

一种基于 Parzen 窗估计的鲁棒 ELM 烧结温度检测方法

陈华^{1,2} 章兢^{1,2} 张小刚² 胡义函²

摘要 在回转窑燃煤火焰视频模糊且干扰较大的情况下, 基于火焰辐射能量和燃烧稳定程度提取多帧煤粉燃烧图像的统计特征进行烧结温度判断. 为克服工业现场特征数据中的粗差干扰, 将极限学习机 (Extreme learning machine, ELM) 与稳健估计理论相结合, 用训练误差分布的 Parzen 窗非参数估计构造 ELM 权矩阵, 对其输出层权值进行稳健最小二乘估计. 基于上述火焰视频的统计特征, 用该改进的鲁棒极限学习机 (Robust-ELM) 检测烧结带温度. 实验结果表明, 在视频图像模糊、不能用常规静态图像处理方法软测量烧结带温度时, 本文方法可快速有效地检测窑内烧结温度, 且检测系统不易受现场干扰, 稳定性强.

关键词 煤粉燃烧, 火焰图像, 鲁棒极限学习机, 烧结温度, Parzen 窗估计

引用格式 陈华, 章兢, 张小刚, 胡义函. 一种基于 Parzen 窗估计的鲁棒 ELM 烧结温度检测方法. 自动化学报, 2012, 38(5): 841–849

DOI 10.3724/SP.J.1004.2012.00841

A Robust-ELM Approach Based on Parzen Window's Estimation for Kiln Sintering Temperature Detection

CHEN Hua^{1,2} ZHANG Jing^{1,2} ZHANG Xiao-Gang² HU Yi-Han²

Abstract To eliminate the interference in the blurring pulverized coal flame image sequences of rotary kiln, a new kiln sintering temperature measurement method based on statistical features of pulverized coal flames and robust extreme learning machine (robust-ELM) is proposed in this paper. The degree of stability and quantity of radiant energy are computed from a blurry flames image sequences as statistical features, robust-ELM is presented to estimate the sintering temperature based on the above features of flames image. The distribution of training error of extreme learning machine (ELM) is estimated by Parzen windows to make up the weighted matrix to reduce the disturbance of gross errors in industrial field. Finally, a series of tests were undertaken on an industrial-scale flame videos, which showed the methods could measure sintering temperature more accurately, quickly, and robustly.

Key words Pulverized coal combustion, flame image, robust extreme learning machine (robust-ELM), sintering temperature, Parzen windows estimation

Citation Chen Hua, Zhang Jing, Zhang Xiao-Gang, Hu Yi-Han. A robust-ELM approach based on Parzen window's estimation for kiln sintering temperature detection. *Acta Automatica Sinica*, 2012, 38(5): 841–849

燃煤窑炉广泛应用于发电、冶金、水泥等工业生产的各个领域. 该类窑炉生产的关键环节是煤粉燃烧过程的检测与控制, 可直接影响产品质量, 生产能耗和空气污染物的排放. 随着工业现场火焰视频监控的广泛应用, 基于窑炉内火焰图像的燃烧过程检测逐渐成为近年来国内外工业煤粉燃烧过程研究的热点, 在火焰温度测量及多维温度场构建^[1-2]、锅

炉燃烧工况的识别^[3-4]、燃烧废气中碳和 NO_x 排放检测^[5-6] 等领域都取得了较好进展.

回转窑是一类典型的复杂工业燃煤窑炉. 煤粉在缓慢转动的空腔窑体内燃烧, 对生料 (石灰、氧化铝、碳素等) 进行烧结. 与煤粉燃烧研究应用较多的电厂锅炉相比, 回转窑内的煤粉与不同成分原料间的热物理和化学反应使其燃烧机理更复杂, 且其生产过程粗放, 因此烧结温度的检测一直是回转窑生产控制的关键和难点^[7]. 首先由于受到旋转窑体结构的限制, 回转窑火焰监控摄像机只能安装在窑头, 因此无法像电厂锅炉一样进行多路监控, 构建窑内多维温度场^[2]. 另外, 不同于电厂锅炉内的稳定火焰, 回转窑内的火焰区距窑头的位置在不同工况下位置变动较大 (一般在 3 m ~ 15 m 之间变化), 从窑头拍摄的火焰图像受到火焰位置的影响, 检测温度会产生较大偏差^[8]. 因此采用类似电厂锅炉基于火焰

收稿日期 2011-09-01 录用日期 2011-12-11
Manuscript received September 1, 2011; accepted December 11, 2011

国家自然科学基金 (60874096, 61174050, 61174140) 资助
Supported by National Natural Science Foundation of China (60874096, 61174050, 61174140)

本文责任编辑 董峰
Recommended by Associate Editor DONG Feng

1. 湖南大学信息科学与工程学院 长沙 410082 2. 湖南大学电气与信息工程学院 长沙 410082

1. School of Information Science and Engineering, Hunan University, Changsha 410082 2. College of Electrical and Information Engineering, Hunan University, Changsha 410082

辐射原理^[1-4]对窑内烧结带温度进行直接精确测量困难很大。

近年来利用回转窑烧结带图像的区域特征对窑内燃烧过程进行软测量的研究逐渐受到国内外学者的重视^[9-15]。文献 [9] 利用回转窑火焰区 HIS 数据计算其 1 阶~4 阶的统计量作为图像特征, 结合热工数据利用多变量回归方法建立燃烧工况的识别模型; 文献 [10] 利用大津法从烧结图像中分割出物料区和火焰区, 采用最速下降法选择支持向量回归 (Support vector regression, SVR) 模型的参数建立烧成带温度的软测量模型; 文献 [11-15] 研究了使用改进的模糊 C-均值 (Fuzzy C-means, FCM) 聚类算法^[11-14] 或神经网络方法^[15] 将烧结带图像分割成多个感兴趣区域, 然后提取区域图像特征来进行烧结带工况检测的方法。上述利用图像检测烧结温度的研究方法均是先将单帧窑内火焰图像分割成“黑把子”、“火圈”、“物料区”、“窑壁”等区域, 然后利用这些区域的面积、平均灰度、物料区纹理等图像特征来进行烧结带工况检测。

