



经典译丛

PEARSON

信息与通信技术

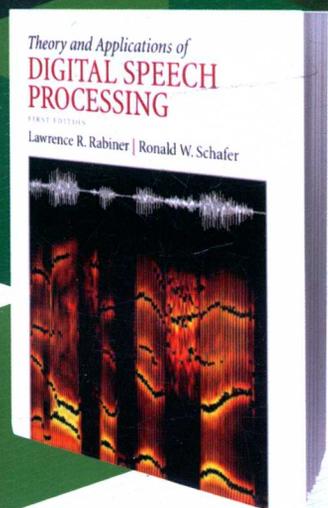
数字语音处理 理论与应用

Theory and Applications of Digital Speech Processing

【美】 Lawrence R. Rabiner 著
Ronald W. Schafer

刘加 张卫强 何亮 路程 等译

Theory and Applications of Digital Speech Processing



中国工信出版集团



电子工业出版社
PUBLISHING HOUSE OF ELECTRONICS INDUSTRY
<http://www.phei.com.cn>

经典译丛·信息与通信技术

数字语音处理

理论与应用

Theory and Applications of Digital
Speech Processing

[美] Lawrence R. Rabiner
Ronald W. Schafer 著

刘加 张卫强 何亮 路程 等译



电子工业出版社

Publishing House of Electronics Industry

北京·BEIJING

内 容 简 介

本书是作者继1978年出版的经典教材《语音信号的数字处理》之后的又一著作，全书除有简练精辟的基础知识介绍外，系统讲解了近30年来语音信号处理的新理论、新方法和在应用上的新进展。全书共14章，分四部分：第一部分介绍语音信号处理基础知识，主要包括数字信号处理基础、语音产生机理、（人的）听觉和听感知机理，以及声道中的声传播原理；第二部分介绍语音信号的时、频域表示和分析；第三部分介绍语音参数估计方法；第四部分介绍语音信号处理的应用，主要包括语音编码、语音和音频信号的频域编辑、语音合成、语音识别及自然语言理解。

本书可供高等院校通信、电子、计算机等专业作为研究生和本科生的教材，也可供相关科研和工程技术人员参考，是一本既有系统的基础理论讲解，又有最新研究前沿介绍并紧密结合应用发展的教材。

Authorized Translation from the English language edition, entitled Theory and Applications of Digital Speech Processing, ISBN: 9780136034285 by Lawrence R. Rabiner and Ronald W. Schafer, published by Pearson Education, Inc., publishing as Prentice Hall, Copyright © 2011 Pearson Education, Inc.

All Rights Reserved. No part of this book may be reproduced or transmitted in any form or by any means, electronic or mechanical, including photocopying, recording or by any information storage retrieval system, without permission from Pearson Education, Inc.

CHINESE SIMPLIFIED language edition published by PEARSON EDUCATION ASIA LTD. and PUBLISHING HOUSE OF ELECTRONICS INDUSTRY Copyright © 2015.

本书中文简体字版专有出版权由Pearson Education（培生教育出版集团）授予电子工业出版社，未经出版者预先书面许可，不得以任何方式复制或抄袭本书的任何部分。

本书封面贴有Pearson Education（培生教育出版集团）激光防伪标签，无标签者不得销售。

版权贸易合同登记号 图字：01-2010-5783

图书在版编目（CIP）数据

数字语音处理理论与应用/（美）拉比纳（Rabiner, L. R.），（美）谢弗（Schafer, R. W.）著；刘加等译.

北京：电子工业出版社，2016.1

书名原文：Theory and Applications of Digital Speech Processing

ISBN 978-7-121-27590-6

I. ①数… II. ①拉… ②谢… ③刘… III. ①语音数据处理—高等学校—教材 IV. ①TN912.3

中国版本图书馆 CIP 数据核字（2015）第 273596 号

策划编辑：马 岚

责任编辑：谭海平

印 刷：涿州市京南印刷厂

装 订：涿州市京南印刷厂

出版发行：电子工业出版社

北京市海淀区万寿路 173 信箱 邮编 100036

开 本：787×1 092 1/16 印张：42.5 字数：1196 千字 彩插：2

版 次：2016 年 1 月第 1 版

印 次：2016 年 1 月第 1 次印刷

定 价：128.00 元

凡所购买电子工业出版社图书有缺损问题，请向购买书店调换。若书店售缺，请与本社发行部联系，联系及购电话：（010）88254888。

质量投诉请发邮件至 zlts@phei.com.cn，盗版侵权举报请发邮件至 dbqq@phei.com.cn。

服务热线：（010）88258888。

译者序

语音信号处理是一门古老而新颖的学科，说它“古老”是因为它与数字信号处理同时代产生，说它“新颖”是因为它一直经历着令人激动的变革和挑战。Lawrence R. Rabiner 教授作为这些变革的亲历者和大师级人物，有着深刻的切身体验，他的著作，如 1978 年他与 Ronald W. Schafer 教授合著的《语音信号数字处理》和 1993 年他与 Biing-Hwang Juang 教授合著的《语音识别基本原理》，也成为了语音信号处理领域的经典和必备读物。2010 年，在清华大学电子工程系朱雪龙教授的推荐下，电子工业出版社希望我们完成 Rabiner 教授和 Schafer 教授的新作《数字语音处理理论与应用》一书的翻译工作，我们欣然接受了翻译任务。然而，翻译的过程是艰辛的，为了能够对原文有比较准确的翻译表述，我们经历了无数个不眠之夜，历时五载，终于完成了初稿。在此期间，由于机器学习（尤其是深度学习）、听觉感知、听觉场景分析等理论和技术的发展，语音信号和信息处理技术经过一段平缓发展期后，又开始生机盎然，语音识别、说话人识别、语种识别、语音增强、语音和音频编解码、自然语言处理等技术都有新的创新，其系统性能也有显著提升。语音相关的产品也如雨后春笋般地涌现。在此时机下，我们期待此书的翻译出版能对国内语音界的科研人员，以及本科生和研究生的专业教学有所帮助。

本书原著结合自己的科研实践对数字语音信号处理的基本原理和应用进行了深入分析，既有理论深度，又通俗易懂。内容分为四个层次逐级展开：第一个层次介绍语音信号处理基础知识，主要包括数字信号处理基础、语音产生机理、人的听觉和听感知与声道中的声传播；第二个层次介绍语音信号的时频表示，主要包括时域表示、频域表示、倒谱及同态处理和线性预测分析；第三个层次介绍语音参数估计算法，主要包括静音检测、清浊判断、基音和共振峰估计等；第四个层次介绍语音信号处理的应用，主要包括语音编码、语音和音频频域编码、语音合成、语音识别和自然语言理解。除了深入浅出的讲解外，书中还附有大量生动的插图，各章之后还附有精心设计的习题和 MATLAB 练习，以便读者对基础知识和基本方法深入理解和灵活应用。

