烧结断面火焰图像多核 Boosting 显著性检测

王福斌¹⁾, 刘贺飞¹⁾, 王蕊¹⁾, 何江红¹⁾, 武晨²⁾

¹⁾ (华北理工大学电气工程学院 唐山 063210)

²⁾ (唐钢国际工程技术股份有限公司 唐山 063000)
(wfb2313@126.com)

摘 要: 烧结断面火焰图像受烟尘与光晕干扰, 图像中火焰边缘与料层区域出现模糊退化现象. 为解决传统基于二维图像特征的显著性检测方法难以有效地获取断面火焰图像实际显著区域的问题, 提出基于边界连通性与多核 Boosting 的显著性检测方法. 首先在图像颜色空间转换过程中采用色彩去相关原理, 利用边界连通性与暗通道先验获取初始显著性图, 提高初始显著性模型的检测水平; 然后根据断面火焰图像超像素区域自身信息、区域方差和区域对比度构建区域描述符, 在 4 个尺度上描述超像素分割区域, 并使用基于支持向量回归的多核 Boosting 算法生成辅助显著性图; 最后将初始显著性图与辅助显著性图进行加权融合, 得到最终显著性图. 以 $P-R$ 曲线、 F -measure、平均绝对误差和单幅图像的运行时间为评价指标, 采用包含人工标注的 600 幅烧结断面火焰图像将所提方法与其他 5 种现有方法进行对比, 并对所提方法各阶段进行分析. 实验结果表明, 所提方法优于其他 5 种方法, 各阶段检测性能逐步增强, 为提高断面火焰图像有效信息的提取精度奠定了基础.

关键词: 烧结火焰图像; 显著性检测; 边界连通性; 支持向量回归; 多核 Boosting

中图法分类号: TP391.41 **DOI:** 10.3724/SPJ.1089.2021.18686

Multiple Kernel Boosting Saliency Detection of Flame Image of Sintering Section

Wang Fubin¹⁾, Liu Hefei¹⁾, Wang Rui¹⁾, He Jianghong¹⁾, and Wu Chen²⁾

¹⁾ (College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210)

²⁾ (Tang Steel International Engineering Technology Corp, Tangshan 063000)

Abstract: The flame image of the sintering section is usually interfered by smoke and halo, which would cause the blurring of flame edge and material layer in the image. In order to solve the problem that traditional saliency detection method based on two-dimensional image features is difficult to effectively obtain the actual saliency of the cross-sectional flame image, a saliency detection method based on boundary connectivity and multi-kernel Boosting is proposed. Firstly, the color de-correlation is used in the process of image color space conversion. Boundary connectivity and dark channel prior principle are used to obtain the initial saliency map. Secondly, the super-pixel region information, regional variance and regional contrast of the flame image are used to construct region descriptor, the multiple kernel Boosting algorithm based on support vector regression is used to generate the complementary saliency map on 4 scales. Finally, the initial saliency map and the complementary saliency map are fused to obtain the final saliency map. 600 flame images including manual labeling are used to compare the proposed method with other 5 existing methods and each stage of the proposed method is analyzed. $P-R$ curve, F -measure, mean absolute error and running

收稿日期: 2020-09-28; 修回日期: 2021-05-04. 基金项目: 高端钢铁联合研究基金(F20192093231). 王福斌(1968—), 男, 博士, 副教授, 硕士生导师, 主要研究方向为数字图像处理、机器视觉; 刘贺飞(1996—), 男, 硕士研究生, 主要研究方向为数字图像处理; 王蕊(1996—), 女, 硕士研究生, 主要研究方向为数据挖掘; 何江红(1996—), 男, 硕士研究生, 主要研究方向为深度学习; 武晨(1990—), 女, 硕士, 中级工程师, 主要研究方向为计算机视觉.

time are taken as evaluation indexes. The experimental results show that the proposed method is superior to the other 5 methods, and the detection performance of each stage is gradually enhanced, which lays a foundation for improving the effective information extraction of sintering flame section image.