在现场拍摄图像清晰的情况下, 上述基于单帧图像进行分析的方法可获得较好的烧结带温度检测效果。但回转窑工业现场环境恶劣, 悬浮于高温气体中的煤粉、物料颗粒和冷却机二次风带入窑内的粉尘颗粒使窑内拍摄视频污染严重, 大部分情况下图像的清晰度较差。上述文献 [9-15] 提到的兴趣区域被烟尘和煤粉爆燃产生的亮斑掩盖, 形成一大片亮区 (以下定义为火焰区), 无法分辨物料区、火圈等其他区域, 这时通过单帧图像进行特征提取进行烧结温度软测量很难奏效。此外由于窑前现场电磁环境恶劣, 视频信号经常受到干扰产生畸变, 给基于视频图像的温度检测带来诸多困难。图 1 为回转窑现场提取的正常模糊图像, 图 2 为受干扰图像, 其中图 2(a) 为煤粉爆燃时的图像帧, 图 2(b)~2(d) 为受电磁干扰的图像。




图 1 回转窑模糊视频图像帧

Fig. 1 Blurry flame images of sintering zone in rotary kiln

本文针对这类带有不确定干扰的模糊火焰视频, 从火焰辐射能量和稳定程度综合分析提取特征, 对回转窑内的烧结温度进行鲁棒 ELM 检测。首先由视频段内各帧图像分段统计获取短时能量, 火焰平均丰度, 火焰平均灰度及其方差 4 个统计量特征, 然后为消除因回转窑现场各类不确定干扰而产生的粗

差数据, 基于系统辨识中的稳健估计理论, 在极限学习机 (Extreme learning machine, ELM)^[16] 的基础上, 提出一种新的鲁棒极限学习机 (Robust extreme learning machine, Robust-ELM), 以减少粗差对学习机的干扰, 有效地提高 ELM 在工业现场应用的抗干扰能力, 实现烧结带温度的稳健测量。




图 2 粉尘和电磁干扰的模糊视频图像帧

Fig. 2 Blurry flame images with interference in rotary kiln

1 基于模糊火焰视频的特征提取

针对单帧模糊图像分割火焰区, 提取其特征向量, 是检测烧结温度的基础。本节研究其视频统计特征的分析 and 提取。

1.1 火焰的辐射能量

基于辐射测温原理, 火焰的辐射能量与图像的灰度有直接的正向相关性^[17-18], 可在一定程度上反映燃烧温度的高低。因此将采样周期 T 内的火焰区平均灰度和灰度方差作为判别温度的特征量:

1) 火焰区平均灰度

$$G_t = \frac{1}{T} \sum_{i=1}^T g(i) \quad (1)$$

其中, T 为采样图像的帧数, $g(i)$ 表示 i 时刻采样的单帧图像火焰区平均灰度, 计算如式 (2):

$$g(i) = \frac{1}{H} \sum_{j=1}^H f_j \quad (2)$$

其中, H 为火焰区的像素个数, f_j 为火焰区单个像素的灰度值。

2) 火焰区灰度方差

$$\sigma_t = \sqrt{\frac{1}{T} \sum_{i=1}^T (g(i) - G_t)^2} \quad (3)$$

图 3 给出了一段 90 分钟窑前火焰视频中 (采样周期为 2 秒, 帧率为 25 帧/秒) 火焰区平均灰度 G_t 在烧结温度低 (Low), 正常 (Norm) 和高 (High) 三种情况下的条件概率密度函数图。由图 3 观察可知, 三种情况下 G_t 的概率密度分布在有效灰度级范围内 (50~170) 有较大重合。这是因为: CCD 在火焰

辐射较强情况下, 会出现亮度饱和, 因此造成温度正常与温度高两类的分布重合较大; 而且在窑内升温过程中, 常常出现煤粉的爆燃(火焰变短), 使得温度低的分布出现向右的拖尾现象, 造成火焰区变亮的假象. 因此常用的基于辐射测温原理的灰度特征不能很好区分烧结温度等级. 下一节提出基于燃烧稳定程度的特征选取.




图3 G_t 在3种温度条件下的概率分布
Fig.3 Probability distributions of G_t at different temperatures

1.2 燃烧稳定程度

煤粉火焰的温度变化与其燃烧的稳定性的有密切联系^[19]. 根据回转窑现场看火经验, 当烧结带温度稳定时, 煤粉火焰闪烁平稳, 火焰区面积在正常范围波动; 而当温度变低时, 火焰闪烁剧烈, 常出现如图2(a)所示的爆燃现象, 火焰区面积明显增大. 根据这一现场工艺特点, 构造如下衡量燃烧稳定程度的两个特征量:

1) 火焰区平均丰度. 将 t 时刻, T 帧图像的火焰区平均丰度 M_t 作为刻画稳定程度的特征量, 定义如下:

$$M_t = \frac{1}{T} \sum_{i=0}^T c(i) \quad (4)$$

其中, $c(i)$ 是第 i 帧采样图像的火焰区丰度值, 定义为二值化分割后火焰区的像素总和与整幅图像像素总和的比值:

$$c(i) = \frac{H}{I} \quad (5)$$

其中, H 是像素值为 1 (即火焰区) 的点的数目, I 是整幅图像的像素数目. M_t 描述了 t 时刻平滑滤波后的火焰区面积. 显然当火焰出现剧烈闪动时, M_t 的值将会变大.

2) 火焰短时能量. 短时能量是语音信号中衡量语音信号强弱和变化快慢的一个重要参数^[20], 本文借鉴语音信号处理的方法, 对采样信号进行加窗处理, 计算窗宽为 N 时, 视频段内的火焰区丰度短时

能量值, 作为衡量火焰稳定程度的特征量. 在 t 时刻, 火焰区短时能量 E_t 的定义如下:

$$E_t = \sum_{i=t-(N-1)}^t [M_i w(t-i)]^2 \quad (6)$$

其中, M_i 为 i 时刻火焰区平均丰度, E_t 表示 t 时刻取窗宽为 N 时, M_i 的短时能量. $w(t-i)$ 为窗函数. 当取矩形窗时,

$$E_t = \sum_{i=t-(N-1)}^t M_i^2 \quad (7)$$

如果在求和窗宽内爆燃帧越多, E_t 就越大, 反映火焰闪动越剧烈, 火焰燃烧稳定性越低. 反之亦然. 图4为采用第1.1节同一段火焰视频, 火焰短时能量 E_t 在烧结温度偏低 (Low), 正常 (Norm) 和高 (High) 三种情况下的条件概率密度函数图, 用 $P(E_t)$ 表示. 由图可知, E_t 在三类概率密度函数的峰值相差较大, 可较好区分不同的烧结温度.

