

基于全卷积神经网络的焊缝特征提取

张永帅, 杨国威*, 王琦琦, 马雷, 王以忠

天津科技大学电子信息与自动化学院, 天津 300222

摘要 基于深层卷积神经网络的特征学习能力,提出了一种基于全卷积神经网络的焊缝特征提取方法。该方法利用全卷积神经网络将包含焊缝特征信息的像素预测出来,通过融合低层与高层特征信息来补充焊缝边缘的特征信息。研究表明:所提方法能在强烈弧光和烟尘干扰下准确地提取出焊缝位置,具有抗干扰能力强、识别准确的优点。

关键词 图像处理; 卷积神经网络; 焊缝跟踪; 自动焊接系统; 深度学习

中图分类号 TP242.2

文献标识码 A

doi: 10.3788/CJL201946.0302002

Weld Feature Extraction Based on Fully Convolutional Networks

Zhang Yongshuai, Yang Guowei*, Wang Qiqi, Ma Lei, Wang Yizhong

College of Electronic Information and Automation, Tianjin University of Science & Technology, Tianjin 300222, China

Abstract Based on the feature learning ability of deep convolutional neural networks, a weld feature extraction method based on fully convolutional networks is proposed. In this method, the fully convolutional networks is used to predict the pixels containing the feature information of the weld, and the edge feature information of weld is supplemented by the fusion of low-level and high-level feature information. The results show that the method can get the weld position accurately under the interference of strong arc and soot particles, and has the advantages of strong anti-interference ability and accurate recognition.

Key words image processing; convolutional neural network; seam tracking; automatic welding system; deep learning

OCIS codes 100.2650; 200.4260

1 引言

随着制造行业自动化进程的迅速发展,金属焊接成为生产过程中必不可少的环节。为满足自动化焊接生产的要求,需要实时获得焊接过程中焊缝的宽度、中心线等位置信息。基于激光视觉的焊缝跟踪已成为自动焊接领域的研究热点^[1-3]。激光视觉传感技术是将激光投射在焊缝表面,形成包含焊缝轮廓信息的焊缝条纹图像,然后进行特征分析。在焊接过程中,因为受到强烈弧光、飞溅、烟尘等的干扰,采集到的图像受噪声污染比较严重,难以准确定位,从而直接影响了焊接的质量。因此,在自动焊接过程中,准确获得焊缝位置信息变得尤为重要。

应用于焊缝激光特征提取的方法很多,有按

照目标和背景不同级灰度值分割的阈值法和灰度重心法,有提取目标边缘的边缘法和提取图像中心的几何中心法^[4],以及利用 Steger 算法求光条纹的像素位置等^[5]。南方等^[6]利用自适应阈值法提取条纹区域,通过随机霍夫变换与法线计算出光条纹区域的宽度,根据不同的宽度值分别设定参数进行 Steger 算法提取。霍平等^[7]先对滤波后的焊缝图像进行阈值分割,去除图像噪声,再用二值形态学进行边缘检测,通过对检测边缘的上下边界取平均值来提取光条纹的中心线。袁攀等^[8]针对 V 型焊接坡口的采集图片进行预处理,提出了一种两步式组合滤波的方法,并采用该方法去噪,对二值化后的图像进行卷积,再通过一种面积统计法去除剩余噪声。刘习文等^[9]通过对图像进行 Radon 变换来消除飞溅及

收稿日期: 2018-07-20; 修回日期: 2018-10-22; 录用日期: 2018-11-22

基金项目: 国家自然科学基金青年科学基金项目(51805370)、天津科技大学青年教师创新基金(2017LG08)