Key words: sintering flame image; saliency detection; boundary connectivity; support vector regression; multiple kernel Boosting

基于图像传感器和数字图像处理技术的火焰图像检测广泛应用于众多领域,特别是在火灾检测和烧结机尾烧结状态检测等应用中^[1]. 烧结机的烧结过程具有强非线性、大时滞、高耦合等特征,难以用数学关系表示. 烧结机尾燃烧状态检测需要根据烧结机尾断面火焰图像的特征信息进行判断,因此,烧结机尾断面火焰图像分割是准确判断烧结状态的前提. 传统火焰图像的分割方法大多基于阈值法,选取固定的阈值得到火焰区域^[2]. 由于烧结机尾部工况复杂,机尾断面火焰图像采集过程受到烟尘、光照、热辐射等因素干扰,造成断面火焰图像质量下降,难以选择合适的阈值对其进行分割,直接影响到烧结机尾断面火焰图像特征提取与烧结状态检测的准确性,因此,大量研究致力于实现火焰区域自动识别和燃烧状态检测^[3]. 近年来,众多学者对基于视觉显著性的目标检测方法进行研究,由于不需要训练大量的数据,并且可以快速聚焦图像中的重要目标,该方法广泛应用图像分割、图像压缩和目标检测等方面.

显著性目标检测可以分为自下而上的数据驱动方法^[4]和自上而下的目标驱动方法^[5]. 自下而上的方法通常基于图像像素与其周围邻域的差异确定目标的显著性,在检测细节上比全局形状信息更有效. 自上而下的方法能够根据训练样本中的特征检测出特定大小和类别的目标,但通常需要高层次的语义信息,且计算复杂度高、检测结果细节较少. 因此,自下而上的显著性检测方法应用更加广泛. Itti 等^[6]受视觉系统的神经结构和行为启发,提出一种自下而上的显著性检测模型,计算图像的颜色、亮度和方向特征信息,融合多尺度特征得到显著性图,但在提取图像显著特征时只强调局部特征,结果模糊且包含大量背景区域. 基于贝叶斯模型的显著性检测算法^[7]利用中低层线索得到清晰的显著性图,但对于前景与背景对比度低以及多目标的图像检测效果并不理想. Li 等^[8]基于贝叶斯模型提出一种运动显著性和颜色显著性相结合的火焰图像分割算法,得到较为准确的显著性检测结果. 在大多数低层视觉显著性检测中,最

广泛使用的假设是目标与背景区域之间具有较高特征反差^[9],称为对比度先验. Perazzi 等^[10]将图像抽象化并移除多余细节,基于对比度先验理论最终得到显著性图. 但由于对比度先验的显著性检测方法受到低层视觉线索的限制,通常会产生噪声. 背景先验理论则基于边界连通性优先原则去除图像背景区域,得到显著性检测结果. Yang 等^[11]将图像表示为一个以超像素为节点的闭环图,基于图像边界优先对节点进行流形排序,实现背景区域和前景显著目标有效提取. Wei 等^[12]将图像显著性定义为图像块到图像边界的最短路径距离,但该方法将图像所有边界作为背景,当目标对象距离边界较近时目标的显著值则会降低,也可能将其误检测为背景区. Zhu 等^[13]利用边界连通性提高背景先验的鲁棒性,并整合了其他低层显著性线索,可以有效地计算前景与背景相似图像的显著性.

由于烧结断面火焰图像存在环境因素的干扰,造成目标与背景对比度低,传统方法难以准确地获取显著目标. 本文根据烧结断面火焰图像亮度、颜色和纹理特征具有较高显著性,提出一种烧结断面火焰图像显著性检测模型. 首先,将断面火焰图像基于简单线性迭代聚类(simple linear iterative clustering, SLIC)算法分割为若干多尺度的超像素区域,并在颜色空间转换过程中对断面火焰图像进行色彩去相关处理,结合暗通道先验原理与边界连通性计算初始显著性图;其次,采用区域自身信息、区域方差与区域对比度描述图像区域特征,使用基于支持向量回归的多核 Boosting 算法计算其辅助显著性图;最后,将初始显著性图与辅助显著性图通过加权融合,得到最终的显著性检测结果.

1 烧结断面火焰图像预处理

1.1 烧结断面火焰图像采集

烧结机尾料层断面火焰图像中蕴含着大量的与烧结终点关联的信息,通过观测断面火焰图像可以准确地掌握料层的烧结状态,判断烧结矿质量.

