

结合重正化操作的快速二值分组算术编码器

杨胜天

(浙江大学 信息与电子工程学系, 浙江 杭州 310027)

摘要: 通过使用查表、概率量化和修改的重正化操作的方法, 给出了一个简单的无乘法的二值分组算术编码方案。实验结果显示其平均码字长度比常用的快速编码器更接近于源编码理论的理论下限。

关键词: 分组算术编码; 源编码; 数据压缩

中图分类号: TN911.21

文献标识码: A

文章编号: 1000-436X(2004)03-0119-07

A rapid binary block arithmetic coder combined with renormalization operations

YANG Sheng-tian

(Department of Information Science and Electronic Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: By using the methods of table lookups, probability quantization and modified renormalization operations, a simple multiplication-free binary block arithmetic coding scheme is given. Experimental results show that its average codeword length is closer to the theoretic lower bound of source coding than many popular rapid coders.

Key words: block arithmetic coding; source coding; data compression

1 引言

信源无失真编码的基本问题就是在给定信源的前提下如何设计具有最佳编码效率的最优编码方案问题。根据信息论的源编码理论, 对于离散无记忆信源 X , 其信源熵 $H(X)$ 是信源无失真编码平均码长的理论下限。

目前, 使用最广泛的编码方案是霍夫曼编码^[1]和算术编码^[2]。霍夫曼编码属于一类最优前缀码, 其平均码长小于信源熵加 1, 但在大多数情况下, 其平均码长并不能很好的逼近信源熵这一下限, 要进一步提高编码效率就必须采用扩展字符集的技术, 此外, 其算法实现也较复杂, 尤其是在自适应方式下。与霍夫曼编码相比, 算术编码是从全序列出发进行编码的, 所以理论上可以无限逼近信源熵这一下限, 但它的缺点是算法复杂, 且信道误差的扩散问题十分严重。

为了克服一般算术编码方案的各种不足, 于是出现了一类称为分组算术编码的编码方案。它的基本思路就是在一般有限精度算术编码的基础上, 放弃了原有的重正化 (renormalization)

收稿日期: 2002-05-27; 修订日期: 2003-12-09

操作, 所以当整数区间的精度无法表示字符集时, 就输出对应的整数, 然后再将整数区间恢复到初始状态, 有关该类编码算法的介绍参见文献[3]。虽然分组算术编码因此丧失了一定的编码效率, 但也因而获得了其他的一些优点。与霍夫曼编码、一般算术编码相比, 该编码方案是变长码输入、定长码输出, 因而在传输中, 即使发生信道错误, 也只会局限于出错的某一分组码中。在算法实现上, 该编码方案总体要比前两种编码简单, 但是现有的分组算术编码算法也存在一些不足, 主要是每编码一个字符, 算法就需要通过数次的乘法与除法运算来进行区间的再分割, 这些算术运算都是十分耗时的。为了进一步提高编码速度, 本文给出了一个高效、无乘法的二值分组算术编码器。

2 设计思路

要消除算术编码中的乘除运算, 就需要从符号的概率估计直接得到对应的子区间长度。一种方法是采用近似算法, 这种方法被 IBM 的 Q 编码器^[4]所采用; 另一种方法则是将对应概率的区间长度全部计算出来, 列成表格以备查找。本文的编码器正是采用了后一种方法, 由于表格必定是有限的, 所以首先必须对概率进行量化, 同时考虑到算法设计的简单性, 本文设计的是一个二值编码器。然而, 概率量化和查表方法又带来了另一个问题, 即算法的空间复杂性。假设分组算术编码的分组长度为 n (比特), 概率的量化级数为 k , 由于区间再分割后的子区间长度依赖于当前区间的长度和估计概率的量化值, 需要存储的表空间的数量级为 $O(2^n k)$, 所以随着 n 的增长, 空间复杂性呈指数增长, 这就给实际应用带来了极大的矛盾。一方面为了提高编码效率, 需要提高 n 值, 而另一方面为了降低内存开销, 又不得不降低 n 值。为了解决这一问题, 本文又重新采用了普通算术编码算法中的重正化操作, 但作了一定的修改, 使其适合于分组算术编码的特点。以下, 将就编码器的设计思路作一个介绍 (关于分组算术编码的基本原理, 本文不再赘述)。

