \in A_{\epsilon}^{(n)}} p(x^n) \cdot [n(H(x) + \epsilon) + 1 + 1] + \sum_{x^n \in A_{\epsilon}^{(n)}} p(x^n) [n \log |X| + 2]$$

$$= \Pr\{A_{\epsilon}^{(n)}\} [n(H(x) + \epsilon) + n\epsilon + 2] + \Pr\{\overline{A_{\epsilon}^{(n)}}\} [n \log |X| + 2]$$

$$\leq n(H(x) + \epsilon) + 2 + n\epsilon \log |X| + 2\epsilon$$

$$= n(H(x) + \epsilon'). \quad \text{其中 } \epsilon' = \epsilon + \epsilon \log |X| + \frac{2\epsilon}{n}$$

|简单说明:

|平均码长可分为典型序列和非典型序列之和.

|采用典型序列的定义. 进行缩放. 非典型序列直接缩放到一般化值.

| $+1, +1$ 是由于进位取整来转换为典型序列.

|代入良 X . 为线性缩放.

|可见 $n \rightarrow \infty$ 时. $\epsilon' \rightarrow 0$.

|于是得证.

取一个实际的例子.

设信源 X 为车辆行驶状态分布为

$$\begin{pmatrix} X \\ P(X) \end{pmatrix} = \begin{pmatrix} a_1 & a_2 & a_3 & a_4 & a_5 & a_6 & a_7 & a_8 \\ 0.40 & 0.18 & 0.10 & 0.10 & 0.07 & 0.08 & 0.05 & 0.04 \end{pmatrix}$$

要求编码错误概率不小于 10^{-8} , 且编码效率大于 90%. 求最小可行分组长度.

首先定义一下错误概率. 也就是非典型序列的错误率.

$$\Pr\{\overline{A_{\epsilon}^{(n)}}\} \leq \frac{D(I(x))}{N^{\epsilon}}$$

这个公式目前不知道怎么求出来.

接着. 我们定义编码效率. 编码效率的极限值是完全无失真压缩, 即使条件非常多, 信息熵也尽可能不会减小.

那极限值就是 $H(x)$ 即 $I(x)$. 那么我们能达到的极限是 $H(x) + \epsilon'$, 这在上面的证明中也给到了. 编码效率即为

$$\frac{H(x)}{H(x) + \epsilon'}, \quad \frac{H(x)}{H(x) + \epsilon'} > 0.9 \Rightarrow \epsilon' < 0.28 \Rightarrow \Pr\{\overline{A_{\epsilon}^{(n)}}\} \leq 10^{-8} \Rightarrow N > 10^8.$$

关于编解码原理, 就这样.

$$H(x)+\varepsilon, H(u)+\varepsilon > 0 \Rightarrow \varepsilon < 0.28 \Rightarrow N > 10^6$$

关于定长编码的更理的总结：

首先我们需要知道为什么会有定长编码，所以我们需要有一个以简单之极限，这个极限是商进制。随着分组码的增加，平均每个字母的熵 $H(u)$ 为极限值。数学上即 $H_{\infty}(U) = \frac{1}{N} H(U_1, U_2, \dots, U_N)$ 。而对于商进制信源，有一条定理 $H_{\infty}(U) = \lim_{N \rightarrow \infty} H(U_1, U_2, \dots, U_{N-1})$ ，证明过程可参考教材，较为精炼的见 [1]。

根据商进制信源的定义

$$H(U_1 | U_2, U_3, \dots, U_{N-1}) = H(U_{N-1} | U_1, \dots, U_{N-2})$$

这体现了时间上的无记忆。而根据条件减少熵。

$$H(U_1 | U_2, U_3, \dots, U_{N-1}) \geq H(U_1 | U_1, \dots, U_{N-1})$$

我们可以看到条件熵随着 N 的增大而减小。

$$NH_{\infty}(U) = H(U_1) + H(U_2 | U_1) + \dots + H(U_N | U_1, U_2, \dots, U_{N-1})$$

$$\geq NH(U_1 | U_1, U_2, \dots, U_{N-1})$$

我们可以知道，信息熵的降低是时间上统计失真使信息量减少的主要原因。

$$\text{另一方面, } NH_{\infty}(U) = H(U_1 | U_1, U_2, \dots, U_{N-1}) + (N-1)H_{\infty}(U), \text{ 且 } H_{\infty}(U) \geq H(U_1 | U_1, U_2, \dots, U_{N-1})$$