烧结生产的目的是将铁矿石、溶剂和燃料按一定的配比在带式抽风烧结机上烧结成块,为高炉炼铁提供主要原料.随着烧结过程的持续进行,料层会相继出现烧结矿层、燃烧层、干燥层、预热层和过湿层 5 层区域.在运行至烧结机尾部时,前 4 层区域在台车移动和风箱作用下逐渐消失,转变为烧结矿层,最后在烧结机尾部因重力作用断裂掉落,至此,一个完整的烧结过程结束.烧结断面火焰图像的采集则需记录从机尾断面火焰开始出现到料层断面掉落的过程.经观察发现,一个机尾断面掉落过程大概需要 40 s,机尾断面掉落的过程如图 1 所示.

图 1 机尾断面掉落过程

1.2 火焰图像的超像素分割

超像素分割在计算机视觉领域应用广泛,通常采用低计算成本产生紧凑的规则数量的超像素区域^[14].SLIC算法在 RGBXY 5 维空间中使用 K 均值聚类算法对图像进行局部聚类^[15],得到若干边缘敏感的局部超像素区域,分割后的每个超像素区域均能较好地表示图像的局部结构^[16].

本文使用 SLIC 算法将烧结断面火焰图像分割为视觉上均匀的若干超像素区域以提高计算效率,如图 2 所示.由于显著性目标在不同尺度下超像素区域都可能出现,显著性图的精度对超像素区域的数量变得十分敏感,超像素区域太少会丢失图像的细节信息,太多则易受噪声和误差的干扰,同时也会增加计算时间.本文选取 4 种不同粒度的超像素区域数量 N 来解决图像尺度问题,超像素区域表示为 $\{c_i\}_{i=1}^N$,其中, $N=100, 150, 200, 250$.

1.3 图像色彩去相关

Schauerte 等^[17]提出色彩去相关理论并在多种显著性检测算法上验证其假设的准确性,证明该理论能有效地提高显著性模型的检测水平.首先,

图 2 烧结断面火焰图像多尺度超像素分割

将输入火焰图像表示为在颜色空间中尺寸为 $M \times N$ 且包含 K 维分量的图像 $I \in \mathbb{R}^{M \times N \times K}$,减去每维图像中的像素均值;其次,重构图像矩阵,定义一个新的以图像像素均值为中心的色矩阵 $X \in \mathbb{R}^{M \times N \times K}$,去相关后的输出矩阵 Y 可以表示为

$$Y = XW \quad (1)$$

其中, W 表示去相关矩阵,目的是去除输入数据中的冗余信息. W 可利用主成分分析法(principal component analysis, PCA)、零相位成分分析法(zero-phase component analysis, ZCA)求解.本文根据 PCA 方法^[17]计算 W ,表示为

$$W_{PCA} = S^{-1/2}U^T \quad (2)$$

其中, S 表示协方差矩阵 $C = \frac{1}{MN}XX^T$ 的特征值矩阵; U 表示特征向量矩阵.

重构 Y ,使其在维度上与原始图像 I 相对应,从而得到色彩去相关后的输出图像 $I_{PCA} \in \mathbb{R}^{M \times N \times K}$.利用图像色彩去相关理论对烧结断面火焰图像进行处理,将输入 RGB 图像转化为 RGB:PCA, Lab:PCA 和 HSV:PCA,如图 3 所示.

图 3 烧结断面火焰色彩去相关图像

本文将色彩去相关用于初始显著性图提取的颜色空间转换过程与辅助显著性图特征提取的过程中,可有效地提高显著性检测水平,并在客观评价中展示其有效性.

2 烧结断面火焰图像显著性检测模型

2.1 初始显著性图获取

烧结断面火焰图像的采集过程受到粉尘散射和光照不均等因素干扰, 导致断面火焰图像前景与背景对比度较低, 利用边界连通性^[13]能够有效地判断超像素区域属于背景的概率. 该方法能够有效地描述图像区域相对于图像边界的空间分布, 仅当超像素区域与图像边界紧密连接时该区域为背景区域, 因此具有较高的鲁棒性. He 等^[18]提出用于图像去雾的暗通道先验原理, 即一幅图像至少有一个颜色通道在某些像素点处具有非常低的亮度. 图像中的暗通道主要由彩色或深色物体和阴影产生, 由于烧结机尾烟尘环境下采集到的图像存在大量暗像素, 因此可结合暗通道先验原理与边界连通性这 2 种假设, 构造初始显著性检测模型.