2.1 概率量化方案与查找表的生成

由熵的性质知, 若 $P = \{p_1, p_2, \dots, p_n\}$ 为一个概率分布, 即 $0 \leq p_i \leq 1, \sum p_i = 1$; 同时 $Q = \{q_1, q_2, \dots, q_n\}$, 且满足 $0 \leq q_i \leq 1, \sum q_i \leq 1$ 。那么

$$\sum_{i=1}^n p_i \log \frac{1}{p_i} \leq \sum_{i=1}^n p_i \log \frac{1}{q_i} \quad (1)$$

当且仅当 $q_i = p_i$ ($1 \leq i \leq n$) 时取等号。

若将 q_i 看成是概率 p_i 的量化值, 则不等式的左边是信源熵, 右边是采用量化概率进行算术编码的平均码长, 所以量化的代价就是即使采用算术编码, 其平均码长也要大于信源熵, 因此, 需要仔细设计量化方案使算术编码的平均码长最优地接近于信源熵, 本文采用了如下最优准则

$$e_{\min} = \min_Q \max_{0.5 \leq p \leq 1} \{-p \log[Q(p)] - (1-p) \log[1-Q(p)] - H(p)\} \quad (2)$$

其中, $H(p) = -p \log p - (1-p) \log(1-p)$ 。

这里, 假设信源为二值离散无记忆信源, 同时由于对称性, 只需考虑概率 $0.5 \leq p \leq 1$ 的情形。 $Q(p)$ 表示概率量化函数, 由于概率取值是一维的, 所以该函数就是一般的标量量化函数, 其参数是量化级数 k 。由上述最优准则可以推知: 如果采用最优的量化函数 Q , 那么编

码器平均码长的下限将不大于 $H(p)+e_{\min}$ 。实际中, 取量化级数 $k=16$, 通过最优化算法可以得到如表 1 的量化方案, 可以计算出在区间 $[0.5, 0.985]$ 内, 该量化方案使 $e_{\min} \approx 0.0015$ 。

表 1 概率量化函数

概率区间	量化值	概率区间	量化值
[0.5000, 0.5228)	0.5000	[0.8164, 0.8504)	0.8336
[0.5228, 0.5683)	0.5456	[0.8504, 0.8815)	0.8662
[0.5683, 0.6132)	0.5908	[0.8815, 0.9094)	0.8957
[0.6132, 0.6572)	0.6353	[0.9094, 0.9339)	0.9219
[0.6572, 0.6998)	0.6786	[0.9339, 0.9548)	0.9446
[0.6998, 0.7408)	0.7205	[0.9548, 0.9718)	0.9636
[0.7408, 0.7798)	0.7605	[0.9718, 0.9887)	0.9788
[0.7798, 0.8164)	0.7983	[0.9887, 1.0000]	0.9950

确定了量化方案, 接下来就是生成区间长度估计用的查找表。设当前区间的基偏移量为 $B[n]$ 、长度为 $L[n]$ (其中 n 表示第 n 次区间分割, 当前编码的实际区间就为 $[B[n], B[n]+L[n]]$), 待编码的二值符号 0 或 1 的估计概率为 $p[n]$, 那么子区间的长度可以近似为

$$L[n+1] = \min\{\lfloor [L[n]+1] \times p[n] - 0.5 \rfloor, L[n]-1\} \quad (3)$$

其中函数 $\lfloor x \rfloor$ 取不大于 x 的最大整数。设 $L[n]$ 取值范围在 1 至 2^M-1 之间, 量化函数的量化级数为 k , 则若要将上述计算公式根据量化概率全部转换为查找表, 那么相应的生成算法为:

