

# 基于 DHMM 的轴承故障音频诊断方法

陆汝华<sup>1</sup>, 杨胜跃<sup>1</sup>, 朱颖<sup>2</sup>, 樊晓平<sup>1</sup>

LU Ru-hua<sup>1</sup>, YANG Sheng-yue<sup>1</sup>, ZHU Ying<sup>2</sup>, FAN Xiao-ping<sup>1</sup>

1.中南大学 信息科学与工程学院, 长沙 410083

2.上海大学 计算机学院, 上海 200072

1.School of Information Science & Engineering, Central South University, Changsha 410083, China

2.School of Computer Science, Shanghai University, Shanghai 200072, China

E-mail: luruhua658520@163.com

LU Ru-hua, YANG Sheng-yue, ZHU Ying, et al. DHMM-based acoustic fault diagnosis method for bearings. *Computer Engineering and Applications*, 2007, 43(17): 218-220.

**Abstract:** Acoustic signals emitted by bearing contain lots of important information about its operation status. Compared with vibration signals, acoustic signals can be collected with non-contact sensors, so as to be convenient and cheap. By abstracting the mel-frequency-cepstrum-coefficients (MFCC) from acoustic signals of engine bearing as the characteristic parameters, and using Hidden Markov Model (HMM) with the good performance of recognizing and anti-noise to analyze the operation status, this paper presents a new fault diagnosis method by acoustic signals based on HMM. In order to achieve diagnosis of bearing fault in real-time, this paper adopts discrete HMM (DHMM) with low computational complexity to fasten the speed of training and identifying. Experiments results prove that, with an average recognition rate for all bearing operating status of near 90% and recognition time of about 31ms, the presented method is effective and feasible and has a great prospect.

**Key words:** bearing; fault diagnosis; HMM; MFCC; acoustic signal

**摘要:** 轴承音频信号包含了大量的运行状态信息, 与振动信号相比, 音频信号的采集是非接触式的, 具有使用方便和成本低廉等优势。通过提取机械轴承音频信号的 Mel 频率倒谱系数 (MFCC) 特征参数, 并使用具有良好识别和抗噪性能的隐马尔可夫模型 (HMM) 分析轴承运行状态, 首次将 HMM 对音频信号的分析方法应用于故障诊断。为了能够实现轴承故障的实时诊断, 采用计算量较小的离散 HMM (DHMM) 模型加快训练和识别速度。实验结果表明, 该方法对轴承运行状态的识别正确率接近 90%, 识别时间约为 31 ms, 效果较好, 有效可行, 具有很好的应用前景。

**关键词:** 轴承; 故障诊断; 隐马尔可夫过程; Mel 频率倒谱系数; 音频信号

**文章编号:** 1002-8331(2007)17-0218-03 **文献标识码:** A **中图分类号:** TP391

## 1 引言

轴承运行状态直接影响整台机器的性能, 轴承故障诊断成了目前研究热点之一<sup>[1-7]</sup>, 但目前国内外还没有非常成熟、有效的诊断方法。根据所采用的状态量, 轴承故障诊断主要有温度法、油样分析法、振动信号法及音频信号法<sup>[2]</sup>。振动信号法通过安装在轴承座或箱体适当地方的加速度传感器测取轴承振动信号, 并对此振动信号进行分析与处理, 进而判断轴承是否工作正常。此方法的不足在于需要将加速度传感器固定在待检测的设备上, 增加成本, 使用不便。音频信号采集属于非接触式, 使用方便, 成本低廉, 具有振动信号分析法不可代替的优势。目前, 基于音频信号的轴承故障诊断方法主要有: 小波分析<sup>[3-4]</sup>、神经网络<sup>[5]</sup>和盲源分离<sup>[6]</sup>等。

