

## 基于深度卷积网络的电熔镁炉欠烧工况在线识别

卢绍文<sup>†</sup>, 王克栋, 吴志伟, 李鹏琦, 郭 章

(东北大学 流程工业综合自动化国家重点实验室, 沈阳 110004)

**摘 要:** 欠烧是电熔镁炉熔炼过程中由于原料杂质不均匀导致炉壁局部过热的异常工况, 若不及时发现和处理, 可能导致炉体烧穿. 目前, 欠烧工况主要依靠有经验的巡检工人在电熔镁生产现场“看火”, 劳动强度大且危险性高, 容易漏检、误检. 鉴于此, 提出一种基于深度卷积网络的可见光 RGB 图像与红外热像相结合的电熔镁炉欠烧工况感知技术, 并基于此开发原型系统. 采用工业相机和红外热像仪获取电熔镁生产现场过程图像, 利用深度学习技术并结合现场工人经验建立对欠烧工况视频图像的检测和识别模型, 通过实时的图像分析, 实现对欠烧工况的在线识别. 将该技术在某氧化镁企业进行工业实验, 验证了所提出技术的有效性.

**关键词:** 电熔镁炉; 深度学习; 工况感知; 图像检测; 识别模型; 生成对抗网络

中图分类号: TP273

文献标志码: A

## Online detection of semi-molten of fused magnesium furnace based on deep convolutional neural network

LU Shao-wen<sup>†</sup>, WANG Ke-dong, WU Zhi-wei, LI Peng-qi, GUO Zhang

(State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110004, China)

**Abstract:** In the smelting process of fused magnesium furnace, semi-molten is the abnormal working condition that burns the furnace wall to red because of the uneven impurities in material. If it is not detected and dealt with timely, the furnace can be burnt through. At present, the detection of semi-molten mainly relies on experienced operators by “observing fire” at the scene of the fused magnesium production. The environment of scene is hostile and the working intensity is high. The human observation may cause safety issues and can lead to overlook and mistakes. This work introduces a detection technology for the semi-molten working conditions of fused magnesium furnace based on the deep convolutional neural network(CNN) model trained using historical images of visible and infrared thermal sensors. A prototype system is developed based on this technology. An industrial camera and an infrared thermal imager are used to acquire images of the fused magnesium productive process, and the deep learning technology is combined with the working condition of workers’ experience to build the detection and recognition model. With the system, on-line identification of semi-molten condition through real-time image analysis is achieved. The proposed technology is tested in a factory of electric-fused magnesium, which can demonstrate its effectueners.

**Keywords:** fused magnesium furnace; deep learning; working condition detection; image detection; recognition model; generative adversarial networks

## 0 引 言

电熔镁砂熔点高、抗氧化、耐腐蚀性强, 是一种优良的耐高温化工材料, 应用前景广阔, 在现代工业中有着举足轻重的地位. 我国电熔镁行业主要以菱镁矿为原料通过三相交流电熔镁炉熔炼再结晶进行生产制备<sup>[1]</sup>. 在熔炼过程中, 电弧产生的热量将不断加入的原料融化, 同时熔池上升, 通过观察显示仪表指示的电流, 不断调整电极升、降, 直到熔池到达炉口附

近才结束熔炼.

原料菱镁矿或轻烧镁砂在炉内熔炼的过程可分为: 起炉、加料、正常熔炼、排气、停炉、欠烧、排气异常等工况, 其中, “欠烧工况” 是一种炉壁局部过热烧红的异常工况, 其成因是由于原料杂质不均匀, 在某段时间部分原料燃烧不充分而没有完全达到熔融状态, 在炉内搅拌不均匀形成巨大气泡, 气泡内温度远高于熔液温度, 进而导致炉体温度局部过高, 引起炉

收稿日期: 2017-12-05; 修回日期: 2018-05-11.

基金项目: 国家自然科学基金项目(61473071).

<sup>†</sup>通讯作者. E-mail: lusw@mail.neu.edu.cn.

壁过热烧红.倘若未能及时处理,将导致炉壁烧穿,造成巨大经济损失,高温矿物熔液泄露还可能危及现场工人的安全.

目前,电熔镁炉欠烧工况的预警主要依靠现场工人的不间断巡检,以保证电熔镁炉正常运行.工人通过观察生产过程中炉口火焰的形态、亮度、火星,以及炉壁是否有过热烧红区域等特征,根据经验预先判断可能会发生的欠烧工况.人工巡检的主要问题是:1)工人巡检劳动强度大,且工况判别的准确性与现场工人的经验和状态相关,容易漏检、误检;2)现场生产环境恶劣(强光、高温、灰尘、噪声等),危险性高,不适于工人长时间现场巡检.因此,企业急需一种智能的欠烧工况识别技术,能够稳定、准确地在欠烧工况刚发生的时候预警,将人从这项工作中解放出来.

针对以上问题,本文提出一种基于深度卷积网络的电熔镁炉欠烧工况感知技术.采用工业相机和红外热像仪获取电熔镁生产现场过程图像,利用深度学习技术结合现场工人经验建立对欠烧工况视频、图像的检测和分类模型,通过实时的图像分析,实现对欠烧工况在线识别.此方法的优势在于:采取普通可见光RGB图像与红外热像图结合的方式,在所获得的视频、图像信息中增加了一维信息,增加了现场监控与工况分类可视化的信息量,提高工况感知的准确性.对于降低工人劳动强度、维护工人人身安全、提高电熔镁砂产品质量、增加经济效益有积极意义.

