

基于改进卷积神经网络的管焊缝 X 射线 图像缺陷识别方法

樊丁¹, 胡桢得¹, 黄健康¹, 徐振亚², 徐旭³

(1. 兰州理工大学, 省部共建有色金属先进加工与再利用国家重点实验室, 兰州, 730050; 2. 宝山钢铁股份有限公司, 上海, 201900; 3. 兰州兰石检测技术有限公司, 兰州, 730314)

摘要: 针对卷积神经网络 (CNN) 应用于焊缝探伤图像识别时, 目标区域占比小, 局部信息冗余, 激活函数小于零时出现硬饱和区导致模型对输入变化较敏感、网络参数难以训练的问题, 采用超像素分割算法 (SLIC) 和改进的 ELU 激活函数构建 CNN 模型进行焊缝探伤图像缺陷识别. 首先, 在 CNN 模型中使用 ELU 激活函数, 在缓解梯度消失时对输入噪声产生更好的鲁棒性, 同时, 利用 SLIC 算法对图像像素进行像素块处理的特点, 增大焊缝探伤图像中感兴趣区域的占比, 降低局部冗余信息, 提高模型在训练过程中的特征提取能力. 通过对焊缝探伤图像感兴趣区域提取并与所述 CNN 模型进行对比试验. 结果表明, 该方法在焊缝探伤图像特征提取、训练耗时及识别准确率方面较传统卷积神经网络有更好的表现.

关键词: 焊缝缺陷识别; 卷积神经网络; SLIC 算法; ELU 函数

中图分类号: TG 409 **文献标识码:** A **doi:** 10.12073/j.hjxb.20190703002

0 序言

在管道焊接中, 受焊接过程中各种参数稳定性的影响会产生各种缺陷, 主要分为外部缺陷 (咬边、焊瘤、塌陷等) 和内部缺陷 (裂纹、气孔、夹渣、未焊透等)^[1-2]. 工业生产中常采用射线检测技术对焊缝内部缺陷进行检测, 针对目前缺陷检测中出现的漏检、错检、低效等问题, 寻求一种焊接缺陷的自动检测与识别方法显得尤为重要, 可使缺陷检测高效、规范与智能化^[3].

卷积神经网络 (CNN) 不需要人工对目标图像进行特征描述和提取, 可通过神经网络自主地从训练样本中学习特征, 并且这些特征与分类器关系紧密, 这可以很好的解决了人工提取特征和分类器选择的难题, 利用其“端到端”的优势解决过去焊缝探伤图像缺陷识别中被认为难以解决的一些问题^[4]. 目前广泛使用的 CNN 模型是 Hubel-Wiesel 模型在经过简化之后的版本^[5], 对该模型的研究主要集中在算法改进^[6] 和结构改进^[7] 两方面. 通过算法改进的深度神经网络已在图像识别中取得了显著成果,

但其在卷积神经网络中还存在一些不足, 例如: 目标区域在图像中的占比较小, 导致目标图像中局部信息冗余, 在 CNN 训练过程中的冗余信息使计算数据和噪声增加, 对训练时间和拟合效果产生影响. 另外, 修正线性单元 (RELU) 作为非饱和激活函数, 在训练过程中存在神经元死亡现象, 当大梯度流过神经元并更新参数后, 神经元将不会再出现激活现象, 如果存在较大的学习率, 则会导致过量的神经元死亡, 在训练正确率方面产生影响.

针对以上问题, 采用改进指数线性单元 (ELU) 激活函数^[8] 的特征模型选择方法和超像素分割算法 (SLIC)^[9] 对焊缝探伤图像缺陷进行识别, 研究该算法和改进激活函数在焊缝探伤图像缺陷识别中有效性和正确率的影响.

1 基于改进 CNN 的特征选择方法

1.1 ELU 激活函数特性分析

对于传统卷积神经网络中出现的问题, 文中采用一种能够综合考虑激活函数饱和性的 ELU 非线性激活函数, 该激活函数能够融合 Sigmoid 和 ReLU 函数的优点, 在函数右侧保持无饱和性的同

时增加函数左侧的软饱和性,使得无饱和性部分能够在模型训练过程中缓解梯度消失现象,而软饱和性能够使模型对输入变化或存在的噪声更具有鲁棒性. ELU 函数表达式及函数图像分别为式(1)、图 1 所示.

$$\text{ELU}(x) = \begin{cases} x, & x \geq 0 \\ a(e^x - 1), & x < 0 \end{cases} \quad (1)$$




图 1 ELU 激活函数

Fig. 1 ELU activation function

通过对 ELU 函数的分析可知,卷积神经网络中采用该激活函数可以在缓解梯度消失的情况下增强 CNN 识别的鲁棒性.在传统 CNN 模型的基础上将 RELU 函数更改为 ELU 函数,其它网络层的数量及类型不发生改变.