隐马尔可夫模型 (Hidden Markov Model, HMM) 是一种用参数表示, 用于描述随机过程统计特性的概率模型, 其强大之处在于观察到的事件与内在的状态间建立了一种概率模型。HMM 建模方法具有良好的抗噪性能, 在交通监测系统<sup>[8]</sup>、图像识别<sup>[9]</sup>、语音识别<sup>[10-14]</sup>以及基于振动信号的故障诊断<sup>[11-15]</sup>等中都得到了较好的应用, 也是目前为止最有效的语音信号识别方法。Mel 频率倒谱系数 (Mel-Frequency Cepstrum Coefficients, MFCC) 特征参数考虑了人耳听觉特性, 能很好地反映音频信号特征, 在语音识别、音频分类和检索研究领域应用十分广泛<sup>[11]</sup>。本文通过提取轴承音频信号 MFCC 特征参数, 首次将 HMM 应用于轴承故障音频信号的建模与诊断研究。实验结果表明, 基于 HMM 建模的轴承故障诊断音频信号方法有效可行, 具有十

**基金项目:** 国家自然科学基金 (the National Natural Science Foundation of China under Grant No.69975003); 湖南省自然科学基金 (the Natural Science Foundation of Hunan Province of China under Grant No.06JJ50141); 上海市教委自然科学基金 (No.205457)。

**作者简介:** 陆汝华 (1980-), 女, 硕士研究生, 主要研究方向有智能信息处理, 虚拟现实; 杨胜跃, 博士, 副教授, 主要研究方向有智能信息处理, 学习控制等; 朱颖, 博士, 副教授, 主要研究方向有智能信息处理; 樊晓平, 博士, 教授, 博士生导师, 主要研究方向有智能信息处理, 智能控制, 智能交通系统。

分好的应用前景。

## 2 HMM 基本原理

HMM 是一个双重随机过程,一个描述状态的转移,另一个描述状态和观察值之间的统计对应关系。HMM 是一个双重随机过程的概率模型,一个用来描述状态的转移,另一个描述状态与观察序列间的关系。设观察值序列为  $O=\{O_1, O_2, \dots, O_T\}$ , 则一个隐 Markov 模型 HMM 可用如下基本元素描述<sup>[10,11]</sup>:

E1: Markov 模型中的状态数为  $N$ , 记为  $S=S_1, S_2, \dots, S_N$ 。

E2: 第  $t$  时刻 Markov 链所处的状态记为  $q_t, q_t \in (S_1, S_2, \dots, S_N)$ 。

E3: 每个状态对应的可能的观察值数目为  $M$ , 记为  $V_1, V_2, \dots, V_M$ 。

E4: 第  $t$  时刻观察到的观察值为  $O_t, O_t \in (V_1, V_2, \dots, V_M)$ 。

E5:  $\pi=\{\pi_i | 1 \leq i \leq N\}$  为初始概率分布,  $\pi_i$  表示 Markov 链从状态  $i$  开始的初始概率, 其中

$$\begin{cases} \pi_i = P(q_1 = S_i), 1 \leq i \leq N \\ \sum_{i=1}^N \pi_i = 1, \pi_i \geq 0 \end{cases} \quad (1)$$

E6:  $A=\{a_{ij} | 1 \leq i, j \leq N\}$  为状态转移概率矩阵,  $a_{ij}$  表示从状态  $i$  变化到状态  $j$  的转移概率, 其中

$$\begin{cases} a_{ij} = P(q_{t+1} = S_j / q_t = S_i), 1 \leq i, j \leq N \\ \sum_{j=1}^N a_{ij} = 1, a_{ij} \geq 0 \end{cases} \quad (2)$$

E7:  $B=\{b_{jk} | 1 \leq j \leq N, 1 \leq k \leq M\}$  为观察值概率矩阵,  $b_{jk}$  表示进入状态  $j$  时产生输出为  $V_k$  的概率, 根据  $B$  的不同, 将模型分为 CHMM(连续 HMM)和 DHMM(离散 HMM)。其中

$$\begin{cases} b_{jk} = P(O_t = V_k / q_t = S_j), 1 \leq j \leq N, 1 \leq k \leq M \\ \sum_{k=1}^M b_{jk} = 1, b_{jk} \geq 0 \end{cases} \quad (3)$$

