

一组整数的几个实用编码方案

杨胜天, 仇佩亮

(浙江大学 信息与电子工程学系, 浙江 杭州 310027)

摘 要: 以 Golomb 码和扩展 Gamma 码为基础提出了 4 种针对一组整数的编码方案。这些方案增强了对低熵值整数序列的压缩性能, 同时仍保持了整数码低复杂性的特点。通过应用这些编码方案, 设计了一个基于 Burrows-Wheeler 变换的压缩算法。该算法的实验结果表明其压缩比率要优于采用整数码的 BWT 类压缩算法。

关键词: 信息论; 通用数据压缩; 整数编码; Golomb 码; 扩展 Gamma 码; Burrows-Wheeler 变换

中图分类号: TN911.21

文献标识码: A

文章编号: 1000-436X(2005)07-0001-07

Several practical coding schemes for a block of integers

YANG Sheng-tian, QIU Pei-liang

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

Abstract: Four coding schemes for a block of integers were proposed based on Golomb codes and extended Gamma codes. These schemes enhanced the compression performance on integer sequences with low entropy and still enjoy the simplicity of integer codes. By applying these coding schemes, a compression algorithm based on Burrows-Wheeler transform was designed. Experimental results of this algorithm indicate lossless coding rates better than those achieved by BWT-based compression algorithms using integer codes.

Key words: information theory; universal data compression; integer coding; Golomb codes; extended Gamma codes; Burrows-Wheeler transform

1 引言

许多数据压缩算法都会涉及一个变换, 该变换会将原始数据转换为一个整数序列, 其中每个整数的取值会遵循一个共同的近似递减的概率分布, 要获得好的压缩性能, 就需要对这些整数进行有效的编码。整数码就是专门针对整数进行编码的一类码, 几十年来, 文献[1~11]已提出了一系列的整数码。不同于一般的霍夫曼编码和算术编码, 整数编码考虑的是一个字符集大小为可数无穷而概率分布为非递增的信源编码问题, 这一问题在理论上和实际中都具有十分重要的意义。

理论上, Elias 在其关于整数编码的文章^[2]中给出了通用整数码和渐近最优整数码的定义, 并且构

造了一系列通用整数码和渐近最优整数码, 这些码至今已成为通用数据压缩理论分析中常用的编码手段。通用数据压缩研究的主要课题就是如何构造一个固定的编码方案来压缩一个未知信源(例如只假设信源是平稳、遍历的)产生的序列, 希望当序列的长度趋于无穷时, 编码速率能够渐近趋于信源的熵率。由于渐近最优整数码是当信源熵趋于无穷时, 其平均码字长度与信源熵的比值会渐近趋于 1, 所以这类码常常与字符扩展技术相结合, 被应用于通用数据压缩的理论证明(本文第 4 节介绍的基于 Burrows-Wheeler 变换和 Move-to-Front 变换的压缩算法的有关理论性能分析就是一个例子)。

实际中, 当信源字符集非常大或者字符集大小无法设置上界时, 对于使用霍夫曼编码或算术编码

的压缩系统,其复杂性很可能是无法承受的,但如果使用整数编码,整个系统的算法复杂性会非常低。当然,相应的代价是其编码效率与熵最优编码器相比会有一定的损失,尤其是在一些应用中,由于整数序列的熵并不是很高,许多渐近最优整数码的实际性能反而很差,这一问题已在文献[11]中得到一定的解决,主要贡献是提出了一类带有参数的扩展 γ 码,这些扩展 γ 码都是通用码,而且通过观察信源统计量 $E_P[\lfloor \log i \rfloor]$ 选择合适的参数,可以达到目前各类整数码中最好的渐近性能。然而有些时候,数据压缩算法生成的整数序列可能具有接近于零的熵,而整数码都是前缀码,即每个整数至少需要一个比特的字长,因此对于接近零熵值的整数序列无法进行有效的编码。要克服整数码的缺点,就必须考虑一组整数而不是单个整数的编码问题。

