

基于离散余弦变换特征和隐马尔科夫模型的 铜熔炼过程烟雾分级

张宏伟^{1,3*}, 张凌婕¹, 袁小锋², 宋执环³

¹西安工程大学电子信息学院, 陕西 西安 710048;

²中南大学信息科学与工程学院, 湖南 长沙 410083;

³浙江大学控制科学与工程学院, 浙江 杭州 310027

摘要 为实现铜熔炼过程除尘风机转速的自动调节,提出了基于图像分析技术的烟雾浓度分级方法。通过采样窗对烟雾图像从上至下进行采样,形成时间序列,对每个采样子图进行离散余弦变换(DCT)特征提取,提取的系数视作该时刻隐马尔科夫模型(HMM)隐含状态产生的的观测值,一幅图像则分割成一个完整的HMM序列。通过对4种工况分别建立HMM,每种工况各用30幅图像训练估计模型参数,再对待测烟雾样本图像进行分类。实验结果表明,采用HMM分类的准确率最高可达95%,优于最小二乘支持向量机(LSSVM)的识别效果。

关键词 图像处理; 铜熔炼; 图像分析; 离散余弦变换(DCT); 隐马尔科夫模型(HMM); 烟雾分级

中图分类号 TB8; TF3

文献标识码 A

doi: 10.3788/LOP55.121504

Smoke Classification in Copper Smelting Process Based on Discrete Cosine Transform Features and Hidden Markov Model

Zhang Hongwei^{1,3*}, Zhang Lingjie¹, Yuan Xiaofeng², Song Zhihuan³

¹College of Electronics and Information, Xi'an Polytechnic University, Xi'an, Shaanxi 710048, China;

²School of Information Science and Engineering, Central South University, Changsha, Hunan 410083, China;

³Department of Control Science and Engineering, Zhejiang University, Hangzhou, Zhejiang 310027, China

Abstract A smoke concentration grading method based on the image analysis technique is proposed for the automatic speed adjustment of the dust removal fan in the copper smelting process. We obtain a sequence of sub images by using a moving window to slide over the whole smoke image from top to bottom. Then, discrete cosine transform (DCT) is utilized to extract the features of each sub-image and the DCT coefficients are vectorized as the observation data for hidden Markov model (HMM). Thus an image is divided into an observed sequence to build the HMM model for grade classification. Four different running states are considered in the smelting process, in which a HMM model is built for each running state. For each running state, 30 images are used for the training of HMM model. The results show that the classification accuracy can reach 95% with HMM, which is higher than that of least squares support vector machine (LSSVM).

Key words image processing; copper smelting process; image analysis; discrete cosine transform (DCT); hidden Markov model (HMM); smoke classification

OCIS codes 150.5495; 150.1135

1 引言

废杂铜金属熔炼是工业过程中铜金属循环再利用的重要环节,工频熔炼炉熔炼废杂铜是低品质废

杂铜熔炼过程的主要工艺。由于有机物等杂质的燃烧,废杂铜在熔炼过程中会产生大量烟雾废气。为了防止这些烟雾废气排放到空气中污染环境,通常利用顶部配有引风机的炉膛将烟气抽入除尘袋。在

收稿日期: 2018-04-20; 修回日期: 2018-05-25; 录用日期: 2018-07-12

基金项目: 国家自然科学基金面上项目(61573308)、陕西省科技厅自然科学基金(2014JQ-5026)

* E-mail: zhanghongwei@zju.edu.cn

废杂铜熔炼的不同阶段,炉膛内的烟雾浓度差异较大。为了节约能源和降低生产成本,引风机的转速应该根据炉膛内的烟雾浓度进行相应调整,即当烟雾浓度较高时,增大引风机转速,以有效收集熔炼烟雾;当烟雾浓度较低时,应减小引风机转速,以减小引风机的能耗和熔炼过程加热能量的损耗。而由于炉膛温度高等原因,现有仪器难以实现烟雾浓度的在线实时检测。目前,在废杂铜熔炼过程中,引风机调速的工作主要由操作工人根据操作经验目测烟雾浓度,进而手动调整引风机的转速^[1]。为了降低能耗和操作控制的工作强度,本文提出了一种基于图像分析技术的烟雾浓度在线检测分级方法,用于实现引风机速度的自动控制。

