

# 云计算技术在中介语口语语料库建设中的应用<sup>①</sup>

林君峰<sup>②</sup>

The Application of Cloud Computing in the Construction of Inter-language Spoken Corpus

Lin Junfeng

[Abstract] Today's large-scale construction of spoken corpus has been greatly influenced by cloud computing.

## 1 引言

随着社会的发展，人们对于语言学的研究越来越深入，因此大规模的语料库建设也成为了研究的一个重要组成部分。近年来，随着云计算技术的不断发展和成熟，其在语言学领域的应用也受到了更多关注。“除了可以辅助学习者学习口语中词汇、语法、语义、语用等方面的实际表现之外，还可以了解学习者实际的口语语境，可以对其进行声、韵、调等方面的考察与分析。”(臧定国、何春玲, 2015) 目前以大学、科研机构为代表的语料库建设水平已经非常高，如“西南交通大学的‘全球汉语中介语语料库’(目标 5 000 万字)和收集数百万条口语语料的‘方言语料库’”。

<sup>①</sup> 本论文获得教育部语料库与语料学研究重点课题以及福建省社会科学基金项目“福建方言语料库建设及应用研究”的资助，项目编号：12JZD018。

<sup>②</sup> 作者简介：林君峰，福建师范大学海外教育学院讲师，研究方向为语料库建设与应用、计算机辅助教学。

的口语语料。

然而,在口语语料库建设规模不断扩大的同时,其建设方式仍主要依靠人工。口语音频语料的人工转写工作相比书面语语料费时费力,转写过程中经常需要反复播放,一份音频文

字时,需要占用的服务器运算资源、带宽等也比较大,费用成本会高一些,这也可能会影响建设单位对外开放语料库的意愿。

**联动共建共享语料库——助力语料库建设人员专注语料建设,降低运营费用,提高建设效率和建设质量,并促进语料库的开放共享。**

## 1.2 云计算技术的优势

云计算技术是“通过互联网提供各种计算服务和存储服务”的新兴技术,“云服务供应商

对于用户来说,云计算技术将原本由设备商承担的数据存储、计算等工作,分散到云端。云计算系统的管理和服务模块化,用户不需要关心具体的服务器硬件,数据先上传至云端管理。云计算环境下,服务器运营成本显著下降,维护工作得到极大简化,可靠性也更加确定,数据安全也更有保障。

在国内互联网上,已有云存储服务提供商存储了海量的各种公有云计算服务可供使用,这些云服务都可以整合起来用于汉语中介口语语料库的建设。云服务器可用于运行语料库建设及检索系统,云语音可用于语音转写,云存储可用于音频文件存储、加工及检索。

## 2 语音转写测试

口语语料库建设流程大致可分为音源材料采集、音频转写为文本、三重标注及质量标注性、建立数据库、编写检索程序等几个环节,其中转写和标注的人工绝对最长。书面语的转写流程与口语语料库建设相比,由于人机协作的模式,效率会高很多,但口语语料的标注也类似。但现在汉语语音识别技术已经有了很大的发展与进步,口语音频材料的转写如

方言、藏语、维吾尔语、英语,不仅让学习者了解各语种的语音面貌,还能水平参差不齐,国内的大学语音实验室学习者所报的汉语课堂效果如何,教师的真实用语水平,还能进行实际的测试。

本文实现了中英双语口语语料库学习平台,该平台文字部分用多种语言,使用谷歌翻译直接或百度翻译开放平台,进行了独特的自动评价测试模式。

① <http://yuvin.hainu.edu.cn>

## 2.1 音频材料的准备

将录音转换为百度语音云服务平台所支持的格式,再从中选取一部分录音剪辑另存,生成一批单个录音时长不超过 60 秒的音频文件<sup>①</sup>。

### 2.1.1 选取测试录音

在中级、高级阶段各选取了一位学生的 HSKK 模拟考试录音,一位是蒙古学生(口语一般,参加中级口语模拟考试),一位是越南学生(口语较好,参加高级口语模拟考试)。

蒙古学生的录音、考生回答部分为三音教育,3.考官“好,考试现在结束,请告诉我”之后的致谢等。

最后,将录音转格式。转换完成后保存录音文件为 Windows PCM 格式文件(后缀名为 .wav),作为标准录音文件,再将添在录音文件另存一份,音频采样类型调整为百度语音云服务所支持的 16000 采样率、16 位单声道,以用于下一步的剪辑。