本文在第 2 节给出了一个针对二进制序列的编码方案;在第 3 节中以 Golomb 码和扩展 γ 码为基础,结合前一节的成果,给出了 4 种针对一组整数的编码方案;在第 4 节中设计了一个以 Burrows-Wheeler 变换为基础,并采用整数组编码作为最后的编码环节的通用数据压缩算法,数据压缩的测试结果表明本文算法的性能要明显优于采用整数码的同类压缩算法。

以下是全文中使用的符号与定义。

在本文中, $\log x = \log_2 x$, $\lfloor x \rfloor$ 表示不超过 x 的最大整数, $\lceil x \rceil$ 表示不被 x 超过的最小整数, $x \bmod y$ 表示整数 x 除以整数 y 的余数, N 表示非负整数集合, N^* 表示正整数集合。

任意给定一个字符集 A , 则 A^* 表示由集合 A 中的符号组成的所有有限长度序列的集合, 集合 A^* 中任意两个序列 α 和 β 的级联记为 $\alpha\beta$, 序列 α 的长度记为 $|\alpha|$, 空串记为 ε , 所有长度为 n 的序列集合记为 A^n , 长度为 n 的序列 α 也常记为 α^n , 而 α_i^j 表示从序列 α 的第 i 个字符到第 j 个字符形成的一个子序列 ($1 \leq i \leq j \leq n$)。一个常用的字符集就是二进制字符集 $B = \{0, 1\}$ 。对于字符 $a \in B$ 和序列 $\alpha \in B^*$, $\bar{a}$ 和 $\bar{\alpha}$ 分别表示对二进制字符 a 和序列 α 作求反运算。

此外, 还需要定义一些表示二进制序列的记号。令 $(j)_2$ 为一个正整数 j 的标准二进制表示 (最左边的比特位必为 1)。例如, $(11)_2 = 1011$ 。又令 $[j]_2$ 表示正整数 j 的去除最高位的标准二进制表示。例如, $[11]_2 = 011$ 。 $(j)_2$ 和 $[j]_2$ 的长度分别记为

$$\begin{cases} \lambda(j) \equiv |(j)_2| = \lfloor \log j \rfloor + 1 \\ \lambda(j) \equiv |[j]_2| = \lfloor \log j \rfloor \end{cases} \quad (1)$$

令一个正整数 j 的一元码为 $(j)_1$, 其编码规则为输出 $j-1$ 个字符 1, 然后输出结尾字符 0。例如, $(1)_1 = 0$, $(2)_1 = 10$, $(3)_1 = 110$, ...。显然 $|(j)_1| = j$ 。最后, 定义一个表示 0 到 $l-1$ 这 l 个整数的分组码 $BC_l(j)$, 其定义为

$$BC_l(j) = \begin{cases} BC_{2^{k-l}}(j) & j < 2^k - l \\ BC_{2^k}(j + 2^k - l) & j \geq 2^k - l \end{cases} \quad (2)$$

其中 $k = \lceil \log l \rceil$, $BC_{2^k}(j)$ 表示整数 j 的 k 比特二进制表示。分组码的码字长度为

$$|BC_l(j)| = k - u(2^k - l - 1 - j) \quad (3)$$

其中 $u(x)$ 为阶跃函数 (当 $x \geq 0$, $u(x) = 1$, 否则 $u(x) = 0$)。

2 二进制序列的编码

文献[12]对一组整数的编码作了理论上的探讨, 虽然没有给出实际可行的算法, 但其中从整数序列中分离出二进制序列进行编码的思想对笔者颇有启发, 因此本节将首先考虑一个二进制序列的编码问题。

设一个长度为 n 的二进制序列 $\alpha^n = \alpha_1 \alpha_2 \dots \alpha_n$, 首先考虑将其转换为一个正整数序列。定义变换 $BTN_n: B^n \rightarrow (B, N^*)$ 为 $\alpha^n \mapsto (b, \beta)$, 具体算法如下。