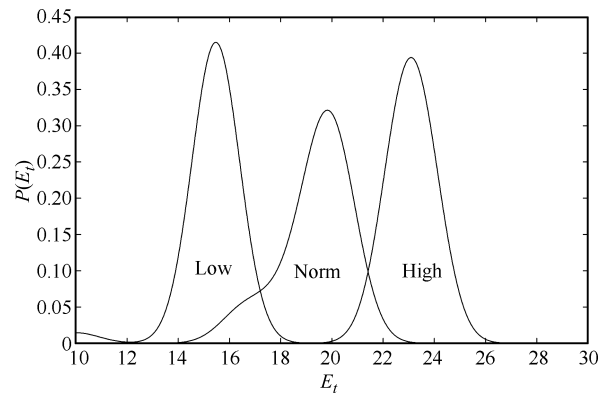


图4 E_t 在3种温度条件下的概率分布
Fig.4 Probability distributions of E_t at different temperatures

2 鲁棒极限学习机

极限学习机 (ELM) 是由 Huang 在 2005 年提出的一种新的单隐层前馈神经网络, 研究已证实 ELM 具有与神经网络 (Neural network, NN) 相同的全局逼近性质^[21], 其参数学习不需迭代, 速度明显快于现有的 NN 和支持向量机 (Support vector machine, SVM), 可以满足回转窑工业现场实时性的要求, 其改进算法的研究和现场应用受到广泛关注^[22]. 但从网络学习的稳健性考虑, ELM 仍有两个尚待解决的固有缺陷: 1) 其隐层部分参数的选取为随机确定, 这会造成 ELM 的网络的训练结果有较大的不稳定性^[23]. 为了解决这一问题, 文献 [24] 利用粒子群优化 (Particle swarm optimization, PSO) 对随机选取的参数进行优化以提升学习器精度, 文献

[25–26] 则采用多个分类器集成的方法如 Adaboost 理论来提升算法性能. 2) 如果训练数据存在共线性或粗差干扰, 输出层权值的最小二乘估计结果会很差. 文献 [27] 提出贝叶斯极限学习机 (Bayesian ELM, BELM) 试图利用一些先验知识来弥补学习过程粗差干扰问题; 文献 [28] 提出一种基于最小二乘辨识中的岭估计来解决训练数据中的共线性问题, 但回归参数 k 的最优值依赖于模型未知参数 β 和误差的方差 δ^2 , 使得 $\hat{\beta}(k)$ 的估计实质成为一个非线性估计, 丧失了最小二乘的快速性. 上述改进的 ELM 学习方法虽然提高了学习的稳定性, 但或因计算复杂度较高而丧失了极限学习的快速性, 或需要一些先验知识现场较难获取, 并不适用于回转窑工业现场.

本文结合线性系统的稳健估计理论, 提出一种新的鲁棒极限学习机 (Robust-ELM), 通过 Parzen 窗非参数估计训练误差的概率分布, 构造权矩阵对输出层权值进行加权最小二乘稳健估计, 在无需先验知识的同时计算速度损失也较小, 可大大提升现有 ELM 的抗干扰能力, 以期克服回转窑现场火焰视频中各种不确定性, 实现烧结带温度的鲁棒检测.

2.1 极限学习机

给定训练集 $D = \{(\mathbf{x}_i, \mathbf{t}_i) | \mathbf{x}_i \in \mathbf{R}^d, \mathbf{t}_i \in \mathbf{R}^m, i = 1, 2, \dots, N\}$, 则具有 L 个隐节点和激活函数 $g(x)$ 的单隐层前向网络, 可描述为如下线性方程组形式:

$$H\beta = T \quad (8)$$

其中, H 为隐层节点的输出矩阵.

$$H = \begin{bmatrix} g_1(\mathbf{w}_1\mathbf{x}_1 + b_1) & \cdots & g_L(\mathbf{w}_L\mathbf{x}_1 + b_L) \\ \vdots & \ddots & \vdots \\ g_N(\mathbf{w}_1\mathbf{x}_N + b_1) & \cdots & g_L(\mathbf{w}_L\mathbf{x}_N + b_L) \end{bmatrix}_{N \times L}$$

$\beta = [\beta_1, \beta_2, \dots, \beta_L]^T \in \mathbf{R}^{L \times d}$ 为输出层权值向量, $T = [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_N]^T \in \mathbf{R}^N$ 为样本输出矩阵.

Huang 等^[16] 证明了如果隐层的权值和阈值参数 (\mathbf{w}_i, b_i) 是基于某连续取样分布概率 $\mathbf{R}^d \times \mathbf{R}$ 随机生成, 且激活函数 $g(x)$ 为任意区间无限可微, 则 H 矩阵的秩为 L . 因此输出层的权值 β 可由 $H\beta = T$ 线性方程组直接解出. 即

$$\hat{\beta} = H^\dagger T \quad (9)$$

其中, H^\dagger 为矩阵 H 的摩尔广义逆, H^\dagger 具有多种计算方法, 其中 $\hat{\beta}_{LS} = (H^T H)^{-1} H^T T$ 为 β 的最小二乘估计^[16], $\hat{\beta}(k) = (H^T H + kI)^{-1} H^T Y$, $k > 0$ 为岭估计^[28] 等, 考虑到岭估计 $\hat{\beta}(k)$ 中 k 确定的复杂性, 且现场误差 ϵ 服从标准正态分布 $N(0, \delta^2)$ 的前提很难满足, 本文将主要从最小二乘稳健估计的角

度进行算法改进.

2.2 输出层权值的鲁棒辨识

利用广义摩尔逆求解式 (9), 获得的是线性方程组的一个二乘解, 本质上是对线性模型 β 参数的最小二乘估计. 这种估计有两个优良的性质.

