

文章编号: 1672-2892(2012)05-0574-05

多样本状态加权合成的 CGHMM 训练算法

陆汝华, 李盛欣

(湘南学院 计算机科学系, 湖南 郴州 423000)

摘 要:为解决隐马尔可夫模型(HMM)中参数很多,实际当中难以提供足够多训练数据的问题,根据观察值序列的状态分布情况,描述了一种基于状态加权合成的连续高斯混合密度隐马尔可夫模型(CGMM)训练算法,对多个 CGMM 模型进行加权合成,并将此方法应用于轴承故障诊断进行仿真实验。实验结果表明,平均训练时间为 12.86 s,诊断时间为 0.189 s,诊断准确率为 96%。可见,多样本状态加权合成的 CGMM 轴承故障诊断方法确实有效可行,具有良好的应用前景。

关键词:连续高斯混合密度隐马尔可夫模型;训练算法;状态加权合成

中图分类号: TN912.34; TP277

文献标识码: A

Training algorithm of HMM based on multi-sample state-weighted synthesis

LU Ru-hua, LI Sheng-xin

(Department of Computer Science, Xiangnan University, Chenzhou Hunan 423000, China)

Abstract: A training algorithm, state-weighted synthesis Continuous Gaussian mixture Hidden Markov Model(CGMM) synthesized by several CGMMs, is presented according to the states distribution of observations. It can solve the problem that it was difficult to provide enough training data due to too many parameters in HMM model. The proposed method is applied in bearing fault diagnosis, and the average training time of 12.86 s, diagnosis time of 0.189 s, and diagnosis rate of 90% are obtained. The method based on state-weighted synthesis CGMM is effective and feasible in bearing fault diagnosis and has a great prospect for application.

Key words: Continuous Gaussian mixture Hidden Markov Model; training algorithm; state-weighted synthesis

1970 年前后,由 Baum 等人建立起来的隐马尔可夫模型(Hidden Markov Model, HMM)具有良好识别和抗噪性能^[1-2],是语音识别领域最受瞩目、最有效的技术之一^[3],同样在故障诊断研究中得到了较好的效果^[4-6]。但是,由于 HMM 参数很多,在实际当中,一般难以提供足够多的训练数据,此时需要针对同一对象表示的不同 HMM 模型进行加权合成^[7]。但对加权合成的 HMM 模型只有少量研究,在国内仅谢锦辉研究了离散 HMM(Discrete HMM, DHMM),并只应用于语音识别,而且论文并没有较为详细和完善的算法介绍^[7]。由于连续高斯混合密度 HMM(CGMM)的输出序列不存在量化处理,能够比较精确地表示原始信号,有利于提高识别准确度;并且利用高斯混合密度函数对输出概率进行描述,能够减少模型存储空间,降低运算复杂度^[8]。因此,本文针对多样本观察值序列问题,详细地描述了一种基于状态加权合成的 CGMM 训练算法,并将其应用于轴承故障诊断。实验结果表明,多样本加权合成的 CGMM 轴承故障诊断方法确实有效可行,具有良好的应用前景。

1 单个样本的 CGMM 训练算法

一个 CGMM 模型 $\lambda = (\pi, A, \mu_{jm}, \sigma_{jm}^2, \omega_{jm})$ 包含 5 个待估计参数,为了得到满意模型,需要选取多样本来进行 CGMM 模型训练。

设训练样本数为 L , 定义 $\varepsilon_t^{(l)}(i, j)$ ($1 \leq t \leq T, 1 \leq l \leq L, 1 \leq i, j \leq N$) 为第 l 个训练样本 $O^{(l)}$ 在 t 时刻模型处于状态

收稿日期: 2012-01-01; 修回日期: 2012-02-23

基金项目: 国家自然科学基金资助项目(61103108); 湖南省科技计划资助项目(2010FJ6028); 湖南省教育科学“十二五”规划课题(XJK012CGD034)

S_i 和 $t+1$ 时刻处理状态 S_j 时的概率, 表示为:

$$\varepsilon_t^{(l)}(i, j) = [\alpha_t^{(l)}(i) a_{ij} b_j(O_{t+1}^{(l)}) \beta_t^{(l)}(j)] / P(O^{(l)} / \lambda) \quad (1)$$