本书能够得以完成，要特别感谢清华大学的朱雪龙教授，他不但为我们和出版社牵线搭桥，而且一直关心着我们的翻译工作；另外他于 1983 年牵头翻译的《语音信号数字处理》也为本书提供了诸多宝贵的参考和基础。感谢电子工业出版社的相关编辑，他们为本书的引进做出了贡献，同时对我们的翻译工作给予了大力支持。

在本书的翻译工作中，清华大学电子工程系语音与音频技术实验室的博士研究生和博士后也参与了部分内容的翻译工作，他们是（按姓氏拼音排序）：蔡猛、钱彦旻、单煜翔、史永哲、杨毅等，在此一并表示感谢。

本书虽然经过两次翻译校对，但是难免仍然会存在错误和不妥之处，欢迎读者批评指正。

刘加 张卫强 何亮 路程
2015 年 11 月于清华园

前 言

70 多年来, 语音信号处理一直是一个活跃且不断发展的领域。最早的语音处理系统是模拟系统, 如 20 世纪 30 年代由 Homer Dudley 及其同事们在贝尔实验室开发并于 1939 年在纽约世博会上展出的 Voder 系统, 该系统可通过手工操作合成出语音; 同期, Homer Dudley 在贝尔实验室还开发出了通道声码器或声音编码器; 20 世纪 40 年代, Koenig 及其同事们在贝尔实验室开发出了声音语谱图系统, 该系统可以在时域和频域展示语音的时变特征; 另外, 20 世纪 50 年代, 全世界的很多研究实验室都开发出了早期的语音单词识别系统。

数字信号处理 (DSP) 起源于 20 世纪 60 年代, 在 DSP 应用的广泛领域中, 语音处理是其早期发展的驱动力。在此期间, 先驱研究者如麻省理工学院林肯实验室的 Ben Gold 和 Charlie Rader, 贝尔实验室的 Jim Flanagan、Roger Golden 和 Jim Kaiser, 他们开始研究数字滤波器的设计 and 应用方法, 并用于语音处理系统的模拟仿真。随着 1965 年 Jim Cooley 和 John Tukey 发明快速傅里叶变换 (FFT) 技术以及 FFT 在快速卷积和谱分析方面的广泛应用, 模拟技术的束缚和局限逐渐被打破, 数字语音处理随之产生并展现出了清晰的面貌。

1968 年至 1974 年期间, 本书作者 (Lawrence R. Rabiner 和 Ronald W. Schafer) 在贝尔实验室一起密切地工作, 期间 DSP 领域取得了很多的基础性进展。当 Ronald W. Schafer 于 1975 年离开贝尔实验室并在佐治亚理工学院任学术职位时, 数字语音处理领域已蓬勃发展, 于是我们觉得是时候写一本关于语音信号数字处理方法和系统的教材了。到 1976 年, 我们相信数字语音处理的理论发展得已经足够完备, 精心撰写一本教材不但可以作为讲授数字语音处理基础知识的教材, 还可以作为未来语音处理实际应用系统设计的参考书。1978 年, Prentice Hall 公司出版了这本教材《数字语音信号处理》。采用这本教材, Ronald W. Schafer 开设了第一门数字语音处理的研究生课程, 期间 Lawrence R. Rabiner 仍在贝尔实验室从事数字语音处理基础的研究工作 (Lawrence R. Rabiner 在贝尔实验室和 AT&T 实验室工作了 40 年, 2002 年也进入学术界, 在罗格斯大学和加州大学圣巴巴拉分校任教。Ronald W. Schafer 在佐治亚理工学院工作 30 年后, 于 2004 年加入了惠普实验室)。

1978 年出版的教材的目标是, 介绍语音基础知识和数字语音处理方法, 以便构建强大的语音信号处理系统。从宏观层面来说, 我们达到了最初的目标。本书按我们的预想服务了 30 多年, 令我们高兴的是, 直到今天它仍然广泛应用于本科生和研究生的语音信号处理课程教学。然而, 根据我们过去 20 年来教授语音处理课程的经验, 原书的基础尚可, 但很多内容已与当代语音信号处理系统脱节, 且未涉及当前的很多研究热点。这本新书正是我们改进这些问题的尝试。

在着手统一数字语音处理的现有理论和实践的艰巨任务时, 我们发现原书中的很多内容还是正确且相关的, 因此新书的起点很好。此外, 我们从语音处理的科研和教学经验中了解到, 1978 年出版的教材中, 虽然内容组织基本上没有问题, 但它已经不适合用来理解当代的语音处理系统。针对这些问题, 我们在组织新书的内容时采用了新的框架, 它与原书相比有两大改变。首先, 我们包含了已有的数字语音处理知识体系结构。这种体系的第一层是语音基础科学和工程方面的基础知识; 第二层是语音信号的各种表示。原书主要侧重了这两层, 但一些关键主题则有所缺失。第三层是操作、处理和抽取语音信号中信息的各种算法, 这些算法基于前两层的科学和技术知识。

顶层（即第四层）是语音处理算法的各种应用，以及处理语音通信系统中问题的技术。

我们努力按照这种体系结构（即语音金字塔）来展现新书的内容。为达到这一目的，第2章至第5章主要介绍金字塔的底层，内容包括语音产生和感知基础知识、DSP 基础知识回顾，以及声学、语音学、语言学、语音感知、声道中的声音传播等。第6章至第9章介绍如何通过基本的信号处理原理来表示数字语音信号（语音金字塔的第二层）。第10章介绍如何设计可靠和稳健的语音算法来估计感兴趣的语音参数（语音金字塔的第三层）。最后，第11章至第14章介绍如何利用语音金字塔前几层的知识来设计和实现各种语音应用（语音金字塔的第四层）。

新书在结构和行文上的一个重要变化是，为了尽可能地方便教学，我们在呈现内容时侧重于学习新思想的三个方面，即理论、概念和实现。对每个基本概念，我们都用很容易理解的 DSP 概念进行理论阐释；类似地，为了加深理解，每个新概念都提供了简单的数学解释和精心准备的例子与插图；最后，基于教学中对基础知识的理解，针对每个新概念的实现，提供了可实现特定语音处理操作的 MATLAB 代码（通常包含在每章中），每章的习题中配备了文档详尽的 MATLAB 练习。我们还在教学网站上提供了求解所有 MATLAB 练习所需要的内容，如 MATLAB 代码、数据库、语音文件等。最后，我们提供了几种语音处理系统结果的音频演示。通过这种方式，读者可以直观地了解各种语音信号处理后的语音质量。