## 1 研究现状

对于复杂工业生产过程,工况感知是实现智能控制和优化决策的核心问题.目前,越来越多的工业生产过程中装备视频监控设备,使得发展基于可视化特征分析的工况感知技术提供了可能.工业过程的图像数据提供了相对直观的信息,传统的基于图像的工况感知技术主要采用从图像中提取底层或中层特征的方法,进而建立工况判别模型.但是,这类方法易受到工业过程多模态、动态时变的影响,导致其鲁棒性和识别精度较差.近几年,以深度学习为代表的新的智能感知技术取得突破,尤其是基于深度卷积网的图像理解技术在工业机器人特征提取、工业系统在线状态监测和诊断等领域以及故障检测、关键参数软测量等领域已经得到越来越多的应用.

电熔镁炉是一类较为典型的复杂流程工业过程.其生产过程包括多种工况,反映在图像上,表现出多模态、动态、高噪声等复杂特性.目前,电熔镁炉的工况识别主要通过电极电流、电压以及功率数据

的历史数据值建立工况判别模型,再通过实时采集的上述过程数据来判断电熔镁炉工况<sup>[2]</sup>,而欠烧工况主要需要依靠人的现场观察.这是因为欠烧发生初期,镁炉炉口的火焰或者炉壁具备区别性的可视化特征,这是判断电熔镁炉欠烧工况的直接依据.根据这些特征,本文将视频监控技术和工人“看火”的经验结合起来,对采集的视频、图像信息建立电熔镁炉欠烧工况的图像识别模型,实现基于监控视频的电熔镁炉欠烧工况的自动识别技术.与此同时,本系统在实现欠烧工况识别时仅需要前期的视频、图像采集过程,信息传输完毕则欠烧工况识别过程结束,直接在电熔镁炉熔炼监控视频中对欠烧工况进行识别和报警,实现端到端处理的过程.不仅提供满足用户需求的电熔镁炉欠烧工况感知技术,还满足实时、准确等性能需求.

## 2 关键技术

### 2.1 电熔镁炉工况定义与可视化特征

电熔镁熔炼过程是一个复杂的过程,不同的电热制度将导致不同的工况,生产出纯度不同、晶粒不同的产品.在熔炼过程中具有较明显可视化特征的工况主要有:起炉、加料、熔炼、欠烧工况<sup>[3]</sup>.首先经过起炉过渡到熔炼状态,加料与正常熔炼交替进行,欠烧作为异常工况一般发生在熔炼过程中.不同的工况在图像中具有不同的可视化特征.分别给出电熔镁炉具有较明显可视化特征的几种工况的典型图像如图1所示.



图1 电熔镁多种工况示意图

当起炉工况发生时,炉内生料会在瞬间熔化,炉口会因为电弧的产生忽然形成火焰(如图1起炉图所示),并在较短时间内进入到加料状态.

进入到加料工况后,会向炉内持续加入原料,熔炼产生的火焰会被新填入的原料遮挡,使炉口火焰和图像整体变暗,出现忽明忽暗的情况,且持续时间较长,如图1加料图所示.正常熔炼时炉口火焰和图像整体持续呈现较亮的状态,且在整个熔炼过程中持续时间较长,如图1正常图所示.

欠烧工况一般发生在熔炼过程中,是由于原料杂质不均匀,在某段时间部分原料燃烧不充分而没有完全达到熔融状态,在熔池内搅拌不均匀形成巨大气泡,进而导致炉体温度局部过高,引起炉壁过热烧红

而形成的危及经济与人身安全的一种异常工况. 根据长时间对电熔镁炉熔炼过程的观察,发现在发生欠烧工况时炉壁会持续出现因为局部过热而烧红的区域,如图1欠烧图所示.

### 2.2 关键问题及解决思路

**多源图像感知问题.** 工业图像RGB传感器受到电熔镁炉熔炼生产现场的高温、粉尘的环境的干扰,极易产生过曝、高噪声等问题,仅靠可见光相机采集电熔镁炉熔炼视频,并不能及时反映工况变化. 而红外热像仪所具有的无接触式、无损式以及可以获取不可见光信息的优点可以弥补这种不足<sup>[4]</sup>. 因此,本技术采用工业相机和红外热像仪搭建图像采集硬件平台,使本技术方案即使在电熔镁生产现场高温、粉尘、强光、浓烟的干扰下也会采集到效果较好的电熔镁炉视频图像,为进一步的图像特征提取、分析、建模起到关键作用.

**基于动态视频的工况感知建模问题.** 以往的电熔镁炉工况识别技术通过采集电流、电压、功率等数据信息对电熔镁炉熔炼过程进行建模以判别其加料和熔炼两种工况,主要采用频域法、时域法、神经网络等算法<sup>[5]</sup>,缺少从图像特征中提取的工况信息. 本技术采用动态视频作为主要的模型输入,在训练过程中,首先对熔炼视频进行分帧处理,然后在每帧图像中用卷积神经网络(CNN)<sup>[6]</sup>实现炉口火焰、炉壁欠烧、炉外火星以及背景区域的特征提取,进而建立电熔镁炉熔炼过程图像的检测和工况分类模型.