式中: $\alpha_t^{(l)}(i)$ 和 $\beta_t^{(l)}(i)$ 是根据前向-后向算法^[5]得出的第 l 个训练样本的前向概率和后向概率, 其他 T, N, S_i 等本文所涉及到的所有 CGHMM 参数描述参见文献^[5]。再定义 $\gamma_t^{(l)}(j, m)$ 为观察序列 $O^{(l)}$ 在 t 时刻处于状态 S_j 时对于第 m 个混合高斯元的输出概率, 称为混合输出概率, 即

$$\gamma_t^{(l)}(j, m) = \frac{\alpha_t^{(l)}(j) \beta_t^{(l)}(j)}{\sum_{i=1}^N \alpha_t^{(l)}(i) \beta_t^{(l)}(i)} \frac{\omega_{jm} N(O_t^{(l)}, \mu_{jm}, \sigma_{jm}^2)}{\sum_{k=1}^M \omega_{jk} N(O_t^{(l)}, \mu_{jk}, \sigma_{jk}^2)} \quad (2)$$

记第 l 个 CGHMM 模型参数 $\lambda_l = (\pi_{il}, a_{ijl}, \mu_{jml}, \sigma_{jml}^2, \omega_{jml})$, 则第 l 个观察值序列的训练算法表示为:

$$\pi_{il} = \sum_{j=1}^N \varepsilon_1^{(l)}(i, j) \quad (3)$$

$$a_{ijl} = \frac{\sum_{t=1}^{T-1} \varepsilon_t^{(l)}(i, j)}{\sum_{t=1}^{T-1} \sum_{k=1}^N \varepsilon_t^{(l)}(i, k)} \quad (4)$$

$$\mu_{jml} = \frac{\sum_{t=1}^T \gamma_t^{(l)}(j, m) O_t^{(l)}}{\sum_{t=1}^T \gamma_t^{(l)}(j, m)} \quad (5)$$

$$\sigma_{jml}^2 = \frac{\sum_{t=1}^T \gamma_t^{(l)}(j, m) (O_t^{(l)} - \mu_{jml})(O_t^{(l)} - \mu_{jml})'}{\sum_{t=1}^T \gamma_t^{(l)}(j, m)} \quad (6)$$

$$\omega_{jml} = \frac{\sum_{t=1}^T \gamma_t^{(l)}(j, m)}{\sum_{t=1}^T \sum_{k=1}^M \gamma_t^{(l)}(j, k)} \quad (7)$$

2 状态加权合成的权值计算

一般来说, 合并 L 个模型可表示为 $\lambda = \sum_{l=1}^L \omega_l \lambda_l$, 且满足 $\sum_{l=1}^L \omega_l = 1$, 其中 λ 是结果模型, $\lambda_l (1 \leq l \leq L)$ 是待合并模型。但是, 此合并方法中每个 HMM 模型只有 1 个权值, 并不能取得较好的效果^[7]。由于 CGHMM 模型中的状态体现了观察值序列分布情况, 对每一个待合并模型中的每个状态都选定 1 个权值, 能使训练出来的模型具有更好的识别效果, 因此, 本文使用一种基于状态分布的加权合成方法。

定义: $R_{il} (1 \leq i \leq N, 1 \leq l \leq L)$ 为第 l 个 CGHMM 模型的加权合成权值, 表示处于状态 S_i 的观察值序列中, 第 l 个训练样本 $O^{(l)}$ 所占的比例, 即

$$R_{il} = \frac{O^{(l)} \text{ number of observation in state } S_i}{\sum_{k=1}^L O^{(k)} \text{ number of observation in state } S_i} \quad (8)$$

显然满足合并 L 个模型的基本条件 $\sum_{l=1}^L R_{il} = 1$ 。根据 L 个观察值序列 CGHMM 状态的分布情况, 计算出每一次参数重估的合并权值。下面是基于欧氏距离分配观察值序列状态计算权值的具体实现步骤。

Step1: 设定参数: 输入观察值序列 $O = \{O^{(1)}, O^{(2)}, \dots, O^{(L)}\}$; 状态数为 N ; 迭代算法的最大迭代次数为 L ; 畸变改进阈值为 δ 。