首先统计二进制序列 α^n 中 0 和 1 的个数, 设 0 的个数为 n_0 , 1 的个数为 n_1 , 显然 $n_0 + n_1 = n$ 。于是

$$b = u(n_1 - n_0) \quad (4)$$

然后对二进制序列作一个一元码的解码处理。在解码前, 如果 $b = 0$, 那么首先对二进制序列作一个求反运算, 然后为保证二进制序列为有效的一元码级联, 检查二进制序列最后一个字符是否为 0, 如果不为 0, 就在末尾添加一个字符 0。于是

$$\beta = U^{-1}(\alpha') \quad (5)$$

其中, U 为一元码的编码函数, 即定义为 $U(\beta) = (\beta_1)_1 (\beta_2)_1 \dots (\beta_{|\beta|})_1$, 而 U^{-1} 为逆函数, 即一元码的解码函数。此外

$$\alpha' = \begin{cases} \bar{\alpha}^n & b = 0, \alpha_n = 1 \\ \bar{\alpha}^n 0 & b = 0, \alpha_n = 0 \\ \alpha^n & b = 1, \alpha_n = 0 \\ \alpha^n 0 & b = 1, \alpha_n = 1 \end{cases} \quad (6)$$

可以注意到正整数序列的长度 $|\beta|$ 与总和 s_β 分别为

$$|\beta| = n_b + \overline{b \oplus \alpha_n} \quad (7)$$

$$s_\beta = n_b + |\beta| = n + \overline{b \oplus \alpha_n} \quad (8)$$

其中, $\oplus$ 表示异或运算。相应地, 逆变换 $\text{BTN}_n^{-1}: (B, N^{**}) \rightarrow B^*$ 可以定义为

$$\text{BTN}_n^{-1}(b, \beta) = \begin{cases} (\overline{U(\beta)})_1^n & b=0 \\ (U(\beta))_1^n & b=1 \end{cases} \quad (9)$$

显然在直观上, 当二进制序列具有很多的 0 或 1 时, 通过 BTN_n 变换就可以将一个很长的二进制序列转换为长度相对要短很多的正整数序列, 接下来就是如何对这个正整数序列进行有效编码的问题。如果假设二进制序列满足独立同分布的条件, 那么其变换后的正整数序列遵循单边几何分布 (OSGD, one-sided geometric distribution) 的规律, 由文献[1,13]知带参数的 Golomb 码是单边几何分布下最优的编码方案, 所以考虑采用 Golomb 码。一个参数为 $l \in N^+$ 、基于正整数 ($i \in N^+$) 的 Golomb 码可表示为

$$g_l(i) = \left(\left\lfloor \frac{i-1}{l} \right\rfloor + 1 \right) \text{BC}_l((i-1) \bmod l) \quad (10)$$

当然, 文献[13]中的最优参数准则过于复杂, 故考虑采用文献[11]中的最优准则。由文献[11]中的定理 1 知, 当参数 l 为

$$l_i = 2^{\lfloor \log \max\{\mu_p - 1, 1\} \rfloor} \quad (11)$$

时, Golomb 码平均码长的上界为最小, 其中 μ_p 为正整数序列的均值。由于 l 的最优值都是 2 的次幂, 所以实际使用的 Golomb 码只是其中一个子类的码, 称为 Rice 码^[14]。记参数为 $k \in N$ 的 Rice 码为

$$r_k(i) = \left(\left\lfloor \frac{i-1}{2^k} \right\rfloor + 1 \right) \text{BC}_{2^k}((i-1) \bmod 2^k) \quad (12)$$

式中 $i \in N^+$, 而其最优参数为

$$k_1 = \lfloor \log \max\{\mu_p - 1, 1\} \rfloor \quad (13)$$

最优准则看似复杂, 其实可以用非常简单的移位运算来完成。定义函数 $\text{FloorLog}: (N, N^+) \rightarrow N$ 为

$$\text{FloorLog}(s, n) = \left\lfloor \log \max\left\{\frac{s}{n}, 1\right\} \right\rfloor \quad (14)$$

其 C++ 代码为

```
int FloorLog(int s, int n)
```

```
{
    for (int k = 0; (n << (k + 1)) <= s; k++);
    return k;
}
```

接下来继续考虑正整数序列的编码问题。由式(7)和(8)知, 其最优参数为

$$\begin{aligned} k_\beta &= \text{FloorLog}(s_\beta - |\beta|, |\beta|) \\ &= \text{FloorLog}(n_b, n_b + \overline{b \oplus \alpha_n}) \end{aligned} \quad (15)$$

