

基于卷积神经网络的CO₂焊接熔池 图像状态识别方法

覃科¹ 刘晓刚¹ 丁立新²

(1. 桂林航天工业学院 广西高校机器人与焊接技术重点实验室培育基地, 广西 桂林 541004;

2. 武汉大学 软件工程国家重点实验室, 武汉 430072)

摘要 为了通过熔池图像对焊接状态进行判断, 将卷积神经网络引入到 CO₂ 焊接熔池图像状态识别中, 提出了一种 CO₂ 焊接熔池状态识别卷积神经网络 CNN-M。该网络使用简单预处理的熔池图像作为输入向量, 避免了人工提取图像特征的主观性对识别率的不良影响。同时, CNN-M 采用了 ReLU 激活函数、随机 Dropout 及 SVM 分类器来降低样本集稀少可能导致的网络过拟合现象。试验结果表明, 和人工提取熔池特征状态作为输入向量的 BP 神经网络相比, CNN-M 在识别率及识别速度方面均体现出了更好的性能, 其良好的泛化能力能够满足在线熔池状态监控的要求。

关键词: 焊接熔池 卷积神经网络 状态识别

中图分类号: TG409

0 序 言

在机器人焊接过程中, 焊接熔池的状态信息能够直接反映焊接工艺的科学性和焊接质量的可靠性, 因此通过熔池图像特征来判断焊接质量的好坏一直是焊接工艺的研究热点。由于焊接过程是一个多参数耦合的随机时变过程, 因此有学者使用基于神经网络的方法研究焊接熔池形态并取得了一定的成果。文献[1]使用基于遗传算法改进的 BP 神经网络来建立焊接外观与激光焊接熔池阴影特征之间的关系模型, 提供了一种有效的方法, 来预测焊接外观和实时评估焊接质量。文献[2]通过观测熔池形态, 使用 BP 神经网络和 RBF 神经网络预测焊缝宽度, 为实现焊接质量在线监控提供了基础。文献[3]从熔池图像中提取熔池面积、熔池熔宽及熔池半长, 利用 ICA-BP 神经网络建立特征参数与熔透状态的关系模型, 对不同条件下的熔透状态进行预测。

目前, 大多数研究均使用 BP 神经网络或改进的 BP 神经网络, 从熔池图像中提取熔池特征参数, 将特征参数作为神经网络的输入向量, 来对焊接状态进行

识别。然而, 作为输入向量的熔池特征参数提取依赖于熔池图像的预处理及人的经验和主观意识, 若提取的特征参数出现偏差, 整个神经网络的性能及预测精度都会受到严重影响。

卷积神经网络(Convolutional Neural Network, 简称 CNN)是一种层与层之间局部连接的深度神经网络, 直接将图像作为输入向量, 把特征提取作为一个自适应、自学习的过程, 从而避免了传统识别算法中复杂的特征提取和数据重建过程^[4]。卷积神经网络中的特征提取和模式分类同时进行, 对图像的位移、缩放、倾斜及其它形式的扭曲变形都具有良好的鲁棒性, 已经成为当前图像识别领域的研究热点^[5]。基于卷积神经网络在图像处理方面的优秀性能, 文中使用 CO₂ 焊接熔池图像作为卷积神经网络的输入向量, 利用卷积神经网络对 CO₂ 焊接熔池图像状态进行识别, 并将其性能与人工提取熔池特征参数作为输入向量的 BP 神经网络性能进行对比。试验表明, 文中提出的方法在识别率及识别速度方面均体现出了更好的性能, 能够较好满足在线熔池状态监控的要求。

1 图像的获取与预处理

1.1 图像的获取

由于 CO₂ 焊接具有生产效率高且质量稳定的特点, 在国内外的企业生产中得到广泛应用^[6]。但由于

收稿日期: 2017-01-21

基金项目: 广西自然科学基金资助项目(2014GXNSFAA1183105, 2016GXNSFAA380226)