基于图像分析的自动化检测技术被广泛应用于食品质量检测^[2-3]、纺织面料检测^[4-5]、金属检测^[6-8]、医疗诊断^[9-10]和卫星遥感^[11]等领域,但是在废杂铜熔炼行业中的应用较少^[1]。一般而言,图像分析包含图像的获取、预处理、特征提取和建模识别等部分。在农业生产中,图像分析技术常被用于对农产品进行分类和测量,如进行水果质量等级评估^[12];在工业应用中,图像检测技术常被用于无损检测^[13]和软测量^[8-14]。利用图像分析技术对烟雾浓度检测方面的研究主要围绕火灾烟雾的检测,冶金过程烟雾检测的研究鲜有报道。有研究者通过图像检测烟雾时序性的光烟流模式进行火灾报警和排除险情^[15],还有研究者提出了基于图像分析和隐马尔科夫模型(HMM)的在线燃烧烟雾系统的监控。对于废杂铜熔炼过程的烟雾检测,曾有研究者提出了基于背景模糊度特征和最小二乘支持向量机(LSSVM)模型的熔炼过程烟雾分级和引风机控制算法,这些前期工作作为熔炼过程中烟雾分级的图像序列化分析和分类提供了研究思路。

在烟雾检测分析系统中,有效的图像特征和分类建模方法是决定模型性能的关键因素。目前,已有很多图像的特征提取方法,如主成分分析^[16]、小波分析^[17]和频域变换^[18]等。离散余弦变换(DCT)是一种与傅里叶变换相关的变换,它具有很强的能量集中特性,即能量集中在DCT的低频部分,且当信号具有接近马尔科夫过程的统计特性时,DCT的去相关性接近于Karhunen-Loeve(KL)变换^[19-20]。因此,DCT常用于语音和图像特征的提取。采用DCT提取烟雾图像特征,可以充分利用烟雾图像的有效信息,以便后续建立高效的分类模型。在图像检测中,另一个重要步骤是在提取的烟雾图像特征

的基础上,建立可靠有效的分类模型。在众多的分类方法中,HMM因其提供了一种描述复杂动态关联现象的可能机制和良好的扩容性而备受青睐,已在语音信号识别、人脸识别、生物结构识别和行为分析等领域取得了重大成果。本文将同一种工况下的烟雾图像视为同一个HMM,每一幅图像采用移动窗从上至下进行序列化采样,得到了子图像序列。利用DCT对序列子图像进行特征提取,将每一幅熔炼烟雾图像转化为一个HMM样本序列。利用训练样本对模型参数进行训练,实现了对烟雾图像的等级分类,可为引风机速度的自动控制提供准确的反馈。

2 DCT 和 HMM

2.1 DCT

DCT具有良好的能量集中特性,是一种能够减少空间冗余和压缩能量的信号变换方法。常见的信号处理采用一维DCT,但其常被扩展为二维DCT,用于处理像图像这种二维信号。

对于一幅大小为 $M \times N$ 的图像矩阵 $f(x, y)$,其DCT定义式^[21]为

$$C(u, v) = a(u)a(v) \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \cdot \cos \frac{(2x-1)u\pi}{2M} \cos \frac{(2y-1)v\pi}{2N}, \quad (1)$$

式中: $C(u, v)$ 为矩阵 $f(x, y)$ 的DCT系数,其中参数 u 和 v 的取值范围分别为 $u=0, 1, \dots, M-1, v=0, 1, \dots, N-1$;系数 $a(u)$ 、 $a(v)$ 分别定义为

$$a(u) = \begin{cases} \sqrt{1/M}, & u=0 \\ \sqrt{2/M}, & u=1, 2, \dots, M-1 \end{cases}, \quad (2)$$

$$a(v) = \begin{cases} \sqrt{1/N}, & v=0 \\ \sqrt{2/N}, & v=1, 2, \dots, N-1 \end{cases}. \quad (3)$$

经过上述二维DCT后,原二维图像的像素矩阵转变成由二维DCT系数构成的相同大小的系数矩阵。在该矩阵中,低频系数集中在矩阵的左上角,反映了图像的整体特性;高频系数集中在图像矩阵的右下角,反映了图像的局部特性。由定义可知,二维DCT与离散傅里叶变换(DFT)相近,但二维DCT的变换核为实数的余弦函数,不涉及复数计算。因此,DCT的计算速度比变换核为复指数的DFT快,能够极大地提高高维图像数据压缩的速度。由此可知,二维DCT作为图像特征提取的方法,具有以下几个优点:1)大多数二维DCT的系数