注意, 若 $k_\beta = 0$, 则相当于将正整数序列 β 再进行一次一元码的编码, 又将序列变换为原始的序列, 所以当 $k_\beta = 0$ 时, 可以直接输出原二进制序列。因此最终的输出编码为:

若 $k_\beta > 0$, 则

$$\text{BTB}_n(\alpha^n) = (k_\beta + 1)_1 \text{NTB}_{k_\beta}(\text{BTN}_n(\alpha^n)) \quad (16a)$$

否则 $k_\beta = 0$, 则

$$\text{BTB}_n(\alpha^n) = (k_\beta + 1)_1 \alpha^n = 0 \alpha^n \quad (16b)$$

其中, 函数 $\text{NTB}_k: (B, N^{**}) \rightarrow B^*$ 定义为

$$\text{NTB}_k(b, \beta) = b r_k(\beta_1) r_k(\beta_2) \cdots r_k(\beta_{|\beta|}) \quad (17)$$

3 一组整数的编码

在二进制序列编码算法的基础上, 就可以开始考虑一组整数的编码问题。文献[11]给出了任意分布下的 Golomb 码和扩展 γ 码的最优参数准则, 本节将在这两类整数码的基础上给出一组整数的 4 种实用编码算法。设一个 n 长的正整数序列为 $x^n = x_1 x_2 \cdots x_n$, 则一组整数的编码就是一个从 N^{*n} 到 B^* 的映射, 于是本节的 4 种编码分别记为函数 BR_n 、 BRE_n 、 BG_n 和 BGE_n 。

3.1 BR_n 码

BR_n 码本质上是由 Rice 码演化而来的。首先, 考虑一个 n 长的正整数序列的 Rice 编码。与第 2 节类似, 其编码为

$$(k+1)_1 r_k(x_1) r_k(x_2) \cdots r_k(x_n) \quad (18)$$

其中参数 k 由式(13)给出。根据 Rice 码的定义, 每个 Rice 码包括一个一元码和一个分组码, 可以考虑将这些码作一个置换, 将所有的一元码放在一起, 而后将所有的分组码也放在一起, 于是式(18)中的

码字就变换为

$$(k+1)_1(y_1)_1 \cdots (y_n)_1 BC_{2^k}(z_1) \cdots BC_{2^k}(z_n) \quad (19)$$

其中

$$y_i = \left\lfloor \frac{x_i - 1}{2^k} \right\rfloor + 1 \quad (20a)$$

$$z_i = (x_i - 1) \bmod 2^k \quad (20b)$$

由于只是码字的位置发生了变化,所以整个码字长度并没有改变。可以注意到当一个整数序列的熵非常低,或者由于概率分布的形状非常特别而导致参数 k 的估计过小或过大,一元码部分就会出现较为明显的冗余,即 y_i 频繁地为 1 或频繁地大于 1。要消除这种冗余,可以在作一元码编码前先将这类信息从整数序列 y_i 中分离出来单独编码。定义一个 n 长的二进制序列 δ^n 为

$$\delta^n = u(y_1-2) u(y_2-2) \cdots u(y_n-2) \quad (21)$$

同时,可以将整数序列 $y^n = y_1 y_2 \cdots y_n$ 中大于 1 的整数减去 1 组成一个新的整数序列 $\zeta^n = \zeta_1 \zeta_2 \cdots \zeta_n$ ($n' = \sum \delta_i$)。于是新的编码为

$$BR_n(x^n) = (k+1)_1 BTB_n(\delta^n)(\zeta_1)_1 \cdots (\zeta_{n'})_1 BC_{2^k}(z_1) BC_{2^k}(z_2) \cdots BC_{2^k}(z_n) \quad (22)$$

这就是 BR_n 码。

3.2 BRE_n 码

BRE_n 码是在 BR_n 码的基础上进一步提出来的编码方案。 BR_n 码主要针对一元码部分的冗余进行编码,然而对于一些特别的概率分布,其分组码部分也存在极大的冗余, BRE_n 码就是为消除分组码中的冗余而设计的。因为每一个分组码 $BC_{2^k}(z_i)$ 都是一个 k 比特的二进制序列,所以很容易想到将每个分组码中的某一位信息提取出来组成一个新的二进制序列,然后再进行编码,这样总共会有 k 个 n 长的二进制序列,记为 $\eta(j)^n$ ($0 \leq j \leq k-1$),其具体算法如下

$$\begin{aligned} \eta(j)^n &= \eta(j)_1 \eta(j)_2 \cdots \eta(j)_n \\ \eta(j)_i &= \left\lfloor \frac{BC_{2^k}(z_i)}{2^j} \right\rfloor \bmod 2 \end{aligned} \quad (23)$$