更具体地讲，这本新书的组织如下。第1章简要介绍语音处理的领域，简要讨论贯穿于全书的主题的应用领域。第2章简要回顾 DSP 的概念，重点在于与语音处理系统密切相关的几个关键概念：

1. 从时域到频域的转换（通过离散时间傅里叶变换方法）。
2. 了解频域采样的影响（即时域混叠）。
3. 了解时域采样（包括下采样和上采样）的影响，以及频域的混叠和镜像。

在回顾 DSP 技术的基础知识后，第3章和第4章讨论语音的产生和感知。这两章与第2章和第5章一起，构成了语音金字塔的底层。从这里，我们开始讨论语音产生的声学理论，对不同的语音发音，我们导出了一系列声学语音模型，并展示了语言学和语音学如何与语音发声声学一起相互作用，生成语音信号及其在语言上的解释。讨论从语音在人耳中如何处理开始，到声音转换为通往大脑的听感知神经通路中的神经信号结束，我们通过分析语音感知过程，讨论了语音通信的基本过程，还简要讨论了几种在一些语音处理应用中可能嵌入语音感知知识到听感知模型的方法。第5章介绍关于人类声音在声道中传播问题的基础知识，表明与声道相似的均匀无损声管具有共振结构，以此阐明语音中的共振（共振峰）频率。还展示了如何通过适当的“终端模拟”数字系统来表示一系列级联声管的传播特性。该“终端模拟”数字系统具有特定的激励函数、对应不同长度和面积声管的特定系统响应，以及对对应声音在唇端传输的特定辐射特征。

接下来的四章主要介绍4种数字语音信号的表示（语音金字塔的第二层）。第6章从语音产生的时域模型开始，逐步展示了如何通过简单的时域测量方法来估计模型中的基本时变属性。第7章介绍对语音信号应用短时傅里叶分析，以便实现无失真的分析/合成系统。取决于待处理信息的性质，我们解释了两种短时傅里叶分析/合成系统，两者都有着广泛的应用。第8章描述语音的同态（倒谱）表示，其中用到了卷积信号（如语音）可以转换为一系列加性分量这一性质。由于语音信号可以表示为激励信号和声道系统的卷积，因此语音信号非常适合于这种分析。第9章介绍线性预测分析和实践，线性预测是语音信号的一种模型表示，当前的语音样本可以通过先前 p 个语音样本的线性组合建模表示，通过寻找最优线性预测器（最小均方误差）的系数，实现在给定时间段内最优的匹配语音信号。

第10章（语音金字塔的第三层）使用前面章节中介绍的信号处理表示和语音信号基础知识，

介绍了如何使用短时（对数）能量、短时过零率、短时自相关函数等测量值来估计基本的语音属性，例如分析的信号段是语音还是静音（背景信号）、语音段是浊音还是清音、浊音语音段的基音周期（基音频率）、语音段的共振峰（声道共振）等。对于许多语音属性，4种语音表示中的每一种，都可以作为估计语音属性的高效算法使用。同时还介绍了如何基于4种语音表示中的两种测量法来估计共振峰。

第11章至第14章（语音金字塔的顶层）介绍语音和音频信号处理技术的几种主要应用。这些应用是深入理解语音和音频技术的成果。讨论语音应用的目的是，让读者基本了解如何构建这些应用，了解它们在不同比特率和不同应用场景下的性能。具体来讲，第11章介绍语音编码系统（包括开环和闭环系统）；第12章介绍如何使用感知掩蔽准则来构建具有最小编码感知误差的音频编码系统；第13章介绍如何构建口语对话系统中使用的文语转换合成系统；第14章介绍语音识别和自然语言处理系统，以及它们在一系列面向任务的场景中的应用。

本书可作为已先修DSP课程的一个学期的语音处理教材。在我们自己的教学实践中，重点讲解第3章至第11章，同时选讲其他章节的部分内容，以便使学生对音频编码、语音合成和语音识别系统也有一定的认识。为了帮助教学，每章都提供了一些有代表性的课后习题，以强化每章讨论的概念。成功完成合理数量的课后习题，对理解语音处理的数学和理论概念非常重要。但如读者了解的那样，很多语音处理都是经验性的，因此我们提供了许多MATLAB练习来强化学生对语音处理基本概念的理解。我们还提供了配套的教学网站^①（http://www.pearsonhighered.com/educator/product/Theory-and-Applications-of-Digital-Speech-Processing/9780136034285.page#dw_resources），并随时更新网站的内容，包括所需的语音文件、数据库和求解MATLAB练习的MATLAB代码，以及一系列语音处理概念的演示。

致谢

在语音处理的职业生涯中，我们非常幸运拥有过在杰出研究和学术机构的工作经历，这些单位为我们提供了充满激情的研究环境，并且鼓励我们分享知识。对于Lawrence R. Rabiner而言，这些单位包括贝尔实验室、AT&T实验室、罗格斯大学和加州大学圣巴巴拉分校；对于Ronald W. Schafer而言，这些单位包括贝尔实验室、佐治亚理工大学ECE和惠普实验室。没有这些单位的同事和领导的支持与鼓励，这本书不会存在。

很多人对本书的内容有直接或间接的重大影响，但我们最应感谢的是James L. Flanagan博士，他是我们两人职业生涯中很多关键时期的导师和益友。Jim为我们如何从事科研、如何清晰地呈现研究结果提供了指导。无论是对这本书还是对我们各自的职业，他的影响都是非常深远的。

感谢有幸合作并互相学习的其他人，包括我们的导师麻省理工学院的Alan Oppenheim教授和Kenneth Stevens教授，以及我们的同事佐治亚理工学院的Tom Barnwell教授、Mark Clements教授、Chin Lee教授、Fred Juang教授、Jim McClellan教授和Russ Mersereau教授。这些人既是我们的同事，又是我们的老师，我们感激他们的睿智和多年来的指导。