CO₂ 气体本身具有较强的氧化性,在焊接过程中会引起合金元素烧损,从而引起较强的飞溅,这使得通过电荷耦合元件(Charge - coupled Device,简称 CCD)采集到的熔池图像会受到飞溅、弧光及电磁场等随机因素的强烈干扰^[7]。

试验观察表明:CO₂ 焊接在短路阶段,电弧熄灭且很少产生飞溅,此时熔池受到的电弧和烟尘干扰最小;并且熔池表面温度下降,熔池图像灰度分布相对较稳定,有利于熔池状态的判定^[8]。因此,在焊接短路阶段采集熔池图像信息是最为理想的时刻。在文中所使用的焊接熔池图像获取方案中,利用 CO₂ 焊接短路周期与焊接电流变化的对应关系,通过电流传感器的转换得到与焊机工作电流相同变化频率的矩形脉冲波形,在熔滴短路阶段电流脉冲波形的下降沿产生触发,由触发器来控制高速工业相机的拍摄时刻,得到短路时刻的焊接熔池图像。高速工业相机配备窄带光学滤光片进一步抑制弧光干扰、提高图像信噪比。

1.2 图像预处理

在 CO₂ 焊接的短路阶段获取的熔池图像信息虽然能够剔除大多数的弧光、飞溅和噪声干扰,但仍然存在着小部分的飞溅和烟尘噪声。通过对比多幅带有飞溅噪声的图像后发现,每幅图像中飞溅的位置均不相同。若在焊接过程中熔池的成像位置相对不变,考虑使用高速工业相机能够使得图像的两次获得间隔时间 Δt 足够短,利用机器人学的微分运动理论,将两幅图像的

公共区域进行与运算,则能够去除飞溅噪声,保留有用的熔池图像^[9]。

为了加快熔池图像处理的速度,将图像中的熔池区域和背景区域进行阈值分割。由于图像中熔池区域和背景区域所占据的灰度级范围有较大差异,因此使用 Otsu 方法动态选取阈值。对于大小为 $M \times N$ 的图像 $I(x,y)$ 有:

$$g = \omega_1 \times \omega_2 \times (\mu_1 - \mu_2)^2 \quad (1)$$

式中: g 为熔池区域和背景区域的类间方差; ω_1 为熔池区域的像素点数占整幅图像的比例; μ_1 为熔池区域像素的平均灰度; ω_2 为背景区域的像素点数占整幅图像的比例; μ_2 为背景区域像素的平均灰度。

采用遍历方法得到使类间方差 g 最大的阈值 T , T 即为熔池图像熔池区域与背景区域的分割阈值。

2 卷积神经网络识别熔池状态

2.1 网络结构

卷积神经网络结构主要包括输入层、卷积层、采样层及输出层。多个交叠的卷积层和采样层负责提取输入层图像特征。输出层使用一层或两层全连接神经网络,根据提取的特征向量进行分类^[10]。

考虑到获取的熔池图像经过前期处理后特征相对明显、熔池形状相对简单,并且样本数据比较稀少的情况,文中采取的熔池图像状态识别的卷积神经网络 CNN - M 结构如图 1 所示。

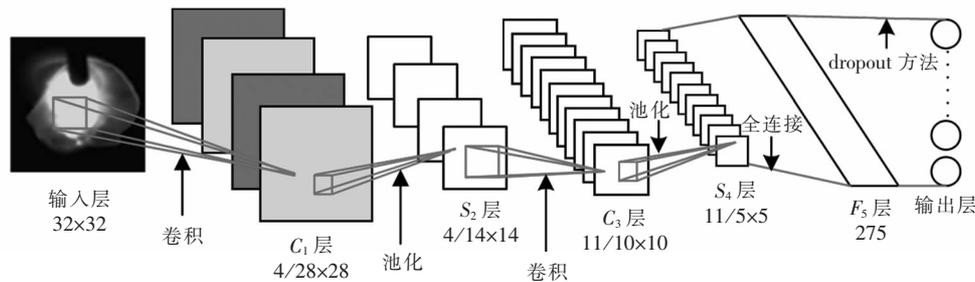


图 1 熔池状态识别的卷积神经网络结构

CNN - M 使用了 C_1, C_3 共 2 个卷积层及 S_2, S_4 共 2 个池化层对熔池图像进行特征提取,使用 F_5 层进行特征向量分类。前一层的特征图与自学习的卷积核进行卷积计算,计算结果经过激活函数输出,从而形成卷积层的特征图。卷积层的计算公式为

