

关于整数编码和 Slepian-Wolf 编码的研究
(博士学位论文)

2005.6

杨胜天

浙江大学信息与电子工程学系

专业：通信与信息系统

导师：仇佩亮

2009 年 11 月 14 日修订版

摘要

论文研究了无损信源编码中两个重要的问题。

第一个问题是通用信源编码中的整数编码问题。论文分析了任意分布下 Golomb 码的性能，并在 Golomb 码的基础上构造了一类通用的扩展 γ 码。为了理解这些整数码，论文提出了最大熵码的概念，并证明了 Golomb 码和扩展 γ 码分别是两类信源下的最大熵码。此外，论文还考虑了一组整数的编码问题，提出了四个实用的一组整数的编码方案，并将其应用于基于 Burrows-Wheeler 变换的压缩算法设计中，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。

第二个问题是分布式信源编码中的 Slepian-Wolf 编码问题。论文在相关一般信源下推导出 Slepian-Wolf 系统平均 MAP 译码错误概率的一个上界，并在此基础上，给出了相关一般信源下 Slepian-Wolf 定理正命题部分的一个新证明。然后，论文在相关平稳无记忆信源下推导出线性 Slepian-Wolf 系统平均 MAP 译码错误概率的一个改进上界，并在这一改进上界的基础上，分析了基于 LDPC 码和随机置换的 Slepian-Wolf 系统的性能，证明了在一定的条件下，当编码长度非常大时，几乎所有的 LDPC 编码器和置换对于实际 Slepian-Wolf 系统的设计都是足够好的。最后，论文对通用 Slepian-Wolf 编码问题作了探讨，依靠信息谱方法建立了先验一般信源与通用 Slepian-Wolf 编码间的联系。作为一个例子，论文通过给出最小熵译码器所对应的先验一般信源，揭示了其通用编码的原理。

关键词： 通用信源编码，整数编码，Golomb 码，Elias γ 码，Burrows-Wheeler 变换 (BWT)，Slepian-Wolf 编码，最大后验概率 (MAP) 译码，一般信源，一般信道，信息谱，低密度偶校验 (LDPC) 码，最小熵译码器。

Abstract

Two important problems in lossless source coding are studied in this thesis.

The first problem is the integer coding problem, one of the problems in universal source coding. The performance of Golomb codes for arbitrary probability distributions is analyzed, and then a class of universal codes called extended γ codes is constructed based on Golomb codes. To understand these integer codes, we present the concept of maximum entropy code, and then prove that Golomb codes and extended γ codes are maximum entropy codes for two classes of sources respectively. Furthermore, the coding problem of a block of integers is considered, and four practical coding schemes of a block of integers are proposed and then applied to the design of compression algorithm based on Burrows-Wheeler transform. Experimental results of the algorithm indicate lossless coding rates better than those achieved by BWT-based compression algorithms using integer codes.

The second problem is the Slepian-Wolf coding problem, one of the problems in distributed source coding. An upper bound on the average MAP decoding error probability of Slepian-Wolf systems for correlated general sources is derived, and a new proof of the direct part of the Slepian-Wolf theorem for correlated general sources is given based on this bound. Moreover, an improved upper bound on the average MAP decoding error probability of linear Slepian-Wolf systems for stationary memoryless sources is derived. Based on this improved bound, we analyze the performance of Slepian-Wolf systems based on LDPC codes and random permutations, and prove that under some conditions, all but diminishingly small proportion of LDPC encoders and permutations are good enough for the design of practical Slepian-Wolf systems when the coding length is very large. Finally, the problem of universal Slepian-Wolf coding is considered. With the power of information spectrum methods, we establish the connection between a priori general sources and universal Slepian-Wolf coding. As an example, we explain the principle of the minimum entropy decoder by finding its corresponding a priori general source.

Key words: Universal source coding, integer coding, Golomb codes, Elias γ code, Burrows-Wheeler transform (BWT), Slepian-Wolf coding, maximum a posterior probability (MAP) decoding, general source, general channel, information spectrum, low density parity check (LDPC) codes, minimum entropy decoder.

目录

摘 要	i
Abstract	ii
目录	iii
插图	v
表格	vi
常用符号约定	vii
第一章 绪论	1
第二章 通用信源编码	5
2.1 整数的通用编码	5
2.1.1 基本理论框架	5
2.1.2 各类通用整数码	7
2.1.3 任意分布下 Golomb 码性能的分析	8
2.1.4 扩展的 γ 码及其在任意分布下的性能分析	18
2.1.5 最大熵码	20
2.1.6 一个低复杂性的通用数据压缩框架	25
2.2 一组整数的实用编码技术	27
2.2.1 二进制序列的编码	28
2.2.2 一组整数的编码	31
2.3 基于 BWT 和整数编码的通用数据压缩算法的设计	32
2.3.1 介绍	32
2.3.2 BWT 的原理与快速算法的设计	33
2.3.3 数据后处理算法的设计	36
2.3.4 基于整数组编码的 BWT 压缩算法设计	38

2.4 本章小节	40
第三章 分布式信源编码	41
3.1 基本问题与研究进展	41
3.2 信道编码分析中的 Gallager 方法	45
3.3 Slepian-Wolf 系统 MAP 译码错误概率的分析	46
3.4 相关一般信源下 Slepian-Wolf 定理正命题的证明	54
3.5 平稳无记忆信源下线性 Slepian-Wolf 系统 MAP 译码错误概率的分析	60
3.6 关于通用 Slepian-Wolf 编码的思考	73
3.7 本章小结	80
参考文献	82
攻读博士学位期间的研究成果	91
致 谢	92

插图

2.1	非递增概率分布下最小上界与估计公式的差值曲线 ($\mu_P \in [1, 131]$) . . .	16
2.2	非递增概率分布下混合方案与最优方案的性能上界差 ($\mu_P \in [1, 131]$) . . .	18
2.3	基于整数编码的通用数据压缩框架	25
2.4	基于 BWT 的数据压缩算法的一般结构	33
2.5	基于整数组编码的 BWT 压缩方案	38
3.1	Slepian-Wolf 编码系统	41
3.2	Slepian-Wolf 编码的虚拟信道思想	42
3.3	Wyner-Ziv 编码系统	43
3.4	DISCUS 算法的编码和译码	44
3.5	函数 $J(R)$ 的草图	52
3.6	一个长度为 10 的 (3,6) 规则 LDPC 码的双向图	68
3.7	一个基于 LDPC 码和交织器的对称 Slepian-Wolf 编码方案	72

表格

2.1	非递增概率分布下 $\mu_P \in [1, 129]$ 的最优参数	15
2.2	根据式 (2.1.34) 计算的参数 ($\mu_P \in [1, 171]$)	17
2.3	采用 Golomb 码方案的压缩结果 (码长单位: bits/symbol)	26
2.4	采用扩展 γ 码方案的压缩结果 (码长单位: bits/symbol)	27
2.5	自适应方式下 Golomb 码和扩展 γ 码方案的压缩结果	28
2.6	常用压缩算法的性能比较 (Calgary Corpus 数据)	33
2.7	BWT 正变换的实例 ($x^n = \text{bananas}$)	34
2.8	BWT 反变换的实例 ($y^n = \text{bnnsaaa}, a = 4$)	35
2.9	Calgary Corpus 的压缩结果 (单位: bits/symbol)	39
2.10	Canterbury Corpus 的压缩结果 (单位: bits/symbol)	39

常用符号约定

集合符号

整数集合	\mathbb{Z}
正整数集合	\mathbb{Z}^+
非负整数集合	\mathbb{N}
$\{0, 1\}$ 二进制集合	\mathbb{B}
Galois 域	$GF(q)$
集合 A 的 n 维乘积空间	A^n
由集合 A 中元素组成的所有有限长度序列的空间	A^*
集合 A 和 B 的乘积	$A \times B$
长度为 n 的序列	x^n

运算与关系符号

二进制数 x 与 y 按位异或	$x \oplus y$
二进制数 x 按位求反	\bar{x}
上确界	\sup
下确界	\inf
上极限	\limsup
下极限	\liminf
依概率上极限	$p\text{-lim sup}$
依概率下极限	$p\text{-lim inf}$
定义符	\triangleq

函数符号

实数 x 的下取整	$\lfloor x \rfloor$
-------------------	---------------------

实数 x 的上取整	$\lceil x \rceil$
随机变量 X 的数学期望	$E[X]$ 或 $E_P[X]$
阶跃函数	$u(x)$
指示函数	$1\{\cdot\}$

其他符号

使得 (such that)	s. t.
存在	\exists

第一章 绪论

自 Shannon 于 1948 年以《A Mathematical Theory of Communication》^[90] 一文创立信息论学科以来，信源编码一直是信息论研究的一个重要方向。信源编码包括无损信源编码和有损信源编码（亦称为率失真理论）。虽然有损信源编码在目前高速发展的多媒体技术下具有更广泛的应用范围，但在不少应用场合，由于要求数据被无失真地恢复，所以必须采用无损信源编码（如计算机数据的压缩存档等）。另一方面，由于无损信源编码是有损信源编码的一种特殊情况，即失真度为零，所以在理论上，无损信源编码理论是整个信源编码理论的基础，实际中有损信源编码的设计也常常依托于无损信源编码的设计（如熵编码器的使用）。

近几十年来，无损信源编码理论和应用的研究突飞猛进，其中又可以分为单用户无损信源编码的研究和多用户无损信源编码的研究。单用户无损信源编码的研究可以分为以下三个方向：

一、可达速率区（Achievable Rate Region）的研究

所谓可达速率，即指在该速率的任意邻域内存在符合某种条件的编码器与解码器。由所有可达速率组成的集合称为可达速率区。由于存在各种不同类型的码，所以可达速率区的问题也要在不同类型码的情况下分别进行考虑。

根据 Han 和 Kobayashi 的《Mathematics of Information and Coding》^[51] 一书，各种信源编码首先可以分为分组码（Block Codes）和序贯码（Sequential Codes）。所谓分组码，即由信源生成的序列被分成若干块（不一定等长），每一块被分别编码，每块的编码过程都与其他块不相关。而序贯码则相反，它在编码器中保留之前所读数据的有关信息，以此结合当前段的数据来进行编码。实际中，为了获得较好的压缩性能，许多系统都被设计为序贯码，然而在理论上，笔者认为序贯码可以等同为某个长度更长的分组码。分组码还可以依照其输入分组长度和输出分组长度的特点分为 FF 码、VF 码、FV 码和 VV 码，其中 F 表示固定长度（Fixed-Length），V 表示可变长度（Variable-Length），第一个字符表示输入分组长度的特点，而第二个字符表示输出分组长度的特点，以 FV 码为例，就是输入分组长度固定、输出分组长度可变的码。

FF 码是信源编码理论中研究较多的码，信息论中大多数关于可达速率区的研究都是首先围绕 FF 码展开的，然后再推广到其他类型的码（主要是 FV 码）。在 [90] 中，Shannon 首先运用典型列的思想给出了离散无记忆信源（Discrete Memoryless

Sources, DMSs) 下的可达速率区, 而后 Shannon 又进一步推广到有限状态的遍历 Markov 信源。1953 年, McMillan 将统计力学中的术语渐近等分性质 (Asymptotic Equipartition Property, AEP) 引入信息论^[71], 用于描述 Shannon 证明中所用到的典型列的典型特性。同一文中, McMillan 还进一步运用概率论中的遍历定理 (Ergodic Theorem) 推广了 Shannon 关于典型列的结果, 得出了每一个有限字符集的平稳遍历过程 (Stationary Ergodic Processes) 都满足 AEP 的结论, 现在的教科书 (如 [24]) 通常将之称为 Shannon-McMillan 定理。运用 Shannon-McMillan 定理, 平稳遍历过程的可达速率区问题就可以非常容易地运用 AEP 性质解决。然而, 对于非平稳或者非遍历的信源, 并不一定满足 AEP, 所以需要更一般的理论来研究这些信源。1993 年, Han 和 Verdú 在 [52] 中提出了信息谱 (Information Spectrum) 的方法, 运用该方法可以计算任意一般信源 (General Sources) 的可达速率区。

二、熵编码器 (Entropy Coder) 的设计

计算出可达速率区, 只是说明在这些速率下存在符合性能要求的码, 而实际应用中需要的是能够以较低的算法复杂性来构造出这些码, 这就是熵编码器的设计问题, 即在已知信源统计特性的条件下如何设计接近可达速率区边界 (最优压缩) 的编码器。

FF 码虽然具有重要的理论意义, 但是由于这种码本质上必然是有译码错误的, 故其只具有理论意义 (在多用户无损信源编码中并非如此), 并未被应用于实际。实际中最常用的是 FV 码, Huffman 于 1952 年在 [54] 中提出的最优前缀码就是一类在离散无记忆信源下平均码字长度达到最小的 FV 码, 现在的教科书上通常称为 Huffman 编码, 其平均码字长度小于信源熵加 1。与 Huffman 码性能相似的 FV 码还有 Shannon 码^[90]、Shannon-Fano-Elias 码^[24] 等。相比 FF 和 FV 码, VF 码的研究较少, 而 VV 码则几乎没有什么研究, 在 Tunstall 的博士论文 [97] 中给出了一种构造无记忆信源下最优 VF 码的算法。

虽然理论上可以通过增大分组长度 (即扩展字符集) 的技术, 使分组码 (如 Huffman 编码) 的平均码字长度渐近趋向于信源熵, 但是这在实际中会导致算法复杂性过高, 而编码性能的收敛速度过慢。所以, 研究者们转而考虑序贯码的设计。Rissanen 在 [85] 中提出的算术编码是目前使用最为广泛并最具灵活性的一类序贯编码算法, 这种编码算法的基本原理源于 Shannon-Fano-Elias 码, 其本质就是给出了一个有效的递归算法可以将长分组 Shannon-Fano-Elias 码分解为许多较小分组 (通常就是单个字符) 的序贯编码算法, 同时还要解决实际实现中的有限精度算术问题。由于算术编码可以非常容易地通过待编码字符的条件概率来挖掘信源的记忆特性, 所以结合一定的统计模型或预测模型就可以达到较高的压缩性能。

三、通用编码 (Universal Coding) 的研究

虽然熵编码器可以生成任意信源下接近可达速率区边界的码, 但是它要求知道信源的统计特性, 这个条件在实际应用中常常无法满足, 所以在更多的应用环境下, 我们需要考虑信源统计特性未知条件下的无损信源编码问题。解决这一问题的一个最直

接的思路就是先对信源数据进行统计分析, 然后再用熵编码器进行编码, 这类技术还可以进一步分为自适应和非自适应两类方法, 这些都是目前数据压缩中最常用的方法, 但是还有更好的解决方案, 即构造通用码 (Universal Codes)。通用一词最早是 Kolmogorov 在 [59] 中提出的, 意指数据压缩算法没有关于信源统计特性的先验知识。根据笔者的理解, 目前理论研究的通用码可以按照译码是否会产生错误分为渐近无错码和无错码。

渐近无错通用码通常为 FF 码, 即一个固定速率码, 所以也常称为定长码, 它可以做到对于某一类信源, 只要信源的可达速率区包含其码率, 就可以达到渐近无错的无损压缩。关于渐近无错通用码的研究, 以 Csiszár 和 Körner 的类型论方法为代表^[27], 通过使用最小熵译码器, 可以证明离散无记忆信源下存在通用 FF 码, 甚至是通用线性 FF 码^[25]。但是, 这些工作只是证明了通用 FF 码的存在性, 至于实际通用定长码的构造仍有待于进一步的研究。

无错通用码由于其无错的特性, 必然要求其输入或输出序列至少有一边是变长序列, 故无错码也常称为变长码, 它可以做到对于某一类信源, 其平均码字长度随数据长度的增加渐近收敛于信源熵。无错通用码的研究是单用户无损信源编码研究的一个重点, 至今, 数据压缩中大部分的理论研究和实际应用都是围绕无错通用码的构造与分析展开的。关于无错通用码的早期工作有 Fitingof 的组合论方法构造的通用编码算法^[39] 和 Davisson 的概率论方法建立的通用编码的理论框架^[28]。而后, Ziv 和 Lempel 于 1977 年和 1978 年提出了目前使用最为广泛的两类通用压缩算法: LZ'77^[109] 和 LZ'78^[110]。从八十年代末至九十年代初, Wyner、Ziv、Willems 等一批学者以 Kac 的返回时间定理^[57] (Kac Return-Time Theorem) 为基础, 对与两类 LZ 算法密切相关的重复时间和重复长度的渐近特性进行了深入的研究, 进而对各种 LZ 类变种算法的性能进行了深入的分析, 有关这些进展的介绍可参见 [104]。除了 LZ 类压缩算法, 部分匹配预测 (Prediction by Partial Matching, PPM) 算法^[20] 和 Burrows-Wheeler 变换 (Burrows-Wheeler Transform, BWT) 算法^[16] 也是目前研究和应用较多的通用数据压缩算法。此外, 关于具有可数无穷字符集和未知分布的离散无记忆信源的 (无错) 压缩问题也是通用数据压缩研究中一个非常有意义的问题, 通常称为整数的通用编码 (Universal Coding of Integers) 问题, 其基本的理论框架可参见 [32]。

以上, 我们对单用户无损信源编码的研究进展作了一个简略的回顾。受限于本文的主题和笔者的知识面, 这一回顾必然是简略的, 同时也不一定十分全面 (笔者已经省略了关于受限系统编码的研究), 比如上文中提及的文献主要是各个方向的开题工作或经典工作, 但实际上每个方向都有非常丰富的研究成果。

与单用户无损信源编码相比, 多用户无损信源编码要复杂得多, 无论是研究问题的类型、难度都远远超过了单用户的情形。笔者个人认为, 即使是需要解决的问题模型种类还会有进一步的发展空间, 目前研究较多的问题主要有两类。一类是 1973 年由 Slepian 和 Wolf 提出的相关信源的分离编码问题^[92], 这是分布式信源编码研究中的

一个基本问题, 虽然理论上, 各种信源条件下该问题的可达速率区已获得基本解决, 但实际如何编码、如何构造通用码的问题还有很长的路要走。另一类则是网络编码 (Network Coding) 问题, 其标志性文章为 2000 年 Ahlswede 等人发表的 [3], 网络编码主要研究网络传输 (如单信源或多信源的多播问题) 中的编码问题, 希望通过编码的方法达到比简单路由方法更好的网络性能, 这几年来, 关于网络编码的文献有加速增长的趋势。

通过对无损信源编码理论的全面回顾并结合自身的兴趣, 笔者将在论文中重点研究以下两个问题:

(1) 单用户通用无损信源编码 (常简称为通用信源编码) 中的整数编码问题 (第二章)。我们分析了任意分布下 Golomb 码的性能, 并在此基础上提出了一类通用的扩展 γ 码, 然后提出了最大熵码的概念, 并证明了 Golomb 码和扩展 γ 码都是最大熵码, 进而考虑了一组整数的编码问题, 提出了一系列的实用编码方案, 并将其应用于基于 BWT 的压缩算法设计中。

(2) 分布式信源编码中的 Slepian-Wolf 编码问题 (第三章)。我们在一般信源下给出了 Slepian-Wolf 系统平均 MAP 译码错误概率的上界, 并在此基础上给出了一般信源下 Slepian-Wolf 定理正命题部分的一个新证明, 然后在相关平稳无记忆信源下给出了线性 Slepian-Wolf 系统平均 MAP 译码错误概率的一个改进上界, 进而分析了基于 LDPC 码和随机置换的 Slepian-Wolf 系统的性能, 证明了当编码长度非常大时, 大多数 (概率趋近于 1) LDPC 码和置换可以帮助我们构建性能优良的对称 Slepian-Wolf 编码系统。最后, 我们还对通用 Slepian-Wolf 编码作了探讨, 在信息谱理论的框架下建立了先验信源与通用编码间的联系, 并运用这种观点对最小熵译码器的原理进行了解释, 为今后通用 Slepian-Wolf 编码理论和应用的研究指出了一条有益的思路。

第二章 通用信源编码

2.1 整数的通用编码

2.1.1 基本理论框架

从字面来看，“整数的通用编码”包括两层意思：第一层就是指整数的编码，即关于可数无穷字符集的编码；第二层则是指编码为通用编码，即没有关于整数概率分布的先验知识。

整数的编码问题并不是一个平凡的问题，由于字符集是可数无穷的，所以通常的编码算法根本无法胜任。如计算机中的定点、浮点表示，虽然其表示范围已很大，但仍无法表示可数无穷个字符。又如 Huffman 编码^[54]，虽然对于有限字符集给出了令人满意的码字构造算法，但这些算法都无法简单地扩展到可数无穷字符集。事实上，整数的编码问题还与一类计算机科学中称为无界搜索（Unbounded Search）的基本问题有着密切的联系。

整数的通用编码问题则更是一个十分有意义的问题，因为整数的通用码经常被用于通用信源编码（也称为通用数据压缩）的理论分析中。由于在通用数据压缩的理论分析中，为了证明编码性能具有某种渐近收敛的特性，常常使用扩展字符集的技术，而扩展字符集的本质就是使字符集的基数趋于可数无穷，于是一般信源的通用编码问题就转化为整数的通用编码问题。

虽然在 Elias 的工作之前，也有一些关于整数编码的工作，但整数通用编码的基本理论框架主要是由 1975 年 Elias 的文章 [32] 建立起来的。在介绍有关理论之前，我们先引入有关的记号。

首先，记二进制集合 $\{0, 1\}$ 为 \mathbb{B} ， \oplus 表示异或运算（即模 2 加法）， \bar{x} 表示对二进制字符 x 求反，定义 \mathbb{B}^* 表示由集合 \mathbb{B} 中的符号组成的所有有限长度的二进制序列的集合，集合 \mathbb{B}^* 中的任意两个序列 α 和 β 的级联记为 $\alpha\beta$ ，序列 α 的长度记为 $|\alpha|$ 。设一组由可数无穷个码字构成的前缀码 $C = \{c_i \in \mathbb{B}^* : i \in \mathbb{Z}^+\}$ 。其次，定义正整数信源 $S = (\mathbb{Z}^+, P)$ ， \mathbb{Z}^+ 为信源的字符集， P 为定义在正整数集合上的概率分布函数。于是，信源 S 的熵和均值分别表示为 $H(P) \triangleq E_P[-\log p(i)]$ 和 $\mu_P \triangleq E_P[i]$ 。本章中， $\log x \triangleq \log_2 x$ ， $\lfloor x \rfloor$ 表示对 x 下取整， $\lceil x \rceil$ 表示对 x 上取整， $\langle x \rangle \triangleq x - \lfloor x \rfloor$ ， $x \bmod y \triangleq x - \lfloor x/y \rfloor y$ 。我们将每个码字 c_i 与每个正整数联系起来，那么对于一个给

定的前缀码 C 和一个给定的信源 S , 其平均码长定义为

$$\overline{L_P(C)} \triangleq E_P[|c_i|] = \sum_{i \in \mathbb{Z}^+} p(i)|c_i|. \quad (2.1.1)$$

在 [32] 中, Elias 首先将整数的通用编码问题设定在一类特殊的信源上, 即由所有具有有限熵且概率分布函数非递增的正整数信源构成的信源类 \mathcal{S}_{NI} 。随后, Elias 给出了通用码和渐近最优码的定义。前缀码 C 是通用的, 当且仅当比率

$$\frac{\overline{L_P(C)}}{\max\{1, H(P)\}} \leq K_C, \quad \forall S \in \mathcal{S}_{NI}. \quad (2.1.2)$$

前缀码 C 是渐近最优的, 当且仅当比率

$$\frac{\overline{L_P(C)}}{\max\{1, H(P)\}} \leq R_C(H(P)) \leq K_C, \quad \text{且} \quad \lim_{H(P) \rightarrow \infty} R_C(H(P)) = 1. \quad (2.1.3)$$

在其后关于整数的通用编码问题上, 几乎所有的工作都是在这一理论框架下进行的, 至多对上述两种码的定义作轻微的修改。在进一步具体介绍通用整数码之前, 我们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

$$\Lambda(j) \triangleq |(j)_2| = \lceil \log j \rceil + 1, \quad \lambda(j) \triangleq |[j]_2| = \lceil \log j \rceil. \quad (2.1.4)$$

令 $(j)_1$ 为一个正整数 j 的一元表示。例如, $(1)_1 = 0$, $(2)_1 = 10$, $(3)_1 = 110$, ...。显然, $|(j)_1| = j$ 。令 $B_l(j)$ 为表示 0 到 $l-1$ 这 l 个整数的分组码, 其编码规则为

$$B_l(j) \triangleq \begin{cases} B_{2^{k-1}}(j), & j < 2^k - l \\ B_{2^k}(j + 2^k - l), & j \geq 2^k - l \end{cases} \quad (2.1.5a)$$

$$(2.1.5b)$$

式中 $B_{2^k}(j)$ 定义为整数 j 的 k 比特二进制表示, $k = \lceil \log l \rceil$ 。例如, 当 $l = 5$ 时, 则 $k = 3$, $2^k - l = 3$, 于是

$$\begin{aligned} B_5(0) &= B_4(0) = 00, \\ B_5(1) &= B_4(1) = 01, \\ B_5(2) &= B_4(2) = 10, \\ B_5(3) &= B_8(3+3) = 110, \\ B_5(4) &= B_8(4+3) = 111. \end{aligned}$$

码字 $B_l(j)$ 的长度为

$$|B_l(j)| = \lceil \log l \rceil - u(2^{\lceil \log l \rceil} - l - 1 - j). \quad (2.1.6)$$

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

2.1.2 各类通用整数码

到目前为止，各类通用整数码大体可以按照是否具有错误恢复能力分为两类，我们不妨将这两类码分别称为易错（Error Sensitive）码和鲁棒（Robust）码。

大多数易错码都是以正整数的二进制表示为基础构造的，有些文献中将这种构造原理的整数码称为对数斜坡表示（Logarithmic Ramp Representation），文献 [5] 则将其称为消息长度策略（Message Length Strategy）。文献 [32] 中提出的几类通用码，如 γ 码、 δ 码和 ω 码都属于这一类。

γ 码以二进制表示 $[j]_2$ 为基础，然后在每个二进制字符前插入字符 0，最后插入 1 表示二进制字符的结束。例如， $[5]_2 = 01$ ，所以

$$\gamma(5) = 00 \underline{01} 1.$$

γ 码还有一个变种 γ' 码，它主要是将插入字符的方法改为前置字符，还是以正整数 5 为例，

$$\gamma'(5) = 001 \underline{01}.$$

可以看出 γ' 码的头部就是一个一元码（但与本文中的定义相反），所以如果使用本文的一元码代之， γ' 码的算法可以表示为

$$\gamma'(j) = (|(j)_2|)_1 [j]_2 = (\Lambda(j))_1 [j]_2. \quad (2.1.7)$$

下文中，我们都将以 (2.1.7) 来计算 γ 码。 γ 码是通用码，但不是渐近最优的。

δ 码则是以 γ 码为基础构造的，它先写下正整数 j 的去除最高位的标准二进制表示 $[j]_2$ ，然后再将其长度信息以 γ 码写在其头部，具体算法可定义为

$$\delta(j) = \gamma(|(j)_2|) [j]_2 = \gamma(\Lambda(j)) [j]_2. \quad (2.1.8)$$

以正整数 17 为例，则

$$\delta(17) = \gamma(5) [17]_2 = 110 01 0001.$$

δ 码是渐近最优码。

顺着 δ 码的这种思路， ω 码将这种构造码的思想发挥到极点，其基本思路为先写下正整数的二进制表示，而后将该二进制表示的长度信息以二进制表示写在其前面，然后将这第二个二进制表示的长度信息再以二进制表示写在其前面，如此反复，直到长度信息的二进制表示缩短到满足一定的约束条件（长度小于等于 2）。当然， ω 也是渐近最优码。其例子如下：

$$\omega(1) = 0, \quad \omega(2) = 10 0, \quad \omega(3) = 11 0, \quad \dots, \quad \omega(17) = 11 101 10001 0.$$

与 ω 码类似的有 Even 和 Rodeh 的 R 码^[34]、Stout 的 R_l 码和 S_l 码^[94]、Ahlswede 等的 ω' 码^[4] 等。

除了上述这些基于消息长度策略的整数码，Amemiya 和 Yamamoto 还提出了一类称为基于分组策略（Grouping Strategy）的整数码^[5]。其实，常用的 Golomb 码^[48]就是基于分组策略的，但它不是通用码。

所谓鲁棒码，即当码字出现一个传输错误时，译码器可以在某个序列长度之后重新恢复至正确译码，换言之，错误被局限在某段序列中而不会无限制地影响到以后所有的序列。通常，鲁棒码中会包含一个固定模式（Pattern）以表示码字的结束。Lakshmanan 对以长度为 k 的二进制字符串 p 结尾的编码集合 $C(k, p)$ 的信源编码性能进行了初步分析^[62]，证明了 $C(2, 00)$ 、 $C(2, 11)$ 和 $C(k, p)$ ($k \geq 3$, p 任意) 都是通用码，但都不是渐近最优的。Capocelli 则进一步运用生成函数（Generating Function）的方法对 $C(k, p)$ 编码集合作了更为精细的分析^[18]，证明了 p 的自相关多项式 pp_t 在 $t = 2$ 的值越大，其渐近性能越好。其中，若设 $p = p_1 p_2 \cdots p_k$ ，则自相关多项式定义为

$$pp_t \triangleq \sum_{n=0}^{k-1} \left(\prod_{m=1}^{k-n} \overline{p_m \oplus p_{m+n}} \right) t^{k-1-n}. \quad (2.1.9)$$

Capocelli 还证明了正规（Regular）码中不存在渐近最优码，所谓正规码是指可被有限状态自动机（Finite-State Automaton）识别的码。

实际鲁棒码的构造主要有两类。一类是由 Apostolico 和 Fraenkel 提出的基于 Fibonacci 计数系统的编码^[6, 17]。他们考虑了模式 $p = 1^m$ 的情形，其文中记为 $C_1^{(m)}$ 。由于该情形下不同长度的码字个数正好对应于 k 阶 Fibonacci 数，所以这类码可以用 m 阶的 Fibonacci 计数系统来计算，并由此定义了两类基本的 Fibonacci 表示，此外，文献 [6] 还提出了另一种基于 m 阶的 Fibonacci 计数系统的 Fibonacci 码 $C_2^{(m)}$ ，最后证明了所有的 Fibonacci 表示都是通用的，关于其它的一些 Fibonacci 码变种可参见 [41]。另一类是由 Wang 提出的基于 Flag 的编码^[100]，即用模式 $p = 0^f$ ($f \geq 0$) 作为表示一个码字结束的 Flag，他首先把正整数用标准二进制表示出来，然后将该二进制序列颠倒，序列中每逢 $f - 1$ 个 0 就插入一个 1，然后在末尾加上 0^f 。Yamamoto 和 Ochi 则进一步改进并推广了 Wang 的 Flag 编码方案^[105]，Flag 可以取满足以下自相关多项式的 p ，

$$pp_t = t^{f-1}, \quad p'p'_t = t^{f-1} + 1,$$

式中 $p' = p_1 p_2 \cdots p_{f-1} \overline{p_f}$ 。上述基于 Flag 的编码都是通用码。

2.1.3 任意分布下 Golomb 码性能的分析

虽然到目前为止，整数编码的研究者们已经提出了一系列通用的整数编码方案，但很多编码方案在数据压缩中并没有多大的实用价值，其主要原因是大部分的编码方案只有在具有较大熵值的信源下才能体现出其通用或者是渐近最优的性能，而实际应用中，字符集通常不是可数无穷的，甚至很小，信源的熵根本不可能达到体现这些编码性能的范围。而与此形成鲜明对比的是一类非通用码 Golomb 码却在实际的数据压

缩中获得了广泛的应用，所以在研究通用整数编码之前，我们将首先对 Golomb 码的性能进行深入的研究。

Golomb 码是 Golomb 于 1966 年提出的一类带参数的前缀码^[48]，由一个一元码和一个匹配均匀分布的 Huffman 码构成。由于其编码和解码的算法十分简单，到目前为止，已被广泛地应用于数据压缩领域，如无损图像压缩^[82, 101]。关于 Golomb 码的性能，Gallager 等证明了其在单边几何分布 (One-Sided Geometric Distribution, OSGD) 下是最优的^[45]，并给出了参数为 θ 的 OSGD 下的最优参数准则，即满足 $\theta^l + \theta^{l+1} \leq 1 < \theta^l + \theta^{l-1}$ 的整数 l ；Szpankowski 则进一步分析了其在 OSGD 下码字冗余长度的渐近特性^[95]。另一方面，Merhav 等在双边几何分布 (Two-Sided Geometric Distribution, TSGD) 下提出了一类性能最优的扩展的 Golomb 码^[72]。与这些理论上的进展相比，在实际中，Golomb 码的应用并没有仅仅局限于 OSGD 或 TSGD 的信源，它常常被用于那些具有近似递减概率特性但确切概率模型未知的信源上^[37, 53, 82]，因此，很有必要对 Golomb 码在任意分布下的性能进行分析。

我们首先分析 Golomb 码在具有有限均值的任意分布下的平均码字长度的上下界，并给出使 Golomb 码达到最低上下界的参数公式。原始的 Golomb 码是基于非负整数的，本文为和描述整数码的文献保持一致，所以给出了以下这个略微修改的基于正整数的 Golomb 码。

定义参数为 l ($l \in \mathbb{Z}^+$) 的 Golomb 码为

$$G_l = \left\{ g_l(i) \mid g_l(i) = \left(\left\lfloor \frac{i-1}{l} \right\rfloor + 1 \right)_1 B_l((i-1) \bmod l), i \in \mathbb{Z}^+ \right\}. \quad (2.1.10)$$

例如，当 $l = 5$ 时，整数 13 和 14 的编码分别为

$$g_5(13) = \left(\left\lfloor \frac{13-1}{5} \right\rfloor + 1 \right)_1 B_5((13-1) \bmod 5) = (3)_1 B_5(2) = 110 10$$

和

$$g_5(14) = \left(\left\lfloor \frac{14-1}{5} \right\rfloor + 1 \right)_1 B_5((14-1) \bmod 5) = (3)_1 B_5(3) = 110 110.$$

于是，我们有如下定理。

定理 2.1 对于一个给定的信源 S ，其均值 $\mu_P < \infty$ ，则对于任意的 $l \in \mathbb{Z}^+$ 有

$$LB_G(l, \mu_P) \leq \overline{L_P(G_l)} \leq UB_G(l, \mu_P), \quad (2.1.11)$$

式中

$$LB_G(l, \mu_P) = \lceil \log l \rceil + \frac{\mu_P - 2^{\lceil \log l \rceil}}{l} + 1, \quad (2.1.12)$$

$$UB_G(l, \mu_P) = \lceil \log l \rceil + \frac{\mu_P - 2^{\lceil \log l \rceil} - 1}{l} + 2. \quad (2.1.13)$$

下界 $LB_G(l, \mu_P)$ 在

$$l_0 = 2^{\lceil \log \mu_P \rceil} \quad (2.1.14)$$

处取到最小值, 所以对于所有的 $l \in \mathbb{Z}^+$,

$$\overline{L_P(G_l)} \geq LB_G(l_0, \mu_P) \geq \log \mu_P + \log \left(\frac{e}{\log e} \right). \quad (2.1.15)$$

上界 $UB_G(l, \mu_P)$ 在

$$l_1 = 2^{\lceil \log \max\{\mu_P - 1, 1\} \rceil} \quad (2.1.16)$$

处取到最小值, 且

$$UB_G(l_1, \mu_P) \leq \log \max\{\mu_P - 1, 1\} + \min\{\mu_P, 2\}. \quad (2.1.17)$$

证明: 由 Golomb 码的定义式 (2.1.10) 以及 (2.1.6) 知道, 一个参数为 l 的 Golomb 码, 其码字长度为

$$|g_l(i)| = \left\lfloor \frac{i-1}{l} \right\rfloor + 1 + \lceil \log l \rceil - u(2^{\lceil \log l \rceil} - l - 1 - (i-1) \bmod l).$$

因此由 (2.1.1), Golomb 码的平均码长为

$$\begin{aligned} \overline{L_P(G_l)} &= \sum_{i \in \mathbb{Z}^+} p(i) \left[\left\lfloor \frac{i-1}{l} \right\rfloor + 1 + \lceil \log l \rceil - u(2^{\lceil \log l \rceil} - l - 1 - (i-1) \bmod l) \right] \\ &= \lceil \log l \rceil + \frac{\mu_P - 1}{l} + 1 - \sum_{i \in \mathbb{Z}^+} p(i) \left[\left\langle \frac{i-1}{l} \right\rangle + u(2^{\lceil \log l \rceil} - l - 1 - (i-1) \bmod l) \right] \\ &= \lceil \log l \rceil + \frac{\mu_P - 1}{l} + 1 - \sum_{j=0}^{l-1} \sum_{\substack{(i-1) \bmod l = j, \\ i \in \mathbb{Z}^+}} p(i) \left[\frac{j}{l} + u(2^{\lceil \log l \rceil} - l - 1 - j) \right] \\ &= \lceil \log l \rceil + \frac{\mu_P - 1}{l} + 1 - \sum_{j=0}^{l-1} \tilde{p}(j) w(j, l), \end{aligned} \quad (2.1.18)$$

式中

$$\tilde{p}(j) = \sum_{(i-1) \bmod l = j, i \in \mathbb{Z}^+} p(i), \quad w(j, l) = \frac{j}{l} + u(2^{\lceil \log l \rceil} - l - 1 - j). \quad (2.1.19)$$

因为当 $0 \leq j \leq l-1$ 时,

$$\frac{2^{\lceil \log l \rceil}}{l} - 1 \leq w(j, l) \leq \frac{2^{\lceil \log l \rceil} - 1}{l},$$