较小,只有极少数大系数集中在低频分量中,具有能量集中的特性;2)二维DCT的特征系数对图像的旋转、噪声及光照等因素较不敏感,因而能够有效减小环境干扰等对烟雾图像带来的不利影响;3)二维DCT特征系数的低频部分能够较好地描述图像的整体变化特征,而其高频部分又可以反映不同阶段图像的局部特征;4)二维DCT特征提取能够有效避免烟雾图像像素点直接建模带来的计算量大、计算时间长和算法不稳定等问题,可大大降低建模数

据的维度,提高建模速度和准确性。

2.2 HMM

HMM是图像识别领域的重要方法之一,是马尔科夫过程的进一步发展。马尔科夫过程描述的是一个总随机过程中一系列状态之间的不断转移,可用图1(a)所示的框图表示,时刻 t 的状态用 Q_t 表示。HMM的状态 Q_t 是隐藏的,不可直接观测,能观测的是这些隐含状态所表现出来的观测向量 O_t ,如图1(b)所示,其中 T 为时间序列的总时间长度。




图1 框图。(a)马尔科夫过程;(b)隐马尔科夫过程

Fig. 1 Block diagram. (a) Markov process; (b) hidden Markov process

一个离散HMM可以用以下参数^[22-23]进行定义。

1) 状态集 $S = \{S_1, S_2, \dots, S_N\}$,即模型在任意时刻 t 的隐含状态 Q_t 的所有取值的集合,整个模型共有 N 个不同的取值状态。

2) 观测集 $V = \{V_1, V_2, \dots, V_M\}$,即模型在任意时刻 t 的观测值 O_t 的所有取值的集合,整个模型共 M 个不同的取值观测符号。

3) 状态转移矩阵 $A = \{a_{ij} = a(S_i \rightarrow S_j)\}$,其为 $N \times N$ 矩阵。矩阵元素 a_{ij} 定义为从状态 S_i 转移到状态 S_j 的概率值,即

$$a_{ij} = a(S_i \rightarrow S_j) = \Pr\{Q_{t+1} = S_j \mid Q_t = S_i\}, \quad 1 \leq i, j \leq N, \quad (4)$$

式中: \Pr 为概率求解函数,且有 $a_{ij} \geq 0, \sum_{j=1}^M a_{ij} = 1$ 。

4) 观测概率矩阵 $B = \{b_{ik} = b(V_k \mid S_i)\}$,其为 $N \times M$ 矩阵,矩阵元素 b_{ik} 表示在状态 S_i 下观测到观测符号 V_k 的概率值,即

$$b_{ik} = b(V_k \mid S_i) = \Pr\{O_t = V_k \mid Q_t = S_i\}, \quad 1 \leq i \leq N, 1 \leq k \leq M, \quad (5)$$

且有 $b_{ik} = b(V_k \mid S_i) \geq 0, \sum_{k=1}^M b_{ik} = 1$ 。

5) 初始状态概率分布 $\Pi = \{\sigma(S_i)\}$,它表示在时刻 $t=1$ 时处于各个状态值的概率大小,即

$$\sigma(S_i) = \Pr\{Q_1 = S_i\}, 1 \leq i \leq N, \quad (6)$$

且有 $\sigma(S_i) \geq 0, \sum_{i=1}^N \sigma(S_i) = 1$ 。

一般地,可用 $\lambda = (S, V, A, B, \Pi)$ 来简洁地表示一个HMM。实际中,利用HMM时常需解决如下三个基本问题。

1) 给定观测序列 $O = O_1 O_2 \dots O_T$ 和模型参数 $\lambda = (S, V, A, B, \Pi)$,计算由模型产生该观测序列的概率,即 $\Pr(O \mid \lambda)$ 。该问题一般采用前向-后向算法进行求解。

2) 给定观测序列 $O = O_1 O_2 \dots O_T$ 和模型参数,选择在某种意义下产生该序列的最优状态序列 $O = O_1 O_2 \dots O_T$ 。该问题一般用Viterbi算法求解。

3) 给定一系列观测序列 $O = O_1 O_2 \dots O_T$,估计HMM的参数 $\lambda = (S, V, A, B, \Pi)$ 。该问题一般采用期望最大算法进行求解。