这样, HMM 模型可以描述为:  $\lambda=(\pi, A, B)$ 。

HMM 模型训练是指根据已知观察值序列  $O=\{O_1, O_2, \dots, O_T\}$  和初始模型  $\lambda(\pi, A, B)$ , 以一定的规则逐步构成新的模型参数  $\bar{\lambda}$ , 使得  $P(O|\bar{\lambda}) > P(O|\lambda)$ , 反复修正模型参数, 直至  $P(O|\lambda)$  收敛, 最终得到一个优化模型。

Baum-Welch 算法是经典的 HMM 训练算法, 参数修正公式为<sup>[10]</sup>:

$$\begin{cases} \bar{\pi}_i = \frac{\alpha_i(i)\beta_1(i)}{P(O|\lambda)}, 1 \leq i \leq N \\ \bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \alpha_i(i)a_{ij}b_j(O_{t+1})\beta_{t+1}(j)/P(O|\lambda)}{\sum_{t=1}^{T-1} \alpha_i(i)\beta_t(i)/P(O|\lambda)}, 1 \leq i, j \leq N \\ \bar{b}_{jk} = \frac{\sum_{t=1}^T \alpha_i(j)\beta_t(j)/P(O|\lambda)}{\sum_{t=1}^T \alpha_i(j)\beta_t(j)/P(O|\lambda)}, 1 \leq j \leq N, 1 \leq k \leq M \end{cases} \quad (4)$$

其中  $\alpha_i(i)$  和  $\beta_i(i)$  可由模型  $\lambda=(\pi, A, B)$  推出, 分别表示前向概率变量和后向概率变量:

$$\begin{cases} \alpha_i(i) = P(O_1, O_2, \dots, O_t, q_t = S_i | \lambda) \quad 1 \leq t \leq T \quad 1 \leq i \leq N \\ \beta_i(i) = P(O_{t+1}, O_{t+2}, \dots, O_T / q_t = S_i, \lambda) \quad 1 \leq t \leq T \quad 1 \leq i \leq N \end{cases} \quad (5)$$

HMM 模式识别是待检测观察值序列  $O=\{O_1, O_2, \dots, O_T\}$  与训练好的 HMM 模型库中参数的匹配过程, 通常是求出观察序列  $O=\{O_1, O_2, \dots, O_T\}$  下各 HMM 模型输出概率  $P(O|\lambda)$ , 根据概率大小, 辅以必要的后处理, 最终得到识别结果。

## 3 轴承故障诊断系统

系统主要完成三个部分的功能: 特征参数提取、HMM 模型训练以及模式识别, 具体步骤如图 1 所示。




图 1 基于 HMM 的轴承故障音频诊断系统

### 3.1 特征参数提取

特征参数提取是指从轴承音频信号中提取有用的统计数据, 是故障建模与识别的关键, 特征参数选取直接影响到故障诊断效果。MFCC 充分利用人耳的听觉特性, 能很好的体现音频信号的主要信息, 在语音识别、音频分类和检索领域应用十分广泛<sup>[11]</sup>。本系统选用 MFCC 特征参数, 其计算过程如下<sup>[13]</sup>:

步骤 1 确定每一帧信号的长度  $N$  及帧移, 并对每一帧信号序列进行预处理(加窗、预加重等), 其目的是对采集过程或分帧等因素所造成的数据损失予以补偿, 更好地应用音频信号中的有用信息。本文采用应用较广的汉明窗:

$$\omega(n) = (1-\alpha) - \alpha \cos(2\pi n/N) \quad (6)$$

式中,  $0 < \alpha < 1$ , 通常取值为 0.46。

步骤 2 将预处理后的信号进行快速傅立叶变换(FFT), 将时域信号转换为频域信号, 再计算其模的平方得到能量谱  $P[k], 1 \leq k \leq N-1$ 。

步骤 3 选取滤波器个数为  $M$ , 并定义最低频率接近零, 最高频率为输入音频信号频率的一半, 再根据  $mel(f)$  频率与实际线性频率  $f$  的关系  $mel(f) = 2595 \lg(1 + f/700)$  计算出三角带通滤波器组  $H_m[k]$ 。则能量谱  $P[k]$  通过三角带通滤波器组  $H_m[k]$  后的输出为:

$$S[m] = \ln \left( \sum_{k=0}^{N-1} P[k] H_m[k] \right) \quad 0 \leq m \leq M-1 \quad (7)$$