所以结合 (2.1.18) 便可推出 (2.1.11)、(2.1.12) 和 (2.1.13)。

通过观察, 可以注意到如果 $\lceil \log l \rceil = \lceil \log l' \rceil$, 并且 $l < l'$, 那么 $LB_G(l, \mu_P) > LB_G(l', \mu_P)$, 所以函数 $LB_G(l, \mu_P)$ 的最小值只可能取在 $l = 2^k$ ($k \geq 0$)。于是, 我们计算如下的差式:

$$LB_G(2^{k+1}, \mu_P) - LB_G(2^k, \mu_P) = 1 - \frac{\mu_P}{2^{k+1}} \quad (2.1.20)$$

通过计算 (2.1.20) 知, 当 $2^{k+1} \leq \mu_P$ 时, $LB_G(2^{k+1}, \mu_P) \leq LB_G(2^k, \mu_P)$, 而当 $2^{k+1} > \mu_P$ 时, $LB_G(2^{k+1}, \mu_P) > LB_G(2^k, \mu_P)$ 。因此函数 $LB_G(2^k, \mu_P)$ 的最小值就是取在满足不等式 $2^{k+1} > \mu_P$ 的最小非负整数 k 上。通过解不等式, 就可以推出 (2.1.14)。于是, 对于所有 $l \in N^+$,

$$\overline{L_P(G_l)} \geq LB_G(l_0, \mu_P) = \log \mu_P + 2^{\langle \log \mu_P \rangle} - \langle \log \mu_P \rangle.$$

由微积分的知识知道, 函数 $f(x) = 2^x - x$ ($0 \leq x < 1$) 的最小值取在满足 $f'(x) = 0$ 的值上, 即 $x_0 = \log \log e$, 所以,

$$LB_G(l_0, \mu_P) \geq \log \mu_P + 2^{\log \log e} - \log \log e = \log \mu_P + \log \left(\frac{e}{\log e} \right),$$

(2.1.15) 得证。

与下界函数的证明类似, 同理可以证明上界函数在 (2.1.16) 处取得最小值, 而且当 $l = l_1$ 时, 若 $\mu_P \geq 2$, 则

$$\begin{aligned} UB_G(l_1, \mu_P) &= \lfloor \log \max\{\mu_P - 1, 1\} \rfloor + \frac{\mu_P - 1}{2^{\lfloor \log \max\{\mu_P - 1, 1\} \rfloor}} + 1 \\ &= \lfloor \log(\mu_P - 1) \rfloor + \frac{\mu_P - 1}{2^{\lfloor \log(\mu_P - 1) \rfloor}} + 1 \\ &= \log(\mu_P - 1) + 1 + 2^{\langle \log(\mu_P - 1) \rangle} - \langle \log(\mu_P - 1) \rangle \\ &\stackrel{(a)}{\leq} \log(\mu_P - 1) + 2, \end{aligned}$$

式中 (a) 利用了不等式 $2^x \leq x + 1$ ($0 \leq x \leq 1$)。若 $\mu_P < 2$, 则显然 $UB_G(l_1, \mu_P) = \mu_P$ 。结合上述两式, 从而 (2.1.17) 得证。□

定理2.1不仅给出了具有有限均值的任意分布下 Golomb 码平均码字长度的最紧的上下界, 而且还分别给出了 Golomb 码达到最低上下界的参数公式, 特别是 (2.1.16), 它给出了在已知信源均值的条件下 Golomb 码参数的最优选择准则, 这对于实际的应用是非常有指导意义的。从 (2.1.15) 和 (2.1.17) 可以看出, 在任意的有限均值分布下, Golomb 码的最优平均码长大约近似为 $\log \mu_P$, 所以 Golomb 码的最优性能几乎完全由信源的均值决定。

由于实际应用中, Golomb 码常常被用于具有近似递减概率分布的信源, 所以我们进一步分析了其在非递增概率分布下的性能。

定理 2.2 对于一个给定的信源 S , 其均值 $\mu_P < \infty$, 且其概率分布满足条件

$$p(1) \geq p(2) \geq \cdots \geq p(i) \geq \cdots,$$

则对于任意的 $l \in \mathbb{Z}^+$ 有

$$LB'_G(l, \mu_P) \leq \overline{L_P(G_l)} \leq UB'_G(l, \mu_P), \quad (2.1.21)$$

式中

$$LB'_G(l, \mu_P) = \lceil \log l \rceil + \frac{\mu_P - 1}{l} + 1 - W_1(l), \quad (2.1.22)$$

$$UB'_G(l, \mu_P) = \lceil \log l \rceil + \frac{\mu_P - 1}{l} + 1 - W_2(l), \quad (2.1.23)$$

并且

$$W_1(l) = \begin{cases} \frac{l-1}{2l}, & m = 0 \\ \frac{m-1}{2l} + 1, & m > 0 \end{cases} \quad (2.1.24a)$$

$$(2.1.24b)$$

$$W_2(l) = \begin{cases} 0, & m = 0 \\ \frac{n}{2l} + \frac{m}{n+1}, & 0 < m < \frac{l+1}{2} \\ 1, & m \geq \frac{l+1}{2} \end{cases} \quad (2.1.25a)$$

$$(2.1.25b)$$

$$(2.1.25c)$$

式中

$$m \triangleq 2^{\lceil \log l \rceil} - l, \quad n \triangleq \left\lfloor \sqrt{2ml + \frac{1}{4}} - \frac{1}{2} \right\rfloor. \quad (2.1.26)$$

此外, 对于 $0 < m < \frac{l+1}{2}$,

$$\frac{n}{l} \leq W_2(l) < \frac{n+1}{l}, \quad (2.1.27)$$

$$2m - 1 \leq n \leq l - 1, \quad (2.1.28)$$

因此

$$W_1(l) - W_2(l) \leq 1 - \frac{3m}{2l}. \quad (2.1.29)$$

证明: 与定理2.1的前段证明类似, 我们也有 (2.1.18), 但多了一个约束条件, 即对于任意 $j_1 < j_2$, $\tilde{p}(j_1) \geq \tilde{p}(j_2)$, 这是由非递增概率分布条件推出的。

令 $W_1(l)$ 和 $W_2(l)$ 分别为 $\sum_{j=0}^{l-1} \tilde{p}(j)w(j, l)$ 的上界与下界, 于是有 (2.1.21)、(2.1.22) 和 (2.1.23)。因此, 证明的关键就是计算 $W_1(l)$ 与 $W_2(l)$ 。

为简化证明, 我们定义 $\hat{p}(l) = 0$, 同时注意到对于任意 $0 \leq j_1 < j_2 \leq l$, $\tilde{p}(j_1) \geq \tilde{p}(j_2)$, 于是我们有

$$\begin{aligned} \sum_{j=0}^{l-1} \tilde{p}(j)w(j, l) &= \sum_{j=0}^{l-1} w(j, l) \sum_{k=j}^{l-1} [\tilde{p}(k) - \tilde{p}(k+1)] \\ &= \sum_{k=0}^{l-1} [\tilde{p}(k) - \tilde{p}(k+1)] \sum_{j=0}^k w(j, l) \\ &= \sum_{k=0}^{l-1} \hat{p}(k)\hat{w}(k, l), \end{aligned} \quad (2.1.30)$$

式中

$$\hat{p}(k) = (k+1)[\tilde{p}(k) - \tilde{p}(k+1)],$$

$$\hat{w}(k, l) = \frac{1}{k+1} \sum_{j=0}^k w(j, l).$$

显然, $\sum_{k=0}^{l-1} \hat{p}(k) = 1$ 。由 (2.1.19), 我们有

$$\begin{aligned} \hat{w}(k, l) &= \frac{1}{k+1} \sum_{j=0}^k \left[\frac{j}{l} + u(2^{\lceil \log l \rceil} - l - 1 - j) \right] \\ &= \frac{k}{2l} + \min\left\{1, \frac{2^{\lceil \log l \rceil} - l}{k+1}\right\} \\ &= \frac{k}{2l} + \min\left\{1, \frac{m}{k+1}\right\}. \end{aligned}$$

若 $m = 0$, 则对于 $0 \leq k \leq l-1$

$$0 \leq \hat{w}(k, l) \leq \frac{l-1}{2l}.$$

上式结合 (2.1.30) 即可推出 (2.1.24a) 和 (2.1.25a)。

若 $m > 0$, 我们有

$$1 \leq \hat{w}(k, l) \leq \frac{m-1}{2l} + 1, \quad \text{当 } 0 \leq k \leq m-1$$

与

$$\hat{w}(k, l) = \frac{k}{2l} + \frac{m}{k+1}, \quad \text{当 } m \leq k \leq l-1.$$

因为

$$\left(\frac{m-1}{2l} + 1\right) - \left(\frac{k}{2l} + \frac{m}{k+1}\right) = (k-m+1) \left(\frac{1}{k+1} - \frac{1}{2l}\right) \stackrel{(a)}{\geq} \frac{1}{l} - \frac{1}{2l} > 0,$$

式中, (a) 利用了不等式 $m \leq k \leq l-1$, 所以 $\hat{w}(k, l)$ 的最大值是 $\frac{m-1}{2l} + 1$ 。该式结合 (2.1.30) 即可推出 (2.1.24b)。

为了求当 $m \leq k \leq l-1$ 时 $\hat{w}(k, l)$ 的最小值, 我们计算 $\hat{w}(k, l)$ 关于 k 的差分。为简单起见, 我们定义 $\hat{w}(l, l) = \frac{1}{2} + \frac{m}{l+1}$ 。于是当 $m \leq k \leq l-1$ 时,

$$\hat{w}(k+1, l) - \hat{w}(k, l) = \frac{1}{2l} + \frac{m}{k+2} - \frac{m}{k+1} = \frac{1}{2l} - \frac{m}{(k+1)(k+2)}.$$

令 $\hat{w}(k+1, l) - \hat{w}(k, l) = 0$, 则得到方程

$$k^2 + 3k + 2 - 2ml = 0.$$

方程的根为

$$k = \pm \sqrt{2ml + \frac{1}{4}} - \frac{3}{2}.$$

因为 k 必须是正的, 所以我们仅考虑正根并记为 k_0 。注意到当 $m \leq k \leq k_0$ 时, $\hat{w}(k+1, l) - \hat{w}(k, l) \leq 0$, 而当 $k > k_0$ 时 $\hat{w}(k+1, l) - \hat{w}(k, l) > 0$ 。所以, 最小值取在

满足 $\hat{w}(k+1, l) - \hat{w}(k, l) > 0$ 的最小整数上, 即 $n = [k_0] + 1$ (定义式 (2.1.26)), 并且 n 必须满足条件 $m \leq n \leq l-1$ 。

若 $0 < m < \frac{l+1}{2}$, 则

$$n \geq \left\lceil \sqrt{2m(2m-1) + \frac{1}{4}} - \frac{1}{2} \right\rceil = 2m - 1$$

且

$$n < \left\lceil \sqrt{l(l+1) + \frac{1}{4}} - \frac{1}{2} \right\rceil = l,$$

于是 (2.1.28) 得证。因此, 如果 $0 < m < \frac{l+1}{2}$, 那么 $\hat{w}(k, l)$ 在 $m \leq k \leq l-1$ 上的最小值是

$$\hat{w}(n, l) = \frac{n}{2l} + \frac{m}{n+1}.$$

由 n 的特性, 我们有

$$\hat{w}(n+1, l) - \hat{w}(n, l) = \frac{1}{2l} - \frac{m}{(n+1)(n+2)} > 0,$$

$$\hat{w}(n, l) - \hat{w}(n-1, l) = \frac{1}{2l} - \frac{m}{n(n+1)} \leq 0.$$

即

$$\frac{n}{2l} \leq \frac{m}{n+1} < \frac{n+2}{2l},$$

因此

$$\frac{n}{l} \leq \hat{w}(n, l) < \frac{n+1}{l} \leq 1.$$

该式结合 (2.1.30) 即可推出 (2.1.25b) 和 (2.1.27)。并且可以进一步得到

$$\begin{aligned} W_1(l) - W_2(l) &\stackrel{(a)}{=} \frac{m-1}{2l} + 1 - \frac{n}{2l} - \frac{m}{n+1} \\ &\stackrel{(b)}{\leq} 1 + \frac{m - (2m-1) - 1}{2l} - \frac{m}{l} \\ &= 1 - \frac{3m}{2l}, \end{aligned}$$

式中 (a) 利用了 (2.1.24b) 和 (2.1.25b), (b) 利用了 (2.1.28), 于是 (2.1.29) 得证。

若 $m \geq \frac{l+1}{2}$, 则 $n \geq l$, 因此 $\hat{w}(k, l)$ 在 $m \leq k \leq l-1$ 上的最小值是

$$\hat{w}(l-1, l) = \frac{l-1}{2l} + \frac{m}{l} \geq \frac{l-1}{2l} + \frac{l+1}{2l} = 1.$$

因此 $\hat{w}(k, l)$ ($0 \leq k \leq l-1$) 的最小值是 $\min\{1, \hat{w}(l-1, l)\} = 1$, 从而推出 (2.1.25c)。

□

定理2.2给出的上下界都是充分紧的，但要使这些结果具有实用价值，还必须找出使其上界 $UB'_G(l, \mu_P)$ 最小的最优参数，这是十分困难的，特别是要得到精确的最优参数公式。所以，我们首先直接计算均值 $\mu_P \in [1, 129)$ 的最优参数（见表2.1）。通过线性回归的方法，我们还对这些最优参数达到的最小上界作了估计，得到如下估计公式

$$\log \mu_P + 1.507. \quad (2.1.31)$$

图2.1绘出了最小上界与估计公式 (2.1.31) 的差值曲线。可以看出，当 μ_P 较大时，估计公式还是非常精确的。

表 2.1: 非递增概率分布下 $\mu_P \in [1, 129)$ 的最优参数

μ_P	最优 l	μ_P	最优 l
[1.00, 3.00)	1	[45.31, 45.95)	26
[3.00, 6.00)	3	[45.95, 66.55)	43
[6.00, 9.00)	5	[66.55, 68.80)	44
[9.00, 11.88)	6	[68.80, 71.49)	45
[11.88, 18.70)	11	[71.49, 74.32)	46
[18.70, 21.90)	12	[74.32, 77.26)	47
[21.90, 22.88)	13	[77.26, 80.50)	48
[22.88, 33.00)	21	[80.50, 84.08)	49
[33.00, 35.25)	22	[84.08, 88.03)	50
[35.25, 38.10)	23	[88.03, 90.79)	51
[38.10, 41.45)	24	[90.79, 129.00)	85
[41.45, 45.31)	25		

对于许多应用而言，采用类似于表2.1的查找表就已经足够了。但我们还是期望能找到一个简单的参数公式，且具有接近于最优参数的性能，因此接下来，我们将进一步分析上界函数 (2.1.23) 的性质。

推论 2.1 在定理2.2的相同条件下，由 (2.1.23) 定义的上界 $UB'_G(l, \mu_P)$ 在 $2^k \leq l \leq 2^k + c(k)$ 上是单调递减的，式中 k 是一个任意的非负整数，而 $c(k)$ 由下式定义。

$$c(k) = \left\lfloor \frac{2^k - 1}{3} \right\rfloor. \quad (2.1.32)$$

证明： 由定理2.2知，对于 $2^k \leq l \leq 2^k + c(k)$

$$UB'_G(l, \mu_P) = k + \frac{\mu_P - 1}{l} + 1,$$

因为当 $2^k < l \leq 2^k + c(k)$ 时，根据 (2.1.32) 有

$$m = 2^{k+1} - l \geq 2^k - c(k) \geq \frac{2^k + c(k) + 1}{2} \geq \frac{l + 1}{2},$$

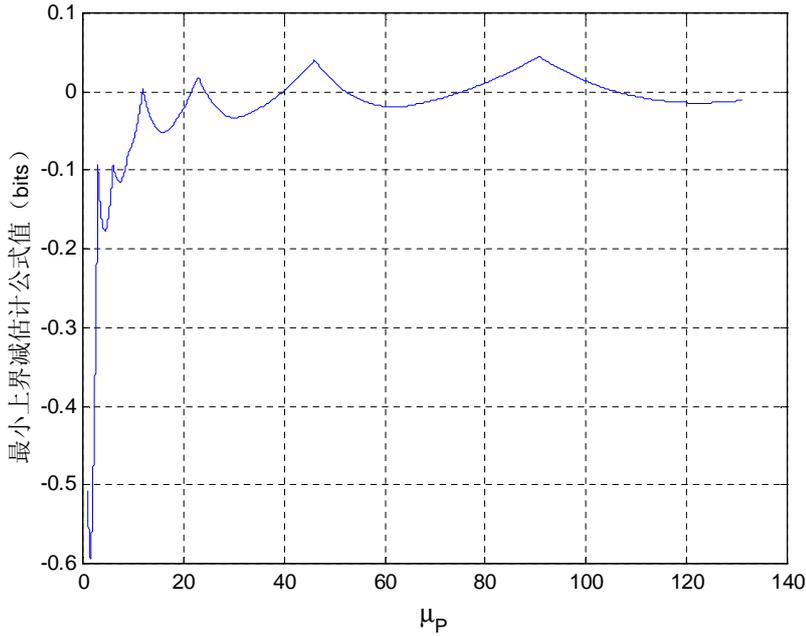


图 2.1: 非递增概率分布下最小上界与估计公式的差值曲线 ($\mu_P \in [1, 131]$)

因此由 (2.1.25c) 推出 $W_2(l) = 1$ 。于是显然, $UB'_G(l, \mu_P)$ 在 $2^k \leq l \leq 2^k + c(k)$ 上是单调递减的。□

定义序列 $d_k = 2^k + c(k)$ ($k \in \mathbb{N}$)。该序列的前几项如下: $d_0 = 1, d_1 = 2, d_2 = 5, d_3 = 10, d_4 = 21, d_5 = 42, d_6 = 85, \dots$ 。根据推论 2.1, 该序列在正整数的一个子集上是不错的, 即具有较低的上界, 而且我们注意到表 2.1 中的最优参数其实都是在这个序列中某一项的附近取值, 所以我们转而考虑该序列下的最优参数问题。如此, 问题得到了极大的简化, 而最终的性能又接近于原问题的目标。

推论 2.2 定义序列 $\{d_k\}_{k \in \mathbb{N}}$

$$d_k = 2^k + c(k), \quad (2.1.33)$$

式中 $c(k)$ 由 (2.1.32) 定义。于是, 在定理 2.2 的相同条件下, 满足条件

$$d_k > (\mu_P - 1) \left(1 - \frac{d_k}{d_{k+1}}\right) \quad (2.1.34)$$

的第一项 d_k 就是序列 $\{d_k\}_{k \in \mathbb{Z}}$ 中使上界 $UB'_G(l, \mu_P)$ 最小的那一项, 且

$$\lim_{k \rightarrow \infty} (\mu_P - 1) \left(1 - \frac{d_k}{d_{k+1}}\right) = \frac{\mu_P - 1}{2}. \quad (2.1.35)$$

证明: 由推论 2.1 的证明知,

$$UB'_G(d_k, \mu_P) = k + \frac{\mu_P - 1}{d_k} + 1.$$

接着，我们计算差值 $UB'_G(d_{k+1}, \mu_P) - UB'_G(d_k, \mu_P)$ ，结果为

$$\begin{aligned} & UB'_G(d_{k+1}, \mu_P) - UB'_G(d_k, \mu_P) \\ &= 1 + \frac{\mu_P - 1}{d_{k+1}} - \frac{\mu_P - 1}{d_k} \\ &= 1 + \frac{\mu_P - 1}{d_k} \left(\frac{d_k}{d_{k+1}} - 1 \right). \end{aligned}$$

显然，最优参数就是满足 $UB'_G(d_{k+1}, \mu_P) - UB'_G(d_k, \mu_P) > 0$ 的第一项 d_k ，于是我们得到条件 (2.1.34)。最后，很容易验证对于所有整数 k ，

$$\frac{2}{5} \leq \frac{d_k}{d_{k+1}} \leq \frac{1}{2},$$

且

$$\lim_{k \rightarrow \infty} \frac{d_k}{d_{k+1}} = \frac{1}{2},$$

从而推出 (2.1.35)。 □

为便于和最优参数（表2.1）作一个对比，我们将由公式 (2.1.34) 计算出的参数列于表2.2。通过计算表明，当 μ_P 较大时，式 (2.1.34) 给出的参数达到的上界非常接近

表 2.2: 根据式 (2.1.34) 计算的参数 ($\mu_P \in [1, 171]$)

μ_P	Optimal l	μ_P	Optimal l
[1.00, 3.00)	1	[20.09, 43.00)	21
[3.00, 4.33)	2	[43.00, 84.02)	42
[4.33, 11.00)	5	[84.02, 171.00)	85
[11.00, 20.09)	10		

于由最优参数达到的最小上界，但当 μ_P 较小时，如 $\mu_P \in [3, 6)$ ，其上界就相对较高。所以，我们考虑采用混合方案，即对于 $\mu_P \geq 6$ 采用准则 (2.1.34)，而对于 $\mu_P < 6$ 采用查找表（表 2.1）。图2.2给出了混合方案与最优方案的性能上界差曲线，作为对比，也同时给出了针对任意分布的准则 (2.1.16) 和最优方案的性能上界差。从图中可以看出，混合方案与最优方案的最大上界差大约仅为 0.093 比特 ($\mu_P \approx 20$ 处)，这说明混合方案的性能是十分不错的。

以上，我们对 Golomb 码在任意概率分布以及任意非递增概率分布下的性能进行了深入的分析，其中由 (2.1.16)、表2.1和 (2.1.34) 给出的参数选择准则对于实际的压缩应用具有重要的指导意义。当然，由 [62] 的 Lemma 1 知道，Golomb 码并不是通用码，所以在下文中，我们将以 Golomb 码为基础构造一类带参数的通用码。

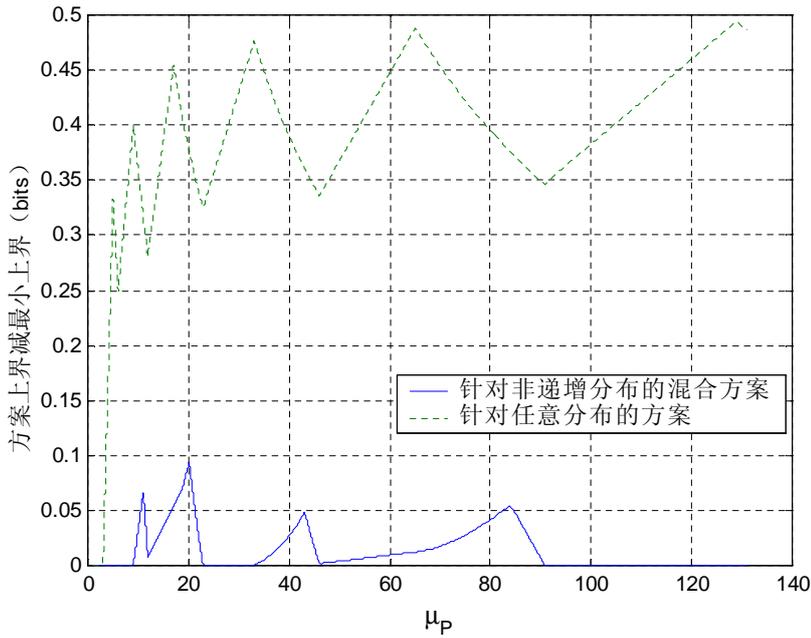


图 2.2: 非递增概率分布下混合方案与最优方案的性能上界差 ($\mu_P \in [1, 131]$)

2.1.4 扩展的 γ 码及其在任意分布下的性能分析

Elias γ 码是 Elias 在文献 [32] 中提出的一类通用码, 本节将以 Golomb 码为基础推广 Elias γ 码。正如第 2.1.2 节中 (2.1.7) 所述, γ 码的一个变种为

$$\gamma(i) = (\Lambda(i))_1[i]_2.$$

可以注意到, γ 码的一个特点就是其码字中包含着一个一元码, 即参数为 1 的 Golomb 码, 所以可以很自然地想到将参数为 1 的 Golomb 码替换为参数为 l 的 Golomb 码, 于是我们有以下扩展的 γ 码:

$$\Gamma_l = \{\gamma_l(i) \mid \gamma_l(i) = g_l(\Lambda(i))[i]_2, i \in \mathbb{Z}^+\}. \quad (2.1.36)$$

例如, 当 $l = 3$ 时, 整数 15 和 16 的编码分别为

$$\gamma_3(15) = g_3(\Lambda(15))[15]_2 = g_3(4) 111 = 10 0 111$$

和

$$\gamma_3(16) = g_3(\Lambda(16))[16]_2 = g_3(5) 0000 = 10 10 0000.$$

扩展 γ 码的一个子类 (即 l 取值为 2 的幂次) 在文献 [5] 中从其他角度被提出过。

我们首先分析扩展 γ 码在任意分布下的性能, 于是有如下定理。

定理 2.3 对于一个给定的信源 S ，定义其取整对数均值为

$$\nu_P \triangleq E_P[\lambda(i)] = \sum_{i \in \mathbb{Z}^+} p(i) \lceil \log i \rceil, \quad (2.1.37)$$

并且 $\nu_P < \infty$ ，则对于任意的 $l \in \mathbb{Z}^+$ 有

$$LB_\Gamma(l, \nu_P) \leq \overline{L_P(\Gamma_l)} \leq UB_\Gamma(l, \nu_P), \quad (2.1.38)$$

式中

$$LB_\Gamma(l, \nu_P) = \left(1 + \frac{1}{l}\right)\nu_P + \lceil \log l \rceil - \frac{2^{\lceil \log l \rceil} - 1}{l} + 1, \quad (2.1.39)$$

$$UB_\Gamma(l, \nu_P) = \left(1 + \frac{1}{l}\right)\nu_P + \lceil \log l \rceil - \frac{2^{\lceil \log l \rceil}}{l} + 2. \quad (2.1.40)$$

下界 $LB_\Gamma(l, \nu_P)$ 在

$$l'_0 = 2^{\lceil \log(\nu_P + 1) \rceil} \quad (2.1.41)$$

处取到最小值，所以对于所有的 $l \in \mathbb{Z}^+$ ，

$$\overline{L_P(\Gamma_l)} \geq LB_\Gamma(l'_0, \nu_P) \geq \nu_P + \log(\nu_P + 1) + \log\left(\frac{e}{\log e}\right). \quad (2.1.42)$$

上界 $UB_\Gamma(l, \nu_P)$ 在

$$l'_1 = 2^{\lceil \log \max\{\nu_P, 1\} \rceil} \quad (2.1.43)$$

处取到最小值，且当 $l = l'_1$ 时，

$$UB_\Gamma(l'_1, \nu_P) \leq \nu_P + \log \max\{\nu_P, 1\} + \min\{\nu_P + 1, 2\}. \quad (2.1.44)$$

证明： 由扩展 γ 码的定义式 (2.1.36) 可以计算得到其码字长度为 $|\gamma_l(i)| = |g_l(\Lambda(i))| + \lambda(i)$ ，所以根据 (2.1.1)，参数为 l 的扩展 γ 码的平均码长为

$$\overline{L_P(\Gamma_l)} = \sum_{i \in \mathbb{Z}^+} p(i) [|g_l(\Lambda(i))| + \lambda(i)] \stackrel{(a)}{=} \nu_P + \sum_{j \in \mathbb{Z}^+} \sum_{\substack{\Lambda(i)=j, \\ i \in \mathbb{Z}^+}} p(i) |g_l(j)| = \nu_P + \overline{L_{P'}(G_l)} \quad (2.1.45)$$

式中概率分布 P' 定义为

$$p'(j) = \sum_{\Lambda(i)=j, i \in \mathbb{Z}^+} p(i),$$

而步骤 (a) 利用了式 (2.1.37) 以及求和式的恒等变换。又因为

$$\mu_{P'} = \sum_{j \in \mathbb{Z}^+} j p'(j) = \sum_{i \in \mathbb{Z}^+} p(i) \Lambda(i) \stackrel{(a)}{=} \nu_P + 1 \quad (2.1.46)$$

式中 (a) 利用了定义式 (2.1.4) 和 (2.1.37)，所以，结合 (2.1.45)，(2.1.46) 和定理 2.1 的结论，就可以依次推出 (2.1.38) ~ (2.1.44)。□

进一步, 如果信源 $S \in \mathcal{S}_{NI}$, 我们有以下的推论。

推论 2.3 如果 $S \in \mathcal{S}_{NI}$, 那么对于任意的 $l \in N^+$ 有

$$\overline{L_P(\Gamma_l)} \leq (1 + \frac{1}{l})H(P) + \lceil \log l \rceil - \frac{2^{\lceil \log l \rceil}}{l} + 2 \quad (2.1.47)$$

而且

$$\overline{L_P(\Gamma_{l_1}')} \leq H(P) + \log \max\{H(P), 1\} + 2 \quad (2.1.48)$$

式中 l_1' 由式 (2.1.43) 定义。

证明: 因为 $S \in \mathcal{S}_{NI}$, 所以由文献 [102] 的 Wyner 不等式知,

$$\nu_P = E_P[\lambda(i)] \leq E_P[\log i] \leq H(P) \quad (2.1.49)$$

由式 (2.1.40), 式 (2.1.44) 和式 (2.1.49) 便可分别推出式 (2.1.47) 和式 (2.1.48)。□

根据式 (2.1.2) 和式 (2.1.47) 可以知道扩展 γ 码是一类通用码, 当 $H(P)$ 趋向于无穷时, 其平均码长大约为 $(1 + 1/l)H(P)$, 因为 $l \geq 1$, 所以其系数可以随 l 在 1 到 2 之间变动。具有类似性质的带参数码有文献 [6] 提出的基于斐波那契 (Fibonacci) 计数系统的编码方案, 以及文献 [100] 和 [105] 提出的基于 Flag 策略的两类编码方案。但是斐波那契码的编解码算法较复杂, 而基于 Flag 策略的码字长度并不是单调不增的, 所以相比这三类方案, 虽然扩展 γ 码不具有自同步的鲁棒 (Robust) 码特性, 但对于一般的数据压缩应用却是首选的方案。

2.1.5 最大熵码

从通用信源编码理论的观点来看, 在我们关于 Golomb 码和扩展 γ 码的性能分析中, 以期望值 μ_P 或者 ν_P 而不是熵来推导其编码性能的上下限是不寻常的。为了解释这一现象, 我们考虑以下问题。

假设有一类定义在参数空间 Θ 上的信源 $\mathcal{S}_\Theta = \{S_\theta : S_\theta = (\mathbb{Z}^+, P_\theta), \theta \in \Theta\}$, 且 $\sup_{\theta \in \Theta} H(P_\theta)$ 有界。现在, 我们要找出这类信源上的最优编码。不同于经典的通用信源编码理论, 我们使用平均码字长度而不是平均冗余作为最优准则。因此最好的码 C_{opt} 就是使

$$SL(C, \mathcal{S}_\Theta) \triangleq \sup_{\theta \in \Theta} \overline{L_{P_\theta}(C)}$$

值最小的码 C 。因此, 对于所有的 $S_\theta \in \mathcal{S}_\Theta$,

$$\overline{L_{P_\theta}(C_{opt})} \leq SL(C_{opt}, \mathcal{S}_\Theta). \quad (2.1.50)$$

所以, $SL(C_{opt}, \mathcal{S}_\Theta) \geq \sup_{\theta \in \Theta} H(P_\theta)$, 即一个码本能达到的最好性能就是 $\sup_{\theta \in \Theta} H(P_\theta)$ 。因此, 我们定义一个码本 C 为最大熵码, 如果它满足

$$SL(C, \mathcal{S}_\Theta) \leq \sup_{\theta \in \Theta} H(P_\theta) + 1. \quad (2.1.51)$$

最大熵码的一个简单例子就是等长度码，它对于所有满足 $P(i) = 0$ ($i > M$) 的信源构成的信源类就是一个最大熵码。因为，对于所有的 $\theta \in \Theta$ ，我们有

$$\overline{L_{P_\theta}(C)} = \lceil \log M \rceil < \log M + 1 = \sup_{\theta \in \Theta} H(P_\theta) + 1.$$

那么，对于一个信源类，其最大熵码是否存在，又有什么特征呢？关于具有线性约束的信源类，我们有以下定理。

引理 2.1 假设有一信源类 \mathcal{S}_M 满足

$$E_P[M_k(i)] = \alpha_k, \quad k = 1, 2, \dots, n \quad (n \geq 1), \quad (2.1.52)$$

式中 $M_k(i)$ ($1 \leq k \leq n$) 为正整数集到实数集的映射，且 α_k ($1 \leq k \leq n$) 为实数。如果存在一个信源 S^* ，其概率分布 P^* 定义为

$$p^*(i) = 2^{\beta_0 + \sum_{k=1}^n \beta_k M_k(i)}, \quad (2.1.53)$$

且满足条件 (2.1.52) 和 $\sum_{i \in \mathbb{Z}^+} p^*(i) = 1$ ，那么 $S^* = (\mathbb{Z}^+, P^*)$ 就是 \mathcal{S}_M 的信源中使熵 $H(P)$ 最大化的信源，且对于所有信源 $S = (\mathbb{Z}^+, P) \in \mathcal{S}_M$ ，

$$H(P) + D(P||P^*) = H(P^*) = \sup_{S \in \mathcal{S}_M} H(P), \quad (2.1.54)$$

式中 $D(\cdot||\cdot)$ 为散度 (Divergence)。

证明： 由熵和散度的定义，我们有

$$H(P) + D(P||P^*) = - \sum_{i \in \mathbb{Z}^+} p(i) \log p^*(i) \stackrel{(a)}{=} -\beta_0 - \sum_{k=1}^n \beta_k \alpha_k \triangleq H_0,$$

式中 (a) 利用了条件 (2.1.52) 和 (2.1.53)。因为， $D(P||P^*) \geq 0$ ，当且仅当 $P = P^*$ 时取等号，所以，对于所有信源 $S = (\mathbb{Z}^+, P) \in \mathcal{S}_M$ ，

$$H(P) \leq H_0,$$

当且仅当 $P = P^*$ 时取等号，即 $H_0 = H(P^*)$ 。 \square

引理2.1本质上是 [24] 中定理 11.1.1 的离散化版本。由引理2.1，我们立刻推出最大熵码的存在性定理。

定理 2.4 对于一个满足条件 (2.1.52) 的信源类 \mathcal{S}_M ，如果存在一个信源 $S^* \in \mathcal{S}_M$ ，其概率分布 P^* 由 (2.1.53) 定义，令 $C^* = \{c_i^* \in \mathbb{B}^* : i \in \mathbb{Z}^+\}$ 为概率分布 P^* 下的前缀 Shannon 码，其码字长度定义为

$$|c_i^*| = \lceil -\log p^*(i) \rceil.$$

于是，对于所有信源 $S = (\mathbb{Z}^+, P) \in \mathcal{S}_M$ ，我们有

$$\sup_{S \in \mathcal{S}_M} H(P) \leq \overline{L_P(C^*)} < \sup_{S \in \mathcal{S}_M} H(P) + 1.$$

证明： 显然，由码字长度的定义可以推出

$$-\log p^*(i) \leq |c_i^*| < -\log p^*(i) + 1,$$

代入平均码字长度的定义式，并利用恒等式 (2.1.54)，即可得证。 \square

应用引理2.1的思想，我们可以证明 Golomb 码和扩展 Gamma 码都是某类信源下的最大熵码。为此，我们首先需要证明两个关于最大熵的引理。

引理 2.2 ([24], Lemma 12.10.2) 定义信源类 \mathcal{S}_{μ_0} 为满足 $E_P[i] = \mu_0$ 的所有信源 S ，则

$$\sup_{S \in \mathcal{S}_{\mu_0}} H(P) = H(P_{\mu_0}^*) = \mu_0 \log \mu_0 - (\mu_0 - 1) \log(\mu_0 - 1),^1 \quad (2.1.55)$$

式中信源 $S_{\mu_0}^* = (\mathbb{Z}^+, P_{\mu_0}^*)$ 定义为

$$p_{\mu_0}^*(i) = (1 - \theta_0)\theta_0^{i-1}, \quad (2.1.56)$$

其中

$$\theta_0 = \frac{\mu_0 - 1}{\mu_0}. \quad (2.1.57)$$

证明： 根据引理2.1中的 (2.1.53)，我们定义信源 $S_{\mu_0}^*$ 的概率分布为

$$p_{\mu_0}^*(i) = 2^{\beta_0 + \beta_1 i},$$

令 $\theta_0 = 2^{\beta_1}$ ，并结合条件 $\sum_{i \in \mathbb{Z}^+} p_{\mu_0}^*(i) = 1$ ，上式可以化为

$$p_{\mu_0}^*(i) = (1 - \theta_0)\theta_0^{i-1}.$$

因而其均值为

$$E_{P_{\mu_0}^*}[i] = \frac{1}{1 - \theta_0},$$

结合条件 $E_P[i] = \mu_0$ ，即可推出 (2.1.57)。最后，我们来验证 (2.1.55)。

$$\begin{aligned} H(P_{\mu_0}^*) &= -E_{P_{\mu_0}^*}[\log p_{\mu_0}^*(i)] \\ &= -E_{P_{\mu_0}^*}[\log(1 - \theta_0) + (i - 1) \log \theta_0] \\ &\stackrel{(a)}{=} \log \mu_0 - (\mu_0 - 1) \log \frac{\mu_0 - 1}{\mu_0} \\ &= \mu_0 \log \mu_0 - (\mu_0 - 1) \log(\mu_0 - 1), \end{aligned}$$

式中 (a) 利用了等式 (2.1.57)。 \square

¹[24] 中的结果与本文略有出入，它是错的，根据其结果，其概率分布应该定义在非负整数上，而不是正整数。

引理 2.3 定义信源类 \mathcal{S}_{ν_0} 为满足 $E_P[\lceil \log i \rceil] = \nu_0$ 的所有信源 S , 则

$$\sup_{S \in \mathcal{S}_{\nu_0}} H(P) = H(P_{\nu_0}^*) = \nu_0 + (\nu_0 + 1) \log(\nu_0 + 1) - \nu_0 \log \nu_0, \quad (2.1.58)$$

式中信源 $S_{\nu_0}^* = (\mathbb{Z}^+, P_{\nu_0}^*)$ 定义为

$$p_{\nu_0}^*(i) = (1 - 2\iota_1)\iota_1^{\lceil \log i \rceil}, \quad (2.1.59)$$

