

DOI:10.16136/j.joel.2023.10.0650

基于深度学习的钢材金相图像晶粒度等级评定方法

王 森¹, 国 蓉¹, 胡海军^{2*}, 张 钰³, 李秀峰⁴

(1. 西安工业大学 光电工程学院, 陕西 西安 710021; 2. 西安交通大学 化学工程与技术学院, 陕西 西安 710049; 3. 陕西师范大学 计算机科学学院, 陕西 西安 710062; 4. 中国特种设备检测研究院, 北京 100029)

摘要:准确地评定钢材金相组织晶粒度等级能检测材料劣化情况,保障设备的服役安全。针对传统人工评定钢材金相组织晶粒度等级的方法耗时久且易受人工经验影响,评价结果一致性差且不可重复等问题,提出了一种基于深度学习的钢材金相晶粒度等级评定方法。在 U-net 模型上添加跳跃连接层并减少下采样次数来提高模型的分割准确率并减少网络参数量,在 117 张验证集上的像素准确率达 93.86%,平均像素准确率(mean pixel accuracy, MPA)达 86.89%,网络参数量仅为 2.02 M。对晶界预测结果进行数字图像处理并结合截点法进行晶粒度等级评定,在测试图像上评定钢材晶粒度等级平均耗时仅 8.3 s/张。与人工评级方法相比,本文方法具有准确性、高效性及可重复性。

关键词:金相图像; 晶界分割; 截点法; 晶粒度等级

中图分类号: TP751 **文献标识码:** A **文章编号:** 1005-0086(2023)10-1075-09

A deep learning-based method for grading the grain size of steel metallographic images

WANG Sen¹, GUO Rong¹, HU Haijun^{2*}, ZHANG Yu³, LI Xiufeng⁴

(1. School of Opto-electronic Engineering, Xi'an Technological University, Xi'an, Shaanxi 710021, China; 2. School of Chemical Engineering and Technology, Xi'an Jiaotong University, Xi'an, Shaanxi 710049, China; 3. School of Computer Science, Shaanxi Normal University, Xi'an, Shaanxi 710062, China; 4. China Special Equipment Inspection and Research Institute, Beijing 100029, China)

Abstract: Accurate assessment of the metallographic grain size grade of steel can detect material deterioration and ensure the safety of equipment in service. In order to solve the problems that the traditional manual evaluation of steel metallographic grain size grade is time-consuming and easily influenced by manual experience, the evaluation results are not consistent and irreducible, etc, a deep learning-based steel metallographic grain size grade evaluation method is proposed. By adding a jump connection layer to the U-net model and reducing the number of downsampling to improve the segmentation accuracy and reduce the number of network parameters, the pixel accuracy is 93.86% and the mean pixel accuracy (MPA) is 86.89% on the 117 validation sets. The number of network parameters is only 2.02 M. The grain boundary prediction results are digitally processed and combined with the intercept point method to grade the grain size, and the average time taken to grade the grain size of steel on the test image is only 8.3 s/sheet. Compared with manual rating methods, this method is accurate, efficient and repeatable.

Key words: metallographic image; grain boundary segmentation; intercept point method; grain size grade

* E-mail: 1264180391@qq.com

收稿日期: 2022-09-21 修订日期: 2022-11-17

基金项目: 2020 年教育部产学合作协同育人项目(202002321008)和西安市科学技术局重点产业链核心技术攻关项目(2022JH-RG-ZN-000)资助项目

0 引言

钢材设备在恶劣的工作环境下受温度、压力、腐蚀等情况影响,其材料性能会发生变化,对材料的劣化情况进行检测十分重要。金相检验是检测钢材的劣化情况、保障设备服役安全的重要手段^[1]。对钢材的检测主要分为表面宏观检测和微观组织检测,宏观检测主要是低倍组织检验,用肉眼或在不大于10倍的放大镜下检查钢材表面或断面,以确定材料的低倍组织缺陷;微观组织检测主要包括晶粒度检测、非金属夹杂物和显微组织检测等,它们都是在光学显微镜下检查材料的微观组织状态和分布情况。对材料显微组织的识别属于图像识别问题,同时也属于计算机视觉等技术在材料科学领域的应用^[2,3]。

实际晶粒度指的是钢在具体热处理或热加工条件下所得到的奥氏体的晶粒大小,其基本上反映了钢件的晶粒大小。晶粒的尺寸大小即钢材的晶粒度,通常情况下金属基体内的晶粒不可能完全一样大小,但其晶粒大小的分布在大多情况下呈近似单一对数正态分布,常规采用“平均晶粒度”表示,其对钢材的拉伸强度、韧性、塑性等机械性质有决定性影响。准确地评定金相图像晶粒度等级是金相检测中最为关键的任务。

