

汉语中介语动态追踪有声 数据库建设的基本设想

袁丹 吴勇毅^①

[摘要] 本文介绍了汉语中介语动态追踪有声数据库不同于以往中介语语料库的特点，其特点在于语音的多样性、自动词典与词表的设计、信息库的建立、语音数据采集、语音标注、语音识别、语音参数提取软件、声乐训练软件等。该数据库将为汉语学习者提供一个良好的学习环境，从而为汉语留学生语音测试软件用于语音诊断及语音矫正提供研究基础。

[关键词] 汉语中介语、动态追踪、有声数据库

The Innovation of Chinese Inter-language Dynamic Tracing Audio Database

Yuan Dan Wu Yongyi

[Abstract] This paper discusses the construction process of the Chinese inter-language dynamic tracing audio database, which with different characteristics from the previous inter-language database, includes word list designing, information database building, sound data collecting, sound labeling, sound recognition, speech parameters extracting software, vocal training software, etc. This database will provide a good learning environment for Chinese learners, and thus provide research basis for pronunciation test software used for speech diagnosis and speech correction.

[Key words] Chinese inter-language, dynamic tracing, audio database

1 引言

因为对语音数据库建立最为关注的是少数民族语言学界，鲍怀慈等（1992）就已提出了建立藏语拉萨话语音学参数数据库的构想，而后蒙古语（呼和等，1997）、安多藏语（于洪志等，2007）、哈萨克语（努孜古丽·吐尔根那比，2010）等少数民族语言的声乐数据语音研究也已

① 作者简介：袁丹，华东师范大学对外汉语学院研究生；吴勇毅，男，博士，江南大学外国语学院院长，教授，博士生导师，主要从事对外汉语教学法、第二语言习得、语用学、语篇语义学研究。

开放,这些研究除了有效提升了少数民族语言的语音资源外,还为少数民族语言的语音合成为新物种和新物种打下了研究基础(南格拉等,2003)。2007年,国家语言文字工作委员会、教育部、国家语委启动了“中国少数民族语言资源库”项目,该项目由北京语言大学牵头,联合全国各民族语言文字工作者,对全国各民族语言文字进行系统整理、分类、标注、分析、研究,并建立数据库。

当然,随着一些与民族相关的项目的开展,如语音标注软件的开发、语言文化产品的制作和传播等,民族语言的保护工作也有了长足的进步。

从目前看,建设少数民族语言数据库的工作主要集中在以下方面:(1)对少数民族语言的语音特征进行整理、标注;(2)对少数民族语言的语音学参数进行整理、标注;(3)对少数民族语言的声乐分析和声学参数的登录。非常可惜的是,这个中介语语音语料库的材料未能共享,因此一般无法查到这个数据库。另外,近年来,北京语言大学、南京大学、苏州大学、南京师范大学等高校都在建立中介语语料库。这些中介语语料库收集了较大规模的中介语语料,但是对于录音质量却不如以考声不能运用于定性语音学的分析与研究。事实上,国内对外国学生汉语语音“知音”的研究起步较晚,但随着社会对留学生语音水平的重视程度越来越高,越来越多的高校在教学中都开始重视留学生的语音测试软件。这为建立大规模的中介语语音语料库奠定了基础,也为语音教学、语音测试、语音诊断、语音矫正等打下基础,同时也为完善二语习得理论提供了大数据支撑。

2 基本特点

不同于以往的中介语口语语料库,我们要建设的汉语中介语动态追踪有声数据库,旨在建立一个可进行动态追踪和语音客观量化分析的语音语料库数据库,以往的语料库是静态的,只能体现某个留学生在某个阶段的语言面貌,本数据库要求对留学生的语音错误进行动态追踪,从而获得更全面的数据。以目前的中介语语音语料库为例,语音种类的丰富度相对不高,但本数据库要求采集的语料必须是高质量、非压缩的语音信号,以利于后期的语音特征提取。具体来看,有以下几个特点:

2.1 大量的语音数据

语料库建设的一个重要前提是语音的采集量,采集量不足,语料库就无法发挥其应有的作用。因此,在建设语料库时,应尽可能地采集各种母语背景者的语音数据,希望最大限度地保证每种语言都能建立一个分数据库,这样才能保证提取普遍性规则的有效性,保证母语迁移差异性特征的多样化。不同母语背景的分数据库建设,应采取“从整体到部分”的原则,即先建立母语数据库,再建立子语种数据库。