步骤 4 对  $S[m]$  进行离散余弦变换(DCT)即得到 MFCC 系数

$$C[n] = \sum_{m=0}^{M-1} S[m] \cos(\pi n(m+0.5)/M) \quad 0 \leq n \leq M-1 \quad (8)$$

步骤 5 取  $C[1], C[2], \dots, C[V]$  作为 MFCC 参数, 此处  $V$  是 MFCC 参数的维数。

### 3.2 HMM 模型训练

HMM 模型训练的目的是从大量的音频信号样本中提取有关信息, 确定模型的初始概率矢量  $\pi$ 、状态转移矩阵  $A$  以及观察输出矩阵  $B$  等参数。训练之前, 首先对模型参数进行初始化设置。 $\pi$  和  $A$  在遵循归一化条件下随机化选取; 参数  $B$  对系统的影响非常大, 如果随机选取不当, 不仅会大幅度增加训练时间, 也会降低最后的识别正确率, 本文根据矢量量化的码本大小初始化  $B$ 。

典型 Baum-Welch 训练算法是在假定只有一个观察值训

练序列的条件下得到的,为了增加 HMM 故障诊断系统的稳健性和提高故障诊断的准确率,本文选取多个样本进行训练,以建立轴承各类故障状态的 HMM 参数模型。本文针对三类故障状态(内圈异音、外圈异音以及滚动体异音等),各选取若干样本进行训练,建立每种故障状态的 HMM 模型。记  $L$  个观察值序列(即个样本)为  $O^{(1)}, O^{(2)}, \dots, O^{(L)}$  每个观察值序列的长度记为  $T$ ,那么,  $O^{(l)} = \{O_1^l, O_2^l, \dots, O_T^l\}, l=1, 2, \dots, L$ 。

此时基于多观察值序列训练的重估公式可写为:

$$\begin{cases} \bar{\pi}_i = \sum_{l=1}^L \alpha_1^{(l)}(i) \beta_1^{(l)}(i) / P(O^{(l)} / \lambda), 1 \leq i \leq N \\ \bar{a}_{ij} = \frac{\sum_{l=1}^L \sum_{t=1}^{T-1} \alpha_t^{(l)}(i) a_{ij} b_j(O_{t+1}^{(l)}) \beta_{t+1}^{(l)}(j) / P(O^{(l)} / \lambda)}{\sum_{l=1}^L \sum_{t=1}^{T-1} \alpha_t^{(l)}(i) \beta_{t+1}^{(l)}(j) / P(O^{(l)} / \lambda)}, 1 \leq i, j \leq N \\ \bar{b}_{jk} = \frac{\sum_{l=1}^L \sum_{t=1}^T \alpha_t^{(l)}(j) \beta_t^{(l)}(j) / P(O^{(l)} / \lambda)}{\sum_{l=1}^L \sum_{t=1}^T \alpha_t^{(l)}(j) \beta_t^{(l)}(j) / P(O^{(l)} / \lambda)}, 1 \leq j \leq N, 1 \leq k \leq M \end{cases} \quad (9)$$

### 3.3 故障诊断

训练完成之后将模型参数存储,此时,系统就具备了诊断的能力。诊断过程中,输入待检测轴承音频信号,经过预处理、特征参数提取和矢量量化后,得到观察值序列。然后,快速有效地计算出观察值序列在各 HMM 模型下的输出概率,通常情况下,概率最大的模型即为识别结果。为了提高系统的识别率,可在后处理阶段辅以必要的拒识算法,比如设定适当的概率阈值,如果最大概率小于这个阈值,则诊断为其它运行状态。

## 4 实验结果

本文实验在 Visual C++ 7.0 平台下完成,诊断对象为 6202CM 深沟球滚动轴承;轴承转速为 1 800 rpm;采样频率为 22 050 Hz;A/D 转换精度 16 位;数据帧长 512,帧移 128;通过特征提取,将每帧信号都转换成 12 维 MFCC 的特征矢量,形成观察值序列。