1.2 SLIC 算法原理及应用

SLIC 算法可以将焊缝探伤图像由像素级转化为区域级,划分成超像素区域.其主要思想为:利用 LAB 颜色空间中的亮度分量和 2 个颜色分量以及 x, y 坐标组合为五维空间进行聚类.主要步骤如下.

- (1) 在已有图像中通过设置预定参数将图像像素划分为固定的像素块并计算像素块种子点坐标.
- (2) 利用种子点的 8 链码像素点计算获得最小梯度的像素值并将其作为新的种子点.
- (3) 遍历种子点后以 K-means 聚类方法对像素点进行聚类.
- (4) 通过变换的欧式距离计算像素点与种子点间的距离.

将 SLIC 算法应用于焊缝探伤图像中可减少图像中局部信息的冗余,通过迭代分割处理获得满足训练的图像.图 2 为经过像素块化的气孔缺陷图像,其中种子点数量为 30.

1.3 基于改进 CNN 的缺陷类型识别流程

综上所述,提出的基于改进卷积神经网络模型的焊缝缺陷类型识别流程如图 3 所示,将焊缝探伤图像进行常规图像预处理至满足卷积神经网络模



图 2 SLIC 算法迭代处理

Fig. 2 SLIC algorithm iterative processing

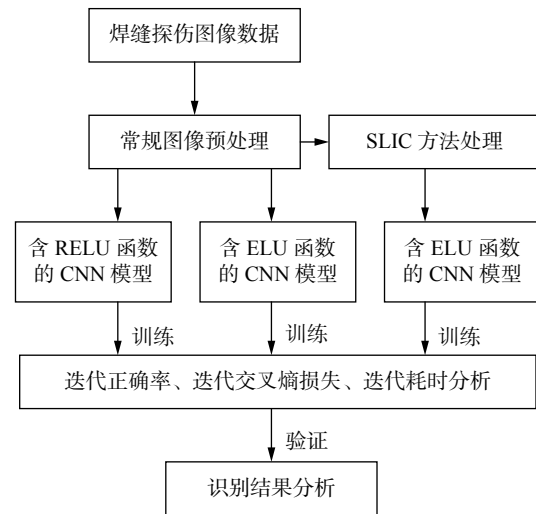


图 3 缺陷识别流程图

Fig. 3 Defect identification flowchart

型的输入要求,在此基础上对图像进行 SLIC 处理.通过构建含不同激活函数的卷积神经网络模型,并加载图像数据进行训练及验证,分析不同激活函数及预处理图像对训练及识别结果的影响.

2 CNN 模型构建与缺陷识别

2.1 改进 CNN 模型构建

对于卷积神经网络模型,根据输入层的大小可以适当的调节卷积神经网络的各连接层及深度,随着模型深度的增加,学习效果也越好,但是增加网络的深度会增加计算时间及训练数据量,在训练数据不充足的情况下也会增加过拟合的风险,因此在试验中增加网络层深度并不是网络模型的首选^[10].在建立卷积神经网络模型中有效地选择网络参数来获得具有最小层数的最大输出,通过连接各特征面的局部感受野,映射输入图像的原始像素以分层方式提取各层感受野范

围内的特征,并利用权值共享策略降低神经网络中的数据量,额外改变激活函数来减小模型的复杂度使网络更易于训练.为验证文中采用方法的有效性,分别构建名为 CNN-1, CNN-2 和 CNN-3 的模型, CNN-1 模型在 CNN-2 模型基础上将 E 层转换为 RELU 激活函数, CNN-3 模型对采用 SLIC 方法获得的图像数据进行训练,各模型构建方式如表 1 所示.