**电熔镁炉欠烧工况的样本生成问题.** 在深度学

习的模型训练中,比较关键的因素是训练样本的完整性,如果不同分类的样本不均匀,会导致训练模型不准确,影响整个系统的工况感知效果. 而电熔镁炉的欠烧工况是一种异常工况,发生的频率较低,并不具备大量的样本用于分类器的训练. 针对这一问题,本文采用深度卷积对抗网络(DCGAN)<sup>[7-8]</sup>,并基于TensorFlow<sup>[9-10]</sup>深度学习框架来建立欠烧工况的生成模型,用于合成欠烧工况的样本图像,提供训练样本的完整性和平衡性.

综上,本文提出的总体技术框架分为离线和在线两个部分. 其中,离线部分包括欠烧工况图片的样本生成和工况判别模型的离线训练,在线部分即为电熔镁炉熔炼过程视频、图片的在线测试,如图2所示. 总体技术路线为:

- 1) 通过图像信息采集模块采集电熔镁炉熔炼过程中现场工况的普通可见光与热红外视频、图像信息,传输至样本生成模块;
- 2) 样本生成模块对训练样本进行生成,将生成的图像和原样本图像融合并输入检测分类模块用于模型训练;
- 3) 检测分类模块通过相应算法对图像信息进行特征提取和处理,建立电熔镁炉熔炼过程图像的检测和分类模型;
- 4) 上位机模块运用后台检测分类模块建立的智能检测、分类模型,对新的测试视频在线处理,将感知信息和报警信息通过监控终端显示出来,实现电熔镁炉熔炼过程欠烧工况的感知功能.

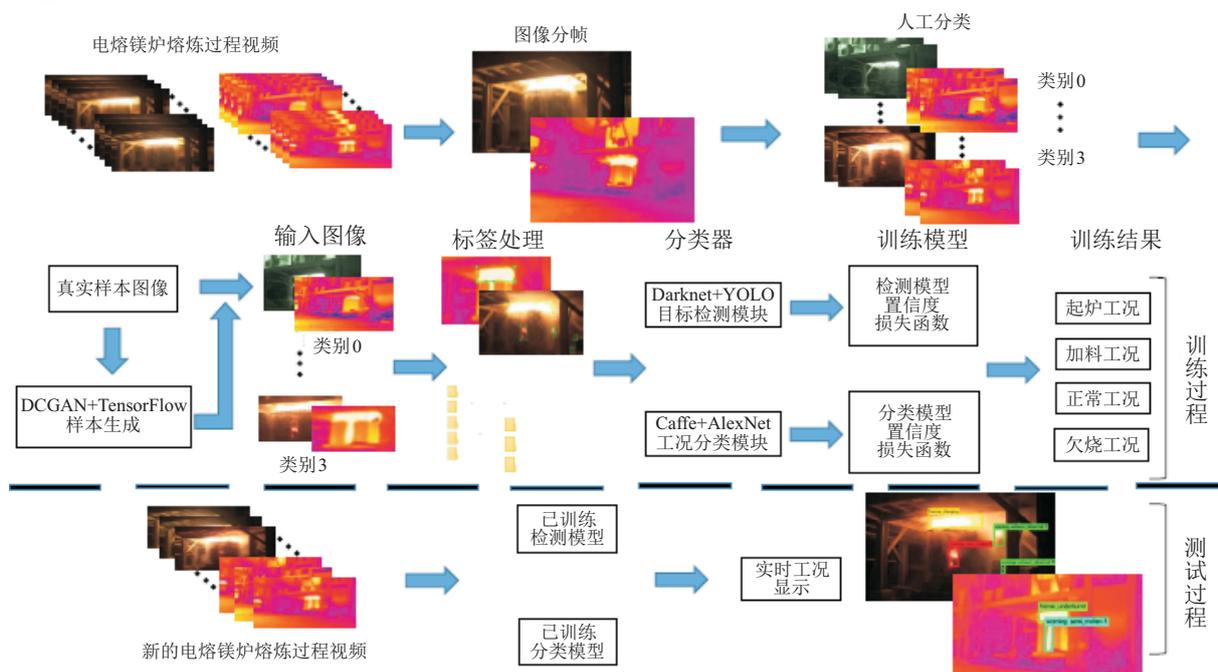


图2 系统实现的总流程

### 3 技术实现

#### 3.1 基于YOLO算法的关键可视化区域检测

本文利用YOLO目标检测算法<sup>[11]</sup>检测关键目标可视化区域,即炉口火焰区域、炉壁欠烧区域、炉外火星区域.YOLO算法将目标检测问题转换为回归问题,利用带有标记的关键区域图像信息和当前工况标记信息作为训练数据,用于建立候选对象区域的置信度模型.最后,采用Darknet<sup>[12]</sup>深度学习框架实现基于YOLO算法的电熔镁炉视频图像的关键可视化区域检测模块,如图3所示.

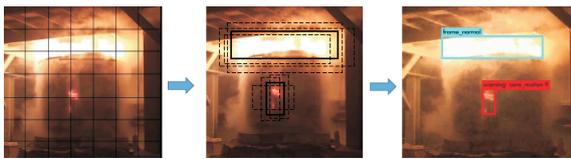


图3 基于YOLO算法的关键区域检测

YOLO回归网络采用简化了的GoogLeNet模型<sup>[13-14]</sup>.训练和在线检测过程中,以单张电熔镁炉的视频监控图像作为输入,将其划分为若干个区域,在输出层计算每个区域边框的坐标位置和归属置信度,并根据置信度重新分配边框权重.最后,设置阈值进行非极大值抑制处理,抑制冗余的框,只输出一个最优的检测结果.