数据库时不能将其合并,因为它们在元音音质上并不能完全对应。这样的差别会对某些母语者的声音产生影响,但是在某些音特征上,它们又几乎一致,如没有送气和不送气塞音的对立,在考察这样的语音特征时可以灵活合并。在保证语言多样性的同时,还要保证每种语言具有足够大的样本量。一般来说,日韩来华留学生较多,样本量能够有所保证,但其他语言样本量的采集就会遇到困难。由于此数据库还有个人语音诊断的作用,因此在样

本量的采集上,我们将采取“多多益善”的原则,即对不同母语背景的样本量的均衡性不做过

学习汉语(或入学)之初,就给他建档,动态采集其在不同学习阶段的语料,以达到动态追踪的目的。实验研究表明,语言习得者在语言学习之初要掌握汉语系中产生的元音对立会比较困难,但随着学习时间的增加,这种困难会得到改进,甚至完全克服。如 Liu 和 Jongman(2012)对美国学生习得汉语[ts]和[tsh]的研究结果表明:初等一级的美国学生能

够掌握这些音,但是到了初中级的时候就会出现音位的失衡和语音的交叉,不能很好地将[ts]与[tsh]对立,而初等三级的学生则两者都尚未掌握。因此,对学生的语音学习过程进行动态追踪,可以发现哪些是学习者在习得过程中易于矫正的错误,哪些是学习者容易“化石化”难以改变的错误。另外为每个学习者建立一个语音数据库,可以对每个学习者进行追踪检测,每两一级时即可为学生进行测试,并生成报告,并提出建议的矫正方案。

2.3 有声性

不同于以往的中介语口语语料库,本数据库十分注重录音样本的采集方式。以往的中介语口语语料库虽然也强调了有声性,但是对录音质量的控制却并不十分严格,大多采用录音笔录音。当然这和语料库的建库目的相关。以往的语料库一般用来做词汇、句法、语篇的

使用大数只拍向话筒 XNO C520。

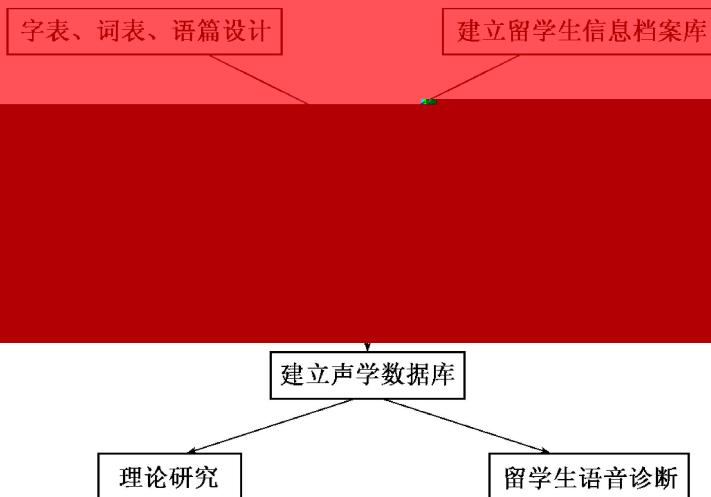
2.4 开放性和共享性

一个庞大的数据库,需要有庞大的数据样本量作为支撑,而数据库的开放性则是数据库

能够发挥其最大效用的关键。本数据库将致力于实现开放性,从而促进学术研究、教育事业与科学技术的进步,而实现最充分的资源共享是达成目标的前提”。实现共享性的主要途径:

- 任何人都可以在网上随时下载语音数据,真正实现数据共享(研究者也可以无须申请有条约为本数据库提供符合要求的语音资料)。

来的录音材料都需要进行标注,然后进行声学分析,建立声学参数库,最后将这些数据用于理论研究以及应用于留学生语音诊断(具体流程参见下图)。以下我们将分步骤详细阐述建库流程。



3.1 字表、词表、语篇的设计

字表理论上要包括普通话声、韵、调配合的所有音节,但需要排除某些音节可能只有生僻字的音节,扣除后再经过挑选,确定普通话 1000 个音节为数据库的字表。考虑到初级学生在辨识汉字上还有很大的困难,1000 个音节只列出拼音不列汉字。

能依据经验来判断哪些音节次日而安设计两个组的两组,如王工文调、赵飞李吉和王赵飞李

级学生只能识别不能读汉字。听说部分的训练设计要尽量做到听、说、读、辨识的全面性,可考虑设计多个较短小的环节让学生训练。听说部分可确定几个话题,如,个人爱好、个人经历、家庭情况等让学生自由发挥讲述,时长为 10~15 分钟。朗读部分的训练可以老木沙

