

基于发音特性的摩擦音和塞擦音分类算法

张连海 陈 斌 屈 丹

(解放军信息工程大学信息工程学院 郑州 450002)

摘要 提出了一种基于发音特性的摩擦音和塞擦音分类方法,该方法首先基于 Seneff 听觉谱提取一组描述音段能量分布特性和谱统计量的特征参数,刻画两者在发音过程上的差异,然后采用支持向量机模型实现摩擦音和塞擦音的分类。实验结果表明,其干净语音分类准确率可以达到 90.08%,信噪比为 5dB 的语音分类准确率可达到 80.4%,与传统的基于时频能量分布特征的摩擦音和塞擦音分类方法相比,较大地提高了低信噪比下的性能。

关键词 摩擦音与塞擦音分类,发音特性,谱统计量,Seneff 听觉模型

中图分类号 TN912.3 文献标识码 A

Method for Fricative and Affricate Classification Based on Articulatory Characteristic

ZHANG Lian-hai CHEN Bin QU Dan

(Institute of Information Engineering, PLA Information Engineering University, Zhengzhou 450002, China)

Abstract A fricative and affricate classification method based on articulatory characteristic was proposed. According to this method, the speech segment energy distributions and spectrum statistical features were first got based upon Seneff's auditory spectrum, and the differences of them were well described. Then fricative and affricate classification was achieved using the support vector machine model. The experimental results show that the classification accuracy is 90.08% for clean speech, 80.4% for noisy speech with the SNR of 5dB. Compared with the traditional time-frequency energy distribution features based fricative and affricate classification methods, the proposed method gets great performance improvement under low SNR.

Keywords Fricative and affricate classification, Articulatory characteristic, Spectrum statistical, Seneff auditory model

1 引言

目前,经典的基于 HMM 模型的语音识别技术有了长足的发展,但是离实用化还有很大的距离,尤其是在复杂环境下,经典的语音识别技术遇到了发展的瓶颈。相比而言,人却能够在复杂环境下准确地识别语音。以人识别语音的过程为基础,提出了一种以知识为基础并结合统计模型的语音识别新框架^[1],其得到了广泛研究^[2,3]。

知识的准确提取,是实现该框架的前提。这里,知识主要是指声学单元边界和类别信息。汉语连续语音识别中,声韵母是常用的识别单元。目前,有关声韵母的分类和定位取得了一定的进展^[4,5]。其中,基于 Seneff 听觉模型的检测系统较好地实现了声韵母边界的检测与非塞音定位^[6]。由于非塞音(塞擦音、摩擦音)是由唇、舌、齿、颚等较多发音器官的复杂配合而发出的,因此通过对塞擦音和摩擦音的分析可以对发音器官病变进行排查和确认,也可以对汉语学习者发音方式进行纠正,对提高语音识别的性能也具有重要的作用,因此在得到非塞音类别的基础上,进一步将非塞音分为塞擦音和摩擦音以得到更为精细的类别信息是十分有必要的。

由于不同的语言非塞音的声学性质具有较大的差异性,

如汉语中非塞音除摩擦音/r/外均为清音,而英语非塞音中有清音、浊音和响音性子音(Sonorant Consonant),因此进行塞擦音和摩擦音的分类,需要结合具体语言选择合适的特征参数,通用性的参数和方法较少。目前对塞擦音和摩擦音的分类较为常用的方法有基于 FFT 变换后谱的统计量^[7]、Bark 谱的统计量^[8]、后端韵母第二共振峰起始位置(F2 Onset)、后端韵母能量变化率^[9]、能量上升时间(Rise Time)^[10]和根据塞擦音与摩擦音在时频分布上的差异,采用计算听觉场景分析的方法^[11]等。为了达到较高的塞擦音和摩擦音的分类性能,需要在上述方法的基础上,根据汉语的特点选取合适的参数进行非塞音的分类。

本文主要是根据摩擦音与塞擦音发音过程的不同,采用音段能量分布特性并结合 Seneff 听觉谱统计量特征,来实现汉语塞擦音和摩擦音的分类。由于语音信号具有相当大的随机性,即使是同一个人在不同的时刻说相同的声韵母,时间长度等特性可能会存在较大的差别,在较小的分析时长内声学性质可能会有较大的变化,因此对语音信号进行分帧处理,难以得到声韵母整体的声学性质,进而影响声韵母类别的检测性能。与传统基于帧的声韵母类别检测方法不同,本文首先对语音信号进行声韵母边界检测,得到声韵母音段;然后采用