性质 1. 依据线性方程组求解理论易知: 特殊解 $\hat{\beta} = H^\dagger T$ 在所有 $H\beta = T$ 的二乘解中具有最小的模, 即 $\|\hat{\beta}\| = \|H^\dagger T\| \leq \|\beta\|, \forall \beta \in \{\beta : \|H\beta - T\| \leq \|H\mathbf{z} - T\|, \forall \mathbf{z} \in \mathbf{R}^L\}$. 又根据 Bartlett 理论^[29], NN 在训练错误尽可能小的同时, 输出权值的模越小, 网络的泛化能量越强.

性质 2. 依据最小二乘估计理论, 在数据正态分布的条件下, 最小二乘估计为线性最优估计, 因此 $\hat{\beta} = H^\dagger T$ 可获得最小的训练误差.

下面将从线性系统辨识的角度阐述 ELM 中 β 参数的估计问题, 考虑到线性模型的误差, 可将式 (8) 改写为

$$H\beta = T + \epsilon \quad (10)$$

其中, $\epsilon = [\epsilon_1, \epsilon_2, \dots, \epsilon_N]^T$ 为模型的残差向量.

由最小二乘估计理论可知在残差 ϵ 服从 $N(0, \delta^2)$ 正态分布的条件下, 使 $\min_{\beta} \|H\beta - T\|_2 = \min_{\beta} \epsilon^T \epsilon$, 模型 (10) 中参数 β 的最小二乘估计 $\hat{\beta}_{LS} = (H^T H)^{-1} H^T T$ 具有最优一致无偏且方差最小的性质, 因此才导出性质 2 的成立.

但系统的残差不一定会服从 $N(0, \delta^2)$ 分布, 且一般最小二乘估计的抗差能力较差, 在观测值出现粗差污染时, 最小二乘估计的优异性能将大大降低. 因此在系统辨识领域的研究过程中先后出现了 M 估计, L 估计和 R 估计等多种稳健估计方法^[30]. M 估计使用比 $\|\epsilon\|_2$ 增长速度更慢的准则函数, 以求减少粗差对整体估计的影响, 达到稳健估计的效果, 但是算法需要多重递归寻优, 计算效率较低. 本文采取一种基于 Parzen 窗估计的抗差最小二乘方法对 β 进行鲁棒估计, 具体阐述如下.

定理 1. 对于线性系统 $H\beta = T + \epsilon$, 设误差权重矩阵 $P \in \mathbf{R}^{N \times N}$, 在满足 $\min_{\beta} \|H\beta - T\|_2 = \min_{\beta} \epsilon^T P \epsilon$ 准则函数下, β 的加权最小二乘估计为

$$\hat{\beta}_{LSR} = (H^T P H)^{-1} H^T P T \quad (11)$$

证明. 将 $\epsilon = H\beta - T$ 代入准则函数 $\epsilon^T P \epsilon$, 求 $\frac{\partial(\epsilon^T P \epsilon)}{\partial \beta} = 0$, 得 $H^T P H \beta - H^T P T = 0$, 即 $\hat{\beta} = (H^T P H)^{-1} H^T P T$. \square

权重矩阵 P 的选取是抗差最小二乘估计的关键. 为了在误差不服从 $N(0, \delta^2)$ 分布情况下也能取得较好的估计效果, 考虑到粗差出现的偶然性, 其必然远离残差的分布中心, 因此在已知残差的概率分布情况下, 可利用残差出现的概率构造误差权重

矩阵 $P = \text{diag}\{p_1, p_2, \dots, p_N\}$, 其中, $p_i = f(\varepsilon_i)$, $f(\varepsilon)$ 为残差变量 ε 的概率密度函数.

一般情况下残差的概率分布 $f(\varepsilon)$ 是未知的, 我们可以先对模型 (10) 进行一次最小二乘估计, 求出 $\hat{\beta}_{LS}$, 然后利用 $\varepsilon = H\hat{\beta}_{LS} - T$ 计算标准的残差向量 $\varepsilon = [\varepsilon_1, \varepsilon_2, \dots, \varepsilon_N]^T$, 利用 ε 对其概率密度函数 $f(\varepsilon)$ 进行估计. 由于对 $f(\varepsilon)$ 的分布无先验信息, 因此采用 Parzen 窗法对 $f(\varepsilon)$ 进行非参数估计如下:

$$\hat{f}(\varepsilon) = \frac{1}{N} \sum_{i=1}^N \frac{1}{h_N} \varphi\left(\frac{\varepsilon - \varepsilon_i}{h_N}\right) \quad (12)$$

其中, N 为样本点数目, $h_N = h/\sqrt{N}$ 为窗宽, 如果 h 过大, $\hat{f}(\varepsilon)$ 会成为一个平均估计, 估计分辨率降低, 降低学习机的抗噪能力; 如果 h 过小, 会使 $\hat{f}(\varepsilon)$ 趋于以样本为中心的 δ 函数的叠加, 丧失掉函数的外推性能, 增加样本的加权风险, 降低学习机的分类精度, 因此 h 值对学习机的抗噪能力和学习精度均有影响. $\varphi(\cdot)$ 为窗函数, 只需具有密度函数的形式即可, 本文采用式 (13) 的正态窗函数, 在有限样本数下可获得较平滑的 $\hat{f}(\varepsilon)$, 减少估计的不确定性.

$$\varphi(u) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}u^2\right) \quad (13)$$

2.3 鲁棒极限学习机

采取上述基于 Parzen 窗估计的抗差最小二乘估计方法对 β 进行鲁棒估计, 构造鲁棒极限学习机 (Robust-ELM). 结合前面输出层权值的鲁棒辨识讨论, 在给定训练集 $D = \{(\mathbf{x}_i, \mathbf{t}_i) | \mathbf{x}_i \in \mathbf{R}^d, \mathbf{t}_i \in \mathbf{R}^m, i = 1, 2, \dots, N\}$ 条件下, Robust-ELM 的具体训练步骤如下:

步骤 1. 确定隐节点类型和数目 L 后, 随机产生隐层节点参数 $\mathbf{w}_i, b_i, i = 1, 2, \dots, L$;

步骤 2. 计算隐层输出矩阵 H ;

步骤 3. 计算输出层权值 $\hat{\beta}_{LS} = (H^T H)^{-1} H^T T$;