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} \times k_{ij}^l + b_j^l\right) \quad (2)$$

式中, l 为卷积层的层数; f 为激活函数; M_j 为上一层的一个输入特征图; b 为偏置; k 为卷积核即共享权重,此

处取 5×5 大小的模板。 k 与 b 初始化为随机值,通过网络训练调整至最佳。

池化层对卷积层获取到的图像特征进行下采样,在保留图像有效信息的同时减少计算量。池化层的计算公式为

$$x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l) \quad (3)$$

式中, l 为池化层的层数; f 为激活函数; $\text{down}(\cdot)$ 为下采样函数; β 为下采样系数; b 为偏置。 β 和 b 通过网络训练调整至最佳。

全连接层的计算公式如下:

$$x^l = f(W^l x^{l-1} + b^l) \quad (4)$$

式中, l 为当前层; W 为权值; b 为偏置。

考虑到样本数据相对稀少, 为了防止过拟合并减少计算量, f 使用 ReLU (Rectified Linear Units) 函数, 即 $f(x) = \max(0, x)$, 池化均采用 maxpooling 方式。

输入层图像经过归一化处理, 以 32×32 大小输入网络。 C_1 层为第一个卷积层, 由 4 个特征图组

成, 每个神经元与输入层图像的 5×5 邻域相连, 每个特征图大小为 28×28 。 S_2 层为第一个池化层, 由 4 个大小为 14×14 的特征图组成, 特征图的每个神经元与 C_1 层中相应特征图的 2×2 邻域相连进行下采样。 C_3 为第二个卷积层, 由 11 个大小为 10×10 的特征图组成, 特征图的每个神经元按照表 1 的方式与 S_2 层中若干个特征图的 5×5 邻域相连, 表 1 中 \times 代表选中。

表 1 S_2 层与 C_3 层特征图的连接方式

S_2 层	C_3 层										
	0	1	2	3	4	5	6	7	8	9	10
0	×			×	×		×		×	×	×
1	×	×				×	×	×		×	×
2		×	×	×			×	×	×		×
3			×		×	×		×	×	×	×

S_4 层为第二个池化层, 在 C_3 层的基础上进行下采样, 由 11 个大小为 5×5 的特征图组成。 F_5 层由 275 个特征值组成, 实际上 F_5 层也是一个卷积层, 每个特征值与 S_4 层的全部 11 个特征图的 5×5 邻域相连, 从而构成了 F_5 与 S_4 之间的全连接。

考虑到通过试验采集到的样本集状态, 输出层设置 3 个神经元, 分别对应焊接正常、焊偏及焊穿这三种常见的 CO_2 短路过渡焊接状态。输出层的每个神经元与 F_5 层进行全连接, 采用 SVM 分类器进行分类回归。SVM 通过寻求结构化风险最小来提高学习机泛化能力, 实现经验风险和置信范围的最小化, 从而能够在样本量较少的情况下获得良好的统计规律^[11]。

为了进一步减少样本数量稀少而导致过拟合情况出现的可能, 在 F_5 和输出层的全连接中使用随机 Dropout 方法, 如图 2 所示。Dropout 在网络训练过程中随机让某些隐含层的神经元不工作, 保留其值并将其

当前输出设置为 0。在下次训练过程中恢复这些神经元的值参与网络训练, 并再次选择部分神经元重复此过程^[12]。Dropout 使得网络在训练过程中, 每次用于输入网络的训练样本在权值更新时不再依赖于有固定关系隐含节点的共同作用, 防止出现某些特征仅仅在其它特定特征下才有效的情况, 从而避免网络对某种局部特征的过拟合^[13]。

