

综述与评论

广播新闻自动记录系统研究现状 ——语音识别的重要应用¹⁾

张 红 黄泰翼 徐 波

(中国科学院自动化研究所 模式识别国家重点实验室 北京 100080)
(E-mail: huang@nlpr.ia.ac.cn)

摘要 广播新闻自动记录系统是近两年国际上出现的大词汇量连续语音识别系统研究的新热点,是语音识别技术进一步走向实用化的重要过渡形式。文中介绍了目前国际上广播新闻自动记录系统出现的背景和发展历史,从系统性能与理论研究两方面介绍了这方面的研究现状并加以分析,最后对开发我国自己的广播新闻自动记录系统提出了具体的发展方案。

关键词 广播新闻自动记录,大词汇量连续语音识别,分段,自适应。

THE STATE OF THE ART OF THE BROADCAST NEWS TRANSCRIPTION SYSTEM

ZHANG Hong HUANG Tai-Yi XU Bo

(National Laboratory of Pattern Recognition, Institute of Automation,
Chinese Academy of Sciences, Beijing 100080)
(E-mail: huang@nlpr.ia.ac.cn)

Abstract The broadcast news transcription system has been a new highlight for the research of large vocabulary continuous speech recognition in recent years. It is a bridge for speech recognition technology to come to the real application. This paper introduces the background and history of the research on current broadcast news transcription systems. The state of the art of the research in this domain is introduced and analyzed with respect to system performance and theory research. At the end, a developing scheme is proposed for domestic on broadcast news transcription system.

Key words Broadcast news transcription, large vocabulary continuous speech recog-

1)“九七三”计划(G1998030504)和“八六三”计划(863-306-ZD03-01-1)资助课题。

nition, segmentation, adaptation.

1 背景

目前语音技术在实验室条件下已经相当成熟,正处于实用化发展的阶段。商业化产品开发大量涌现,这其中包括计算机用户的语音服务,如语音命令、文本听写等,以及电信业务方面的自动寻呼和语音拨号、银行业务和保安系统方面的应用等。而另一方面,研究者们也在对提高系统鲁棒性及应变能力进行更深入的研究,在这方面引人注目的是广播新闻自动记录系统的研究。

广播新闻节目中包括了不同的声学和语言学特性的信号段,在段与段之间的变化既有突然猛烈的,也有平缓过渡的。信号的质量可能是播音室的高保真质量,也可能是经由电话或其它含噪信道传送的有限带宽信号(如,由于有加性噪声或非线性失真使信号质量下降),以及在音乐背景下的语声或是纯音乐段。仅对语音信号来说,讲话人也是形形色色,有新闻播音员、脱口秀主持人、地方口音浓重的普通百姓、语音不地道的外国人等等。语言风格有播音员纯正的文稿式语言,也有记者随意的即兴表达。面对这样变化多端的信号,在实验室里用纯净语音训练出来的声学模型,显然是不能胜任识别任务的。

语音技术如果要走向实用,必须使语音识别系统能在实际应用环境下保持原有的性能,即对说话人、方言口音、麦克风、声学环境、讲话内容等方面的变化保持鲁棒性。而广播新闻节目,包括了上述特征,并且易于收集数据,形成统一的评测标准,这对于语音技术的实用化研究是一种理想的研究对象。因此,建立这样一个广播新闻自动记录系统,无论在语音识别理论上,还是对于语音技术走向实用化方面都有着重大的意义。

2 发展历史

在国际上广播新闻自动记录系统的研究起源于美国国防部高级研究计划局(DARPA—— Defense Advanced Research Projects Agency)所资助的人类语言系统(HLS—— Human Language System)项目中的语音技术部分。DARPA 将这个计划分成很多项目,由多家研究机构和高校来完成。其中参与口语识别与理解方面项目的研究机构或大学有 BBN 系统与技术公司(主要承担交互式口语理解系统,鲁棒连续语音识别研究),CMU(主要承担口语系统研究),MIT(主要承担语音识别与理解的层次结构研究),科学应用国际公司(SAIC)(主要承担语音识别技术集成)等。