算法具体实现:首先,将电熔镁炉熔炼过程图像分成 $S \times S$ 个网格.如果关键区域中目标(object)的中心落在这个网格中,则此网格负责预测此目标.每个网格要将所含目标边框的中心坐标 $(x, y)$ 、宽度 $(w)$ 和高度 $(h)$ 归一化到 $0 \sim 1$ 之间.该边框的预测置信度(confidence)代表框中含有目标的概率和预测的准确率两重信息,其值按下式计算:

$$\text{confidence} = \text{Pr}(\text{Object}) \times \text{IoU}_{\text{pred}}^{\text{truth}} \quad (1)$$

其中:如果有对象落在网格里, $\text{Pr}(\text{Object})$ 取1,

否则取0; $\text{IoU}_{\text{pred}}^{\text{truth}}$ 定义为边框与真实标记框ground\_truth的交叠面积比率,如下式所示:

$$\text{IoU}_{\text{pred}}^{\text{truth}} = \frac{\text{bounding\_box} \cap \text{ground\_truth}}{\text{bounding\_box} \cup \text{ground\_truth}} \quad (2)$$

此外,每个网格还要预测 $C$ 种被检测目标的类别,对于电熔镁炉熔炼过程中的工况分为4类:起炉、加料、正常熔炼、欠烧.输出数据共计 $S \times S \times (5 \times B + C)$ .

最后,对电熔镁炉视频进行测试,每个网格预测的类别信息和边框预测的置信度信息相乘,得到每个边框的特定类别的置信得分,有

$$\begin{aligned} &\text{Pr}(\text{Class}_i | \text{Object}) \times \text{Pr}(\text{Object}) \times \text{IoU}_{\text{pred}}^{\text{truth}} = \\ &\text{Pr}(\text{Class}_i) \times \text{IoU}_{\text{pred}}^{\text{truth}} \end{aligned} \quad (3)$$

其中: $\text{Pr}(\text{Class}_i | \text{Object})$ 为每个网格预测的类别信息, $\text{Pr}(\text{Object})$ 为每个边框预测的置信度的值, $\text{Pr}(\text{Class}_i) \times \text{IoU}_{\text{pred}}^{\text{truth}}$ 为预测的边框属于某一类的概率.这个乘积既表示了预测的边框属于某一类的概率,也有该边框的准确度信息.最后,在得到每个边框的特定类别置信得分后设置阈值,滤掉得分低的边框,对保留的边框进行非极大值抑制处理,得到最终的检测结果.

#### 3.2 基于AlexNet网络模型的工况分类

本文采用多层CNN建立电熔镁炉的工况分类器模型.模型的输入是电熔镁炉图像整体图像,提取图像整体亮度、颜色,局部特征目标(火焰、炉壁、背景)的可视化特征,用于工况分类模型.网络的结构采用AlexNet<sup>[15-16]</sup>,包括5个卷积层、3个池化层、3个全连接层,以及1个Softmax层用于多工况分类.本文采用AlexNet是由于其较好的深度特征提取能力和泛化能力,而且考虑到本文所建立的电熔镁炉工况模型总数有限(目前为起炉、正常、加料、欠烧4种),采用AlexNet足以满足本问题的规模.网络配置结构中各层的数据流如图4所示.

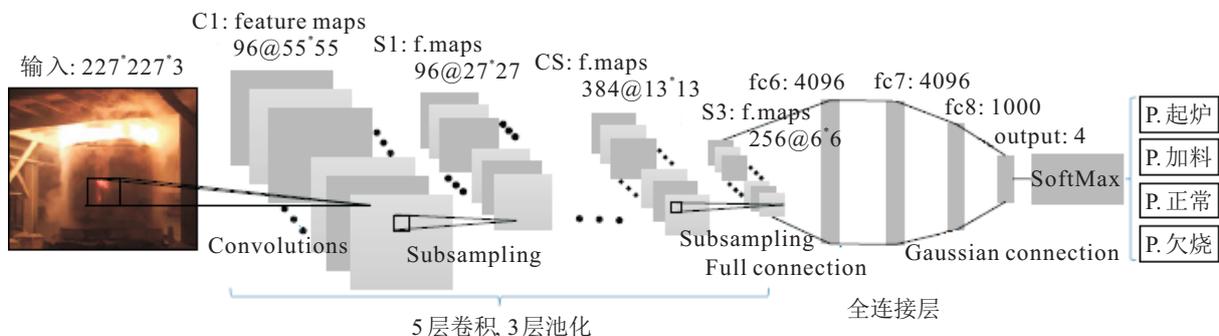


图4 AlexNet模型

CNN的特征提取层通过提取整张电熔镁炉熔炼过程图片的可视化特征并训练数据进行学习,所以在

使用CNN时,不会显示提取的特征,而隐式地从提取到的电熔镁炉熔炼图像的训练数据中进行学习(即

CNN在特征提取时,其具体提取的特征具有不可解释性). 由于对同一特征的神经元权值相同(权值共享),网络可以并行学习,其原理为

$$\begin{aligned} a_1^{(2)} &= f(W_{11}^{(l)}x_1 + W_{12}^{(l)}x_2 + W_{13}^{(l)}x_3 + b_1^{(l)}), \\ a_2^{(2)} &= f(W_{21}^{(l)}x_1 + W_{22}^{(l)}x_2 + W_{23}^{(l)}x_3 + b_2^{(l)}), \\ a_3^{(2)} &= f(W_{31}^{(l)}x_1 + W_{32}^{(l)}x_2 + W_{33}^{(l)}x_3 + b_3^{(l)}), \\ h_{w,b}(x) &= a_1^{(3)} = \\ &= f(W_{11}^{(2)}a_1^{(2)} + W_{12}^{(2)}a_2^{(2)} + W_{13}^{(2)}a_3^{(2)} + b_1^{(2)}). \end{aligned} \quad (4)$$