其中

$$\iota_1 = \frac{\nu_0}{2(\nu_0 + 1)}. \quad (2.1.60)$$

证明: 根据引理2.1中的 (2.1.53), 我们定义信源 $S_{\nu_0}^*$ 的概率分布为

$$p_{\nu_0}^*(i) = 2^{\beta_0 + \beta_1 \lceil \log i \rceil} = \iota_0 \iota_1^{\lceil \log i \rceil},$$

式中 $\iota_0 = 2^{\beta_0}$, $\iota_1 = 2^{\beta_1}$ 。为消去未知数 ι_0 , 考虑概率归一化条件

$$\sum_{i \in \mathbb{Z}^+} \iota_0 \iota_1^{\lceil \log i \rceil} = 1.$$

然后对上式左边进行变形。

$$\begin{aligned} \sum_{i \in \mathbb{Z}^+} \iota_0 \iota_1^{\lceil \log i \rceil} &= \iota_0 \sum_{j \in \mathbb{N}} \sum_{\substack{\lceil \log i \rceil = j, \\ i \in \mathbb{Z}^+}} \iota_1^{\lceil \log i \rceil} \\ &= \iota_0 \sum_{j \in \mathbb{N}} (2\iota_1)^j \\ &= \frac{\iota_0}{1 - 2\iota_1}. \end{aligned}$$

因此 $\iota_0 = 1 - 2\iota_1$, 即 $p_{\nu_0}^*(i) = (1 - 2\iota_1)\iota_1^{\lceil \log i \rceil}$ 。接下来, 我们计算 $E_{P_{\nu_0}^*}[\lceil \log i \rceil]$ 。

$$\begin{aligned} \sum_{i \in \mathbb{Z}^+} p_{\nu_0}^*(i) \lceil \log i \rceil &= (1 - 2\iota_1) \sum_{i \in \mathbb{Z}^+} \iota_1^{\lceil \log i \rceil} \lceil \log i \rceil \\ &= (1 - 2\iota_1) \sum_{j \in \mathbb{N}} \sum_{\substack{\lceil \log i \rceil = j, \\ i \in \mathbb{Z}^+}} \iota_1^{\lceil \log i \rceil} \lceil \log i \rceil \\ &= (1 - 2\iota_1) \sum_{j \in \mathbb{N}} j (2\iota_1)^j \\ &= \frac{2\iota_1}{1 - 2\iota_1}. \end{aligned}$$

因此由方程

$$\frac{2\iota_1}{1 - 2\iota_1} = \nu_0$$

即可求出 (2.1.60)。最后，我们来验证 (2.1.55)。

$$\begin{aligned}
 H(P_{\nu_0}^*) &= -E_{P_{\nu_0}^*}[\log p_{\nu_0}^*(i)] \\
 &= -E_{P_{\nu_0}^*}[\log(1 - 2\iota_1) + [\log i] \log \iota_1] \\
 &\stackrel{(a)}{=} \log(\nu_0 + 1) - \nu_0 \log \frac{\nu_0}{2(\nu_0 + 1)} \\
 &= \nu_0 + (\nu_0 + 1) \log(\nu_0 + 1) - \nu_0 \log \nu_0,
 \end{aligned}$$

式中 (a) 利用了等式 (2.1.60)。 \square

依靠上述两个引理，我们将证明 Golomb 码和扩展 γ 码分别是信源类 \mathcal{S}_{μ_0} 和 \mathcal{S}_{ν_0} 上的最大熵码。

定理 2.5 对于所有的信源 $S \in \mathcal{S}_{\mu_0}$,

$$\overline{L_P(G_{l_1})} \leq \sup_{S \in \mathcal{S}_{\mu_0}} H(P) + 1, \quad (2.1.61)$$

式中 l_1 由 (2.1.16) 定义。

证明： 若 $1 \leq \mu_0 < 2$ ，则由 (2.1.17) 有

$$\begin{aligned}
 \overline{L_P(G_{l_1})} &\leq \mu_0 \\
 &\stackrel{(a)}{\leq} \log \mu_0 + 1 \\
 &\stackrel{(b)}{\leq} \log \mu_0 + (\mu_0 - 1) \log \frac{\mu_0}{\mu_0 - 1} + 1 \\
 &\stackrel{(c)}{=} \sup_{S \in \mathcal{S}_{\mu_0}} H(P) + 1,
 \end{aligned}$$

式中 (a) 利用了函数 $\log \mu_0$ 的凹函数特性和 Jensen 不等式，(b) 利用了函数 $(\mu_0 - 1) \log[\mu_0/(\mu_0 - 1)]$ 当 $\mu_0 \geq 1$ 时的非负特性，(c) 利用了引理 2.2。

若 $\mu_0 \geq 2$ ，则由 (2.1.17) 有

$$\begin{aligned}
 \overline{L_P(G_{l_1})} &\leq \log(\mu_0 - 1) + 2 \\
 &< \log \mu_0 + 2 \\
 &\stackrel{(a)}{\leq} \log \mu_0 + (\mu_0 - 1) \log \frac{\mu_0}{\mu_0 - 1} + 1 \\
 &\stackrel{(b)}{=} \sup_{S \in \mathcal{S}_{\mu_0}} H(P) + 1,
 \end{aligned}$$

式中 (a) 利用了函数 $(\mu_0 - 1) \log[\mu_0/(\mu_0 - 1)]$ 当 $\mu_0 \geq 2$ 时单调递增的特性。(b) 利用了引理 2.2。 \square

定理 2.6 对于所有的信源 $S \in \mathcal{S}_{\nu_0}$,

$$\overline{L_P(\Gamma_{l'_1})} \leq \sup_{S \in \mathcal{S}_{\nu_0}} H(P) + 1, \quad (2.1.62)$$

式中 l'_1 由 (2.1.43) 定义。

证明：若 $0 \leq \nu_0 < 1$ ，则由 (2.1.44) 有

$$\begin{aligned} \overline{L_P(\Gamma_{l_1}')} &\leq 2\nu_0 + 1 \\ &\stackrel{(a)}{\leq} \nu_0 + \log(\nu_0 + 1) + 1 \\ &\stackrel{(b)}{\leq} \nu_0 + \log(\nu_0 + 1) + \nu_0 \log \frac{\nu_0 + 1}{\nu_0} + 1 \\ &\stackrel{(c)}{=} \sup_{S \in \mathcal{S}_{\nu_0}} H(P) + 1, \end{aligned}$$

式中 (a) 利用了函数 $\log(\nu_0 + 1)$ 的凹函数特性和 Jensen 不等式，(b) 利用了函数 $\nu_0 \log[(\nu_0 + 1)/\nu_0]$ 当 $\nu_0 \geq 0$ 时的非负特性，(c) 利用了引理 2.3。

若 $\nu_0 \geq 1$ ，则由 (2.1.44) 有

$$\begin{aligned} \overline{L_P(\Gamma_{l_1}')} &\leq \nu_0 + \log \nu_0 + 2 \\ &< \nu_0 + \log(\nu_0 + 1) + 2 \\ &\stackrel{(a)}{\leq} \nu_0 + \log(\nu_0 + 1) + \nu_0 \log \frac{\nu_0 + 1}{\nu_0} + 1 \\ &\stackrel{(b)}{=} \sup_{S \in \mathcal{S}_{\nu_0}} H(P) + 1, \end{aligned}$$

式中 (a) 利用了函数 $\nu_0 \log[(\nu_0 + 1)/\nu_0]$ 当 $\nu_0 \geq 1$ 时单调递增的特性。(b) 利用了引理 2.3。□

2.1.6 一个低复杂性的通用数据压缩框架

我们以 Golomb 码和扩展 γ 码为基础，给出一个低复杂性的基于整数编码的通用数据压缩框架，这是一个两阶段的框架系统（如图 2.3）。首先，对数据进行预处理，

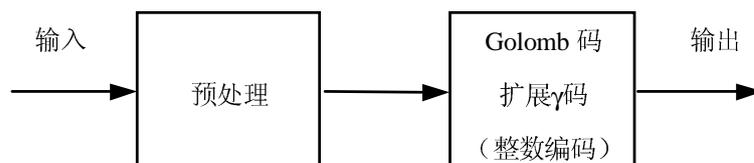


图 2.3: 基于整数编码的通用数据压缩框架

其目的就是将不同的数据类型都变换为一个以正整数为字符集而概率分布为近似递减的信源。因此，对于不同的数据类型会采用不同的预处理技术，如声音、图形等的连续信号数据，可以采用预测技术将信号变换为误差信号，再通过由整数到正整数的一个变换，就可以得到概率分布近似递减的信源（如文献 [101]），又如一般的文本数据，可以采用 Burrows-Wheeler 变换 (BWT) [16] 和 Move-to-Front (MTF) 变换 [12] 对数据进行处理，也可以得到概率分布近似递减的信源。然后，将预处理后的数据编码为 Golomb 码或扩展 γ 码，其参数的选择由 μ_P 或 ν_P 来确定。在具体实现中，这两个统

计值可以用逐个样本的自适应模式去估计，也可以用逐块样本的非自适应模式去计算，然后将参数写在每块数据的头部。

我们以此框架为基础，通过在预处理阶段采用 MTF 变换，构建了一个简单的通用数据压缩样例系统，以此说明 Golomb 码和 γ 码的实际应用价值。关于 MTF 变换的原理与细节见第 2.3.3 节，简而言之就是通过自适应的方式对各字符进行重新排列，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 [12, 76] 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。

我们首先测试了非自适应方式下 Golomb 码和 γ 码的性能。对于 MTF 变换后的数据，我们计算其全局的 μ_P 或 ν_P ，然后根据 (2.1.16) 或 (2.1.43) 确定最优的编码参数，并将参数值以参数为 1 的 Golomb 码编码在文件头部（因为这个参数只占用了几个比特，所以在下文的实验数据中忽略不计），最后用选择的参数对数据进行 Golomb 编码或扩展 γ 编码。我们对 Calgary Corpus 数据测试集进行了实验，表 2.3 和表 2.4 分别列出了各个文件的一阶熵、 μ_P 、 ν_P 、最优参数、性能上下界、Golomb 码和扩展 γ 码的实际平均码长等。从表 2.3 和表 2.4 可以看到，Golomb 码的平均性能只比一阶熵

表 2.3: 采用 Golomb 码方案的压缩结果（码长单位：bits/symbol）

文件	一阶熵	μ_P	最优参数	性能下界	性能上界	实际平均码长
bib	5.201	19.797	16	5.237	6.175	5.739
book1	4.527	12.715	8	4.589	5.464	5.038
book2	4.793	13.193	8	4.649	5.524	5.098
geo	5.646	47.796	32	6.494	7.462	7.168
news	5.190	17.011	16	5.063	6.001	5.606
obj1	5.948	33.996	32	6.062	7.031	6.720
obj2	6.260	29.585	16	5.849	6.787	6.360
paper1	4.983	14.797	8	4.850	5.725	5.303
paper2	4.601	12.998	8	4.625	5.500	5.071
pic	1.210	3.163	2	2.582	3.082	3.042
progc	5.199	17.392	16	5.087	6.025	5.636
progl	4.770	12.242	8	4.530	5.405	5.040
progp	4.869	14.614	8	4.827	5.702	5.329
trans	5.533	17.387	16	5.087	6.024	5.630
平均	4.909			4.966	5.850	5.484

高了 11.7%，而扩展 γ 码的性能要差一些，比一阶熵高 22.9%，主要原因是测试数据 MTF 变换后的概率分布并非严格递减的，特别是取值为 1 的概率几乎为 0（除了文件 pic，其他文件较少存在长串的不同字符），同时 ν_P 也不够大，无法体现扩展 γ 码的渐近最优的性能。相比算术编码和自适应霍夫曼编码的复杂性，显然，Golomb 码和

表 2.4: 采用扩展 γ 码方案的压缩结果 (码长单位: bits/symbol)

文件	一阶熵	ν_P	最优参数	性能下界	性能上界	实际平均码长
bib	5.201	3.328	2	6.492	6.992	6.701
book1	4.527	2.853	2	5.780	6.280	6.056
book2	4.793	2.874	2	5.811	6.311	6.074
geo	5.646	3.697	2	7.046	7.546	7.384
news	5.190	3.040	2	6.060	6.560	6.335
obj1	5.948	3.101	2	6.152	6.652	6.430
obj2	6.260	3.567	2	6.851	7.351	7.103
paper1	4.983	2.973	2	5.960	6.460	6.221
paper2	4.601	2.880	2	5.820	6.320	6.090
pic	1.210	0.429	1	1.858	1.858	1.857
progc	5.199	3.051	2	6.077	6.577	6.353
progl	4.770	2.582	2	5.373	5.873	5.667
progp	4.869	2.745	2	5.618	6.118	5.915
trans	5.533	3.004	2	6.006	6.506	6.262

扩展 γ 码在对于实时性能有较高要求的应用中具有相对较强的竞争力。进一步, 如果 Golomb 码和扩展 γ 码以自适应的方式工作, 那么压缩性能还可以进一步提高。压缩结果见表2.5。

如果结合 BWT 技术, 压缩的性能还可以大幅度提升, 关于具体的算法设计将在下文中介紹。

2.2 一组整数的实用编码技术

整数编码非常适合于某些具有低复杂性要求且字符集庞大的数据压缩应用。因为在实际中, 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些的损失, 尤其是在一些应用中, 由于整数序列的熵并不是很高, 许多渐近最优的整数码的实际性能反而很差。这一问题在第2.1.4节中得到了一定的解决, 我们的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 ν_P (定义 (2.1.37)) 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, 因此对于接近于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。目前, 该问题的研究还较少, 仅有理论方面的一点工作 [40, 79]。

表 2.5: 自适应方式下 Golomb 码和扩展 γ 码方案的压缩结果

文件	一阶熵	Golomb 码平均码长	扩展 γ 码平均码长
bib	5.201	5.733	6.589
book1	4.527	5.000	5.853
book2	4.793	5.061	5.912
geo	5.646	7.148	6.533
news	5.190	5.438	6.173
obj1	5.948	6.082	6.122
obj2	6.260	6.284	6.842
paper1	4.983	5.250	6.067
paper2	4.601	5.030	5.931
pic	1.210	2.170	1.746
progc	5.199	5.545	6.205
progl	4.770	4.972	5.534
progp	4.869	5.261	5.740
trans	5.533	5.498	6.183
平均	4.909	5.319	5.816

所以，有必要考虑一组整数的实用编码问题。

2.2.1 二进制序列的编码

文献 [40] 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 $\alpha^n = \alpha_1\alpha_2\cdots\alpha_n$ ，首先考虑将其转换为一个正整数序列。定义变换 $\text{BTN}_n: \mathbb{B}^n \rightarrow (\mathbb{B}, \mathbb{Z}^{+*})$ 为 $\alpha^n \mapsto (b, \beta)$ ，具体算法如下。

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

$$b = u(n_1 - n_0), \quad (2.2.1)$$

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，

$$\beta = U^{-1}(\alpha') \quad (2.2.2)$$

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

数，即一元码的解码函数，而 α' 定义为

$$\alpha' = \begin{cases} \overline{\alpha^n} & b = 0, \alpha_n = 1 & (2.2.3a) \\ \overline{\alpha^n 0} & b = 0, \alpha_n = 0 & (2.2.3b) \\ \alpha^n & b = 1, \alpha_n = 0 & (2.2.3c) \\ \alpha^n 0 & b = 1, \alpha_n = 1 & (2.2.3d) \end{cases}$$

可以注意到正整数序列的长度 $|\beta|$ 与总和 s_β 分别为

$$|\beta| = n_{\overline{b}} + \overline{b \oplus \alpha_n}, \quad (2.2.4)$$

$$s_\beta = n_b + |\beta| = n + \overline{b \oplus \alpha_n}, \quad (2.2.5)$$

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

$$\text{BTN}_n^{-1}(b, \beta) = \begin{cases} (\overline{U(\beta)})_1^n, & b = 0 & (2.2.6a) \\ (U(\beta))_1^n, & b = 1 & (2.2.6b) \end{cases}$$

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 (one-sided geometric distributions, OSGDs) 的规律，由文献 [45, 48] 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 (参见第 2.1.3 节)。当然，文献 [45] 中的最优参数准则过于复杂，故考虑采用定理 2.1 中的最优准则 (2.1.16)。由于 (2.1.16) 给出的最优值都是 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^[82]。记参数为 $k \in \mathbb{N}$ 的 Rice 码为

$$R_k = \{r_k(i) : r_k(i) = \left(\left\lfloor \frac{i-1}{2^k} \right\rfloor + 1 \right)_1 B_{2^k}((i-1) \bmod 2^k), i \in \mathbb{Z}^+\}, \quad (2.2.7)$$

其最优参数准则为

$$k_1 = \lfloor \log \max\{\mu_P - 1, 1\} \rfloor. \quad (2.2.8)$$

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 $\text{FloorLog} : (\mathbb{N}, \mathbb{Z}^+) \rightarrow \mathbb{N}$ 为

$$\text{FloorLog}(s, n) = \left\lfloor \log \max\left\{\frac{s}{n}, 1\right\} \right\rfloor \quad (2.2.9)$$

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 (2.2.4) 和 (2.2.5) 知, 其最优参数为

$$k_\beta = \text{FloorLog}(s_\beta - |\beta|, |\beta|) = \text{FloorLog}(n_b, n_{\bar{b}} + \overline{b \oplus \alpha_n}). \quad (2.2.10)$$

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:

$$\text{BTB}_n(\alpha^n) = \begin{cases} (k_\beta + 1)_1 \alpha^n, & k_\beta = 0 \\ (k_\beta + 1)_1 \text{NTB}_{k_\beta}(\text{BTN}_n(\alpha^n)), & k_\beta > 0 \end{cases} \quad (2.2.11a)$$

$$(2.2.11b)$$

式中, 函数 $\text{NTB}_k : (\mathbb{B}, \mathbb{Z}^{+*}) \rightarrow \mathbb{B}^*$ 定义为

$$\text{NTB}_k(b, \beta) = br_k(\beta_1)r_k(\beta_2) \cdots r_k(\beta_{|\beta|}). \quad (2.2.12)$$

我们举一个实例来说明编码的具体过程。设序列

$$\alpha^n = 00010\ 00000\ 10000\ 00010,$$

所以, 序列长度 $n = 20$, 序列中 0 和 1 的个数分别为

$$n_0 = 17, \quad n_1 = 3.$$

于是编码过程如下。首先, 由 (2.2.1) 知

$$b = u(n_1 - n_0) = u(-14) = 0,$$

接着, 由 (2.2.3) 有

$$\alpha' = \overline{\alpha^n}0 = 11101\ 11111\ 01111\ 11101\ 0,$$

所以, 由 (2.2.2) 有

$$\beta = U^{-1}(\alpha') = U^{-1}(1110\ 1111110\ 11111110\ 10) = 4\ 7\ 8\ 2,$$

并且

$$s_\beta = 21, \quad |\beta| = 4.$$

然后根据 (2.2.8) 计算 Rice 码的参数

$$k_\beta = \left\lceil \log \max\left\{\frac{21}{4} - 1, 1\right\} \right\rceil = 2.$$

最后, 根据 (2.2.11), 我们有

$$\text{BTB}_n(\alpha^n) = (2 + 1)_1\ 0\ r_2(4)r_2(7)r_2(8)r_2(2) = 110\ 0\ 011\ 1010\ 1011\ 001.$$

可以注意到, 输出码字的头 4 个比特是表征参数 k_β 和 b 的, 当序列较短时, 这是一笔不小的开销, 但当序列较长时, 这一开销就可以忽略不计了。

2.2.2 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。第2.1.3节和第2.1.4节分别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四个实用编码算法。设一个 n 长的正整数序列为 $x^n = x_1x_2 \cdots x_n$ ，则一组整数的编码就是一个从 \mathbb{Z}^{+n} 到 \mathbb{B}^* 的映射，于是本节的四种编码分别记为函数 BR_n 、 BRE_n 、 BG_n 和 BGE_n 。

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 长正整数序列的 Rice 编码。与上节类似，其编码为

$$(k+1)_1 r_k(x_1) r_k(x_2) \cdots r_k(x_n), \quad (2.2.13)$$

式中参数 k 由 (2.2.8) 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块，而后将所有的分组码也放在一块，于是 (2.2.13) 中的码字就变换为

$$(k+1)_1 (y_1)_1 (y_2)_1 \cdots (y_n)_1 B_{2^k}(z_1) B_{2^k}(z_2) \cdots B_{2^k}(z_n), \quad (2.2.14)$$

式中

$$y_i = \left\lfloor \frac{x_i - 1}{2^k} \right\rfloor + 1, \quad z_i = (x_i - 1) \bmod 2^k. \quad (2.2.15)$$

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

$$\delta^n = u(y_1 - 2)u(y_2 - 2) \cdots u(y_n - 2). \quad (2.2.16)$$

同时，可以将整数序列 $y^n = y_1y_2 \cdots y_n$ 中大于 1 的整数减去 1 组成一个新的整数序列 $\zeta^{n'} = \zeta_1\zeta_2 \cdots \zeta_{n'}$ ($n' = \sum_{i=1}^n \delta_i$)。于是新的编码为

$$\text{BR}_n(x^n) = (k+1)_1 \text{BTB}_n(\delta^n) (\zeta_1)_1 (\zeta_2)_1 \cdots (\zeta_{n'})_1 B_{2^k}(z_1) B_{2^k}(z_2) \cdots B_{2^k}(z_n), \quad (2.2.17)$$

这就是 BR_n 码。

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 $B_{2^k}(z_i)$ 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：

$$\eta(j)^n = \eta(j)_1 \eta(j)_2 \cdots \eta(j)_n, \quad \eta(j)_i = \left\lfloor \frac{B_{2^k}(z_i)}{2^j} \right\rfloor \bmod 2. \quad (2.2.18)$$

于是， BRE_n 码为

$$\text{BRE}_n(x^n) = (k+1)_1 \text{BTB}_n(\delta^n) (\zeta_1)_1 \cdots (\zeta_{n'})_1 \text{BTB}_n(\eta(0)^n) \cdots \text{BTB}_n(\eta(k-1)^n). \quad (2.2.19)$$

BG_n 码和 BGE_n 码

类似于 BR_n 码和 BRE_n 码，也可以从扩展 γ 码相应地构造出 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

$$\text{BG}_n(x^n) = \text{BR}_n(\Lambda(x_1)\Lambda(x_2)\cdots\Lambda(x_n))[x_1]_2[x_2]_2\cdots[x_n]_2 \quad (2.2.20)$$

和

$$\text{BGE}_n(x^n) = \text{BRE}_n(\Lambda(x_1)\Lambda(x_2)\cdots\Lambda(x_n))[x_1]_2[x_2]_2\cdots[x_n]_2. \quad (2.2.21)$$

关于性能

以上，我们给出了一组整数的四种编码方案，当 n 较大时，这四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，故在下文中，笔者将在基于 Burrows-Wheeler 变换的通用数据压缩算法设计中应用这些编码方案，以考察其实际的性能。

2.3 基于 BWT 和整数编码的通用数据压缩算法的设计

2.3.1 介绍

Burrows-Wheeler 变换是 Burrows 和 Wheeler 于 1994 年提出的一种略微扩展的可逆序列变换^[16]，目前在实际的无损数据压缩技术中倍受关注。使用这一变换的算法的实验结果表明，该算法虽然比部分匹配预测 (Prediction by Partial Matching, PPM) 类压缩算法^[20, 75] 性能略差，但其压缩性能要高于 Ziv-Lempel 类压缩算法 (LZ'77^[109]，

LZ78^[110]), 同时, 其算法实现复杂性与 LZ 类算法相当, 运行速度要比 PPM 类算法快好多。表2.6 列出了几种常见压缩算法在 Calgary Corpus 数据测试集下的平均压缩性能, 其中 gzip 在算法原理和性能上与 Windows 下的常用软件 Winzip 类似。

表 2.6: 常用压缩算法的性能比较 (Calgary Corpus 数据)

压缩算法	平均压缩性能 (单位: bits/symbol)
GZIP [66] (LZ 类)	2.697
PPMZ2 [15] (PPM 类)	2.086
BZIP2 [88] (BWT 类)	2.368

BWT 本身并不对数据进行压缩, 它通过排序的方法将具有相似上下文 (Context) 的字符聚合在一块, 从而便于后续的压缩技术对数据进行压缩。目前大多数基于 BWT 的数据压缩算法都可以归结为如图2.4的系统。

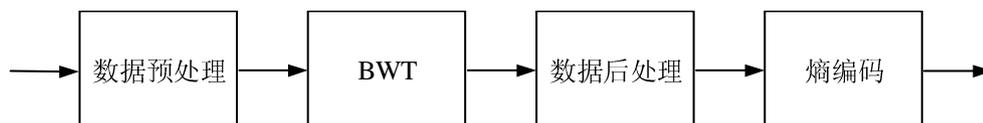


图 2.4: 基于 BWT 的数据压缩算法的一般结构

数据预处理的主要目的是使 BWT 能更有效地将具有相似上下文的字符或词聚合在一块。例如, 通过调整字符集中的字符顺序来提高压缩性能 (如 [19]), 还可以先将数据 (特别是文本数据) 解析 (Parse) 为词, 然后对词使用 BWT (如 [55])。在较老的算法中, 还常常在数据预处理中预先对数据进行简单压缩, 其主要目的是为了缩短 BWT 的时间, 现在 BWT 算法已经发展到较快的水平, 所以这些处理就没有必要再使用了。数据后处理的主要目的是对 BWT 生成的数据进行变换, 以便于后面的熵编码器对数据进行压缩。由于 BWT 生成的数据序列并非平稳序列, 所以这一模块的设计对于整个算法的性能起决定性的作用。

纵观这近十年的 BWT 压缩算法的研究进展, 大部分的研究主要集中在以下两个方面: (1) BWT 快速算法的设计; (2) 数据后处理算法的设计。下面, 我们将分别讨论这两个问题。

2.3.2 BWT 的原理与快速算法的设计

首先, 我们介绍 BWT 的基本原理。设字符串的字符集为 \mathcal{A} , 则长度为 n 的所有字符串组成的集合记为序列空间 \mathcal{A}^n , 而序列空间 \mathcal{A}^n 中的某一序列记为 $x^n = x_1x_2 \cdots x_n$ 。我们将 n 维的 BWT 正变换记为

$$\text{BWT}_n : \mathcal{A}^n \rightarrow \mathcal{A}^n \times \{1, 2, \dots, n\}, \quad (2.3.1)$$

而将其反变换记为

$$\text{IBWT}_n : \mathcal{A}^n \times \{1, 2, \dots, n\} \rightarrow \mathcal{A}^n. \quad (2.3.2)$$

由于通过其作用参数的序列可以明显地表示出 BWT 和 IBWT 的作用序列长度，所以我们也常常省略下标 n ，而使用如下简化的形式：

$$(y^n, a) = \text{BWT}(x^n), \quad x^n = \text{IBWT}(y^n, a).$$

式中 $x^n, y^n \in \mathcal{A}^n$, $a \in \{1, 2, \dots, n\}$ 。

BWT 正变换的基本原理为：

- (1) 对于 $x^n \in \mathcal{A}^n$ ，形成 x^n 的所有循环移位序列（包括 x^n ）；
- (2) 对所有这些序列按字符集上预先定义的词典序进行排序；
- (3) 按排序后的顺序输出每个序列的最后一个字符，从而形成 x^n 的一个置换，即 y^n ，同时输出排序后 x^n 所属行的序号，即 a 。

与此相反，BWT 反变换的基本原理就是以序列 y^n 为基础，利用其后续字符（即首字符序列）在字符阵列中按词典序排列的特性，重构由所有 x^n 的循环移位序列按词典序排列的字符阵列，然后根据序号 a ，读出原始序列 x^n 。原理上，字符阵列的重构算法可以分为 $n - 1$ 步，对于第 i 步，需要做如下事情：

- (1) 将第 n 列（即 y^n ）置于第 1 至 $i - 1$ 列之前；
- (2) 将上述 n 个 i 长的序列按词典序进行排序；
- (3) 将排好序的列表至于字符阵列的第 1 至 i 列。

此处，我们介绍的 BWT 是 Burrows 和 Wheeler 提出的原始变换，在后来的研究中，有的研究者采用了某些变种算法，主要是用一个特殊的结尾字符加在序列的结尾，从而将序列的循环移位消解为简单移位序列，由于这种处理对于最终的压缩性能几乎没有什么影响，所以我们还是选择介绍更具对称性的原始算法。为了更好地理解其基本原理，让我们来看一个简单的例子（见表 2.7 和表 2.8），其中以序列 bananas 为例。由表 2.7 和表 2.8 可以看出 $\text{BWT}(\text{bananas}) = (\text{bnnsaaa}, 4)$ 和

表 2.7: BWT 正变换的实例 ($x^n = \text{bananas}$)

	第 1 步	第 2 步	第 3 步
1	b a n a n a s	a n a n a s b	b
2	s b a n a n a	a n a s b a n	n
3	a s b a n a n	a s b a n a n	n
4	n a s b a n a	b a n a n a s	s
5	a n a s b a n	n a n a s b a	a
6	n a n a s b a	n a s b a n a	a
7	a n a n a s b	s b a n a n a	a

$\text{IBWT}(\text{bnnsaaa}, 4) = \text{bananas}$ 。

表 2.8: BWT 反变换的实例 ($y^n = \text{bnmsaaa}, a = 4$)

	第 1 步			第 2 步			第 3 步			...	第 6 步	
	1	2	3	4	5	6	7	8	9	...	16	17
1	b	a	a ... b	ba	an	an ... b	ban	ana	ana ... b	...	banana	ananas
2	n	a	a ... n	na	an	an ... n	nan	ana	ana ... n	...	nanasb	anasba
3	n	a	a ... n	na	as	as ... n	nas	asb	asb ... n	...	nasban	asbana
4	s	b	b ... s	sb	ba	ba ... s	sba	ban	ban ... s	...	sbanan	banana
5	a	n	n ... a	an	na	na ... a	ana	nan	nan ... a	...	ananas	nanasb
6	a	n	n ... a	an	na	na ... a	ana	nas	nas ... a	...	anasba	nasban
7	a	s	s ... a	as	sb	sb ... a	asb	sba	sba ... a	...	asbana	sbanan

上述算法只是 BWT 的基本原理，在实际中是根本不可行的，因此，需要设计快速 BWT 算法，同时必须具有较低的内存开销。BWT 反变换快速算法的设计较为容易，目前使用的 BWT 反变换算法大同小异，都是源于 [16] 中的原始算法，其时间复杂度为 $O(n + c|\mathcal{A}|)$ (c 为常数， $|\mathcal{A}|$ 表示集合 \mathcal{A} 的基数)。

BWT 正变换的快速算法可就不那么容易设计了，关键在于如何设计一个有效的排序算法对所有的循环移位序列按词典序进行排序，在计算机科学中，这称为后缀排序 (Suffix Sorting) 算法。为了说明该类算法设计的困难，我们先考察一种非常简单的排序算法，即整体上对所有序列进行常用的快速排序算法，而每两个序列的比较采用逐个字符比较法。若我们假设每一对序列的平均比较次数与 n 成正比，则整个算法的时间复杂度为 $O(n^2 \ln n)$ 。显然，这种算法的时间复杂度过高，还无法达到实用的标准。目前，实用的快速后缀排序算法大体可以分为三类。

第一类算法称为直接比较算法 (Direct-Comparison Algorithm)，如 [56, 69, 89]。其基本原理就是我们在上文中提到的简单排序算法，但通常采用 Bentley 和 Sedgewick 的三元快速排序 (Ternary QuickSort) 算法^[11]。虽然这种算法在最坏的情形下会达到 $O(n^2 \ln n)$ 的时间复杂度，但由于实际中，许多数据文件的平均匹配长度 (Average Match Length, AML) 都较短，所以这类算法在这些数据上往往会表现出较高的性能。当然，还需要采取一系列的小技巧来克服某些较坏的情形，同时利用后缀排序的特点进一步降低排序时间。目前，这类算法的内存开销大约为 $5n$ 字节^[69]。

第二类算法称为后缀树 (Suffix Tree) 排序算法，如 [35, 61, 70]。这一类算法的时间复杂度在三类算法中是最低的，为 $O(n)$ ，但其内存开销较大，通常至少消耗 $15n$ 字节，这就大大制约了其在 BWT 算法中的应用。

第三类算法称为后缀阵列 (Suffix Array) 排序算法，如 [63, 68, 86]。这类算法与直接排序算法有一定的相似之处，主要的区别是后缀阵列排序算法运用了倍增 (Doubling) 技术来提高算法的速度，这种思想最早源于 Karp 等人在 [58] 中提出的在字符串中寻找重复模式的算法，通过这种方法可以使字符串的比较由逐个字符的比较转变为相继 $1, 2, 4, 8, \dots$ 个字符的倍增模式的比较，所以粗略地估计就可以得出其时间

复杂性为 $O(n(\ln n)^2)$ ，更精细的分析表明其时间复杂性为 $O(n \ln n)$ 。至于内存开销，以 [63] 的算法为例，大约需要 $8n$ 字节。最近两年也出现了一些具有 $O(n)$ 线性时间复杂性的后缀数组排序算法，但最近的研究 [81] 表明这些理论上的高性能算法实际中与算法 [63]、[69] 相比还有相当大的差距。

就笔者的观点而言，上述三类算法中，第三类算法是最具商业应用价值的，因为该类算法具有稳定而且适中的时间复杂性和较低的内存开销。

2.3.3 数据后处理算法的设计

本质上，BWT 只是对数据做了一个置换，所以真正的数据压缩是要靠数据后处理算法配合熵编码来完成的。通过 BWT，具有相似后缀的字符就会被聚合在一块，所以，变换后的整个序列可以近似地分割为一些字符组，其中每一块字符的概率分布即为其所对应的某个后缀（即上下文）的条件概率，于是，可以把 BWT 变换的输出序列近似为一个分段独立同分布（Piecewise Independent and Identically Distributed, p.i.i.d.）序列。

理论上，如果假设某序列是由一个有限记忆信源（Finite Memory Sources）生成的，又假设该序列的 BWT 变换输出序列中的每一个独立同分布段的边界都已知道，那么，可以用简单的自适应熵编码器对其中每一段进行编码，因而可以非常容易地达到渐近收敛于信源熵率的压缩编码速率。即使是任意的平稳遍历信源，我们也可以采用某个有限记忆信源去逼近它，进而使编码速率渐近收敛于信源熵率。然而，问题的难点在于 BWT 变换输出序列中每一个独立同分布段的边界并不能预先知道，如果不考虑计算上的代价，编码器是可以容易地获取这些信息的，然而对于解码器，就必须采用某种隐式的自适应方式或者显式的编码方式使其获取有关序列分段的知识，当然，这些技术会引入额外的编码开销，关键是如何设计这些技术，使这些开销随着序列长度的增加，其分摊到每个字符上的编码量能尽可能快地渐近趋向于零。这就是数据后处理算法的任务，文献 [31] 从理论上对这个问题进行了深入的探讨和分析，给出了一系列算法及其冗余度的渐近分析。

在基于 BWT 的压缩算法中，Move-to-Front 变换（MTF，也称为 Recency-Rank 变换）及其变种是一类最常用的数据后处理算法。这种变换最早出现在文献 [12, 33] 中，关于其性能的详细分析可以参见 [76]。MTF 的基本算法为：构造字符集 \mathcal{A} 的一个有序列表

$$L = \{a_1, a_2, \dots, a_{|\mathcal{A}|}\}, \quad a_i \in \mathcal{A} (i = 1, 2, \dots, |\mathcal{A}|)$$

作为初始化列表，然后将序列 x^n 的字符逐个映射为一个正整数序列 $y^n = y_1 y_2 \dots y_n$ 。其映射规则为：如果 x_i 等于列表 L 中的第 y_i 个字符，那么就将 x_i 映射为 y_i ，同时将第 y_i 个字符移到列表 L 的第一项，其它各项依次往后移。我们将该变换记为 $\text{MTF}_n : \mathcal{A}^n \rightarrow \mathbb{Z}^n$ ，于是 $y^n = \text{MTF}_n(x^n)$ ，或简写为 $y^n = \text{MTF}(x^n)$ 。类似地，依照对称性，可以很容易地得到其反变换，我们将其记为 $\text{IMTF}_n : \mathbb{Z}^n \rightarrow \mathcal{A}^n$ 。

直观地看, 该变换的本质就是使频繁出现的字符在统计平均意义下具有较低的映射值。仔细观察表明, 其输出整数序列就是输入字符从前一次出现到这一次出现间的不同字符的个数, 这就赋予了该变换局部化的特征, 因此对于分段独立同分布序列, 它会较快地从前一个段切换至下一个段。而且, 还可以注意到, 输入字符从前一次出现到这一次出现间的不同字符的个数的最大取值就是两字符间的时间间隔, 即我们常称为回归时间 (Recurrence Time) 的量, 这是一个非常重要的量, 因为它和该字符的概率 (也可以是经验概率, 在这种情形下, 我们所讨论问题中的数学期望将改为时间平均, 而相应的形式则将更接近于组合方面的讨论) 存在一定的关系, 当一个随机过程为平稳过程时, 由 Kac 返回时间定理^[57] 知

$$E[\tau(a)|X_0 = a] \leq \frac{1}{\Pr\{X_0 = a\}},$$

当随机过程为平稳遍历过程时取等号, 式中

$$\tau(a) \triangleq \min\{n \in \mathbb{Z}^+ | X_{-n} = a\}.$$

如果注意到, 假如对回归时间序列进行通用整数编码, 那么通常其编码长度中的主要部分就是 $\lfloor \log \tau(a) \rfloor$, 并进一步注意到类似如下的数学形式,

$$\begin{aligned} E[\lfloor \log \tau(X_0) \rfloor] &\leq \sum_a \Pr\{X_0 = a\} E[\log \tau(a) | X_0 = a] \\ &\stackrel{(a)}{\leq} \sum_a \Pr\{X_0 = a\} \log E[\tau(a) | X_0 = a] \\ &\leq \sum_a \Pr\{X_0 = a\} \log \frac{1}{\Pr\{X_0 = a\}}, \end{aligned}$$