对于像素 p , 暗通道先验图像 $S_d(p)$ 定义为

$$S_d(p) = 1 - \min_{q \in \Omega(p)} \left\{ \min_{u \in \{r, g, b\}} [I^u(q)] \right\} \quad (3)$$

其中, $\Omega(p)$ 表示以 p 为中心 5×5 的局部区域; $I^u(q)$ 为对应颜色通道 u 内像素 q 的像素值. 计算每个超像素区域的暗通道为

$$S_d(c_i) = \frac{1}{|c_i|} \sum_{p \in c_i} S_d(p) \quad (4)$$

其中, $|c_i|$ 表示超像素区域 c_i 内的像素总数.

边界连通性表示为超像素区域到图像四周边界的最短路径距离除以各区域到所有区域的最短路径距离之和, 将此作为显著性度量构建背景概率和前景项以及平滑项的损失函数, 通过最小二乘法进行优化得到显著性区域 $w(c_i)$. 由此得到初始显著性图, 如图 4 所示, 其表达式为

$$M_I = S_d(c_i) \times w(c_i) \quad (5)$$

a. 输入图像 b. 真实区域 c. 初始显著图

图 4 初始显著性图获取

2.2 超像素区域特征描述

采用色彩去相关后的 RGB:PCA, Lab:PCA 和 HSV:PCA 这 3 种颜色特征、局部二值模式特征 (local binary pattern, LBP)、尺度不变特征转换 (scale-invariant feature transform, SIFT)、方向梯度

直方图 (histogram of oriented gradient, HOG) 特征和超像素区域到图像边界的测地距离 (geodesic distance, GD) 共 7 种特征可以全面地描述断面火焰图像的每个超像素区域. 其中, LBP 特征为描述图像局部纹理特征的算子, 在每个像素的 3×3 邻域内利用等价模式^[19]给每个像素分配一个 $0 \sim 58$ 的值. 利用文献^[20]方法提取像素级 SIFT 特征. HOG 特征和 GD 特征均是先计算各区域块的值, 然后赋值给块内所属像素点, 得到像素级的特征值.

综合上述 7 种特征的区域自身信息、区域方差和区域对比度^[21], 将三者合并为一个区域特征描述符 $x_{i,k}$, 表示为

$$x_{i,k} = [x_{i,k}^s, x_{i,k}^v, x_{i,k}^t] \quad (6)$$

其中, $x_{i,k}^s$ 表示区域自身信息, 通过计算超像素区域 c_i 内的全体像素平均值求得; k 表示特征数量 ($k=1, 2, \dots, 7$); $x_{i,k}^v = \sum_{q \in c_i} \|z_k - \theta_{i,k}\|^2 / |c_i|$ 表示区域方差, $\theta_{i,k} = \sum_{q \in c_i} z_k / |c_i|$, z_k 表示超像素区域 c_i 内像素点的第 k 种特征; $x_{i,k}^t$ 表示 3 种区域对比度的串联, 分别为局部区域、全局区域和边界区域; $x_{i,k}^t = \sum_{c_i \neq c_j} \exp(-\|\rho_i - \rho_j\|^2 / 2) \lambda_j D_k(c_i, c_j)$, ρ_i 和 ρ_j 表示 2 个不同超像素区域的几何中心; λ_j 表示超像素区域 c_i 的面积; $D_k(c_i, c_j)$ 表示 2 个超像素区域之间的空间距离.

2.3 基于支持向量多核 Boosting 辅助显著性模型计算

核学习的方法可以有效地解决分类和回归问题^[22], 传统方法通常使用支持向量机进行半监督学习. 由于单个分类器的分类性能存在局限性, Rakotomamonjy 等^[23]将多核学习框架与支持向量机相结合用于数据分类, 结果表明, 多核学习能大幅提高分类器的分类能力与精度. 多核 Boosting 算法^[24]首先利用不同特征的样本和多种核函数构建具有差异性的支持向量机作为单核弱分类器; 之后利用 Boosting 算法对单核弱分类器进行选择, 从而得到分类能力更强的多核分类器, 保证训练样本能够集中难以分类的样本并形成分类. 图 5 所示为本文采用支持向量回归器 (support vector regression, SVR) 构建断面火焰图像显著性检测模型.