2.2 网络训练

CNN - M 采用残差后向传播进行网络训练, 使用随机梯度下降对公式(2)中的卷积核 k 及偏置 b 、公式(3)中的下采样系数 β 及偏置 b 、公式(4)中的权值 W 及偏置 b 进行更新, 直至满足预设条件或达到迭代次数。

代价函数使用平方误差, 则包含有 N 个训练样本的 c 类问题代价函数为:

$$E^N = \frac{1}{2} \sum_{n=1}^N \sum_{k=1}^c (t_k^n - y_k^n)^2 \quad (5)$$

式中, t_k^n 为第 n 个样本对应标签的第 k 维; y_k^n 为第 n 个样本对应网络的第 k 个输出。网络训练的实质就是求代价函数最小值所对应的训练参数值, 即梯度 $\partial E / \partial k$, $\partial E / \partial \beta$ 及 $\partial E / \partial b$ 的计算。

对于全连接层 l , 其残差为:

$$\delta^l = (W^{l+1})^T \delta^{l+1} O f'(u^l) \quad (6)$$

式中, $u^l = W^l x^{l-1} + b^l$; O 表示每个元素相乘的运算。

对于卷积层 l , 其残差为:

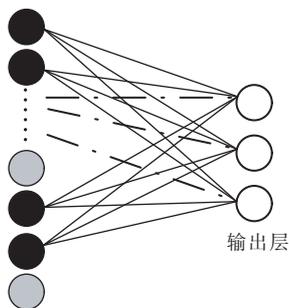


图 2 使用 Dropout 的全连接层

$$\delta_j^l = \beta_j^{l+1} (f'(u_j^l) \text{Oup}(\delta_j^{l+1})) \quad (7)$$

式中, $u_j^l = \sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l$; $\text{up}(\cdot)$ 为上采样函数, 将第 $l+1$ 层大小扩展为与第 l 层一样; β_j^{l+1} 为卷积层 l 后一池化层的下采样系数。

对于池化层 l , 其残差为:

$$\delta_j^l = f'(u_j^l) \text{Oconv2}(\delta_j^{l+1}, \text{rot}180(k_j^{l+1}), 'full') \quad (8)$$

式中, $u_j^l = \beta_j^l \text{down}(x_j^{l-1}) + b_j^l$; k_j^{l+1} 为池化层 l 后一卷积层的卷积核; $\text{conv}(\cdot)$ 为卷积运算; $\text{rot}(\cdot)$ 为翻转卷积核运算; full 卷积保证 $l+1$ 层神经元的输入为全尺寸的卷积核。

得到各层的残差表达式后, 即可求得每层的梯度, 从而对参数值进行调整^[14]。

3 试验结果与分析

3.1 试验数据

采集熔池图像的试验平台如图 3 所示, 焊枪与 CCD 相机固定相连, 使得 CCD 相机镜头位置与焊枪的运动路线保持一致, 从而保证在焊接过程中熔池的成像位置相对不变, 以便于对熔池状态的跟踪和判定。

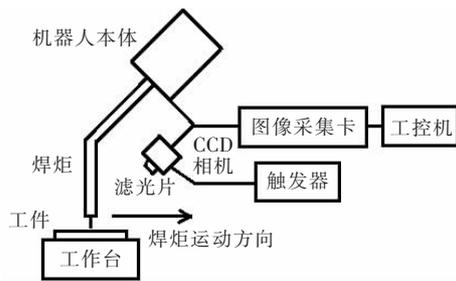
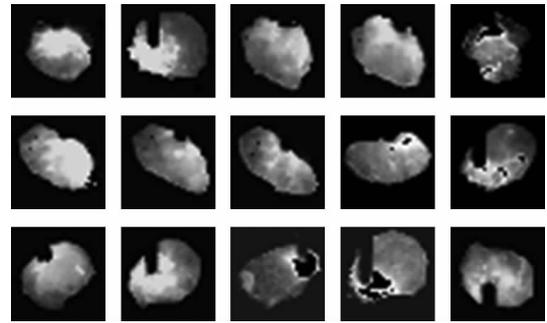
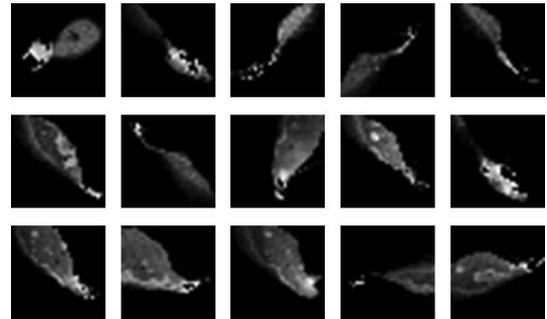