收稿日期:2011-11-06 返修日期:2012-01-19 本文受国家自然科学基金(61175107,60872142)资助。

张连海(1971-),男,硕士,副教授,主要研究方向为语音信号处理、模式识别,E-mail:lianhaiz@sina.com;陈斌(1987-),男,博士生,主要研究方向为语音信号处理。

基于音段(segment based)的方法提取特征参数,描述声韵母整体的声学特性;最后利用支持向量机从非塞音中实现塞擦音和摩擦音的分类识别,分类系统如图 1 所示。

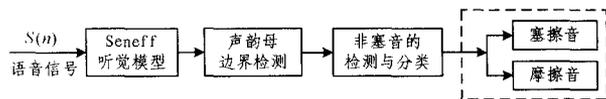


图 1 摩擦音和塞擦音的分类系统图

2 基于听觉谱的音段能量分布特性和谱统计量参数选取

Seneff 听觉模型^[12,13]由 40 个临界频带滤波器组成,能较好地模拟人耳对语音的听觉处理过程,描述听觉神经饱和、自适应调适、掩蔽,对电流感应具有单向性,易受低频周期信号激发等。Seneff 听觉感知模型的输出称为 Seneff 听觉谱,它能够较好地描述音素的能量分布特性和共振峰结构。Seneff 听觉谱由两部分组成:包络响应(Envelope Detector)ED 和同步响应(Generalize Synchrony Detector)GSD。其中,ED 凸显语音信号中变化剧烈区域的开始与结束,GSD 则突出共振峰结构。由于 GSD 的求解过程是直接对每个通道的 GSD_i 求平均,因此它会导致频域分辨率降低,同时出现伪峰值。为了避免 GSD 直接求平均,增强共振峰提取的可靠性,Alj^[14,15]提出了平均局部同步输出(Average Localize Synchrony Detector)ALSD。

研究发现,摩擦音和塞擦音声学性质的差异主要是由其不同的发音过程造成的。本文利用这种差异性特征进行摩擦音和塞擦音的检测分类,这种特征是指音段能量分布特性及其衍生特征,主要包括能量最大变化位置、高频带能量、音段前端与后端能量比和谐统计量等。

由于塞擦音与摩擦音发音方法的主要区别在于塞擦音产生过程中具有发音声道某位置先闭合,积累声压后又突然释放的过程,故其能量最大变化率发生位置一般会位于音段的中间部分,即气流释放瞬间,而摩擦音能量缓慢累积、缓慢释放,能量最大变化率发生位置大都位于音段的最前端与最后端。由于摩擦音和塞擦音能量主要分布在高频带,这里采用高频带包络响应最大变化率发生位置(High-Band ED Largest Change Rate Location, HLCRL) $HLCRL_{ED}$ 参数来描述这一特性,计算式为:

$$HLCRL_{ED} = \arg \max_n \{ |HBE_{ED}(n+1) - HBE_{ED}(n)| \} \quad (1)$$

式中, $HBE_{ED}(n) = \sum_{i=36}^{40} ED_i(n)$, $i=1, \dots, 40$ 为听觉模型通道值, $n=1, \dots, N$ 为每一通道的输出。

由于塞擦音和摩擦音在音段长度内能量变化率有较大的差异,并且它们在高频带的能量分布差异性最大,因此这里采用归一化高频带 ED 能量(Normalized High-Band ED, NHBE) $NHBE_{ED}$ 进行描述,求解式为:

$$NHBE_{ED} = \frac{1}{N} \sum_{n=1}^N \left(\sum_{i=36}^{40} ED_i(n) \right) / \left(\max \left(\sum_{i=36}^{40} ED_i(n) \right) \right) \quad (2)$$

塞擦音的音段前端存在发音器官闭合的现象,因此音段前端的能量值会偏低,随着气流的释放,音段后端的能量值会逐渐地增大,音段前端的能量值会小于后端的能量值,因此塞擦音的音段前端能量与音段后端能量之比通常会小于 1。而