### 2.1.3 男辩测试样本

从已转换格式的 2 份录音文件中各剪辑出 12 份小文件,内容分别为:

- (1) 对姓名的提问和回答;
- (2) 对国别的提问和回答;
- (3) 对考生序号的提问和回答;
- (4) 引导语,提醒考生接下来要跟读句子;
- (5) 已旦诺说明要求,朗读。考生朗读 1 分钟。

(B) ① 念第一段,考生跟读各 3 个句子;

② 念第二段,考生跟读各 3 个句子;

③ 念第三段,考生跟读各 3 个句子。

<sup>①</sup> 百度语音云服务平台当前只能上传不超过 60 秒的音频文件,超出时长则报错,不能识别。

- (1) 完全正确,人工重播录音后,可直接确认通过的。
- (2) 吊右小吊挂混但仍成右,在重播录音后可在已识别中的前后立基础上标注江工的
- (3) 部分识别,但不或每,重播录音后正较多内容。
- (4) 基本不成句,大部分内容必须重新由人工表示的。

例5: 兴趣系指好了两声。(人工转录:兴趣是最好的老师。)

### 2.2.2 识别准确度统计

2	交替发音(共2个短句,二语者1句)	A	B
3	交替发音(共2个短句,二语者1句)	D	A
4	只有母语者发音(3个句子)	—	—
5	交替发音(共2个句子,二语者1句)	C	A
6	交替发音(共3个句子,二语者1句)	C	A

3	交替发音(共6个句子,二语者3句)	DAD	ABA
0	交替发音(共0个句子,二语者0句)	CDC	ABA

① 这里忽略标点的差异,因为语音识别得到的文本基本上全用逗号。

(续表)

录音样本	样本说明	蒙古学生 (HSKK 中级)	越南学生 (HSKK 高级)
10	只有母语者发音(3个句子)	—	—
11	只有二语者发音(2个句子)	20	20
12	只有二语者发音(成段表达,50秒左右,若干个句子,包括长句)	CCDD	BBBBBBBB
统计	句数(二语者发音)	共 19 句	共 23 句
	A	15.8%(3 句)	34.8%(8 句)
	B	10.5%(2 句)	60.9%(14 句)
	C	31.6%(6 句)	4.3%(1 句)
	D	42.1%(8 句)	0%(0 句)

### 2.3 可行性分析

从表 2 可以看出,蒙古语识别系统对蒙古语的识别率是 95.7%,而大部分识别不出来的原因是识别系统不能识别出蒙古语的声调,所以识别率较低。蒙古语识别系统对蒙古语的识别率是 95.7%,而大部分识别不出来的原因是识别系统不能识别出蒙古语的声调,所以识别率较低。蒙古语识别系统对蒙古语的识别率是 95.7%,而大部分识别不出来的原因是识别系统不能识别出蒙古语的声调,所以识别率较低。

从图 6 可以看出,蒙古语识别系统对蒙古语的识别率是 95.7%,而大部分识别不出来的原因是识别系统不能识别出蒙古语的声调,所以识别率较低。蒙古语识别系统对蒙古语的识别率是 95.7%,而大部分识别不出来的原因是识别系统不能识别出蒙古语的声调,所以识别率较低。蒙古语识别系统对蒙古语的识别率是 95.7%,而大部分识别不出来的原因是识别系统不能识别出蒙古语的声调,所以识别率较低。