直接参与本书准备工作的同事包括Bishnu Atal博士、Victor Zue教授、Jim Glass教授和Peter Noll教授，他们都提供了见解深刻的成果，这些成果对本书中的很多内容产生了很大的影响。感谢其他人允许我们使用其发表物中的图表，包括Alex Acero、Joe Campbell、Raymond Chen、Eric Cosatto、Rich Cox、Ron Crochiere、Thierry Dutoit、Oded Ghitza、Al Gorin、Hynek Hermansky、Nelson Kiang、Rich Lippman、Dick Lyon、Marion Macchi、John Makhoul、Mehryar Mohri、Joern Ostermann、David Pallett、Roberto Pieraccini、Tom Quatieri、Juergen Schroeter、Stephanie Seneff、Malcolm Slaney、Peter Vary和Vishu Viswanathan。

^① 本书向授课教师提供英文原版教辅（习题解答、PPT），具体申请方式请参见书后的“教学支持说明”。

感谢朗讯-阿尔卡特公司、IEEE、美国声学学会和 House-Ear Institute 允许我们使用已发表或备档的图表。

同时要感谢 Prentice Hall 公司的那些帮助出版本书的人员，包括策划编辑 Andrew Gilfillan、责任编辑 Clare Romeo 和助理编辑 William Opaluch。还要感谢 TexTech International 公司负责文字编校工作的 Maheswari PonSaravanan。

最后，感谢赞助商 Suzanne Dorothy 对我们给予的关爱、耐心和支持。

Lawrence R. Rabiner 和 Ronald W. Schafer

目 录

第 1 章 数字语音处理介绍	1	2.5.7 FIR 滤波器的优点	34
1.1 语音信号	2	2.6 小结	34
1.2 语音堆	5	习题	34
1.3 数字语音处理的应用	6	第 3 章 人类语音产生基础	42
1.3.1 语音编码	6	3.1 引言	42
1.3.2 文语转换合成	7	3.2 语音产生过程	42
1.3.3 语音识别和其他模式匹配问题	7	3.2.1 语音产生机理	42
1.3.4 其他语音应用	8	3.2.2 语音特征与语音波形	46
1.4 参考文献评论	9	3.2.3 语音生成的声学理论	49
1.5 小结	10	3.3 语音的短时傅里叶表示	50
第 2 章 数字信号处理基础回顾	11	3.4 声音语音学	53
2.1 引言	11	3.4.1 元音	55
2.2 离散时间信号与系统	11	3.4.2 双元音	60
2.3 信号与系统的变换表示	13	3.4.3 声音的辨音特质	60
2.3.1 连续时间傅里叶变换	14	3.4.4 半元音	61
2.3.2 z 变换	14	3.4.5 鼻音	62
2.3.3 离散时间傅里叶变换	16	3.4.6 清擦声	64
2.3.4 离散傅里叶变换	17	3.4.7 浊擦音	65
2.3.5 DTFT 的采样	18	3.4.8 浊塞音	67
2.3.6 DFT 的性质	19	3.4.9 清塞音	67
2.4 数字滤波器基础	20	3.4.10 破擦声和耳语音	69
2.4.1 FIR 系统	20	3.5 美式英语音素的辨音特质	70
2.4.2 FIR 滤波器设计方法	21	3.6 小结	70
2.4.3 FIR 滤波器实现	23	习题	71
2.4.4 IIR 系统	23	第 4 章 听觉、听感知模型和语音感知	80
2.4.5 IIR 滤波器设计方法	23	4.1 引言	80
2.4.6 IIR 系统的实现	24	4.2 语言链	80
2.4.7 关于 FIR 和 IIR 滤波器设计方法的说明	27	4.3 解剖学和耳的功能	82
2.5 采样	27	4.3.1 基底膜机理	84
2.5.1 采样原理	27	4.3.2 临界频带	85
2.5.2 语音和音频波形的采样率	28	4.4 声音的感知	85
2.5.3 改变采样信号的采样率	29	4.4.1 声音的强度	87
2.5.4 抽取	29	4.4.2 人的听觉范围	87
2.5.5 插值	32	4.4.3 响度级	90
2.5.6 非整数采样率变化	33	4.4.4 响度	91
		4.4.5 音高	91

4.4.6	掩蔽效应——音调	92	6.2	语音的短时分析	154
4.4.7	掩蔽效应——噪声	93	6.2.1	短时分析的通用框架	156
4.4.8	时域掩蔽效应	94	6.2.2	短时分析中的滤波和采样	156
4.4.9	语音编码中的掩蔽效应	95	6.3	短时能量和短时幅度	159
4.4.10	参数鉴别——JND	95	6.3.1	基于短时能量的自动增益控制	160
4.5	听感知模型	96	6.3.2	短时幅度	162
4.5.1	感知线性预测	96	6.4	短时过零率	163
4.5.2	Seneff 听感知模型	97	6.5	短时自相关函数	169
4.5.3	Lyon 听感知模型	99	6.6	修正短时自相关函数	173
4.5.4	整体区间直方图方法	100	6.7	短时平均幅度差分函数	176
4.5.5	听感知模型小结	101	6.8	小结	177
4.6	人类语音感知实验	101	习题		177
4.6.1	噪声中的声音感知	102	第 7 章	频域表示	183
4.6.2	噪声中的语音感知	103	7.1	引言	183
4.7	语音质量和可懂度测量	104	7.2	离散时间傅里叶分析	184
4.7.1	主观测试	105	7.3	短时傅里叶分析	186
4.7.2	语音质量的客观测量	106	7.3.1	DTFT 解释	187
4.8	小结	107	7.3.2	DFT 实现	188
习题		107	7.3.3	加窗对分辨率的影响	188
第 5 章	声道中的声音传输	109	7.3.4	关于短时自相关函数	193
5.1	语音产生的声学原理	109	7.3.5	线性滤波解释	193
5.1.1	声音传播	109	7.3.6	时域和频域中 $X_n(e^{j\omega})$ 的采样率	197
5.1.2	例子: 均匀无损声管	110	7.4	频谱显示	199
5.1.3	声道中损耗的影响	114	7.5	合成的重叠相加法	206
5.1.4	嘴唇的辐射影响	117	7.5.1	精确重建的条件	206
5.1.5	元音的声道传输函数	120	7.5.2	合成窗的应用	211
5.1.6	鼻腔耦合的影响	123	7.6	合成的滤波器组求和方法	212
5.1.7	声道中声音的激励	123	7.7	时间抽取滤波器组	217
5.1.8	基于声学理论的模型	127	7.7.1	通用 FBS 抽取系统	218
5.2	无损声管模型	128	7.7.2	最大抽取滤波器组	221
5.2.1	级联无损声管中的波形传播	128	7.8	双通道滤波器组	222
5.2.2	边界条件	130	7.8.1	正交镜像滤波器组	223
5.2.3	与数字滤波器的关系	134	7.8.2	QMF 滤波器组的多相结构	225
5.2.4	无损声管模型的传输函数	137	7.8.3	共轭正交滤波器	225
5.3	采样语音信号的数字模型	141	7.8.4	树形结构滤波器组	226
5.3.1	声道建模	141	7.9	使用 FFT 实现 FBS 方法	228
5.3.2	辐射模型	143	7.9.1	FFT 分析技术	228
5.3.3	激励模型	144	7.9.2	FFT 合成技术	230
5.3.4	完整模型	144	7.10	OLA 再论	232
5.4	小结	146	7.11	修正的 STFT	233
习题		146			
第 6 章	语音信号处理的时域方法	153			
6.1	引言	153			