于是, BRE_n 码为

$$BRE_n(x^n) = (k+1)_1 BTB_n(\delta^n)(\zeta_1)_1 \cdots (\zeta_{n'})_1 BTB_n(\eta(0)^n) \cdots BTB_n(\eta(k-1)^n) \quad (24)$$

3.3 BG_n 码和 BGE_n 码

类似于 BR_n 码和 BRE_n 码,也可以由文献[11]中的扩展 γ 码相应构造出 BG_n 码和 BGE_n 码,然而正如扩展 γ 码是在 Golomb 码的基础上提出的,本节也将直接用 BR_n 码和 BRE_n 码来构造 BG_n 码和 BGE_n 码。与扩展 γ 码的构造类似,可以先给出整数序列中每个整数的去除最高位的标准二进制表示,而后将其长度信息组成的新的整数序列进行 BR_n 码或 BRE_n 码的编码,并置于其之前,即

$$BG_n(x^n) = BR_n(A(x_1) \cdots A(x_n))[x_1]_2 \cdots [x_n]_2 \quad (25)$$

$$BGE_n(x^n) = BRE_n(A(x_1) \cdots A(x_n))[x_1]_2 \cdots [x_n]_2 \quad (26)$$

4 一个基于 Burrows-Wheeler 变换的通用数据压缩算法

第3节中给出了一组整数的4种编码方案,当 n 较大时,这4种码的性能不会比相应的 Golomb 码或扩展 γ 码差,所以 BG_n 码和 BGE_n 码也是 Elias 意义下的通用码,在适当参数下也能达到渐近最优的性能。但是,要在任意分布下分析这些码的性能是十分困难的,故转而考察其实际的编码效率。本节将设计一个基于 Burrows-Wheeler 变换的通用数据压缩算法,最后的编码环节将采用第3节提出的4种编码方案。

近年来,在数据压缩方面一个十分有意义的发展就是 Burrows-Wheeler 变换^[15] (BWT)。BWT 是一种略微扩展的可逆序列变换,其主要原理就是通过将具有相同后缀的字符排在一起,形成一个近似的分段独立同分布 (PIID, piecewise independent and identically distributed) 序列,从而便于进一步的压缩处理。近几年来,该技术在实际的无损数据压缩技术和通用数据压缩理论中倍受关注(例如文献[16~18])。一些实验结果表明,使用这一变换的压缩算法虽然比部分匹配预测 (PPM, prediction by partial matching) 类压缩算法^[19, 20] 性能略差,但其压缩性能要高于 Ziv-Lempel 类压缩算法 (LZ77^[21], LZ78^[22]), 同时,其算法实现复杂性与 LZ 算法相当,要比 PPM 类算法运行快得多。(MTF, move-to-front) 变换也是一种可逆变换^[23~25], 它经常和 BWT 变换一起使用,其主要作用就是通过自适应的方式将不同概率的字符进行重新排列,使高概率字符趋向于排在低概率字符的前面,然后输出重新排列后的列

表索引。文献[23~25]中的理论分析表明 MTF 配合渐近最优的整数编码，同时结合字符扩展技术，可以达到渐近于信源熵率的性能，因此在理论上，本文提出的 BG_n 码和 BGE_n 码应用于 BWT/MTF 压缩算法的性能是有保证的。