* E-mail: yangguowei@tust.edu.cn

弧光噪声,采用最大类间方差法(Ostu)提取除噪声后的激光条纹。雷正龙等^[10]提出了一种基于自动阈值的自适应中值滤波方法,该方法保护了条纹数据特征,减小了识别难度。工业现场复杂焊接过程引起的焊缝图像特征变化以及弧光等噪声对焊缝特征提取算法提出了更高的要求,使得焊缝特征提取算法研究从传统的单一的或特定的几何特征提取算法向具有广泛学习能力的多层次特征提取的智能学习算法方向发展,以提高焊缝特征提取的自适应性以及抗干扰能力。近年来,基于深度学习的目标提取方法开始应用于焊缝检测。邹焱彪等^[11]利用深度卷积神经网络特征的学习能力与表达能力,对含有焊缝信息的激光条纹进行提取,用相应的卷积核获得特征图,并采用非极大值抑制策略进行最终定位。该方法具有很强的畸变容忍能力,能够有效地提取焊缝位置。

本文提出了一种基于全卷积神经网络(FCN)^[12]的焊缝激光线特征提取方法,该方法将通过视觉传感器采集的投射到焊缝上的线激光图像作为训练集,去训练一个能够达到像素级分类的全卷积神经网络模型;用训练好的模型预测焊缝图片中每一个像素的所属类别,将焊缝特征提取出来,再采用反卷积策略恢复图像尺寸,从而实现了在受噪声污染严重的图片中准确地得到焊缝位置信息。该方法大大提升了抗干扰能力,保证了焊接质量。

2 全卷积神经网络

以传统卷积神经网络为基础提出的全卷积神经

网络能够做到每一个像素与它对应位置的像素点端对端的训练,实现像素级分类。受其启发,将其引入到焊缝的提取中,从大量样本中学习焊缝的激光线特征信息,实现焊缝像素级别的提取。

卷积神经网络的数据层一般是一个 $H \times W \times D$ 的三维数组,其中 H 为行, W 为列, D 为通道数。卷积神经网络具有平移不变的特性,输入图像在相应位置进行卷积、池化、激励等操作,记 $x^l \in R^{H^l \times W^l \times D^l}$ 表示三维输入集合 R 中的某一数据在卷积神经网络第 l 层的输入。 x^l 经过第 l 层操作处理后输出 y ,可以表示为

$$y = f_{ks}(x^l), x^l \in R^{H^l \times W^l \times D^l}, \quad (1)$$

式中: k 为卷积核大小; s 为步长或降采样因子; f_{ks} 为操作处理类型。全卷积神经网络只通过这样的操作层进行数据传递,与传统卷积神经网络最大的不同是没有全连接层。以本研究所基于的 VGG-net (该网络由牛津大学的 Visual Geometry Group 提出,并由此得名)^[13] 为例,VGG-net 采用多个小卷积层堆叠的方式,能够提取更深层的特征信息。全卷积神经网络将 VGG-net 最后三个全连接层表示为卷积层,如图 1 中虚线框所示。这样的转化使得网络可以接受任意尺寸的输入图像,不受全连接层的限制,同时又保留了空间信息,使得输出图像为二维分类图而不是一维标量,实现了输出映射与原始图像端对端的训练。图像经过多次卷积池化以后会降低像素的大小,为了将输出的特征映射维度还原为原始图像维度,对最后一层进行上采样操作。