相信读者就可以大致的理解 MTF 之所以能进行有效压缩的原因了 (式中 (a) 应用了 Jensen 不等式和对数函数 $\log x$ 的凹函数特性)。当然上述的叙述是极不严格的, 但就是由于存在着这种联系, [76] 证明了在渐近平稳 (Asymptotically Mean Stationary, AMS) 信源下, MTF 配合渐近最优的整数编码和字符扩展技术可以在几乎必然 (Almost Sure, a.s.) 意义下渐近收敛于信源的熵率。[7, 31] 则进一步分析了 BWT 配合 MTF 技术的压缩性能, [31] 的结果表明该类算法的平均每字符编码冗余度为 $O(\log \log n / \log n)$ 。显然, 这种渐近速度实在是太慢了, 不过实际中我们使用的是熵编码器, 所以性能要好得多。在实际的 BWT 算法中, 研究者们又对 MTF 进行了改进, 以期获得更好的压缩性能, 其改进的重点就是列表 L 的更新策略, 如 [9] 的 MTF-1 算法、[38] 的 sticky MTF 等。

除了 MTF 算法, 研究者们还提出了其它一系列的算法, 如 Arnavut 和 Magliveras 提出的倒转频率 (Inversion Frequencies, IF) 方法^[8], Deorowicz 提出的加权频率计数 (Weighted Frequency Count, WFC) 方法^[29] (一种推广的 MTF 算法)。甚至, 也有用其他压缩方法直接对 BWT 输出序列进行压缩的, 如 [30]。

总的看来, 关于数据后处理算法的设计问题目前仍然处于纯经验的状态, 缺乏更多的理论思考, 虽然有些方法获得了较好的效果, 但由于其测试数据集过小, 很难说明这些方法都是广泛适用的。

2.3.4 基于整数组编码的 BWT 压缩算法设计

本节将主要在第2.2节的基础上考虑设计一个基于整数组编码的 BWT 压缩算法。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^[88]。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^[37, 38]。事实上, 第 2.2 节中提出的四个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

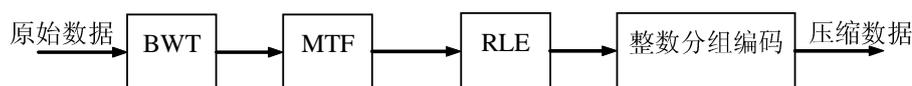


图 2.5: 基于整数组编码的 BWT 压缩方案

行 MTF 变换和行程编码 (Run Length Encoding, RLE), 最后对整数序列按固定的块大小进行分组编码。

其中, RLE 采用的实际编码方案是 Wheeler 1/2 码^[36], 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 0 开始计数的, 所以变为整数 0)。虽然, 本文的整数组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。

第2.2节提出了四种针对一组整数的编码方案, 相应地由图2.5可以派生出四种压缩方案, 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。笔者将这四种算法对常用的 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 [38] 中的 Simple 算法和 Seward 的 BZIP2 软件^[88] 的压缩结果。从表中可以看出，本文的四

表 2.9: Calgary Corpus 的压缩结果 (单位: bits/symbol)

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
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 2.10: Canterbury Corpus 的压缩结果 (单位: bits/symbol)

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
plravn12.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

个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^[32] 和 Fibonacci 码^[41] 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。

仔细比较本文四个编码方案的压缩结果还会发现, 对于有的文件, BR 和 BRE 算法的结果要好一点, 而对于其他的一些文件, BG 和 BGE 算法的结果要好一点, 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。

2.4 本章小节

本章的主要贡献如下:

在第2.1.3中, 我们分析了任意概率分布下 Golomb 码的性能 (定理2.1), 给出了 Golomb 码的最优参数选择准则 (2.1.16), 进而分析了任意非递增概率分布下 Golomb 码的性能 (定理2.2), 给出了其性能的一个充分紧的上下界, 并给出了一个最优参数选择的近似方法 (推论2.1), 实际计算表明基于该近似方法的混合参数选择方案选择的参数所达到的上界还是十分接近最小上界的 (图2.2)。

在第2.1.4中, 我们在 Golomb 码的基础上, 对 Elias γ 码进行了推广, 提出了一类扩展的 γ 码, 而在任意概率分布下分析了扩展 γ 码的性能 (定理2.3), 给出了扩展 γ 码的最优参数选择准则 (2.1.43), 进而证明了扩展 γ 码都是通用码, 而且在参数选择准则 (2.1.43) 下可以达到渐近最优的性能 (推论2.3)。

在第2.1.5节中, 为了更好地理解 Golomb 码和扩展 γ 码, 我们提出了最大熵码的概念, 进而证明了 Golomb 码和扩展 γ 码分别是 S_{μ_0} 和 S_{ν_0} 两类信源上的最大熵码 (定理2.5和定理2.6)。其中, 为证明定理2.6而证明的引理 2.3 更是给出了一个用 $E_P[\lceil \log i \rceil]$ 表达的关于熵的一个最紧上界。

在第2.2节中, 我们首先在 Golomb 码的基础上提出了一种二进制序列的编码算法 (第2.2.1节), 而后, 我们在上述编码算法的基础上, 同时结合 Golomb 码和扩展 γ 码的构造原理, 给出了一组整数的四个实用编码方案, 在一定程度上提高了对低熵值序列的编码效率 (第2.2.2节)。

在第2.3节中, 我们将整数组编码方案结合 Burrows-Wheeler 变换应用于数据压缩算法的设计 (图2.5), 实验结果表明其性能明显优于使用 Elias γ 码和 Fibonacci 码的同类方案 (表2.9和表2.10)。

第三章 分布式信源编码

3.1 基本问题与研究进展

近十几年来，随着诸如 JPEG-LS、JPEG2000、MPEG4、H.264 等一系列成熟高效的数据压缩标准的出现，面向单个用户的信源编码技术已十分成熟，然而，面向网络、面向多个用户的信源编码技术的研究与应用仍然处于起步阶段，许多基本的理论问题和实现问题都还远没有获得满意的解决。其中，以 Slepian-Wolf 编码^[92]及对应的率失真问题（包括 Wyner-Ziv 编码问题^[103]）、网络信源编码^[26, 50]和 CEO 问题^[13]等一系列课题为代表的分布式信源编码的研究是当前国际上这一领域的前沿和研究热点。上述这些课题中，又以 Slepian-Wolf 编码及对应的率失真问题为基本问题，其他问题往往是在其基础上的进一步推广。

Slepian-Wolf 编码问题是多用户信息论中的一个经典问题，它是由 Slepian 和 Wolf 于 1973 年提出的一个关于相关信源的分离编码问题（Separate Coding of Correlated Sources）^[92]。该问题的基本内容为：当两个（离散无记忆）相关信源被独自进行编码，然后在接收端联合译码，问使得存在渐近无错无损压缩的编码/译码器的可达速率区为多大（如图3.1）？Slepian 和 Wolf 给出的答案是令人吃惊的，即证明了存在这样的

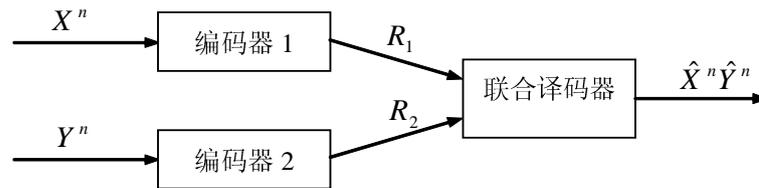


图 3.1: Slepian-Wolf 编码系统

编码/译码器，它们可以做到与联合编码的情形下一样好，该结果称为 Slepian-Wolf 定理，其数学形式为

$$R_1 \geq H(X|Y), \quad R_2 \geq H(Y|X), \quad R_1 + R_2 \geq H(XY), \quad (3.1.1)$$

式中， X 和 Y 表示两个相关的离散无记忆信源， $XY \triangleq (X, Y)$ ， R_1 和 R_2 分别对应于两个编码器的编码速率，由 (3.1.1) 所规定的可达速率区称为 Slepian-Wolf 区域，而该问题中所讨论的数据压缩系统则通常简称为 Slepian-Wolf 系统。

之后, Cover 运用平稳遍历过程的 AEP 性质将 Slepian-Wolf 定理推广到遍历信源 (Ergodic sources) [23], Miyake 与 Kanaya 则进一步运用信息谱 (Information Spectrum) 的方法将该定理推广到一般信源 (General Sources) [74]。

在该问题的证明思路上, 也经历了一个不断发展的过程。最初, [92] 是将两个相关信源间的相关性等效为由信源 X 到信源 Y 的一个虚拟信道, 然后用信道编码中的随机编码方法生成大约 $2^{nH(X|Y)}$ 个随机码本来渐近覆盖由信源 X 生成的所有 n 长序列, 所以编码时只需将序列所在码本的编号以速率 $H(X|Y)$ 传给译码器, 而对信源 Y 进行单信源编码, 以速率 $H(Y)$ 传至译码器, 由译码器在相应的码本下从 Y^n 的值译出 X^n , 于是便可以实现 Slepian-Wolf 区域的一个角点 (即速率对 $(H(X|Y), H(Y))$) 的渐近无错传输 (如图3.2)。由对称性, 也可以实现另一个角点的渐近无错传输, 再

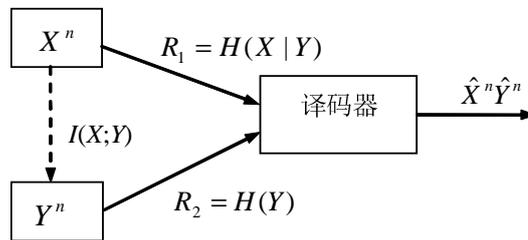


图 3.2: Slepian-Wolf 编码的虚拟信道思想

运用时分 (Time Sharing) 技术就可以实现 Slepian-Wolf 区域边界上任意一点的渐近无错压缩, 这种方法可以称为非对称压缩。之后, Cover 在 [23] 中仍然采用了这种思路, 只是在具体编码上采用了随机装箱 (Random Binning) 的方法。那么能否不采用时分技术, 而直接实现对称压缩呢? Gamal 和 Cover 在 [46] 中就采用了对称压缩的方法, 编码依然采用随机装箱的方法, 但对称压缩必须估计三项译码错误的上界, 而由这三项译码错误正好可以推出 Slepian-Wolf 区域的三个不等式, 从而得证, 这也就是现在的教材通常介绍的证明方法。

两个相关信源的 Slepian-Wolf 定理是可以很容易推广到任意 n 个信源的, 研究者们还进一步考察了比其更一般的信源网络的可达速率区问题, 如 [26, 50]。

在实际应用场合, 相关信源的统计特性往往是未知的, 即使预先可以对其统计特性进行测算, 但由于大多数系统都是时变的, 其信源统计特性也往往具有某种波动性。所以必须设计具有稳健性的 Slepian-Wolf 压缩系统, 即通用 Slepian-Wolf 数据压缩系统。于是, 研究者们又研究了 Slepian-Wolf 系统的通用编码问题, 即要求其编码和译码的算法都不依赖于信源的统计特性。最早是 Csiszár 和 Körner 在 [26] 中解决的, 他们证明了在采用最小熵译码器条件下, 对于任意的速率对设置, 存在编码器对, 不管无记忆相关信源的统计特性如何, 只要其 Slepian-Wolf 区域包含该速率对, 就可以达到渐近无错的无损压缩。Csiszár 在 [25] 中则进一步证明了在线性编码器中也存在这种通用编码器。Oohama 与 Han 则在译码错误指数的估计上进一步加强了他们的结果 [78]。以上这些进展都是以类型 (Type) 论为工具展开的, 虽然类型论是一种非常有威力的

工具，然而通常的类型论只适用于离散无记忆信源，所以上述研究成果也只能局限于离散无记忆信源。关于更一般信源的通用编码问题，进展十分有限，只有 Uyematsu 运用概率量化和相关一般信源的编码定理^[74] 给出了遍历 Markov 信源下通用编码的存在性证明^[99]。

如果引入失真度量，我们立刻得到 Slepian-Wolf 问题的率失真版本，然而这个问题到现在还未得到完全解决，只是获得了一些外界或内界的估计。但是该问题的一个简化版本，即译码端具有边信息的率失真问题^[103]（通常称为 Wyner-Ziv 编码问题），早在 70 年代就已获解决，其编码系统如图 3.3。图中具有边信息的率失真函数 $R_Y(D)$

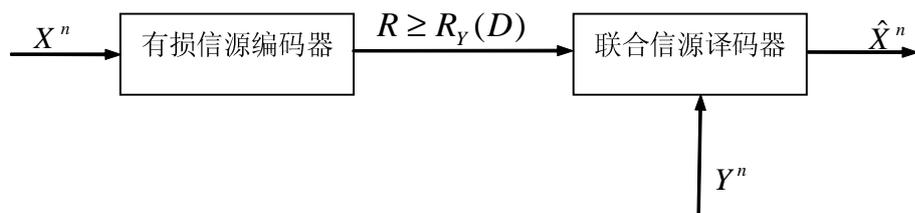


图 3.3: Wyner-Ziv 编码系统

定义为

$$R_Y(D) = \min_{p(w|x)} \min_f \{I(X;W) - I(Y;W)\}, \quad (3.1.2)$$

式中最小化取在所有的函数 $f: \mathcal{Y} \times \mathcal{W} \rightarrow \hat{\mathcal{X}}$ 和所有的条件概率分布 $p(w|x)$ ($|\mathcal{W}| \leq |\mathcal{X}| + 1$), 且满足

$$\sum_x \sum_w \sum_y p(x,y)p(w|x)d(x, f(y,w)) \leq D.$$

虽然 Slepian-Wolf 问题和 Wyner-Ziv 问题从提出到现在已有三十多年，但真正考虑如何实现 Slepian-Wolf 数据压缩系统还只是近五至十年的事，其发展很大程度上得益于无线传感器网络研究与应用的快速发展。无线传感器网络是一个由许多微小、廉价的无线传感器组成的无线网络。由于无线传感器网络中的传感器节点都是不可再充电的，故其能量都是有限的，这就会对整个传感器网络的寿命及可处理的信息量产生极大的影响，因此如何降低功耗就成为了无线传感器网络设计的一个重点。要降低功耗，一种有益的思路就是利用传感器节点采集数据间的相关性通过压缩的方法降低实际传输给基站的数据量，同时压缩算法的复杂性应尽可能集中在解码端，使传感器节点上的编码算法尽可能简单，从而在通信和计算两个方面降低节点功耗，达到延长传感器网络寿命，提高处理信息量的目的。分布式信源编码正好适应这种需求，一方面，分离编码的特点可以使传感器节点在互不通信的前提下，通过利用各节点采集数据间的统计相关性对数据进行压缩，从而达到降低通信数据量的目的，另一方面，联合译码的特点使得整个压缩算法的复杂性主要集中于接收端的基站，从而达到降低节点计算复杂性的目的。所以近年来，在无线传感器网络应用需求的刺激下，分布式信源编码实际系统的设计实现问题逐步成为国际数据压缩领域的一个研究热点。当然，分布

式信源编码的应用范围并不仅仅限于无线传感器网络，例如，视频压缩也是该技术的一个非常重要的应用（如 [2]）。利用 Wyner-Ziv 编码，可以在编码端不采用或少采用复杂的帧间预测技术，而在解码端利用帧间的相关性来提高视频图像的质量，通过采用这种技术，其编解码系统相对于传统技术具有更大的抗信道差错的性能，即鲁棒性，而且编码的复杂性有所下降，解码的复杂性有所提高，因此两端的复杂性相对较为平衡。

理论上，由 Slepian-Wolf 定理^[92] 和 Wyner-Ziv 定理^[103]，我们已经知道存在某种编码的方法可以在渐近无错的意义上接近定理中预言的极限性能。而且，在 [25] 中，Csiszár 还进一步证明了这种好的编码器在线性编码器中就可以找到。但是，到目前为止，多数的理论研究由于使用纯粹的随机编码方法来原因理论证明，因此对于实际编码方案设计很难再给出进一步的提示。Uyematsu 在 [98] 中提出了一种基于代数几何码的编码/解码算法，可惜其算法复杂性仍旧过高，无法真正应用于实际。2003 年，Muramatsu 等人在 [77] 中对基于 LDPC 码的 Slepian-Wolf 系统在一般信源（General Sources）下的性能作了理论分析，这是一个非常有意义的进展。至于将通用 Slepian-Wolf 编码理论与实际相联系的工作则更少，仅有 [22, 98]，而 [98] 的工作离实际实现还是很远。从目前的研究进展来看，通用编码器的设计问题其实并不是关键，因为在高级信道码中就存在着非常好的通用码，问题的关键是如何实现一个低复杂性的通用译码器，所以 Coleman 在 [22] 中的研究方向是可取的。

在应用方面，较早取得突破的是 Pradhan 等人的工作^[80]，它将理论中陪集编码的思想应用于实际，用信道码来构造用于相关信源编码的线性编码器，提出了 DISCUS（Distributed Source Coding Using Syndromes）方案，如图 3.4。其基本思路就是将

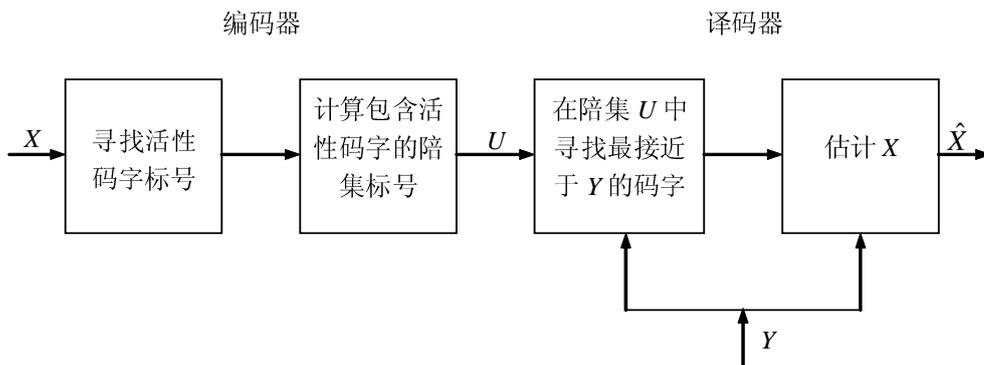


图 3.4: DISCUS 算法的编码和译码

Wyner-Ziv 定理的编码思想具体实现出来。首先，对信源 X 进行最优量化得到活性码字（第 1 模块），比如采用 TCQ（Trellis Coded Quantization）技术；其次，运用 Wyner 的陪集码思想对其进行陪集划分并计算出活性码字的陪集号 U （第 2 模块）；而后，在译码端利用边信息 Y ，将 X 和 Y 之间的统计相关性看作一个虚拟的信道，以信道译码的方式从陪集号为 U 的陪集码中译出活性码字（第 3 模块）；最后，以活性

码字和边信息 Y 为基础, 得到 X 的最优估计 \hat{X} (第 4 模块)。本质上, 第 2、3 模块就是非对称的 Slepian-Wolf 编码。与此类似的, 还有 Zamir 等人提出的嵌套格子码 (Nested Lattice Code) 思想^[107], 即在一个较细的格子码中还嵌套着一个较粗的格子码, 从而细格子码关于粗格子码形成了一系列的陪集码。

此后, 有大批的研究者围绕着如何达到 Slepian-Wolf 限和 Wyner-Ziv 限, 提出了大量基于高级信道编码 (如 Turbo 码、LDPC 码) 的方案, 如 [1, 47, 106, 108] 等。早期的工作往往主要集中于特殊相关模型下的非对称压缩编码, 近两年来, 关于对称压缩编码方案的设计有一定的进展, 提出了不少解决方法, 包括: 信道码本分割 (Channel Code Partitioning) 方法^[87, 93]、信源剖分 (Source-Splitting) 方法^[21] 以及使用联合分布进行 LDPC 的迭代译码。至于任意相关信源的压缩, 文献 [47, 64, 87] 也对其进行了一些有益的探讨。

总体而言, 关于分布式信源编码技术还远没有达到成熟, 有许多理论和实际的问题有待于解决, 特别是关于任意相关信源的对称压缩编码的设计, 还有很长的路要走。考虑到理论上有损分布式压缩问题至今未获解决, 而实际中多数压缩方案都是以无损的 Slepian-Wolf 编码和单信源量化技术为基础的, 所以在下文中, 我们将主要从理论的层面上对 Slepian-Wolf 编码的性能进行深入的分析, 期望能对实际编码设计给出一些有益的提示。

3.2 信道编码分析中的 Gallager 方法

由于我们的分析方法主要受信道编码中最大似然 (Maximum Likelihood, ML) 译码错误概率分析方法^[10, 43, 73, 91] 的启发, 所以, 在这一节中, 我们先简要地介绍一下这一方法的精髓, 即两个非常基本的不等式。因为这种方法首先由 Gallager 提出, 故将其称为 Gallager 方法。

在文献 [43] 中, Gallager 运用分析的方法而不是通常所采用的典型列的方法对信道编码在 ML 译码下的错误概率进行了分析, 其中很关键的一步就是他运用了一个看似非常复杂却又非常美妙的不等式, 原文中的形式如下:

$$\phi_m(\mathbf{y}) \leq \left[\frac{\sum_{m' \neq m} \Pr(\mathbf{y}|\mathbf{x}_{m'})^{1/(1+\rho)}}{\Pr(\mathbf{y}|\mathbf{x}_m)^{1/(1+\rho)}} \right]^\rho, \quad \rho > 0 \quad (3.2.1)$$

式中函数 $\phi_m(\mathbf{y})$ 定义为

$$\phi_m(\mathbf{y}) = \begin{cases} 1, & \text{如果存在某个 } m' \neq m \text{ 使得 } \Pr(\mathbf{y}|\mathbf{x}_m) \leq \Pr(\mathbf{y}|\mathbf{x}_{m'}) \quad (3.2.2a) \\ 0, & \text{否则} \quad (3.2.2b) \end{cases}$$

显然, 函数 $\phi_m(\mathbf{y})$ 就是在 ML 译码准则下推导出来的指示函数 (Indicator Function)。一眼看去, 不等式 (3.2.1) 的使用非常突兀, 似乎是突发灵感的产物, 但看过 Gallager

在其书 [44] 中的解释后，一切就变得十分自然了。通过对其思想的消化，笔者进一步将其提炼为两个非常基本的不等式，如下：

$$1\{x \leq x'\} \leq \left(\frac{x'}{x}\right)^s, \quad x > 0, x' \geq 0, s > 0 \quad (3.2.3)$$

$$\min\{x, 1\} \leq x^\rho, \quad x \geq 0, 0 < \rho \leq 1 \quad (3.2.4)$$

运用这两个不等式，就可以推出 (3.2.1)，如下：

$$\begin{aligned} \phi_m(\mathbf{y}) &= 1\{\exists m' \neq m, \text{ s. t. } \Pr(\mathbf{y}|\mathbf{x}_m) \leq \Pr(\mathbf{y}|\mathbf{x}_{m'})\} \\ &\leq \min\left\{\sum_{m' \neq m} 1\{\Pr(\mathbf{y}|\mathbf{x}_m) \leq \Pr(\mathbf{y}|\mathbf{x}_{m'})\}, 1\right\} \\ &\stackrel{(a)}{\leq} \left[\frac{\sum_{m' \neq m} \Pr(\mathbf{y}|\mathbf{x}_{m'})^s}{\Pr(\mathbf{y}|\mathbf{x}_m)^s}\right]^\rho, \end{aligned}$$

式中 (a) 运用了不等式 (3.2.3) 和 (3.2.4)。显然不等式 (3.2.1) 就是上式在 $s = 1/(1 + \rho)$ 时的一个特例。

3.3 Slepian-Wolf 系统 MAP 译码错误概率的分析

本节中，我们将运用 Gallager 方法对 Slepian-Wolf 系统在最大后验概率（maximum a posterior probability, MAP）译码下的性能进行分析，给出其平均译码错误概率的一个上界。在这之前，首先需要引入一些符号和定义。

在信息谱理论^[49]中，一个相关一般信源（Correlated General Source）定义为一个 n 维随机变量的无穷序列

$$\mathbf{XY} = \{X^n Y^n = (X_1^{(n)} Y_1^{(n)}, X_2^{(n)} Y_2^{(n)}, \dots, X_n^{(n)} Y_n^{(n)})\}_{n=1}^\infty, \quad (3.3.1)$$

其中 n 维随机变量的每个分量 $X_i^{(n)} Y_i^{(n)} \triangleq (X_i^{(n)}, Y_i^{(n)})$ ($1 \leq i \leq n$)，其取值在一个有限的积空间 $\mathcal{X} \times \mathcal{Y}$ 上。类似地，可以定义一般信源 \mathbf{X} 和 \mathbf{Y} 。此外，我们分别将 n 维随机变量 $X^n Y^n$ 、 X^n 和 Y^n 的样本空间和样本序列分别记为 $\mathcal{X}^n \times \mathcal{Y}^n$ 、 \mathcal{X}^n 、 \mathcal{Y}^n 和 $x^n y^n$ 、 x^n 、 y^n 。对于一个相关的平稳无记忆信源，其记号可以简化为随机变量 $XY \triangleq (X, Y)$ ，而随机序列 $X^n Y^n$ 可以由 XY 的反复独立抽取来生成。为了方便，我们还将记号 $\Pr\{X = x\}$ 和 $\Pr\{X = x|Y = y\}$ 分别简写为 $P_X(x)$ 和 $P_{X|Y}(x|y)$ 。

一个基于 MAP 译码的 Slepian-Wolf 编码系统可以定义如下：信源输出 X^n 和 Y^n 被分别独自编码为 $\phi_n(X^n)$ 和 $\psi_n(Y^n)$ ，然后 MAP 译码器观察这些编码序列，产生 $X^n Y^n$ 的最大可能估计 $\hat{X}^n \hat{Y}^n$ ，其中 $\phi = \{\phi_n\}_{n=1}^\infty$ 和 $\psi = \{\psi_n\}_{n=1}^\infty$ 为编码器序列对，定义为

$$\phi_n : \mathcal{X}^n \rightarrow \mathcal{L}_n = \{1, 2, \dots, |\mathcal{L}_n|\}, \quad \psi_n : \mathcal{Y}^n \rightarrow \mathcal{M}_n = \{1, 2, \dots, |\mathcal{M}_n|\}. \quad (3.3.2)$$

编码器 ϕ_n 和 ψ_n 的速率分别定义为 $R(\phi_n) \triangleq \ln |\mathcal{L}_n|/n$ 和 $R(\psi_n) \triangleq \ln |\mathcal{M}_n|/n$ 。本章中, 信息的单位都采用奈特 (nat)。MAP 译码器序列 $\text{map} = \{\text{map}_n\}_{n=1}^\infty$ 定义为

$$\text{map}_n(l, m) \triangleq \arg \max_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} \Pr\{X^n Y^n = x^n y^n | X^n Y^n \in \phi_n^{-1}(l) \times \psi_n^{-1}(m)\}, \quad (3.3.3)$$

式中 $l \in \mathcal{L}_n$, $m \in \mathcal{M}_n$ 。上式的一个等价形式为

$$\text{map}_n(l, m) \triangleq \arg \max_{x^n y^n \in \phi_n^{-1}(l) \times \psi_n^{-1}(m)} P_{X^n Y^n}(x^n y^n). \quad (3.3.4)$$

整个系统的 MAP 译码错误概率可以用下式来计算:

$$P_e^{(n)}(\phi_n, \psi_n) \triangleq \Pr\{\hat{X}^n \hat{Y}^n \neq X^n Y^n\} = \Pr\{\text{map}_n(\phi_n(X^n), \psi_n(Y^n)) \neq X^n Y^n\}. \quad (3.3.5)$$

我们称速率对 (R_1, R_2) 是可达的, 是指如果存在一个编码器序列对 (ϕ, ψ) 满足 $\lim_{n \rightarrow \infty} P_e^{(n)}(\phi_n, \psi_n) = 0$ 、 $\limsup_{n \rightarrow \infty} R(\phi_n) \leq R_1$ 和 $\limsup_{n \rightarrow \infty} R(\psi_n) \leq R_2$ 。所有可达速率对组成的集合则称为可达速率区。

关于 MAP 译码错误概率, 我们证明了以下定理。

定理 3.1 对于一对给定的随机编码器 Φ_n 和 Ψ_n (独立于 $X^n Y^n$), 如果对于任意不等的 $x^n, \hat{x}^n \in \mathcal{X}^n$ 和 $y^n, \hat{y}^n \in \mathcal{Y}^n$, 以下条件都满足

$$\begin{aligned} \Pr\{\Phi_n(x^n) = \Phi_n(\hat{x}^n)\} &\leq \alpha_n |\mathcal{L}_n|^{-1}, \quad \Pr\{\Psi_n(y^n) = \Psi_n(\hat{y}^n)\} \leq \beta_n |\mathcal{M}_n|^{-1}, \\ \Pr\{\Phi_n(x^n) = \Phi_n(\hat{x}^n), \Psi_n(y^n) = \Psi_n(\hat{y}^n)\} &\leq \gamma_n |\mathcal{L}_n|^{-1} |\mathcal{M}_n|^{-1}, \end{aligned} \quad (3.3.6)$$

式中 α_n 、 β_n 和 γ_n 为非负实数, 那么平均 MAP 译码错误概率满足

$$\begin{aligned} E[P_e^{(n)}(\Phi_n, \Psi_n)] &\leq \exp\{-nJ_1^{(n)}(R(\Phi_n) - \ln \alpha_n/n)\} + \exp\{-nJ_2^{(n)}(R(\Psi_n) - \ln \beta_n/n)\} \\ &\quad + \exp\{-nJ_3^{(n)}(R(\Phi_n) + R(\Psi_n) - \ln \gamma_n/n)\}, \end{aligned} \quad (3.3.7)$$

式中

$$J_i^{(n)}(R) \triangleq \max_{0 \leq \rho_i \leq 1} \{\rho_i R - J_{i0}^{(n)}(\rho_i)\}, \quad i = 1, 2, 3 \quad (3.3.8)$$

$$J_{10}^{(n)}(\rho_1) \triangleq \frac{1}{n} \ln \sum_{y^n \in \mathcal{Y}^n} \left(\sum_{x^n \in \mathcal{X}^n} P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)} \right)^{1+\rho_1}, \quad (3.3.9)$$

$$J_{20}^{(n)}(\rho_2) \triangleq \frac{1}{n} \ln \sum_{x^n \in \mathcal{X}^n} \left(\sum_{y^n \in \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_2)} \right)^{1+\rho_2}, \quad (3.3.10)$$

$$J_{30}^{(n)}(\rho_3) \triangleq \frac{1}{n} \ln \left(\sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_3)} \right)^{1+\rho_3}. \quad (3.3.11)$$

证明： 要估计 MAP 译码平均错误概率的上界，首先必须分析产生错误的事件集合，显然，错误事件集合可以写为三个事件集合的并集，即

$$E(\phi_n, \psi_n) = \bigcup_{i=1}^3 E_i(\phi_n, \psi_n), \quad (3.3.12)$$

式中

$$\begin{aligned} E_1(\phi_n, \psi_n) &\triangleq \{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n | \exists \hat{x}^n \neq x^n, \\ &\text{s. t. } \phi_n(\hat{x}^n) = \phi_n(x^n), P_{X^n Y^n}(\hat{x}^n y^n) \geq P_{X^n Y^n}(x^n y^n)\}, \\ E_2(\phi_n, \psi_n) &\triangleq \{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n | \exists \hat{y}^n \neq y^n, \\ &\text{s. t. } \psi_n(\hat{y}^n) = \psi_n(y^n), P_{X^n Y^n}(x^n \hat{y}^n) \geq P_{X^n Y^n}(x^n y^n)\}, \\ E_3(\phi_n, \psi_n) &\triangleq \{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n | \exists \hat{x}^n \neq x^n, \exists \hat{y}^n \neq y^n, \\ &\text{s. t. } \phi_n(\hat{x}^n) = \phi_n(x^n), \psi_n(\hat{y}^n) = \psi_n(y^n), P_{X^n Y^n}(\hat{x}^n \hat{y}^n) \geq P_{X^n Y^n}(x^n y^n)\}. \end{aligned}$$

因此，MAP 译码错误概率

$$\begin{aligned} P_e^{(n)}(\phi_n, \psi_n) &= \Pr\{X^n Y^n \in E(\phi_n, \psi_n)\} \\ &= \Pr\{X^n Y^n \in \bigcup_{i=1}^3 E_i(\phi_n, \psi_n)\} \\ &\leq \sum_{i=1}^3 \Pr\{X^n Y^n \in E_i(\phi_n, \psi_n)\}. \end{aligned}$$

于是，平均 MAP 译码错误概率为

$$\begin{aligned} E[P_e^{(n)}(\Phi_n, \Psi_n)] &\leq E\left[\sum_{i=1}^3 \Pr\{X^n Y^n \in E_i(\Phi_n, \Psi_n)\}\right] \\ &\stackrel{(a)}{=} \sum_{i=1}^3 \sum_{x^n y^n \in \mathcal{X} \times \mathcal{Y}} P_{X^n Y^n}(x^n y^n) E[1_{E_i(\Phi_n, \Psi_n)}(x^n y^n)], \quad (3.3.13) \end{aligned}$$

式中 (a) 利用了随机编码器与信源独立的特性。可以看出，要估计其上界，就必须对 (3.3.13) 求和式中的每一项的上界作出估计。类似于 Gallager 的方法^[43]，我们有

$$\begin{aligned} 1_{E_1(\phi_n, \psi_n)}(x^n y^n) &\leq \left(\frac{\sum_{\hat{x}^n \neq x^n} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)} 1_{\phi_n^{-1}(\phi_n(x^n))}(\hat{x}^n)}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1}, \\ 1_{E_2(\phi_n, \psi_n)}(x^n y^n) &\leq \left(\frac{\sum_{\hat{y}^n \neq y^n} P_{X^n Y^n}(x^n \hat{y}^n)^{1/(1+\rho_2)} 1_{\psi_n^{-1}(\psi_n(y^n))}(\hat{y}^n)}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_2)}} \right)^{\rho_2}, \\ 1_{E_3(\phi_n, \psi_n)}(x^n y^n) &\leq \left(\frac{\sum_{\hat{x}^n \neq x^n} \sum_{\hat{y}^n \neq y^n} P_{X^n Y^n}(\hat{x}^n \hat{y}^n)^{1/(1+\rho_3)} 1_{\phi_n^{-1}(\phi_n(x^n)) \times \psi_n^{-1}(\psi_n(y^n))}(\hat{x}^n \hat{y}^n)}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_3)}} \right)^{\rho_3}, \end{aligned}$$

式中 $0 \leq \rho_i \leq 1$ ($i = 1, 2, 3$)。运用函数 $y = x^\rho$ ($0 \leq \rho \leq 1$) 的凹函数特性和 Jensen 不等式, 进一步有

$$\begin{aligned} E[1_{E_1(\Phi_n, \Psi_n)}(x^n y^n)] &\leq \left(\frac{\sum_{\hat{x}^n \neq x^n} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)} E[1_{\Phi_n^{-1}(\Phi_n(x^n))}(\hat{x}^n)]}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1} \\ &= \left(\frac{\sum_{\hat{x}^n \neq x^n} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)} \Pr\{\Phi_n(x^n) = \Phi_n(\hat{x}^n)\}}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1} \\ &\stackrel{(a)}{\leq} \alpha_n^{\rho_1} |\mathcal{L}_n|^{-\rho_1} \left(\frac{\sum_{\hat{x}^n \in \mathcal{X}^n} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)}}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1} \\ &= \alpha_n^{\rho_1} \exp\{-n\rho_1 R(\Phi_n)\} \left(\frac{\sum_{\hat{x}^n \in \mathcal{X}^n} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)}}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1}, \end{aligned}$$

式中 (a) 利用了条件 (3.3.6)。然后代入 (3.3.13) 式的第一项, 则有

$$\begin{aligned} &\sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) E[1_{E_1(\Phi_n, \Psi_n)}(x^n y^n)] \\ &\leq \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) \alpha_n^{\rho_1} \exp\{-n\rho_1 R(\Phi_n)\} \left(\frac{\sum_{\hat{x}^n \in \mathcal{X}^n} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)}}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1} \\ &= \alpha_n^{\rho_1} \exp\{-n\rho_1 R(\Phi_n)\} \sum_{y^n \in \mathcal{Y}^n} \left(\sum_{x^n \in \mathcal{X}^n} P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)} \right)^{1+\rho_1} \\ &= \exp\{-n[\rho_1(R(\Phi_n) - \ln \alpha_n/n) - J_{10}^{(n)}(\rho_1)]\}, \end{aligned} \quad (3.3.14)$$

若进一步令该上界最小化, 即令 (3.3.14) 中的指数最大化, 我们就得到了 (3.3.7) 中的第一项。同理可以估计出 (3.3.13) 中第二、三项的上界, 即 (3.3.7) 中的第二、三项, 因此定理得证。□

在 Gallager 的书 [44, Exercise 5.16] 中, Gallager 对信源信道联合编码进行分析时, 也获得了一个类似于 (3.3.11) 的函数 (当然概率分布是一维的), 然而就笔者所知, 在关于 Slepian-Wolf 问题的研究文献中并未见类似于定理 3.1 的结果。虽然运用类型论也可以在平稳无记忆信源下获得与定理 3.1 类似 (应该可以证明等价) 的错误指数, 但其有效性仅仅局限于平稳无记忆信源, 而我们的方法是不依赖于大数定理的, 所以在一般信源下仍然有效。

要理解定理 3.1, 就必须熟悉函数 (3.3.9)、(3.3.10) 和 (3.3.11) 的特性。通过运用分析的技巧, 我们得到如下引理。

引理 3.1 定义函数

$$J_0(x) \triangleq \ln \sum_{i=1}^m \left(\sum_{j=1}^n p_{ij}^{1/x} \right)^x, \quad x > 0, \quad (3.3.15)$$