得到 DARPA 语音项目资助的各个研究机构,每年都要进行一次由美国国家标准技术研究所(NIST—— National Institute of Standards and Technology)主持的性能评测。首次试验性的基准测试于1995年11月举行^[1],以后每年都进行一次,一般是当年年底测试(通常在11月份),次年年初举行研讨会。最近的一次是1998年11月进行的^[2]。

1995年的测试称为演习测试,因为所有参加测试的研究机构都没有识别广播语料的经验。1996年的测试则为预备性的基准测试,因为在 DARPA 资助下,由 NIST 主持的语音系统基准测试并没有包含广播与电视新闻语料的先例。此后,由于有了先例,从1997年11月起,每年定期举办这项测试,并在测试后举行研讨会。

1995年11月的演习性基准测试有IBM, CMU, 等四个单位参加。在这次测试中, 测试语料并未按声学状况的类别标注切分。在测试后举行的研讨会上, 与会者认为, 对于这种混合类型的语料的识别必然要先将语音段按声学条件类型进行分段(segmentation), 而语音识别系统进行自动分段这样的任务自身也有很大的挑战, 并可能使研究重点偏离语音识别的任务。于是在1996年初的研讨会上, 参加会议的几个研究机构讨论、制订了分类(partitioned)测试协议。在处理测试数据中及对测试结果总结时都可以采用分类标注信息。测试完整系统若未采用标注文件中的分类信息, 就是未分类评测 UE(Unpartitioned Evaluation), 反之就是分类评测 PE(Partitioned Evaluation)。以后参加评测的各研究单位都可以用分类评测, 以便于集中于复杂声学条件的语音识别的研究。

在分类测试协议中, 声学条件的分类是根据语料中的口音、讲话方式、保真度和背景情况等确定的, 具体规定为7类, 如表1所示^[1]。

表1 NIST 广播新闻自动记录系统测试数据声学条件分类

类别	口音	讲话方式	保真度	背景
基本播音 F0	母语	文稿式	高	纯净
口语播音 F1	母语	口语式	高	纯净
有限带宽 F2	母语	任意方式	中/低	纯净
含背景音乐 F3	母语	任意方式	高	音乐
退化声学环境 F4	母语	任意方式	高	语声或其它噪声
非母语讲话人 F5	非母语	文稿式	高	纯净
所有上述类别的组合 FX	—	—	—	—

显然, 以前传统的大词汇量连续语音识别(LVCSR)系统对类别F0基本播音方式具有最好的效果, 对F1以下的类别就逐步下降。

3 广播电视新闻自动记录系统的研究现状

参与测试的各研究机构的广播新闻自动记录系统都是由以前的大词汇量连续语音识别(LVCSR)系统发展而来。而且这些机构也多参加了NIST以前的相应测试。在出现了广播新闻自动记录系统测试后, 这些研究机构也都转而参加了这项测试。因此, 从NIST每年的评测结果, 可以看出国际上在广播新闻自动记录系统方面的研究状况。

NIST在1996年举办的测试中^[3], 共有8家单位的9个研究组参加, 结果如表2所示。

表2 1996年广播新闻自动记录测试结果(词错误率%)

系统	全部测试	F0	F1	F2	F3	F4	F5	FX
Bbn1	30.2	21.6	29.5	32.7	23.3	38.4	31.8	49.9
Cmul	34.9	25.8	32.1	38.6	36.6	43.7	36.6	55.8
Cu-con1	34.7	25.8	33.5	40.4	33.4	39.3	40.5	53.1
Cu-htk1	27.5	18.7	26.5	33.1	23.6	29.1	21.7	51.0
Ibm1	32.2	21.6	30.4	38.9	28.0	42.2	30.8	54.2
Limsil	27.1	20.8	26.0	27.1	20.3	33.3	27.7	46.1
Nyu1	33.0	26.0	32.5	32.6	34.2	38.4	31.1	48.1
Ru1	56.1	43.0	51.7	74.6	50.0	81.6	54.8	72.1
Ru2	53.8	42.7	51.9	72.9	50.0	59.2	54.8	71.9
Sri1	33.3	26.4	33.0	31.7	34.7	38.5	34.4	48.3

在1996年DARPA的广播新闻测试中^[3],第一次向语音自动识别系统提供了混合的整体性输入测试语音信号,即典型的无线电广播和电视广播信号混为一体的声音信号。这样,使得在所有类别的测试条件都更加严酷了。