卷积神经网络有两个重要参数:权重( $W$ )和偏置( $b$ ),有

$$(W, b) = (W^{(l)}, b^{(l)}).$$

其中:  $W_{ij}^{(l)}$  为第  $l$  层第  $j$  单元与第  $l + 1$  层第  $i$  单元之间连接参数(权重);  $b_i^{(l)}$  为第  $l + 1$  层第  $i$  单元的偏置项;  $a_i^{(l)}$  表示第  $i$  单元的激活值(输出值),当  $l = 1$  时,即第  $i$  个输入值(输入值的第  $i$  个特征). 对于给定参数集合  $W$  和  $b$ ,网络根据函数  $h_{w,b}(x)$  计算输出结果.

本技术在 Caffe<sup>[17]</sup> 深度学习框架下建立 AlexNet 网络模型,利用 CNN 局部感知和权值共享的特性,对电熔镁炉熔炼过程工况图片进行特征提取、训练和

智能建模. 在测试过程中,利用训练完毕的工况分类智能模型,实现对单帧的整张电熔镁炉熔炼过程现场工况图像的感知,对最终欠烧工况的识别结果进行增强.

### 3.3 基于 DCGAN 网络的欠烧工况样本生成

本文采用深度卷积生成对抗网络(DCGAN)算法,用于对电熔镁炉熔炼过程中欠烧工况较少的图像做样本生成,增加欠烧工况图像,得到完整、平衡的训练样本(起炉、加料、正常、欠烧4种工况).

生成式对抗网络(GAN)<sup>[18-19]</sup> 有两个网络:  $G$  (Generator)和  $D$  (Discriminator).  $G$  是一个生成图片的网络,它接收一个随机的噪声  $z$ ,通过此噪声生成图片,记作  $G(z)$ .  $D$  是一个判别网络,判别图片是否“真实”. 其输入参数是  $x$ ,  $x$  代表一张电熔镁炉熔炼图像,输出  $D(x)$  代表  $x$  为真实图片的概率,如果值为 1,则代表 100% 是真实图片,输出为 0,则代表不可能是真实图片. DCGAN 的原理与 GAN 一样,将  $G$  和  $D$  换成两个卷积神经网络(CNN),其结构如图 5 所示. 本模块最终得到的是,生成图片网络  $G$  输出的让识别网络  $D$  不能辨出真假的生成电熔镁炉图片.

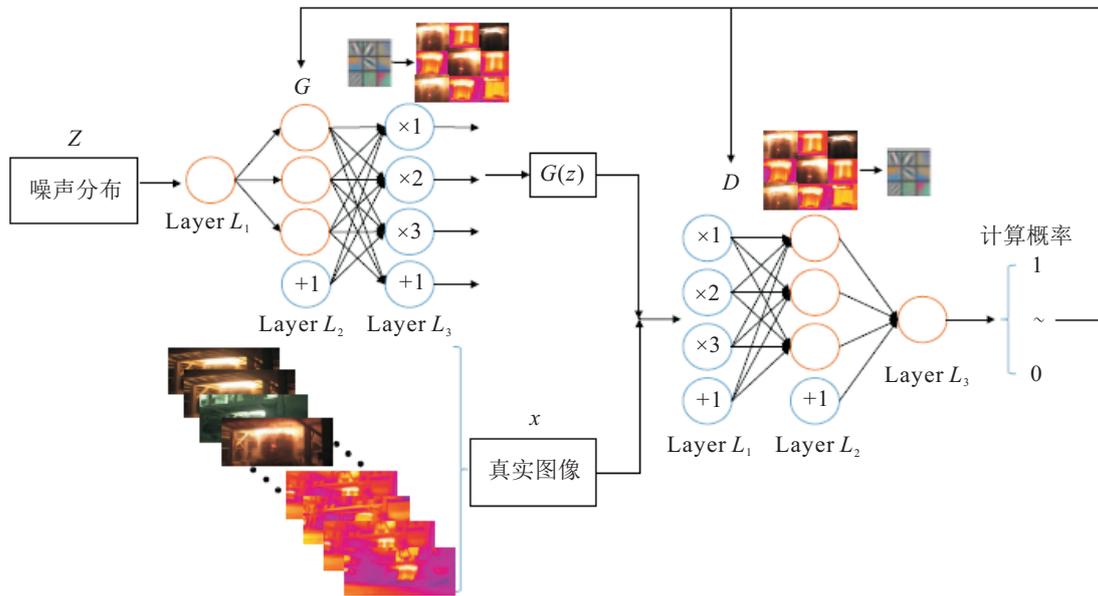


图 5 DCGAN 网络结构

在训练过程中,生成图片网络( $G$ )的目标是尽量生成看似真实的图片去欺骗判别网络( $D$ ). 判别网络( $D$ )的目标是尽量将网络( $G$ )生成的图片与真实图片进行区分和辨别. 这样, $G$ 和 $D$ 构成了一个动态的“博弈过程”. 在最理想的状态下, $G$ 可以生成足以“以假乱真”的图片  $G(z)$ . 对于  $D$  而言,它难以判定  $G$  生成的图片究竟是不是真实的,因此得到了一个生成