图 3 CO₂ 焊接熔池图像采集平台

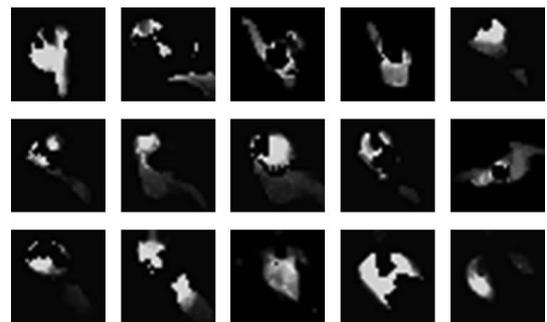
通过 CO₂ 焊接试验, 共采集到焊接正常状态、焊偏状态、焊穿状态的熔池图像各 300 张。网络训练过程中使用的样本集图片占图片总数的 65%, 并且从三种焊接状态图像中以平均分布的方式选取。测试集及验证集图片分别占图片总数的 25% 及 15%。为了进一步解决训练样本数量相对稀少所导致的过拟合问题, 选取样本集中 50% 的图片进行角度的旋转和亮度、对比度的调节, 从而生成新的训练样本, 来模拟在不同情况下的多态模式以训练网络, 增强网络的泛化能力。图 4 为样本集中的部分样本图片, 其中, 图 4a 为焊接正常状态部分样本图片, 图 4b 为焊偏状态部分样本图片, 图 4c 为焊穿状态部分样本图片。



(a) 焊接正常状态熔池图片



(b) 焊偏状态熔池图



(c) 焊穿状态熔池图片

图 4 样本集部分样本图片

3.2 试验结果及分析

采用文中所提出的卷积神经网络进行熔池状态识别。输入层为 32×32 大小的 BMP 格式灰度图像, 下采样系数 β 取常量 0.25, 网络学习率设置为 0.01, Dropout 随机设置 F_5 层中 10% ~ 30% 的神经元输出为 0。网络训练方式采用批处理随机梯度下降法, 每输入 50 个样本处理一次残差后向传播, 对参数权值进行调整。试验环境为 Window 10(64 bit) 操作系统, CPU 采用 Intel i7-5960X 八核 3.0GHZ, 32GB 内存, MATLAB2014a 软件平台。

为了检测 CNN-M 的性能, 文中使用 BP 神经网络与之进行识别率及识别速度的比较。BP 神经网络采用常用的三层结构, 隐含层取 400 个神经元节点, 网络学习率设置为 0.01。使用 Candy 算子提取预处理后熔

池图像的边缘信息,利用熔池的边缘信息计算熔池的长宽比、面积及复杂度,将这三个特征值作为 BP 神经网络的输入向量。熔池的复杂度定义为熔池周长平方与熔池面积的比值,比值越大,意味着熔池轮廓形状越复杂。