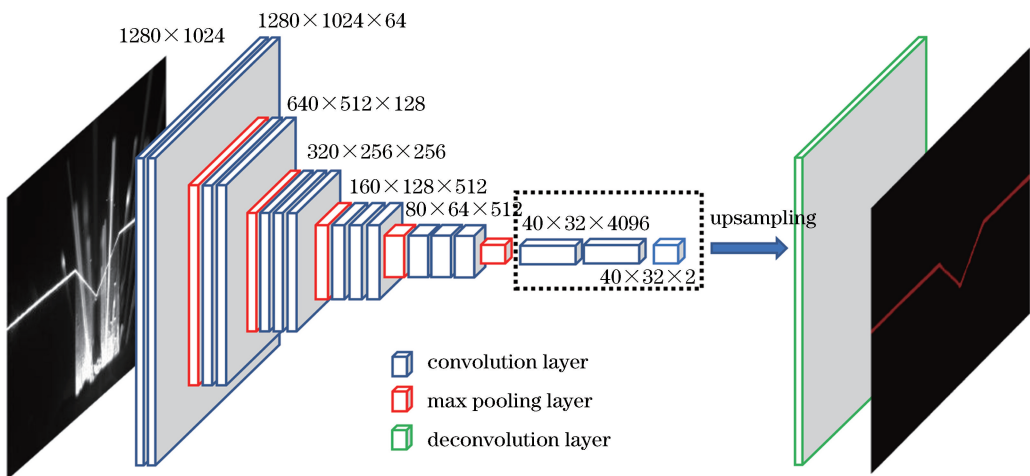


图 1 基于 VGG-net 的全卷积神经网络

Fig. 1 Fully convolutional networks based on VGG-net

上采样可通过插值的方法进行,如双线性插值法^[14],本研究是通过反卷积层实现的。反卷积操作

为卷积的逆过程,同样包括卷积核与步长等。图像经过 5 组卷积和池化以后,它的大小依次缩小为原

来的 1/2、1/4、1/8、1/16、1/32。对于最后一层的输出图像,需要进行 32 倍上采样的反卷积操作恢复到原来的大小,由此得到的图像称为 FCN-32s。在不断的卷积池化过程中,图像的特征信息会丢失很多,如边缘信息、目标位置等。焊缝特征提取要求能够提供准确的位置信息以及激光线的边缘特征,FCN-32s 的图像精度不能够满足需要。为得到更加精细的结果,利用卷积神经网络低层的感知也能够提供目标的更多具体细节这一特点,结合低层与高层输出进行了相加的特征融合。于是,在池化层 Pool4 后添加卷积核为 1×1 的卷积层来产生额外预测(为了使低层输

出与高层特征映射维度保持一致),与卷积层 Conv8 的特征映射图 2 倍上采样后进行特征融合,之后对特征融合图进行 16 倍上采样的反卷积操作得到 FCN-16s。同理,在池化层 Pool3 后添加卷积核为 1×1 的卷积层进行与上述类似的操作,得到 FCN-8s。通过进行特征融合补充局部细节特征,得到最终的焊缝提取效果图。由于进行更深的提取后,效果的提升也十分有限,所以不再进行下去。上采样与特征融合过程如图 2 所示,其中 Conv、Pool、Deconv 分别为卷积层(convolution layer)、池化层(pooling layer)、反卷积层(deconvolution layer)的缩写。