摩擦音一开始发声能量就持续上升,音段后端则逐渐减弱,因此摩擦音音段前端的能量值会大于后端能量值,音段前端能量与音段后端能量之比通常会大于 1。这里基于 ALSO 输出采用 $PreABE_{ALSD}$ 来描述音段全频带的前端能量, $BackABE_{ALSD}$ 描述音段全频带的后端能量, $PARABE_{ALSD}$ 描述音段的前端与后端能量的比,计算式如下:

$$PARABE_{ALSD} = (PreABE_{ALSD}) / BackABE_{ALSD} \quad (3)$$

式中, $(PreABE_{ALSD}) = \sum_{n=S}^{S+0.5 \cdot D} ABE_{ALSD}(n)$, $(BackABE_{ALSD}) = \sum_{n=S+0.5 \cdot D}^{S+D} ABE_{ALSD}(n)$, S 为音段的起始点, D 为音段的持续时间。

塞擦音与摩擦音的发音方式不同,使谱之间存在较大差异,如摩擦音中软腭音的谱较为集中,中心值较高;而塞擦音中软腭音的谱缓慢上升,摩擦音中双唇音的谱较为平坦等。图 2 为塞擦音/sh/与摩擦音/z/的语谱图,由图 2 看出,两者在谱形状上存在较大的差异,可以采用谱的统计量去刻画谱的形状,进而实现塞擦音与摩擦音的区分。

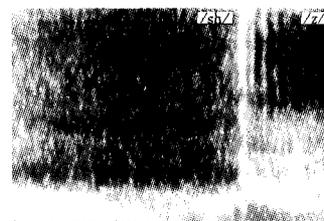


图 2 塞擦音/sh/与摩擦音/z/的语谱图

这里采用 Seneff 听觉模型中临界频带滤波器组输出的谱统计量进行描述。求解步骤为:

(1) 计算频域的谱统计量

对音段进行 512 点的 FFT 变换,利用前 256 点进行谱统计量的计算,可以得到频域谱的统计量均值 L_{mean} 、方差 L_{var} 、偏度 L_{skew} 和峰度 L_{kurt} :

$$L_{mean} = \sum_{k=1}^K f_k p(k) \quad (4)$$

$$L_{var} = \sum_{k=1}^K (f_k - L_{mean})^2 p(k) \quad (5)$$

$$L_{skew} = \sum_{k=1}^K (f_k - L_{mean})^3 p(k) / (L_{var})^{\frac{3}{2}} \quad (6)$$

$$L_{kurt} = \sum_{k=1}^K (f_k - L_{mean})^4 p(k) / (L_{var})^2 - 3 \quad (7)$$

式中, $p(k) = P(k) / \sum_{k=1}^{256} P(k)$, $P(k)$ 为对应的频谱幅度值, $f_k = kf_s / 512$, k 为频率采样点, f_s 为采样频率。

(2) 根据频率与滤波器组频率的对应关系进行非线性压缩转换

Seneff 听觉模型中,线性频域 f_k 与临界频带滤波器组中频域 C_k 的对应关系为:

$$C_k = 13 \arctan(0.00076 f_k) + 3.5 \arctan(0.0075 f_k)^2 \quad (8)$$

变换后的频谱幅度值 $P_C(k)$ 与线性频域频谱幅度值 $P(k)$ 的对应关系为 $P_C(k) = (C_k - C_{k-1}) P(k)$, 频率 f_k 用对应的 C_k 替换,便可以得到基于 Seneff 听觉模型相对应的谱统计量均值 S_{mean} 、方差 S_{var} 、偏度 S_{skew} 和峰度 S_{kurt} 。

3 支持向量机分类模型

对摩擦音与塞擦音的分类,利用支持向量机模型采用 C-SVC 方法,对于线性可分数据的二元分类,支持向量机的机

理可以简单描述为:寻找一个满足分类要求的最优分类超平面,使该超平面在保证分类精度的同时,超平面两侧的分类间隔最大化。从理论上来说,支持向量机能够对线性可分数据的最优分类,同时具有较好的泛化能力。而对于非线性问题,通常可以通过非线性变换将原始集合映射到高维特征空间,并转化为某个高维空间中的线性问题,在新的空间中求最优分类面。在最优分类面中采用适当的内积函数就可以实现某一非线性变换后的线性分类。其中,两类模式摩擦音和塞擦音之间的识别函数可以定义为:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^l \alpha_i y_i K(x, x_i) + b \right\} = \begin{cases} 1, & \text{Fricative} \\ -1, & \text{Affricate} \end{cases} \quad (9)$$