从而得到 $H_{\infty}(U) \leq H_{N-1}(U)$ ，下同。

我们可知 N 减少时，熵增大。由单向极性可知 $H_{\infty}(U) \leq \log k$ ， k 为源字典表长度。

因此，当信息源分布不均匀时，即使不存在依赖关系，也不能最大限地压缩带信息。

那么反映信息有效程度的物理量就是冗余度和对冗余度。

冗余度： $\log k - H_{\infty}(U)$ ，相对冗余度： $1 - \frac{H_{\infty}(U)}{\log k}$ 。我们进行定长编码时使各独立度为独立，非等概度为等概的过程。

关于定长编码定理我们还有一个形式的定理：

设信息率为 $H_{\infty}(U)$ ，商进制无记忆信源被分成 N 个子信源，其平均长度为 \bar{J} ，并用长为 \bar{J} 的码字组进行编码，而每组长度为 J 。

则对于任意的 $\epsilon > 0$ 和 $\delta > 0$ ，只要 N 足够大，且满足不等式

$$\frac{N}{\bar{J}} \log J > H_{\infty}(U) + \delta.$$

则源字典表没有自己特有的符号本段平均 \bar{J} 可以大于 \bar{J} 。

这个定理证明比较简单。

$$N_G = 2^{N(H_{\infty}(U) + \delta)}$$

我们只编得模型序列，那么只要不小于 \bar{J} 就大于模型序列数。

$$J^N \geq 2^{N(H_{\infty}(U) + \delta)} \Rightarrow N \log J \geq N(H_{\infty}(U) + \delta) \Rightarrow \frac{N}{\bar{J}} \log J \geq H_{\infty}(U) + \delta.$$

但是定长编码定理只是证明了理论上可行，实际上，正如例题所示，一个较好的定长编码需要增加 δ 的分组长度。这无论从时间延迟，还是硬件成本，都是无法接受的。我们也无法找到一个满意的解决方案，这也充分说明应用范围不广的弊端。

3. 变长码

3.1 变长码的类型

研究无失真编码一定要保证是一一映射，那么我们称其为非奇异码。

若一个码 C 可以将不同的 X 映射为不同的 $C(X)$ 为例，即

$$X = X' \Rightarrow C(X) \neq C(X')$$

则称该码为非奇异码。

但即使是一一映射也会有麻烦，例如，对于不等长的编码

$$C(X_1) = 0, C(X_2) = 1, C(X_3) = 01$$

则码的解出现了歧义，那么我们为了改进则有了唯一译码，定义如下。

称码 C 是不等长的广义，当 C 是有限长 X 序列到有限长 D 一进制序列的映射，且满足

$$C(X_1, X_2, \dots, X_n) = C(X_1)C(X_2) \dots C(X_n)$$

那么当其扩展是非奇异的，我们则称为唯一译码。

这是更是一个定义上的解答，并没有可建设性方案，换言之，没有码序是不等长的组合。

例如 $C(X_1) = 0, C(X_2) = 01, C(X_3) = 10$ ，则序列 01010010 唯一译码为 $X_1 X_1 X_3 X_1 X_2 X_1$ ，你已经注意到这个计算法们可实现。还有一个译码非唯一译码，即两个不同的序列可以译码为同一个码字。

(这其实是一个定义上的解答，并没有可建设性方案。换言之，没有码序是不可字元组合)
 例如 $C(x_1) = 0$, $C(x_2) = 01$, $C(x_3) = 11$. 则序列 06110010 唯一可译为 $x_1 x_1 x_3 x_1 x_2 x_1$
 但是经过自己的计算我们可知，这是有一个译码并且译码过程需要回退。
 虽然唯一可译不易可以解决译码匹配问题，但是对于解码器的实现和理解，于是我们需要另一种速度更快的解码称为
 即时码。也将称为前缀码。

当没有码序是其他不可字元的前缀时，那么则称该前缀码为即时码。

例如： $C(1) = 0$, $C(2) = 10$, $C(3) = 110$, $C(4) = 111$ ，则序列 01011111010 直接可译为 12432。
 这是一种很好性质的码。