7.11.1	乘性修正	233	9.2.2	自相关法	305
7.11.2	加性修正	236	9.2.3	协方差法	307
7.11.3	时间标度修正: 相位声码器	237	9.2.4	小结	308
7.12	小结	242	9.3	模型增益的计算	309
	习题	242	9.4	线性预测分析的频域解释	311
第 8 章	倒谱和同态语音处理	255	9.4.1	线性预测短时频谱分析	311
8.1	简介	255	9.4.2	均方预测误差的频域解释	313
8.2	卷积同态系统	256	9.4.3	模型阶数 p 的作用	316
8.2.1	DTFT 表示	257	9.4.4	线性预测语谱图	318
8.2.2	z 变换表示	260	9.4.5	与其他谱分析方法的对比	320
8.2.3	复倒谱的性质	260	9.4.6	选择性线性预测	321
8.2.4	复倒谱分析实例	262	9.5	LPC 方程组的解	322
8.2.5	最小和最大相位信号	264	9.5.1	Cholesky 分解	322
8.3	语音模型的同态分析	265	9.5.2	Levinson-Durbin 算法	325
8.3.1	浊音模型的同态分析	266	9.5.3	格型公式及其解	328
8.3.2	清音模型的同态分析	271	9.5.4	计算需求比较	334
8.4	计算语音的短时倒谱和复倒谱	273	9.6	预测误差信号	335
8.4.1	基于离散傅里叶变换的计算	273	9.6.1	归一化均方误差的其他表示法	338
8.4.2	基于 z 变换的计算	276	9.6.2	LPC 参数值的实验评估	339
8.4.3	最小相位和最大相位信号的递归计算	278	9.6.3	归一化误差随帧位置的变化	342
8.5	自然语音的同态滤波	279	9.7	LPC 多项式 $A(z)$ 的一些性质	344
8.5.1	语音短时倒谱分析模型	280	9.7.1	预测误差滤波器的最小相位性质	344
8.5.2	使用多项式根的短时分析实例	281	9.7.2	PARCOR 系数和 LPC 多项式的稳定性	344
8.5.3	应用 DFT 的浊音分析	282	9.7.3	最佳 LP 模型根的位置	345
8.5.4	最小相位分析	286	9.8	线性预测分析与无损声管模型的关系	348
8.5.5	应用 DFT 的清音分析	287	9.9	LP 参数的替代表示	351
8.5.6	短时倒谱分析小结	289	9.9.1	预测误差多项式的根	351
8.6	全极点模型的倒谱分析	290	9.9.2	全极点系统 $\bar{H}(z)$ 的冲激响应	352
8.7	倒谱距离度量	291	9.9.3	冲激响应的自相关	352
8.7.1	线性滤波补偿	292	9.9.4	倒谱	352
8.7.2	加权倒谱距离度量	292	9.9.5	预测器多项式的自相关系数	353
8.7.3	群时延频谱	293	9.9.6	PARCOR 系数	353
8.7.4	mel 频率倒谱系数	294	9.9.7	对数面积比系数	353
8.7.5	动态倒谱特征	296	9.9.8	线性谱对参数	355
8.8	小结	296	9.10	小结	357
	习题	296		习题	357
第 9 章	语音信号的线性预测分析	301	第 10 章	语音参数的估计算法	368
9.1	引言	301	10.1	引言	368
9.2	线性预测分析的基本原理	302			
9.2.1	线性预测分析方程的基本公式	304			

10.2	中值平滑和语音处理	369	11.8.3	Δ 调制中的高阶预测器	481
10.3	语音背景/静音的鉴别	373	11.8.4	LDM 到 PCM 的转换	482
10.4	浊音/清音/静音检测的一种贝叶斯方法	378	11.8.5	Δ - Σ 模数转换	485
10.5	基音周期估计(基音检测)	383	11.9	差分脉冲编码调制	486
10.5.1	理想的基音周期估计	383	11.9.1	自适应量化 DPCM	487
10.5.2	使用一种并行处理方法的基音周期估计	386	11.9.2	自适应预测 DPCM	488
10.5.3	自相关、周期性和中心削波	390	11.9.3	ADPCM 系统的对比	491
10.5.4	一种基于自相关的基音估计器	395	11.10	ADPCM 编码器的改善	492
10.5.5	频域中的基音检测	397	11.10.1	ADPCM 编码的基音预测	493
10.5.6	用于基音检测的同态系统	399	11.10.2	DPCM 系统中的噪声整形	495
10.5.7	使用线性预测参数的基音检测	403	11.10.3	完全量化的自适应预测编码器	498
10.6	共振峰估计	405	11.11	综合分析语音编码	502
10.6.1	共振峰估计的同态系统	405	11.11.1	A-b-S 语音编码系统的基本原理	504
10.6.2	使用线性预测参数的共振峰分析	410	11.11.2	多脉冲 LPC	507
10.9	小结	412	11.11.3	码激励线性预测(CELP)	509
习题		412	11.11.4	比特率为 4800bps 的 CELP 编码器	514
第 11 章	语音信号数字编码	424	11.11.5	低延时 CELP (LD-CELP) 编码	516
11.1	引言	424	11.11.6	A-b-S 语音编码小结	517
11.2	语音信号采样	426	11.12	开环语音编码器	517
11.3	语音统计模型	427	11.12.1	二态激励模型	518
11.3.1	自相关函数和功率谱	427	11.12.2	LPC 声码器	519
11.4	瞬时量化	433	11.12.3	残差激励 LPC	521
11.4.1	均匀量化噪声分析	435	11.12.4	混合激励系统	522
11.4.2	瞬时压扩(压缩/扩展)	442	11.13	语音编码器的应用	522
11.4.3	最优 SNR 量化	448	11.13.1	语音编码器的标准化	523
11.5	自适应量化	453	11.13.2	语音编码器的质量评价	524
11.5.1	前馈自适应	454	11.14	小结	526
11.5.2	反馈自适应	458	习题		526
11.5.3	自适应量化的总体评价	461	第 12 章	语音和音频的频域编码	541
11.6	语音模型参数的量化	461	12.1	引言	541
11.6.1	语音模型的标量量化	462	12.2	历史回顾	542
11.6.2	向量量化	463	12.2.1	通道声码器	542
11.6.3	VQ 实现的要素	466	12.2.2	相位声码器	545
11.7	差分量化的一般理论	470	12.2.3	早期的 STFT 数字编码工作	546
11.8	Δ 调制	476	12.3	子带编码	546
11.8.1	线性 Δ 调制	476	12.3.1	理想的 2 子带编码器	547
11.8.2	自适应 Δ 调制	479			