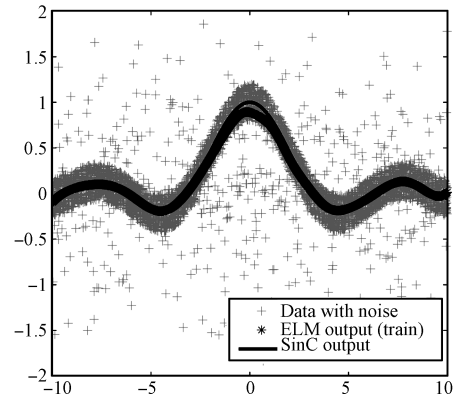
步骤 4. 利用 $\varepsilon = H\hat{\beta}_{LS} - T$ 计算残差向量 $\varepsilon = [\varepsilon_1, \varepsilon_2, \dots, \varepsilon_N]^T$;

步骤 5. 利用式 (12) 对 ε 进行 Parzen 窗估计, 获取残差的概率分布 $\hat{f}(\varepsilon)$, 计算 $p_i = \hat{f}(\varepsilon_i)$, 构造权重矩阵 $P = \text{diag}\{p_1, p_2, \dots, p_N\}$;

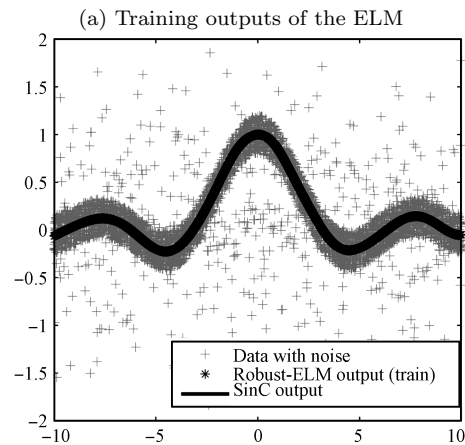
步骤 6. 计算输出层权值的鲁棒估计 $\hat{\beta}_{LSR} = (H^T P H)^{-1} H^T P T$.

为验证 Robust-ELM 的抗差能力, 采用加噪声点的 SinC 函数进行仿真. 数据产生方法如下: 在 $(-10, 10)$ 区间随机产生训练和测试数据各 5000 个, 在训练数据集的每个数据上叠加取值范围为 $[-0.2, +0.2]$ 的随机噪声, 并在训练数据集中再随

机加入 500 个取值范围 $[-2, +2]$ 的离群噪声点, 测试数据无噪声. Robust-ELM 和 ELM 训练和测试效果如图 5 和图 6 所示. 由图可知, Robust-ELM 的输出对训练和测试真实数据的拟合效果均好于 ELM.



(a) ELM 训练输出



(b) Robust-ELM 训练输出

(b) Training outputs of the robust-ELM

图 5 ELM 与 Robust-ELM 加噪声训练数据输出

Fig. 5 Training results of ELM and robust-ELM

3 实验分析

采用中国铝业公司某大型氧化铝厂 6 号回转窑 2008 年 7 月 15 日~19 日采集的 12 小时长的窑前火焰监控视频 (25 帧/秒) 生成训练数据. 根据现场经验, 将视频分为温度高、偏高、正常、偏低, 低五类, 共形成 21 600 组训练数据 (其中温度高 2 793、偏高 3 792、正常 7 284、偏低 2 949、低 4 782 个数据). 采用 7 月 20 日一段 4 小时视频生成 7 200 组测试数据.

3.1 火焰视频特征提取

各样本的特征提取方法如下: 首先分割火焰区. 按 5 帧/秒进行单帧采样, 将提取的单帧 RGB 图像转换为 256 级灰度图, 用中值滤波消除单帧图像上

孤立噪声点的干扰,采用 Otsu 单阈值法^[31],自动寻找使火焰区和背景间灰度方差距离最大的分割阈值,分割出火焰区. 图 7 为原始视频图像帧经过预处理

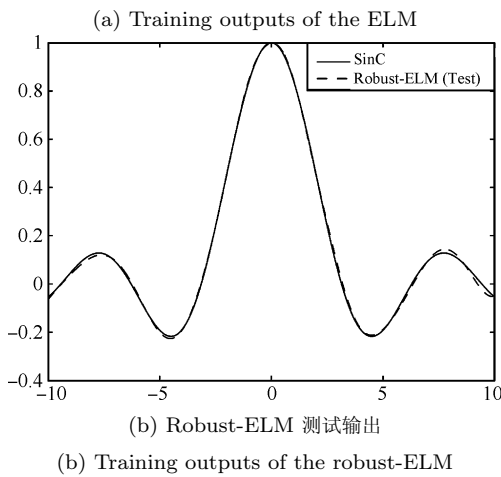
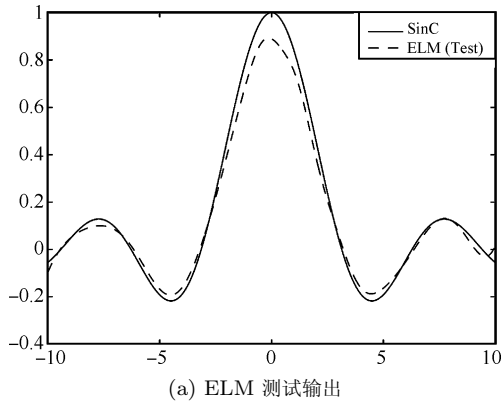


图 6 ELM 与 Robust-ELM 测试数据输出
Fig. 6 Testing results of ELM and robust-ELM



图 7 图像单阈值分割结果
Fig. 7 Results of single threshold segmentation

后分割出火焰区的过程.

然后计算火焰视频的统计特征:按式(1),式(3)和式(4)分别计算平均灰度 G_t 、灰度方差、平均丰度 M_t 三个特征量,统计时间窗 T 为 10 帧,按式(7)计算火焰短时能量 E_t ,窗宽 N 为 250. 将上述 4 个特征作为当前采样时刻 t 的一组特征数据.