图 5 为 CNN-M 及 BP 神经网络在网络训练过程中的识别率曲线图。从图 5 中可以看到,CNN-M 在网络训练过程中的识别率和收敛速度均要优于 BP 神经网络。在迭代 300 次以后,CNN-M 的识别率能够达到 99.2%,而 BP 神经网络的最高识别率为 94.5%。图 6 为 CNN-M 及 BP 神经网络在网络检测过程中的识别率曲线图。从图 6 中可以看到,CNN-M 的识别率要远高于 BP 神经网络。迭代 300 次以后,CNN-M 的识别率能达到 95.8%,而 BP 神经网络的最高识别率为 83.1%。这是因为在 CO₂ 焊接过程中,焊偏状态及焊穿状态的熔池图像均为非规则形状,熔池边缘的提取偏差较大,会直接影响到熔池图像特征状态提取的准确性。而 CNN-M 直接将熔池图像作为输入向量,避免了特征提取的主观性及复杂计算,对于熔池状态的识别具有更高的准确率。从图 5 和图 6 可以看到,CNN-M 中使用的 ReLU 激活函数、随机 Dropout 及

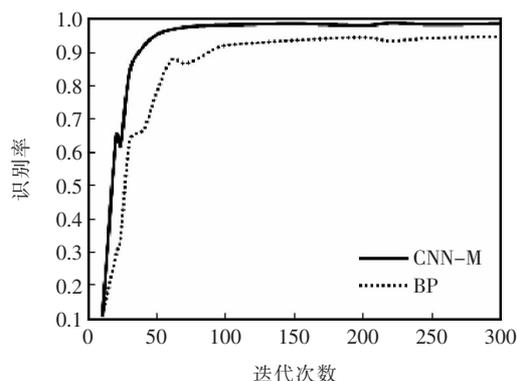


图 5 网络训练过程中的识别率

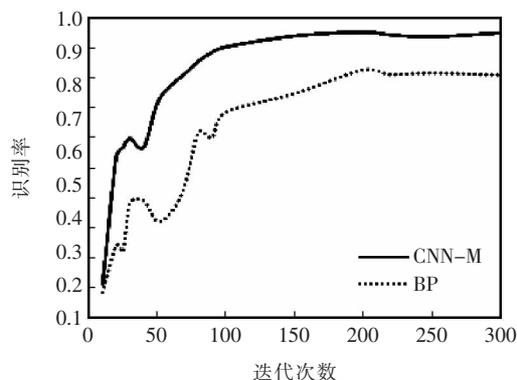


图 6 网络检测过程中的识别率

SVM 分类器有效抑制了样本集稀少可能导致的网络过拟合现象,使得 CNN-M 具有更好的泛化能力。

表 2 为 CNN-M 及 BP 神经网络对于图像识别速度的对比,识别速度以识别 100 张熔池图片状态所需时间来衡量。CNN-M 的识别速度明显优于 BP 神经网络,并且识别 100 张熔池图片状态仅用时 0.183 s,能够满足 CO₂ 焊接熔池状态的在线实时监控要求。

表 2 100 张熔池图像状态识别时间

网络类别	识别时间 t/s
CNN-M	0.183
BP 神经网络	0.547

4 结 论

(1) 提出了一种利用卷积神经网络 CNN-M 对形态复杂的 CO₂ 焊接熔池形态进行识别的方法。该方法将熔池图像经过简单的预处理后,直接作为输入向量,从而避免了对熔池图像特征提取的复杂计算和特征提取的主观性对网络识别率产生的不良影响。

(2) 试验表明,CNN-M 在网络的训练过程和检测过程中的识别率均要优于 BP 神经网络,在样本集稀少的情况下仍能够达到较高识别率和较快识别速度。

(3) 进一步的研究工作如下:①对 CNN-M 的结构与识别率之间的关系进行进一步研究,对不同数量的卷积层及全连接层的卷积神经网络进行试验,验证是否存在性能更好的 CO₂ 焊接熔池形态识别的卷积神经网络结构;②获取状态更丰富、分类更详细的 CO₂ 焊接熔池图像,扩展样本集及验证集熔池图片数量,以期能够通过设置更多的 CNN-M 输出层神经元对熔池状态进行更丰富的分类识别,并建立起熔池状态与焊接参数之间的关系。

参 考 文 献

- [1] Zhang Y, Gao X, Katayama S. Weld appearance prediction with BP neural network improved by genetic algorithm during disk laser welding[J]. Journal of Manufacturing Systems, 2015, 34: 53-59.
- [2] Gao Xiangdong, Zhang Yanxi. Prediction model of weld width during high-power disk laser welding of 304 austenitic stainless steel[J]. International Journal of Precision, Engineering and Manufacturing, 2014, 15(3): 399-405.
- [3] 林俊. 电弧焊熔透状态视觉检测模型研究[D]. 广州: 广东工业大学硕士学位论文, 2015.