在许多实际应用中,集合 V 不是离散值集合,而是连续值集合。此时,对于由状态 S_i 产生的观测值 $O \in V (V = \mathbf{R} \text{ or } \mathbf{R}^d)$ (\mathbf{R}^d 为 d 维多变量实数集合),可将其视为状态 S_i 下对应概率密度函数为 $b(O \mid S_i)$ 产生的随机观测值。常见的方法是将 $b(O \mid S_i)$ 看成高斯混合模型,即

$$b(O \mid S_i) = \sum_{j=1}^{M_i} c_{ij} N(O \mid \theta_{ij}), \quad (7)$$

式中: c_{ij} 为第 i 个状态下 j 个高斯成分的权重; $N(O \mid \theta_{ij})$ 为高斯分布函数,其中 θ_{ij} 为高斯分布的参数。

烟雾图像识别是将待识别的烟雾图像与标准库中的图像进行对比识别的过程,其训练和测试过程与DCT的经典实验极为类似,主要区别在于观测序列的求法不同。因此,利用DCT的思想,可将同一工况下的烟雾图像作为一个HMM,提取图像序列的特征作为模型的观测值,通过解决DCT的三个基本问题,设计出烟雾图像分类模型的训练和识别算法。

3 熔融工艺分析

废杂铜熔炼过程主要分为加料和搅拌、熔融、化验出炉等工序。在各个工况下,炉膛内均会产生相应的烟雾,为了防止烟雾排放到空气中,需要用引风机将烟雾抽入吸尘袋。同时,由于在不同工况下,炉膛内产生的烟雾浓度不同,为了最大限度地减少能源浪费,需要根据炉内烟气浓度等级调整相应的引风机转速。

在加料和搅拌过程中,由于原料中有机物等易燃物的剧烈燃烧,炉膛内会产生大量浓烟和高亮度的火焰,此时引风机需要运行在最高速度状态,将黑烟抽走,防止其排入空气污染环境。图2所示为加料和搅拌过程中典型的炉内烟雾图像。可以看出,此时炉膛内烟雾图像亮度较高,同时,由于烟雾的影响,图像背景会较大程度地被模糊化。

在加料搅拌一段时间后,随着有机物等易燃物的大量燃烧,炉内出现较平稳熔融过程,此时炉膛内仍保持较高的亮度,仍有较多烟雾,但其浓度比之前有所减小,此时引风机速度应降低一级。图3所示为平稳熔融过程中炉膛内的烟雾图像。

在熔炼后期,整个炉膛内趋于稳定状态,烟雾浓度再次减小,此时引风机速度较之前的状态应再降低一级。图4所示为典型的熔融后期的炉膛内烟雾图像。




图2 加料及搅拌过程的烟雾。(a)加料时的烟雾;(b)搅拌时的烟雾

Fig. 2 Smoke in the feeding and stirring process. (a) Smoke in feeding stage; (b) smoke in stirring stage




图3 平稳熔融过程的烟雾。(a)烟雾1;(b)烟雾2

Fig. 3 Smoke in the smooth melting process. (a) Smoke 1; (b) smoke 2




图4 熔融后期的烟雾。(a)烟雾1;(b)烟雾2

Fig. 4 Smoke in the last stage of smelting process. (a) Smoke 1; (b) smoke 2

在化验和出炉阶段,炉膛的炉况很平静,所产生的烟雾基本为零,此时引风机速度减小为最低



档即可。图 5 所示为化验出炉阶段的炉膛内烟雾状况。



图 5 化验与出炉阶段的烟雾。(a)化验时的烟雾;(b)出炉时的烟雾

Fig. 5 Smoke in the component analysis and release stage. (a) Smoke in analysis stage; (b) smoke in release stage

4 烟雾图像分级建模

在烟雾图像的建模过程中,熔融过程大致可分为 4 个主要工况,每个工况分别对应一个 HMM。烟雾图像的分级建模预测需经过图像采样时序化、DCT 特征提取、HMM 训练及 HMM 分类预测等步骤。