12.3.2	子带编码的量化器	552	13.5.3	从文本中进行在线单元选择	597
12.3.3	子带语音编码器示例	552	13.5.4	单元选择问题	597
12.4	自适应变换编码	554	13.5.5	转移代价和单元代价	599
12.5	音频编码的感知模型	556	13.5.6	单元边界平滑和修改	600
12.5.1	短时分析和合成	556	13.5.7	单元选择方法的实验结果	605
12.5.2	临界带理论回顾	557	13.6	TTS 的未来需求	605
12.5.3	听阈	558	13.7	可视化 TTS	605
12.5.4	STFT 的声压校正	559	13.7.1	VTTS 处理	606
12.5.5	掩蔽效应回顾	560	13.8	小结	608
12.5.6	掩蔽音的识别	562	习题		608
12.5.7	STFT 的量化	564	第 14 章	自动语音识别和自然语言理解	610
12.6	MPEG-1 音频编码标准	566	14.1	引言	610
12.6.1	MPEG-1 滤波器组	566	14.2	自动语音识别简述	611
12.6.2	通道信号的量化	571	14.3	语音识别的整体过程	611
12.6.3	MPEG-1 层 II 和层 III	573	14.4	构建一个语音识别系统	612
12.7	其他语音编码标准	574	14.4.1	识别任务	613
12.8	小结	574	14.4.2	识别特征集	613
习题		574	14.4.3	识别训练	614
第 13 章	文语转换合成方法	582	14.4.4	测试与性能评估	614
13.1	简介	582	14.5	ASR 中的决策过程	614
13.2	文本分析	582	14.5.1	ASR 问题的贝叶斯原理	615
13.2.1	文档结构检测	583	14.5.2	Viterbi 算法	618
13.2.2	文本正则化	583	14.5.3	步骤 1: 声学建模	619
13.2.3	语义分析	584	14.5.4	步骤 2: 语言模型	620
13.2.4	语音学分析	584	14.6	步骤 3: 搜索问题	623
13.2.5	多音词消歧	585	14.7	简单的 ASR 系统: 孤立的数字识别	624
13.2.6	字母-声音转换	585	14.8	语音识别器的性能评估	625
13.2.7	韵律分析	586	14.9	口语理解	628
13.2.8	韵律指定	586	14.10	对话管理和口语生成	629
13.3	语音合成方法的发展	587	14.11	用户界面	631
13.4	早期的语音合成方法	588	14.12	多模态用户界面	631
13.4.1	声码器	588	14.13	小结	632
13.4.2	终端模拟语音合成	590	习题		632
13.4.3	发音器官语音合成方法	591	附录 A	语音和音频处理演示	637
13.4.4	单词拼接合成	593	附录 B	频域微分方程求解	644
13.5	单元选择方法	595	参考文献		646
13.5.1	拼接单元的选择	595	术语表		662
13.5.2	自然语音中的单元选择	597			

第 1 章 数字语音处理介绍

本书内容包括从古老人类语言的研究到最新的计算机芯片。自贝尔创造性地发明电话以来，工程师和科学家就一直在研究语音通信，目的是发明更加高效的人与人之间及人与机器之间的通信系统。19 世纪 60 年代，数字信号处理（DSP）技术开始在语音通信研究中处于核心地位，今天 DSP 技术已让过去几十年的许多研究成果得到应用。期间，集成电路技术、DSP 算法和计算机体系结构方面的进展创造了很好的技术环境，为语音处理、图像和视频处理、雷达和声呐、医疗诊断系统及消费电子等领域提供了近乎无限的创新机会。重要的是，要注意到过去 50 多年里 DSP 技术和语音处理技术是共同发展进步的，语音处理技术的应用促进了 DSP 技术理论和算法研究的发展，而这些发展又在语音通信研究和技术领域得到了实际应用。我们有理由预计将来这种共生关系会一直持续下去。

为充分理解一门技术，譬如数字语音处理，我们必须进行三个层次的理解，即理论层次、概念层次和实践层次。图 1.1 描绘了这一技术金字塔^①。就语音技术来说，理论层次包含以下方面：语音产生的声学理论，语音信号表示的基本数学知识，每种表示所关联语音的各种属性的推导，以及通过采样、混频、滤波等将语音信号和现实世界关联的信号处理的基本数学运算。概念层次涉及如何应用语音处理理论进行各种语音测量，以及估计和量化语音信号的各种属性。最后，为使一门技术充分发挥潜力，将理论层次和概念层次转换到实践层次必不可少，即能够实现语音处理系统来求解特殊的应用问题。这个过程涉及对某个应用的约束条件和目标的认识、工程上的取舍和判断、编写可工作的计算机代码（通常是用 MATLAB、C 或 C++ 编写的程序），或是运行在实时信号处理芯片（如 ASIC、FPGA、DSP 芯片）上的特定代码的能力。

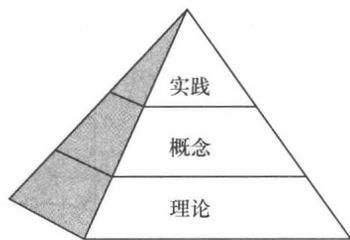


图 1.1 技术金字塔：理论、概念和实践

数字实现技术能力的持续改进反过来又开辟了新的应用领域，这些领域过去被认为是不可能或不现实的，这一道理同样适用于数字语音处理领域。因此，本书将重点放在对前面两个层次的理解上，但应时刻牢记最终的技术回报是在技术金字塔的第三层（实践层）。数字语音处理领域的基本原理和概念必然会继续发展和扩大，但过去 50 多年里学到的知识仍会为我们在未来几十年里看到的应用奠定基础。因此，对于本书涵盖的语音处理方面的各个主题，我们将努力使大家对理论层和概念层有尽可能多的理解；我们会提供一组练习题让读者在实践层次获得专业知识，这通常是通过每章后面习题中的 MATLAB 练习题来达到的。