式中 $m \geq 1$, $n \geq 1$, 且 p_{ij} 为满足 $\sum_{i=1}^m \sum_{j=1}^n p_{ij} = 1$ 的非负实数, 于是

$$\frac{dJ_0(x)}{dx} = \sum_{i=1}^m P_i(x) \sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \geq 0, \quad (3.3.16)$$

$$\begin{aligned} \frac{d^2 J_0(x)}{dx^2} &= \sum_{i=1}^m P_i(x) \left(\sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \right)^2 - \left(\sum_{i=1}^m P_i(x) \sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \right)^2 \\ &\quad + \frac{1}{x} \sum_{i=1}^m P_i(x) \left[\sum_{j=1}^n Q_{ij}(x) \left(\ln \frac{1}{Q_{ij}(x)} \right)^2 - \left(\sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \right)^2 \right], \end{aligned} \quad (3.3.17)$$

式中

$$P_i(x) \triangleq \frac{\left(\sum_{j'=1}^n p_{ij'}^{1/x} \right)^x}{\sum_{i'=1}^m \left(\sum_{j'=1}^n p_{i'j'}^{1/x} \right)^x}, \quad Q_{ij}(x) \triangleq \frac{p_{ij}^{1/x}}{\sum_{j'=1}^n p_{ij'}^{1/x}}, \quad (3.3.18)$$

于是

$$\frac{d^2 J_0(x)}{dx^2} \geq 0, \quad (3.3.19)$$

当且仅当存在一个整数 K ($1 \leq K \leq n$) 使得对于每个 i 下式成立时取等号,

$$\frac{p_{ij}}{\sum_{j=1}^n p_{ij}} = \frac{1}{K} \text{ 或 } 0, \quad \text{或} \quad \sum_{j=1}^n p_{ij} = 0. \quad (3.3.20)$$

引理3.1中的部分结果可以用 Gallager 在 [43] 中的方法来证明, 即运用 Hölder 不等式, 但是, 我们选择了直接计算一阶和二阶导数的证明方法, 并且通过一定的观察, 将计算所得的一阶导数和二阶导数用两个带参数的概率分布函数表征出来。在笔者看来, 这是一个非常美妙的形式, 直觉上感觉其中可能包含着许多有待于探究的分析和几何方面的特性。

证明: 我们首先验证 (3.3.16) 和 (3.3.17) 是正确的, 先计算函数 $J_0(x)$ 的一阶导数。

$$\begin{aligned} \frac{dJ_0(x)}{dx} &= \frac{1}{\sum_{i=1}^m \left(\sum_{j=1}^n p_{ij}^{1/x} \right)^x} \sum_{i=1}^m \left(\sum_{j=1}^n p_{ij}^{1/x} \right)^x \left(\ln \sum_{j=1}^n p_{ij}^{1/x} + x \frac{\sum_{j=1}^n p_{ij}^{1/x} \ln p_{ij} \left(-\frac{1}{x^2}\right)}{\sum_{j=1}^n p_{ij}^{1/x}} \right) \\ &= \sum_{i=1}^m \frac{\left(\sum_{j'=1}^n p_{ij'}^{1/x} \right)^x}{\sum_{i'=1}^m \left(\sum_{j'=1}^n p_{i'j'}^{1/x} \right)^x} \sum_{j=1}^n \frac{p_{ij}^{1/x}}{\sum_{j'=1}^n p_{ij'}^{1/x}} \ln \frac{\sum_{j'=1}^n p_{ij'}^{1/x}}{p_{ij}^{1/x}}. \end{aligned}$$

应用条件熵的非负性就可证明一阶导数的非负性。

然后计算二阶导数。

$$\begin{aligned} &\frac{d^2 J_0(x)}{dx^2} \\ &= \sum_{i=1}^m \left(\frac{\left(\sum_{j'=1}^n p_{ij'}^{1/x} \right)^x}{\sum_{i'=1}^m \left(\sum_{j'=1}^n p_{i'j'}^{1/x} \right)^x} \right)' \sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \\ &\quad + \sum_{i=1}^m P_i(x) \left(\sum_{j=1}^n \frac{p_{ij}^{1/x}}{\sum_{j'=1}^n p_{ij'}^{1/x}} \ln \frac{\sum_{j'=1}^n p_{ij'}^{1/x}}{p_{ij}^{1/x}} \right)' \end{aligned}$$

$$\begin{aligned}
&= \sum_{i=1}^m \left\{ \frac{\left(\sum_{j'=1}^n p_{ij'}^{1/x} \right)^x \sum_{j'=1}^n Q_{ij'}(x) \ln \frac{1}{Q_{ij'}(x)}}{\sum_{i'=1}^m \left(\sum_{j'=1}^n p_{i'j'}^{1/x} \right)^x} \right. \\
&\quad \left. - \frac{\left(\sum_{j'=1}^n p_{ij'}^{1/x} \right)^x \sum_{i'=1}^m \left(\sum_{j'=1}^n p_{i'j'}^{1/x} \right)^x \sum_{j'=1}^n Q_{i'j'}(x) \ln \frac{1}{Q_{i'j'}(x)}}{\left[\sum_{i'=1}^m \left(\sum_{j'=1}^n p_{i'j'}^{1/x} \right)^x \right]^2} \right\} \sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \\
&\quad + \sum_{i=1}^m P_i(x) \left\{ \sum_{j=1}^n \left[\frac{p_{ij}^{1/x} \ln p_{ij}(-\frac{1}{x^2})}{\sum_{j'=1}^n p_{ij'}^{1/x}} - \frac{p_{ij}^{1/x} \sum_{j'=1}^n p_{ij'}^{1/x} \ln p_{ij'}(-\frac{1}{x^2})}{\left(\sum_{j'=1}^n p_{ij'}^{1/x} \right)^2} \right] \ln \frac{1}{Q_{ij}(x)} \right. \\
&\quad \left. - \sum_{j=1}^n Q_{ij}(x) \frac{1}{Q_{ij}(x)} \left[\frac{p_{ij}^{1/x} \ln p_{ij}(-\frac{1}{x^2})}{\sum_{j'=1}^n p_{ij'}^{1/x}} - \frac{p_{ij}^{1/x} \sum_{j'=1}^n p_{ij'}^{1/x} \ln p_{ij'}(-\frac{1}{x^2})}{\left(\sum_{j'=1}^n p_{ij'}^{1/x} \right)^2} \right] \right\} \\
&= \sum_{i=1}^m P_i(x) \left(\sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \right)^2 - \left(\sum_{i=1}^m P_i(x) \sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \right)^2 \\
&\quad + \frac{1}{x} \sum_{i=1}^m P_i(x) \left[\sum_{j=1}^n Q_{ij}(x) \left(\ln \frac{1}{Q_{ij}(x)} \right)^2 - \left(\sum_{j=1}^n Q_{ij}(x) \ln \frac{1}{Q_{ij}(x)} \right)^2 \right].
\end{aligned}$$

应用 Jensen 不等式和函数 $y = x^2$ 的凸函数特性, 就可以推出 (3.3.19) 和 (3.3.20) 故引理得证. \square

由引理3.1知, 函数 (3.3.9)、(3.3.10) 和 (3.3.11) 都是递增的凸函数, 在此基础上, 我们可以证明指数 (3.3.8) 是连续、递增的凸函数。

推论 3.1 定义函数

$$J(R) = \max_{1 \leq x \leq 2} \{(x-1)R - J_0(x)\}, \quad R \geq 0 \quad (3.3.21)$$

则 $J(R)$ 是一个连续、递增的凸函数, 且

$$J(R) = \begin{cases} 0, & 0 \leq R \leq J'_0(1) \\ (a-1)R - J_0(a), & J'_0(1) < R = J'_0(a) < J'_0(2) \\ R - J_0(2), & R \geq J'_0(2) \end{cases} \quad (3.3.22a)$$

$$(3.3.22b)$$

$$(3.3.22c)$$

证明: 我们只证明 $J(R)$ 是一个连续递增的凸函数, 至于 (3.3.22), 其主干部分已蕴含在下述证明中。我们假设

$$J'_0(2) > J'_0(1), \quad J'_0(1) \leq R \leq J'_0(2),$$

至于其他情形, 都十分简单。

由引理3.1知, 对于所有的 $1 \leq x \leq 2$, $J''_0(x) > 0$ 。因此, 对于 $J'_0(1) \leq R \leq J'_0(2)$,

$$J(R) = (y(R) - 1)R - J_0(y(R)),$$

式中 $y(R)$ 由下式以隐函数的方式定义。

$$J'_0(y(R)) = R.$$

由上述等式可知，函数 $y(R)$ 是可微的，且

$$J''_0(y(R))y'(R) = 1.$$

故函数 $J(R)$ 是可微的。我们分别计算其一阶、二阶导数，如下：

$$\begin{aligned} J'(R) &= y'(R)R + y(R) - 1 - J'_0(y(R))y'(R) \\ &= y'(R)(R - J'_0(y(R))) + y(R) - 1 \\ &= y(R) - 1 \geq 0. \end{aligned}$$

$$J''(R) = y'(R) = \frac{1}{J''_0(y(R))} > 0.$$

所以函数 $J(R)$ 是递增和凸的。 □

由推论3.1，我们就可以得到函数 $J(R)$ 大致的草图（如图3.5）。定理3.1 中的三个错误指数函数，即 (3.3.8)，其函数曲线与图3.5类似，只是具体取值不同。

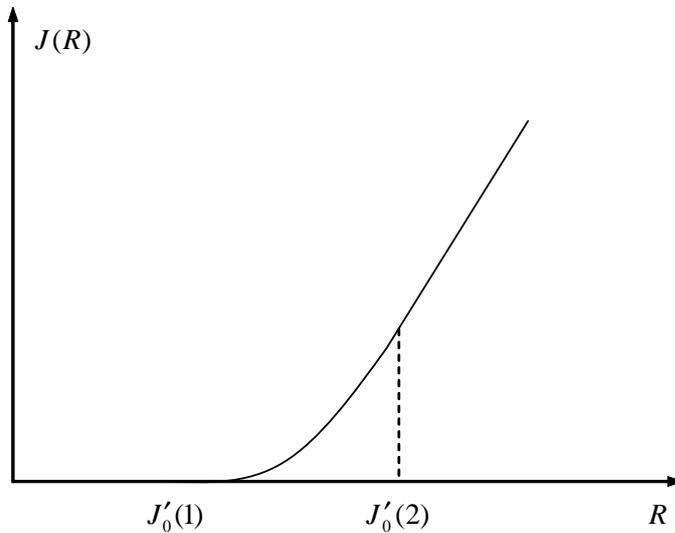


图 3.5: 函数 $J(R)$ 的草图

接下来，我们将用所获得的结果来证明相关平稳无记忆信源下 Slepian-Wolf 定理的正命题部分 (Direct Part)，不过在这之前，我们将利用无记忆的特性对函数 (3.3.9)、(3.3.10) 和 (3.3.11) 作进一步的化简。

推论 3.2 若随机序列 $X^n Y^n$ 满足独立性条件，即

$$P_{X^n Y^n}(x^n y^n) = \prod_{i=1}^n P_{X_i Y_i}(x_i y_i), \quad \forall x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n,$$

则 (3.3.9)、(3.3.10) 和 (3.3.11) 式可以化简为

$$J_{10}^{(n)}(\rho_1) = \frac{1}{n} \sum_{i=1}^n \ln \sum_{y \in \mathcal{Y}} \left(\sum_{x \in \mathcal{X}} P_{X_i Y_i}(xy)^{1/(1+\rho_1)} \right)^{1+\rho_1}, \quad (3.3.23)$$

$$J_{20}^{(n)}(\rho_2) = \frac{1}{n} \sum_{i=1}^n \ln \sum_{x \in \mathcal{X}} \left(\sum_{y \in \mathcal{Y}} P_{X_i Y_i}(xy)^{1/(1+\rho_2)} \right)^{1+\rho_2}, \quad (3.3.24)$$

$$J_{30}^{(n)}(\rho_3) = \frac{1}{n} \sum_{i=1}^n \ln \left(\sum_{xy \in \mathcal{X} \times \mathcal{Y}} P_{X_i Y_i}(xy)^{1/(1+\rho_3)} \right)^{1+\rho_3}. \quad (3.3.25)$$

证明： 我们仅给出 (3.3.23) 的证明，其他的证明类似。

$$\begin{aligned} J_{10}^{(n)}(\rho_1) &= \frac{1}{n} \ln \sum_{y^n \in \mathcal{Y}^n} \left(\sum_{x^n \in \mathcal{X}^n} \prod_{i=1}^n P_{X_i Y_i}(x_i y_i)^{1/(1+\rho_1)} \right)^{1+\rho_1} \\ &= \frac{1}{n} \ln \sum_{y^n \in \mathcal{Y}^n} \left(\prod_{i=1}^n \sum_{x \in \mathcal{X}} P_{X_i Y_i}(x y_i)^{1/(1+\rho_1)} \right)^{1+\rho_1} \\ &= \frac{1}{n} \ln \sum_{y^n \in \mathcal{Y}^n} \prod_{i=1}^n \left(\sum_{x \in \mathcal{X}} P_{X_i Y_i}(x y_i)^{1/(1+\rho_1)} \right)^{1+\rho_1} \\ &= \frac{1}{n} \ln \prod_{i=1}^n \sum_{y \in \mathcal{Y}} \left(\sum_{x \in \mathcal{X}} P_{X_i Y_i}(xy)^{1/(1+\rho_1)} \right)^{1+\rho_1} \\ &= \frac{1}{n} \sum_{i=1}^n \ln \sum_{y \in \mathcal{Y}} \left(\sum_{x \in \mathcal{X}} P_{X_i Y_i}(xy)^{1/(1+\rho_1)} \right)^{1+\rho_1}. \end{aligned}$$

□

现在，我们将着手证明 Slepian-Wolf 定理的正命题部分。

定理 3.2 (Slepian-Wolf 定理正命题部分 (平稳无记忆信源)) 若相关信源为平稳无记忆信源 XY ，则以下区域

$$\{(R_1, R_2) | R_1 \geq H(X|Y), R_2 \geq H(Y|X), R_1 + R_2 \geq H(XY)\} \quad (3.3.26)$$

内的速率对是可达的。

证明： 由推论3.2以及信源的平稳性，我们有

$$J_{10}^{(n)}(\rho_1) = \ln \sum_{y \in \mathcal{Y}} \left(\sum_{x \in \mathcal{X}} P_{XY}(xy)^{1/(1+\rho_1)} \right)^{1+\rho_1},$$

$$J_{20}^{(n)}(\rho_2) = \ln \sum_{x \in \mathcal{X}} \left(\sum_{y \in \mathcal{Y}} P_{XY}(xy)^{1/(1+\rho_2)} \right)^{1+\rho_2},$$

$$J_{30}^{(n)}(\rho_3) = \ln \left(\sum_{xy \in \mathcal{X} \times \mathcal{Y}} P_{XY}(xy)^{1/(1+\rho_3)} \right)^{1+\rho_3}.$$

于是, 指数 (3.3.8) 都是常数, 所以只需证明其何时为正值。结合推论3.1, 我们知道当

$$R > \left. \frac{dJ_{10}^{(n)}(\rho_1)}{d\rho_1} \right|_{\rho_1=0} = H(X|Y)$$

时, $J_1^{(n)}(R) > 0$ 。同理, 也可得到当 $R > H(Y|X)$ 时, $J_2^{(n)}(R) > 0$; 当 $R > H(XY)$ 时, $J_3^{(n)}(R) > 0$ 。接下来, 我们用随机装箱 (具体构造方法见 [23]) 的方法来构造随机编码器 Φ_n 和 Ψ_n , 使其渐近速率满足

$$\lim_{n \rightarrow \infty} R(\Phi_n) = R_1, \quad \lim_{n \rightarrow \infty} R(\Psi_n) = R_2,$$

R_1 和 R_2 满足

$$R_1 > H(X|Y), R_2 > H(Y|X), R_1 + R_2 > H(XY).$$

显然 $\alpha_n = \beta_n = \gamma_n = 1$ 。所以, 对于充分大的 n , 我们有

$$R(\Phi_n) - \ln \alpha_n/n = R(\Phi_n) > H(X|Y),$$

$$R(\Psi_n) - \ln \beta_n/n = R(\Psi_n) > H(Y|X),$$

$$R(\Phi_n) + R(\Psi_n) - \ln \gamma_n/n = R(\Phi_n) + R(\Psi_n) > H(XY),$$

因此

$$\begin{aligned} \lim_{n \rightarrow \infty} E[P_e^{(n)}(\Phi_n, \Psi_n)] &\leq \lim_{n \rightarrow \infty} \left\{ \exp\{-nJ_1^{(n)}(R(\Phi_n) - \ln \alpha_n/n)\} \right. \\ &\quad + \exp\{-nJ_2^{(n)}(R(\Psi_n) - \ln \beta_n/n)\} \\ &\quad \left. + \exp\{-nJ_3^{(n)}(R(\Phi_n) + R(\Psi_n) - \ln \gamma_n/n)\} \right\} \\ &= 0, \end{aligned}$$

即所有满足

$$R_1 > H(X|Y), R_2 > H(Y|X), R_1 + R_2 > H(XY)$$

的速率对都是可达的, 由可达性的定义还可以证明其闭包是可达的, 因此定理得证。□

3.4 相关一般信源下 Slepian-Wolf 定理正命题的证明

在第3.3节中, 我们运用分析的方法在相关平稳无记忆信源下证明了 Slepian-Wolf 定理的正命题部分, 这种思路几乎是 Gallager 在信道编码中所运用技巧^[43] 的翻版,

因而也就存在其局限性。我们注意到，如果信源不再是平稳无记忆的，则错误指数 (3.3.8) 将可能不再是一个常数，而是关于 n 的一个函数，所以 Gallager 的方法最多只能证明 (3.3.7) 中的每一项是小于 1 的，却无法证明其收敛于 0，这也正是为什么这数十年间，关于 Gallager 方法的讨论与应用都仅仅局限于离散无记忆信道 (Discrete Memoryless Channel, DMC)。在本节中，我们将发展一种新的方法来分析错误指数，从而可以在相关一般信源下证明 Slepian-Wolf 定理的正命题部分。此外，我们也将该方法应用于信道编码中的 Gallager 限^[43]，相应地将信道编码定理的正命题部分推广到了一般信道 (General Channel)。所有这一切说明，由 Gallager 方法推导出的错误概率上界即使在一般信源或一般信道下仍然是十分紧的，而在我们之前，还没有人注意到这一点。笔者甚至有如下猜测 (类似的猜测也存在于信道编码中)：

当 $n \rightarrow \infty$ 时，如果由 Gallager 方法得到的错误指数函数 (对由 (3.3.8) 所定义的各项错误指数函数取最小值) 收敛于某个关于速率对的非零函数，那么这个错误指数对于靠近可达速率区边界的某个集合中的速率对而言，就是其最大的可达错误指数。

当然上述的猜测是针对较为一般的信源，对于某些特殊信源，其错误指数最大甚至可能会达到无穷，上述的速率对集合极有可能退化为空集。

我们的主要方法就是运用不等式技巧对错误指数给出一个估计，并在信息谱理论^[49]的框架下建立有关的结果，所以在进入正题之前，我们首先需要引入信息谱理论中的两个新的极限概念。对于任意的一个实值随机变量序列 $\{Z_n\}_{n=1}^{\infty}$ ，我们定义其依概率上极限 (Limit Superior in Probability) 和依概率下极限 (Limit Inferior in Probability) 分别为

$$\text{p-lim sup}_{n \rightarrow \infty} Z_n \triangleq \inf \left\{ \alpha \mid \lim_{n \rightarrow \infty} \Pr\{Z_n > \alpha\} = 0 \right\} \quad (3.4.1)$$

和

$$\text{p-lim inf}_{n \rightarrow \infty} Z_n \triangleq \sup \left\{ \beta \mid \lim_{n \rightarrow \infty} \Pr\{Z_n < \beta\} = 0 \right\}. \quad (3.4.2)$$

现在，我们开始运用不等式技巧对错误指数进行估计。

引理 3.2 令 \mathbf{XY} 为一个相关一般信源，满足条件 $|\mathcal{X}| < \infty$ ，于是对于任意 $\delta > 0$ ，存在一个序列 $\{\rho_n\}_{n=1}^{\infty}$ 定义为

$$\rho_n \triangleq \begin{cases} \min\left\{\frac{-\frac{1}{2} \ln \epsilon_n(\delta)}{n(\ln |\mathcal{X}| - \bar{H}(\mathbf{X}|\mathbf{Y}) - \delta)}, 1\right\}, & \bar{H}(\mathbf{X}|\mathbf{Y}) < \ln |\mathcal{X}| - \delta \\ 1, & \bar{H}(\mathbf{X}|\mathbf{Y}) \geq \ln |\mathcal{X}| - \delta \end{cases} \quad (3.4.3a)$$

$$\bar{H}(\mathbf{X}|\mathbf{Y}) \geq \ln |\mathcal{X}| - \delta \quad (3.4.3b)$$

使得对于任何 $n \in \mathbb{Z}^+$,

$$J_{10}^{(n)}(\rho_n) \leq \rho_n(\bar{H}(\mathbf{X}|\mathbf{Y}) + \delta) + \frac{3 \ln 2}{n}, \quad (3.4.4)$$

式中 $J_{10}^{(n)}(\rho)$ 由 (3.3.9) 定义, $\bar{H}(\mathbf{X}|\mathbf{Y})$ 为谱的条件上确界熵率 (Spectral Conditional Sup-Entropy Rate^[49]), 定义为

$$\bar{H}(\mathbf{X}|\mathbf{Y}) \triangleq \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{X^n|Y^n}(X^n|Y^n)}, \quad (3.4.5)$$

而

$$\epsilon_n(\delta) \triangleq \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{X^n|Y^n}(X^n|Y^n)} > \bar{H}(\mathbf{X}|\mathbf{Y}) + \delta\right\}. \quad (3.4.6)$$

引理3.2只给出了函数 (3.3.9) 的渐近特性, 函数 (3.3.10) 和 (3.3.11) 的渐近特性类似, 只需将相应的随机变量作一下替换。

证明: 不失一般性, 我们假设对于所有的 $y^n \in \mathcal{Y}^n$, $P_{Y^n}(y^n) > 0$ 。然后, 我们定义

$$A(y^n, \delta) = \left\{x^n \in \mathcal{X}^n \mid \frac{1}{n} \ln \frac{1}{P_{X^n|Y^n}(x^n|y^n)} \leq \bar{H}(\mathbf{X}|\mathbf{Y}) + \delta\right\}, \quad (3.4.7)$$

于是由定义 (3.4.5) 和 (3.4.6) 有

$$\sum_{y^n \in \mathcal{Y}^n} P_{X^n Y^n}(A(y^n, \delta)^c, y^n) = \epsilon_n(\delta), \quad \lim_{n \rightarrow \infty} \epsilon_n(\delta) = 0.$$

我们再定义

$$B(\delta) = \left\{y^n \in \mathcal{Y}^n \mid P_{X^n|Y^n}(A(y^n, \delta)^c|y^n) < \epsilon_n(\delta)^{\frac{1}{2}}\right\}, \quad (3.4.8)$$

由此可推出

$$\begin{aligned} P_{Y^n}(B(\delta)^c) &= \sum_{y^n \in B(\delta)^c} P_{Y^n}(y^n) \\ &\leq \sum_{y^n \in B(\delta)^c} \frac{P_{X^n Y^n}(A(y^n, \delta)^c, y^n)}{\epsilon_n(\delta)^{\frac{1}{2}}} \\ &\leq \frac{\sum_{y^n \in \mathcal{Y}^n} P_{X^n Y^n}(A(y^n, \delta)^c, y^n)}{\epsilon_n(\delta)^{\frac{1}{2}}} \\ &= \epsilon_n(\delta)^{\frac{1}{2}}. \end{aligned} \quad (3.4.9)$$

于是,

$$\begin{aligned} \exp\{nJ_{10}^{(n)}(\rho_n)\} &= \sum_{y^n \in B(\delta)} P_{Y^n}(y^n) \left(\sum_{x^n \in A(y^n, \delta)} P_{X^n|Y^n}(x^n|y^n)^{\frac{1}{1+\rho_n}} \right. \\ &\quad \left. + \sum_{x^n \in A(y^n, \delta)^c} P_{X^n|Y^n}(x^n|y^n)^{\frac{1}{1+\rho_n}} \right)^{1+\rho_n} \\ &\quad + \sum_{y^n \in B(\delta)^c} \left(\sum_{x^n \in \mathcal{X}^n} P_{X^n Y^n}(x^n|y^n)^{\frac{1}{1+\rho_n}} \right)^{1+\rho_n} \\ &\stackrel{(a)}{\leq} \sum_{y^n \in B(\delta)} P_{Y^n}(y^n) \left(e^{\frac{n\rho_n}{1+\rho_n}(\bar{H}(\mathbf{X}|\mathbf{Y})+\delta)} \right) \end{aligned}$$

$$\begin{aligned}
& + |\mathcal{X}|^{\frac{n\rho_n}{1+\rho_n}} P_{X^n|Y^n}(A(y^n, \delta)^c | y^n)^{\frac{1}{1+\rho_n}})^{1+\rho_n} \\
& + \sum_{y^n \in B(\delta)^c} |\mathcal{X}|^{n\rho_n} P_{Y^n}(y^n) \\
& \stackrel{(b)}{\leq} \sum_{y^n \in B(\delta)} P_{Y^n}(y^n) \left(e^{\frac{n\rho_n(\bar{H}(\mathbf{X}|\mathbf{Y})+\delta)}{1+\rho_n}} + |\mathcal{X}|^{\frac{n\rho_n}{1+\rho_n}} \epsilon_n(\delta)^{\frac{1}{2(1+\rho_n)}} \right)^{1+\rho_n} \\
& \quad + |\mathcal{X}|^{n\rho_n} \epsilon_n(\delta)^{\frac{1}{2}} \\
& \stackrel{(c)}{\leq} e^{n\rho_n(\bar{H}(\mathbf{X}|\mathbf{Y})+\delta)+2\ln 2} + |\mathcal{X}|^{n\rho_n} \epsilon_n(\delta)^{\frac{1}{2}} \\
& \stackrel{(d)}{\leq} e^{n\rho_n(\bar{H}(\mathbf{X}|\mathbf{Y})+\delta)+3\ln 2},
\end{aligned}$$

式中 (a) 利用了 (3.4.7) 和 Jensen 不等式 (或 Hölder 不等式), (b) 利用了 (3.4.8) 和 (3.4.9), (c) 和 (d) 利用了 (3.4.3)。故 (3.4.4) 得证。□

利用引理3.2的结果, 我们得到如下关于错误概率指数的定理。

定理 3.3 对于一个相关一般信源 \mathbf{XY} , 错误概率指数 $J_i^{(n)}(R)$ ($1 \leq i \leq 3$) 有如下性质:

若 $R > \bar{H}(\mathbf{X}|\mathbf{Y})$, 则当 $n \rightarrow \infty$ 时, $nJ_1^{(n)}(R) \rightarrow \infty$

若 $R > \bar{H}(\mathbf{Y}|\mathbf{X})$, 则当 $n \rightarrow \infty$ 时, $nJ_2^{(n)}(R) \rightarrow \infty$

若 $R > \bar{H}(\mathbf{XY})$, 则当 $n \rightarrow \infty$ 时, $nJ_3^{(n)}(R) \rightarrow \infty$

式中 $\bar{H}(\mathbf{X}|\mathbf{Y})$ 、 $\bar{H}(\mathbf{Y}|\mathbf{X})$ 和 $\bar{H}(\mathbf{XY})$ 为信息谱理论^[49] 中定义的谱的 (条件) 上确界熵率。

证明: 由引理3.2知, 对于任意的 $\delta > 0$,

$$nJ_1^{(n)}(R) \geq n(\rho_n R - J_{10}^{(n)}(\rho_n)) \geq n\rho_n(R - \bar{H}(\mathbf{X}|\mathbf{Y}) - \delta) - 3\ln 2, \quad (3.4.10)$$

式中 ρ_n 由 (3.4.3) 定义。因为当 $n \rightarrow \infty$ 时, $n\rho_n \rightarrow \infty$, 所以当 $n \rightarrow \infty$, 对于充分小的 δ , 下界 (3.4.10) 也趋于无穷, 于是 $nJ_1^{(n)}(R) \rightarrow \infty$ 。同理可证明定理中关于指数 $J_2^{(n)}(R)$ 和 $J_3^{(n)}(R)$ 的性质。□

运用定理3.3, 就可以在相关一般信源的条件下证明 Slepian-Wolf 定理的正命题部分。

定理 3.4 (Slepian-Wolf 定理正命题部分 (一般信源)) 若相关信源为一般信源 \mathbf{XY} , 则以下区域

$$\{(R_1, R_2) : R_1 \geq \bar{H}(\mathbf{X}|\mathbf{Y}), R_2 \geq \bar{H}(\mathbf{Y}|\mathbf{X}), R_1 + R_2 \geq \bar{H}(\mathbf{XY})\} \quad (3.4.11)$$

内的速率对是可达的。

证明： 证明略。其主要思路与定理3.3.26的证明类似，只不过应用定理3.3而不是推论3.1来完成证明。 \square

运用相似的方法，我们也证明了信道编码中 Gallager 限在一般信道（General Channel）下是十分紧的，即可以证明一般信道下信道编码定理的正命题部分。

首先定义一般信道为序列 $\mathbf{W} = \{W^n\}_{n=1}^{\infty}$ ，其中 $W^n = W^n(\cdot|\cdot)$ 是一个任意的条件概率分布，对于每个 $n \in \mathbb{Z}^+$ 满足

$$\sum_{y^n \in \mathcal{Y}^n} W^n(y^n|x^n) = 1, \quad \forall x^n \in \mathcal{X}^n.$$

其次，定义 Gallager 限中的一个重要函数

$$E_0^{(n)}(\rho, \mathbf{X}) \triangleq -\frac{1}{n} \ln \sum_{y^n \in \mathcal{Y}^n} \left(\sum_{x^n \in \mathcal{X}^n} P_{X^n}(x^n) W^n(y^n|x^n)^{1/(1+\rho)} \right)^{1+\rho}. \quad (3.4.12)$$

于是，我们有如下引理。

引理 3.3 令 \mathbf{X} 为一个一般信源， \mathbf{W} 为一个一般信道，则对于任意的 $0 < \delta < \underline{I}(\mathbf{X}; \mathbf{Y})$ ，存在一个序列 $\{\rho_n\}_{n=1}^{\infty}$ 定义为

$$\rho_n = \min \left\{ \frac{-\frac{1}{2} \ln \epsilon_n(\delta)}{n(\underline{I}(\mathbf{X}; \mathbf{Y}) - \delta)}, 1 \right\}, \quad (3.4.13)$$

使得对于任意的 $n \in \mathbb{Z}^+$,

$$E_0^{(n)}(\rho_n, \mathbf{X}) \geq \rho_n(\underline{I}(\mathbf{X}; \mathbf{Y}) - \delta) - \frac{3 \ln 2}{n}, \quad (3.4.14)$$

式中 \mathbf{Y} 为信道的输出，而 $\underline{I}(\mathbf{X}; \mathbf{Y})$ 为谱的下确界互信息率（spectral inf-mutual information rate^[49]），定义为

$$\underline{I}(\mathbf{X}; \mathbf{Y}) \triangleq \text{p-lim inf}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{W^n(Y^n|X^n)}{P_{Y^n}(Y^n)}, \quad (3.4.15)$$

而

$$\epsilon_n(\delta) \triangleq \Pr \left\{ \frac{1}{n} \ln \frac{W^n(Y^n|X^n)}{P_{Y^n}(Y^n)} < \underline{I}(\mathbf{X}; \mathbf{Y}) - \delta \right\}. \quad (3.4.16)$$

证明： 不失一般性，我们假设对于所有的 $y^n \in \mathcal{Y}^n$ ， $P_{Y^n}(y^n) > 0$ 。然后，我们定义

$$A(y^n, \delta) = \left\{ x^n \in \mathcal{X}^n \mid \frac{1}{n} \ln \frac{W^n(y^n|x^n)}{P_{Y^n}(y^n)} \geq \underline{I}(\mathbf{X}; \mathbf{Y}) - \delta \right\}, \quad (3.4.17)$$

于是由定义 (3.4.15) 和 (3.4.16) 有

$$\sum_{y^n \in \mathcal{Y}^n} P_{X^n Y^n}(A(y^n, \delta)^c, y^n) = \epsilon_n(\delta), \quad \lim_{n \rightarrow \infty} \epsilon_n(\delta) = 0.$$

我们再定义

$$B(\delta) = \left\{ y^n \in \mathcal{Y}^n \mid P_{X^n|Y^n}(A(y^n, \delta)^c | y^n) < \epsilon_n(\delta)^{\frac{1}{2}} \right\}, \quad (3.4.18)$$

由此可推出

$$\begin{aligned} P_{Y^n}(B(\delta)^c) &= \sum_{y^n \in B(\delta)^c} P_{Y^n}(y^n) \\ &\leq \sum_{y^n \in B(\delta)^c} \frac{P_{X^n Y^n}(A(y^n, \delta)^c, y^n)}{\epsilon_n(\delta)^{\frac{1}{2}}} \\ &\leq \frac{\sum_{y^n \in \mathcal{Y}^n} P_{X^n Y^n}(A(y^n, \delta)^c, y^n)}{\epsilon_n(\delta)^{\frac{1}{2}}} \\ &= \epsilon_n(\delta)^{\frac{1}{2}}. \end{aligned} \quad (3.4.19)$$

于是,

$$\begin{aligned} \exp\{-nE_0^{(n)}(\rho_n, \mathbf{X})\} &= \sum_{y^n \in B(\delta)^c} \left(\sum_{x^n \in \mathcal{X}^n} P_{X^n}(x^n)^{\frac{\rho_n}{1+\rho_n}} P_{X^n Y^n}(x^n, y^n)^{\frac{1}{1+\rho_n}} \right)^{1+\rho_n} \\ &\quad + \sum_{y^n \in B(\delta)} P_{Y^n}(y^n) \left(\sum_{x^n \in \mathcal{X}^n} P_{X^n}(x^n)^{\frac{\rho_n}{1+\rho_n}} P_{X^n|Y^n}(x^n|y^n)^{\frac{1}{1+\rho_n}} \right)^{1+\rho_n} \\ &\stackrel{(a)}{\leq} \sum_{y^n \in B(\delta)^c} P_{Y^n}(y^n) + \sum_{y^n \in B(\delta)} P_{Y^n}(y^n) \\ &\quad \left[\sum_{x^n \in A(y^n, \delta)^c} P_{X^n}(x^n)^{\frac{\rho_n}{1+\rho_n}} P_{X^n|Y^n}(x^n|y^n)^{\frac{1}{1+\rho_n}} + \right. \\ &\quad \left. \sum_{x^n \in A(y^n, \delta)} P_{X^n|Y^n}(x^n|y^n) \left(\frac{P_{X^n}(x^n)}{P_{X^n|Y^n}(x^n|y^n)} \right)^{\frac{\rho_n}{1+\rho_n}} \right]^{1+\rho_n} \\ &\stackrel{(b)}{\leq} \epsilon_n(\delta)^{\frac{1}{2}} + \sum_{y^n \in B(\delta)} P_{Y^n}(y^n) \left(P_{X^n|Y^n}(A(y^n, \delta)^c | y^n)^{\frac{1}{1+\rho_n}} \right. \\ &\quad \left. + e^{-\frac{n\rho_n}{1+\rho_n}(\underline{I}(\mathbf{X}; \mathbf{Y}) - \delta)} \right)^{1+\rho_n} \\ &\stackrel{(c)}{\leq} \sum_{y^n \in B(\delta)} P_{Y^n}(y^n) \left(\epsilon_n(\delta)^{\frac{1}{2(1+\rho_n)}} + e^{-\frac{n\rho_n(\underline{I}(\mathbf{X}; \mathbf{Y}) - \delta)}{1+\rho_n}} \right)^{1+\rho_n} + \epsilon_n(\delta)^{\frac{1}{2}} \\ &\stackrel{(d)}{\leq} e^{-n\rho_n(\underline{I}(\mathbf{X}; \mathbf{Y}) - \delta) + 2 \ln 2} + \epsilon_n(\delta)^{\frac{1}{2}} \\ &\stackrel{(e)}{\leq} e^{-n\rho_n(\underline{I}(\mathbf{X}; \mathbf{Y}) - \delta) + 3 \ln 2}, \end{aligned}$$

式中 (a) 利用了 Hölder 不等式, (b) 利用了 (3.4.17)、(3.4.19) 与 Hölder 不等式, (c) 利用了 (3.4.18), (d) 和 (e) 利用了 (3.4.13)。故 (3.4.14) 得证。□

利用引理3.3的结果, 我们得到如下关于信道编码 ML 译码错误概率指数的定理。

定理 3.5 令 \mathbf{W} 为一个一般信道, 如果编码速率

$$R < C(\mathbf{W}) \triangleq \sup_{\mathbf{X}} \underline{I}(\mathbf{X}; \mathbf{Y}), \quad (3.4.20)$$

则函数

$$E^{(n)}(R) \triangleq \max_{X^n} \max_{0 \leq \rho \leq 1} \{E_0^{(n)}(\rho, \mathbf{X}) - \rho R\} \quad (3.4.21)$$

满足当 $n \rightarrow \infty$ 时, $nE^{(n)}(R) \rightarrow \infty$ 。

证明: 对于任意的速率 $R < C(\mathbf{W})$, 存在一个一般信源 \mathbf{X} 使得 $R < \underline{I}(\mathbf{X}; \mathbf{Y})$ 。然后由引理3.3, 对于任意的 $0 < \delta < \underline{I}(\mathbf{X}; \mathbf{Y})$ 有

$$nE^{(n)}(R) \geq n(E_0^{(n)}(\rho_n, \mathbf{X}) - \rho_n R) \geq n\rho_n(\underline{I}(\mathbf{X}; \mathbf{Y}) - \delta - R) - 3 \ln 2. \quad (3.4.22)$$