本文将烧结断面火焰图像显著性检测视为回归问题, 利用基于支持向量回归的多核 Boosting 算法构建辅助显著性检测模型.

图 5 烧结断面火焰图像显著性检测模型流程

(1) 建立训练集 $\{x_i, y_i\}_{i=1}^{n_s}$. 其中, $x_i = \{x_{i,k}\}_{k=1}^{n_f}$ 表示超像素区域 c_i 的区域特征描述符; $y_i = \{\pm 1\}$ 表示该区域对应的显著性值, 用以区分图像前景与背景区域. 初始显著性图 M_1 的平均显著性值为 μ , 其中, μ_i 为超像素区域 c_i 的平均显著性值. 若 $\mu_i > 1.5\mu$, $y_i = 1$ 记为正样本; 若 $\mu_i < 0.05\mu$, $y_i = -1$ 记为负样本. 以 $\{K_m\}_{m=1}^{n_k}$ 表示核函数, 分别为线性核函数、径向基(radial basis function, RBF)核函数、Sigmoid 核函数和多项式核函数.

(2) 设置 Boosting 算法筛选单核 SVR 的迭代次数为 $J = n_f n_k$ ($n_k = 4, n_f = 7$). 构建包含 J 个 SVR 的集合 ξ , 原始训练集样本初始化权重为 $w_{i,k}^j = 1/n_s$ ($i = 1, 2, \dots, n_s, k = 1, 2, \dots, n_f$), 使用支持向量回归机 $h_{m,k}$ 对训练集进行回归学习, 根据多核 Boosting 算法, 在第 j 次迭代时的回归损失函数定义为

$$\varepsilon_{m,k}^j = \sum_{i=1}^{n_s} w_{i,k}^j \psi[\gamma] \quad (7)$$

其中, $\gamma = |h_{m,k}(x_{i,k})| - \frac{1.5}{n_s} \sum_{i=1}^{n_s} \|y_i - h_{m,k}(x_{i,k})\|^2$, 若 $\gamma > 0$, $\psi[\gamma] = 1$, 否则 $\psi[\gamma] = 0$; $w_{i,k}^j$ 为第 i 个样本在第 k 个特征上第 j 次迭代时的权重.

设置迭代条件 $\delta^j < 0.5$, 令 $\delta^j = \min_{h_{m,k} \in \Omega} \{\varepsilon_{m,k}^j\}$,

采用 Boosting 算法进行筛选后, 得到单核 SVR 的数量不多于 J 个. 选择最佳的 SVR 为 $H^j = \arg \min_{h_{m,k} \in \xi} \{\varepsilon_{m,k}^j\}$, 计算权重 $\beta_j = \frac{1}{2} \lg \frac{1 - \delta^j}{\delta^j}$, 更新样本的权重 $w_{i,k}^{j+1} = w_{i,k}^j \beta_j^{\{1 - \psi[\gamma]\}}$, 并对其进行归一化, 最终得到 SVR 输出为

$$F(x) = \sum_{j=1}^J \beta_j H^j(x) \quad (8)$$

本文方法使用多种特征对多个弱 SVR 进行训练, 保证多个回归器之间的差异性. 在使用 Boosting 算法获得强回归器过程中, 设定迭代条件的给定范围, 从上述训练过程中得到的 J 个弱分类器中挑选出分类效果最好的 n 个进行组合, 从而生成一个新的强 SVR. 本文在 4 个尺度对烧结断面火焰图像的所有超像素区域进行测试, 得到最终的辅助性显著性图

$$M_C = \frac{1}{4} \sum_{m=1}^4 M_{Cm} \quad (9)$$

由于初始显著性模型和辅助显著性模型具有互补性^[24], 初始显著性图包含断面火焰图像的细节和局部结构信息; 而辅助显著性图对大多断面火焰图像都能较好地聚焦全局形状, 因此可以通过加权整合这 2 种显著性图, 采用引导滤波^[25]使图像的轮廓边缘保持平滑, 2 种显著性图加权整合表示为

$$M = \sigma M_I + (1 - \sigma) M_C \quad (10)$$

其中, σ 表示二者整合的权重, 经多次实验, 取 $\sigma = 0.3$, 表示辅助显著性图的所占比重大于初始显著性图; M 表示通过多核支持向量回归 Boosting 算法得到的最终显著性图。