例 6:你最近的办公室在哪里。(人工转录:你最近的办公室在哪里。)

例 7:对不起,这里仅有禁烟区。(人工转录:对不起,这里仅有禁烟区。)

例 8:如果多此一举的话就丢了。(人工转录:如果多此一举的话就丢了。)

例 9:可是两个人从一切物件打由连的时候。(可是两个人从汽车上打由连的时候。)

从图 7 可以看出,

① 全部样本识别结果和人工听录文本下载:[http://www\\_hanyu123\\_cn/html/yuliaoku/](http://www_hanyu123_cn/html/yuliaoku/)。

通过云语音批量自动识别音频语料，辅助口语语料转写工作，显著提高工作效率，减轻人工工作量并对偏误标注有所帮助。

## 3.2 开发及运行环境配置

基础文件格式：以 XML 为基础文件格式，用于保存音频文件信息、语料转写文本等。

“XML……是 Web 服务领域的‘世界语’”，“通用且容易解析的 XML 将会成为主流的数据交换格式。”（单东林、张晓菲、魏然，2012:183）使用 XML 有利于程序和数据维护，便于以后对语料的检索和数据挖掘。

开发环境：编程工具为微软 Visual Studio 2013 集成开发环境（编程语言为 C#4.5），数据库使用能很好地支持 XML 的 SQL Server 2008。

七牛云存储<sup>①</sup>，云语音开放平台为百度语音。七牛云存储可免费存储 10GB 的文件，每月提供 10GB 免费流量，百度语音则完全免费。

预加工好的音频文件存放在云存储平台，相关文件信息存放在 Web 服务器的数据库中。自动转写时，Web 服务器同时连接到云存储和云语音开放平台，从数据库中批量读取

识别结果保存到数据库中。

这样的配置，可以使自动转写过程中的数据传输都在云服务器间进行，运行更加稳定。

## 3.3 转写流程

### 3.3.1 音频预加工

使用 Adobe Audition 音频编辑软件对原始音频内容做无损的加工，仅删除较长时间的空白或纯噪音的部分，不改变音频格式、采样率。（为便于叙述，将加工后的音频文件称为文件 A）

将文件 A 转换为语音云平台指定的音频格式，并拆分出若干个小文件（文件系列 B）。拆分出的单个文件，其时长不能超过云语音平台的限制（百度语音以 60 秒为限）。拆分时记录相对原文件（文件 A）的时间起止。拆分并不影响文件 A 本身。

### 3.3.2 上传音频文件

将文件系列 B 通过 Web 服务器上传至云存储，同时将相关文件信息保存在 Web 服务

<sup>①</sup> <http://www.qiniu.com/>.

### 3.3.3 批量语音识别

在 Web 服务器选定要识别的文件范围(文件系列 B),并从数据库中批量读取文件信息。根据文件信息,调用云存储,将存储在其中的音频文件(文件系列 B)提交到云语音平台进行批量识别,并将返回的识别结果文本以 XML 格式保存到数据库中。

### 3.3.4 人工核对

人工听录音(文件系列 B)并校对识别结果文本,完成语音转写为文本的工作,并可顺带进行部分偏误标注。

### 3.3.5 合成语音文本

语料库的开放共享也有一定的作用。

## 4 小 结

不断扩大的语料库建设规模,与仍主要依靠人工的建设方式是一对矛盾。提升语料库建设的计算机技术含量有助于减轻建设人员负担,提高建设效率和建设质量。

经本文小规模测试,在口语语料库建设中应用云计算技术可以起到较好的效果,能节省

[1] 张宝林,崔希亮.谈汉语中介语语料库的建设标准[J].语言文字应用,2015(2).

[2] 朱文武.多模态云计算[J].电子与世界,2011(6).

[8] 七牛云存储音视频/流媒体在线处理. <http://www.qiniu.com/feature#data-process>.

[9] 讯飞语音云开放平台. <http://www.xfyun.cn/index.php/services/voicedictation>.