图 8 展示了从两段训练视频(时长 20 min)中计算的上述 4 个特征数据曲线,第一行窑内温度逐渐降低,后者为逐渐升高. 观察特征数据,在烧结温度变化时,火焰平均灰度值并未明显变化,但基于平均丰度定义的短时能量体现出明显的趋势特征,具有较强的温度区分度:窑内温度降低时,火焰变得不稳定,爆燃现象增多,短时能量升高(第 1 行). 反之温度升高时,火焰趋于稳定,爆燃减少,短时能量会降低(第 2 行). 在另一方面,由于现场图像易受到粉

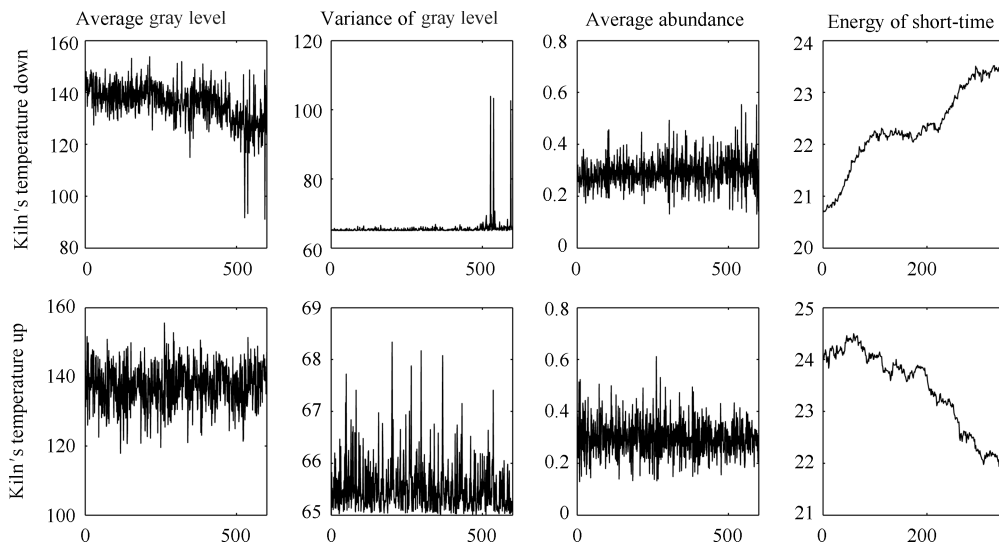


图 8 从窑内视频中提取的温度特征曲线
Fig. 8 Temperature curve in kiln

尘、电磁等干扰, 数据中的各特征量均呈现出不同程度的噪声污染, 因此本文提出一种新的鲁棒极限学习机进行下一步的烧结温度识别.

3.2 鲁棒极限学习机的训练

利用第 2.3 节的 Robust-ELM 方法对上述数据进行学习. ELM 隐层激活函数采用 Sigmoid 函数, 学习机隐节点数目 L 的选取采用递推法: 即由 5~200, 以 5 为间隔, 各训练 100 次取其平均测试准确率, 实验结果如图 9 所示. 随着 L 的增加, 训练和测试准确率均逐渐增大, 但在隐节点数达到 45 以后, 测试准确率却逐渐下降, 系统出现过学习现象, 因此确定分类最佳隐节点数为 45.

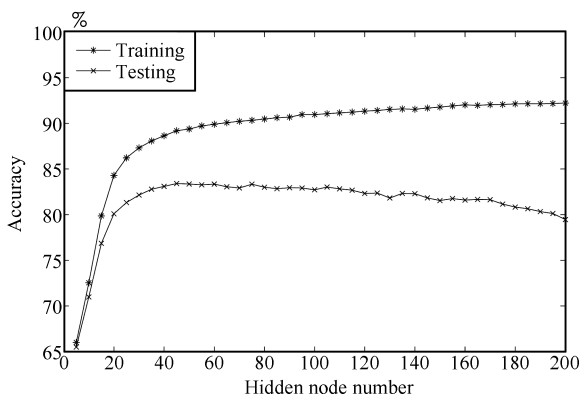


图 9 分类准确率随隐节点数目变化曲线

Fig. 9 Classification accuracy with different number of hidden nodes

为获取较平滑的估计, 采用式 (13) 的正态 Parzen 窗估计 ELM 的训练误差分布. 窗宽是该误差估计过程中的关键参数, 其受到样本数目, 待估样本分布 (未知), 窗函数形式等因素影响. 窗宽的选择原则上是让单个样本的立方体随样本数量的增大缓慢减小, 达到估计密度函数的收敛, 但由于实验样本有限, 多采用经验确定. 图 10 为本次实验过程中窗宽 h 在 2~40 范围变化时, Robust-ELM 的分类精度曲线, 由此确定最优窗宽值 $h = 10$.




图 10 分类准确率随 Parzen 窗宽变化曲线

Fig. 10 Classification accuracy with different width of Parzen window

3.3 实验结果分析

最终的 Robust-ELM 与 ELM 的训练准确率和测试准确率及训练时间、测试时间 (100 次平均) 如表 1 所示. 同时还用 SVM 和 BP 对相同的数据做了反复测试, 获取最优参数后以 100 次的平均数据进行对比, 以验证特征提取的有效性. 由上述实验结果和分析可知: 本文提出的 Robust-ELM 在现场模糊图像不可避免受到各种干扰影响, 数据有较强不确定性情况下, 体现出较强的鲁棒性, 分类准确率比 ELM, SVM, BP 明显提高. 同时在训练时间上, Robust-ELM 略长于普通 ELM, 但远远短于 SVM 和 BP, 表现出较好的实时性. 另外, 上述四种分类器精度均达到 70% 以上, 表明利用本文提出的 4 种火焰视频特征对这一类回转窑复杂燃煤过程烧结带温度检测的有效性. 为进一步说明 Robust-ELM 对各温度段的分类效果, 由 10 次测试实验生成的混淆矩阵 (平均值) 如表 2 所示. 由表计算各类单独准确率分别为 88%, 77.82%, 80.46%, 79.85% 和 93.9% (由高到低), 混淆矩阵中高, 低温度状态的识别率高于中间状态的识别率, 分析原因一是由于极端温度状态下的特征较为明显, 二是现场经验对中间