式的模型  $G$ ,可以用来生成图片,其核心原理如下所示:

$$\begin{aligned} \min_G \max_D V(D, G) = \\ E_{x \sim p_{\text{data}}(x)}[\log D(x)] + E_{z \sim p_z(z)}[\log(1 - D(G(x)))]. \end{aligned} \quad (5)$$

其中:  $z$  为输入网络  $G$  的噪声,  $G(z)$  为  $G$  网络生成的电熔镁炉图片,  $x$  为输入网络  $D$  的真实电熔镁炉图

片,  $D(x)$  为识别网络 ( $D$ ) 判断输入图片是否真实的概率,  $V(D, G)$  为判别网络和生成图片的网络博弈结果输出值,  $D(G(z))$  为识别网络 ( $D$ ) 判断网络 ( $G$ ) 生成的图片是否真实的概率. 其能力越强,  $D(x)$  越大,  $D(G(z))$  越小.  $G$  希望生成的图片“越接近真实越好”, 对于  $G$  而言,  $D(G(z))$  越接近 0 越好.

本模块在系统实现中采用 TensorFlow 深度学习框架在 Linux 系统中实现 DCGAN, 对欠烧工况较少的图像做样本生成, 增加欠烧工况图像, 最终得到完整、平衡的训练样本. 在此模块中, 衡量样本生成效果的两个指标分别为  $d\_loss$  (DCGAN 网络中识别图片网络的损失) 和  $g\_loss$  (DCGAN 网络中生成图片网络的损失), 最终的目标是最小化  $d\_loss$  和  $g\_loss$ , 从而生成“以假乱真”的电熔镁炉熔炼过程的样本图片. 对样本进行迭代 300 之后的  $loss$  为 0.081 07,  $g\_loss$  为 0.913 82. 迭代过程  $loss$  趋势如图 6 所示.

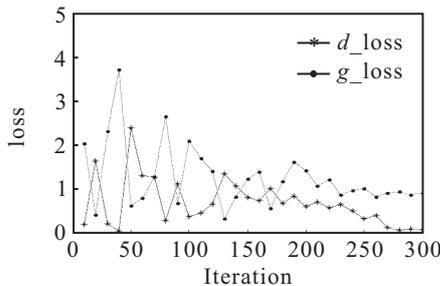


图 6 DCGAN 迭代过程 loss 趋势图

网络迭代 300 次后的电熔镁炉普通可见光和红外热像图样本生成结果如图 7 所示.

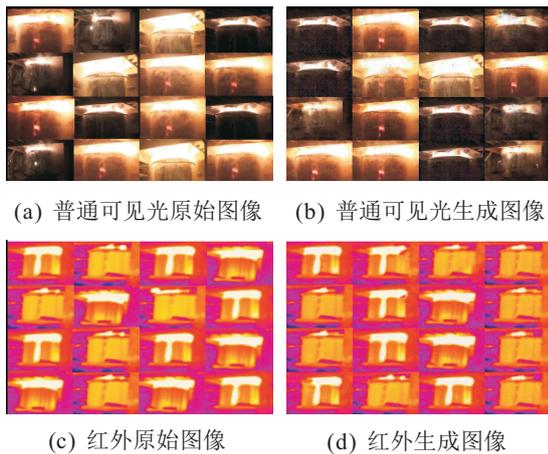


图 7 电熔镁炉图片生成效果图

### 4 实验结果

本文的目标是实现一种适用于电熔镁炉工业现场的欠烧工况感知技术, 将其应用在电熔镁炉欠烧工况在线识别领域. 从辽宁省某电熔镁炉工业现场采集监控视频共计 20 段, 每段时长约 30 min, 并进行工

况标记, 原始视频图像共计  $9 \times 10^5$  帧. 采用 DCGAN 方法合成样本, 得到样本数据共计  $2.7 \times 10^6$  帧. 选取其中 65% 作为训练集, 其余作为测试集.

本技术采用工业相机 + 红外热像仪搭建图像采集硬件平台. 由于传感器本身的成像特点及其在制造工艺上由于人工或者生产仪器所带来的内部误差, 造成其在采集电熔镁炉熔炼视频、图像信息时, 采集到的信息会与现实场景下的信息有一定偏差, 为保证采集的图像信息不失真, 需要对整个硬件设备进行标定. 本技术对前端用于可见光 RGB 信息、红外信息采集的相机标定效果进行验证, 利用“张正友标定法”<sup>[20]</sup> 对红外图像去畸变前后的效果如图 8 所示, 左图为未矫正畸变前, 右图为矫正畸变后.

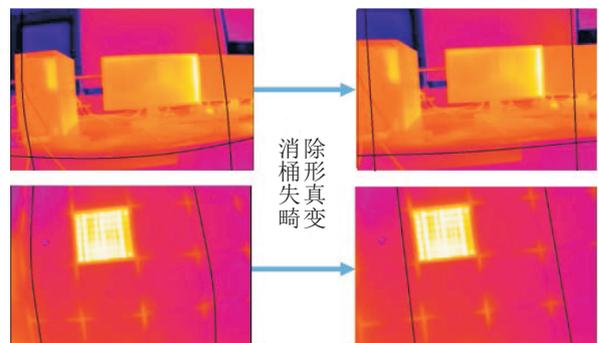


图 8 相机标定结果验证

传感器的输入图像分辨率为  $1920 \times 1080$ , 每一帧的数据处理量都十分巨大, 如果仅使用 CPU 进行顺序操作, 将耗费巨大的运算时间和内存在大量数据的处理与分析上. 本文采用 GPU 的并行计算特性进行加速<sup>[21]</sup>, 采用 NVIDIA GeForce GTX 850M GPU, 搭配 CUDA8.0 及配套 cuDNN8.0. 使得模型训练速度远超单独 CPU 平台.