简述一下各码之间的关系：

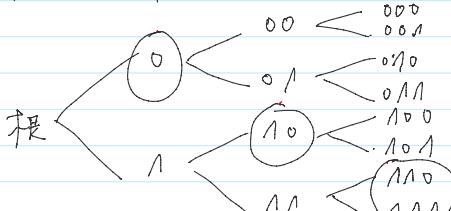
即时码 \subset 唯一可译码 \subset 非奇异码 \subset 所有码。

莫尔斯电码不是唯一可译码，需要发报者的干涉。

汉语：“没有鸡鸭也可没有鱼肉也可青菜豆腐不可少。”这是歧义句。没有汉字没有标点也不是唯一可译码。

3.2 Kraft 不等式与香农第一定理

我们已经知道了前缀码具有较好的性质，我们从定义中也可以直接得到，前缀码不能使用最短的不符号，否则消去的条件无法满足，我们可以用二叉数来表示。



我们能够发现，无论是宽长还是瘦长都对应树的叶子。例如，我们可能这样选取前缀码。

那么我们仍需要回答如何构造前缀码？前缀码存在什么特征是什么？

实际上通过树图，我们已经可以很直观的发现其中的规律，下面我们将以公式用数学语言来描述。
 由于前缀码只在树上，D 由树构成 D 为树。若被选为不符号的左或右叶子会被删除。没有前缀码为 l_1 ，最长为 l_{max} 。
 所所有

$$D^{-l_i} = D^{-l_{max}} \cdot D^{l_1 + l_2 + \dots + l_k}$$

于是，设含有 k 个语言字母的信源需要用 D 个字母的码字表示进行变长编码，则且仅当各不符号的长度 l_1, l_2, \dots, l_k 满足 Kraft 不等式。

$$\sum_{i=1}^k p_i^{l_i} \leq 1.$$

我们已经证明了必要性 3. 关于充分性的证明其实差不多。我们只是要砍掉其他的叶子，所以这个过程一定是可逆的。
 只不过这一项还有一个必要条件，但是它仅仅是从编码的构造考虑，与码是否最优无关。以后我们再考虑最优化。
 关于码的长度，变长编码一致，有以下的定理。

对于随机变量 X 進行 D -进制前缀码编解码。令 $H_D(X)$ 表示 X 的熵， $L = H_D(X)$ ，等价于 $D^{-l_i} = p_i$ 时成立。

证明如下：

$$\begin{aligned} L - H_D(X) &= \sum p_i l_i - \sum p_i \log \frac{1}{p_i} \\ &= \sum p_i \log \frac{D^{-l_i}}{p_i} = \sum p_i \log D^{-l_i} - \sum p_i \log p_i \\ &= \sum p_i \log D^{-l_i} - \sum p_i \log \frac{D^{-l_i}}{D^{-l_i}} = \sum p_i \log D^{-l_i} - \sum p_i \log D^{-l_i} - \log D \end{aligned}$$

其中 $\Delta = \sum D^{-l_i}$ ，那么上式即变为

$$L - H_D(X) = \sum p_i \log D^{-l_i} + \log \frac{1}{\Delta}$$

根据隔壁的信息对数本不等式，第一项大于 0。由 Kraft 不等式，第二项也大于 0。即 $p_i < 1$ 时正
 与是我们找到了一个下界。我们发现当 $D^{-l_i} = p_i$ 时，可以直接取等。

这里稍微分析一下这个定理，对于一个有 k 个字母的信源，每个字母出现的概率为 p_i ，那么这个信源的熵因为他的平均带宽含
 有 $\sum p_i \log \frac{1}{p_i}$ ，而我们为了使这个熵尽可能小，那么 p_i 应该尽可能大，即 $p_i = 1/k$ ，这时 $\sum p_i \log \frac{1}{p_i}$ 一个常数，即固定值（这个不等式）

与我们找到了一个下界，我们发现当 $l_i = p_i$ 时，可以直接取等。
 ⑤里稍讲的是另一个定理，对于一个有 k 个字母的信源，每个字母出现的概率为 p_i ，那么这个信源的熵因为他的概率分布而固定。而我们的哈夫曼编码是既 p_i 是一个对称树，于是我们利用了这个对称树实际上也直接反映了这个平均概率分布。这个不等式等价于一个余比文的熵公式也是相同的。所以我们有了这样一个结论。
 实际上鉴别信息也告诉我们 3-1 页道理，要让这个平均长度也靠近新分布信息量更小，我们应该让概率分布更可能的靠近原始分布，这样可以使信息熵鉴别信息下降。
 那么最优的码长应为多少呢？有以下定理，这个定理也被称为香农第一定理。