到1998年,这项测试相对往年有一些变化^[2]。首先是训练语料比以前增加了一倍,达到200小时。其次是增加了一项10倍实时的系统测试(Rover系统^[4]),即各个系统将系统进行一定程度的简化,使之达到10倍实时的要求,然后进行测试。这主要是为了使各参加评测的单位能致力于提高系统的计算效率,以便今后向实时化发展。1998年相应的测试结果如表3和表4所示。1998年评测结果中,最佳系统的整体词错误率为13.5%,10倍实时系统中的最佳系统的整体词错误率为16.1%。与1996年的系统相比,1998年的系统在性能与效率上的提高是非常显著的。对于基准语音测试即分类情况F0,讲话风格为播音员发音的语音,最佳系统的词错误率(WER)已经降到7%~8%的水平。1998年测试结果中另一个值得注意的是在难度很大而且情况不可预知的F1~FX各分类情况中,参加测试的系统所表现出的鲁棒性^[2]。

汉语(普通话)的广播新闻自动记录系统是从1997年在DARPA的评测中才出现的^[5],参测单位一直是IBM和Dragon两家公司。1997年测试结果的字错误率,IBM系统为19.8%,Dragon系统为20.2%。在1998年的测试中^[2],相应的指标,IBM为17.1%,Dragon为20.6%。

表3 1998年广播新闻自动记录测试结果(词错误率%)

系统	全部测试	F0	F1	F2	F3	F4	F5	FX
Bbn1	14.7	9.0	15.0	20.6	19.2	13.9	17.9	25.9
Cu-htk1	13.8	7.8	15.1	20.1	15.8	13.6	16.6	24.1
Dragon1	14.5	8.3	16.8	19.0	15.2	13.4	24.3	25.6
Ibm1	13.5	8.2	16.0	17.4	17.3	12.1	15.3	22.1
Limis1	13.6	8.2	14.4	16.9	16.3	13.6	21.3	22.2
Ogi finix1	25.7	14.9	27.3	38.3	33.4	24.8	29.4	44.0
Philips rwth1	17.6	10.1	20.2	25.6	22.1	16.4	29.4	29.5
Sprach1	20.8	13.1	24.3	30.2	24.5	19.4	24.3	32.7
Sri1	21.1	13.2	22.4	25.9	23.3	20.5	25.5	36.0

表4 1998年广播新闻自动记录测试(10倍实时系统)结果(词错误率%)

系统	全部测试	F0	F1	F2	F3	F4	F5	FX
Bbn2	17.1	10.3	17.0	24.9	22.5	16.5	21.7	29.7
Dragon2	16.7	10.6	19.5	23.6	21.2	14.4	25.5	27.9
Cuhtk entropic	16.1	9.7	17.6	19.1	19.5	15.7	23.4	27.3
Ibm4	19.4	11.0	20.9	28.8	25.1	18.0	23.0	35.2
Sprach2	25.0	16.8	27.3	35.5	33.4	22.7	32.8	39.2
Sri2	22.8	14.4	24.1	28.4	25.7	22.9	27.2	36.9

4 现有广播新闻自动记录系统的主要技术特点

现有的广播新闻自动记录系统均是由原有的大词汇量连续语音识别系统发展而来。广播新闻自动记录系统与传统的语音识别系统的主要区别:一是广泛地应用了自

适应技术,提高了系统的鲁棒性;二是系统还具有自动识别待识别语音流的声学性质的功能。

从总体上来看,这几年广播新闻系统的发展在框架上并无重大的变化。与大词汇量连续语音识别技术相比,主要是增加了自动分段和强化了自适应技术这两个部分,并辅之以系统各个模块的优化及越来越复杂的搜索策略。分段技术虽然实现方法各有不同,但目标都是降低切分错误,从而为后续的自适应技术服务。在自适应技术中,早期侧重于模型参数的自适应,近来的趋势是加入特征参数空间变换,采用了这些技术的系统在性能上均有进一步的提高。从历年的报告中可以看出,每年评测中各个参测系统在性能上的提高,都是由各个局部的不断优化汇聚而来。从1998年的情况来看,广播新闻系统技术的研究在继续提高精度和鲁棒性的同时,目前的研究重点正在转向解决实时化问题^[2,4]。