4.1 图像采样时序化

对于某种工况下的炉膛内烟雾图像,可以视其为该工况对应的 HMM 的一个样本,为了实现样本图像与 HMM 时间序列的对应,采用以下技术对图

像进行采样。

如图 6 所示,对于大小为 $W \times H$ 的熔炼烟雾图像,采用 $W \times P$ 大小的移动窗从上到下进行采样,两个相邻采样窗之间的重叠部分高度为 L 。每个采样窗作为 HMM 时间序列的一个时间点,则第一个采样窗对应为 HMM 过程的时刻 $t=1$,并将衍生出 Q_1 和 O_1 。依次往下,第 t 个采样窗对应 HMM 过程的时刻,并将衍生出 Q_t 和 O_t ,时间序列的总时间长度 T 为

$$T = \frac{H - L}{L - P} + 1. \quad (8)$$




图 6 时序化图像采样

Fig. 6 Sequential image sampling

4.2 DCT 特征提取

通过图像采样时序化,每幅图像共得到 T 个采样图,即 T 个时刻点。对于每个时刻点,需要得到该时刻的观测向量。因此,分别对各个时刻的采样子图进行二维 DCT 转化,得到与采样子图像素矩阵大小相等的系数矩阵。对 DCT 系数矩阵进行锯齿形排序,选取排序后的前若干个系数作为该采样时刻的观测向量 O_t ,选取的系数个数决定了观测向量的维度。对从上到下的采样子图进行同样操作,得到该 HMM 的样本图的一个观测序列 $O = O_1 O_2 \cdots O_T$ 。

4.3 HMM 训练

每一个工况对应的 HMM,均需要通过其对应的训练样本来估计参数。假设该模型共有 L' 幅样本图像,则通过前述步骤可以对每幅图像进行采样时序化和 DCT 特征提取,得到含有 L' 个观测序列的样本集 $\vartheta = \{O^l\}$,其中 $l=1,2,\dots,L'$,且 O^l 代表第 l 幅样本图像经过时序化和 DCT 特征提取后得到的观测序列,即 $O = O_1 O_2 \cdots O_T$ 。利用样本集估计 HMM 参数的基本步骤为:

1) 确定模型拓扑结构,如模型的状态数、允许的状态转移矩阵等;

2) 模型参数初始化;

4) 保存模型参数。

3) 采用 Baum-Welch 算法对参数进行重新估计,迭代调整模型参数,直至满足收敛条件;

图 7 所示为基于 DCT 特征提取和 HMM 分类建模框架的基本流程图。

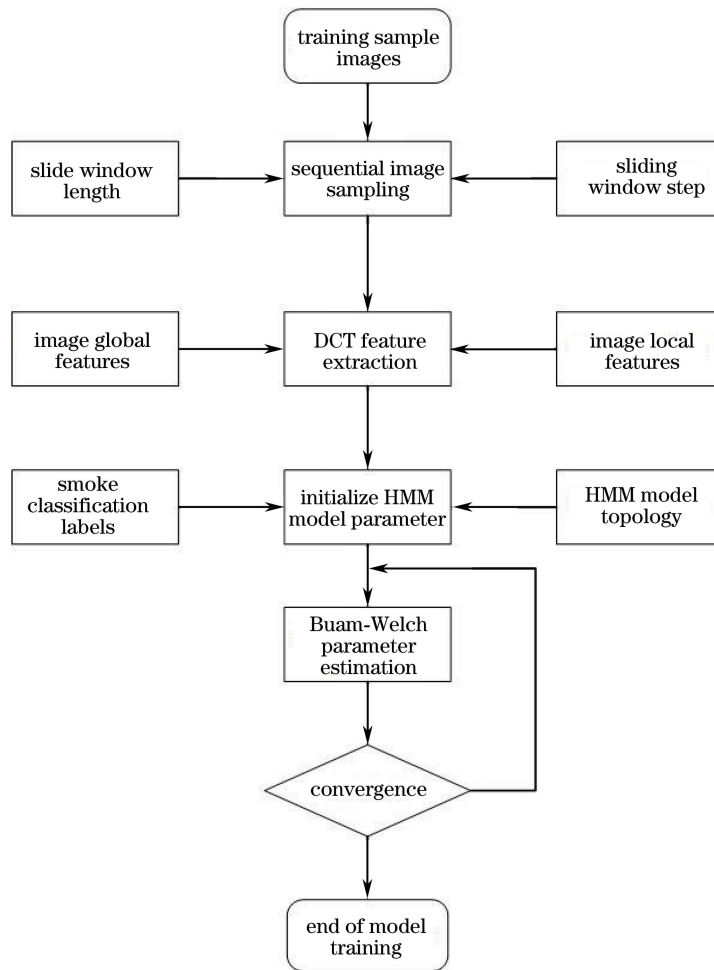


图 7 HMM 训练过程

Fig. 7 HMM training process

4.4 HMM 分类预测

对各个工况分别建模,并利用样本训练 HMM 参数,则可以对炉膛内的烟雾图像进行分级预测。基本方法是先对烟雾图像进行采样时序化,进而提取 DCT 特征形成观测序列,分别求取各个 HMM 下产生该观测序列的概率值,其中使得该观测序列概率值最大的对应模型类别即为该图像样本所属的等级类别。图 8 所示为 HMM 烟雾图像分类预测的基本流程。