对于信源 X 有 $H(X) \leq L^+ \leq H(X) + 1$

$H(X)$ 对于非独立的情形应严格写为 $\frac{H(X)}{\log J}$
 (这个定理的证明也是非常巧妙的，香农也构造了一个零码，其码长为 $\lceil \log \frac{1}{p_i} \rceil$)。那么

$$\sum D - \lceil \log \frac{1}{p_i} \rceil \leq \sum D - \log \frac{1}{p_i} = \sum p_i = 1$$

所以满足 Kraft 不等式，一定是一个唯一可译码。

$$\log \frac{1}{p_i} \leq \log \frac{D}{p_i} = \log D - \log p_i + 1.$$

$$\Rightarrow H(X) \leq \sum p_i l_i \leq H(X) + 1.$$

$$\Rightarrow H(X) \leq L^+ \leq H(X) + 1.$$

为什么码一定不能比这个码更差，那么巧妙的证明，请看。

那么良码能告诉我们的我们可以做到平均码长和元概率之间有 ϵ 的误差，而变长编码则有一个优势，我们还可以将两者结合做的更好。

对于信源 X 有 $H(X) \leq L^+ \leq H(X) + 1$ 满足不等式

$$\frac{H(X_1, X_2, \dots, X_n)}{n} \leq L_n^+ \leq \frac{H(X_1, \dots, X_n)}{n} + \frac{1}{n}$$

这个过程就是先分组，然后进行变长编码，若信源独立，那么 $L_n^+ \sim H(X)$ 。

如果我们对信源分布的估计出了偏差，那么性能一定不会变好，因为鉴别信息的非负性，定量的分析有如下定理

对于服从 p_i 的信源 X (进行前缀编码)，若码字长度取 $l_i = \lceil \log \frac{1}{p_i} \rceil$ ，则平均码长满足

$$H(p) + D(p||q) \leq E_p(l_i) < H(p) + D(p||q) + 1.$$

因为 $H(q) = H(p) + D(p||q)$ ，所以这个定理实际上并不需要证的。

3.3. 几种前缀变长码分析

3.3.1 香农码。

香农码在一般情况下有非最优情况。

我们举一个简单例子。

$$k=2, p(k_1)=0.9999, p(k_2)=0.0001, \text{那么 } l_1=1, l_2=14.$$

我们可以计算一下。

$$H(k) = p(k_1) \log \frac{1}{p(k_1)} + p(k_2) \log \frac{1}{p(k_2)} = 1.47 \times 10^{-3}.$$

$E(l_{\text{shannon}}) = 0.9999 \times 1 + 0.0001 \times 14 = 1.0013$ 。但是我们依然可以用 1 比特搞定，且他的平均码长差距也很远。

其原因也很直白易见，当对一个这样的码 $\log \frac{1}{p_i}$ 向左取整时，误差可能会非常大，这时我们会有很大的冗余，码长会很长。

3.3.2. Huffmann 编码。

Huffmann 作为于士华在 1952 年提出的，可以证明 Huffmann 编码具有最优性，即给定信源符号的根分布和码字的根分布下，没有其他码字序列比 Huffmann 编码更短且平均码长。

先抛开 Huffmann 编码不谈，我们对上面的例子进行更深入的分析。

$$H(k) = p(k_1) \log \frac{1}{p(k_1)} + p(k_2) \log \frac{1}{p(k_2)} = p(k_1) \cdot 1.44 \times 10^{-3} + p(k_2) \cdot 13.2.$$

$$E(l) = p(k_1) l_1 + p(k_2) l_2.$$

通过二叉树我们可以发现，让 k_2 的长度可以为 1，最后平均码长为 1.44，平均码长。

当然，这个过程违背了鉴别信息对于平均码长的理论指导，但是，我们经过人为的修正，可以更好的减少误差，Huffmann 算法（这么做）让概率大的信源的码长更可能短，当然前提是能短的话。

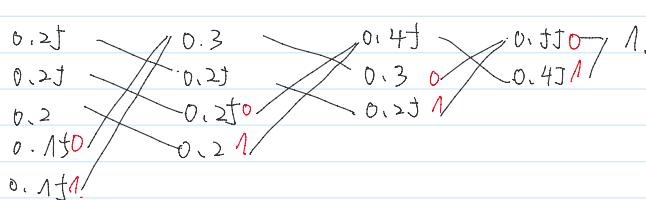
（注：由于千篇一律的讲法，导致理解起来比较困难，所以本章的大部分内容都从头开始讲，希望大家能够理解。

当然这个过程违背了监督信息对于平均码长的理论指导. 但是, 我们经过人为的修正, 可以更好的减少误差. Huffman 算法(这个很公平)让概率大的信源更可能被选中, 当然前提是能编码到.