广播新闻自动记录系统的主要技术大致上集中在以下几个方面。

1) 分段(segmentation)技术。如前所述,广播新闻自动记录系统所面对的信号是一整段包括各种声学性质的语音信号。分段最基本的目的就是将这一整段的信号分割成便于识别器处理的小段语音信号。分段技术就是将连续的数据流切分为几类适当长度的语音段,每一段都是均质的,即对于每一段为同一讲话人和同样的声学条件,这样也便于同一类的段共享一套自适应变换^[6,7]。系统的分段一般都是将输入信号分为均质的三大类:宽带语音,窄带语音和音乐。通常还要对讲话人的性别进行标注。在后续处理中非语音段要丢弃。分段技术常用的方法是分类建模方法,利用高斯密度模型建模进行重估和聚类。用于分段的特征与用于识别的特征相当,仅少了能量一项^[8]。另一种非分类建模的分段技术是贝叶斯信息判据法^[9,10]。

2) 前端处理技术。语音的声学特征一般用MFCC、对数能量及相应的一阶二阶差分。也有与PLP相结合的MF-PLP特征参数^[11]。参数提取后一般还要作倒谱均值去除^[12],以减小信道畸变的影响。有些系统还采用了一种对角化变换(diagonalizing transformation)^[13],将特征进行变换。在针对中文的系统中,一般还采用基频作为附加特征,语音信号中每一帧都提取基频,并将归一化基频以及差分基频用于后续的识别过程中^[14,15]。

3) 声学模型(acoustic models)。声学模型一般采用的是连续密度HMM模型,高斯密度混合数一般在32以上。在广播新闻自动记录系统中的声学模型训练,一般来说至少要将宽带信号与窄带信号分开,文稿类、口语类与外国口音类均为宽带。然后用混合数据训练宽带模型,而用电话段语音数据训练窄带模型^[15]。另外一种趋势是在建立声学模型过程中采用分裂的决策树技术^[16]。

4) 自适应技术。出于速度上的考虑,多使用变换法。在模型参数方面,采用得最多的是最大似然线性回归(MLLR——Maximum Likelihood Linear Regression)^[17],也有采用最大后验概率(MAP——Maximum a posteriori)的^[18]。而在特征参数方面的变换方法主要有声道长度归一化(VTLN)^[18]、上下文相关特征分析^[14]等。具体的做法通常是,用原有的纯净语音训练好的模型,通过均值方差MLLR自适应到各个不同的声学类别的数据上,或者只保留一个用所有数据训练的鲁棒声学模型,分别用有监督的MLLR对各类数据分别自适应。近年来还发展了应用讲话人自适应训练(Speaker Adaptive Training)^[19]和聚类自适应训练(Cluster Adaptive Training)的方法^[20],从而实现了自适应技术与分段技术

相结合的算法。

5)解码过程(decoding).一般要有多达三次以上的搜索过程,各搜索过程所用声学模型也有所不同.一种典型的方法是^[21]:系统的解码搜索在两次预备性搜索后,产生一个词阵列(word lattice);然后用三元语言模型进行搜索,之后进行基于聚类的声学模型自适应(cluster-based acoustic model adaptation);最后应用MLLR自适应。

6)语言模型(language models).语言模型一般都是采用后退n元语言模型.最常用的是二元和三元模型,也有采用四元模型的.在语言模型的应用上,过去的方法是把所有语料合并训练,近来则发现在不同的语料库上分别训练语言模型,然后再将这些语言模型进行插值,这样得到最终的语言模型性能更好^[16].

5 对于目前广播新闻自动记录系统的研究现状的分析及对策

鉴于广播新闻自动记录系统对语音识别研究的重要性,国内有必要开展这方面的研究.经过十几年的发展,我国的自动语音识别技术在实验室条件下也达到了国际一流水平,具备了向实用化发展的技术条件.虽然国际上的广播新闻自动记录系统已经发展到了相当好的水平,但我们选择适当的发展策略,也能使我们自己的系统研究在比较短的时间里达到相应的水平.

具体来说,我们应该从以下几个方面着手.