表 1 Robust-ELM、ELM、SVM 和 BP 训练结果比较

Table 1 Training results of robust-ELM, ELM, SVM, and BP

| | 运行时间 (s) | | 准确率 (%) | | 隐节点/支持向量个数 |
|------------|----------|-------|---------|-------|--|
| | 训练样本 | 测试样本 | 训练样本 | 测试样本 | |
| Robust ELM | 1.653 | 0.407 | 89.67 | 83.41 | 45 |
| ELM | 1.416 | 0.393 | 78.89 | 76.14 | 45 |
| SVM | 13.636 | 3.481 | 82.26 | 78.35 | 62 (罚因子 $C = 4, \sigma = 2, \xi = 0.1$) |
| BP | 6.553 | 0.412 | 78.17 | 75.64 | 50 |

表 2 Robust-ELM 分类混淆矩阵

Table 2 Classification confusion matrix of robust-ELM

| | 高 | 偏高 | 正常 | 偏低 | 低 |
|----|-------|--------|--------|--------|--------|
| 高 | 714.6 | 45.7 | 37 | 13.8 | 0.9 |
| 偏高 | 114.6 | 1034.2 | 84.7 | 94.6 | 0.9 |
| 正常 | 13.9 | 102.4 | 1708.9 | 191.1 | 107.7 |
| 偏低 | 0.2 | 2.8 | 130.6 | 1207.4 | 171 |
| 低 | 0.1 | 0.6 | 2.2 | 83.9 | 1336.2 |

偏高和偏低温度状态的判断有偏差,造成类标误分,给分类器带来学习的难度。

4 结论

本文分析了国内外煤粉燃烧图像检测和极限学习机的相关研究进展,针对回转窑现场燃煤火焰的特殊性,从火焰辐射能量和火焰燃烧稳定程度两方面,提出 4 种烧结温度的火焰视频统计特征,并将 ELM 与稳健估计理论相结合,用训练误差分布的 Parzen 窗非参数估计构造 ELM 权矩阵,对其输出层权值进行稳健最小二乘估计改进极限学习机,提出一种抗粗差干扰的 Robust-ELM. 这种基于 Parzen 窗估计的鲁棒 ELM 烧结温度软测量方法可快速有效地检测窑内烧结温度,且检测系统不易受现场干扰,稳定性强. 后续如何利用模糊视频中提取的图像特征数据,结合现场热工数据,对烧结带温度进行更准确的测量,是我们下一步工作的重点。

References

- Jiang Z W, Luo Z X, Zhou H C. A simple measurement method of temperature and emissivity of coal-fired flames from visible radiation image and its application in a CFB boiler furnace. *Fuel*, 2009, **88**(6): 980–987
- Luo Z X, Zhou H C. A combustion-monitoring system with 3-D temperature reconstruction based on flame-image processing technique. *IEEE Transactions on Instrumentation and Measurement*, 2007, **56**(5): 1877–1882
- Bae H, Kim S, Wang B H, Lee M H, Harashima F. Flame detection for the steam boiler using neural networks and image information in the Ulsan steam power generation plant. *IEEE Transactions on Industrial Electronics*, 2006, **53**(1): 338–348
- Liu He. Judging boiler combustion stability based on flame image and fuzzy neural network. *Chinese Journal of Scientific Instrument*, 2008, **29**(6): 1280–1284
(刘禾. 基于火焰图像和模糊神经网络的锅炉燃烧稳定性判别. 仪器仪表学报, 2008, **29**(6): 1280–1284)
- Krabicka J, Lu G, Yan Y. Profiling and characterization of flame radicals by combining spectroscopic imaging and neural network techniques. *IEEE Transactions on Instrumentation and Measurement*, 2011, **60**(5): 1854–1860
- Smart J, Lu G, Yan Y, Riley G. Characterisation of an oxy-coal flame through digital imaging. *Combustion and Flame*, 2010, **157**(6): 1132–1139
- Zhang Xiao-Gang, Chen Hua, Zhang Jing, Liu Xiao-Yan. Intelligent predictive control strategy applied to sintering temperature in rotary kiln based on image feedback. *Control Theory and Applications*, 2007, **24**(6): 995–998
(张小刚, 陈华, 章兢, 刘小燕. 基于图像反馈的回转窑烧结温度智能预测控制. 控制理论与应用, 2007, **24**(6): 995–998)
- Zhang Xiao-Gang, Chen Hua, Zhang Jing. Rotary kiln sintering temperature measurement and control based on fuzzy multisensor data fusion. *Control and Decision*, 2002, **17**(6): 865–870
(张小刚, 陈华, 章兢. 基于多传感器数据融合的回转窑烧结温度检测和控制方法. 控制与决策, 2002, **17**(6): 865–870)
- Lin B, Jørgensen S B. Soft sensor design by multivariate fusion of image features and process measurements. *Journal of Process Control*, 2011, **21**(4): 547–553
- Jiang Hui-Yan, Wang Xiao-Dan, Zhou Xiao-Jie, Chai Tian-You. Study on soft sensor for temperature of burning zone based on SVR. *Journal of System Simulation*, 2008, **20**(11): 2951–2955
(姜慧研, 王晓丹, 周晓杰, 柴天佑. 基于 SVR 的回转窑烧带温度软测量方法的研究. 系统仿真学报, 2008, **20**(11): 2951–2955)
- Yi Zheng-Ming, Lv Zi-Jian, Liu Zhi-Ming. Flame image processing and its characteristic extraction for alumina rotary kiln. *Chinese Journal of Scientific Instrument*, 2006, **27**(8): 969–972
(易正明, 吕子剑, 刘志明. 氧化铝回转窑火焰图像处理与特征提取. 仪器仪表学报, 2006, **27**(8): 969–972)
- Yi Zheng-Ming, Yan Ming, Chi Yun-Guang, Wang Li-You. Measurement technique of flame temperature in rotary kiln based on image processing. *Acta Metrologica Sinica*, 2008, **29**(1): 43–46
(易正明, 鄢明, 迟云广, 王理猷. 基于图像处理的回转窑火焰温度测量技术研究. 计量学报, 2008, **29**(1): 43–46)
- Sun Peng, Zhou Xiao-Jie, Chai Tian-You. FCM segmentation for flame image of rotary kiln based on texture coarseness. *Journal of System Simulation*, 2008, **20**(16): 4438–4445
(孙鹏, 周晓杰, 柴天佑. 基于纹理粗糙度的回转窑火焰图像 FCM 分割方法. 系统仿真学报, 2008, **20**(16): 4438–4445)
- He Min, Zhang Jing, He Zhao-Hui, Jing Li-Wei. Measurement of filling percentage of clinker using rotary kiln image. *Journal of Scientific Instrument*, 2009, **30**(12): 2586–2591
(何敏, 章兢, 何昭晖, 靖立伟. 基于回转窑图像的熟料填充率测量. 仪器仪表学报, 2009, **30**(12): 2586–2591)
- Li Shu-Tao, Wang Yao-Nan. The segmentation of kiln flame image based on neural networks. *Journal of Scientific Instrument*, 2001, **22**(1): 10–13
(李树涛, 王耀南. 基于神经网络的回转窑火焰图像分割. 仪器仪表学报, 2001, **22**(1): 10–13)
- Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications. *Neurocomputing*, 2006, **70**(1–3): 489–501
- Li Han-Zhou, Pan Quan, Zhang Hong-Cai, Zhao Chun-Hui, Feng Min. A study of algorithms of temperature measurement based on digital image processing. *Proceedings of*