编序不对(信源上是均匀分布, 接下来是大到小分布, 然后进行对称排列, 我们举一个来说明)

考虑 $(1 \ 2 \ 3 \ 4 \ 5)$
 $(0.25 \ 0.25 \ 0.2 \ 0.15 \ 0.1)$

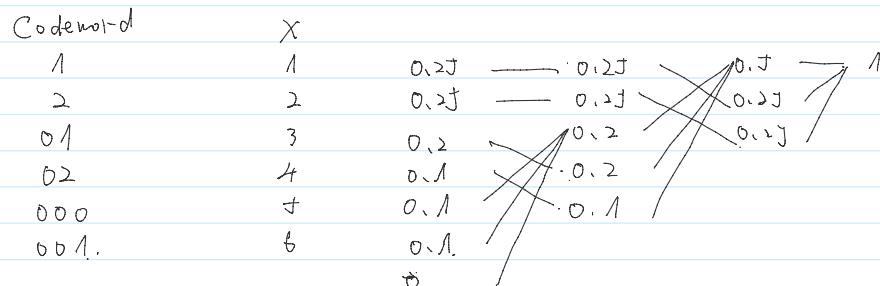
Huffman 编码生成树.



最后与到

1 $\rightarrow 01$
 2 $\rightarrow 10$
 3 $\rightarrow 11$
 4 $\rightarrow 000$
 5 $\rightarrow 001$

三进制有三个分支, 这时出现了问题可以剪一些枝条. 如下所示情形, 每次迭代缩减减少($D-1$), 由于最初有一支重叠, 所以要由 D 缩减为 1. 剪完后还应该一分为二和 $k(D-1)$.



Huffman 算法不精确在于他取极性. 我们接下来从最简单的二元情形证明他, 这个证明也比较容易推广到其他形式. 我们通过分析也发现了. 对于二元情形, 我们要让他尽可能短, 一直走依次排列. 但概率较小的很多尽可能长. 于是本章有两条定理

1. 对于给定的离散无记忆信源, 存在一个最优的二元前缀码. 这个码中最小发生概率的两个字具有相同长度且码中相同长度的字具有两个或两个以上时, 码中必有两个字的字节差只在最高一位.

2. 设 C' 是某信源经缩减后得到的编译码库, 其中最短的前缀码不短于 C , 将 C' 中由原信源的最小概率的两个字节缩减得到的字节所对应的字节各加 1, 作原信源的最小概率的两个字节其字节不变, 则这样得到的码 C 对原信源也是最佳的.

第一个定理的证明可以用反证法. 第二个则可以用第一个定理得到. 详细的证明可以参见《应用信息论基础》.

3.3.3 算术编码

在之前的讲解中, 当 $\log p(a_k)$ 不为整数时, 我们要通过扩展字母的办法来改进压缩效果, 即需要分组, 这自然会使编译码更复杂. 我们可以用树对某字符做一个问题.

对于离散无记忆信源树码的一种长阵编码方法是由 P. Elias 提早在一篇未发表的研究报告中提到. 后注下, Jelink 和 Rissanen 等人改进和发展进入实用, 现在人们一般称之为算术码 (Arithmetical Coding).