3 实验结果与分析

在 Intel Core i5-5200U 2.20GHz CPU 和 Windows7 64 位操作系统下, 采用 Matlab R2019a 编程实现了本文方法, 以评估该方法的检测效果。实验数据为 600 幅烧结断面火焰图像, 并提供人工

标注的像素级的分割结果。随机抽取 400 幅图像用于训练显著性检测模型, 剩余的 200 幅图像用于测试样本。

3.1 主观评价

图 6 所示为本文方法与其他 5 种显著性检测方法对于烧结断面火焰图像的检测效果的主观对比, 包括结合低水平线索的显著性检测方法(saliency filter, SF)^[10]、基于边界先验的显著性检测方法(manifold ranking, MR)^[11]、GS(geodesic saliency)^[12]、基于边界连通性与显著性优化的检测方法(weighted contrast, WCT)^[13], 以及结合自底向上的显著性模型与自顶向下的显著性检测方法(bootstrap learning, BL)^[26]。

图 6 6 种方法获得的显著性图主观对比

由于烧结断面火焰图像存在光晕、烟尘和光照不均等干扰因素, 采用 MR 和 GS 方法较难完整地获取实际火焰区域, 仍存在一定的光晕干扰, 如图 6b 和图 6c 第 7 行所示; SF 和 WCT 方法相比前 2 种方法可以有效地检测显著目标, 但对于一些面积较小和前景背景对比度接近的火焰区域, 仍存在漏检的问题; BL 方法不能有效地处理环境因素引发的前景与背景对比度低问题, 较难克服光晕干扰, 导致检测到的火焰显著区域较为模糊; 相比上述 5 种方法, 本文方法能克服环境干扰因素, 得到较为完整的显著目标, 轮廓较为清晰, 并保留烧结断面火焰区域的大量细节, 检测效果最优。

3.2 客观评价

为了进一步验证本文方法的有效性, 采用精准率 P 和召回率 R 曲线(precision-recall, P-R)、平均绝对误差值(mean absolute error, MAE)、阈值为 0~255 的所有 F -measure 的平均值 $F_{\beta_{avg}}$ 和阈值为 0~255 的所有 F -measure 的最大值 $F_{\beta_{max}}$ 对 6 种方法进行评价。

将显著图进行二值化时, 阈值设置为 0~255, 每取一个阈值, 即可计算一组相对应的 P 和 R , 将所有图像在该阈值下的 P 和 R 分别求平均值, 最终得到 256 对 P - R 值。以 R 为横坐标, P 为纵坐标绘制 P - R 曲线, 通过右上角的平衡点可判断显著

性检测方法的效果. 对不同显著性检测方法的检测效果进行对比, 如图 7a 所示. 本文方法中每个组成部分都参与了最终显著图的构建, 图 7b 所示为本文方法中每个阶段的性能, 即初始显著性图、初始显著性图+暗通道先验、初始显著性图+暗通道先验+色彩去相关、辅助显著性图和最终显著性图; 可以看出, 色彩去相关对显著性检测贡献最小, 但对本文方法整体性能提升也是必不可少的.

图 7 不同方法客观实验结果对比

表 1 6 种方法实验结果对比

方法	$F_{\beta_{avg}}$	$F_{\beta_{max}}$	MAE
SF ^[10]	0.9097	0.9469	0.0851
GS ^[12]	0.9221	0.9309	0.0829
MR ^[11]	0.8977	0.9597	0.0886
WCT ^[13]	0.9187	0.9507	0.0793
BL ^[26]	0.8341	0.9297	0.2154
本文	0.9326	0.9783	0.0738

注. 加粗字体表示每列最优结果.

表 2 所示为本文方法与 WCT, BL 这 2 种采用 Boosting 的检测方法处理单幅图像的运行时间对比.

表 2 3 种方法运行时间对比

方法	运行时间/s
WCT ^[13]	54.69
BL ^[26]	51.24
本文	49.67

注. 加粗字体表示每列最优结果.