在绪论的剩余部分，我们首先介绍语音通信过程和语音信号，最后介绍数字语音处理技术的重要应用领域。本书其他部分的设计是为了给读者对基本原理的学习打下扎实的基础，并强调 DSP 技术在现代语音通信研究和应用中扮演的核心角色。我们的目标是全面概述数字语音处理，内容涵盖了从语音信号的基本特性、以数字形式表示语音的各种方法，到语音通信及语音自动合成和识别应用的各个方面。在这个过程中，我们希望回答如下问题：

- 语音信号的本质是什么？
- 学习语音信号过程中 DSP 技术扮演怎样的角色？

^① 使用术语“技术金字塔”而非“技术三角形”，是为了强调每层都有宽度和厚度并且支持更高的层。

- 语音信号有哪些基本的数字表示？它们在语音处理算法中怎样使用？
- 数字语音处理方法有哪些重要应用？

首先介绍语音信号以了解语音信号的性质。

1.1 语音信号

语音的基本目的是为了人类沟通，即说话者和倾听者之间消息的传输。据香农信息论^[364]，以离散符号序列表示的消息可对其信息量以比特进行量化，信息传输速率可用比特/秒（bps）进行度量。在语音产生及许多人类设计的电子通信系统中，待传输信息以连续变化的波形（模拟波形）进行编码，这种波形可以传输、记录（存储）、操纵，最后被倾听者解码。消息的基本模拟形式是一种称为语音信号的声学波。如图 1.2 所示，语音信号可通过麦克风转换成电信号，进一步通过模拟和数字信号处理方法进行操纵，然后可根据需要通过扬声器、电话听筒或头戴式耳机转换回声学波。这种语音处理方式为贝尔发明电话奠定了基础，同时也是今天大多数记录、传输、操纵语音和音频信号的设备的基础。用贝尔自己的话说^[47]：“华生，如果我能够得到一种像声音传播时空气改变密度那样改变电流密度的机制，就能通过电来传递任何声音，甚至是语音。”

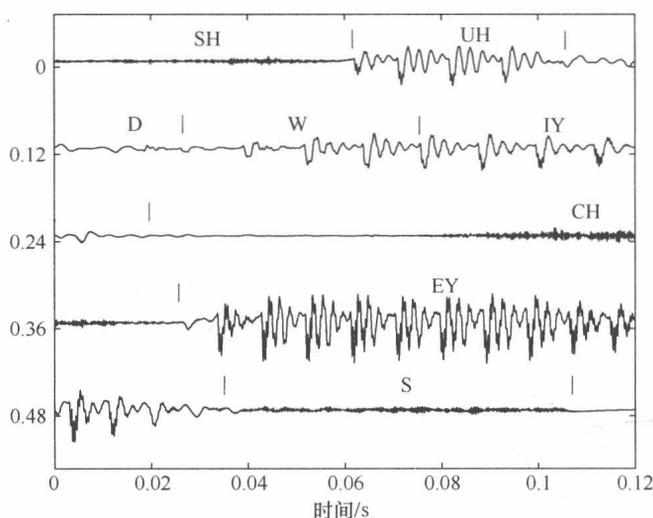


图 1.2 消息“should we chase”的语音波形，其中带有音素标记

虽然贝尔在不知道信息论的情况下有了伟大的发明，但信息论的原理在设计复杂的现代数字通信系统时发挥着巨大的作用。因此，尽管我们的重点在于语音波形和其参数化模型的表示，但讨论一下在语音波形编码中使用的信息论还是有用的。

图 1.3 形象化地展示了语音信号产生和感知的完整过程——从说话者大脑中消息的形成，到语音信号的产生，最后到倾听者对消息的理解。Denes and Pinson^[88]在其语言学的经典介绍中，将这一过程称为语音链。图 1.4 给出了语音链的详细框图。这个过程从左上方开始，此时消息以某种方式出现在说话者的大脑中。在语音产生过程中，消息携带的信息可认为有着不同的表示形式（如图 1.4 上面的路径所示）。例如，消息最初可能以英语文本的形式表示。为“说出”这条消息，说话者隐式地将文本转换成对应口语形式声音序列的符号表示。该步骤在图 1.4 中被称为语言码生成过程，它将文本符号转换成音素符号（伴随着重音和段长信息），音素符号用来描述口语形式消息的基本声音及声音产生的方式（即语速和语调）。例如，若将图 1.2 中的波形片段用一种便

于计算机键盘输入的 ARPabet^①代码标记, 则文本“should we chase”按照发音可表示成[SH UH D - WIY - CH EY S] (关于音素标注的详细讨论, 见第 3 章)。语音产生过程的第三步是转变成“神经肌肉控制”, 这组控制信号指引神经肌肉系统以一种与产生口语形式消息及其语调相一致的方式, 移动舌头、唇、牙齿、颌、软腭这些发音器官, 神经肌肉控制这一步的最终结果是产生一组关节运动(连续控制), 使声道发音器官按照规定的方式移动, 进而发出期望的声音。语音产生过程的最后一步是“声道系统”, 声道系统产生物理声源和恰当的时变声道形状, 产生图 1.2 所示的声学波形。通过这种方式, 期望表达消息中的信息就被编码为语音信号。

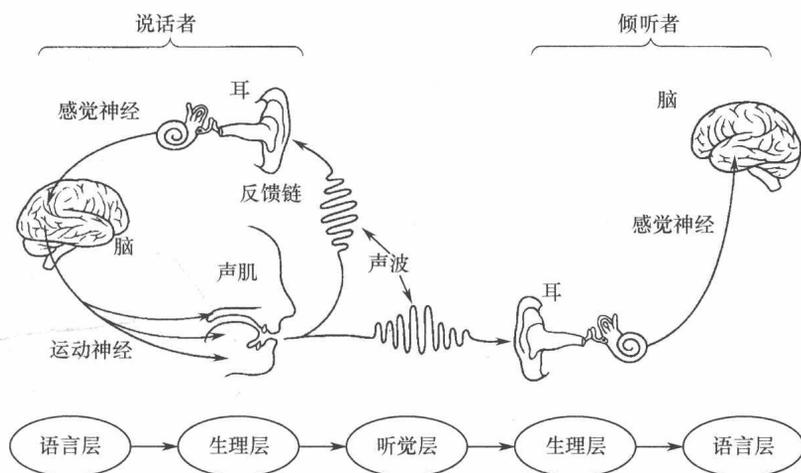


图 1.3 语音链: 从消息到语音信号再到理解 (据 Denis and Pinson^[88])