5 实验结果及讨论

实验中铜熔炼过程的 4 个工况分别采用 30 幅图像训练和估计 HMM 参数,每个工况各选择 30 幅图像用于测试模型的分类准确性。各个 HMM 采用左右型 HMM 拓扑结构。由于 DCT 模型获取

的特征观测序列为连续变量值,HMM 类别选为连续型,即各个状态产生的观测值的概率分布为混合高斯密度函数。每个状态包含多个高斯成分的 HMM 和包含多个状态但每个状态仅包含单高斯成分的 HMM 在似然函数上是等价的,在实验中考虑 HMM 的各个状态产生的观测值均为单高斯分布。因此,选择合适的 HMM 状态数,是模型分类准确性的关键。为了选择最优状态数,取状态数 $N' = 2 \sim 10$ 分别训练 HMM,并将训练好的模型对 120 个测试样本进行分类估计,计算样本的识别正确率。当 HMM 状态数分别从 2 取到 10 时,在测试样本上的识别正确率如图 9 所示。可以看出,当转态数增大时,HMM 对烟雾图像的分类准确性整体上呈先提高后降低的趋势。当状态数为 2 时,烟雾图像的分类准确性最低。此时,简单的 HMM 无法准确

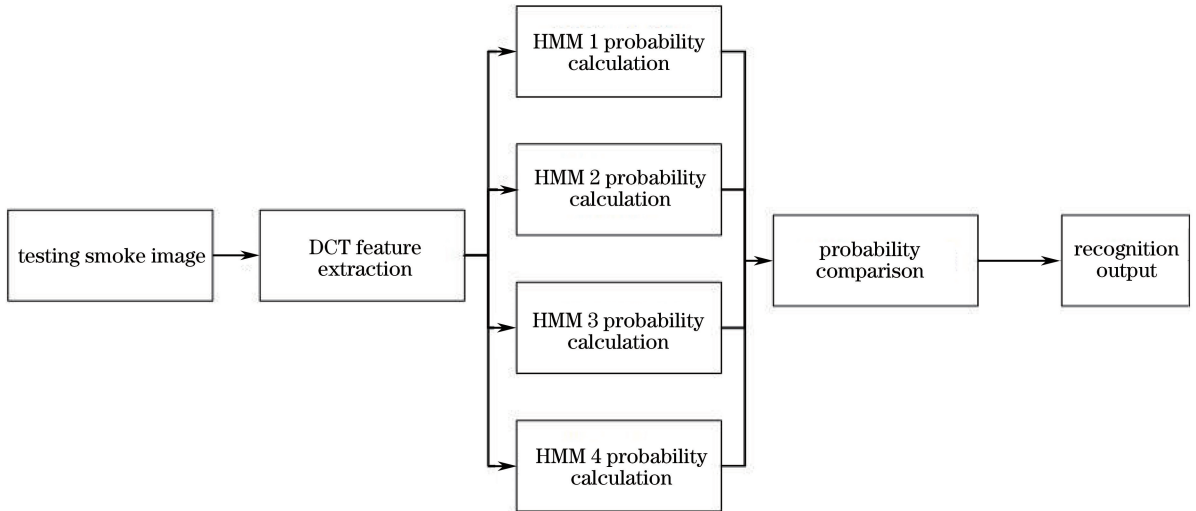


图 8 HMM 烟雾图像分类预测流程

Fig. 8 Flow of smoke image classification prediction using HMM

描述复杂的烟雾图像特征序列,图像的正确识别率只有 87.5%。当状态数增大至 3 时,HMM 对复杂烟雾图像的建模能力更优,其对烟雾等级分类的准确性可显著提高到 93.3%。当 HMM 状态数增大至 4 时,该模型对烟雾图像特征序列的描述能力达到最优。此后,模型的分类性能随着状态数的增大而有所降低。故当状态数选择为 4 时,模型的分类准确率最高。