3.3.3.1 基本概念

设信源序列表为 a_1, a_2, \dots, a_k , 序列 a_k 的概率是 $p(a_k)$ ($k = 1, 2, \dots, k$), 将字母按其出现概率排序并记作 $a_1 > a_2 > \dots > a_k$, 于是, 可以将 a_k 序列按概率.

$$F(a_k) = \sum_{a_i > a_k} p(a_i)$$

再定义修正概率

$$\bar{F}(a_k) = \sum_{a_i > a_k} p(a_i) + \frac{1}{2} p(a_k)$$

那么我们能得到一个积累值 $F(a_k)$ 和 $\bar{F}(a_k)$, 将这个值用相对应的树表示, 则可以得到字母. 举一个例子.

a_k	$p(a_k)$	$F(a_k)$	$\bar{F}(a_k)$	$\bar{F}(a_k)$ 二进制表示	字母	Huffman 编码
a_1	0.25	0.25	0.125	0.001	001	10
a_2	0.5	0.75	0.5	0.10	10	0
a_3	0.125	0.875	0.875	0.1101	1101	110
a_4	0.125	1	0.9375	0.11111	11111	1111

我们可知编码树.对于长的序列的直接进行编码效果不是很好,这不如Huffman编码.这是因为前缀是修正的Kraft代表的也是一个线段长.所以既有冗余,也有对信源的扩展.还是当阶段长度缩短.当信源长度趋于无限时,平均在区间内成为一点,即pm冗余则会随着长度而自然降低(举一个假设分布的例子 $X \sim B(0.6)$).

设信源在输出第n-1个字符后,平均在区间为 $[A_{n-1}, B_{n-1}]$, 那么有

$$\begin{cases} A_n = A_{n-1} \\ B_n = A_{n-1} + 0.6(B_{n-1} - A_{n-1}) \end{cases} \quad m_n = a_0$$

$$\begin{cases} A_n = A_{n-1} + 0.6(B_{n-1} - A_{n-1}) \\ B_n = B_{n-1} \end{cases} \quad m_n = a_1$$

我们可知随着n增大区间越来越小,而最后趋于一个点.

当信源输出第N个信源符号时,不再输出的是此时 A_n 和 B_n 中未被标记部分.此时输出也是一个有限数.二元树码的长度应为 m .

$$\frac{1}{2^m} > \prod_{n=1}^N p(m_n) > \frac{1}{2^{m+1}}$$

3.3.3.2 极限情况下压缩效果.

对于长的信源序列,同样可以加以分析.

例如有 $v_n = m_1 m_2 \dots m_N$, $v'_n = m'_1 m'_2 \dots m'_N$

若存在 $t \leq N$, 使

$$m_n = m'_n \quad \text{当 } n < t \text{ 时}$$

$$m_t > m'_t \quad \text{当 } n = t \text{ 时}$$

则记 $v_n > v'_n$, 我们对此信源序列进行排序.可定义 v_n 的累积概率为

$$F(v_n) = \sum_{v'_n > v_n} p(v'_n)$$

现设序列 v_n 与字符 m_{n+1} , 形成新序列 $v_{n+1} = v_n m_{n+1}$, 则此序列的概率为

$$p(v_{n+1}) = p(v_n) p(m_{n+1})$$

此时的累积概率为

$$\begin{aligned} F(v_{n+1}) &= \sum_{v'_{n+1} > v_{n+1}} p(v'_{n+1}) \\ &= F(v_n) + p(v_n) \sum_{m_{n+1} > m'_n} p(m'_{n+1}) \\ &= F(v_n) + p(v_n) F(v_{n+1}) \end{aligned}$$

由于累积概率随序列表示的平移而增加.所以只要将区间

$$[F(v_n), F(v_n) + p(v_n) F(v_{n+1})]$$

用有限精度二进制数加以表示.并将此二进制数与 v_n 加以对应.就可以实现无失真编码.由于这种情况下存在冗余分量仍然是 Kraft 不等式.所以在极限情况下,算术码可以实现对信源压缩的无失真编码.

3.4 高效码率的信源熵

关于不可失真译码基本内容这里不在描述.参阅随机信号处理.

求熵首先要求条件熵.

设过去某一时刻的状态为 $S_1 = i$, 现在要求即时状态信源输出序列的熵

$$H(U_m | U_1 U_2 \dots U_{n-1}, S_1 = i)$$

$$= - \sum_{U_1 U_2 \dots U_n} p(U_1 U_2 \dots U_n | S_1 = i) \log(p(U_m | U_1 U_2 \dots U_{n-1}, S_1 = i))$$

由算术码定义可知.

1. 即时输出那个字符只与此时信源下处的状态有关,而与以前的状态以及之前已输出的字符无关.

2. 信源未来时刻所处的状态,由当前输出字符和前一时刻信源下处的状态唯一确定.