首先要建立中文广播新闻语音库和语料库.这是进行广播新闻记录研究的基础.从广播新闻自动记录系统的研究情况可以发现,由于这种特定任务本质上的声学性质多样性,对数据的依赖是显而易见的.国外都报道了在采用新的更多的数据后可以有效地提高声学模型的精度.在建立语料库的过程中,不仅要收集语音素材,还要投入大量细致而艰辛的劳动完成语料的属性标注工作.

应当建立一个有适当集成度的自动语音识别平台,将现有的技术集成在系统之中.结构化的研究平台在当大型语音识别系统的研究中具有重要作用,而拥有完善的研究平台可以对系统各个环节上的多种方案进行对比测试,研究对系统性能的影响,从而获得最优的方案.有一个性能良好的系统平台,不仅对于系统的改进非常方便,而且便于大规模处理语音数据.事实证明一个性能优良的系统,其声学模型和语言模型都是建立在大规模的训练数据之上.

广播新闻自动记录系统的结构中,还应当把声学模型和语言模型进一步优化,并配之以强大的自适应技术.自适应方法已经成为解决语音识别鲁棒性的主流手段,必须加强实用化自适应技术的方法研究,以适应广播新闻领域的应用要求.

在广播新闻自动记录系统的各种新技术中,分段技术占据了一个非常重要的地位.有效的分段技术一方面是用于精确划分输入信号中的语音段从而处理不同的声学环境,另一方面也是处理大型的数据库,实现大规模的声学模型训练的必备技术.此外,在现有的特征提取尚未取得更大突破之前,精确地划分输入信号中的语音段是系统取得好识别结果的决定性因素之一.

在降低系统复杂度,提高响应速度方面,系统与算法的集成是一个很有希望的方向.从实际情况出发,在系统中以算法来集成也许更为现实一些.

由于受资金与研究力量的限制,我们的研究发展原则应该是由小到大,由简到繁,选择有限的目标进行突破。并且应注重系统的结构化,统一数据接口,保持研究工作的延续性。

参 考 文 献

- 1 Pallett D S, Fishcus J G, Fisher W M, Garofolo J S, Use of broadcast news materials for speech recognition benchmark tests. In: Proceedings of EUROSPEECH'97, Rhodes, Greece, Sep. 22~25, 1997, **4**: 1903~1906
- 2 Pallett D S, Fiscus J G, Garofolo F S et al. 1998 broadcast news benchmark test results: english and non-english word error rate performance measures. In: Proceedings of the DARPAR Broadcast News Workshop, Feb. 28~Mar. 3, 1999, Herndon, USA
- 3 Pallett D S, Fiscus J G, Przybocki M A, 1996 preliminary broadcast news benchmark tests. In: Proceedings of the 1997 DARPA Speech Recognition Workshop, Feb. 2~5, 1997, Chantilly, Virginia, USA
- 4 Kubala F, Broadcast News is Good News, In: Proceedings of the DARPAR Broadcast News Workshop, Feb 28~Mar. 3, 1999, Herndon, USA
- 5 Pallett D S, Fiscus J G, Przybocki M A. 1997 broadcast news benchmark test results: english and non-English. In: Proceedings of the 1998 DARPA Broadcast News Transcription and Understanding Workshop, Feb. 8~11, 1998, Lansdowne, Virginia, USA
- 6 Woodland P C, Hain T, Johnson S E et al. The 1997 HTK Broadcast News Transcription System. In: Proceedings of the 1998 DARPA Broadcast News Transcription and Understanding Workshop, Feb. 8~11, 1998, Lansdowne, Virginia, USA
- 7 Hain T, Johnson S E, Tuerk A et al. Segment generation and clustering in the HTK broadcast news transcription system. In: Proceedings of the 1998 DARPA Broadcast News Transcription and Understanding Workshop, Feb. 8~11, 1998, Lansdowne, Virginia, USA
- 8 Gauvain J L, Adda G, Lamel L, Adda-Decker M, Transcribing broadcast news: The LIMSI Nov96 Hub4 system. In: Proceedings of the 1997 DARPA Speech Recognition Workshop, Feb. 2~5, 1997, Chantilly, Virginia, USA
- 9 Chen S S, Eide E M, Gales M J et al. Recent improvements to IBM's speech recognition system for automatic transcription of broadcast news. In: the Proceedings of ICASSP'99, May 15~19, 1999, Phoenix, Arizona, USA
- 10 Chen S S, Gopaladrishnan P S. Speaker, environment and channel change detection and clustering via the Bayesian information criterion. In: Proceedings of the 1998 DARPA Broadcast News Transcription and Understanding Workshop, Feb. 8~11, 1998, Lansdowne, Virginia, USA
- 11 Woodland P C, Gales M J F, Pye D, Young S J, The development of the 1996 HTK broadcast news transcription system. In: Proceedings of the 1997 DARPA Speech Recognition Workshop, Feb. 2~5, 1997, Chantilly, Virginia, USA
- 12 Furrui S. Cepstral analysis Techniques for Automatic Speaker Verification. *IEEE Trans. ASSP*, 1981, **29**: 254~272.
- 13 Zhan P, Wegmann S, Gillick L, Improvement to DRAGON systems' 1998 Mandarin broadcast news transcription system. In: Proceedings of the 1999 DARPA Broadcast News Workshop, Feb 28~Mar 3, 1999, Herndon, USA
- 14 Guo X F, Zhu W B, Shi Q. The IBM LVCSR System Used for 1998 mandarin broadcast news transcription evaluation. In: Proceedings of the DARPAR Broadcast News Workshop, Feb. 28~Mar. 3, 1999, Herndon, USA
- 15 Bakis R, Chen S, Gopalakrishnan P et al. Transcription of broadcast news shows with the IBM large vocabulary speech recognition system. In: Proceedings of the 1997 DARPA Speech Recognition Workshop, Feb. 2~5, 1997, Chantilly, Virginia, USA
- 16 Woodland P C, Hain T, Moore G L et al. The 1998 HTK broadcast news transcription system: development and