式中, $x_i \in \mathbf{R}^7$ ($i=1, 2, \dots, l$) 为 7 维训练样本, 个数为 l ; $x \in \mathbf{R}^7$ 为实时样本。 y 为样本标签, $y_i \in \{-1, 1\}$ 。 α 为拉格朗日乘子系数向量, $0 \leq \alpha_i \leq C$, $y^T \alpha = 0$ 。 b 为两类间分类阈值。 $K(*, *)$ 为核函数, 文中使用径向基(RBF)核函数, 表达式为:

$$K(x, x_i) = \exp \left\{ -\frac{\|x - x_i\|^2}{\sigma^2} \right\} \quad (10)$$

式中, σ^2 为核函数的参数。文中模式识别是“一对一”, 对非塞音音段提取音段能量分布特性和谱统计量特征, 组成训练特征矢量, 结合交叉验证进行参数 C 与 σ^2 的最佳搭配选取。

4 实验及结果分析

4.1 实验语料

随机从微软语料库 Speech Corpora (Version 1.0) 中截取 43 段连续语流作为实验语料, 总共有 610 个非塞音音段, 其中塞擦音与摩擦音各 305 个, 语音的采样频率为 16kHz, 量化精度为 16bit, 人工进行声韵母的边界和塞擦音与摩擦音的标注。对检测结果的评估采用语音识别的评估方式。实际检测单元的总数记为 N , 正确检测单元的总数记为 H , 删除错误的总数记为 D , 插入错误的总数记为 I 。正确率和准确率的定义如式(11)和式(12)所示^[16]。

$$\%C = \frac{H}{N} \times 100\% \quad (11)$$

$$\%A = \frac{H-I}{N} \times 100\% \quad (12)$$

4.2 实验结果

本文采用的是无师学习, 在塞擦音与摩擦音音段中各选取 150 个作为训练语料, 剩下的 155 个作为测试语料。将上述音段能量分布特性和谱统计量参数输入到支持向量机模型(SVM)中, 以进行检测分类。表 1 为采用音段能量分布特性参数和音段能量分布特性参数与谱统计量相结合的塞擦音与摩擦音的分类检测结果。

表 1 塞擦音与摩擦音的分类检测结果

检测结果	塞擦音		摩擦音	
	正确率% C	准确率% A	正确率% C	准确率% A
特征参数				
音段能量分布特性参数	88.13	86.34	87.72	85.42
+谱统计量	93.33	90.15	92.68	89.76

由表 1 可知, 音段能量分布特性参数对于区分塞擦音和摩擦音具有较好的效果, 进一步分析参数可知, 音段前端与后端能量比 $PARABE_{ALSD}$ 对于塞擦音和摩擦音的分类有着较为关键的作用, 因为这个参数结合了音段能量分布特性、时域特性和能量变换特性。在音段能量分布特性参数的基础上结合谱统计量能够进一步提高分类的效果。通过对分类错误的

音段进行观察可知, 其主要是由塞擦音/zh/、/ch/与摩擦音/sh/引起的, 三者之间具有很相似的声学特性和谱形状, 引入了较多的删除错误和插入错误。塞擦音和摩擦音中, 唇齿音和舌齿音之间差异性较大, 具有很高的分类准确率。

为了验证所提参数的有效性和塞擦音与摩擦音的分类检测效果, 对最近提出的采用计算听觉场景分析^[11]的方法与本文方法的分类性能进行比较, 表 2 为两种方法在不同信噪比条件下的检测结果。

表 2 不同方法的塞擦音和摩擦音分类性能

分类方法	检测指标	噪声	干净语音	20dB/%	10dB/%	5dB/%
		/ %				
本文方法	正确率% C	92.87	90.23	88.59	84.81	
	准确率% A	90.08	86.17	84.82	80.40	
基于计算听觉场景分析	正确率% C	92.56	88.37	77.18	65.61	
	准确率% A	89.64	85.42	72.37	60.72	

由表 2 可知, 本文方法与基于计算听觉场景分析的塞擦音与摩擦音分类方法相比, 在干净语音和高信噪比的条件下, 分类性能有所提高, 能较为明显地提高低信噪比条件下的分类性能。这主要是因为基于听觉场景分析的塞擦音与摩擦音的分类方法是根据语音信号的能量分布特性来进行时频分析, 对语音信号在语谱图上进行分离和重构, 由于塞擦音和摩擦音是清音谱, 类似于噪声, 因此随着信噪比的降低其会与噪声混淆得较为严重, 难以正确地分离。而本文方法采用基于 Seneff 听觉谱的发音特性参数, 由于 Seneff 听觉谱具有较好的抗噪声性能, 另外发音特性参数受噪声的影响较小, 具有较好的稳定性和鲁棒性, 因此本文方法能得到较好的塞擦音和摩擦音的分类性能。