本文采用 P - R 曲线与 F -measure 值评价模型的性能, 由图 7a 与表 1 可以看出, 本文显著性检测结果的 P, R 值较高于 SF 和 WCT 方法, 明显高于 MR, GS 和 BL 方法, F -measure 值也高于其他方法. 这是由于本文方法结合边界连通性与暗通道先验原理得到初始显著图, 并在此基础上, 利用基于支持

F -measure 对 P 和 R 进行综合, 表示非负权重下的加权调和平均数, 计算式为

$$F_{\beta} = \frac{(1 + \beta^2)PR}{\beta^2 P + R} \quad (11)$$

其中, 加权系数 β^2 通常取值为 0.3, 目的是增大 P 的比重. MAE 可用来衡量显著性检测结果与人工标注的真实区域之间的逼近程度^[9].

6 种方法实验结果对比如表 1 所示.

向量回归的多核 Boosting 算法构建辅助显著图, 能有效地提高显著区域的检测能力. 由表 2 可以看出, 本文方法处理单幅图像的运行时间优于另外 2 种采用 Boosting 的检测方法. 由图 7b 与表 3 可以看出, 通过分析本文方法每阶段的 P - R 曲线 F -measure 值, 得出各阶段检测性能逐步提高, 因此该方法各阶段都对最终显著性图获取做出一定贡献.

表 3 本文方法各阶段实验结果对比

方法	$F_{\beta_{avg}}$	$F_{\beta_{max}}$	MAE
初始显著性图	0.8056	0.9014	0.2453
初始显著性图+暗通道	0.9181	0.9469	0.1499
初始显著性图+暗通道+色彩去相关	0.9505	0.9654	0.1291
辅助显著性图	0.9586	0.9725	0.1134
最终显著性图	0.9651	0.9788	0.0859

注. 加粗字体表示每列最优结果.

4 结 语

传统的显著性检测方法通常基于图像的二维特征, 但对于包含光晕与烟尘干扰的烧结断面火焰图像特征提取较为困难, 无法完整地检测到显著目标. 本文提出一种基于边界连通性与多核 Boosting 算法的显著性目标检测方法, 首先在获取

初始显著性图的过程中利用色彩去相关原理,以提高初始显著性模型检测效果;然后采用基于支持向量回归的多核 Boosting 算法有效地集成具有代表性的特征及相应的核函数,并得到多个尺度下的辅助显著性图;最终通过加权得到高质量显著性检测结果.实验结果表明,该方法对烧结断面火焰图像表现良好,能有效地克服断面火焰图像中的干扰因素,相比其他几种方法准确率较高,为提取断面火焰图像有效特征奠定了基础.今后将考虑采用更多的图像特征并构建不同的特征描述符对辅助显著性图进行优化,并结合实际生产过程中的多种烧结情况,达到判断质量及烧结终点状态的应用需求.

参考文献(References):