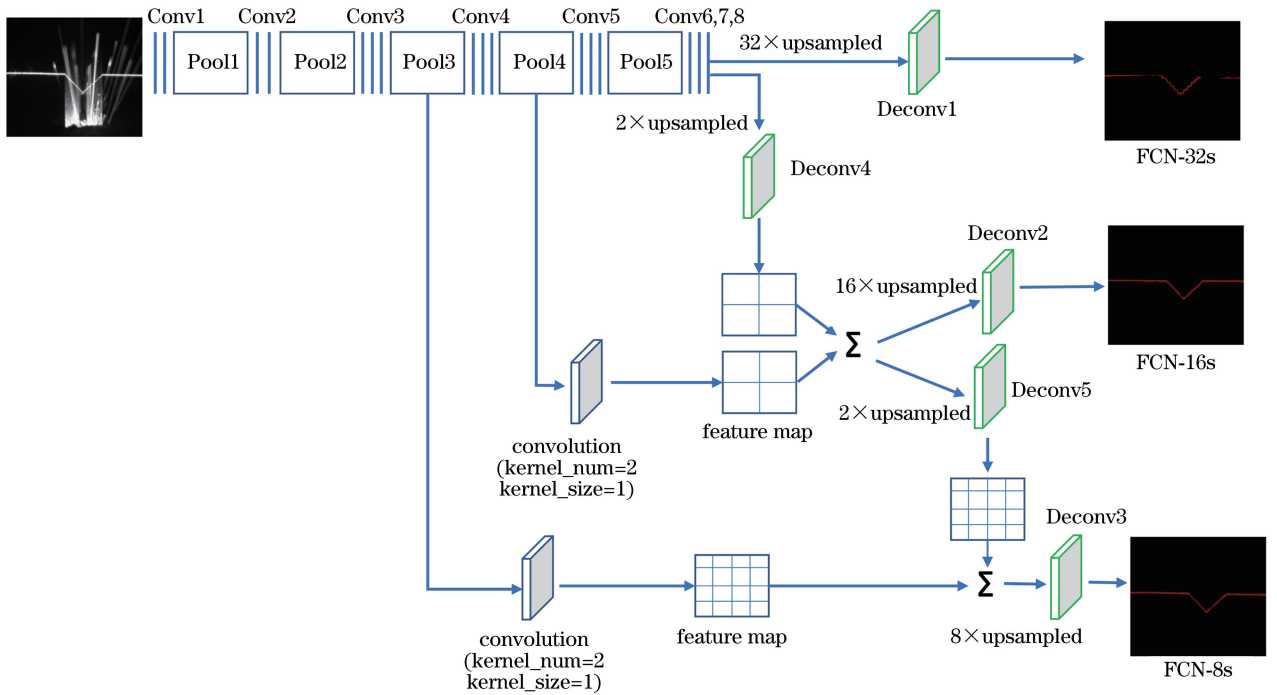


图 2 上采样与特征融合过程

Fig. 2 Process of upsampling and feature fusion

3 基于全卷积神经网络的焊缝提取

3.1 数据集准备

全卷积神经网络和传统卷积神经网络一样,是一个监督学习的过程,需要大量的训练样本,使用视觉传感器采集的原图与人工进行标注的分割图片对模型进行训练。数据集的获取是进行网络训练的前提。在大量的采集图像中选择具有代表性的图片进行训练,使网络模型能够提取不同的特征,具有更好的泛化能力。单一类型的图像训练出来的网络模型不能准确地从复杂图像中分割出焊缝位置。本研究针对的是 V 型坡口钢材,坡口顶端最宽为 25 mm,深度为 15 mm。焊接工艺为钨极惰

性气体保护焊,传感器内置 650 nm 线激光器,采集相机为 acA1280-60gm 相机,采集了 200 张焊缝图片(1280 pixel×1024 pixel),并在保证不影响原图焊缝特征的情况下,通过对图像进行翻转变换、平移变换等操作将数据扩充到 1000 张,涵盖了提取过程中焊缝的基本特征。采集的部分图像数据集如图 3 所示。

采集好图片后,另一个重要的环节是对采集的图片进行人工标注。这些图片本身没有标签,必须进行人工标注后才能用于监督训练。在获取的图片中,需要标注的类别只有两类,焊缝对应的颜色为红色,背景对应的为黑色。原图与对应的标注图如图 4 所示。




图 3 部分图像数据集

Fig. 3 Partial image datasets




图 4 (a)原图及(b)对应的标注图

Fig. 4 (a) Original image and (b) corresponding label image

3.2 全卷积神经网络模型参数

本研究所使用的全卷积神经网络如图 2 所示, 主要包含卷积层 (Conv1~Conv8)、最大池化层 (Pool1~Pool5) 以及 5 个反卷积层 (Deconv1~Deconv5), 均采用具有稀疏激活性的修正线性单元 (Relu) 作为激活函数。Conv1~Conv5 用堆叠的卷积方式, 每个卷积层后设置 1~2 个完全相同的卷积层堆叠。为防止过拟合, 提高模型的稳健性, 在 Conv6 和 Conv7 两层后加入 Dropout 层, 使一部分神经元的输出为 0, 不参与网络传播, 以提高泛化能力。此外, 为保持卷积前后的图像大小一致, 需要对图像周围做补零填充处理, 各层卷积核大小 (kernel)、卷积核移动步长 (stride)、补零填充层数 (pad) 的详细参数如表 1 所示, 由于网络层数较多, 将其部分层数进行合并表示。