Step2: 设定初值: 根据经验或等间隔选取 N 个点, 分别作为 N 个状态的初值 $S_1, S_2, \dots, S_N$, 并记状态 S_i 的长度为 N_i , N_i 初值为零; 迭代次数初值 $m = 1$ 。

Step 3: 将 $O_t^{(l)}$ 分配给状态 S_j ; 同时, $N_j \leftarrow N_j + 1$; 其中,

$$j = \arg \min_{1 \leq i \leq N} (\|O_t^{(l)} - S_i\|), \quad i = 1, 2, \dots, N \quad (9)$$

$\|O_t^{(l)} - S_i\|$ 表示观察序列 $O_t^{(l)}$ 到 S_i 的距离。

Step4: 将每类状态的均值向量作为该类状态的新值:

$$S_j = \frac{1}{N_j} \sum_{O_t^{(l)} \in S_j} O_t^{(l)}, \quad 1 \leq j \leq N \quad (10)$$

Step5: 计算所有观察序列 $O_t^{(l)}$ 到其对应状态值的误差平方和

$$J_e = \sum_{j=1}^N \sum_{O_t^{(l)} \in S_j} \|O_t^{(l)} - S_j\|^2 \quad (11)$$

如果 J_e 的变化值小于畸变改进阈值 δ , 则转入 Step7。

Step6: 若 $m < L$, 则令 $m = m + 1$, N_i 为零, 同时转入 Step3。

Step7: 算法结束。

该迭代算法中设置了畸变改进阈值 δ 来终止迭代计算, 表明再进行迭代运算失真的减小是有限的, 可以停止运算。同时为了避免迭代算法无限循环, 又设置了最大迭代次数为 L , 防止畸变改进阈值 δ 设置较低而迭代次数过多。迭代算法退出之后, 根据最后一次 Step 3 将观察值序列分配的状态结果, 计算出每个样本每种状态的合并权值 $R_{il} (1 \leq i \leq N, 1 \leq l \leq L)$ 。

3 多样本状态加权合成的 CGHMM 训练算法

根据上述计算出来的单个样本的 CGHMM 模型参数 $\lambda_l = (\pi_{il}, a_{ijl}, \mu_{jml}, \sigma_{jml}^2, \omega_{jml}) (1 \leq l \leq L)$ 和多样本状态加权合成的权值 $R_{il} (1 \leq i \leq N, 1 \leq l \leq L)$, 可以得出, 基于多样本状态加权合成的 CGHMM 训练算法为:

$$\overline{\pi_i} = \sum_{l=1}^L R_{il} \overline{\pi_{il}} = \sum_{l=1}^L R_{il} \sum_{j=1}^N \varepsilon_1^{(l)}(i, j) \quad (12)$$

$$\overline{a_{ij}} = \sum_{l=1}^L R_{il} \overline{a_{ijl}} = \sum_{l=1}^L R_{il} \frac{\sum_{t=1}^{T-1} \varepsilon_t^{(l)}(i, j)}{\sum_{t=1}^{T-1} \sum_{k=1}^N \varepsilon_t^{(l)}(i, k)} \quad (13)$$

$$\overline{\mu_{jm}} = \sum_{l=1}^L R_{jl} \overline{\mu_{jml}} = \sum_{l=1}^L R_{jl} \frac{\sum_{t=1}^T \gamma_t^{(l)}(j, m) O_t^{(l)}}{\sum_{t=1}^T \gamma_t^{(l)}(j, m)} \quad (14)$$

$$\overline{\sigma_{jm}^2} = \sum_{l=1}^L R_{jl} \overline{\sigma_{jml}^2} = \sum_{l=1}^L R_{jl} \frac{\sum_{t=1}^T \gamma_t^{(l)}(j, m) (O_t^{(l)} - \mu_{jm})(O_t^{(l)} - \mu_{jm})'}{\sum_{t=1}^T \gamma_t^{(l)}(j, m)} \quad (15)$$

$$\overline{\omega_{jm}} = \sum_{l=1}^L R_{jl} \overline{\omega_{jml}} = \sum_{l=1}^L R_{jl} \frac{\sum_{t=1}^T \gamma_t^{(l)}(j, m)}{\sum_{t=1}^T \sum_{k=1}^M \gamma_t^{(l)}(j, k)} \quad (16)$$