在训练过程中, 衡量训练模型精度主要的两个参数为当前  $loss$  和验证集的  $accuracy$ . 为了训练得到最优的训练模型又不会出现过拟合现象, 最终的损失函数要接近于零. 训练过程中, 在初始学习率为 0.01 的情况下, 迭代 5 000 次对于验证集的精度和损失如图 9 所示. 最终验证准确度稳定在 98.6% 左右,  $loss$  降到  $10^{-5}$ .

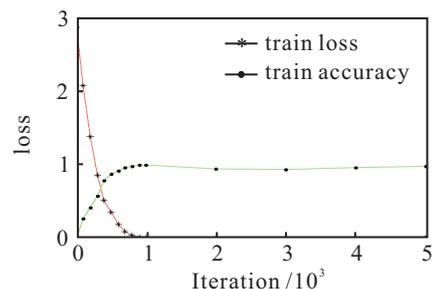
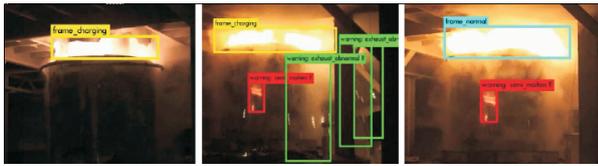
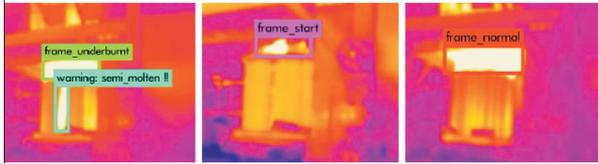


图 9 训练精度和损失趋势图

对电熔镁炉熔炼过程普通可见光和红外视频图像进行测试如图10所示。



(a) 普通可见光视频中的工况感知效果



(b) 红外热像视频中的工况感知效果

图 10 电熔镁炉视频图像工况感知效果验证

最后,基于Qt和C++设计并开发上位机监控终端,显示图像检测、识别结果,进行历史记录等功能,将检测到的信息截取出来,为进一步的图像特征分析做准备,如图11所示。

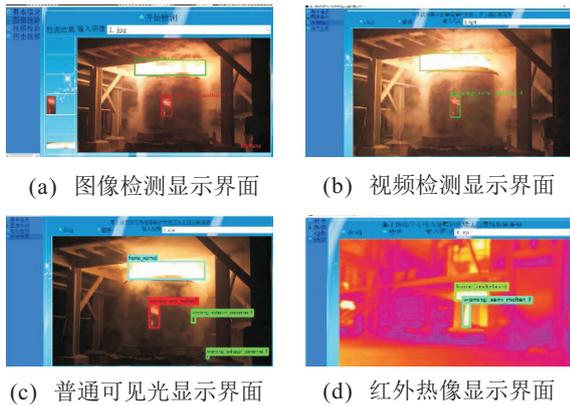


图 11 上位机监控终端显示界面

将本文所采用的基于深度卷积网络的工况判别技术与BP神经网络(BPNN)<sup>[22]</sup>、随机权神经网络(RWNN)<sup>[23-24]</sup>、支持向量机(SVM)<sup>[25]</sup>进行对比分析。每种分类器进行5次实验,计算5次实验的平均消耗时间并对电熔镁炉欠烧工况的感知精度进行对比,结果如表1所示。可以看出,相比于BPNN、RWNN和SVM,本文技术工况感知精度最高,而且由于本技术采用了GPU并行处理加速技术,在处理速度和实时性问题上也优于其他3类分类器。

表1 不同分类器识别结果的比较

分类器	时间/s	精度/%
BPNN	2.516	93.872
SVM	2.816	79.168
RWNN	0.862	64.974
不使用GPU	6.749	98.376
使用GPU	0.093	98.692

## 5 结论

针对电熔镁炉熔炼过程的工况特点,本文提出了一种基于深度卷积网络的普通可见光信息+红外热像信息的电熔镁炉视频中欠烧工况感知技术,并对本技术的硬件平台和软件算法进行了相应的介绍。在辽宁省大石桥市某电熔镁砂生产现场进行工业验证的效果表明,本技术能够有效实现电熔镁炉欠烧工况的在线自动识别,且能够用于类似工业监控的问题。随着深度学习技术的发展,将本技术用于实际工业生产具有非常广泛的应用前景和推广价值。