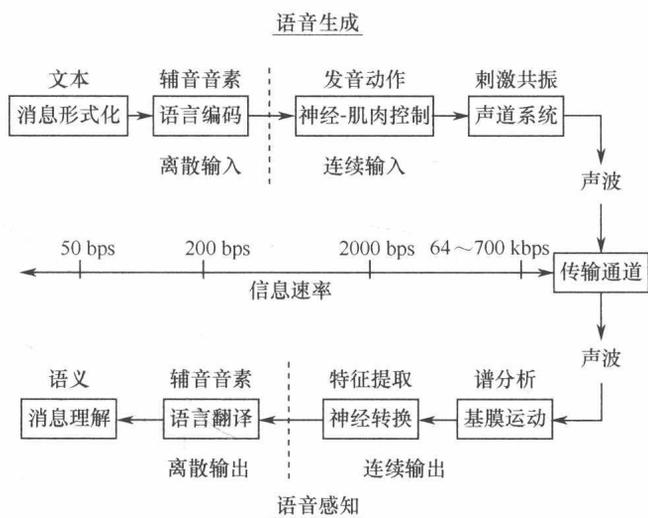


图 1.4 语音链的框图表示

为了确定语音产生过程中信息流的速率, 我们假设在书面语中约有 32 个符号(字母, 英语中有 26 个字母, 若包括标点符号和空格, 则接近 $32 = 2^5$ 个符号)。正常的平均说话速率约为 15 个符号每秒, 因此, 假设字母相互独立后做简单的一阶近似, 文本消息编码成语音后的基本信息速率约为 75bps (5 比特每符号乘以 15 个符号每秒)。但是, 实际的速率会随着说话的速率变化而变化。

① 国际语音协会 (IPA) 为音素标注提供了一套规则, 它用等价的一组特殊符号来表示音标。ARPabet 编码不需要特殊字体, 因此更加便于计算机应用。

对于图 1.2 中的例子，文本包含 15 个字母（包括空格），对应的语音词条持续了 0.6 秒，因此有更高的速率 $15 \times 5 / 0.6 = 125\text{bps}$ 。在语音产生过程的第二个阶段，文本表示转变成基本声音的单元，它们称为带有韵律（即音高和重音）标记的音素，此时信息速率很容易达到 200bps 以上。图 1.2 中用来标注语音片段的 ARBAbet 音素集包含近 $64 = 2^6$ 个符号，即 6 比特每音素（假设音素相互独立得到的粗略近似）。在图 1.2 中，大约 0.6 秒的时间里大约有 8 个音素，计算得到信息速率为 $8 \times 6 / 0.6 = 80\text{bps}$ ，考虑描述信号韵律特征的额外信息（如段长、音高、响度），文本信息编码成语音信号后，总信息速率需要再加上 100bps 。

语音链前两个阶段的信息表示是离散的，所以用一些简单假设就可估计信息流的速率。在语音链中语音产生部分的下一阶段，信息表示变成连续的（以关节运动时的神经肌肉控制信号的形式）。若它们能被度量，就可估计这些控制信号的频谱带宽，进行恰当的采样和量化获得等效的数字信号，进而估计数据的速率。与产生的声学波形的时间变化相比，关节的运动相当缓慢。带宽估计和信号表示需要达到的精度要求意味着被采样的关节控制信号的总数据率约为 2000bps ^[105]。因此，用一组连续变化信号表示的原始文本消息传输，比用离散文本信号表示的消息传输需要更高的数据率^①。在语音链中语音产生部分的最后阶段，数字语音波形的数据率可从 64000bps 变化到超过 700000bps 。我们是通过测量表示语音信号时为达到想要的感知保真度所需要的采样率和量化率计算得到上面的结果的。例如，“电话质量”的语音处理需要保证带宽为 $0 \sim 4\text{kHz}$ ，这意味着采样率为 8000 个样本/秒。每个样本可以用对数尺度量化成 8 比特，从而得到数据率 64000bps 。这种表示方式很容易听懂（即人们可很容易地从其中提取出消息），但对于大多数倾听者来说，语音听起来与说话者发出的原始语音会有不同。另一方面，语音波形可以表示成“CD 质量”，即采用 44100 个样本/秒的采样率，每个样本 16 比特，总数据率为 705600bps ，此时复原的声学波听起来和原始语音信号几乎没有区别。

当我们通过语音链将文本表示变成语音波形表示时，消息编码后能够以声学波形的形式进行传播，并且可被倾听者的听觉机制稳健地解码。前面对数据率的分析表明，当我们将消息从文本表示转换成采样的语音波形时，数据率会增大 10000 倍。这些额外信息的一部分能够代表说话者的一些特征，如情绪状态、说话的习惯、口音等，但主要是由简单采样和对模拟信号进行精细量化的低效性导致的。因此，出于语音信号固有的低信息速率的考虑，很多数字语音处理的重点是用比采样波形更低的数据率对语音进行数字表示。

完整的语音链包括上面讨论的语音产生/生成模型，也包括图 1.4 底部从右向左显示的语音感知/识别模型。语音感知模型显示了从耳朵捕捉语音信号到理解语音信号编码中携带的消息的一系列处理步骤。第一步是将声学波有效地转换成频谱表示，这是由耳朵内部的基底膜实现的，基底膜的作用类似于非均匀频谱分析仪，它能将输入语音信号的频谱成分进行空间分离，以非均匀滤波器组的方式进行频谱分析。语音感知过程中的第二步是神经传导过程，将频谱特征变成可被大脑解码和处理的声音特征（或语音学领域中所指的差异性特征）。第三步通过人脑的语言翻译过程将声音特征变成与输入消息对应的一组音素、词和句子。语音感知模型中的最后一步是将消息对应的音素、词和句子变成对基本信息意义的理解，进而做出响应或采取适当的处理。我们对图 1.4 中大部分语音感知模块过程的基本理解还是非常初步的，但人们普遍认为语音感知模型中各个步骤物理间的相互关联发生在人脑中，因此整个模型对于思考语音感知模型中各个过程的发生非常有帮助。第 4 章中将讨论听觉和感知机理。

图 1.4 所示的整个语音链框图中还有一个过程我们没有讨论，即模型中语音产生部分和语音感

① 为数字表示引入术语“数据率”，是为了区别于语音信号表示的消息中所含的内在信息内容。