4 轴承故障诊断仿真实验

本次实验的对象为轴承 4 种典型的故障(外圈故障、内圈故障、滚动体故障、保持架故障)和正常等 5 类运行状态下轴承工作时所发出来的音频信号。音频信号共 200 个样本, 包含正常声音、外圈异音、内圈异音、滚动体异音和保持架异音等 5 类各 40 个。其中每类的 30 个共 150 个样本用于多样本状态加权合成的 CGHMM 训练, 每类剩下的 10 个信号共 50 个用于 CGHMM 诊断实验, 以测试本文方法在 Visual C++ 环境下的故障诊断效果。

4.1 加权合成的训练实验

加权合成的模型训练首先是对权值的计算。设置迭代算法的最大迭代次数 L 为 50，畸变改进阈值 δ 为 1，以此来共同控制迭代循环。通过多次实验表明，在迭代过程中，公式(11)获得的误差平方和 J_e 趋于越来越小，大约平均循环 40 次即可退出迭代算法。本次实验设置 CGHMM 模型的状态数为 7，将每个样本形成长度为 35 的观察值序列，则 30 个样本的观察值序列长度为 1050。其中，在正常声音 30 个样本的 CGHMM 训练实验中，获得 7 种状态 S_i ($1 \leq i \leq N$) 的长度 N_i 分别为：168,165,172,158,89,131,167，并且，第 1 个样本分布在 7 种状态 S_i 中的状态数分别为：7,7,3,5,5,4,4，由此可得，正常声音第 1 个样本加权合成的权值 R_{i1} 为：0.042,0.042,0.017,0.032,0.056,0.031,0.024。

获得权值之后，利用式(12)~式(16)进行加权合成的 CGHMM 训练，测试出正常声音、外圈异音、内圈异音、滚动体异音和保持架异音等 5 类模型的训练时间，如表 1 所示，其中平均训练时间为 12.86 s。5 个模型共有 150 个样本的总共训练时间只需要 64.30 s，大概 1 min 即可完成整个训练过程，完全满足程序的实时性要求。

表 1 各种故障类型的训练时间
Table 1 Training time for all kinds of faults

fault type	normal	inner ring	outer ring	rolling element	cage
training time/s	12.61	13.03	12.91	12.61	13.14

4.2 诊断实验

对正常声音、外圈异音、内圈异音、滚动体异音和保持架异音等 5 类模型训练完成之后，将各 CGHMM 模型参数存储，这些模型参数构成了一个模型库，此时，系统就具备了故障诊断的能力。输入一个待诊断信号，使用 CGHMM 识别算法^[5]，计算其在模型库中各模型条件下的输出概率，通常情况下，概率最大的模型即为诊断结果。图 1 为正常声音剩下的 10 个信号在各模型条件下的输出概率图，其中横坐标表示信号数，纵坐标表示输出概率以 10 为底的对数，还有输出概率为零的在图中未作说明。从图中可以看出，10 个信号在正常声音模型下所输出的概率都是最大，其他大部分为零，都识别为正常声音，诊断正确率为 100%。

为了检验加权合成 CGHMM 方法的训练效果，对其他 40 个信号也进行了同样的测试，并且记录了 50 个信号的诊断结果和平均诊断时间，结果如表 2 所示。共 50 个数据有 2 个误识，总的诊断准确率为 96%。本次实验的诊断时间都非常短，5 类数据的平均诊断时间都在 0.2 s 之内，总的平均诊断时间为 0.189 s。测试结果表明，本文方法有较高的诊断准确度和较快的诊断速度，可以满足可靠性和实时性要求，具有很好的应用前景。




Fig.1 Probability output
图 1 概率输出图

表 2 诊断结果
Table2 Results of diagnosis

fault type	diagnosis times	diagnosis results						diagnosis precision	average diagnosis time/s
		normal	outer ring	inner ring	rolling element	cage	others		
normal	10	10	0	0	0	0	0	100%	0.195
outer ring	10	0	10	0	0	0	0	100%	0.188
inner ring	10	0	0	10	0	0	0	100%	0.190
rolling element	10	0	0	0	9	1	0	90%	0.185
cage	10	0	0	0	9	0	1	90%	0.188