- results. In: Proceedings of the DARPA Broadcast News Workshop, Feb 28~Mar 3, 1999, Herndon, USA
- 17 Leggetter C J, Woodland P C. Maximum likelihood linear regression for speaker adaptation of continuous density hidden markov models. *Computer Speech and language*, 1995, 9(2):171~185
- 18 Gauvain J and Lee C. Maximum a posteriori estimation for multivariate gaussian mixture observations of markov chains. *IEEE Trans. on SAP.*, 1994, 2(2):291~298
- 19 Gales M J F. Maximum likelihood linear transformations for HMM-based speech recognition. *Computer speech and Language*, 1998, 12:75~78
- 20 Gales M J F. Cluster adaptive training for speech recognition. In: Proceedings of ICSLP98, Nov. 30~Dec. 4, 1998, Sydney, Australia
- 21 Gauvain J, Lamel L, Adda G, Jardino M. The LIMSI 1998 hub-4e Transcription System. In: Proceedings of the DARPAR Broadcast News Workshop, Feb. 28~Mar. 3, 1999, Herndon, USA

张 红 1968年生,中国科学院自动化研究所博士后,研究领域为语音识别。

黄泰翼 1934年生,研究员,长期从事信息科学的研究,主要研究领域是人机语音通讯方法及语言信息处理,曾主持多个国家科技攻关项目及重大研究项目。

徐 波 1966年生,研究员,主要研究领域是口语及语言信息处理。目前主持多项国家科技攻关项目、“八六三”计划及“九七三”国家重大基础研究项目。

(上接第337页)

项目名称	主要内容	时间	地点	联系人
中国6省(区)自动化学会学术年会	中南地区各省自动化学会例行学术年会	4季度	湖南	长沙市麓山南路326号 唐春华 电话:(0731)8639298 邮编:410012
华东6省1市自动化学会学术年会	华东地区各省自动化学会例行学术年会	3季度	福州	福州大学自动化所 郑应文 电话:(0591)7892009 邮编:350002
华北5省市自动化学会学术年会	华北地区各省自动化学会例行学术年会	7月	秦皇岛	石家庄市友谊南大街 省科学院科研处刘鸿宾 电话:(0311)3031035 邮编:050081
中国自动化学会第16届青年学术年会	线性与非线性系统控制,自适应控制和预测控制;智能控制、模糊控制;神经网络及控制;人工智能与专家系统;机器人与机器人控制;系统工程理论方法及应用;企业改革、发展策略及管理决策;工业过程与生产管理等	7月	桂林	广西桂林电子工业学院计算机系党选举 电话:(0773)5601443 邮编:541004