虽然基于 BWT 的数据压缩算法具有较好的压缩性能，但是现有的大多数算法在编码环节都是使用算术编码，算术编码虽是最优编码，但复杂性高，耗时大，这对于 BWT 类压缩算法推向实际应用是一个制约，要进一步使 BWT 类压缩算法实用化，编码方案的设计也是至关重要的。Seward 采用 Huffman 编码开发了一个非常实用的基于 BWT 的压缩算法，即 BZIP2^[26]。Fenwick 则进一步探讨采用某类简单的前缀码（即整数码）来进行编码^[27, 28]。事实上，本文提出的 4 种针对一组整数的编码方案，就其复杂性而言与一般的整数码相当或略高一些，因而是 BWT 类算法的一个极好的候选编码方案。出于上述考虑，本文设计了一个基于整数组编码的 BWT 算法（如图 1）。它采用了最常用的 BWT 压缩算法结构，即首先对数据进行 BWT 变换，而后进行 MTF 变换和行程编码（RLE, run length encoding），最后对整数序列按固定的块大小进行分组编码。




图 1 基于整数组编码的 BWT 压缩方案

其中，RLE 采用的实际编码方案是 Wheeler 1/2 码^[29]，其主要作用是对 MTF 变换后产生的长串的整数 0 进行行程编码。Wheeler 1/2 码的基本算法就是对每一段连续的整数 0 序列进行计数，令计数值为 j ，则将编码 $[j+1]_2$ 的二进制序列按整数序列输出，相应地将其不为 0 的整数都加 1。因为数据经过

BWT 变换后，会出现成串的重复字符，而经过 MTF 变换后，这些字符就会被编码为一长串的整数 0（按本文的约定应该是整数 1，但因为实现中的列表是从零开始计数的，所以变为整数 0）。虽然，本文的一组整数的编码方案要比原有的整数码更好地适应于低熵值序列的压缩编码，但是因为整数序列最终是要进行分组编码的，而且由于整数序列只具有局部平稳性，分组长度不可能太长，所以编码的性能受到一定的限制。实践表明，使用 Wheeler 1/2 码会对压缩性能有较明显的改善。

本文提出了 4 种针对一组整数的编码方案，相应地由图 1 可以派生出 4 种压缩方案，按照编码的不同分别记为 BWT-BR、BWT-BRE、BWT-BG 和 BWT-BGE，其后半部分就是对应编码的记号。算法还包括一个整数分组长度的参数，实际中的分组长度取值为 128。将这 4 种算法对常用的 Calgary Corpus 和 Canterbury Corpus 数据测试集进行压缩，压缩结果如表 1 和表 2，其中还列出了 Fenwick 在文献[28]中的 Simple 算法和 Seward 的 BZIP2 软件^[26]的压缩结果。从表中可以看出，本文的 4 种算法的平均压缩性能都要好于 Fenwick 的 Simple 算法，Fenwick 的 Simple 算法选择性地使用了 Elias γ 码^[2]和 Fibonacci 码^[9]作为最后的编码方案，而其之前的算法与本文完全相同，这说明本文针对一组整数的编码的确比一般的整数码具有更好的性能，而且编码的复杂性并没有明显的提高。当然，本文算法与采用最优 Huffman 编码的 BZIP2 还是有一定的距离，压缩结果平均而言大约要高出 6%，这是使用简单编码技术必然带来的损失，但是低复杂性的编码技术将十分有利于实际系统特别是硬件系统的设计和实现，尤其是在大字符集下的压缩中，算术编码和 Huffman 编码算法的时间复杂性会大大增加，此时应用本文的编码算法将会在压缩性能和运行时间上获得较好的平衡。

表 1

Calgary Corpus 的压缩结果（单位：bit/byte）

文件名	长度	BWT-BR	BWT-BRE	BWT-BG	BWT-BGE	Fenwick2002	BZIP2
bib	111261	2.064	2.057	2.092	2.093	2.178	1.975
book1	768771	2.517	2.516	2.712	2.714	2.857	2.420
book2	610856	2.159	2.154	2.246	2.247	2.344	2.062
geo	102400	4.781	4.750	5.071	5.036	5.267	4.447
news	377109	2.650	2.640	2.664	2.665	2.779	2.516

续表

文件名	长度	BWT-BR	BWT-BRE	BWT-BG	BWT-BGE	Fenwick2002	BZIP2
obj1	21504	4.338	4.227	4.068	4.073	4.047	4.013
obj2	246814	2.860	2.753	2.565	2.568	2.587	2.478
paper1	53161	2.608	2.599	2.607	2.608	2.719	2.492
paper2	82199	2.533	2.530	2.620	2.621	2.739	2.437
pic	513216	0.840	0.839	0.847	0.847	0.832	0.776
progc	39611	2.700	2.680	2.612	2.613	2.716	2.533
progl	71646	1.840	1.828	1.815	1.815	1.846	1.740
progp	49379	1.858	1.845	1.779	1.780	1.835	1.735
trans	93695	1.660	1.629	1.554	1.555	1.581	1.528
平均		2.529	2.503	2.518	2.517	2.595	2.368