5 结论

在解决隐马尔可夫模型中参数很多，实际当中难以提供足够多训练数据的问题时，本文通过对单个样本的 CGHMM 训练算法和状态加权合成的权值计算步骤等进行研究，详细地描述了一种基于状态加权合成的 CGHMM 算法，对多个 CGHMM 模型进行加权合成，并将此方法应用于轴承故障诊断进行仿真实验。实验结果表明，多样本加权合成的 CGHMM 轴承故障诊断方法确实有效可行，具有良好的应用前景。但是，由于训练过程数据量较大，实验中存在少数数据溢出现象，一定程度上影响了实验结果，相关问题有待进一步研究。

参考文献:

- [1] 张玉军,杨巨龙,孙大飞,等. 小波 MFCC 和 HMM 在低空声目标识别中的应用[J]. 信息与电子工程, 2011,9(6): 744-748. (ZHANG Yujun,YANG Julong,SUN Dafei,et al. Application of wavelet MFCC and HMM in low altitude acoustic target recognition[J]. Information and Electronic Engineering, 2011,9(6):744-748.)
- [2] 刘辉,杨俊安,许学忠. 基于 MFCC 参数和 HMM 的低空目标声识别方法研究[J]. 弹箭与制导学报, 2007,27(5):217-219. (LIU Hui,YANG Junan,XU Xuezhong. A Novel Low Altitude Passive Acoustic Target Identify Approach Research Based on MFCC and HMM[J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2007,27(5):217-219.)
- [3] 韩纪庆,张磊,郑铁然. 语音信号处理[M]. 北京:清华大学出版社, 2004. (HAN Jiqing,ZHANG Lei,ZHENG Tieran. Speech Signal Processing[M]. Beijing:Tsinghua University Press, 2004.)
- [4] 陆汝华,杨胜跃,朱颖,等. 基于 DHMM 的轴承故障音频诊断方法[J]. 计算机工程与应用, 2007,43(17):218-220. (LU Ruhua,YANG Shengyue,ZHU Ying,et al. DHMM-based acoustic fault diagnosis method for bearings[J]. Computer Engineering and Applications, 2007,43(17):218-220.)
- [5] 陆汝华,段盛,杨胜跃,等. 基于 CGHMM 的轴承故障音频信号诊断方法[J]. 计算机工程与应用, 2009,45(11):223-225. (LU Ruhua,DUAN Sheng,YANG Shengyue,et al. Continuous Gaussian mixture HMM based acoustic fault diagnosis scheme for bearings[J]. Computer Engineering and Applications, 2009,45(11):223-225.)
- [6] 陆汝华,樊晓平,杨胜跃,等. 基于音频信号的轴承故障诊断方法[J]. 电子技术应用, 2008,34(9):112-114,117. (LU Ruhua,FAN Xiaoping,YANG Shengyue,et al. A bearing fault diagnosis scheme based on acoustic signals[J]. Application of Electronic Technique, 2008,34(9):112-114,117.)
- [7] 谢锦辉,高雨青. 关于 HMM 相对可靠性量度[J]. 自动化学报, 1993,19(5):637-640. (XIE Jinhui,GAO Yuqing. On An HMM Relative Reliability Measure[J]. Acta Automatica Sinica, 1993,19(5):637-640.)
- [8] 路迎晨,李兵. 一个计算隐马氏模型相似度的改进方法[J]. 信息与电子工程, 2004,2(4):284-286. (LU Yingchen,LI Bing. An improved calculation method of the hmms similar degree[J]. Information and Electronic Engineering, 2004,2(4): 284-286.)

作者简介:



陆汝华(1980-),女,湖南省娄底市人,硕士,讲师,主要研究方向为智能信息处理、可视化技术.email:luruhua658520@163.com.

李盛欣(1981-),男,湖南省郴州市人,硕士,讲师,主要研究方向为 C 语言程序设计、网络计算.

(上接第 561 页)

作者简介:



孙蓓云(1966-),女,西安市人,高级工程师,博士,主要从事电磁脉冲技术方面的研究工作.email:sunbeiyun@126.com.

程引会(1967-),男,西安市人,高级工程师,博士,主要从事电磁脉冲数值模拟技术方面的研究工作.

聂鑫(1977-),男,吉林省吉林市人,副研究员,硕士,主要从事电磁脉冲测量技术方面的研究工作.

周辉(1961-),男,浙江省金华市人,研究员,主要从事电磁脉冲技术方面的研究工作.