## 参考文献(References)

- [1] 李军, 宋伟. 电熔镁产业发展研究[J]. 冶金能源, 2010, 29(4): 8-10.  
(Li J, Song W. Research on the development of electro-melting magnesium industry[J]. Metallurgical Energy, 2010, 29(4): 8-10.)
- [2] 吴志伟, 柴天佑, 吴永建. 电熔镁砂产品单吨能耗混合预报模型[J]. 自动化学报, 2013, 39(12): 2002-2011.  
(Wu Z W, Chai T Y, Wu Y J. A hybrid predictio model of energy consumption per ton for fused magnesia[J]. Acta Automatica Sinica, 2013, 39(12): 2002-2011.)
- [3] 吴志伟, 柴天佑, 付俊, 等. 电熔镁炉熔炼过程的智能设定值控制[J]. 控制与决策, 2011, 26(9): 1417-1420.  
(Wu Z W, Chai T Y, Fu J, et al. Intelligent setpoints control of smelting process of fused magnesium furnace[J]. Control and Decision, 2011, 26(9): 1417-1420.)
- [4] 郭伟, 董丽虹, 徐滨士, 等. 主动红外热像无损检测技术的研究现状与进展[J]. 无损检测, 2016, 38(4): 58-66.  
(Guo W, Dong L H, Xu B S, et al. Research status and progress of active infrared thermographic nondestructive testing[J]. Nondestructive Testing, 2016, 38(4): 58-66.)
- [5] Wang D, Huang J. Neural network-based adaptive dynamic surface control for a class of uncertain nonlinear systems in strict-feedback form[J]. IEEE Trans on Neural Networks, 2017, 28(9): 2156-2167.
- [6] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [7] Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks[J]. Computer Science, 2016, DOI: arXiv:1511.06434.
- [8] Zhao D, Weng J, Liu Y. Generating traffic scene with deep convolutional generative adversarial networks[C]. Chinese Automation Congress. Ji'nan: IEEE, 2017: 6612-6617.
- [9] Abadi M. TensorFlow: Learning functions at scale[J].

- Acm Sigplan Notices, 2016, 51(9): 1.
- [10] Wongsuphasawat K, Smilkov D, Wexler J, et al. Visualizing dataflow graphs of deep learning models in tensorFlow[J]. IEEE Trans on Visualization & Computer Graphics, 2017, 24(1): 1-12.
- [11] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]. Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 779-788.
- [12] Bailey M, Cooke E, Jahanian F, et al. Practical darknet measurement[C]. Information Sciences and Systems, New Jersey: IEEE, 2007: 1496-1501.
- [13] Al-Qizwini M, Barjasteh I, Al-Qassab H, et al. Deep learning algorithm for autonomous driving using GoogLeNet[C]. Intelligent Vehicles Symposium. Redondo: IEEE, 2017: 89-96.
- [14] Zhong Z, Jin L, Xie Z. High performance offline handwritten Chinese character recognition using GoogLeNet and directional feature maps[C]. Int Conf on Document Analysis and Recognition. Narly: IEEE, 2015: 846-850.
- [15] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[C]. Int Conf on Neural Information Processing Systems. Lake Tahoe: MIT Press 2012: 1097-1105.
- [16] Ballester P, Araujo R M. On the performance of GoogLeNet and AlexNet applied to sketches[C]. The 30th AAAI Conf on Artificial Intelligence. Phoenix: AAAI Press, 2016: 1124-1128.
- [17] Jia Y Q, Evan Shelhamer, Jeff Donahue, et al. Caffe: Convolutional architecture for fast feature embedding[C]. Proc of the 22nd ACM Int Conf on Multimedia. Drlando: ACM Press 2014: 675-678.
- [18] Guo J, Lei B, Ding C, et al. Synthetic aperture radar image synthesis by using generative adversarial nets[C]. IEEE Geoscience & Remote Sensing Letters, 2017, 14(7): 1111-1115.
- [19] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[J]. Advances Conf on Neural Information Processing Systems. Montreal: MIT Press, 2014: 2672-2680.
- [20] Zhang Z. A flexible new technique for camera calibration[J]. IEEE Trans on Pattern Analysis & Machine Intelligence, 2000, 22(11): 1330-1334.
- [21] Ryoo S, Rodrigues C I, Baghsorkhi S S, et al. Optimization principles and application performance evaluation of a multithreaded GPU using CUDA[C]. ACM Sigplan Symposium on Principles and Practice of Parallel Programming. Salt Lake City: DBLP, 2008: 73-82.
- [22] Yin F, Mao H, Hua L, et al. Back propagation neural network modeling for warpage prediction and optimization of plastic products during injection molding[J]. Materials & Design, 2011, 32(4): 1844-1850.
- [23] Alhamdoosh M, Wang D. Fast decorrelated neural network ensembles with random weights[J]. Information Sciences, 2014, 264(6): 104-117.
- [24] 赵立杰, 李彬, 汪滢, 等. 磨机负荷参数快速去相关神经网络集成模型[J]. 控制工程, 2017, 24(9): 1952-1957.  
(Zhao L J, Li B, Wang Y, et al. Mill load parameter model using fast decorrelated neural network ensemble[J]. Control Engineering of China, 2017, 24(9): 1952-1957.)
- [25] Cherkassky V, Ma Y. Practical selection of SVM parameters and noise estimation for SVM regression[J]. Neural Networks, 2004, 17(1): 113-126.

### 作者简介

卢绍文(1977—), 男, 教授, 博士, 从事工业过程建模、仿真与可视化等研究, E-mail: lusw@mail.neu.edu.cn;

王克栋(1991—), 男, 硕士生, 从事工业过程建模的研究, E-mail: hualuo\_xinggun@163.com;

吴志伟(1982—), 男, 讲师, 博士, 从事嵌入式系统的研究, E-mail: wuzhiwei\_2006@163.com;

李鹏琦(1992—), 男, 硕士生, 从事图像处理的研究, E-mail: 1208708534@qq.com;

郭章(1992—), 男, 硕士生, 从事机器学习的研究, E-mail: 1162879518@qq.com.

(责任编辑: 郑晓蕾)