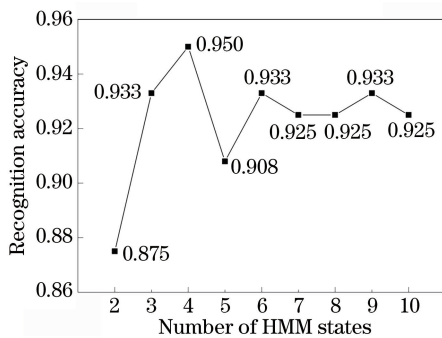


图 9 HMM 不同状态数的识别率

Fig. 9 Recognition accuracy comparison for different HMM states

为了验证模型的有效性,在相同训练样本和测试样本的条件下,采用 LSSVM 对烟雾图像进行分类建模,各个模型对烟雾图像的识别正确率如表 1 所示。

可以看出,基于 HMM 的熔炼烟雾分级方法的熔炼烟雾分级识别准确率显著优于 LSSVM。这是因为基于 LSSVM 的烟雾图像分级方法关注的是烟雾图像的整体特征,只对烟雾图像的整体特征进行训练和分类,无法对烟雾的局部特征进行描述,故其

分类准确性较差。基于 DCT 特征提取和 HMM 的烟雾图像分级方法对图像采样时序化,通过滑动窗口操作对图像进行序列化子图像,得到各个子窗口图像的二维 DCT 系数矩阵特征,充分利用了烟雾图像的整体和局部块信息,烟雾图像的描述更加精准。因此,在熔炼烟雾图像的分级实验中,基于 HMM 方法的分类效果显著优于 LSSVM。

从 HMM 自身来看,不同状态数 N' 对观测向量的描述也是不同的。当状态数目 N' 过少时,数据的拟合不充分,模型的识别率相对较小;当状态数 N' 过多时,会出现对数据的过拟合,识别率不同程度地减小。从实验结果看,采用不同状态数的 HMM 对熔炼烟雾图像的分级准确率整体较好,除了状态数为 2 时识别准确率小于 90%,其余 8 个状态数的 HMM 识别准确率都在 90% 以上。当状态数 N' 为 4 时,模型的识别率取得实验的最优值,达

表 1 不同模型识别正确率比较

Table 1 Recognition accuracy comparison for different models

Model	N'	Recognition accuracy / %
HMM	2	87.5
	3	93.3
	4	95.0
	5	90.8
	6	93.3
	7	92.5
	8	92.5
	9	93.3
	10	92.5
	LSSVM	

到 95%。通过上述实验分析,验证了所提基于 DCT 特征提取和 HMM 的烟雾图像分级算法的有效性和可靠性,为废杂铜熔炼过程烟雾检测提供了一种可行的图像分析方法。

6 结 论

针对目前铜熔炼过程除尘风机的烟雾控制中存在的能源浪费和人工操作劳动强度大等问题,研究了基于 DCT 特征提取的图像处理技术和融合 HMM 的烟雾自动分级方法,实现了废杂铜熔炼过程烟雾分级的高准确率检测。实验结果表明,DCT 图像特征和 HMM 在废杂铜熔炼过程烟雾自动分级建模中取得了较好的效果,对风机转速节能控制具有一定的工程应用价值。

参 考 文 献

- [1] Zhang H, Ge Z, Ye L, *et al.* Vision-based fan speed control system in the copper scraps smelting process [J]. *Asian Journal of Control*, 2014, 17(5): 1742-1755.
- [2] Russ J C. Image analysis of foods [J]. *Journal of Food Science*, 2015, 80(9): E1974-E1987.
- [3] Qin J W, Chao K L, Kim M S, *et al.* Hyperspectral and multispectral imaging for evaluating food safety and quality [J]. *Journal of Food Engineering*, 2013, 118(2): 157-171.
- [4] Jing J F, Liu S M, Li P F, *et al.* The fabric defect detection based on CIE $L^* a^* b^*$ color space using 2-D Gabor filter [J]. *The Journal of the Textile Institute*, 2016, 107(10): 1305-1313.
- [5] Schneider D, Holtermann T, Merhof D. A traverse inspection system for high precision visual on-loom fabric defect detection [J]. *Machine Vision and Applications*, 2014, 25(6): 1585-1599.
- [6] Lei N, Soshi M. Vision-based system for chatter identification and process optimization in high-speed milling [J]. *International Journal of Advanced Manufacturing Technology*, 2017, 89: 2757-2769.
- [7] Li X Q, Wang L H, Cai N X. Machine-vision-based surface finish inspection for cutting tool replacement in production [J]. *International Journal of Production Research*, 2004, 42(11): 2279-2287.
- [8] Zhang H W, Ge Z Q, Yuan X F, *et al.* Rapid vision-based system for secondary copper content estimation [J]. *Transactions of Nonferrous Metals Society of China*, 2014, 24(8): 2665-2676.
- [9] Huang H, Hu X T, Zhao Y, *et al.* Modeling task