- [4] 刘建伟,刘 媛,罗雄麟. 深度学习研究进展[J]. 计算机应用研究,2014,31(7): 1921 - 1942.
- [5] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks[C]. Advances in Neural Information Processing Systems, Curran Associates RedHook, NY, USA, 2012: 1097 - 1105.
- [6] 夏胜全,区智明,孙晓明. 一种降低 CO₂ 气体保护焊接能量输入的方法[J]. 焊接,2012(3): 32 - 35.
- [7] 向远鹏,曹 彪. 熔滴短路过渡频率对 CO₂ 焊接过程稳定性的影响[J]. 焊接,2010(12): 33 - 37.
- [8] 齐志龙,李 科,孙佳男,等. CO₂ 气体保护焊短路过渡熔滴尺寸的研究[J]. 焊接,2016(11): 34 - 37.
- [9] 刘晓刚,谢存禧,张昌年,等. 基于弧光反射的焊缝图像获取及图像处理[J]. 焊接学报,2008,29(4): 73 - 76.
- [10] 杨 钊,陶大鹏,张树业,等. 大数据下的基于深度神经网络的相似汉字识别[J]. 通信学报,2014,9(35): 184 - 189.
- [11] Khemchandani R, Pal A. Multi-category laplacian least squares twin support vector machine [J]. Applied Intelligence,2016: 1 - 17.
- [12] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing co-adaptation of feature detectors[J]. Computer Science,2012,3(4): 212 - 223.
- [13] Mendenhall J, Meiler J. Improving quantitative structure-activity relationship models using Artificial Neural Networks trained with dropout[J]. Journal of computer-aided molecular design,2016,30: 1 - 13.
- [14] Bouvrie J. Notes on convolution neural networks[R]. MIT CBCL,2006.

作者简介: 章 科,1979 年出生,硕士,讲师。主要从事图像处理、智能计算及其理论方面的科研和教学工作,发表论文 10 余篇。

基于压电执行器的 GMAW 焊接解耦控制方法及机理的研究

朱孝祥 刘 嘉 白立来

(北京工业大学 机械工程与应用电子技术学院,北京 100124)

摘要 采用基于压电执行器的焊丝回抽机构,结合以 DSP 为核心的控制系统,研究额外力对熔滴过渡的影响。通过焊接过程高速摄像,研究不同参数对熔滴过渡的影响。结果表明,采用基于压电执行器的焊丝回抽机构,可以给熔滴增加额外分离力,实现熔滴过渡;回抽时间越长,焊接电流越大,送丝速度越大,越容易实现熔滴过渡;焊接过程几乎没有飞溅;可以在电流较小时实现非短路过渡的熔滴过渡。

关键词: 压电执行器 回抽 熔滴过渡

中图分类号: TG444⁺

0 序 言

随着国内制造业的迅猛发展和焊接技术的不断进步,焊接技术得到了泛的使用,每年的焊接工程量巨

大,这对焊接效率和质量都提出了更高的要求。在诸多焊接方法中,熔化极气体保护焊(GMAW)具有生产效率高、焊接质量好、易于实现自动化焊接、可全位置焊接、节能等优点,成为高效化焊接方法的重要选择之一^[1-2]。GMAW 已应用到汽车、造船、航天等先进领域^[3]。尽管 GMAW 优势明显、应用广泛,并应用到一些先进制造领域,但其所占的比重并不大。这是由

收稿日期: 2017 - 01 - 16

基金项目: 国家自然科学基金资助项目(51375022)