- the Chinese Society for Electrical Engineering*, 2003, **23**(6): 195–200
(李汉舟, 潘泉, 张洪才, 赵春晖, 冯旻. 基于数字图像处理的温度检测算法研究. 中国电机工程学报, 2003, **23**(6): 195–200)
- 18 Lou Chun, Zhou Huai-Chun, Zhu Guo-Liang, Shao Yong. Analysis and measurement of radiative properties of particulate medium in a large-scale coal-fired boiler of power plant. *Journal of Engineering Thermophysics*, 2007, **28**(S2): 217–220
(娄春, 周怀春, 朱国良, 邵勇. 煤粉炉内颗粒辐射特性的检测与分析. 工程热物理学报, 2007, **28**(S2): 217–220)
- 19 Huang Ben-Yuan, Luo Zi-Xue, Zhou Huai-Chun. Diagnosis of combustion stability in furnace by using flame image method. *Thermal Power Generation*, 2007, **36**(12): 19–22
(黄本元, 罗自学, 周怀春. 炉膛燃烧稳定性的火焰图像诊断方法. 热力发电, 2007, **36**(12): 19–22)
- 20 Lamel L, Rabiner L, Rosenberg A, Wilpon J. An improved endpoint detector for isolated word recognition. *IEEE Acoustics, Speech and Signal Processing Magazine*, 1981, **29**(4): 777–785
- 21 Huang G B, Chen L, Siew C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes. *IEEE Transactions on Neural Networks*, 2006, **17**(4): 879–892
- 22 Huang G B, Wang D H, Lan Y. Extreme learning machines: a survey. *International Journal of Machine Learning and Cybernetics*, 2011, **2**(2): 107–122
- 23 Suresh S, Babu R V, Kim H J. No-reference image quality assessment using modified extreme learning machine classifier. *Applied Soft Computing*, 2009, **9**(2): 541–552
- 24 Saraswathi S, Sundaram S, Sundararajan N, Zimmermann M, Nilsen-Hamilton M. ICGA-PSO-ELM approach for accurate multiclass cancer classification resulting in reduced gene sets in which genes encoding secreted proteins are highly represented. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2011, **8**(2): 452–463
- 25 Tian H X, Mao Z Z. An ensemble ELM based on modified AdaBoost.RT algorithm for predicting the temperature of molten steel in ladle furnace. *IEEE Transactions on Automation Science and Engineering*, 2010, **7**(1): 73–80
- 26 Heeswijk M, Miche Y, Lindh-Knuutila T, Hilbers P A, Honkela T, Oja E, Lendasse A. Adaptive ensemble models of extreme learning machines for time series prediction. In: *Proceedings of the 19th International Conference on Artificial Neural Networks: Part II*. Berlin, Heidelberg: Springer-Verlag, 2009. 305–314
- 27 Soria-Olivas E, Gómez-Sanchis J, Martin J D, Vila-Francés J, Martínez M, Magdalena J R, Serrano A J. BELM: Bayesian extreme learning machine. *IEEE Transactions on Neural Networks*, 2011, **22**(3): 505–509
- 28 Deng Wan-Yu, Zheng Qing-Hua, Chen Lin, Xu Xue-Bing. Research on extreme learning of neural networks. *Chinese Journal of Computers*, 2010, **33**(2): 279–287
(邓万宇, 郑庆华, 陈琳, 许学斌. 神经网络极速学习方法研究. 计算机学报, 2010, **33**(2): 279–287)
- 29 Bartlett P L. The sample complexity of pattern classification with neural networks: the size of the weights is more important than the size of the network. *IEEE Transactions on Information Theory*, 1998, **44**(2): 525–536
- 30 Jiang Rui, Luo Gui-Ming. Optimal adaptive controller for stochastic systems based on weighted least-squares algorithm. *Acta Automatica Sinica*, 2006, **32**(1): 140–147
(姜睿, 罗贵明. 基于加权最小二乘法的最优适应控制器. 自动化学报, 2006, **32**(1): 140–147)
- 31 Otsu N. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 1979, **9**(1): 62–66



陈 华 湖南大学信息科学与工程学院讲师. 主要研究方向为图像处理与模式识别. E-mail: anneychen@126.com
(**CHEN Hua** Lecturer at the School of Information Science and Engineering, Hunan University. Her research interest covers image processing and pattern recognition.)



章 兢 湖南大学电气与信息工程学院教授. 主要研究方向为复杂工业过程控制与优化. E-mail: zhangj@hnu.edu.cn
(**ZHANG Jing** Professor at the College of Electrical and Information Engineering, Hunan University. His research interest covers complex process control and optimization.)



张小刚 湖南大学电气与信息工程学院教授. 主要研究方向为工业窑炉过程控制与模式识别. 本文通信作者.
E-mail: zhangxiaogang@126.com
(**ZHANG Xiao-Gang** Professor at the College of Electrical and Information Engineering, Hunan University. His research interest covers process control and pattern recognition for industrial kiln. Corresponding author of this paper.)



胡义函 湖南大学硕士研究生. 主要研究方向为模式识别.
E-mail: hu_yihan@qq.com
(**HU Yi-Han** Master student at the College of Electrical and Information Engineering, Hunan University. His main research interest is pattern recognition.)