3.3 全卷积神经网络模型的训练

本研究中基于全卷积神经网络的焊缝特征提取

是在 Caffe^[15] 深度学习框架上实现的。Caffe 深度学习框架提供了 Python 接口, 所提算法通过 Python 编程实现。本研究所使用的环境配置为 Ubuntu 16.04 操作系统, 内存为 32 GB DDR4, 显卡为 GPU TITAN XP, CPU E5-2640V4。

训练时, 采集的原图和对应的人工分割图片采用有监督的学习方式进行训练。本次实验将 1000 张数据集分为 750 张训练数据集和 250 张测试数据集。为加快模型的收敛速度, 采用预训练的策略进行参数微调。将在大规模含标签数据集 ImageNet^[16] 中训练好的 VGG16 网络模型作为预训练模型, 结合焊缝图像训练数据集训练好 FCN-32s 模型, 保存模型参数。用该参数作为 FCN-16s 的预训练模型和焊缝图像训练数据集再次训练 FCN-16s 模型, 依次递进, 得到 FCN-8s 模型, 以此加快收敛速度, 减少训练时间, 得到最终效果较好、精度较高的模型。本实验所有训练过程的训练参数

表 1 网络结构参数
Table 1 Parameters of network structure

Layer	Kernel (width×height×numbers)	Stride	Pad
Conv1	3×3×64,3×3×64	1,1	1,1
Pool1	2×2	2	0
Conv2	3×3×128,3×3×128	1,1	1,1
Pool2	2×2	2	0
Conv3	3×3×256,3×3×256,3×3×256	1,1,1	1,1,1
Pool3	2×2	2	0
Conv4	3×3×512,3×3×512,3×3×512	1,1,1	1,1,1
Pool4	2×2	2	0
Conv5	3×3×512,3×3×512,3×3×512	1,1,1	1,1,1
Pool5	2×2	2	0
Conv6-Conv8	1×1×4096,1×1×4096,1×1×2	1,1,1	0,0,0
Deconv1-Conv3	32×32×2,16×16×2,8×8×2	32,16,8	0,0,0
Deconv4-Deconv5	4×4×2,4×4×2	2,2	0,0

如下: 训练次数为 10000 次, 权重衰减系数为 0.0005, 确定的权值参数的学习率为 10^{-12} , 使用随机梯度下降法更新权值。训练结束后, 将训练好的权值参数保存在 caffemodel 文件中。为更好地衡量分割结果, 采用文献[12]中的评价标准, 用像素准确率(PACC)、平均准确率(MACC)和平均重叠率(MIU)三个指标来判定模型的分割精度。记 n_{ij} 为属于 i 类而被判为 j 类的像素点个数, n_{cl} 为类别总数(本研究只有焊缝与背景两类), $t_i = \sum_i n_{ij}$ 为属于 i 类像素点的总个数。定义像素准确率为

$$V_{PACC} = \sum_i n_{ii} / \sum_i t_i \quad (2)$$

定义平均准确率为

$$V_{MACC} = (1/n_{cl}) \sum_i (n_{ii}/t_i) \quad (3)$$

定义平均重叠率为

$$V_{MIU} = (1/n_{cl}) \sum_i n_{ii} / (t_i + \sum_j n_{ji} - n_{ii}) \quad (4)$$

在前面的模型介绍中有三种不同的上采样方式, 分别是 FCN-32s, FCN-16s, FCN-8s。三种不同上采样结构的训练结果如表 2 所示。

表 2 三种上采样结构的训练结果

Table 2 Training results of three upsampling structures

Network model	PACC /%	MACC /%	MIU /%
FCN-32s	99.2	89.9	81.3
FCN-16s	99.4	94.3	86.8
FCN-8s	99.5	97.4	87.7

由表 2 可知, FCN-8s 在这三个指标上都是最高的, 具有非常好的分割效果, 能够准确分割焊缝图片。图 5 是全卷积神经网络进行单次前向传播分割出来的效果图, FCN-32s, FCN-16s, FCN-8s 与标注图的对比结果表明: FCN-16s 与 FCN-8s 较为接近人工标注图; FCN-32s 提取的效果比较粗糙, 并且部分焊缝信息丢失; FCN-8s 通过特征融合补充边缘信息使提取结果连续、精细。