表 1 模型构建方式
Table 1 Model construction method

CNN模型名称	训练图像	激活函数
CNN-1	未进行SLIC处理	RELU
CNN-2	未进行SLIC处理	ELU
CNN-3	进行SLIC处理	ELU

通过构建不同 CNN 模型进行对比试验, CNN-1 与 CNN-2 模型试验以未进行 SLIC 处理的

图像为训练,利用不同的激活函数进行训练可验证文中采用 ELU 激活函数的有效性; CNN-2 与 CNN-3 模型试验均采用 ELU 激活函数,通过训练不同的焊缝探伤图像验证文中 SLIC 方法的有效性.其中 CNN-2 模型如图 4 所示, Input image 为输入层, C 为卷积层,卷积核的尺寸均为 5×5 ,深度依次为 6, 12, 16, 每层卷积层由若干卷积单元组成并利用反向传播算法最佳化获得卷积单元参数,通过提取输入的不同特征迭代提取更复杂的特征. N 为正则化,可对卷积结果进行约束. E 为 ELU 激活函数,通过 ELU 函数对计算结果去线性化. P 为池化层,其卷积核尺寸设定为 2×2 ,移动步长为 2,卷积层与池化层均使用全 0 填充. FC 为全连接层,通过两层全连接层将节点个数缩小至 60 个.因文中所设计的 CNN 待分类识别的缺陷类型为 4 类,故设置输出层 S 的个数为 4.

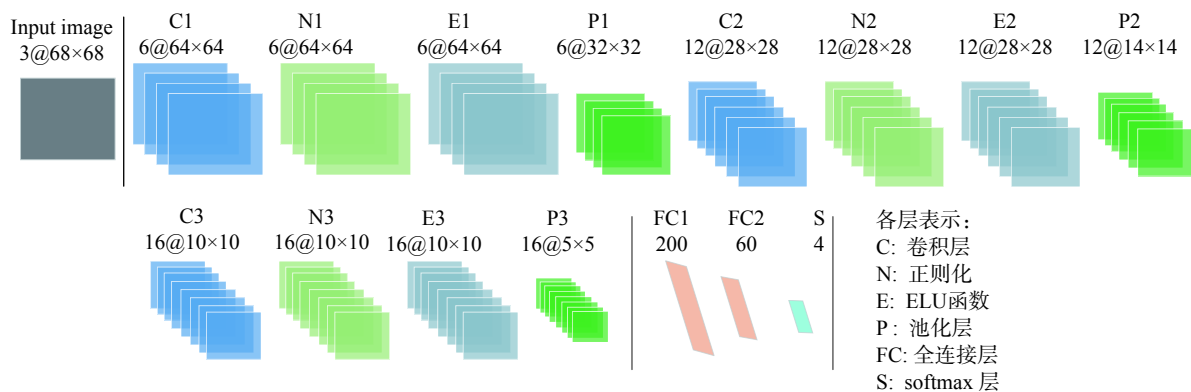


图 4 改进卷积神经网络模型

Fig. 4 Improved convolutional neural network model

2.2 焊缝探伤图像数据集概述

文中选用的焊缝射线探伤图像由两部分构成,一部分取自名为 GDxray^[11] 的公共数据库,另一部分由国内某焊接加工企业提供的管焊缝射线探伤图像.由于图像处理过程中所需的图像感兴趣区域较小,而焊缝探伤图像整体不感兴趣区域所占比例较大,采用整体图像进行训练难度较大.因此,在 CNN 模型进行训练前先进行图像预处理,根据焊缝探伤图像缺陷的类型和大小影响,截取焊缝中缺陷所在位置的 68×68 大小为感兴趣区域.为进一步增加焊缝探伤图像训练数据量,采用图像数据增强技术将原有的数据图像按 1:10 进行扩充,扩充后的焊缝探伤图像数据集中包含气孔图片 1 255 张,未焊透图片 200 张,未融合图片 75 张,无

缺陷图片 1 140 张,所有图像按 4:1 划分为训练集和验证集,图 5 为截取的部分焊缝缺陷图像.




图 5 部分试验图像数据

Fig. 5 Partial experimental image data

2.3 图像缺陷识别与分析

试验基于 Linux Ubuntu16.04 操作系统, Inter

(R) Core(TM) i5-2400 CPU @ 3.10GHz 处理器, 在 Tensorflow 框架下进行. 采用文中所提供的图像数据集对 CNN-1, CNN-2 及 CNN-3 模型进行 10 000

次迭代训练, 通过模型迭代可以获得其正确率及交叉熵损失变化如图 6 所示, 模型迭代耗时如表 2 所示.