- [1] Lin Xiao, Liu Zuxiang, Zheng Xiaomei, *et al.* Saliency detection based on improved manifold ranking via convex hull[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2019, 31(5): 761-770(in Chinese)
(林晓, 刘祖祥, 郑晓妹, 等. 基于凸包改进的流行排序显著性检测[J]. *计算机辅助设计与图形学学报*, 2019, 31(5): 761-770)
- [2] Bai Xiaojing, Lu Gang, Yan Yong. Flame image segmentation using multiscale color and wavelet-based texture features[J]. *Computer Engineering and Applications*, 2017, 53(9): 213-219 (in Chinese)
(白晓静, 卢钢, 闫勇. 基于多尺度颜色小波纹理特征的火焰图像分割[J]. *计算机工程与应用*, 2017, 53(9): 213-219)
- [3] Baswaraj D, Sree D S, Govardhan A, *et al.* An efficient autoadaptive edge detection approach for flame and fire images[J]. *International Journal on Computer Science & Engineering*, 2013, 5(9): 823-829
- [4] Cheng M M, Mitra N J, Huang X L, *et al.* Global contrast based salient region detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(3): 569-582
- [5] Yang J, Yang M H. Top-down visual saliency via joint CRF and dictionary learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 39(3): 576-588
- [6] Itti L, Koch C, Niebur E. A model of saliency-based visual attention for rapid scene analysis[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, 20(11): 1254-1259
- [7] Xie Y L, Lu H C, Yang M H. Bayesian saliency via low and mid level cues[J]. *IEEE Transactions on Image Processing*, 2012, 22(5): 1689-1698
- [8] Li Y Y, Wang L. Flame image segmentation algorithm based on motion and color saliency[C] //*Proceedings of the 8th International Conference on Communications, Signal Processing, and Systems*. Heidelberg: Springer, 2018: 184-191
- [9] Fu Lihua, Li Cancan, Cui Xinxin, *et al.* Saliency detection based on depth selective difference and background prior[J]. *Journal of Beijing University of Technology*, 2019, 45(9): 838-852(in Chinese)
(付利华, 李灿灿, 崔鑫鑫, 等. 基于深度选择性差异及背景先验的显著性检测[J]. *北京工业大学学报*, 2019, 45(9): 838-852)
- [10] Perazzi F, Krähenbühl P, Pritch Y, *et al.* Saliency filters: contrast based filtering for salient region detection[C] //*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2012: 733-740
- [11] Yang C, Zhang L H, Lu H C, *et al.* Saliency detection via graph-based manifold ranking[C] //*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2013: 3166-3173
- [12] Wei Y C, Wen F, Zhu W J, *et al.* Geodesic saliency using background priors[C] //*Proceedings of European Conference on Computer Vision*. Heidelberg: Springer, 2012: 29-42
- [13] Zhu W J, Liang S, Wei Y C, *et al.* Saliency optimization from robust background detection[C] //*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Los Alamitos: IEEE Computer Society Press, 2014: 2814-2821
- [14] Lin Xiao, Wang Yanling, Zhu Hengliang, *et al.* Saliency detection based on the Bayesian model of improved convex hull[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2017, 29(2): 221-228(in Chinese)
(林晓, 王燕玲, 朱恒亮, 等. 改进凸包的贝叶斯模型显著性检测算法[J]. *计算机辅助设计与图形学学报*, 2017, 29(2): 221-228)
- [15] Achanta R, Shaji A, Smith K, *et al.* SLIC superpixels compared to state-of-the-art superpixel methods[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(11): 2274-2282
- [16] Zeng Liling, Li Chaofeng. Multiple-kernel learning based object tracking algorithm with Boosting and SVM[J]. *Computer Engineering and Applications*, 2018, 54(13): 203-208(in Chinese)
(曾礼灵, 李朝锋. 结合 Boosting 方法与 SVM 的多核学习跟踪算法[J]. *计算机工程与应用*, 2018, 54(13): 203-208)
- [17] Schauerte B, Wörtwein T, Stiefelhagen R. Color decorrelation helps visual saliency detection[C] //*Proceedings of the IEEE International Conference on Image Processing*. Los Alamitos: IEEE Computer Society Press, 2015: 1965-1969
- [18] He K M, Sun J, Tang X O. Single image haze removal using dark channel prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(12): 2341-2353
- [19] Ojala T, Pietikainen M, Maenpää T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, 24(7): 971-987
- [20] Vedaldi A, Fulkerson B. VLFeat: an open and portable library of computer vision algorithms[C] //*Proceedings of the 18th ACM international conference on Multimedia*. New York: Association for Computing Machinery, 2010: 1469-1472
- [21] Zhou X F, Liu Z, Sun G L, *et al.* Improving saliency detection via multiple kernel boosting and adaptive fusion[J]. *IEEE Signal Processing Letters*, 2016, 23(4): 517-521
- [22] Lin Yining, Wei Wei, Dai Yuanming. General object categori-

- zation and recognition based on multi-kernel Boosting method[J]. Opto-Electronic Engineering, 2011, 38(10): 66-71 (in Chinese)
(林亦宁, 韦巍, 戴渊明. 基于多核 Boosting 方法的通用目标分类和识别[J]. 光电工程, 2011, 38(10): 66-71)
- [23] Rakotomamonjy A, Bach F, Canu S, *et al.* More efficiency in multiple kernel learning[C] //Proceedings of the 24th International Conference on Machine Learning. New York: Association for Computing Machinery, 2007: 775-782
- [24] Yang F, Lu H C, Chen Y W. Human tracking by multiple kernel Boosting with locality affinity constraints[C] //Proceedings of Asian Conference on Computer Vision. Heidelberg: Springer, 2010: 39-50
- [25] He K M, Sun J, Tang X O. Guided image filtering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(6): 1397-1409
- [26] Tong N, Lu H C, Ruan X, *et al.* Salient object detection via bootstrap learning[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2015: 1884-1892