即 m_i 为前 i 个字符

$$p(m_n | m_1 m_2 \dots m_{n-1}, S_1 = i) = p(m_n | S_1)$$

$$P(U_1, U_2, \dots, U_n | S_1=i) = P(U_1, U_2, \dots, U_{n-1}, S_1=i) \cdot P(U_n | S_1=i)$$

将这两个结果代入定义式中。

$$H(U_n | U_1 U_2 \dots U_{n-1}, S_1=i)$$

$$= - \sum_{S_1=i} p(S_1=i) \cdot P(U_n | S_1=i) \log P(U_n | S_1=i)$$

$$= \sum_{j=1}^S p(S_n=j | S_1=i) H(U_n | S_n=j)$$

那么我们代入前面的 S_1 即可得到条件熵

$$H(U_n | U_1 U_2 \dots U_{n-1}, S_1) = \sum_{j=1}^S p(S_n=j) H(U_n | S_n=j)$$

对于独立且各司其职率 $p(S_n=j)$ 是 S_1 的概率分布函数（平稳分布时），且 $H(U_n | S_n=j)$ 与 n 无关，可以记做 $H(U | S=j)$ 。那么

$$H(U_n | U_1 U_2 \dots U_{n-1}, S_1) = \sum_{j=1}^S p(j) H(U | S=j)$$

有了条件熵之后，就可以根据引理 4 生出若干

$$\frac{1}{N} H(U_1 U_2 \dots U_N | S_1) = \frac{1}{N} \sum_{n=1}^N H(U_n | U_1 U_2 \dots U_{n-1}, S_1)$$

$$= \frac{1}{N} \sum_{n=1}^N \sum_{j=1}^S p(j) H(U | S=j)$$

$$= \sum_{j=1}^S p(j) H(U | S=j)$$

如果不起干扰变动，可简化。

$$P_{(1, N)}(j) = \frac{1}{N} \sum_{n=1}^N p(S_n=j)$$

代入可得

$$H(U_1 U_2 \dots U_N | S_1) = \sum_{j=1}^S P_{(1, N)}(j) H(U | S=j)$$

最后就可以求 $H_{\text{avg}}(U)$ 了。

$$H(U_1 U_2 \dots U_N) = I(S_1; U_1 \dots U_N) + H(U_1 U_2 \dots U_N | S_1)$$

其中

$$I(S_1; U_1 \dots U_N) = H(S_1) - H(S_1 | U_1 U_2 \dots U_N) \leq H(S_1) \leq \log S.$$

代入 $H_{\text{avg}}(U)$ 在定义式中。

$$H_{\text{avg}}(U) = \lim_{N \rightarrow \infty} \frac{1}{N} H(U_1 U_2 \dots U_N)$$

$$= \lim_{N \rightarrow \infty} \left[-\frac{1}{N} I(S_1; U_1 U_2 \dots U_N) + \frac{1}{N} H(U_1 U_2 \dots U_N | S_1) \right].$$

我们可知互信息 $I(S_1; U_1 \dots U_N)$ 在有界上，所以 $\lim_{N \rightarrow \infty} \frac{1}{N} \log S = 0$ 。

$$H_{\text{avg}}(U) = \lim_{N \rightarrow \infty} \frac{1}{N} H(U_1 U_2 \dots U_N | S_1) = \sum_{j=1}^S p(j) H(U | S=j)$$

高斯马尔可夫信源熵是单条件以熵减或 0，由条件熵 + 常数可知 马尔可夫信源熵与熵相似之前提到的高斯无记忆信源相比较更小。

马尔可夫信源之所以重要，也是因为生活中很多情形下都可以用这个模型来表达，例如天气预报、语言文字等。若马尔可夫输出序列相关性只与前 m 个字母输出字母有关，与更早的输出无关，则称之为 m 阶马尔可夫信源。若信源输出字母的总数为 k ，则一般情况下， m 阶马尔可夫信源的总数 $S = k^m$ 。虽然 m 越大，对马尔可夫信源的数学模型就越复杂。

如何选择恰当的 m 阶马尔可夫信源来逼近实际信源，是工程上要考虑的重要问题，例如，英文字母通常认为有 5 个字母，而 m 越大越好，但一般取 m 为 3、4、5。

3.5 高斯马尔可夫信源的编码定理与最佳编码码。

我们在之前提到过一般公平概率分布的信源及其编码定理可以实现理想的压缩，这里也是成立的。

对于一个二进制信源，其输出为 $0, 1, \dots, 2^{k-1}$ ，其概率为 $p_0, p_1, \dots, p_{2^k-1}$ ，则其平均信息量为 $H = \sum p_i \log p_i$ 。