(1) 初始化

设查找表为一个二维数组 $LookupTable$, 分配一个 $2^M \times k$ 的内存单元, 初始值设为 0, 数组的引用形式为 $LookupTable(row, col)$, 其中 $0 \leq row \leq 2^M-1$, $0 \leq col \leq k-1$ 。

(2) 计算表值

对于所有 $1 \leq row \leq 2^M-1$, $0 \leq col \leq k-1$ 的数组元素, 作如下计算

$$LookupTable(row, col) = \min\{\lfloor [row+1] \times Q_{col} - 0.5 \rfloor, row-1\} \quad (4)$$

其中, Q_{col} 表示量化函数的第 col 个量化概率值。显然, 该表的空间复杂性为 $O(2^M k)$, 所以若 M 过大, 查找表的内存开销是无法承担的。

2.2 利用重正化操作降低算法的空间复杂性

由以上的分析可知, 一方面, 增加字长会增大查找表的内存开销, 另一方面, 要提高分组算术编码的编码效率, 又必须增加字长, 所以必须给出一个两全其美的解决方案。

设分组算术编码的分组长度为 N , 则区间长度的取值为 0 至 2^N-1 , 直接以此范围来生成查找表显然是行不通的, 但可以对区间长度采用低分辨率的描述方式, 即在计算区间长度时, 可以始终保持区间长度的有效数字为 M 比特, 那么实际有效的区间长度取值只有 2^M 种, 表的空间复杂性为 $O(2^M k)$, 它不会随着 N 的增大而呈指数上升。此外, 可以设一个参数 R ($1 \leq R \leq M$), 表示当区间长度的有效数字比特数降至 $M-R$ 比特以下时, 可以通过扩展有效比特

数的方法将有效数字比特数重新恢复到 M 比特, 以保证编码器的概率分辨率, 这就是重正化操作。上述思路的一种实现方式即为结合重正化操作的分组算术编码。

3 具体算法步骤

本节将完整地介绍结合重正化操作的快速二值分组算术编码算法, 图 1 给出了编码器的整体结构。

在介绍算法之前, 先就有关符号的表示作一个定义。

(1) 编码器基本参数: 分组长度 N (比特); 区间长度的字长 M (比特); 重正化参数 R (比特)。

(2) 概率量化与区间估计基本参数: 量化级数 k ; 量化函数 $Q: p \rightarrow Q_j, 0 \leq j \leq k-1$; 查找表 $LookupTable(row, col)$ 。

(3) 编码器工作变量: 编码区间基偏移量 B ; 编码区间长度 L 。

(4) 概率估计相关的符号集: 二值离散信源的符号集 $A=\{0, 1\}$, a 表示符号集 A 的一个字符; 符号集 A 的概率分布 $P(A)=\{p(0), p(1)\}$; 符号集 A 经映射后的符号集 $S=\{MPS, LPS\}$, MPS 为较大可能字符 (more probable symbol), LPS 为较小可能字符 (less probable symbol), b 表示符号集 S 的一个字符; 可逆映射 $G: a \rightarrow b, a \in A, b \in S$ 。其定义如下

$$b = G(a) = \begin{cases} MPS & \text{if } p(a) = \max\{P(A)\} \\ LPS & \text{if } p(a) = \min\{P(A)\} \end{cases}, \quad \forall a \in A, \text{ and } p(0) \neq p(1) \quad (5)$$

式(5)未包括 $p(0)=p(1)=0.5$ 的情况, 对此种情况, 可以采取人为约定的方法, 即取 $0 \rightarrow MPS, 1 \rightarrow LPS$ 或 $0 \rightarrow LPS, 1 \rightarrow MPS$ 。