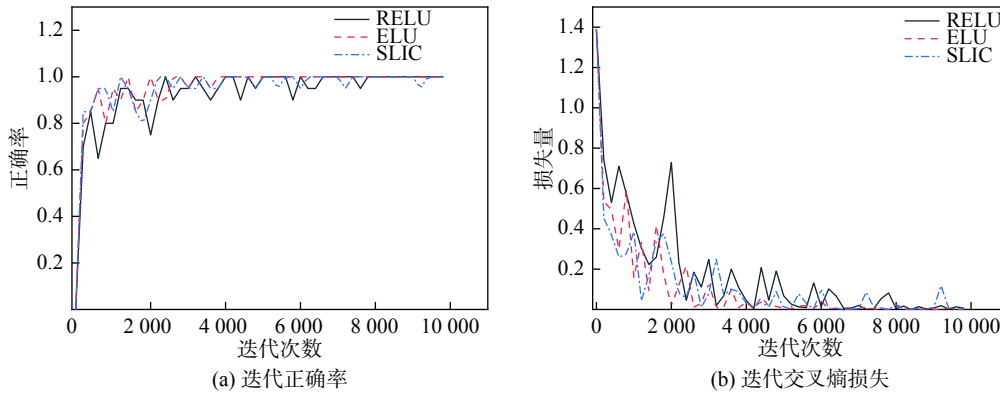


图 6 迭代正确率及交叉熵损失

Fig. 6 Iterative correct rate and cross entropy loss. (a) iterative accuracy rate; (b) iterative cross entropy loss

表 2 各模型迭代耗时
Table 2 Iteration time of each model

CNN模型名称	训练图像	激活函数	耗时减幅
CNN-1	未进行SLIC处理	RELU	0
CNN-2	未进行SLIC处理	ELU	1.07%
CNN-3	进行SLIC处理	ELU	12.87%

通过图 6 及表 2 分析可知: 在相同迭代次数下, 文中所使用的含有 ELU 激活函数的 CNN 模型收敛速度比 RELU 激活函数的 CNN 模型快, 在迭代前期的收敛速度相较 SLIC 方法处理焊缝图像的训练过程慢, 但迭代过程中的梯度变化程度较小. 根据不同模型在同等迭代次数下的时间比较, 含有 ELU 激活函数的 CNN 模型在迭代耗时上较 RELU 激活函数有所减少, 但减少时间有限, 而基

于 SLIC 方法的 CNN 模型迭代耗时较其它两种模型均有较大缩减, 减幅为 12.87%. 由此可以看出, 采用 SLIC 方法将焊缝探伤图像像素点进行像素块化, 减少了焊缝探伤图像的信息冗余, 有效减少了训练迭代耗时, 但该方法在像素块化的同时会放大噪声对训练过程的影响, 使其在训练后期的迭代过程中收敛效果变差. 而改进的 CNN 模型在输入变化或存在噪声时具有的鲁棒性相较于 RELU 激活函数表现更好, 在训练过程中能够保持网络的稀疏性, 同时减少神经元进入硬饱和区而降低迭代识别准确率的风险.

为进一步验证该模型在焊缝探伤图像识别中的有效性及可靠性, 另取部分焊缝探伤图像进行测试, 在测试结果中随机选取四种缺陷类别各 2 张并进行编号, 识别结果如表 3 所示.

表 3 焊缝探伤图像识别结果表
Table 3 Weld flaw detection image recognition result table

测试样本	CNN-1分类及识别结果	CNN-2分类及识别结果	CNN-3分类及识别结果
1号无缺陷	(0.997, 0.002, 0.000, 0.000)	(0.991, 0.000, 0.001, 0.008)	(0.999, 0.000, 0.000, 0.000)
2号无缺陷	(0.999, 0.000, 0.000, 0.000)	(0.998, 0.001, 0.000, 0.001)	(0.999, 0.000, 0.000, 0.000)
1号气孔	(0.000, 0.000, 0.000, 0.999)	(0.000, 0.000, 0.000, 0.999)	(0.000, 0.000, 0.000, 1.000)
2号气孔	(0.000, 0.000, 0.000, 0.999)	(0.000, 0.000, 0.000, 0.999)	(0.000, 0.000, 0.000, 0.999)
1号未熔合	(0.000, 0.500, 0.499, 0.000)	(0.000, 0.043, 0.956, 0.001)	(0.000, 0.005, 0.902, 0.091)
2号未熔合	(0.000, 0.138, 0.797, 0.064)	(0.000, 0.007, 0.981, 0.011)	(0.000, 0.001, 0.549, 0.448)
1号未焊透	(0.000, 0.859, 0.140, 0.000)	(0.000, 0.936, 0.063, 0.000)	(0.000, 0.968, 0.031, 0.000)
2号未焊透	(0.000, 0.957, 0.042, 0.000)	(0.000, 0.907, 0.092, 0.000)	(0.400, 0.598, 0.001, 0.000)

分类结果括号中 4 个数字分别表示经 softmax 层计算后获得待识别图像属于无缺陷、未焊透、未熔合、气孔的概率, 其中概率最大的数值决定分类结果的缺陷类型. 可以看出 CNN-1 对编号 5 的 1 号未熔合缺陷样本误检为未焊透, 且识别结果中的概率值相近, 而 CNN-2 及 CNN-3 对编号的识别样本都做出了正确识别, 对 1 号未熔合样本的识别概率值差别很大, 表明文中方法在特征提取方面更具有优势. 通过总体测试样本识别分析, 文中提出的方法都能有效地对 4 种类型的焊缝探伤图像进行识别, 整体识别准确率可达 97.8%, 在实现对焊缝图像中存在的各种缺陷的准确细分识别是完全可行的.