3.5 可逆信源与大数定律及平均码长的计算

我们之前提到过一般平稳遍历的信源是可编译的，可以实现单向无记忆编译，这与也是成立的。

对于变长编译器，我们也可以简单地将离散大写化为信源：原信源变长编译器到了离散字母的长方信源。

设字母可变信源为信源，其状态为 S_1, S_2, \dots, S_N 。信源输出序列 $u = u_1 \dots u_N$ ，每一步可用变长编译器的方法得到一个对应的字符串，其码字长度 $L(u)$ 满足：

$$J^{-L(u)} \leq P(u_1 u_2 \dots u_N | S_1=i) \leq J^{-L(u)+1}$$

此时有

$$\sum_i P(u_1 u_2 \dots u_N | S_1=i) = 1$$

那么所有字符串满足 Kraft 不等式。我们应用香农第一定理。

$$\frac{H(U_1 U_2 \dots U_N | S_1=i)}{\log J} \leq \overline{L} \leq \frac{H(U_1 U_2 \dots U_N | S_1=i)}{\log J} + 1$$

平均到每个字符串是：

$$\frac{H(U_1 U_2 \dots U_N | S_1)}{N \log J} \leq \overline{L} \leq \frac{H(U_1 U_2 \dots U_N | S_1)}{N \log J} + \frac{1}{N}$$

让 N 趋于无穷，代入得：

$$\lim_{N \rightarrow \infty} \frac{1}{N} H(U_1 U_2 \dots U_N | S_1) = \sum_{j=1}^S P(j) H(U_j | S_1=j)$$

即

$$H(U) = \sum_{j=1}^S P(j) H(U_j | S_1=j)$$

于是有

$$\frac{H(U)}{\log J} \leq \overline{L} \leq \frac{H(U)}{\log J} + \frac{1}{N}$$

这就证明了可变信源的变长编译原理。

当用 J 个字时的平均信源熵率为 $H(U)$ ，而离散字母可变信源进行变长编译时，其平均码长满足

$$\frac{H(U)}{\log J} \leq \overline{L} \leq \frac{H(U)}{\log J} + \frac{1}{N}$$

其中 N 为信源字母的分组元数量。

那么当 N 足够大时， \overline{L} 是可以逼近 $\frac{H(U)}{\log J}$ ，从而达到理论的压缩。

附录

1.

$$P(X_n \in A_\varepsilon) > 1 - \varepsilon.$$

$$\text{设 } Z_n = -\frac{1}{n} \log P(X_n) = -\frac{1}{n} \log [\prod_{i=1}^n P(X_i)] = -\frac{1}{n} \sum_{i=1}^n \log P(X_i)$$

$$\Rightarrow E(Z_n) = -\frac{1}{n} \cdot n \cdot H(X) = H(X)$$

$$\text{var}(Z_n) = \frac{1}{n} \text{var}(-\log_2 P(X))$$

$$P(X_n \in A_\varepsilon) = P(|-\frac{1}{n} \log_2 P(X_i) - H(X)| \leq \varepsilon), \text{ 由弱大数定律可知，上面事件也概率为1.}$$

$$= P(|Z_n - E(Z_n)| \leq \varepsilon)$$

二项分布可看作是大数定律的一个特例。

$$= P(|\bar{z}_n - E(\bar{z}_n)| \leq \varepsilon)$$

应用马尔可夫不等式或者切比雪夫不等式：

$$P(x_n \in A_\varepsilon) = 1 - P(|-n - E(\bar{z}_n)| \geq \varepsilon) \geq 1 - \frac{\text{Var}(\bar{z}_n)}{\varepsilon^2} = 1 - \frac{1}{n} \cdot \frac{\text{Var}(-\log P(X))}{\varepsilon^2} \xrightarrow{P(X)}$$

我们想要 $P(x_n \in A_\varepsilon) > 1 - \varepsilon$, 则

$$\frac{1}{n} \cdot \frac{\text{Var}(-\log P(X))}{\varepsilon^2} < \varepsilon \Rightarrow n > \text{Var}(-\log P(X)) / \varepsilon^2.$$

则有 $P(x_n \in A_\varepsilon) > 1 - \varepsilon$.