- fMRI data via deep convolutional autoencoder [J]. *IEEE Transactions on Medical Imaging*, 2018, 37(7): 1551-1561.
- [10] Wang S K, Pan J X, Chen P. Adaptive segmentation algorithm for CT image sequence based on structure continuity as prior information [J]. *Laser & Optoelectronics Progress*, 2016, 53(11): 111006.
王苏恺, 潘晋孝, 陈平. 基于结构连续先验的 CT 图像序列自适应分割算法 [J]. *激光与光电子学进展*, 2016, 53(11): 111006.
- [11] Blaschke T. Object based image analysis for remote sensing [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2010, 65(1): 2-16.
- [12] Lorente D, Aleixos N, Gómez-Sanchis J, *et al.* Recent advances and applications of hyperspectral imaging for fruit and vegetable quality assessment [J]. *Food and Bioprocess Technology*, 2012, 5(4): 1121-1142.
- [13] Zhu B F, Chen W J, Li W S. Liquid crystal display defect detection based on Fourier-Mellin transform [J]. *Laser & Optoelectronics Progress*, 2017, 54(12): 121502.
朱炳斐, 陈文建, 李武森. 基于 Fourier-Mellin 变换的液晶显示屏显示缺陷检测 [J]. *激光与光电子学进展*, 2017, 54(12): 121502.
- [14] Kim C W, Kim H G, Suk H G. A study on the composition determination of Cu alloys by image processing technology [J]. *Solid State Phenomena*, 2006, 116/117: 795-798.
- [15] Appana D K, Islam R, Khan S A, *et al.* A video-based smoke detection using smoke flow pattern and spatial-temporal energy analyses for alarm systems [J]. *Information Sciences*, 2017, 418: 91-101.
- [16] Mredhula L, Dorairangaswamy M A. Image denoising using principal component analysis (PCA) and pixel surge model (PSM) [J]. *International Journal of Signal and Imaging Systems Engineering*, 2016, 9(4/5): 311-319.
- [17] Naidu V P S, Raol J R. Pixel-level image fusion using wavelets and principal component analysis [J]. *Defence Science Journal*, 2008, 58(3): 338-352.
- [18] Hanbay K, Talu M F, Ozguven O F. Real time fabric defect detection by using Fourier transform [J]. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 2017, 32(1): 151-158.
- [19] Lin Z C, He J F, Tang X O, *et al.* Fast, automatic and fine-grained tampered JPEG image detection via

- DCT coefficient analysis [J]. *Pattern Recognition*, 2009, 42(11): 2492-2501.
- [20] Hernandez J R, Amado M, Perez-Gonzalez F. DCT-domain watermarking techniques for still images: detector performance analysis and a new structure [J]. *IEEE Transactions on Image Processing*, 2000, 9(1): 55-68.
- [21] Yin H T, Fu P, Sha X J. Face recognition based on DCT and LDA [J]. *Acta Electronica Sinica*, 2009, 37(10): 2211-2214.
尹洪涛, 付平, 沙学军. 基于 DCT 和线性判别分析的人脸识别 [J]. *电子学报*, 2009, 37(10): 2211-2214.
- [22] Bicego M, Murino V, Figueiredo M A T. A sequential pruning strategy for the selection of the number of states in hidden Markov models [J]. *Pattern Recognition Letters*, 2003, 24: 1395-1407.
- [23] Lu B, Gu S H. Object tracking algorithm based on hidden Markov model and block feature matching [J]. *Laser & Optoelectronics Progress*, 2017, 54(9): 091006.
陆兵, 顾苏杭. 基于隐马尔可夫模型和分块特征匹配的目标跟踪算法 [J]. *激光与光电子学进展*, 2017, 54(9): 091006.