式中 ρ_n 由 (3.4.13) 定义。因为当 $n \rightarrow \infty$ 时, $n\rho_n \rightarrow \infty$, 所以当 $n \rightarrow \infty$ 时, 对于充分小的 δ , 下界 (3.4.22) 也趋于无穷, 于是 $nE^{(n)}(R) \rightarrow \infty$ 。□

由定理3.5就可以很容易地证明信道编码定理的正命题部分。

定理 3.6 (信道编码定理正命题部分 (一般信源)) 设信道为一个一般信道 \mathbf{W} , 则任何速率 $R < C(\mathbf{W})$ 都是可达的。

证明: 根据 [44, (5.6.12)] 有

$$P_e^{(n)} \leq \exp\{-nE^{(n)}(R)\},$$

故结合定理3.5, 就可以证明任何速率 $R < C(\mathbf{W})$ 都是可达的。□

3.5 平稳无记忆信源下线性 Slepian-Wolf 系统 MAP 译码错误概率的分析

在上文中, 我们对任意 Slepian-Wolf 系统的 MAP 译码错误概率进行了分析, 其中的编码器可以是线性的, 也可以是非线性的。然而, 在实际中, 几乎所有的 Slepian-Wolf 系统都是由线性信道码构造的, 所以有必要对基于线性信道码的线性 Slepian-Wolf 系统作进一步的性能分析。

在下面的分析中, 我们将假设相关信源是平稳无记忆的, 并且我们还需要引入一些与线性 Slepian-Wolf 系统有关的定义与符号。

我们假设字符集 \mathcal{X} 和 \mathcal{Y} 分别为 Galois 域 (有限域) $GF(q_1)$ 和 $GF(q_2)$, 于是线性编码器序列对 (ϕ, ψ) 可以定义为两个线性映射序列 $\phi_n: \mathcal{X}^n \rightarrow \mathcal{X}^{l_n}$ 和 $\psi_n: \mathcal{Y}^n \rightarrow \mathcal{Y}^{m_n}$ 。一个线性编码器 ϕ_n 就是一个与线性信道码相关联的偶校验矩阵, 线性信道码可以定义为 $C_{\phi_n} = \{x^n \in \mathcal{X}^n | \phi_n(x^n) = 0^{l_n}\}$ 。一个线性信道码的特性可以用其码谱来很好地描述。一个信道码 C_{ϕ_n} 的谱定义为 $\{S_u(C_{\phi_n})\}_{u \in \mathcal{T}_n(\mathcal{X})}$, 式中 $S_u(C_{\phi_n})$ 为 C_{ϕ_n} 中类型为 \mathbf{u} 的码字数, 而一个序列 (或码字) $x^n \in \mathcal{X}^n$ 的类型 $\mathbf{u} = \{u_i\}_{i \in \mathcal{X}}$ 为一个 q_1 维的整数向量, u_i 表示 x^n 中符号 i 出现的次数。我们将 \mathcal{X}^n 中所有 n 长

序列的可能类型的集合记为 $\mathcal{T}_n(\mathcal{X})$ ，同时定义 $\mathcal{T}'_n(\mathcal{X}) \triangleq \mathcal{T}_n(\mathcal{X}) \setminus \{\text{type}(0^n)\}$ 。于是，线性编码器 ϕ_n 的谱可以定义为其对应的信道码 C_{ϕ_n} 的谱，而一个随机编码器 Φ_n 的平均谱可以记为 $\{E[S_u(C_{\Phi_n})]\}_{u \in \mathcal{T}_n(\mathcal{X})}$ 。类似的符号也应用于编码器 ψ_n 和二维编码器 (ϕ_n, ψ_n) 。对于后者，我们将 (ϕ_n, ψ_n) 的谱记为 $\{S_w(C_{(\phi_n, \psi_n)})\}_{w \in \mathcal{T}_n(\mathcal{X} \times \mathcal{Y})}$ ，式中 $w = \{w_{i,j}\}_{(i,j) \in \mathcal{X} \times \mathcal{Y}}$ 。此外，我们定义投影 (Projection) 映射 $\pi_1 : \mathcal{T}_n(\mathcal{X} \times \mathcal{Y}) \rightarrow \mathcal{T}_n(\mathcal{X})$ 和 $\pi_2 : \mathcal{T}_n(\mathcal{X} \times \mathcal{Y}) \rightarrow \mathcal{T}_n(\mathcal{Y})$ 为

$$\pi_1(\mathbf{w}) = \left\{ \sum_{j \in \mathcal{Y}} w_{i,j} \right\}_{i \in \mathcal{X}}, \quad \pi_2(\mathbf{w}) = \left\{ \sum_{i \in \mathcal{X}} w_{i,j} \right\}_{j \in \mathcal{Y}},$$

同时定义嵌入 (Injection) 映射 $\iota_1 : \mathcal{T}_n(\mathcal{X}) \rightarrow \mathcal{T}_n(\mathcal{X} \times \mathcal{Y})$ 和 $\iota_2 : \mathcal{T}_n(\mathcal{Y}) \rightarrow \mathcal{T}_n(\mathcal{X} \times \mathcal{Y})$ 分别为

$$\begin{aligned} \iota_1(\mathbf{u})_{i,0} &= u_i, & \text{当 } j \neq 0 \text{ 时, } \iota_1(\mathbf{u})_{i,j} &= 0; \\ \iota_2(\mathbf{v})_{0,j} &= v_j, & \text{当 } i \neq 0 \text{ 时, } \iota_2(\mathbf{v})_{i,j} &= 0. \end{aligned}$$

由上述定义，我们就可以定义 $\mathcal{T}'_n(\mathcal{X} \times \mathcal{Y}) \triangleq \pi_1^{-1}(\mathcal{T}'_n(\mathcal{X})) \cap \pi_2^{-1}(\mathcal{T}'_n(\mathcal{Y}))$ 。

我们还需要引入记号 $\mathbf{B}(XY) = \{B_{i,j}(XY)\}_{(i,j) \in \mathcal{X} \times \mathcal{Y}}$ ，因为它将出现在后面所推导出的公式中，其定义如下：

$$B_{i,j}(XY) \triangleq \sum_{xy \in \mathcal{X} \times \mathcal{Y}} \sqrt{P_{XY}(xy)P_{XY}((x+i)(y+j))}.$$

由 Cauchy-Schwartz 不等式，我们知道

$$B_{i,j}(XY) \leq \sqrt{\sum_{xy \in \mathcal{X} \times \mathcal{Y}} P_{XY}(xy)} \sqrt{\sum_{xy \in \mathcal{X} \times \mathcal{Y}} P_{XY}((x+i)(y+j))} = 1,$$

当且仅当 $P_{XY}(xy)$ 在由 (i, j) 生成的循环加法子群的所有陪集中取相同的值时取等号。给定一个类型 $\mathbf{w} \in \mathcal{T}_n(\mathcal{X} \times \mathcal{Y})$ ，我们进一步定义

$$[\mathbf{B}(XY)]^{\mathbf{w}} \triangleq \prod_{(i,j) \in \mathcal{X} \times \mathcal{Y}} [B_{i,j}(XY)]^{w_{i,j}}.$$

现在，我们开始分析平稳无记忆信源下线性 Slepian-Wolf 系统的性能。

定理 3.7 对于一个相关的平稳无记忆信源 XY 和一对给定的随机线性编码器 Φ_n 和 Ψ_n （独立于信源），其平均 MAP 译码错误概率满足

$$\begin{aligned} E[P_e^{(n)}(\Phi_n, \Psi_n)] &\leq \sum_{u \in U} E[S_u(C_{\Phi_n})][\mathbf{B}(XY)]^{\iota_1(u)} + \exp\{-n\tilde{J}_1(R(\Phi_n) - \ln \alpha_n/n)\} \\ &+ \sum_{v \in V} E[S_v(C_{\Psi_n})][\mathbf{B}(XY)]^{\iota_2(v)} + \exp\{-n\tilde{J}_2(R(\Psi_n) - \ln \beta_n/n)\} \\ &+ \sum_{w \in W} E[S_w(C_{(\Phi_n, \Psi_n)})][\mathbf{B}(XY)]^w + \exp\{-n\tilde{J}_3(R(\Phi_n) + R(\Psi_n) - \ln \gamma_n/n)\}, \end{aligned} \quad (3.5.1)$$

式中 U 、 V 和 W 分别为 $\mathcal{T}'_n(\mathcal{X})$ 、 $\mathcal{T}'_n(\mathcal{Y})$ 和 $\mathcal{T}'_n(\mathcal{X} \times \mathcal{Y})$ 的子集，且

$$\tilde{J}_i(R) \triangleq \max_{0 \leq \rho_i \leq 1} \{\rho_i R - \tilde{J}_{i0}(\rho_i)\}, \quad i = 1, 2, 3 \quad (3.5.2)$$

$$\tilde{J}_{10}(\rho_1) \triangleq \ln \sum_{y \in \mathcal{Y}} \left(\sum_{x \in \mathcal{X}} P_{XY}(xy)^{1/(1+\rho_1)} \right)^{1+\rho_1}, \quad (3.5.3)$$

$$\tilde{J}_{20}(\rho_2) \triangleq \ln \sum_{x \in \mathcal{X}} \left(\sum_{y \in \mathcal{Y}} P_{XY}(xy)^{1/(1+\rho_2)} \right)^{1+\rho_2}, \quad (3.5.4)$$

$$\tilde{J}_{30}(\rho_3) \triangleq \ln \left(\sum_{xy \in \mathcal{X} \times \mathcal{Y}} P_{XY}(xy)^{1/(1+\rho_3)} \right)^{1+\rho_3}, \quad (3.5.5)$$

$$\alpha_n = \max_{u \in U^c} \frac{E[S_u(C_{\Phi_n})] q_1^{l_n}}{\binom{n}{u}}, \quad (3.5.6)$$

$$\beta_n = \max_{v \in V^c} \frac{E[S_v(C_{\Psi_n})] q_2^{m_n}}{\binom{n}{v}}, \quad (3.5.7)$$

$$\gamma_n = \max_{w \in W^c} \frac{E[S_w(C_{(\Phi_n, \Psi_n)})] q_1^{l_n} q_2^{m_n}}{\binom{n}{w}}, \quad (3.5.8)$$

式中 $U^c \triangleq \mathcal{T}'_n(\mathcal{X}) \setminus U$ ， $V^c \triangleq \mathcal{T}'_n(\mathcal{Y}) \setminus V$ ， $W^c \triangleq \mathcal{T}'_n(\mathcal{X} \times \mathcal{Y}) \setminus W$ ， $\binom{n}{t} \triangleq n! / \prod_i t_i$.

证明： 与定理3.1的证明类似，我们需要考虑以下三个 MAP 译码错误事件。

$$\begin{aligned} E_1(\phi_n, \psi_n) &\triangleq \{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n \mid \exists \hat{x}^n \neq x^n, \\ &\text{s. t. } \phi_n(\hat{x}^n) = \phi_n(x^n), P_{X^n Y^n}(\hat{x}^n y^n) \geq P_{X^n Y^n}(x^n y^n)\}, \\ E_2(\phi_n, \psi_n) &\triangleq \{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n \mid \exists \hat{y}^n \neq y^n, \\ &\text{s. t. } \psi_n(\hat{y}^n) = \psi_n(y^n), P_{X^n Y^n}(x^n \hat{y}^n) \geq P_{X^n Y^n}(x^n y^n)\}, \\ E_3(\phi_n, \psi_n) &\triangleq \{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n \mid \exists \hat{x}^n \neq x^n, \exists \hat{y}^n \neq y^n, \\ &\text{s. t. } \phi_n(\hat{x}^n) = \phi_n(x^n), \psi_n(\hat{y}^n) = \psi_n(y^n), P_{X^n Y^n}(\hat{x}^n \hat{y}^n) \geq P_{X^n Y^n}(x^n y^n)\}. \end{aligned}$$

由于对于任意的置换 $\delta_n \in S_n$ (S_n 表示定义在 n 个字符上的对称群)，由平稳无记忆信源生成的随机序列 $X^n Y^n$ 与置换后的随机序列 $\delta_n(X^n Y^n)$ 具有相同的概率分布，即 $\delta_n(X^n Y^n) \stackrel{d}{=} X^n Y^n$ ，式中 $\delta_n(x^n y^n) \triangleq (x_{\delta_n(1)} y_{\delta_n(1)}, \dots, x_{\delta_n(n)} y_{\delta_n(n)})$ ，所以我们考虑一个在 S_n 上以等概率抽取的随机置换 Δ_n ，并令 $\hat{\Phi}_n = \Phi_n \circ \Delta_n$ ， $\hat{\Psi}_n = \Psi_n \circ \Delta_n$ 。于是平均 MAP 译码错误概率可以估计如下。

$$\begin{aligned} E[P_e^{(n)}(\Phi_n, \Psi_n)] &= E[P_e^{(n)}(\hat{\Phi}_n, \hat{\Psi}_n)] \leq E\left[\sum_{i=1}^3 \Pr\{X^n Y^n \in E_i(\hat{\Phi}_n, \hat{\Psi}_n)\}\right] \\ &= \sum_{i=1}^3 \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) E[1_{E_i(\hat{\Phi}_n, \hat{\Psi}_n)}(x^n y^n)] \quad (3.5.9) \end{aligned}$$

最后一个不等式利用了随机编码器与相关信源相独立的事实。我们首先考虑如何估计求和式 (3.5.9) 中第一项的上界。

受 [10] 中方法的启发, 我们考虑一个改进的不等式

$$1_{E_1(\hat{\phi}_n, \hat{\psi}_n)}(x^n y^n) \leq \frac{\sum_{\text{type}(\hat{x}^n - x^n) \in U} \sqrt{P_{X^n Y^n}(\hat{x}^n y^n)} 1_{\hat{\phi}_n^{-1}(\hat{\phi}_n(x^n))}(\hat{x}^n)}{\sqrt{P_{X^n Y^n}(x^n y^n)}} + \left(\frac{\sum_{\text{type}(\hat{x}^n - x^n) \in U^c} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)} 1_{\hat{\phi}_n^{-1}(\hat{\phi}_n(x^n))}(\hat{x}^n)}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1},$$

式中 $\rho_1 \in [0, 1]$ 。于是由 Jensen 不等式有

$$E[1_{E_1(\hat{\phi}_n, \hat{\psi}_n)}(x^n y^n)] \leq \frac{\sum_{\text{type}(\hat{x}^n - x^n) \in U} \sqrt{P_{X^n Y^n}(\hat{x}^n y^n)} \Pr\{\hat{\Phi}_n(\hat{x}^n) = \hat{\Phi}_n(x^n)\}}{\sqrt{P_{X^n Y^n}(x^n y^n)}} + \left(\frac{\sum_{\text{type}(\hat{x}^n - x^n) \in U^c} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)} \Pr\{\hat{\Phi}_n(\hat{x}^n) = \hat{\Phi}_n(x^n)\}}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1}.$$

然后, 我们计算概率 $\Pr\{\hat{\Phi}_n(\hat{x}^n) = \hat{\Phi}_n(x^n)\}$ 。

$$\begin{aligned} \Pr\{\hat{\Phi}_n(\hat{x}^n) = \hat{\Phi}_n(x^n)\} &= \sum_{\phi_n} P_{\Phi_n}(\phi_n) \sum_{\delta_n} P_{\Delta_n}(\delta_n) \Pr\{\phi_n(\delta_n(\hat{x}^n - x^n)) = 0^{ln}\} \\ &= \sum_{\phi_n} P_{\Phi_n}(\phi_n) \frac{S_{\text{type}(\hat{x}^n - x^n)}(C_{\Phi_n}) \prod_i \text{type}(\hat{x}^n - x^n)_i!}{n!} \\ &= \frac{E[S_{\text{type}(\hat{x}^n - x^n)}(C_{\Phi_n})]}{\binom{n}{\text{type}(\hat{x}^n - x^n)}}. \end{aligned} \quad (3.5.10)$$

于是,

$$\begin{aligned} &E[1_{E_1(\hat{\phi}_n, \hat{\psi}_n)}(x^n y^n)] \\ &\leq \frac{\sum_{\text{type}(\hat{x}^n - x^n) \in U} \sqrt{P_{X^n Y^n}(\hat{x}^n y^n)} E[S_{\text{type}(\hat{x}^n - x^n)}(C_{\Phi_n})] / \binom{n}{\text{type}(\hat{x}^n - x^n)}}{\sqrt{P_{X^n Y^n}(x^n y^n)}} + \left(\frac{\sum_{\text{type}(\hat{x}^n - x^n) \in U^c} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)} E[S_{\text{type}(\hat{x}^n - x^n)}(C_{\Phi_n})] / \binom{n}{\text{type}(\hat{x}^n - x^n)}}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1} \\ &\leq \frac{\sum_{\mathbf{u} \in U} E[S_{\mathbf{u}}(C_{\Phi_n})] \binom{n}{\mathbf{u}}^{-1} \sum_{\text{type}(\hat{x}^n) = \mathbf{u}} \sqrt{P_{X^n Y^n}((x^n + \tilde{x}^n) y^n)}}{\sqrt{P_{X^n Y^n}(x^n y^n)}} \\ &\quad + \alpha_n^{\rho_1} q_1^{-\rho_1 l_n} \left(\frac{\sum_{\hat{x}^n \in \mathcal{X}^n} P_{X^n Y^n}(\hat{x}^n y^n)^{1/(1+\rho_1)}}{P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)}} \right)^{\rho_1}. \end{aligned}$$

因此, (3.5.9) 中第一项的上界为

$$\sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) E[1_{E_1(\hat{\phi}_n, \hat{\psi}_n)}(x^n y^n)]$$

$$\begin{aligned}
&\leq \sum_{\mathbf{u} \in U} E[S_{\mathbf{u}}(C_{\Phi_n})] \binom{n}{\mathbf{u}}^{-1} \sum_{\text{type}(\tilde{x}^n) = \mathbf{u}} \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} \sqrt{P_{X^n Y^n}(x^n y^n) P_{X^n Y^n}((x^n + \tilde{x}^n) y^n)} \\
&\quad + \alpha_n^{\rho_1} q_1^{-\rho_1 l_n} \sum_{y^n \in \mathcal{Y}^n} \left(\sum_{x^n \in \mathcal{X}^n} P_{X^n Y^n}(x^n y^n)^{1/(1+\rho_1)} \right)^{1+\rho_1} \\
&\stackrel{(a)}{=} \sum_{\mathbf{u} \in U} E[S_{\mathbf{u}}(C_{\Phi_n})] \binom{n}{\mathbf{u}}^{-1} \sum_{\text{type}(\tilde{x}^n) = \mathbf{u}} \prod_{i=1}^n \sum_{xy \in \mathcal{X} \times \mathcal{Y}} \sqrt{P_{XY}(xy) P_{XY}((x + \tilde{x}_i) y)} \\
&\quad + \alpha_n^{\rho_1} q_1^{-\rho_1 l_n} \sum_{y^n \in \mathcal{Y}^n} \prod_{i=1}^n \left(\sum_{x \in \mathcal{X}} P_{XY}(xy_i)^{1/(1+\rho_1)} \right)^{1+\rho_1} \\
&= \sum_{\mathbf{u} \in U} E[S_{\mathbf{u}}(C_{\Phi_n})] \prod_{i \in \mathcal{X}} [B_{i,0}(XY)]^{u_i} + \alpha_n^{\rho_1} q_1^{-\rho_1 l_n} \sum_{y \in \mathcal{Y}} \left(\sum_{x \in \mathcal{X}} P_{XY}(xy)^{1/(1+\rho_1)} \right)^{n(1+\rho_1)} \\
&= \sum_{\mathbf{u} \in U} E[S_{\mathbf{u}}(C_{\Phi_n})] [\mathbf{B}(XY)]^{l_1(\mathbf{u})} + \exp\{-n[\rho_1(R(\Phi_n) - \ln \alpha_n/n) - \tilde{J}_{10}(\rho_1)]\},
\end{aligned}$$

式中 (a) 与推论3.2的证明类似, 利用了信源的平稳无记忆特性与和式乘积的算术法则。通过使其第二项的错误指数在 $\rho_1 \in [0, 1]$ 上最大化, 我们就获得了最紧的上界。式 (3.5.9) 中的后两项也可以作类似处理, 从而定理得证。□

定理3.7中的 (3.5.6)、(3.5.7) 和 (3.5.8) 是三个关于 Slepian-Wolf 系统渐近性能的重要指标。只有当

$$\lim_{n \rightarrow \infty} \frac{\ln \alpha_n}{n} = \lim_{n \rightarrow \infty} \frac{\ln \beta_n}{n} = \lim_{n \rightarrow \infty} \frac{\ln \gamma_n}{n} = 0 \quad (3.5.11)$$

时, 系统才能渐近达到 Slepian-Wolf 限。以 α_n 为例, 我们注意到

$$\alpha_n = \max_{\mathbf{u} \in U^c} \frac{E[S_{\mathbf{u}}(C_{\Phi_n})] q_1^{l_n}}{\binom{n}{\mathbf{u}}} = \max_{\mathbf{u} \in U^c} \frac{E[S_{\mathbf{u}}(C_{\Phi_n})] / q_1^{n-l_n}}{\binom{n}{\mathbf{u}} / q_1^n},$$

显然, 其分母表示的就是在所有 n 长序列中随机选取一个序列, 其类型为 \mathbf{u} 的概率, 即相当于随机码的谱, 所以, α_n 、 β_n 和 γ_n 表示的就是线性码谱逼近随机码谱的程度, 而我们所期望的好码就是能够渐近逼近随机码谱的线性码, 即满足 (3.5.11)。

接下来的问题是如何计算 α_n 、 β_n 和 γ_n 。显然, 我们必须首先计算出码谱 $E[S_{\mathbf{u}}(C_{\Phi_n})]$ 、 $E[S_{\mathbf{v}}(C_{\Psi_n})]$ 和 $E[S_{\mathbf{w}}(C_{(\Phi_n, \Psi_n)})]$ 。前两项是必须计算的, 那么可不可以利用前两项的结果来计算第三项码谱呢? 在一般情形下, 这是不行的, 但通过附加一些额外的条件, 还是可以做到的。

定理 3.8 若编码器 Φ_n 和 Ψ_n 是相互独立的, 则

$$E[S_{\mathbf{w}}(C_{(\Phi_n, \Psi_n)})] \leq E[S_{\pi_1(\mathbf{w})}(C_{\Phi_n})] E[S_{\pi_2(\mathbf{w})}(C_{\Psi_n})], \quad (3.5.12)$$

若 Ψ_n 对于任意的置换 $\delta_n \in S_n$ 还满足 $\Psi_n \circ \delta_n \stackrel{d}{=} \Psi_n$, 则

$$\frac{E[S_{\mathbf{w}}(C_{(\Phi_n, \Psi_n)})]}{\binom{n}{\mathbf{w}}} = \frac{E[S_{\pi_1(\mathbf{w})}(C_{\Phi_n})]}{\binom{n}{\pi_1(\mathbf{w})}} \cdot \frac{E[S_{\pi_2(\mathbf{w})}(C_{\Psi_n})]}{\binom{n}{\pi_2(\mathbf{w})}}. \quad (3.5.13)$$

证明： 因为编码器 Φ_n 和 Ψ_n 是相互独立的，所以

$$\begin{aligned}
& E[S_w(C_{(\Phi_n, \Psi_n)})] \\
&= \sum_{\phi_n, \psi_n} P_{\Phi_n}(\phi_n) P_{\Psi_n}(\psi_n) \sum_{\text{type}(x^n y^n) = w} 1_{\phi_n(x^n)=0^{l_n}}(x^n) 1_{\psi_n(y^n)=0^{m_n}}(y^n) \\
&= \sum_{\text{type}(x^n y^n) = w} \sum_{\phi_n} P_{\Phi_n}(\phi_n) 1_{\phi_n(x^n)=0^{l_n}}(x^n) \sum_{\psi_n} P_{\Psi_n}(\psi_n) 1_{\psi_n(y^n)=0^{m_n}}(y^n) \\
&\leq \sum_{\text{type}(x^n) = \pi_1(w)} \sum_{\text{type}(y^n) = \pi_2(w)} \sum_{\phi_n} P_{\Phi_n}(\phi_n) 1_{\phi_n(x^n)=0^{l_n}}(x^n) \sum_{\psi_n} P_{\Psi_n}(\psi_n) 1_{\psi_n(y^n)=0^{m_n}}(y^n) \\
&= \left(\sum_{\phi_n} P_{\Phi_n}(\phi_n) S_{\pi_1(w)}(C_{\phi_n}) \right) \left(\sum_{\psi_n} P_{\Psi_n}(\psi_n) S_{\pi_2(w)}(C_{\psi_n}) \right) \\
&= E[S_{\pi_1(w)}(C_{\Phi_n})] E[S_{\pi_2(w)}(C_{\Psi_n})].
\end{aligned}$$

如果编码器 Φ_n 和 Ψ_n 不仅相互独立，而且对于任意的置换 $\delta_n \in S_n$ 有 $\Psi_n \circ \delta_n \stackrel{d}{=} \Psi_n$ ，则定理3.7 证明中诱导出的两个编码器 $\hat{\Phi}_n$ 和 $\hat{\Psi}_n$ 也是相互独立的，其证明如下：

$$\begin{aligned}
\Pr\{\hat{\Phi}_n = \phi_n, \hat{\Psi}_n = \psi_n\} &= \Pr\{\Phi_n \circ \Delta_n = \phi_n, \Psi_n \circ \Delta_n = \psi_n\} \\
&= \sum_{\delta_n} P_{\Delta_n}(\delta_n) \Pr\{\Phi_n \circ \delta_n = \phi_n, \Psi_n \circ \delta_n = \psi_n\} \\
&= \sum_{\delta_n} P_{\Delta_n}(\delta_n) \Pr\{\Phi_n \circ \delta_n = \phi_n\} \Pr\{\Psi_n \circ \delta_n = \psi_n\} \\
&= \sum_{\delta_n} P_{\Delta_n}(\delta_n) \Pr\{\Phi_n \circ \delta_n = \phi_n\} \Pr\{\Psi_n = \psi_n\} \\
&= \sum_{\delta_n} P_{\Delta_n}(\delta_n) \Pr\{\Phi_n \circ \delta_n = \phi_n\} \sum_{\delta'_n} P_{\Delta_n}(\delta'_n) \Pr\{\Psi_n \circ \delta'_n = \psi_n\} \\
&= \Pr\{\hat{\Phi}_n = \phi_n\} \Pr\{\hat{\Psi}_n = \psi_n\}.
\end{aligned}$$

于是，由定理3.7证明中的恒等式 (3.5.10) 可以推出

$$\begin{aligned}
\frac{E[S_{\text{type}(\tilde{x}^n \tilde{y}^n)}(C_{(\Phi_n, \Psi_n)})]}{\binom{n}{\text{type}(\tilde{x}^n \tilde{y}^n)}} &= \Pr\{\hat{\Phi}_n(x^n) = \hat{\Phi}_n(x^n + \tilde{x}^n), \hat{\Psi}_n(y^n) = \hat{\Psi}_n(y^n + \tilde{y}^n)\} \\
&= \Pr\{\hat{\Phi}_n(x^n) = \hat{\Phi}_n(x^n + \tilde{x}^n)\} \Pr\{\hat{\Psi}_n(y^n) = \hat{\Psi}_n(y^n + \tilde{y}^n)\} \\
&= \frac{E[S_{\text{type}(\tilde{x}^n)}(C_{\Phi_n})]}{\binom{n}{\text{type}(\tilde{x}^n)}} \cdot \frac{E[S_{\text{type}(\tilde{y}^n)}(C_{\Psi_n})]}{\binom{n}{\text{type}(\tilde{y}^n)}},
\end{aligned}$$

此即 (3.5.13)。 \square

注意： 一对非随机编码器也可以被看作是一对特殊的相互独立的随机编码器，所以对于非随机线性编码器 ϕ_n 和 ψ_n ，我们有

$$\frac{E[S_w(C_{(\phi_n, \psi_n \circ \hat{\Delta}_n)})]}{\binom{n}{w}} = \frac{E[S_{\pi_1(w)}(C_{\phi_n})]}{\binom{n}{\pi_1(w)}} \cdot \frac{E[S_{\pi_2(w)}(C_{\psi_n})]}{\binom{n}{\pi_2(w)}}, \quad (3.5.14)$$

式中 $\hat{\Delta}_n$ 是一个独立的、均匀分布下的随机置换。

通过定理3.8, 我们开始意识到置换在 Slepian-Wolf 系统中具有非常重要的意义, 为进一步研究其作用, 我们分析了一个基于非随机线性编码器和随机置换的 Slepian-Wolf 系统的性能。

定理 3.9 对于一个相关无记忆信源 XY 和一对给定的非随机线性编码器序列 $\phi = \{\phi_n\}_{i=1}^\infty$ 和 $\psi = \{\psi_n\}_{i=1}^\infty$, 设其渐近速率分别为

$$R_1 = \lim_{n \rightarrow \infty} R(\Phi_n), \quad R_2 = \lim_{n \rightarrow \infty} R(\Psi_n), \quad (3.5.15)$$

则对于任意的 $J < \min\{\tilde{J}_1(R_1 - \epsilon_1), \tilde{J}_2(R_2 - \epsilon_2), \tilde{J}_3(R_1 + R_2 - \epsilon_1 - \epsilon_2)\}$ 有

$$\lim_{n \rightarrow \infty} \Pr\left\{-\frac{1}{n} \ln P_e^{(n)}(\phi_n, \psi_n \circ \hat{\Delta}_n) \geq J\right\} = 1$$

式中 $\hat{\Delta}_n$ 为一个独立的、均匀分布下的随机置换,

$$\epsilon_1 = \limsup_{n \rightarrow \infty} \frac{1}{n} \ln \max_{\mathbf{u} \in \mathcal{T}'_n(\mathcal{X})} \frac{E[S_{\mathbf{u}}(C_{\phi_n})] q_1^{l_n}}{\binom{n}{\mathbf{u}}}, \quad (3.5.16)$$

$$\epsilon_2 = \limsup_{n \rightarrow \infty} \frac{1}{n} \ln \max_{\mathbf{v} \in \mathcal{T}'_n(\mathcal{Y})} \frac{E[S_{\mathbf{v}}(C_{\psi_n})] q_2^{m_n}}{\binom{n}{\mathbf{v}}}. \quad (3.5.17)$$

证明: 由 (3.5.14) 和定理3.7、以及条件 (3.5.15), 同时取 $U = V = W = \emptyset$, 我们有, 对于任意的 $\delta > 0$, 存在一个正整数 $n_1(\delta)$ 使得对于所有的 $n > n_1(\delta)$,

$$E[P_e^{(n)}(\Phi_n, \Psi_n \circ \hat{\Delta}_n)] \leq e^{-n\tilde{J}_1(R_1 - \epsilon_1 - \delta)} + e^{-n\tilde{J}_2(R_2 - \epsilon_2 - \delta)} + e^{-n\tilde{J}_3(R_1 + R_2 - \epsilon_1 - \epsilon_2 - \delta)}.$$

其中 γ_n 的估计如下:

$$\begin{aligned} \gamma_n &= \max_{\mathbf{w} \in \mathcal{T}'_n(\mathcal{X} \times \mathcal{Y})} \frac{E[S_{\mathbf{w}}(C_{(\phi_n, \psi_n \circ \hat{\Delta}_n)})] q_1^{l_n} q_2^{m_n}}{\binom{n}{\mathbf{w}}} \\ &= \max_{\mathbf{w} \in \pi_1^{-1}(\mathcal{T}'_n(\mathcal{X})) \cap \pi_2^{-1}(\mathcal{T}'_n(\mathcal{Y}))} \frac{E[S_{\pi_1(\mathbf{w})}(C_{\phi_n})] q_1^{l_n}}{\binom{n}{\pi_1(\mathbf{w})}} \cdot \frac{E[S_{\pi_2(\mathbf{w})}(C_{\psi_n})] q_2^{m_n}}{\binom{n}{\pi_2(\mathbf{w})}} \\ &\leq \max_{\mathbf{u} \in \mathcal{T}'_n(\mathcal{X})} \frac{E[S_{\mathbf{u}}(C_{\phi_n})] q_1^{l_n}}{\binom{n}{\mathbf{u}}} \cdot \max_{\mathbf{v} \in \mathcal{T}'_n(\mathcal{Y})} \frac{E[S_{\mathbf{v}}(C_{\psi_n})] q_2^{m_n}}{\binom{n}{\mathbf{v}}} \\ &= \alpha_n \beta_n. \end{aligned}$$

由推论3.1知, 函数 $\tilde{J}_i(R)$ 是连续的, 所以, 对于充分小的 δ 和充分大的 n (即 $n > n_2(\delta)$) 有

$$E[P_e^{(n)}(\Phi_n, \Psi_n \circ \hat{\Delta}_n)] \leq e^{-n\tilde{J}_1(R_1 - \epsilon_1 - \delta)} + e^{-n\tilde{J}_2(R_2 - \epsilon_2 - \delta)} + e^{-n\tilde{J}_3(R_1 + R_2 - \epsilon_1 - \epsilon_2 - \delta)} < \frac{1}{n} e^{-nJ}.$$

于是, 对于所有 $n > \max\{n_1(\delta), n_2(\delta)\}$ (δ 充分小),

$$\Pr\left\{-\frac{1}{n} \ln P_e^{(n)}(\Phi_n, \Psi_n \circ \hat{\Delta}_n) < J\right\} = \Pr\{P_e^{(n)}(\Phi_n, \Psi_n \circ \hat{\Delta}_n) > e^{-nJ}\} \stackrel{(a)}{<} \frac{1}{n},$$

式中 (a) 应用了 Markov 不等式, 因而

$$\lim_{n \rightarrow \infty} \Pr\left\{-\frac{1}{n} \ln P_e^{(n)}(\Phi_n, \Psi_n \circ \hat{\Delta}_n) \geq J\right\} \geq \lim_{n \rightarrow \infty} \left(1 - \frac{1}{n}\right) = 1,$$

定理得证。 \square

定理3.9告诉我们, 如果 n 充分大, 那么大部分置换都是足够好的, 即足以帮助我们以较少的好的线性编码器 (即满足 $\epsilon_1 = \epsilon_2 = 0$ 的编码器) 为基础, 构建性能优良的 Slepian-Wolf 系统。从这一事实出发, 我们在构建一个 Slepian-Wolf 系统时, 可以准备一系列针对不同速率的好的线性编码器, 然后为每一个节点分配一个指定速率的编码器和一个随机生成的交织器 (即置换)。这样, 即使对每一个速率只有一个编码器, 也可以通过不同的交织器, 满足多个节点的需求。自然, 接下来的问题就是如何构造好的线性编码器, 于是, 我们考虑分析基于 LDPC 码的线性编码器的性能。

低密度偶校验 (Low Density Parity Check, LDPC) 码是由 Gallager 于上世纪六十年代提出的一类近 Shannon 限的好码^[42], 然而, 从 Gallager 的博士论文^[42] 到 Turbo 码^[14] 的发明之间这一段时间, LDPC 码在很大程度上被忽视和遗忘了, 其间仅有少许值得注意的工作, 如 Tanner 的工作^[96]。随着 Turbo 码发明, LDPC 码又被 MacKay 等人重新发现^[67]。目前, 关于 LDPC 码的构造、分析和解码算法的研究已经取得了空前的进展。在这里, 我们仅从原理上对 LDPC 码作一个简要的介绍。

LDPC 码之所以称为低密度偶校验码, 是因为其对应的校验矩阵是一个稀疏矩阵 (这里, 我们采用的约定为: 设码字为 n 维的列向量 \mathbf{x} , 校验矩阵为 $l \times n$ 维的矩阵 A , 且满足 $A\mathbf{x} = 0$)。以 Gallager 提出的二进制规则 LDPC 码^[42] 为例, 设其参数为 (c, d) , 则其校验矩阵 A 中的每一行恰好有 d 个元素为 1, 而每一列恰好有 c 个元素为 1, 所以 $ld = nc$, 于是矩阵中元素 1 的密度为 $\frac{d}{n}$ 或 $\frac{c}{l}$ 。对于 LDPC 码的研究常常会采用双向图 (Bipartite Graph) 的形式 (如图3.6), 这是由 Tanner 在 [96] 中引入的一种方法, 一个双向图包含两类节点, 一类节点代表码字序列中的每一个字符, 称为变量节点, 另一类节点代表校验矩阵中的每一行方程, 称为校验节点。校验矩阵中的一个元素为 1 即代表其所在列的变量节点与所在行的校验节点间有一条边。根据图中变量节点和校验节点所生长出边的条数 (即度) 的规律可以将 LDPC 码分为规则 LDPC 码和非规则 LDPC 码。规则 LDPC 码就是 Gallager 提出的 LDPC 码, 即每个变量节点的度为 c , 每个校验节点的度为 d ; 非规则 LDPC 码则为变量节点和校验节点分别定义了两个关于度分布的生成函数, 变量节点与校验节点根据度分布以一定的比例取不同的度。非规则 LDPC 码比规则 LDPC 码具有更好的性能, 但这就要求我们首先要能设计出好的关于度分布的生成函数, 例如在 [83] 中, Richardson 等人设计出的 $1/2$ 码率、码长为 10^6 的非规则 LDPC 码在二进制输入的加性白高斯噪声 (Binary-Input Additive White Gaussian Noise, BIAWGN) 信道下, 当误比特率达到 10^{-6} 时, 其每比特能量仅比理论值高出 0.13dB。关于 LDPC 码的译码, 主要采用迭代译码, 其主要算法就是和积算法 (Sum-Product Algorithm), 读者可参阅文献 [60] 的介绍。和积算法在无圈