(5) 衍生的一些参数: 重正化阈值 $T=2^{M-R}-1$; 重正化计数器 C 。

(6) 临时变量: $T1, T2, T3$ 。

以下为编码/解码的具体算法步骤 (其中诸如 $X \leftarrow Y$ 的形式表示将式 Y 的值赋给变量 X):

1) 编码算法

A 初始化: 令 $B=0, L=2^M-1, C=N-M$ 。

B 编码:

输入: 待编码字符 $a \in A$, 已知概率分布 $P(A)$ 。

步骤

① $b=G(a)$;

② 通过量化函数 Q 得到概率 $p(MPS)$ 的对应量化级 j , 即

$$Q(p(MPS))=Q_j, 0 \leq j \leq k-1;$$

③ 令 $T1=LookupTable(L, j)$;

④ 如果 $b=MPS$, 那么令 $L=T1$; 否则, 令 $B \leftarrow B+T1+1, L \leftarrow L-T1-1$;




图1 快速二值分组算术编码器整体结构

⑤ 如果 $L=0$ 并且 $C=0$, 那么

首先, 以二进制形式输出 N 位的 B ;

然后, 令 $B=0$, $L=2^M-1$, $C=N-M$;

否则, 如果 $L \leq T$ 并且 $C > 0$, 那么重复以下操作, 直至 $L > T$ 或 $C=0$,

首先, 令 $T2=\min(R, C)$;

然后, 令 $B \leftarrow B \times 2^{T2}$, $L \leftarrow (L+1) \times 2^{T2}-1$, $C \leftarrow C-T2$;

⑥ 若概率模型为自适应方式, 则更新概率模型;

⑦ 若编码结束, 则跳转至(3), 否则跳至①, 编码下一个字符。

(3) 结束: $B \leftarrow B \times 2^C$, 输出 N 比特的 B 。

2) 解码算法

A 初始化: 令 $B=0$, $L=0$, $C=0$ 。

B 解码:

输入: 已知概率分布 $P(A)$ 。

步骤:

① 如果 $L=0$ 并且 $C=0$, 那么

首先, 输入 M 比特数据到 B ;

然后, 令 $L=2^M-1$, $C=N-M$;

否则, 如果 $L \leq T$ 并且 $C > 0$, 那么重复以下操作, 直至 $L > T$ 或 $C=0$,

首先, 令 $T2=\min(R, C)$;

然后, 输入 $T2$ 比特数据到 $T3$, 令 $B \leftarrow B \times 2^{T2}+T3$, $L \leftarrow (L+1) \times 2^{T2}-1$, $C \leftarrow C-T2$;

② 通过量化函数 Q 得到概率 $p(MPS)$ 的对应量化级 j , 即

$$Q(p(MPS))=Q_j, \quad 0 \leq j \leq k-1;$$

③ 令 $T1=LookupTable(L, j)$;

④ 如果 $B \leq T1$, 那么令 $b=MPS$, $L=T1$; 否则, 令 $b=LPS$, $B \leftarrow B-T1-1$, $L \leftarrow L-T1-1$;

⑤ 若概率模型为自适应方式, 则更新概率模型;

⑥ 输出解码字符 $a=G^{-1}(b)$;

⑦ 若解码结束, 则跳转至(3), 否则跳至①, 解码下一个字符。

3) 结束: 无操作。

在上述快速二值分组算术编码的基本算法中, 虽然存在诸如 $\times 2^{T2}$ 的形式上的乘法, 但实际上可以用二进制移位操作来完成, 所以本质上整个算法没有任何乘法运算。该算法已十分简单, 如果将其额外的加减法也预先算好, 则速度更快。

编码器设计中, 另一个重要的问题是概率估计器的设计。概率估计算法也是编码算法中一个重要组成部分, 由于本算法中只需要对应符号的估计概率量化级, 如果采用传统的频率计数方法, 则还需要进行量化操作, 反而导致整个编码算法的计算量增加, 因此, 在实际应用中可以采用与本算法类似的思路进行查表操作, 直接得到估计概率的量化级, 则编码和解码中的 B-② 将大大地化简, 整个编码器的速度会得到较大幅度的提升。