对于各类轴承运行状态,分别选用 30 个样本用于训练。在模型训练过程中,状态数选为 7。其中,每一种轴承状态循环重估 50 次左右即可收敛,训练时间约为 133 141 ms。

另选 20 个数据用于识别,以检验系统诊断效果。对内圈故障、外圈故障、滚动体故障以及轴承的其它运行状态等 4 组数据分别进行了测试,其识别的具体情况如表 1。总的识别率接近 90%,识别时间约为 31 ms,结果较为理想。

表 1 识别结果

故障类型	训练样本数	内圈故障	外圈故障	滚动体故障	其它	正确率
内圈故障	20	20	0	0	0	100%
外圈故障	20	2	16	0	2	80%
滚动体故障	20	1	0	18	1	90%
其它状态	10	0	0	2	8	80%

## 5 结束语

本文通过提取轴承音频信号的 MFCC 特征参数,首次将基于音频信号的 HMM 方法应用于轴承故障诊断研究,有效利用了 HMM 对随机信号超强的建模能力,以及 MFCC 参数对音频信号所包含信息的描述能力。并采用离散化的 HMM 模型加快训练和识别速度,简化模型复杂度,取得了较好的识别效果。基于较高效率的 Visual C++ 软件平台,加快系统运行速度。实验结果表明,系统对各类故障的识别率均在 80% 以上,而且具有训练时间短和诊断速度快的优点,使故障诊断系统易于实时实现。由此可见,该轴承故障诊断方法有效可行,具有很好的应用前景。(收稿日期:2006 年 11 月)

### 参考文献:

- [1] 柳新民,邱静,刘冠军.基于连续高斯密度混合 HMM 的滚动轴承故障诊断研究[J].机械传动,2005,29(1):7-10.
- [2] 于群,齐富民,闻天苑,等.最新轴承设计与技术规范故障诊断实务全书[M].北京:当代中国音像出版社,2005.
- [3] 周艳玲,杨德斌,徐金梧,等.基于声信号的轴承故障诊断方法[J].振动与冲击,2002,21(2):21-23.
- [4] 张武军,徐金梧,杨德斌,等.声信号分析方法在轴承故障诊断中的应用[J].北京科技大学学报,2002,24(1):58-60.
- [5] 李良敏.基于遗传算法的盲源分离在轴承诊断中的应用[J].轴承,2005(9):31-34.
- [6] Hasan OCAK, Kenneth A LOPARO. A new bearing fault detection and diagnosis scheme based on hidden markov modeling of vibration signals[C]//IEEE International Conference on Acoustics, Speech, and Signal Processing, 2001, 5: 3141-3144.
- [7] 高向东,黄石生,高存臣.神经网络及声谱分析技术在轴承故障诊断中的应用[J].轴承,1996(8):2-5.
- [8] Jien K, Watanabe T, Rittscher J, et al. An HMM-based segmentation method for traffic monitoring movies[J]. IEEE Trans on Pattern Analysis and Machine Intel, 2002, 24(9): 1291-1296.
- [9] Liu Nian-jun, Davis R I A, Lovell B C, et al. Effect of Initial HMM choices in multiple sequence training for gesture recognition[C]//International Conference on Information Technology, 5-7 April 2004: 608-613.
- [10] 谢锦辉.隐 Markov 模型(HMM)及其在语音处理中的应用[M].武汉:华中理工大学出版社,1995.
- [11] 赵力.语音信号处理[M].北京:机械工业出版社,2003.
- [12] Rabiner L R. A tutorial on hidden markov models and selected applications in speech recognition[J]. Proceedings of the IEEE, 1989, 77(2): 257-286.
- [13] Huang Hai-dong. Spoken Language Processing[M]. Beijing: Prentice Hall, 2001.
- [14] Yin Pei, Essa I, Reh J M. Asymmetrically boosted HMM for speech reading[C]//IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004, 2.
- [15] Atlas L, Ostendorf M, Bernard G D. Hidden Markov models for monitoring machining tool-wear[C]//IEEE, IC-ASSP 2000, 2000, 6: 3887-3890.