图 5 三种上采样结构的结果图与标注图。(a) FCN-32s;(b) FCN-16s;(c) FCN-8s;(d)标注图

Fig. 5 Results of three upsampling structures and label image. (a) FCN-32s; (b) FCN-16s; (c) FCN-8s; (d) label image

4 实验与分析

本实验采用 FCN-8s 网络模型进行测试, 读取采集的焊缝图像, 并输入到已训练好的全卷积神经网络中, 只通过前向传递方式输出提取结果。为了

能更好地体现出采用卷积神经网络进行焊缝提取具有更好的切割效果, 本次实验同时采用传统提取光条中心的方法(灰度重心法^[4]和 Steger 算法)进行焊缝提取, 并将提取效果进行对比。不同的焊缝提取方法的定性比较结果如图 6 所示: 图 6(a)~

(a4)为受噪声污染程度不同的焊缝原图,其中图 6(a4)为与图 6(a1)~(a3)不同类型的焊缝图像;图 6(b1)~(b4)为用灰度重心法提取的焊缝结果;图 6(c1)~(c4)为 Steger 算法的提取结果,图 6(d1)~(d4)为全卷积神经网络的提取结果。

提取结果显示:FCN-8s 能更好地从受弧光干扰的图像中提取焊缝特征;对于不受噪声干扰的图像,如图 6(a1),三种方法都能够分割出焊缝的位置,但是对于受弧光干扰比较严重的图像,如图 6(a2)、(a3)、(a4),灰度重心法和 Steger 算法受弧光干扰,提取的焊缝激光位置有噪声偏差。全卷积神

经网络具有深层学习能力,它通过不断训练学习激光线的特征信息,融合了焊缝图像多层次的特征,能准确获取整体焊缝的特征,同时在细节方面也具有很好的噪声抑制能力,提取效果和提取精度更好。在图 6(d3)所示的提取结果中,左侧边缘存在部分像素没有预测出来,出现断点,但这不影响 V 型焊缝拐点的提取,后续将从数据集和网络结构方面继续优化模型,以进一步改善提取结果。图 6(a4)为与图 6(a1)、(a2)、(a3)不同类型的焊缝图像,图 6(d4)所示的全卷积神经网络的提取结果验证了该方法的有效性,避免了训练时引起的过拟合。

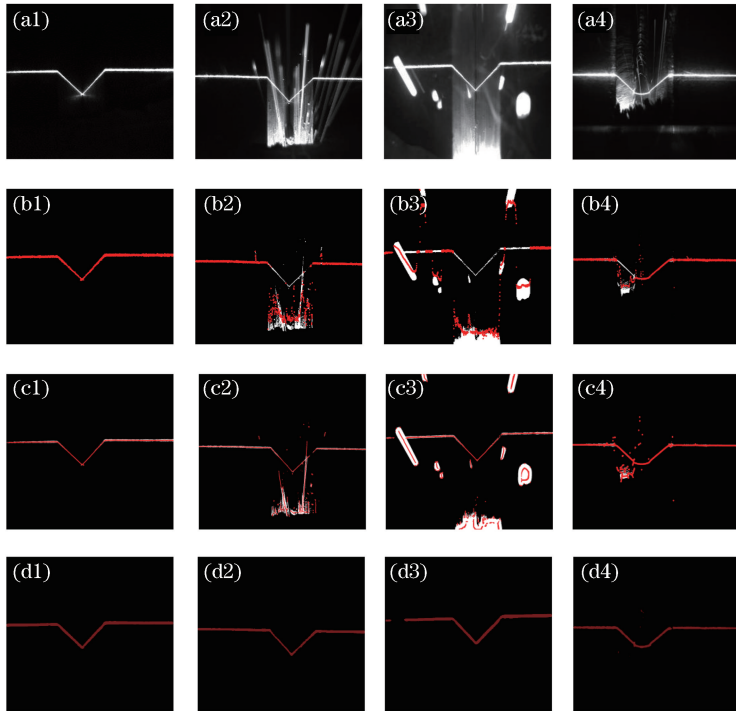


图 6 三种算法的提取结果。(a1)~(a4)焊缝原图;(b1)~(b4)灰度重心法提取的焊缝;(c1)~(c4) Steger 算法提取的焊缝;(d1)~(d4) FCN-8s 提取的焊缝