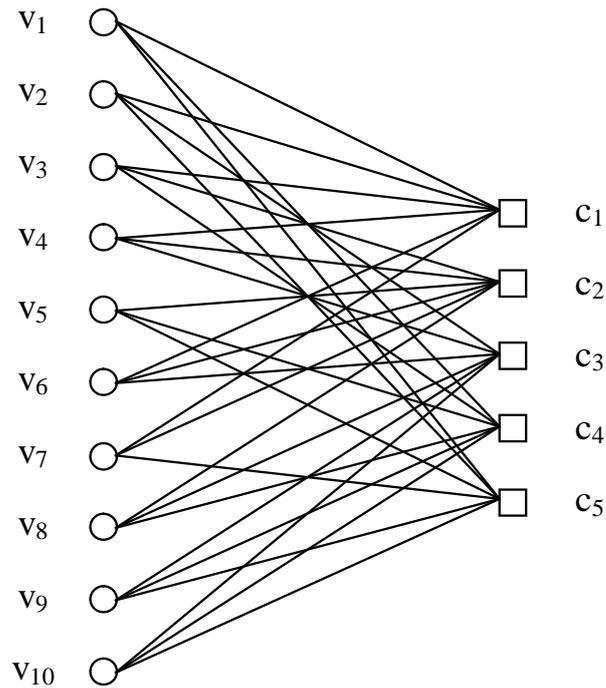


图 3.6: 一个长度为 10 的 (3,6) 规则 LDPC 码的双向图

图下是最优的，但是 LDPC 码所对应的双向图是有圈的，所以有大量的研究围绕着如何构造具有尽可能大的最小圈（称为 Girth）的 LDPC 码。关于 LDPC 码的性能分析主要有两个方向，一类是 ML 译码下性能的分析，如 [10]，其分析主要是基于 Gallager 限 [43] 和 LDPC 码的码谱，关于二进制 LDPC 码的码谱（即重量谱），文献 [65] 作了极为全面的研究；另一类是迭代译码下性能的分析，如 [84]，其主要方法为密度进化（Density Evolution）方法，但到目前为止，迭代译码性能的分析技术还远未达到成熟。

目前，应用研究中已经出现了许多基于 LDPC 码的 Slepian-Wolf 数据压缩系统，所以，很有必要对基于 LDPC 码的 Slepian-Wolf 系统的性能进行分析。我们在分析中所采用的 LDPC 码是 [10, Section IV] 中提出的一类 $GF(q)$ 上的规则 LDPC 码，其本质就是由规则双向图（Regular Bipartite Graph）构造二进制 LDPC 码方法的一种推广。我们首先简要地介绍一下其构造方法。首先，我们在 $GF(q)$ 上构造一个参数为 (c, d) 的规则双向图，其中图的左边有 n 个变量节点（Variable Node），每个节点代表 $GF(q)$ 上的一个变量符号，且每个节点的度为 c （即有 c 条边），图的右边有 l 个校验节点（Check Node），每个节点的度为 d ，并满足 $nc = ld$ ，于是 nc 条边将变量节点和校验节点连接起来，每条边上标注一个非零 $GF(q)$ 符号。然后，我们定义参数为 (c, d) 的规则图集合（Ensemble）。我们分别从变量节点和校验节点两边为每条边标上序号 1 至 nc ，然后对于每个 $i \in \{1, 2, \dots, nc\}$ ，我们将左边的第 i 条边与右边的第 $\tilde{\Delta}_n(i)$ 条边联系起来，同时又为每一条边以等概率的方式赋予一个符号 $g \in GF(q) \setminus \{0\}$ ，其中 $\tilde{\Delta}_n$ 为一个独立的、均匀分布下的随机置换。最后，我们可以将上述的双向图变换为一个

偶校验矩阵。具体方法为：矩阵中每个元素 $A_{i,j}$ 对应于连接第 i 个校验节点和第 j 个变量节点的所有边的标号在 $GF(q)$ 上的和。

基于上述的 LDPC 码，就可以定义一类称为参数为 (c, d) 的 $GF(q)$ 上的规则 LDPC 编码器 Φ_n ，即由上述 (c, d) 规则图集合生成的偶校验矩阵集合，显然，其速率 $R(\Phi_n)$ 就是 $\frac{c}{d} \ln q$ 。现在，我们来分析规则 LDPC 编码器的性能。首先，我们列出证明中将要使用的几个关于 LDPC 码性质的定理。

定理 3.10 ([10], Theorem 8) $GF(q)$ 上的一个 (c, d) 规则 LDPC 码的渐近归一化集平均谱为

$$B(\boldsymbol{\theta}) = H(\boldsymbol{\theta}) - cH(\lambda) - c\lambda \ln(q-1) + \frac{c}{d} \ln \inf_{\text{sgn}(x)=\text{sgn}(\lambda)} \frac{A(x)}{x^{d\lambda}}, \quad (3.5.18)$$

式中 $\boldsymbol{\theta}$ 表示一个满足 $\sum_{i=0}^{q-1} \theta_i = 1$ 的 q 维有理数向量，信道码 C 的渐近归一化集平均谱定义为

$$B(\boldsymbol{\theta}) \triangleq \lim_{n \rightarrow \infty} \frac{1}{n} \ln E[S_{n, \boldsymbol{\theta}}(C)], \quad (3.5.19)$$

$\lambda = 1 - \theta_0$,

$$A(x) = \frac{1}{q} \{ [1 + (q-1)x]^d + (q-1)(1-x)^d \}. \quad (3.5.20)$$

定理 3.11 ([10], Section IV) 考虑 $GF(q)$ 上的一个 (c, d) 规则 LDPC 码的渐近归一化集平均谱 $B(\boldsymbol{\theta})$ ，并假设 $q > 2$ 。令 $0 < \delta < 1$ 为一任意实数，则

$$J_\delta = \left\{ (\theta_0, \dots, \theta_{q-1}) \left| 0 \leq \theta_0 \leq 1 - \delta, \theta_i \geq 0, i = 1, \dots, q-1, \sum_{i=0}^{q-1} \theta_i = 1 \right. \right\}. \quad (3.5.21)$$

令 R 为一给定的正有理数，并令 $\mathcal{R}(\boldsymbol{\theta})$ 为速率 R 下随机编码的归一化谱，于是对于任意的 $\epsilon > 0$ ，存在整数 $d_0 > 0$ 使得对于所有的 $\boldsymbol{\theta} \in J_\delta$ 和所有满足 $d > d_0$ 的 (c, d) ，

$$B(\boldsymbol{\theta}) < \mathcal{R}(\boldsymbol{\theta}) + \epsilon, \quad (3.5.22)$$

式中 $\mathcal{R}(\boldsymbol{\theta}) \triangleq H(\boldsymbol{\theta}) - \ln q + R$ ， $R = (1 - c/d) \ln q$ 。

定理 3.12 ([10], Section IV) 固定速率 $R = 1 - c/d$ ，令 $c \geq 3$ 。于是，存在一个仅依赖于 R 和 q 的 $\gamma > 0$ ，使得

$$\Pr\{d_{\min} \leq \gamma n\} = O(n^{1-c/2}) \quad (3.5.23)$$

式中 d_{\min} 是长度为 n 、 $GF(q)$ 上的一个随机选择的 (c, d) 规则 LDPC 码的最小 Hamming 距离。

下面，我们开始分析 LDPC 编码器的性能。

定理 3.13 令 XY 为一个相关平稳无记忆信源, 令 ϵ 为一任意正实数, 并假设 $q_1, q_2 > 2$ 和 $c_1, c_2 \geq 3$ 。于是对于足够大的 d_1 和 d_2 , 分别定义在 $GF(q_1)$ 和 $GF(q_2)$ 上的相互独立的 (c_1, d_1) 规则 LPDC 编码器 Φ_n 和 (c_2, d_2) 规则 LPDC 编码器 Ψ_n (两者皆独立于信源) 满足对于任意的 $J < \min\{\tilde{J}_1(R_1 - \epsilon), \tilde{J}_2(R_2 - \epsilon), \tilde{J}_3(R_1 + R_2 - \epsilon)\}$,

$$\lim_{n \rightarrow \infty} \Pr\left\{-\frac{1}{n} \ln P_e^{(n)}(\Phi_n, \Psi_n) \geq J\right\} = 1 \quad (3.5.24)$$

式中 $R_1 = \frac{c_1}{d_1} \ln q_1$, $R_2 = \frac{c_2}{d_2} \ln q_2$ 。

证明: 由定理3.12知, 存在 $\delta_1, \delta_2 > 0$ 使得

$$\Pr\{d_{\min}(C_{\Phi_n}) \leq \delta_1 n\} = O(n^{1-c_1/2}) \quad \text{and} \quad \Pr\{d_{\min}(C_{\Psi_n}) \leq \delta_2 n\} = O(n^{1-c_2/2}),$$

因此为了证明定理, 我们首先假设事件

$$D_n \triangleq \{\omega \in \Omega | d_{\min}(C_{\Phi_n}) > \delta_1 n, d_{\min}(C_{\Psi_n}) > \delta_2 n\}$$

发生, 进而考虑 MAP 译码错误的条件平均概率。因为当 $n \rightarrow \infty$ 时, $\Pr(D_n) \rightarrow 1$, 所以对于充分大的 n , 我们有

$$E[S_{\mathbf{u}}(C_{\Phi_n}) | D_n] \leq \begin{cases} 0, & 0 < \text{wt}(\mathbf{u}) \leq \delta_1 n \\ 2E[S_{\mathbf{u}}(C_{\Phi_n})], & \text{wt}(\mathbf{u}) > \delta_1 n \end{cases} \quad (3.5.25a)$$

$$(3.5.25b)$$

和

$$E[S_{\mathbf{v}}(C_{\Psi_n}) | D_n] \leq \begin{cases} 0, & 0 < \text{wt}(\mathbf{v}) \leq \delta_2 n \\ 2E[S_{\mathbf{v}}(C_{\Psi_n})], & \text{wt}(\mathbf{v}) > \delta_2 n \end{cases} \quad (3.5.26a)$$

$$(3.5.26b)$$

式中 $\text{wt}(\mathbf{t})$ 表示类型为 \mathbf{t} 的码字中非零元素的个数。

然后, 我们估计 α_n 、 β_n 和 γ_n 的值。令 $U = \{\mathbf{u} | \text{wt}(\mathbf{u}) \leq \delta_1 n\}$ 、 $V = \{\mathbf{v} | \text{wt}(\mathbf{v}) \leq \delta_2 n\}$ 、 $W = \pi_1^{-1}(U) \cup \pi_2^{-1}(V)$, 于是

$$\begin{aligned} \frac{1}{n} \ln \alpha_n &= \frac{1}{n} \ln \max_{\mathbf{u} \in U^c} \frac{E[S_{\mathbf{u}}(C_{\Phi_n}) | D_n] q_1^{l_n}}{\binom{n}{\mathbf{u}}} \\ &= \max_{\mathbf{u} \in U^c} \left[\frac{1}{n} \ln E[S_{\mathbf{u}}(C_{\Phi_n}) | D_n] - \frac{1}{n} \ln \frac{\binom{n}{\mathbf{u}}}{q_1^{l_n}} \right] \\ &\leq \max_{\mathbf{u} \in U^c} \left[\frac{1}{n} \ln E[S_{\mathbf{u}}(C_{\Phi_n}) | D_n] - \frac{1}{n} \ln E[S_{\mathbf{u}}(C_{\Phi_n})] \right] \\ &\quad + \max_{\mathbf{u} \in U^c} \left[\frac{1}{n} \ln E[S_{\mathbf{u}}(C_{\Phi_n})] - B(\boldsymbol{\theta}) \right] \\ &\quad + \max_{\mathbf{u} \in U^c} [B(\boldsymbol{\theta}) - \mathcal{R}(\boldsymbol{\theta})] + \max_{\mathbf{u} \in U^c} \left[\mathcal{R}(\boldsymbol{\theta}) - \frac{1}{n} \ln \frac{\binom{n}{\mathbf{u}}}{q_1^{l_n}} \right] \end{aligned} \quad (3.5.27)$$

由 (3.5.25) 知, 当 $n \rightarrow \infty$ 时, (3.5.27) 中的第一项趋于 0。第二项的分析则依赖于 [10, Theorem 10] 和定理 3.10 (即 [10, Theorem 8]) 的证明中获得的結果, 即

$$\begin{aligned} \frac{1}{n} \ln E[S_{\mathbf{u}}(C_{\Phi_n})] &= \frac{1}{n} \ln \left[\binom{n}{\mathbf{u}} \Pr\{x^n \in C_{\Phi_n} | \text{type}(x^n) = \mathbf{u}\} \right] \\ &\leq H(\boldsymbol{\theta}) + \frac{1}{n} \ln \frac{[A(x)^{c_1 n / d_1}]_{\lambda c_1 n}}{\binom{c_1 n}{\lambda c_1 n} (q_1 - 1)^{\lambda c_1 n}} \\ &\leq H(\boldsymbol{\theta}) - c_1 H(\lambda) + \frac{q_1}{n} \ln(c_1 n + 1) - c_1 \lambda \ln(q_1 - 1) \\ &\quad + \frac{c_1}{d_1} \ln \inf_{\text{sgn}(x) = \text{sgn}(\lambda)} \frac{A(x)}{x^{\lambda d_1}} \\ &= B(\boldsymbol{\theta}) + \frac{q_1}{n} \ln(c_1 n + 1), \end{aligned}$$

式中 $\theta_i = u_i/n$, $\lambda = 1 - \theta_0$, $A(x)$ 由 (3.5.20) 定义。因此, 当 $n \rightarrow \infty$ 时, (3.5.27) 中的第二项在所有有效类型 \mathbf{u} 上的值都将任意地接近于 0。由定理 3.11 知, 当 $d_1 > d_{10}$ 时, 第三项会小于 $\frac{\epsilon}{2}$ 。最后一项随 n 趋于无穷而趋于 0 更是显然的。所以, 当 $d_1 > d_{10}$ 时,

$$\lim_{n \rightarrow \infty} \frac{1}{n} \ln \alpha_n < \frac{\epsilon}{2}.$$

类似地, 当 $d_1 > d_{10}$ 和 $d_2 > d_{20}$ 时,

$$\lim_{n \rightarrow \infty} \frac{1}{n} \ln \beta_n < \frac{\epsilon}{2},$$

$$\lim_{n \rightarrow \infty} \frac{1}{n} \ln \gamma_n \leq \lim_{n \rightarrow \infty} \frac{1}{n} (\ln \alpha_n + \ln \beta_n) < \epsilon.$$

因此, 当 $d_1 > d_{10}$ 和 $d_2 > d_{20}$ 时, 对于充分大的 n 有 $\frac{1}{n} \ln \alpha_n < \epsilon$, $\frac{1}{n} \ln \beta_n < \epsilon$ 和 $\frac{1}{n} \ln \gamma_n < \epsilon$ 。于是由定理 3.7 知, 对于充分大的 n , 条件平均译码错误概率 $E[P_e^{(n)}(\Phi_n, \Psi_n) | D_n]$ 满足

$$E[P_e^{(n)}(\Phi_n, \Psi_n) | D_n] \leq e^{-n\tilde{J}_1(R_1 - \epsilon)} + e^{-n\tilde{J}_2(R_2 - \epsilon)} + e^{-n\tilde{J}_3(R_1 + R_2 - \epsilon)} < \frac{1}{n} e^{-nJ},$$

即对于充分大的 n , $-\frac{1}{n} \ln(nE[P_e^{(n)}(\Phi_n, \Psi_n) | D_n]) > J$ 。所以, 对于充分大的 n 有

$$\begin{aligned} &\Pr\left\{-\frac{1}{n} \ln P_e^{(n)}(\Phi_n, \Psi_n) < J\right\} \\ &\leq \Pr\left\{-\frac{1}{n} \ln P_e^{(n)}(\Phi_n, \Psi_n) < J | D_n\right\} + \Pr(D_n^c) \\ &\leq \Pr\left\{-\frac{1}{n} \ln P_e^{(n)}(\Phi_n, \Psi_n) < -\frac{1}{n} \ln(nE[P_e^{(n)}(\Phi_n, \Psi_n) | D_n]) \mid D_n\right\} + \Pr(D_n^c) \\ &= \Pr\left\{P_e^{(n)}(\Phi_n, \Psi_n) > nE[P_e^{(n)}(\Phi_n, \Psi_n) | D_n] \mid D_n\right\} + \Pr(D_n^c) \\ &\stackrel{(a)}{<} \frac{1}{n} + \Pr(D_n^c), \end{aligned}$$

式中 (a) 应用了 Markov 不等式, 于是

$$\lim_{n \rightarrow \infty} \Pr\left\{-\frac{1}{n} \ln P_e^{(n)}(\Phi_n, \Psi_n) \geq J\right\} \geq \lim_{n \rightarrow \infty} \left(1 - \frac{1}{n} - \Pr(D_n^c)\right) = 1.$$

定理得证。 \square

定理3.13告诉我们，如果参数 d 和码长足够大，那么大多数（概率趋近于 1）LDPC 编码器都是非常好的编码器。这一结果与文献 [77] 的结果有一定的相似之处，但在平稳无记忆信源下，我们的结果要更强一些。

定理3.13 和定理3.9实际上提示我们考虑一种新的对称 Slepian-Wolf 编码方案，如图3.7。我们首先说明一下其基本的工作原理。系统中最关键的是交织器生成模块和

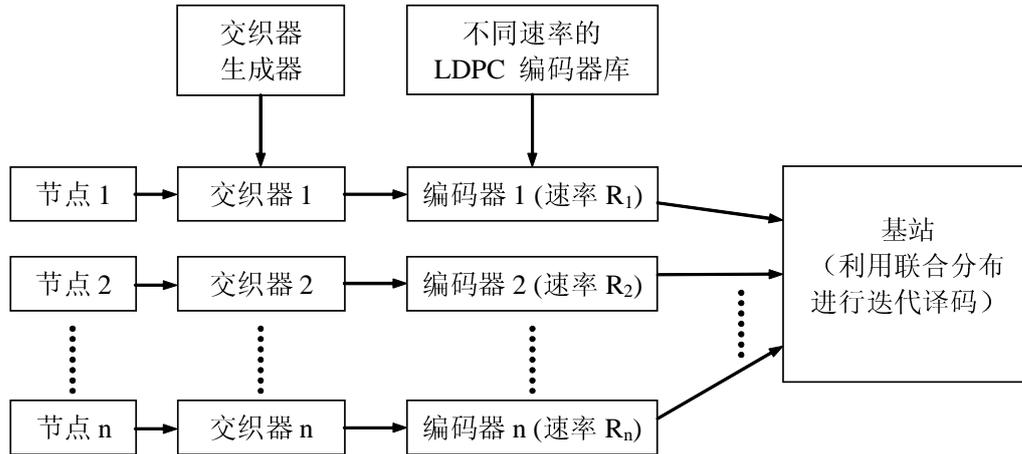


图 3.7: 一个基于 LDPC 码和交织器的对称 Slepian-Wolf 编码方案

LDPC 编码器库（交织器的长度大于等于 LDPC 码的长度）。交织器生成模块会为每个节点随机生成一个交织器（即置换），LDPC 编码器库则储存了具有不同速率的 LDPC 码，这些 LDPC 码都是经过特别优化的，其性能是优越的。于是，整个 Slepian-Wolf 系统就具有非常丰富的码资源，因为，即使有多个相同速率要求的节点，系统可以分配给它们相同的编码器，但为每个节点生成一个不同的交织器，由定理3.9知，系统在 MAP 译码下的性能是有保障的。在接收端，我们采用了利用联合分布进行迭代译码的算法 [21, 87]，它应该可以较好地逼近 MAP 译码的性能。

目前，关于对称编码方案的设计，在编码端主要有两种方法。一种方法是信道码本分割方法 [87, 93]，其主要思想就是选取一个好的信道码，然后根据各节点的速率要求，将信道码的生成矩阵进行分割，为每个节点分配该生成矩阵的一个子矩阵作为生成矩阵。另一种方法是信源剖分方法 [21]，其主要思想就是将各节点的信源进行分割，然后采用非对称的压缩方法按一定的顺序进行压缩，从而达到对称编码的目的。然而，上述两种方法都存在一些问题，第一种方法的问题在于其仅适用于一些特殊的相关模型，而第二种方法则由于剖分算法的引入导致系统结构和相关模型的复杂化，而且还需要额外的方法来使信源数据在剖分算法中保持平等的地位，即不至于产生某些数据取值更容易出错的问题。图3.7给出的对称编码方案就不存在上述问题，它适合于任意节点数下的任何无记忆的相关模型，而且系统的结构非常的对称和简单，十分利于系统的扩展，即增加一个节点不会对原有节点的码分配有任何影响。当然，其可行性仍有待于在今后的研究工作中作进一步的检验。

3.6 关于通用 Slepian-Wolf 编码的思考

本节与前面的工作相对独立，我们将试图揭示关于通用 Slepian-Wolf 编码的一个本质性问题。熟悉单用户无错通用信源编码的人都知道，通用编码的本质就是寻找一个概率分布（可以将其称为先验概率分布），使其与某一类信源中的任意一个信源的散度除以序列长度能够渐近趋向于零，可以用不太严格的数学形式表示如下：

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sup_{\theta \in \Theta} D(X_\theta^n || Y^n) = 0, \quad (3.6.1)$$

式中 Θ 代表这一类信源的参数空间。那么，通用 Slepian-Wolf 编码是不是也等价于寻找某个先验概率分布呢？答案是肯定的，笔者相信这一事实已为少数熟悉信息谱方法的专家们所了解，只是未见到有正式文献来说明这一点，故借撰写博士论文的机会对其作一阐述。下面，我们将首先在信息谱理论^[49] 的框架下建立关于先验信源与通用 Slepian-Wolf 编码之间的联系，然后用该结果来解释最小熵译码器^[25, 26] 的原理。

由于在推导中将使用有关依概率上极限 (3.4.1) 和依概率下极限 (3.4.2) 的运算，所以我们首先列出与这两个极限有关的一些性质。对于任意的实值随机变量序列 $\{Z_n\}_{n=1}^\infty$ 和 $\{V_n\}_{n=1}^\infty$ ，我们有

$$\text{p-lim sup}_{n \rightarrow \infty} (Z_n + V_n) \leq \text{p-lim sup}_{n \rightarrow \infty} Z_n + \text{p-lim sup}_{n \rightarrow \infty} V_n, \quad (3.6.2)$$

$$\text{p-lim inf}_{n \rightarrow \infty} (Z_n + V_n) \geq \text{p-lim inf}_{n \rightarrow \infty} Z_n + \text{p-lim inf}_{n \rightarrow \infty} V_n, \quad (3.6.3)$$

$$\text{p-lim sup}_{n \rightarrow \infty} (Z_n + V_n) \geq \text{p-lim inf}_{n \rightarrow \infty} Z_n + \text{p-lim sup}_{n \rightarrow \infty} V_n, \quad (3.6.4)$$

$$\text{p-lim inf}_{n \rightarrow \infty} (Z_n + V_n) \leq \text{p-lim inf}_{n \rightarrow \infty} Z_n + \text{p-lim sup}_{n \rightarrow \infty} V_n, \quad (3.6.5)$$

$$\text{p-lim inf}_{n \rightarrow \infty} Z_n \leq \text{p-lim sup}_{n \rightarrow \infty} Z_n, \quad (3.6.6)$$

$$\text{p-lim sup}_{n \rightarrow \infty} (-Z_n) = -\text{p-lim inf}_{n \rightarrow \infty} Z_n, \quad (3.6.7)$$

$$\text{p-lim sup}_{n \rightarrow \infty} Z_n = \text{p-lim inf}_{n \rightarrow \infty} Z_n = c \Leftrightarrow \text{p-lim}_{n \rightarrow \infty} Z_n = c. \quad (3.6.8)$$

式 (3.6.8) 中的 $\text{p-lim}_{n \rightarrow \infty} Z_n$ 就是概率论中常规的依概率收敛。

然后，我们列出下文中涉及到的所有量的定义。对于任意给定的相关一般信源 \mathbf{XY} 和 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$ ，定义

$$\bar{H}(\mathbf{XY}) \triangleq \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{X^n Y^n}(X^n Y^n)}, \quad (3.6.9)$$

$$\bar{H}(\mathbf{X}|\mathbf{Y}) \triangleq \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{X^n|Y^n}(X^n|Y^n)}, \quad (3.6.10)$$

$$\bar{H}(\mathbf{Y}|\mathbf{X}) \triangleq \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{Y^n|X^n}(Y^n|X^n)}, \quad (3.6.11)$$

$$\overline{D}(\mathbf{XY} \parallel \hat{\mathbf{X}}\hat{\mathbf{Y}}) \triangleq \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{P_{X^n Y^n}(X^n Y^n)}{P_{\hat{X}^n \hat{Y}^n}(X^n Y^n)}, \quad (3.6.12)$$

$$\overline{D}(\mathbf{X}|\mathbf{Y} \parallel \hat{\mathbf{X}}|\hat{\mathbf{Y}}) \triangleq \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{P_{X^n|Y^n}(X^n|Y^n)}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)}, \quad (3.6.13)$$

$$\overline{D}(\mathbf{Y}|\mathbf{X} \parallel \hat{\mathbf{Y}}|\hat{\mathbf{X}}) \triangleq \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{P_{Y^n|X^n}(Y^n|X^n)}{P_{\hat{Y}^n|\hat{X}^n}(Y^n|X^n)}. \quad (3.6.14)$$

现在，我们将通过证明一系列的结果来揭示先验信源与通用 Slepian-Wolf 编码的联系。

命题 3.1 对于任意给定的相关一般信源 \mathbf{XY} 和 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$ ，我们有

$$\text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \leq \overline{H}(\mathbf{X}|\mathbf{Y}) + \overline{D}(\mathbf{X}|\mathbf{Y} \parallel \hat{\mathbf{X}}|\hat{\mathbf{Y}}), \quad (3.6.15)$$

$$\text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{\hat{Y}^n|\hat{X}^n}(Y^n|X^n)} \leq \overline{H}(\mathbf{Y}|\mathbf{X}) + \overline{D}(\mathbf{Y}|\mathbf{X} \parallel \hat{\mathbf{Y}}|\hat{\mathbf{X}}). \quad (3.6.16)$$

$$\text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n \hat{Y}^n}(X^n Y^n)} \leq \overline{H}(\mathbf{XY}) + \overline{D}(\mathbf{XY} \parallel \hat{\mathbf{X}}\hat{\mathbf{Y}}), \quad (3.6.17)$$

证明：

$$\begin{aligned} & \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \\ &= \text{p-lim sup}_{n \rightarrow \infty} \left(\frac{1}{n} \ln \frac{1}{P_{X^n|Y^n}(X^n|Y^n)} + \frac{1}{n} \ln \frac{P_{X^n|Y^n}(X^n|Y^n)}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \right) \\ &\leq \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{1}{P_{X^n|Y^n}(X^n|Y^n)} + \text{p-lim sup}_{n \rightarrow \infty} \frac{1}{n} \ln \frac{P_{X^n|Y^n}(X^n|Y^n)}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \\ &= \overline{H}(\mathbf{X}|\mathbf{Y}) + \overline{D}(\mathbf{X}|\mathbf{Y} \parallel \hat{\mathbf{X}}|\hat{\mathbf{Y}}), \end{aligned}$$

于是 (3.6.15) 得证，同理可证 (3.6.16) 和 (3.6.17)。 \square

引理 3.4 假设相关信源为一般信源 \mathbf{XY} ，Slepian-Wolf 系统所知的先验信源为一般信源 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$ ，则对于任意的 $n \in \mathbb{Z}^+$ 、 \mathcal{L}_n 和 \mathcal{M}_n ，存在编码器 ϕ_n 和 ψ_n ，使得其译码错误满足

$$\begin{aligned} P_e^{(n)}(\phi_n, \psi_n) &\leq \Pr \left\{ \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \geq R_1 - \gamma \right. \\ &\quad \text{or } \frac{1}{n} \ln \frac{1}{P_{\hat{Y}^n|\hat{X}^n}(Y^n|X^n)} \geq R_2 - \gamma \\ &\quad \left. \text{or } \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n \hat{Y}^n}(X^n Y^n)} \geq R_1 + R_2 - \gamma \right\} + 3e^{-n\gamma}, \quad (3.6.18) \end{aligned}$$

式中 γ 为任意正实数， $R_1 = \frac{1}{n} \ln |\mathcal{L}_n|$ ， $R_2 = \frac{1}{n} \ln |\mathcal{M}_n|$ 。

证明： 证明方法与 [49, Lemma 7.2.1] 相同。

定义三个集合 $T_n^{(1)}, T_n^{(2)}, T_n^{(3)} \in \mathcal{X}^n \times \mathcal{Y}^n$ 如下：

$$T_n^{(1)} = \left\{ x^n y^n \left| \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n | \hat{Y}^n}(x^n | y^n)} < R_1 - \gamma \right. \right\}, \quad (3.6.19)$$

$$T_n^{(2)} = \left\{ x^n y^n \left| \frac{1}{n} \ln \frac{1}{P_{\hat{Y}^n | \hat{X}^n}(y^n | x^n)} < R_2 - \gamma \right. \right\}, \quad (3.6.20)$$

$$T_n^{(3)} = \left\{ x^n y^n \left| \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n \hat{Y}^n}(x^n y^n)} < R_1 + R_2 - \gamma \right. \right\}, \quad (3.6.21)$$

并令

$$T_n = T_n^{(1)} \cap T_n^{(2)} \cap T_n^{(3)}.$$

于是, (3.6.18) 可以重写为

$$P_e^{(n)}(\phi_n, \psi_n) \leq \Pr\{X^n Y^n \notin T_n\} + 3e^{-n\gamma}. \quad (3.6.22)$$

所以只需要证明存在 ϕ_n 和 ψ_n 使得 (3.6.22) 满足。我们的随机编码证明方法如下：

a) 随机编码： 定义随机编码器 Φ_n 为：对于每一个 x^n ，以等概率的方式随机赋予 $\Phi_n(i)$ 为 \mathcal{M}_n 中的任意一个值，此即随机装箱 (Random Binning) 方法。同理可以定义随机编码器 Ψ_n 。

b) 译码算法： 对于编码器的输出 $(l, m) \in \mathcal{L}_n \times \mathcal{M}_n$ ，如果存在唯一的 $x^n y^n$ 满足 $\Phi_n(x^n) = l$ ， $\Psi_n(y^n) = m$ ，且 $x^n y^n \in T_n$ ，那么译码器输出 $x^n y^n$ ，否则输出任意一个序列。

c) 错误概率的计算： 产生译码错误的事件有如下四种：

$$E_n^{(0)} = \{X^n Y^n \notin T_n\},$$

$$E_n^{(1)} = \{\exists \tilde{x}^n \neq X^n : \Phi_n(\tilde{x}^n) = \Phi_n(X^n) \text{ and } \tilde{x}^n Y^n \in T_n\},$$

$$E_n^{(2)} = \{\exists \tilde{y}^n \neq Y^n : \Psi_n(\tilde{y}^n) = \Psi_n(Y^n) \text{ and } X^n \tilde{y}^n \in T_n\},$$

$$E_n^{(3)} = \{\exists \tilde{x}^n \neq X^n, \exists \tilde{y}^n \neq Y^n : \Phi_n(\tilde{x}^n) = \Phi_n(X^n), \Psi_n(\tilde{y}^n) = \Psi_n(Y^n) \text{ and } \tilde{x}^n \tilde{y}^n \in T_n\}.$$

于是, 平均错误概率满足

$$E[P_e^{(n)}(\Phi_n, \Psi_n)] \leq \Pr\{E_n^{(0)}\} + \Pr\{E_n^{(1)}\} + \Pr\{E_n^{(2)}\} + \Pr\{E_n^{(3)}\}. \quad (3.6.23)$$

显然,

$$\Pr\{E_n^{(0)}\} = \Pr\{X^n Y^n \notin T_n\}.$$

接下来, 我们计算 $\Pr\{E_n^{(1)}\}$ 。

$$\Pr\{E_n^{(1)}\} = \Pr\{\exists \tilde{x}^n \neq X^n : \Phi_n(\tilde{x}^n) = \Phi_n(X^n) \text{ and } \tilde{x}^n Y^n \in T_n\}$$

$$\begin{aligned}
&= \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) \Pr\{\exists \tilde{x}^n \neq x^n : \Phi_n(\tilde{x}^n) = \Phi_n(x^n) \text{ and } \tilde{x}^n y^n \in T_n\} \\
&= \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) \sum_{\tilde{x}^n \neq x^n : \tilde{x}^n y^n \in T_n} \Pr\{\Phi_n(\tilde{x}^n) = \Phi_n(x^n)\} \\
&= \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) \sum_{\tilde{x}^n \neq x^n : \tilde{x}^n y^n \in T_n} \frac{1}{|\mathcal{L}_n|} \\
&\leq \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) \sum_{\tilde{x}^n y^n \in T_n} \frac{1}{|\mathcal{L}_n|} \\
&= \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) |S_n(y^n)| \frac{1}{|\mathcal{L}_n|}, \tag{3.6.24}
\end{aligned}$$

式中 $S_n(y^n) = \{x^n \in \mathcal{X}^n | x^n y^n \in T_n\}$ 。另一方面，由于 (3.6.19) 保证了所有 $x^n y^n \in T_n$ 都满足

$$P_{\hat{X}^n | \hat{Y}^n}(x^n | y^n) \geq \frac{e^{n\gamma}}{|\mathcal{L}_n|},$$

所以，

$$|S_n(y^n)| \leq |\mathcal{L}_n| e^{-n\gamma}.$$

将上式代入 (3.6.24)，于是得到

$$\Pr\{E_n^{(1)}\} \leq \sum_{x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n} P_{X^n Y^n}(x^n y^n) e^{-n\gamma} = e^{-n\gamma}.$$

同理可证

$$\Pr\{E_n^{(2)}\} \leq e^{-n\gamma}, \quad \Pr\{E_n^{(3)}\} \leq e^{-n\gamma}.$$

所以，

$$E[P_e^{(n)}(\Phi_n, \Psi_n)] \leq \Pr\{X^n Y^n \notin T_n\} + 3e^{-n\gamma},$$

这就确保了至少存在一对 ϕ_n 和 ψ_n 满足 (3.6.18)。□

基于上述结果，我们就可以得到以先验信源 $\hat{X}\hat{Y}$ 为知识的 Slepian-Wolf 系统的可达速率区的一个子集。

定理 3.14 假设相关信源为一般信源 \mathbf{XY} ，Slepian-Wolf 系统所知的先验信源为一般信源 $\hat{X}\hat{Y}$ ，则以下区域

$$\begin{aligned}
&\{(R_1, R_2) : R_1 \geq \bar{H}(\mathbf{X}|\mathbf{Y}) + \bar{D}(\mathbf{X}|\mathbf{Y} \|\hat{\mathbf{X}}|\hat{\mathbf{Y}}), \\
&\quad R_2 \geq \bar{H}(\mathbf{Y}|\mathbf{X}) + \bar{D}(\mathbf{Y}|\mathbf{X} \|\hat{\mathbf{Y}}|\hat{\mathbf{X}}), \\
&\quad R_1 + R_2 \geq \bar{H}(\mathbf{XY}) + \bar{D}(\mathbf{XY} \|\hat{\mathbf{X}}\hat{\mathbf{Y}})\} \tag{3.6.25}
\end{aligned}$$

内的速率对是可达的。

证明： 由引理3.4知，对于区域 (3.6.25) 内的任意速率对 (R_1, R_2) ，令

$$|\mathcal{L}_n| = \lceil e^{n(R_1+2\gamma)} \rceil, \quad |\mathcal{M}_n| = \lceil e^{n(R_2+2\gamma)} \rceil,$$

γ 为任意的正实数，则存在编码器 ϕ_n 和 ψ_n ，其译码概率满足

$$\begin{aligned} P_e^{(n)}(\phi_n, \psi_n) &\leq \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \geq \frac{1}{n} \ln |\mathcal{L}_n| - \gamma\right. \\ &\quad \text{or } \frac{1}{n} \ln \frac{1}{P_{\hat{Y}^n|\hat{X}^n}(Y^n|X^n)} \geq \frac{1}{n} \ln |\mathcal{M}_n| - \gamma \\ &\quad \left.\text{or } \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n\hat{Y}^n}(X^nY^n)} \geq \frac{1}{n} \ln |\mathcal{L}_n| + \frac{1}{n} \ln |\mathcal{M}_n| - \gamma\right\} + 3e^{-n\gamma} \\ &\leq \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \geq R_1 + \gamma\right. \\ &\quad \text{or } \frac{1}{n} \ln \frac{1}{P_{\hat{Y}^n|\hat{X}^n}(Y^n|X^n)} \geq R_2 + \gamma \\ &\quad \left.\text{or } \frac{1}{n} \ln \frac{1}{P_{\hat{X}^n\hat{Y}^n}(X^nY^n)} \geq R_1 + R_2 + 3\gamma\right\} + 3e^{-n\gamma} \\ &\leq \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \geq R_1 + \gamma\right\} \\ &\quad + \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{\hat{Y}^n|\hat{X}^n}(Y^n|X^n)} \geq R_2 + \gamma\right\} \\ &\quad + \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{\hat{X}^n\hat{Y}^n}(X^nY^n)} \geq R_1 + R_2 + 3\gamma\right\} + 3e^{-n\gamma} \\ &\leq \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{\hat{X}^n|\hat{Y}^n}(X^n|Y^n)} \geq \bar{H}(\mathbf{X}|\mathbf{Y}) + \bar{D}(\mathbf{X}|\mathbf{Y}\|\hat{\mathbf{X}}|\hat{\mathbf{Y}}) + \gamma\right\} \\ &\quad + \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{\hat{Y}^n|\hat{X}^n}(Y^n|X^n)} \geq \bar{H}(\mathbf{Y}|\mathbf{X}) + \bar{D}(\mathbf{Y}|\mathbf{X}\|\hat{\mathbf{Y}}|\hat{\mathbf{X}}) + \gamma\right\} \\ &\quad + \Pr\left\{\frac{1}{n} \ln \frac{1}{P_{\hat{X}^n\hat{Y}^n}(X^nY^n)} \geq \bar{H}(\mathbf{XY}) + \bar{D}(\mathbf{XY}\|\hat{\mathbf{X}}\hat{\mathbf{Y}}) + 3\gamma\right\} + 3e^{-n\gamma} \end{aligned}$$