表 2 Canterbury Corpus 的压缩结果 (单位: bit/byte)

文件名	长度	BWT-BR	BWT-BRE	BWT-BG	BWT-BGE	Fenwick2002	BZIP2
fields.c	11150	2.373	2.327	2.172	2.172	2.244	2.180
kennedy.xls	1029744	1.604	1.227	1.850	1.678	1.996	1.012
ptt5	513216	0.840	0.840	0.847	0.847	0.832	0.776
cp.html	24603	2.611	2.582	2.578	2.579	2.619	2.479
grammar.lsp	3721	2.864	2.795	2.644	2.647	2.723	2.758
xargs.l	4227	3.376	3.348	3.253	3.255	3.326	3.335
asyoulik.txt	125179	2.627	2.626	2.793	2.795	2.947	2.529
plrabn12.txt	481861	2.515	2.514	2.723	2.725	2.881	2.417
sum	38240	3.043	2.921	2.741	2.740	2.771	2.701
lcet10.txt	426754	2.102	2.099	2.208	2.210	2.303	2.019
alice29.txt	152089	2.357	2.354	2.479	2.481	2.589	2.272
平均		2.392	2.330	2.390	2.375	2.476	2.225

仔细比较本文 4 个编码方案的压缩结果还会发现,对于有的文件,BR 和 BRE 算法的结果好一点,而对于其他的一些文件,BG 和 BGE 算法的结果好一点,如果要采用硬件实现本文算法,则可以将这两类算法并行运行,对于每一组整数选择输出长度较短的编码,其性能将更接近于 BZIP2 的性能。还有一点值得注意的是,BRE 算法要比 BR 算法有较明显的改善,而 BGE 算法并没有比 BG 算法好多少,主要的原因是 BRE 和 BGE 算法都是在 BR 和 BG 算法的基础上考虑对病态概率分布的进一步压缩,而 BGE 算法本质上是正整数去除最高位的标准二进制表示加上对长度的 BRE 编码,由于本文算法将计算机文件按字节进行处理,即正整数的取值为 1~256,所以其长度的取值仅为 1~8,这正是 BGE 算法没有明显提高压缩性能的原因,只有在更大的

字符集下 BGE 算法才会有较好的表现。

5 结论

本文以 Golomb 码和扩展 γ 码为基础提出的一组整数的 4 种编码方案是一类非常实用的编码算法。通过应用这些编码算法,本文构建了一个基于 BWT 的压缩算法,获得了较好的压缩效果和较低的编码复杂性。当然,在一组整数的编码中,还有许多问题有待于解决,如本文提出的 4 种编码算法的理论性能如何,以及如何将其应用于各类数据的压缩,这都将成为今后进一步研究的课题。

参考文献:

- [1] GOLOMB S W. Run-length encodings[J]. IEEE Trans Inform Theory, 1966, 12(3): 399-401.