Fig. 6 Extraction results obtained with three different algorithms. (a1)-(a4) Weld original images; (b1)-(b4) welds extracted with gray gravity algorithm; (c1)-(c4) welds extracted with Steger algorithm; (d1)-(d4) welds extracted with FCN-8s

为了准确对比各个算法的提取结果,以人工标注图作为标准图,计算各算法提取的焊缝位置与标注图焊缝位置之间的均方根误差(RMSE),用 RMSE 来定量分析提取的效果,结果如表 3 所示。

从表 3 可以看出,FCN-8s 提取结果的总体 RMSE 远小于灰度重心法和 Steger 算法。为了更好地体现每列像素之间的差异性,本研究以图 6(a2)为例,计算每一列提取位置与标准图焊缝位置的误差,结果如图 7 所示。

从表 3 和图 7 可以看出,与灰度重心法、Steger

表 3 结果图与标注图在焊缝位置的 RMSE
Table 3 RMSE of weld position between results and label images pixel

Algorithm	RMSE for Fig.6(a1)	RMSE for Fig.6(a2)	RMSE for Fig.6(a3)	RMSE for Fig.6(a4)
FCN-8s	4.15	4.78	5.85	3.87
Steger algorithm	13.78	30.56	56.61	44.42
Gray gravity algorithm	13.53	35.01	60.18	47.96

算法相比,FCN-8s 的提取效果图相对于标准图的

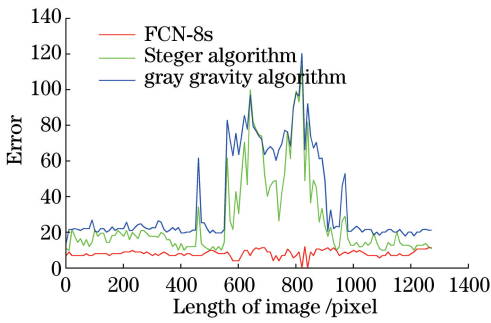


图 7 焊缝提取位置的误差曲线

Fig. 7 Error curves of weld position extraction

误差更小,更接近真值。全卷积神经网络具有深度学习的能力,融合了焊缝图像多层次的特征,能准确获取整体焊缝特征,具有良好的噪声抑制能力,在具有弧光干扰的实际焊接现场中具有一定的应用前景。

5 结 论

针对现阶段自动焊接系统易受环境因素干扰,焊接出现偏移的问题,结合深度学习技术,将深度卷积神经网络应用于焊缝的提取过程,研究了基于全卷积神经网络的焊缝特征提取方法,该方法解决了复杂噪声环境中焊缝定位不准确的问题,能够在强烈弧光、飞溅和烟尘等噪声情况下,准确地找到焊缝位置,提高了自动焊接系统的自适应能力。

另外,通过与传统激光线特征提取方法对比后可知,全卷积神经网络具有良好的抗干扰能力,焊缝提取精度较高,未来的研究工作将从数据集和网络结构方面继续优化模型,以进一步改善提取效果。

参 考 文 献

[1] Ping J, Zeng Y. Real time image processing for seam tracking based on laser stripe-sensor [J]. Applied Laser, 2010, 30(3): 232-235.
平津, 曾毅. 一种快速有效的基于激光视觉的焊缝跟踪实时图像处理方式[J]. 应用激光, 2010, 30(3): 232-235.