结合命题3.1可知，当 n 趋于无穷时，上述四项皆趋于零。另一方面，由于 γ 是任意的，故可选择一递减序列 $\{\gamma_k\}_{k=1}^{\infty}$ 满足 $\lim_{k \rightarrow \infty} \gamma_k = 0$ ，反复应用上述方法，由此得到一个关于 k （行号）和 n （列号）的两维编码器序列 $\phi_{k,n}$ 和 $\psi_{k,n}$ ，然后对每一行编码器，找出一个 $N(k)$ 满足当 $n \geq N(k)$ 时，

$$P_e^{(n)}(\phi_{k,n}, \psi_{k,n}) \leq \frac{1}{k},$$

显然， $N(1) = 1$ 。在此基础上我们定义函数

$$N'(k) \triangleq \begin{cases} N(1), & k = 1 \\ \max\{N(k), N(k-1) + 1\}, & k > 1 \end{cases} \quad (3.6.26a)$$

$$(3.6.26b)$$

于是，可以定义一个新的编码器序列 ϕ'_n 和 ψ'_n 为

$$\phi'_n = \phi_{k(n),n}, \quad \psi'_n = \psi_{k(n),n},$$

式中

$$k(n) = \max\{k \in \mathbb{Z}^+ | N'(k) \leq n\}.$$

因为当 n 趋于无穷时, $k(n)$ 也趋于无穷, 所以

$$\lim_{n \rightarrow \infty} R(\phi'_n) = \lim_{n \rightarrow \infty} \phi_{k(n),n} = R_1 + 2 \lim_{n \rightarrow \infty} \gamma_{k(n)} = R_1,$$

$$\lim_{n \rightarrow \infty} R(\psi'_n) = \lim_{n \rightarrow \infty} \psi_{k(n),n} = R_2 + 2 \lim_{n \rightarrow \infty} \gamma_{k(n)} = R_2,$$

$$\lim_{n \rightarrow \infty} P_e^{(n)}(\phi'_n, \psi'_n) = \lim_{n \rightarrow \infty} P_e^{(n)}(\phi_{k(n),n}, \psi_{k(n),n}) \leq \lim_{n \rightarrow \infty} \frac{1}{k(n)} = 0,$$

即速率对 (R_1, R_2) 是可达的。 □

由定理3.14很容易得到如下推论 (证明略)。

推论 3.3 假设相关信源为一般信源 \mathbf{XY} , Slepian-Wolf 系统所知的先验信源为一般信源 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$, 若满足

$$\overline{D}(\mathbf{X}|\mathbf{Y}||\hat{\mathbf{X}}|\hat{\mathbf{Y}}) = 0, \quad (3.6.27)$$

$$\overline{D}(\mathbf{Y}|\mathbf{X}||\hat{\mathbf{Y}}|\hat{\mathbf{X}}) = 0, \quad (3.6.28)$$

$$\overline{D}(\mathbf{XY}||\hat{\mathbf{X}}\hat{\mathbf{Y}}) = 0, \quad (3.6.29)$$

则以下区域

$$\{(R_1, R_2) : R_1 \geq \overline{H}(\mathbf{X}|\mathbf{Y}), R_2 \geq \overline{H}(\mathbf{Y}|\mathbf{X}), R_1 + R_2 \geq \overline{H}(\mathbf{XY})\}$$

内的速率对是可达的。

推论3.3告诉我们, 如果能够找到满足条件 (3.6.27)、(3.6.28) 和 (3.6.29) 的先验信源 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$, 那么从 Slepian-Wolf 编码的性能来看, 它和真实信源并没有差别。所以, 如果对于一类信源, 我们能够找到一个信源, 使其对于这一类信源都满足上述的条件, 那么我们实际上就已经找到了一种通用 Slepian-Wolf 编码的方法。

现在, 我们将用上述理论结果来解释最小熵译码器。有关类型论的定义、符号和性质, 请参考 [24–27], 我们将直接采用 [25] 中的符号习惯而不再重复定义。

最小熵译码器可以定义如下:

$$\text{me}_n(l, m) \triangleq \arg \min_{x^n y^n \in \phi_n^{-1}(l) \times \psi_n^{-1}(m)} H(P_{x^n y^n}). \quad (3.6.30)$$

式中, $P_{x^n y^n}$ 就是序列 $x^n y^n$ 的类型。对应于最小熵译码器, 我们定义一个一般信源 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$ 为

$$P_{\hat{\mathbf{X}}\hat{\mathbf{Y}}}(x^n y^n) = \frac{1}{|\mathcal{P}_n(\mathcal{X} \times \mathcal{Y})| \cdot |\mathcal{J}(P_{x^n y^n})|}, \quad (3.6.31)$$

式中， $\mathcal{P}(\mathcal{X} \times \mathcal{Y})$ 表示所有类型的集合，而 $\mathcal{J}(P_{x^n y^n})$ 表示所有类型为 $P_{x^n y^n}$ 的序列的集合。因为

$$\frac{1}{(n+1)^{|\mathcal{X}||\mathcal{Y}|}} e^{nH(P_{x^n y^n})} \leq |\mathcal{J}(P_{x^n y^n})| \leq e^{nH(P_{x^n y^n})},$$

所以可以认为信源 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$ 下的 MAP 译码器近似等价于最小熵译码器（笔者猜测两者应该是精确等价的，但即使当 n 很大时，这一点也不是可以轻易证明的）。

下面，我们将证明以 (3.6.31) 为先验知识的 Slepian-Wolf 系统在平稳无记忆信源下是一个通用编码系统。

定理 3.15 设相关平稳无记忆信源为 \mathbf{XY} ，则由 (3.6.31) 定义的一般信源 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$ 满足

$$\bar{D}(\mathbf{X}|\mathbf{Y}||\hat{\mathbf{X}}|\hat{\mathbf{Y}}) = 0, \quad (3.6.32)$$

$$\bar{D}(\mathbf{Y}|\mathbf{X}||\hat{\mathbf{Y}}|\hat{\mathbf{X}}) = 0, \quad (3.6.33)$$

$$\bar{D}(\mathbf{XY}||\hat{\mathbf{X}}\hat{\mathbf{Y}}) = 0, \quad (3.6.34)$$

所以由推论 3.3 知，以 $\hat{\mathbf{X}}\hat{\mathbf{Y}}$ 为知识的 Slepian-Wolf 系统在平稳无记忆信源下是一个通用编码系统。

证明： 首先，我们来估计一般信源 $\hat{\mathbf{X}}$ 和 $\hat{\mathbf{Y}}$ 的概率分布。

$$\begin{aligned} P_{\hat{X}^n}(x^n) &= \sum_{y^n \in \mathcal{Y}^n} P_{\hat{X}^n \hat{Y}^n}(x^n y^n) \\ &= \sum_{P_{XY} \in \mathcal{P}_n(\mathcal{X} \times \mathcal{Y}): P_X = P_{x^n}} \sum_{y^n \in \mathcal{J}_{Y|X}(x^n)} \frac{1}{|\mathcal{P}_n(\mathcal{X} \times \mathcal{Y})| \cdot |\mathcal{J}(P_{x^n y^n})|} \\ &= \sum_{P_{XY} \in \mathcal{P}_n(\mathcal{X} \times \mathcal{Y}): P_X = P_{x^n}} \frac{1}{|\mathcal{P}_n(\mathcal{X} \times \mathcal{Y})| \cdot |\mathcal{J}(P_{x^n})|}, \end{aligned}$$

于是，我们有

$$\frac{1}{|\mathcal{P}_n(\mathcal{X} \times \mathcal{Y})| \cdot |\mathcal{J}(P_{x^n})|} \leq P_{\hat{X}^n}(x^n) \leq \frac{1}{|\mathcal{J}(P_{x^n})|},$$

同理，

$$\frac{1}{|\mathcal{P}_n(\mathcal{X} \times \mathcal{Y})| \cdot |\mathcal{J}(P_{y^n})|} \leq P_{\hat{Y}^n}(y^n) \leq \frac{1}{|\mathcal{J}(P_{y^n})|}.$$

然后，我们来计算 $\bar{D}(\mathbf{X}|\mathbf{Y}||\hat{\mathbf{X}}|\hat{\mathbf{Y}})$ 、 $\bar{D}(\mathbf{Y}|\mathbf{X}||\hat{\mathbf{Y}}|\hat{\mathbf{X}})$ 和 $\bar{D}(\mathbf{XY}||\hat{\mathbf{X}}\hat{\mathbf{Y}})$ 。首先，计算 $\bar{D}(\mathbf{X}|\mathbf{Y}||\hat{\mathbf{X}}|\hat{\mathbf{Y}})$ ，对于任意的 $x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n$ ，我们有

$$\begin{aligned} \frac{1}{n} \ln \frac{P_{\hat{X}^n|\hat{Y}^n}(x^n|y^n)}{P_{\hat{X}^n \hat{Y}^n}(x^n y^n)} &= \frac{1}{n} \ln \frac{P_{\hat{X}^n \hat{Y}^n}(x^n y^n) \cdot P_{\hat{Y}^n}(y^n)}{P_{\hat{X}^n \hat{Y}^n}(x^n y^n) \cdot P_{\hat{Y}^n}(y^n)} \\ &\leq \frac{1}{n} \ln \frac{e^{-n(D(P_{x^n y^n}||X^1 Y^1)+H(P_{x^n y^n}))} \cdot |\mathcal{P}_n(\mathcal{X} \times \mathcal{Y})| \cdot |\mathcal{J}(P_{x^n y^n})|}{e^{-n(D(P_{y^n}||Y^1)+H(P_{y^n}))} \cdot |\mathcal{J}(P_{y^n})|} \\ &= -D(\tilde{X}|\tilde{Y}||X^1|Y^1) - H(\tilde{X}|\tilde{Y}) + \frac{1}{n} \ln |\mathcal{P}_n(\mathcal{X} \times \mathcal{Y})| + \frac{1}{n} \ln |\mathcal{J}_{\hat{X}|\hat{Y}}(y^n)| \\ &\leq \frac{|\mathcal{X}||\mathcal{Y}|}{n} \ln(n+1), \end{aligned}$$

式中 \tilde{X} 和 \tilde{Y} 为哑元随机变量, 满足 $P_{\tilde{X}\tilde{Y}} = P_{x^n y^n}$ 。推导中, 我们应用了如下一些性质:

$$\begin{aligned} P_{X^n Y^n}(x^n y^n) &= e^{-n(D(P_{x^n y^n} \| X^1 Y^1) + H(P_{x^n y^n}))}, \\ P_{Y^n}(y^n) &= e^{-n(D(P_{y^n} \| Y^1) + H(P_{y^n}))}, \\ D(\tilde{X} | \tilde{Y} \| X^1 | Y^1) &\geq 0, \\ |\mathcal{J}_{\tilde{X}|\tilde{Y}}(y^n)| &\leq e^{nH(\tilde{X}|\tilde{Y})}, \\ |\mathcal{P}_n(\mathcal{X} \times \mathcal{Y})| &\leq (n+1)^{|\mathcal{X}||\mathcal{Y}|}. \end{aligned}$$

因此, 对于任意正实数 α , 存在正整数 $N_0(\alpha)$, 使得当 $n \geq N_0(\alpha)$ 时, 对于所有的 $x^n y^n \in \mathcal{X}^n \times \mathcal{Y}^n$,

$$\frac{1}{n} \ln \frac{P_{X^n | Y^n}(x^n | y^n)}{P_{\hat{X}^n | \hat{Y}^n}(x^n | y^n)} \leq \alpha,$$

即对于充分大的 n ,

$$\Pr\left\{\frac{1}{n} \ln \frac{P_{X^n | Y^n}(x^n | y^n)}{P_{\hat{X}^n | \hat{Y}^n}(x^n | y^n)} > \alpha\right\} = 0,$$

由此推出

$$\bar{D}(\mathbf{X} | \mathbf{Y} \| \hat{\mathbf{X}} | \hat{\mathbf{Y}}) = 0,$$

同理可证

$$\bar{D}(\mathbf{Y} | \mathbf{X} \| \hat{\mathbf{Y}} | \hat{\mathbf{X}}) = 0,$$

$$\bar{D}(\mathbf{X} \mathbf{Y} \| \hat{\mathbf{X}} \hat{\mathbf{Y}}) = 0,$$

故定理得证。 □

通过上述的分析, 我们不仅用信息谱的方法建立了先验信源与通用编码间的联系, 而且还成功地解释了最小熵译码器的原理, 相信这种分析会对通用 Slepian-Wolf 编码理论和应用的研究具有一定的指导作用, 即可以把通用编码的研究归结为两方面的工作: 一方面是先验信源的构造, 另一方面是先验信源下低复杂性译码算法的设计。值得注意的是, 上述的理论分析只有在信息谱这一广义的信息论方法下才能获得成功, 因为我们为最小熵译码器所定义的先验信源是一个一般信源, 它并不是一个随机过程。

3.7 本章小结

本章的主要贡献如下:

在第3.3节中, 我们运用 Gallager 方法分析了一般信源下 Slepian-Wolf 系统在 MAP 译码下的性能, 给出了一个平均译码错误概率的上界 (定理3.1)。通过对其错误指数函数性质的分析 (引理3.1, 该引理本身也反映出一些有趣的性质), 我们在平稳无记忆相关信源下给出了 Slepian-Wolf 定理正命题部分的一个新证明 (定理3.2)。

在第3.4节中, 我们进一步结合不等式的技巧和信息谱方法的思想, 以定理3.1为基础, 在一般信源下给出了 Slepian-Wolf 定理正命题部分一个新证明 (定理3.4)。应用相同的技巧, 我们也证明了信道编码中的 Gallager 限在一般信道下也是十分紧的, 即可以用于证明信道编码定理的正命题部分 (定理3.5)。

在第3.5节中, 我们对基于线性信道码的线性 Slepian-Wolf 系统在 MAP 译码下的性能进行了分析, 给出了一个改进的平均译码错误概率的上界 (定理3.7), 该上界将系统的性能与线性码的谱联系了起来, 从而帮助我们更好地理解线性 Slepian-Wolf 系统。在此基础上, 我们分别分析了基于随机置换和 LDPC 码的线性 Slepian-Wolf 系统的性能 (定理3.9和定理3.13), 进而在理论上提出了一个新的对称 Slepian-Wolf 编码方案 (图3.7), 该方案相比现有的技术具有一定的优越性。

在第3.6节中, 我们运用信息谱方法建立了先验信源与通用 Slepian-Wolf 编码的联系 (定理3.14), 而后运用该结果对最小熵译码器作了解释 (定理3.15), 揭示了最小熵译码器的本质即为其所对应的先验信源 (3.6.31), 从而为今后通用 Slepian-Wolf 编码理论和应用的研究指出了一条有益的思路。

参考文献

- [1] A. Aaron and B. Girod, “Compression with side information using turbo codes,” in *Proc. DCC’02*, Mar. 2002, pp. 252–261.
- [2] ———, “Wyner-Ziv video coding with low encoder complexity,” in *Picture Coding Symposium 2004*, Dec. 2004.
- [3] R. Ahlswede, N. Cai, S.-Y. R. Li, and R. W. Yeung, “Network information flow,” *IEEE Trans. Inf. Theory*, vol. 46, no. 4, pp. 1204–1216, Jul. 2000.
- [4] R. Ahlswede, T. S. Han, and K. Kobayashi, “Universal coding of integers and unbounded search trees,” *IEEE Trans. Inf. Theory*, vol. 43, no. 2, pp. 669–682, Mar. 1997.
- [5] T. Amemiya and H. Yamamoto, “A new class of the universal representation for the positive integers,” *IEICE Trans. Fundamentals*, vol. E76-A, no. 3, pp. 447–452, Mar. 1993.
- [6] A. Apostolico and A. S. Fraenkel, “Robust transmission of unbounded strings using Fibonacci representations,” *IEEE Trans. Inf. Theory*, vol. 33, no. 2, pp. 238–245, Mar. 1987.
- [7] M. Arimura and H. Yamamoto, “Asymptotic optimality of the block sorting data compression algorithm,” *IEICE Trans. Fundamentals*, vol. E81-A, no. 10, pp. 2117–2122, Oct. 1998.
- [8] Z. Arnavut and S. S. Magliveras, “Block sorting and compression,” in *Proc. DCC’97*, Mar. 1997, pp. 181–190.
- [9] B. Balkenhol, S. Kurtz, and Y. M. Shtarkov, “Modifications of the Burrows and Wheeler data compression algorithm,” in *Proc. DCC’99*, Mar. 1999, pp. 188–197.
- [10] A. Bennatan and D. Burshtein, “On the application of LDPC codes to arbitrary discrete-memoryless channels,” *IEEE Trans. Inf. Theory*, vol. 50, no. 3, pp. 417–437, Mar. 2004.

-
- [11] J. L. Bentley and R. Sedgwick, “Fast algorithms for sorting and searching strings,” in *Proc. of 8th ACM-SIAM Symposium on Discrete Algorithms*, 1997, pp. 360–369.
- [12] J. L. Bentley, D. D. Sleator, R. E. Tarjan, and V. K. Wei, “A locally adaptive data compression scheme,” *Communications of the ACM*, vol. 29, no. 4, pp. 320–330, Apr. 1986.
- [13] T. Berger and Z. Zhang, “The CEO problem,” *IEEE Trans. Inf. Theory*, vol. 42, no. 3, pp. 887–902, May 1996.
- [14] C. Berrow, A. Glavieux, and P. Thitimajshima, “Near Shannon limit error-correcting coding and decoding,” in *Proc. ICC’93*, May 1993, pp. 1064–1070.
- [15] C. Bloom, “PPMZ2 v0.81,” 2004, <http://www.cbloom.com/src/ppmz.html>.
- [16] M. Burrows and D. J. Wheeler, “A block-sorting lossless data compression algorithm,” Digital System Research Center, Palo Alto, CA, Tech. Rep. SRC 124, 1994.
- [17] R. M. Capocelli, “Comments and additions to ‘robust transmission of unbounded strings using Fibonacci representations’,” *IEEE Trans. Inf. Theory*, vol. 35, no. 1, pp. 191–193, Jan. 1989.
- [18] R. M. Capocelli and A. D. Santis, “Regular universal codeword sets,” *IEEE Trans. Inf. Theory*, vol. 32, no. 1, pp. 129–133, Jan. 1986.
- [19] B. Chapin and S. R. Tate, “Higher compression from the Burrows-Wheeler transform by modified sorting,” in *Proc. DCC’98*, Mar. 1998, p. 532.
- [20] J. G. Cleary and I. H. Witten, “Data compression using adaptive coding and partial string matching,” *IEEE Trans. Commun.*, vol. 32, no. 4, pp. 396–402, Apr. 1984.
- [21] T. P. Coleman, A. H. Lee, M. Médard, and M. Effros, “On some new approaches to practical Slepian-Wolf compression inspired by channel coding,” in *Proc. DCC’04*, Mar. 2004, pp. 282–291.
- [22] T. P. Coleman, M. Médard, and M. Effros, “Towards practical minimum-entropy universal decoding,” in *Proc. DCC’05*, Mar. 2005, pp. 33–42.
- [23] T. M. Cover, “A proof of the data compression theorem of Slepian and Wolf for ergodic sources,” *IEEE Trans. Inf. Theory*, vol. 21, no. 2, pp. 226–228, Mar. 1975.

-
- [24] T. M. Cover and J. A. Thomas, *Elements of Information Theory*. John Wiley & Sons, 1991.
- [25] I. Csiszár, “Linear codes for sources and source networks: Error exponents, universal coding,” *IEEE Trans. Inf. Theory*, vol. 28, no. 4, pp. 585–592, Jul. 1982.
- [26] I. Csiszár and J. Körner, “Towards a general theory of source networks,” *IEEE Trans. Inf. Theory*, vol. 26, no. 2, pp. 155–165, Mar. 1980.
- [27] ———, *Information Theory: Coding Theorems for Discrete Memoryless Systems*. New York: Academic Press, 1981.
- [28] L. D. Davisson, “Universal noiseless coding,” *IEEE Trans. Inf. Theory*, vol. 19, no. 6, pp. 783–795, Nov. 1973.
- [29] S. Deorowicz, “Second step algorithms in the Burrows-Wheeler compression algorithm,” *Software—Practice and Experience*, vol. 32, no. 2, pp. 99–111, Feb. 2002.
- [30] M. Effros, “PPM performance with BWT complexity: A fast and effective data compression algorithm,” *Proc. IEEE*, vol. 88, no. 11, pp. 1703–1712, Nov. 2000.
- [31] M. Effros, K. Visweswariah, S. R. Kulkarni, and S. Verdú, “Universal lossless source coding with the Burrows Wheeler transform,” *IEEE Trans. Inf. Theory*, vol. 48, no. 5, pp. 1061–1081, May 2002.
- [32] P. Elias, “Universal codeword sets and representations of the integers,” *IEEE Trans. Inf. Theory*, vol. 21, no. 2, pp. 194–203, Mar. 1975.
- [33] ———, “Interval and recency rank source coding: Two on-line adaptive variable-length schemes,” *IEEE Trans. Inf. Theory*, vol. 33, no. 1, pp. 3–10, Jan. 1987.
- [34] S. Even and M. Rodeh, “Economical encoding of commas between strings,” *Commun. ACM*, vol. 21, no. 4, pp. 315–317, Apr. 1978.
- [35] M. Farach-Colton, P. Ferragina, and S. Muthukrishnan, “On the sorting-complexity of suffix tree construction,” *Journal of the ACM*, vol. 47, no. 6, pp. 987–1011, Nov. 2000.
- [36] P. Fenwick, “Block sorting text compression — final report,” Department of Computer Science, The University of Auckland, Tech. Rep. 130, Apr. 1996.
- [37] ———, “Punctured Elias codes for variable-length coding of the integers,” Department of Computer Science, The University of Auckland, Tech. Rep. 137, Dec. 1996.

-
- [38] —, “Burrows-Wheeler compression with variable length integer codes,” *Software—Practice and Experience*, vol. 32, no. 13, pp. 1307–1316, Nov. 2002.
- [39] B. M. Fitingof, “Optimal coding in the case of unknown and changing message statistics,” *Problems of Information Transmission*, vol. 2, no. 2, pp. 585–592, 1966.
- [40] D. P. Foster, R. A. Stine, and A. J. Wyner, “Universal codes for finite sequences of integers drawn from a monotone distribution,” *IEEE Trans. Inf. Theory*, vol. 48, no. 6, pp. 1713–1720, Jun. 2002.
- [41] A. S. Fraenkel and S. T. Klein, “Robust universal complete codes for transmission and compression,” *Discr. Appl. Math.*, vol. 64, pp. 31–55, 1996.
- [42] R. G. Gallager, *Low-Density Parity-Check Codes*. Cambridge, MA: MIT Press, 1963.
- [43] —, “A simple derivation of the coding theorem and some applications,” *IEEE Trans. Inf. Theory*, vol. 11, no. 1, pp. 3–8, Jan. 1965.
- [44] —, *Information Theory and Reliable Communications*. New York: Wiley, 1968.
- [45] R. G. Gallager and D. C. Van Voorhis, “Optimal source codes for geometrically distributed integer alphabets,” *IEEE Trans. Inf. Theory*, vol. 21, pp. 228–230, Mar. 1975.
- [46] A. E. Gamal and T. M. Cover, “Multiple user information theory,” *Proc. IEEE*, vol. 68, no. 12, pp. 1466–1483, Dec. 1980.
- [47] J. Garcia-Frias and W. Zhong, “LDPC codes for compression of multi-terminal sources with hidden markov correlation,” *IEEE Commun. Lett.*, vol. 7, no. 3, pp. 115–117, Mar. 2003.
- [48] S. W. Golomb, “Run-length encodings,” *IEEE Trans. Inf. Theory*, vol. 12, pp. 399–401, Jul. 1966.
- [49] T. S. Han, *Information-Spectrum Methods in Information Theory*. Berlin: Springer, 2003.
- [50] T. S. Han and K. Kobayashi, “A unified achievable rate region for a general class of multiterminal source coding systems,” *IEEE Trans. Inf. Theory*, vol. 26, no. 3, pp. 277–288, May 1980.

-
- [51] ———, *Mathematics of Information and Coding*. Providence, Rhode Island: American Mathematical Society, 2002.
- [52] T. S. Han and S. Verdú, “Approximation theory of output statistics,” *IEEE Trans. Inf. Theory*, vol. 39, no. 3, pp. 752–772, May 1993.
- [53] P. G. Howard, “The design and analysis of efficient lossless data compression systems,” Ph.D. dissertation, Brown University, Jun. 1993.
- [54] D. A. Huffman, “A method for the construction of minimum redundancy codes,” *Proceedings of the Institute of Radio Engineers*, vol. 40, no. 9, pp. 1098–1101, Sep. 1952.
- [55] R. Y. K. Isal and A. Moffat, “Parsing strategies for BWT compression,” in *Proc. DCC’01*, Mar. 2001, pp. 429–438.
- [56] H. Itoh and H. Tanaka, “An efficient method for in memory construction of suffix arrays,” in *Proc. of 6th Symposium on String Processing and Information Retrieval*, 1999, pp. 81–88.
- [57] M. Kac, “On the notion of recurrence in discrete stochastic process,” *Bull. Amer. Math. Soc.*, vol. 53, pp. 1002–1010, Oct. 1947.
- [58] R. M. Karp, R. E. Miller, and A. L. Rosenberg, “Rapid identification of repeated patterns in strings, arrays and trees,” in *Proc. of 4th ACM Symposium on Theory of Computing*, 1972, pp. 125–136.
- [59] A. N. Kolmogorov, “Three approaches to the quantitative definition of information,” *Problems of Information Transmission*, vol. 1, no. 1, pp. 1–7, 1965.
- [60] F. R. Kschischang, B. J. Frey, and H.-A. Loeliger, “Factor graphs and the sum-product algorithm,” *IEEE Trans. Inf. Theory*, vol. 47, no. 2, pp. 498–519, Feb. 2001.
- [61] S. Kurtz, “Reducing the space requirement of suffix trees,” *Software—Practice and Experience*, vol. 29, no. 13, pp. 1149–1171, Nov. 1999.
- [62] K. B. Lakshmanan, “On universal codeword sets,” *IEEE Trans. Inf. Theory*, vol. IT-27, no. 5, pp. 659–662, Sep. 1981.
- [63] N. J. Larsson and K. Sadakane, “Faster suffix sorting,” Dept of Computer Science, Lund University, Sweden, Tech. Rep. LU-CS-TR:99-214, 1999.

-
- [64] J. Li, Z. Tu, and R. S. Blum, "Slepian-Wolf coding for nonuniform sources using turbo codes," in *Proc. DCC'04*, Mar. 2004, pp. 312–321.
- [65] S. Litsyn and V. Shevelev, "On ensembles of low-density parity-check codes: Asymptotic distance distributions," *IEEE Trans. Inf. Theory*, vol. 48, no. 4, pp. 887–908, Apr. 2002.
- [66] J. loup Gailly, "GZIP-1.2.4," 1993, <http://www.gzip.org/>.
- [67] D. J. C. MacKay, "Good error-correcting codes based on very sparse matrices," *IEEE Trans. Inf. Theory*, vol. 45, no. 2, pp. 399–431, Mar. 1999.
- [68] U. Manber and E. Myers, "Suffix arrays: A new method for on-line string searches," *SIAM Journal on Computing*, vol. 22, no. 5, pp. 935–948, Oct. 1993.
- [69] G. Manzini and P. Ferragina, "Engineering a lightweight suffix array construction algorithm," in *Lecture Notes in Computer Science*. Springer Verlag, 2002, vol. 2461, pp. 698–710.
- [70] E. M. McCreight, "A space-economical suffix tree construction," *Journal of the ACM*, vol. 23, no. 2, pp. 262–272, Apr. 1976.
- [71] B. McMillan, "The basic theorems of information theory," *Ann. Math. Statist.*, vol. 24, pp. 196–219, Jun. 1953.
- [72] N. Merhav, G. Seroussi, and M. J. Weinberger, "Optimal prefix codes for sources with two-sided geometric distributions," *IEEE Trans. Inf. Theory*, vol. 46, no. 1, pp. 121–135, Jan. 2000.
- [73] G. Miller and D. Burshtein, "Bounds on the maximum-likelihood decoding error probability of low-density parity-check codes," *IEEE Trans. Inf. Theory*, vol. 47, no. 7, pp. 2696–2710, Nov. 2001.
- [74] S. Miyake and F. Kanaya, "Coding theorems on correlated general sources," *IEICE Trans. Fundamentals*, vol. E78-A, no. 9, pp. 1063–1070, Sep. 1995.
- [75] A. Moffat, "Implementing the PPM data compression scheme," *IEEE Trans. Commun.*, vol. 38, no. 11, pp. 1917–1921, Nov. 1990.
- [76] J. Muramatsu, "On the performance of recency-rank and block-sorting universal lossless data compression algorithms," *IEEE Trans. Inf. Theory*, vol. 48, no. 9, pp. 2621–2625, Sep. 2002.

-
- [77] J. Muramatsu, T. Uyematsu, and T. Wadayama, “Low density parity check matrices for coding of correlated sources,” in *Proc. ISIT 2003*, Yokohama, Japan, Jun. 2003, p. 173.
- [78] Y. Oohama and T. S. Han, “Universal coding for the Slepian-Wolf data compression system and the strong converse theorem,” *IEEE Trans. Inf. Theory*, vol. 40, no. 6, pp. 1908–1919, Nov. 1994.
- [79] A. Orłitsky and N. P. Santhanam, “Performance of universal codes over infinite alphabets,” in *Proc. DCC’03*, Mar. 2003, pp. 402–410.
- [80] S. S. Pradhan, “Distributed source coding using syndromes (DISCUS),” Ph.D. dissertation, University of California at Berkeley, fall 2001.
- [81] S. J. Puglisi and W. F. Smyth, “The performance of linear time suffix sorting algorithm,” in *Proc. DCC’05*, Mar. 2003, pp. 358–367.
- [82] R. F. Rice, “Some practical universal noiseless coding techniques—Part III,” Jet Propulsion Laboratory, Pasadena, CA, Tech. Rep. JPL-91-3, 1991.
- [83] T. J. Richardson, M. A. Shokrollahi, and R. L. Urbanke, “Design of capacity-approaching irregular low-density parity-check codes,” *IEEE Trans. Inf. Theory*, vol. 47, no. 2, pp. 619–637, Feb. 2001.
- [84] T. J. Richardson and R. L. Urbanke, “The capacity of low-density parity-check codes under message-passing decoding,” *IEEE Trans. Inf. Theory*, vol. 47, no. 2, pp. 599–618, Feb. 2001.
- [85] J. Rissanen, “Generalized kraft inequality and arithmetic coding,” *IBM J. Res. Devel.*, vol. 20, pp. 198–203, 1976.
- [86] K. Sadakane, “A fast algorithm for making suffix arrays and for Burrows-Wheeler transformation,” in *Proc. DCC’98*, Mar. 1998, pp. 129–138.
- [87] D. Schonberg, K. Ramchandran, and S. S. Pradhan, “Distributed code constructions for the entire Slepian-Wolf rate region for arbitrarily correlated sources,” in *Proc. DCC’04*, Mar. 2004, pp. 292–301.
- [88] J. Seward, “BZIP2-1.0.1,” 2000, <http://www.digistar.com/bzip2/>.
- [89] —, “On the performance of BWT sorting algorithms,” in *Proc. DCC’00*, Mar. 2000, pp. 173–182.

-
- [90] C. E. Shannon, "A mathematical theory of communication," *Bell System Technical Journal*, vol. 27, pp. 379–423 and 623–656, 1948.
- [91] N. Shulman and M. Feder, "Random coding techniques for nonrandom codes," *IEEE Trans. Inf. Theory*, vol. 45, no. 6, pp. 2101–2104, Sep. 1999.
- [92] D. Slepian and J. K. Wolf, "Noiseless coding of correlated information sources," *IEEE Trans. Inf. Theory*, vol. 19, no. 4, pp. 471–480, Jul. 1973.
- [93] V. Stanković, A. D. Liveris, Z. Xiong, and C. N. Georghiades, "Design of Slepian-Wolf codes by channel code partitioning," in *Proc. DCC'04*, Mar. 2004, pp. 302–311.
- [94] Q. F. Stout, "Improved prefix encoding of the natural numbers," *IEEE Trans. Inf. Theory*, vol. 26, no. 5, pp. 607–609, Sep. 1980.
- [95] W. Szpankowski, "Asymptotic average redundancy of Huffman (and other) block codes," *IEEE Trans. Inf. Theory*, vol. 46, no. 7, pp. 2434–2442, Nov. 2000.
- [96] R. M. Tanner, "A recursive approach to low complexity codes," *IEEE Trans. Inf. Theory*, vol. 27, no. 5, pp. 533–547, Sep. 1981.
- [97] B. P. Tunstall, "Synthesis of noiseless compression codes," Ph.D. dissertation, Georgia Institute of Technology, Atlanta, GA, Sep. 1967.
- [98] T. Uyematsu, "An algebraic construction of codes for Slepian-Wolf source networks," *IEEE Trans. Inf. Theory*, vol. 47, no. 7, pp. 3082–3088, Nov. 2001.
- [99] ———, "Universal coding for correlated sources with memory," in *Proc. CWIT 2001*, Jun. 2001.
- [100] M. Wang, "Almost asymptotically optimal flag encoding of the integers," *IEEE Trans. Inf. Theory*, vol. 34, no. 2, pp. 324–326, Mar. 1988.
- [101] M. J. Weinberger, G. Seroussi, and G. Sapiro, "The LOCO-I lossless image compression algorithm: Principles and standardization into JPEG-LS," *IEEE Trans. Image Process.*, vol. 9, no. 8, pp. 1309–1324, Aug. 2000.
- [102] A. D. Wyner, "An upper bound on the entropy series," *Information and Control*, vol. 20, no. 2, pp. 176–181, Mar. 1972.
- [103] A. D. Wyner and J. Ziv, "The rate-distortion function for source coding with side information at the decoder," *IEEE Trans. Inf. Theory*, vol. 22, no. 1, pp. 1–10, Jan. 1976.

-
- [104] A. D. Wyner, J. Ziv, and A. J. Wyner, “On the role of pattern matching in information theory,” *IEEE Trans. Inf. Theory*, vol. 44, no. 6, pp. 2045–2056, Oct. 1998.
- [105] H. Yamamoto and H. Ochi, “A new asymptotically optimal code for the positive integers,” *IEEE Trans. Inf. Theory*, vol. 37, no. 5, pp. 1420–1429, Sep. 1991.
- [106] Y. Yang, V. Stanković, Z. Xiong, and W. Zhao, “On multiterminal source code design,” in *Proc. DCC’05*, Mar. 2005, pp. 43–52.
- [107] R. Zamir, S. Shamai, and U. Erez, “Nested linear/lattice codes for structured multiterminal binning,” *IEEE Trans. Inf. Theory*, vol. 48, no. 6, pp. 1250–1276, Jun. 2002.
- [108] Y. Zhao and J. Garcia-Frias, “Data compression of correlated non-binary sources using punctured turbo codes,” in *Proc. DCC’02*, Mar. 2002, pp. 242–251.
- [109] J. Ziv and A. Lempel, “A universal algorithm for sequential data compression,” *IEEE Trans. Inf. Theory*, vol. 23, no. 3, pp. 337–343, May 1977.
- [110] ———, “Compression of individual sequences via variable-rate coding,” *IEEE Trans. Inf. Theory*, vol. 24, no. 5, pp. 530–536, Sep. 1978.

攻读博士学位期间的研究成果

1. S. Yang and P. Qiu, "Some Extensions of Gallager's Method to General Sources and Channels," accepted by *2005 IEEE International Symposium on Information Theory*.
2. S. Yang and P. Qiu, "On the Performance of Linear Slepian-Wolf Codes for Correlated Stationary Memoryless Sources," in *Proc. Data Compression Conference 2005*, Snowbird, UT, March 29-31, 2005, pp. 53-62.
3. 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. *电子与信息学报*, 2005, 27(4): 514-518.
4. 杨胜天, 仇佩亮. 一组整数的几个实用编码方案. *通信学报*, 已录用.
5. 杨胜天, 仇佩亮. Slepian-Wolf 定理的一个新证明与非随机码的随机编码技术. *2004 年全国博士生学术论坛 (数学学科论文集)*, 北京大学, 2004 年 8 月.
6. 杨胜天, 仇佩亮. 一个快速的二值分组算术编码器. *浙江大学学报 (工学版)*, 2004, 38(4): 461-464.
7. 杨胜天. 结合重正化操作的快速二值分组算术编码器. *通信学报*, 2004, 25(3): 119-125.
8. 杨胜天, 童勤业. 生物医学信号的近无损压缩. *中国生物医学工程学报*, 2003, 22(3): 235-240.
9. S. Yang and P. Qiu, "On the Performance of Golomb Codes for Arbitrary Nonincreasing Probability Distributions," submitted to *IEICE Transaction on Fundamentals of Electronics, Communications and Computer Sciences*, under the final review.
10. 杨胜天, 仇佩亮. Slepian-Wolf 定理的一个新证明与非随机码的性能分析. *电子学报*, 2004 年 6 月投稿.

博士期间参加的科研项目：无线网络中多用户合作分集技术研究（国家自然科学基金 60472079）、基于多用户信息论的无线合作通信技术研究（高等学校博士点科研基金 2004-0335099）。

致 谢

感谢我的导师仇佩亮教授，感谢导师对我的悉心指导，是他将我真正领进了信息论这一广阔而有趣的研究领域，使我确立了毕生为之奋斗的方向。导师严谨的治学态度、求真务实的科研作风、勤奋工作的敬业精神和渊博的知识都使我终身受益。

感谢谢磊、陈惠芳副教授，林丽莉、孙水发、孙健、董斌、余官定、石璟、陈雁博士，苏航、谢林、莫霄雁、陈实、董波、何亮硕士。感谢他们在三年的学习和生活中给予的支持和帮助。

感谢我的父母，感谢他们培养了我对科学真理的执著，支持我从事科学研究工作，感谢他们支持我完成了博士阶段的学业。