3 结论

(1) 在构建 CNN 模型时采用 ELU 激活函数, 使模型在训练过程中具有更好的鲁棒性, 通过良好的网络稀疏性及较小的输出均值增加了收敛速度.

(2) SLIC 方法可有效地将焊缝探伤图像中的像素点进行像素块化, 增大了图像中感兴趣区域的占比, 增强了训练过程中图像特征的提取, 降低了局部信息的冗余, 进而降低训练过程中的迭代耗时, 而整体降低程度而言还需进一步改善.

(3) 文中提供的 SLIC 方法及 ELU 激活函数构建的 CNN 模型可应用于焊缝探伤图像自动化识别领域中并能显著提升焊缝探伤图像中缺陷的识别准确率, 整体识别率可达 97.8%, 在实现对焊缝图像中存在的各种缺陷的准确细分识别是完全可行的, 且该方法具有通用性, 可拓展至其它领域.

参考文献

- [1] 张志芬, 杨哲, 任文静, 等. 电弧光谱深度挖掘下的铝合金焊接过程状态检测 [J]. 焊接学报, 2019, 40(1): 19 – 25.
Zhang Zhifen, Yang Zhe, Ren Wenjing, *et al.* Condition detection in Al alloy welding process based on deep mining of arc spectrum[J]. Transactions of the China Welding Institution, 2019, 40(1): 19 – 25.
- [2] Min Xiangjun. The development and design of the repair welding procedure of the thick wall duplex stainless steel piping[J]. China Welding, 2017, 26(1): 60 – 64.
- [3] 孙怡, 孙洪雨, 白鹏, 等. X 射线焊缝图像中缺陷的实时检测方法 [J]. 焊接学报, 2004, 25(2): 115 – 118.
Sun Yi, Song Hongyu, Bai Peng, *et al.* Real-time automatic detection of weld defects in X-ray images[J]. Transactions of the China Welding Institution, 2004, 25(2): 115 – 118.
- [4] Yang Zhenzhen, Kuang Nan, Fan Lu, *et al.* Review of image classification algorithms based on convolutional neural networks[J]. Journal of Signal Processing, 2018, 34(12): 84 – 99.
- [5] 周飞燕, 金林鹏, 董军. 卷积神经网络综述 [J]. 计算机学报, 2017, 40(6): 1229 – 1251.
Zhou Feiyan, Jin Linpeng, Dong Jun. Review of image classification algorithms based on convolutional neural networks[J]. Chinese Journal of Computers, 2017, 40(6): 1229 – 1251.
- [6] Boureau Y, Roux N L, Bach F, *et al.* Ask the locals: multi-way local pooling for image recognition[C]// IEEE International Conference on Computer Vision. IEEE, 2011: 2651-2658.
- [7] Wu X, He R, Sun Z, *et al.* A light CNN for deep face representation with noisy labels[J]. IEEE Transactions on Information Forensics and Security, 2018, 13(11): 1 – 11.
- [8] Gu J, Wang Z, Kuen J, *et al.* Recent advances in convolutional neural networks[J]. Computer Science, 2018, 77: 354 – 377.
- [9] Achanta R, Shaji A, Smith K, *et al.* SLIC superpixels compared to state of the art superpixel methods[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 34(11): 2274 – 2282.
- [10] Singh R, Om H. Newborn face recognition using deep convolutional neural network[J]. Multimedia Tools & Applications, 2017, 76(18): 1 – 11.
- [11] Mery D, Rizzo V, Zscherpel U, *et al.* The database of X-ray images for nondestructive testing[J]. Journal of Nondestructive Evaluation, 2015, 34(4): 1 – 12.

第一作者简介: 樊丁, 1961 年出生, 教授, 博士研究生导师; 主要从事焊接方法与焊接物理、焊接智能控制及自动化、材料激光加工等方面的教学与科研工作; 发表论文 300 余篇; Email: fand@lut.cn.

(编辑: 殷祚炷)