[2] Guo J C, Zhu Z M, Yu Y F, *et al.* Research and application of visual sensing technology based on laser structured light in welding industry [J]. Chinese Journal of Lasers, 2017, 44(12): 1200001.
郭吉昌, 朱志明, 于英飞, 等. 焊接领域激光结构光视觉传感技术的研究及应用[J]. 中国激光, 2017, 44(12): 1200001.

[3] Zhao J, Zhao J, Zhang L. Image processing and feature extraction for structured light images of

welded seam [J]. Journal of Xi'an Jiaotong University, 2013, 47(1): 114-119.

赵军, 赵继, 张雷. 焊缝结构光图像处理与特征提取方法[J]. 西安交通大学学报, 2013, 47(1): 114-119.

[4] Li J X. Weld tracking and inspection system based on structured light imaging [D]. Taiyuan: North University of China, 2017: 31-37.
李佳璇. 基于结构光成像的焊缝跟踪与检测系统[D]. 太原: 中北大学, 2017: 31-37.

[5] Hu K, Zhou F Q, Zhang G J. Fast extrication method for sub-pixel center of structured light stripe [J]. Chinese Journal of Scientific Instrument, 2006, 27(10): 1326-1329.
胡坤, 周富强, 张广军. 一种快速结构光条纹中心亚像素精度提取方法[J]. 仪器仪表学报, 2006, 27(10): 1326-1329.

[6] Nan F, Li D H, Gao Q, *et al.* Implementation of adaptive light stripe center extraction of improved Steger algorithm[J]. Laser Journal, 2018, 39(1): 85-88.
南方, 李大华, 高强, 等. 改进 Steger 算法的自适应光条纹中心提取[J]. 激光杂志, 2018, 39(1): 85-88.

[7] Huo P, Li J M, Zeng H L, *et al.* The real-time image processing V-shaped seam method based on a structure light[J]. Electric Welding Machine, 2014, 44(12): 144-148.
霍平, 李军萌, 曾翰林, 等. 一种基于结构光的 V 型焊缝实时图像处理方法[J]. 电焊机, 2014, 44(12): 144-148.

[8] Yuan P, Kong J Y, Ze S C, *et al.* The research on image processing method of V-shaped welding groove [J]. Machinery Design & Manufacture, 2017(6): 64-66.
袁攀, 孔建益, 仄士春, 等. V 型焊接坡口图像处理方法的研究[J]. 机械设计与制造, 2017(6): 64-66.

[9] Liu X W, Hong B, Dai T F. Image processing and groove recognition in weld seam tracking based on laser vision[J]. Laser & Infrared, 2011, 41(7): 804-807.
刘习文, 洪波, 戴铁峰. 激光视觉焊缝跟踪图像处理与坡口识别[J]. 激光与红外, 2011, 41(7): 804-807.

[10] Lei Z L, Shen J X, Li B W, *et al.* Recognition of narrow-gap edge welding seam based on autonomous threshold value [J]. Acta Optica Sinica, 2018, 38(8): 0815011.
雷正龙, 沈健雄, 黎炳蔚, 等. 基于自动阈值的窄间隙端焊缝识别技术[J]. 光学学报, 2018, 38(8): 0815011.

- [11] Zou Y B, Zhou W L, Chen X Z. Research of laser vision seam detection and tracking system based on depth hierarchical feature [J]. Chinese Journal of Lasers, 2017, 44(4): 0402009.
邹焱飏, 周卫林, 陈向志. 基于深度分层特征的激光视觉焊缝检测与跟踪系统研究[J]. 中国激光, 2017, 44(4): 0402009.
- [12] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [13] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. Computer Science, 2015(v6): 1409.
- [14] Hariharan B, Arbeláez P, Girshick R, *et al.* Hypercolumns for object segmentation and fine-grained localization [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 447-456.
- [15] Jia Y Q, Shelhamer E, Donahue J, *et al.* Caffe: convolutional architecture for fast feature embedding [C]. ACM International Conference on Multimedia, 2014: 675-678.
- [16] Deng J, Dong W, Socher R, *et al.* ImageNet: a large-scale hierarchical image database [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248-255.