4.3 模型的交叉验证

由于本文的测试和训练样本数相对较少, 为了验证所选用参数和分类方法的有效性, 基于上述实验语料, 本文进一步采用留一法(Leave-One-Out)对分类性能和泛化性能进行测试。留一法的基本思想为对于一个样本总数为 N 的集合, 每次选取一个样本作为测试集, 其余 $N-1$ 为训练集, 重复 N 次。为了减小计算量, 本文从塞擦音和摩擦音中各选取 140 个样本, 分为 20 份, 每次选取 1 份作为测试集, 其余 19 份作为训练集。根据交互验证均方根(RMSEVC)和预测均方根(RMSEP)进行分类性能的评价, RMSEVC 和 RMSEP 数值越小, 模型性能越好。

$$\text{RMSECV} = \sqrt{\frac{\sum_{i=1}^n (c_i - \hat{c}_i)^2}{n}} \quad (13)$$

$$\text{RMSEP} = \sqrt{\frac{\sum_{i=1}^m (c_i - \hat{c}_i)^2}{m}} \quad (14)$$

式中, c_i 是实际值, \hat{c}_i 是测试值, n 是训练集样本数, m 是测试集样本数。本文将 c_i 与 \hat{c}_i 二值化取值为 0 或 1, 即将塞擦音标为 0, 摩擦音标为 1。

经过测试可得本文方法的 $\text{RMSEVC} = 0.0532$, $\text{RMSEP} = 0.7109$, 可知本文模型具有较好的稳定性和泛化性能, 能较好地克服模型的过训练。

结束语 通过对塞擦音和摩擦音发音过程进行研究, 本文提出了一种基于发音特性的塞擦音和摩擦音的分类算法。该方法通过提取音段能量分布特性和谱统计量特征来刻画两

类发音过程的差异,较好地实现了塞擦音和摩擦音的分类,提高了低信噪比下的分类性能。文中较多错误是由塞擦音/zh/、/ch/与摩擦音/sh/引起的,因此后续的研究可以根据其他特征参数来提高塞擦音/zh/、/ch/与摩擦音/sh/间的分类准确率,进一步提高塞擦音与摩擦音的分类准确率。

参考文献

[1] Lee Chin-Hui. From knowledge-ignorant to knowledge-rich modeling, A new speech research paradigm for next generation automatic speech recognition[C]// Proceedings Of ICSLP Keynote Speech, 2004

[2] Geiger J T, Lakhal M A, Schuller B, et al. Learning new acoustic events in an HMM-based system using MAP adaptation[C]// Proceedings of INTERSPEECH, 2011; 293-296

[3] David M-N, Ascensión G-A, Carmen P-M. Feature Extraction Assessment for an Acoustic-Event Classification Task Using the Entropy Triangle[C]// Proceedings of INTERSPEECH, 2011; 309-312

[4] 张宝奇, 张连海, 屈丹. 基于听觉事件检测的汉语语音声韵切分[J]. 声学学报, 2010, 35(6): 701-707

[5] Almpantidis G, Kotropoulos K M. Robust Detection of Phone Boundaries Using Model Selection Criteria With Few Observations[J]. IEEE Transactions on Audio, Speech, and Language Processing, 2009, 17(2): 287-298

[6] 陈斌, 张连海, 王波. 基于 Seneff 听觉谱特征的汉语连续语音声韵母边界检测[J]. 声学学报, 2012, 37(1): 104-112

[7] Forrest K, Weisme G. Statistical analysis of word-initial voiceless obstruents: Preliminary data[J]. Acoustical Society of A-

merica, 1996, 84(1): 115-123

[8] Jongman A, Wayland R, Wong S. Acoustic characteristics of English fricatives[J]. Journal of the Acoustical Society of America, 2000, 108: 1252-1263

[9] Sussman H M, Bessell N, Dalston E, et al. An investigation of stop place of articulation as a function of syllable position; A locus equation perspective[J]. Journal of the Acoustical Society of America, 1998, 101: 2826-2838