- [2] ELIAS P. Universal codeword sets and representations of the integers [J]. IEEE Trans Inform Theory, 1975, 21(2): 194-203.
- [3] EVEN S, RODEH M. Economical encoding of commas between strings [J]. Commun ACM, 1978, 21(4): 315-317.
- [4] STOUT Q F. Improved prefix encoding of the natural numbers[J]. IEEE Trans Inform Theory, 1980, 26(5): 607-609.
- [5] APOSTOLICO A, FRAENKEL A S. Robust transmission of unbounded strings using Fibonacci representations[J]. IEEE Trans Inform Theory, 1987, 33(2): 238-245.
- [6] WANG M. Almost asymptotically optimal flag encoding of the integers[J]. IEEE Trans Inform Theory, 1988, 34(2): 324-326.
- [7] YAMAMOTO H, OCHI H. A new asymptotically optimal code for the positive integers[J]. IEEE Trans Inform Theory, 1991, 37(5): 1420-1429.
- [8] AMEMIYA T, YAMAMOTO H. A new class of the universal representation for the positive integers[J]. IEICE Trans Fundamentals, 1993, 76(3): 447-452.
- [9] FRAENKEL A S, KLEIN S T. Robust universal complete codes for transmission and compression[J]. Discr Appl Math, 1996, 64(1): 31-55.
- [10] FENWICK P. Variable-length integer codes based on the Goldbach conjecture, and other additive codes[J]. IEEE Trans Inform Theory, 2002, 48(8): 2412-2417.
- [11] 杨胜天, 仇佩亮. 任意概率分布下 Golomb 码和扩展 Gamma 码的性能分析[J]. 电子与信息学报, 2005, 27(4): 514-518.
- [12] FOSTER D P, STINE R A, WYNER A J. Universal codes for finite sequences of integers drawn from a monotone distribution[J]. IEEE Trans Inform Theory, 2002, 48(6): 1713-1720.
- [13] GALLAGER R G, VOORHIS D C V. Optimal source codes for geometrically distributed integer alphabets[J]. IEEE Trans Inform Theory, 1975, 21(2): 228-230.
- [14] RICE R F. Some Practical Universal Noiseless Coding Techniques—Part III[R]. Technical Report JPL-91-3, Jet Propulsion Laboratory, Pasadena, CA, 1991.
- [15] BURROWS M, WHEELER D J. A Block-Sorting Lossless Data Compression Algorithm[R]. Technical Report SRC 124, Digital System Research Center, Palo Alto, CA, 1994.
- [16] BALKENHOL B, KURTZ S. Universal data compression based on the Burrows-Wheeler transformation: theory and practice[J]. IEEE Trans Comput, 2000, 49(10): 1043-1053.
- [17] DEOROWICZ S. Improvements to Burrows-Wheeler compression algorithm[J]. Software: Practice and Experience, 2000, 30(13): 1465-1483.
- [18] EFFROS M, VISWESWARIAH K, KULKARNI S R, *et al.* Universal lossless source coding with the Burrows Wheeler transform[J]. IEEE Trans Inform Theory, 2002, 48(5): 1061-1081.
- [19] CLEARY J G, WITTEN I H. Data compression using adaptive coding and partial string matching[J]. IEEE Trans Commun, 1984, 32(4): 396-402.
- [20] MOFFAT A. Implementing the PPM data compression scheme[J]. IEEE Trans Commun, 1990, 38(11): 1917-1921.
- [21] ZIV J, LEMPEL A. A universal algorithm for sequential data compression[J]. IEEE Trans Inform Theory, 1977, 23(3): 337-343.
- [22] ZIV J, LEMPEL A. Compression of individual sequences via variable-rate coding[J]. IEEE Trans Inform Theory, 1978, 24(5): 530-536.
- [23] BENTLEY J L, SLEATOR D D, TARJAN R E, *et al.* A locally adaptive data compression scheme[J]. Commun ACM, 1986, 29(4): 320-330.
- [24] ELIAS P. Interval and recency rank source coding: two on-line adaptive variable-length schemes[J]. IEEE Trans Inform Theory, 1987, 33(1): 3-10.
- [25] MURAMATSU J. On the performance of recency-rank and block-sorting universal lossless data compression algorithms[J]. IEEE Trans Inform Theory, 2002, 48(9): 2621-2625.
- [26] SEWARD J. BZIP2-1.0.1 [EB/OL]. <http://www.digistar.com/bzip2/>.
- [27] FENWICK P. Punctured Elias Codes for Variable-Length Coding of the Integers[R]. Technical Report 137, Department of Computer Science, The University of Auckland, December 1996.
- [28] FENWICK P. Burrows-Wheeler compression with variable length integer codes[J]. Software: Practice and Experience, 2002, 32(13): 1307-1316.
- [29] FENWICK P. Block Sorting Text Compression—Final Report[R]. Technical Report 130, Department of Computer Science, The University of Auckland, April 1996.

作者简介:



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



仇佩亮 (1944-), 男, 上海人, 浙江大学教授、博士生导师, 主要研究方向为数字通信与网络, 信息论与编码。