概率估计查找表的设计也存在空间复杂性的问题。设一个二值 0、1 信源的概率估计器有两个变量, 一个是符号 0 的计数变量 C_0 , 一个是总计数变量 C_{total} , 那么符号 0 的概率就可近似估计为 C_0/C_{total} 。通常, C_0 和 C_{total} 的初始值设为 1 和 2, 并且在更新概率估计时, 为了使

其具有自适应的特性, 会规定一个最大计数值 $C_{\max}$, 当 C_{total} 大于 $C_{\max}$ 时, 就会对 C_0 和 C_{total} 进行折半操作, 因此 C_0 和 C_{total} 的取值范围分别为: $1 \leq C_0 \leq C_{\text{total}} - 1$, $2 \leq C_{\text{total}} \leq C_{\max}$, 如果采用数组形式来存储其对应概率估计的量化级, 则大约需要 $C_{\max} \times C_{\max}$ 个存储单元。通过一定的技巧可以大幅降低存储单元的开销。首先, 将字符 0 的概率估计改为对 MPS 字符的估计, 相应的计数变量为 C_{MPS} , 因此其取值范围为 $C_{\text{total}}/2 \leq C_{\text{MPS}} \leq C_{\text{total}} - 1$ 。其次, 规定 C_{MPS} 和 C_{total} 的初始值为 $C_{\max}/4$ 和 $C_{\max}/2$, 则 C_{total} 的取值范围为 $C_{\max}/2 \leq C_{\text{total}} \leq C_{\max}$, 于是最终只需 $C_{\max} \times C_{\max}/4$ 个存储单元, 只是原有内存开销的四分之一。

4 编码效率测试

图 2 给出了本编码器 (包括概率估计算法) 在二值离散无记忆信源下的编码效率测试结果 (图中, 概率在 0.5~1 间变化, 得到编码器在不同概率下平均每字符的码字长度, 用此平均码长减去对应的熵值, 即为编码后的冗余度, 测试的编码器参数为 $N=32, M=8, R=1, k=16$)。图 3^[5]给出了 QM 编码器 (Q 编码器的软件实现版本) 和 FSM 编码器的效率测试结果。通过比较可以看出, 在大多数情况下, 本编码器的冗余度为最低 (<0.01 bit/sym), FSM 编码器次之, QM 编码器最差, 因此本编码器的总体性能最好, 最接近源编码理论的理论下限。




图 2 快速二值分组算术编码的编码效率





图 3 QM 编码器和 FSM 编码器的编码效率

总之，本文给出的快速二值分组算术编码器具有以下优点：软硬件实现都十分容易，编码和解码速度快；编码效率高；如果信道发生错误，错误只局限于出错的某一分组码内。

参考文献：

- [1] HUFFMAN D A. A method for the construction of minimum-redundancy codes[J]. Proceedings of the Institute of Radio Engineers, 1953, 40(9): 1098-1101.
- [2] WITTEN I H, NEAL R M, CLEARY J G. Arithmetic coding for data compression[J]. Communications of the ACM, 1987, 30(6): 520-540.
- [3] BONCELET C G. Block arithmetic coding for source compression[J]. IEEE Trans Inform Theory, 1993, 39(5): 1546-1554.
- [4] PENNEBAKER W B, MITCHELL J L, LANGDON G G, *et al.* An overview of the basic principles of the Q-coder adaptive binary arithmetic coder[J]. IBM J Res Develop, 1988, 32(6): 717-726.
- [5] GORMISH M J. Source Coding with Channel, Distortion, and Complexity Constraints[D]. Stanford: Stanford University, 1994.

作者简介：



杨胜天（1976-），男，浙江杭州人，浙江大学博士生，主要研究方向为信息论与编码。

万方数据
WANFANG DATA