[10] Kluender K R, Walsh M A. Amplitude rise time and the perception of the voiceless affricate/fricative distinction[J]. Perception and Psychophysics, 2002, 51: 328-333

[11] Hu Guo-ning, Wang De-liang. Separation of fricatives and affricates[C]// Proceedings of ICASSP, 2005; 1001-1004

[12] Seneff S. A joint synchrony/mean-rate model of auditory speech processing[J]. Journal of Phonetics, 1988, 16: 55-76

[13] Seneff S. Pitch and Spectral Analysis of Speech Based on an Auditory Synchrony Model[M]. Cambridge, Massachusetts Institute of Technology, 1985

[14] Ahmed M, Abdelatty A, Jan Van der S, et al. Robust Auditory-Based Speech Processing Using the Average Localized Synchrony Detection[J]. IEEE Transaction on Signal and Audio Processing, 2001, 10: 279-292

[15] AAhmed M. Abdelatty A, Jan Van der S. Paul Mueller Acoustic-Phonetic Features for the Automatic Classification of Stop Consonants[J]. IEEE Transaction on Signal and Audio Processing, 2001, 9(8): 833-841

[16] Young S. The HTK Book (for HTK Version 3. 4) [M]. Cambridge University Engineering Department, 2006; 289

(上接第 191 页)

使用一个合理的 N 值限制负类样本分布,可以增强负类样本的内聚度,提高 RSS 的分类准确性。当 $N=0$ 时,负类样本分布上界约束无效,ARRSS 与 RSS 等价。

结束语 相对间隔被用于限制 SVM 中样本的分布上界,能有效克服特征空间内样本分布不合理引起的性能下降问题。本文将相对间隔加入到单球面分类器 RSS 中,建立了自适应上界约束的最大相对间隔比单球面分类器 ARRSS,通过限制负类样本分布上界的方式提高了分类性能。ARRSS 本质上是一个凸二次规划问题,是对 RSS 的一个拓展,当 $N=0$ 时,ARRSS 等价于 RSS。因此,ARRSS 表现出了比 RSS 更好的性能。ARRSS 使用单球面进行分类,只适用于单模态分布样本集。因此,对于机器学习中普遍存在的多模态分布问题,需要通过构造一系列单球面来进行逼近求解。

参考文献

[1] Cortes C, Vapnik V. Support-vector network[J]. Machine Learning, 1995, 20(3): 273-297

[2] Vapnik V. The nature of statistical learning theory [M]. New York: Springer, 1995

[3] Tax M J, Duin P W. Support vector domain description [J]. Pattern Recognition Letters, 1999, 20: 1191-1199

[4] Schölkopf B, Platt J C, Taylor J S, et al. Estimating the support of a high-dimensional distribution [J]. Neural Computation, 2001, 13: 1443-1471

[5] Larry M M, Malik Y. One-class SVMs for document classification [J]. Journal of Machine Learning Research, 2001, 2: 139-154

[6] Chen Y Q, Zhou X S, Huang T S. One-class SVM for learning in image retrieval[C]// Proceedings of the 2001 IEEE International Conference on Image Processing, Greece; Thessaloniki, 2001, 1: 34-37

[7] Zhu M L, Chen S F, Liu X D. Sphere-structured support vector machines for multi-class pattern recognition [J]. Lecture Notes in Computer Science, 2003, 2639: 589-593

[8] Wang J G, Neskovic P, Cooper L N. Pattern classification via single spheres [J]. Lecture Notes in Computer Science, 2005, 3735: 241-252

[9] Hao P Y, Chiang J H, Lin Y H. A new maximal margin spherical structured multiclass support vector machine [J]. Applied Intelligence, 2009, 30(2): 98-111

[10] 文传军, 詹永照, 陈长军. 最大间隔最小体积球形支持向量机[J]. 控制与决策, 2010, 25(1): 79-83

[11] Shivaswamy P K, Jebara T. Relative margin machines [C]// Advances in Neural Information Processing System. 2008, 21: 1481-1488

[12] Shivaswamy P K, Jebara T. Maximum relative margin and data-dependent regularization [J]. Journal of Machine Learning Research, 2010, 11: 747-788

[13] Shivaswamy P K, Jebara T. Structured prediction with relative margin [C]// International Conference on Machine Learning and Applications, 2009: 281-287