分的语篇可以看出每个学生个体的语音问题。

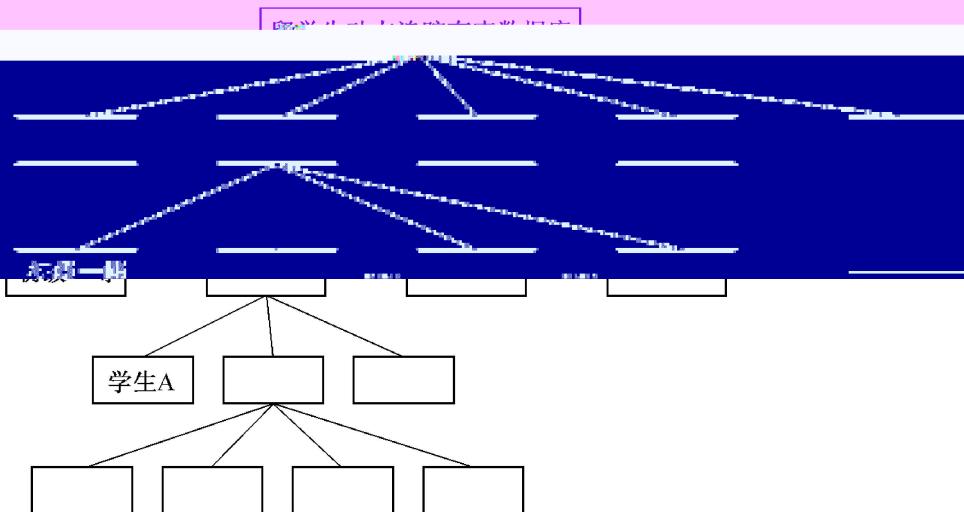
3.2 建立留学生信息档案库

在对留学生语音数据进行分析时,首先可以用来进行口语看学生的社会语言学特征。留学生信息档案库的建立,先要按照不同母语背景建立分库,然后再按照不同等级建立次分库,最后再为每一个留学生建立一个信息库。

3.3 语音采集

为了达到动态追踪的目的,每学期分三次对留学生进行语音采集工作:入学考试一次、期中一次、期末一次。零起点的学生入学初不做采集,在入学一个月后做一次采集。事实

行采集外,我们还将进行母语者的语音采集,选择汉语普通话标准的 15 男、15 女录音,作为和留学生语音偏误进行比较的参照库。数据库将首先按照不同母语背景建立分库,然后再按照不同等级建立分库,为每个留学生建立一个数据库,数据库里包括字库、词库、语篇库以及个人信息库,以便于日后的检索。具体如下图。



3.4 语音标注

采集到的所有录音都需要进行初次标注和二次标注。初次标注包括两层:第一层是音节标注,也就是切分出音节来;第二层是声韵母标注,也即将所有音节都标注出声母段和韵

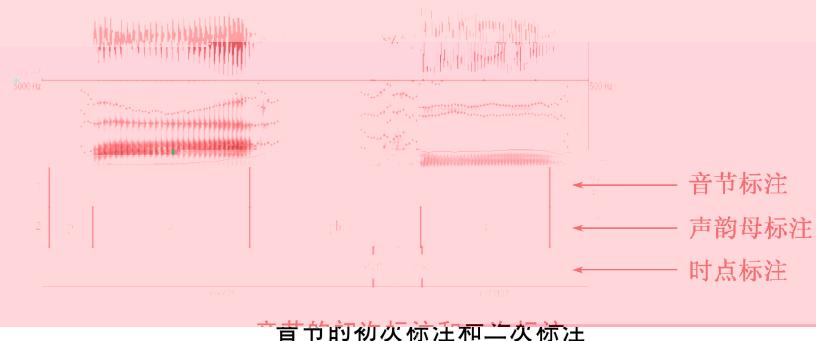
用人工来进行测算,耗费的时间是不可想象的。在 praat 中做完初次标注后,就可以运用其

图例说明：一次标注是时点标注，也就是标注一些重要的时点，如元音的起始、结束等；二次标注是音节标注，也就是标注整个音节。

教学，就如古罗马哲学家爱留克所常说的那样——“人不能两次踏进同一条河流”。在讲授某此

时点标注

注，切分出了 [pa] 和 [pʰa] 两个音段；第二层为声韵母标注，将 [pa] 切分出 [p] 和 [a]，[pʰa] 切分出 [pʰ] 和 [a]；第三层我们对 [pʰ] 的送气段做了时点标注，标注出了起点 (start)、中点 (mid) 和终点 (end)。



声节的初次标注和二次标注

3.5 语音分析

大规模的录音采样完成后，就可以对一些留学生汉语中介语的语音偏误项目进行声学测量参数的设定，建立留学生二语语音声学参数库。什么样的音素应提取什么样的声学参数，一般来说是有针对性的。元音一般提取第一共振峰 (F1) 和第二共振峰 (F2) 这两个声学参数，考察二语学习者的元音声学空间和母语者的元音声学空间的差异；送气声母可以提取

送气时间的时长；清辅音可以提取清辅音的时长；浊辅音可以提取浊辅音的时长；等等。

归结起来，语音分析工作的基础。

3.6 语音诊断

建立起不同母语背景者汉语中介语语音声学参数数据库后，就可以对不同母语背景学生在习得汉语时的语音偏误进行研究和分析，列出偏误要点，并开发留学生汉语语音测试软件，为留学生进行语音诊断，并且进行语音矫正。目前来看，还没有一个留学生汉语语音测

试系统能同时对学生汉语语音进行自动识别、自动分析、自动诊断、自动矫治，但是一些语音识别系统已经能够完成对汉语语音的自动识别、自动分析、自动诊断。

语音识别并非用来判断发音正确与否，而是尽可能地排除个人口音、环境噪音等因素对识别结果的影响，所以对语音失误的宽容度比较高，因此只能作为判断语音的辅助工具，而不能

作为一个语音测试的软件。

第7章 管理系统

(1981、1988、1991、1992)的SLM理论系统阐述了二语语首习得感知和产出中的母语迁移，建立留学生汉语中介语有声数据库，分不同母语背景对留学生汉语的语音习得偏误进行考察，可以为这两个理论提供汉语的例子，进一步完善这两个理论。虽然学者们普遍承认母语迁移在二语语音习得中的重要性，但是也有一些学者指出，母语者和非母语者在相关音位产生差异并不能完全归于非母语者的母语迁移，如Garcia and Herbert(1979)的文章《Some Phonological Errors in Second Language Learning》，在述以前已有其他的研究也提出过类似的观点(如Briere 1966, 1968; Tarone 1978; Wade 1977, 1978)^⑤。Bohn(1995)的研究进一步指出，不仅在二语的首语产出中母语迁移不能解释所有的问题，在跨语言的音素感知研究中母语迁移也不能解释所有的问题，Borden(1995)对德语学习者、中西学习者以及西班牙学习者感知英语的[æ]—[e]，[i]—[ɪ]进行了实验证究，英语的[æ]—[e]，[i]—[ɪ]具有相当的清晰度，两者元音本质的差异，中西学习者差异，西班牙学习者为：清擦音只有[e]，可以和英语的[ε]、[æ]形成对立，且有时长对立，预测德语母语者会以元音音质差异和时长差异来区分英语的[ε]和[æ]；西班牙语有[i]，而英语有[i]、[ɪ]，没有时长差异，预测西班牙学习者仅以音质差异来进行区分，忽略时长的作用；汉语有[i]，而英语有[i]、[ɪ]，没有时长对，因此时长起两个音调的差别作用，预测西班牙学习者和西班牙语学习者一样，以音质差异来进行区分；英汉对比，时长的作用相对较小。实验证实表明，类母语者主要依赖语音音质的差异来进行区分，而母语者为母语的学习者进行的分类依赖时长来进行区分，但母语者进行的感知重心在于音质的识别，而非时长的识别，这与西班牙语学习者进行的感知重心在于时长的识别，而非音质的识别存在很大的差异。此外，Borden还提出了“去蔽名”假说，即当元音者听的差异不能够满足听后人区分元音对立的要求时，时长差异便会用来区分非母语的元音对立，不同母语的二语学习者会表现出共性。因此，通过西班牙语母语者使用平行语谱音数据的实证模拟能够了解不同母语母语背景者汉语语音产出的差异性外，也可以考察产出和感知中的共性问题。

4 结语

因此,我们希望以此具有深刻理论意义和实用价值,能够为学生汉语语音教学、语音测试、语音诊断以及语音矫正等提供大数据支撑。我们认为,通过将留学生的语音采集纳入到留学生入学测试、期中以及期末测试中这样的方式,大规模的数据采样完全可以做到持续而有序的进行。

① 转引自 Bohn(1995)。

参考文献

- [1] 曹志耘.中国语言资源保护的理论与实践[C].TACCL-23 会议论文,2015.
- [2] 鲍怀翹,徐昂,陈嘉猷.藏语拉萨话语音声学参数数据库[J].民族语文,1992(5).
- [3] 呼和,鲍怀翹,确精扎布.关于蒙古语语音声学参数数据库[J].内蒙古大学学报(人文社会科学版),
2007(6).
- [4] 娜孜古丽·吐斯甫那比.哈萨克语语音声学参数数据库研制方法[J].民族翻译,2015(2).

[12] Best, C. T. Nonnative and second-language speech perception: commonalities and complementarities. *Journal of Speech, Language, and Hearing Research*, 2005, 48(3), 722-734.