当前对金相图像晶粒度的测定方式主要为人工检测法或依靠机器视觉^[4]的自动检测法。人工检测法是通过人工将金相图像和标准图谱进行对比,参照国家标准GB/T6394-2017《金属平均晶粒度测定方法》(以下简称国家标准)中比较法得出预测的晶粒度等级。这种方法十分耗时且检测结果易受检测人员的个人主观性影响,一致性和可重复性较差。随着计算机的计算能力和效率的不断提高,机器学习和深度学习算法得以快速发展,卷积神经网络(convolutional neural network, CNN)能够从数据集中自动学习相关特征,在计算机视觉领域及材料研究领域都有广泛的应用^[5]。2014年,由LONG等^[6]提出的全卷积神经网络(fully convolutional networks, FCN)开启了图像分割编码(encoder)-解码(decoder)的新纪元,该网络对每个像素预测的同时保留了原始图像的空间位置信息,最后实现了对像素点的分类^[7]。通过深度学习结合图像处理的晶界检测方法可弥补人工检测费时费力、重复性差等缺点。

近年来,国内外一些企业、科研院所已经提出一些金相晶粒度等级评定方法并研制出一系列定量金相分析系统。目前采用的方法都是通过寻找晶粒、判断晶界、再依据国家标准相关规定进行金

相图像的晶粒度计算。庚嵩等^[8]提出基于高斯混合模型聚类并采用主成分分析(principal component analysis, PCA)去噪算法实现了基于二维指数灰度熵的阈值分割算法。朱建栋^[9]等提出了均值偏移(mean shift, MS)参数自适应算法和基于结构化随机森林的金相图像晶界提取算法,可以较为准确地识别金相晶界。AZIMI等^[10]结合最大投票方式及FCN对低碳钢金相图像实现了较高准确率的分割。包金叶^[11]提出了一种基于多尺度特征融合的FCN晶界提取方法并基于灰度形态学操作增强了晶界提取的正确率。张琦等^[12]采用集成学习并引入迁移学习的方法提取多层级特征,达到了较高的晶粒度预测准确率。蔡超丽等^[13]提出了一种基于神经网络强化学习架构实现了陶瓷晶粒的图像分割。雷涛等^[14]提出一种数据与模型联合驱动的陶瓷材料晶粒分割算法,实现了陶瓷材料晶粒尺寸的精准计算。上述方法仅适用于对比度高、晶界明显及图像特征简单的金相图像,未对金相图像中晶粒及晶界的像素级特征进行提取和深入研究,不适用于低对比度且晶界复杂的金相图像。

针对传统人工方法及现有深度学习方法的缺点,本文提出一种基于深度学习和数字图像处理结合的钢材金相图像晶粒度等级评定方法,提出了改进的轻量型U-net图像分割网络结构,提高了对金相图像晶界分割的准确率;采用数字图像处理并结合国家标准中截点法相关操作,可实现对钢材金相图像的晶粒度等级快速评定。

1 基础理论和图像分割网络设计

1.1 截点法

国家标准中提出评定金属材料平均晶粒度等级的方法主要包括有比较法、面积法及截点法。截点法是计数已知长度的试验线段(或网格)与晶粒截线或者与晶界的截点个数,计算单位长度截线数 N_L 或者截点数 P_L 来确定平均晶粒度 G ,其测量结果是无偏差的。对于同一精度水平,截点法不需要标记就能准确计数,因而较面积法测量快。截点法又分为直线截点法和圆截点法,圆截点法可以不必过多的附加视场,能自动补偿偏离轴晶而引起的误差,其作为质量检测评估晶粒度的方法是普遍适用的。

对于每个测量视场 i ,单位长度上的截线数及截点数的计算式^[15]分别为:

$$N_L = \frac{M \cdot N_i}{L}, \quad (1)$$

$$P_L = \frac{M \cdot P_i}{L}, \quad (2)$$

式中, L 为所用的试验线长度, M 为所用的放大倍数, N_i 为已知长度 L 试验线上的截线计数, P_i 为晶界与试验线的交点数。

对于每个视场的平均截距长度值 $\bar{l}$,

$$\bar{l} = \frac{1}{N_L} = \frac{1}{P_L}, \quad (3)$$

用 N_L 、 P_L 或 $\bar{l}$ 的 n 个测定值的平均数值确定平均晶粒度 G 的计算式如下:

$$G = 6.643856 \lg N_L - 3.288, \quad (4)$$

$$G = 6.643856 \lg P_L - 3.288, \quad (5)$$

$$G = -6.643856 \lg \bar{l} - 3.288. \quad (6)$$

1.2 U-net 系列图像分割网络

U-net CNN 是在 FCN 的基础上改进得到的。其网络结构呈经典的 U 型编码-解码结构, 并给编码和解码结构添加了收缩路径来实现更精准的像素边界定位。FCN 采用特征加操作而 U-net 对跳层特征采用拼接(concat)操作, 使得在上采样过程中可以融入更多的有效特征层信息且特征层的尺寸不变。该网络由收缩路径(contracting path)和扩张路径(expanding path)组成, 收缩路径用于获取上下文信息(context), 扩张路径用于精确的定位。通过上采样和图像拼接来进行边缘信息的找回, 网络的实用性较好。

ZHOU 等^[16]依据 U-net 的网络结构进行了改进, 提出 U-net++ 网络, 该网络结合了类 DenseNet 结构, 采用更加密集的跳跃连接来提高网络模型中

梯度的流动性; 同时将 U-net 的结构空心填满, 可以更好地连接编码器和解码器各特征图之间的语义鸿沟, 通过特征拼接将浅层语义信息和深层语义信息融合, 可以整合二者之间的优点; 在网络模型中采用深度监督模式, 使得网络可以进行剪枝, 可实现修剪模型以调整模型复杂性, 在计算速度和模型性能之间实现平衡。

1.3 改进的轻量型 U-net 网络设计

由于金相图像的对比较低, 部分区域的亮度低; 晶粒边界复杂, 晶粒与晶界之间的特征不明显。为了能够准确地提取出晶粒边界, 本文结合 U-net++ 的设计思路对 U-net 网络模型结构进行改进, 提出一种轻量型 U-net CNN, 提高了该网络模型的浅层特征提取能力及计算速度。其网络模型结构图如图 1 所示。

该网络模型包含左右两个部分, 虚线左侧为收缩路径, 右侧为扩张路径。收缩路径主要为下采样过程, 网络模型输入为 512×512 的灰度图像, 为了保证卷积输出的特征图尺寸不变, 卷积的 Padding 策略采用 Same 模式(保留边界处的卷积结果, 可以使卷积的输入输出尺寸相同), 经两次 3×3 卷积后输出大小为 512×512 、通道数为 32 的特征图。该特征图经过 2×2 的最大池化(max pool)操作进行下采样, 输出大小为 256×256 、通道数为 32 的特征图。依次重复 4 次卷积和 3 次下采样过程, 输出大小为 64×64 、通道数为 256 的特征图。




图 1 改进的 U-net 图像分割网络

Fig. 1 Improved U-net image segmentation network

扩张路径与收缩路径对称, 扩张路径主要是上采样过程。由下采样输出的特征图经 2×2 的反卷

积(Up-Conv)操作使特征图的尺寸乘 2, 通道数减半, 输出大小为 128×128 、通道数为 128 的特征信息

层。为了在上采样过程中融入更多的特征层信息,采用跳跃连接的方式在上采样过程中对3个大小为 128×128 、通道数分别为64、128、128的特征层进行通道的复制拼接操作,将特征图按通道进行拼接,生成一个大小为 128×128 、通道数为320的特征层,该操作可以在上采样过程中有效地融入更多的浅层特征层信息,从而使得模型能更多地关注图像中的边缘信息,有效提高模型的分割准确率。重复3次 2×2 的反卷积、跳跃连接及 3×3 卷积操作,最后再对特征图进行 1×1 的卷积操作,最终输出一个大小为 512×512 、通道数为2的语义分割图像。激活函数采用带泄露的修正线性单元(leaky rectified linear unit, Leaky ReLU),其函数曲线如图2所示,该激活函数解决了神经元的“死亡”问题,提高了网络的特征提取能力。




图2 Leaky ReLU 激活函数

Fig.2 Leaky ReLU activation function

2 实验验证及结果

2.1 数据集

由于暂时没有公开的可用于金相图像晶粒分割的数据集,在进行图像分割网络训练之前,需要建立相应的金相图像晶界分割数据集。对金相显微镜采集到的金相图像分别进行灰度化、自适应直方图均衡化、双边滤波等预处理操作。原始金相图像和预处理操作之后的金相图像分别如图3(a)及图3(b)所示。

原始金相图像局部(图3框中部分)和预处理后的金相图像局部如图4(a)及图4(b)所示。

通过对比原始金相图像和预处理后的金相图像局部可知,预处理操作有效消除了图像中的部分噪声,提高了图像亮度,加大了晶粒和晶界之间的细节对比度。预处理后的金相图像更有利于CNN模型的学习。

对金相图像预处理后,需要手工绘制金相图像的晶界标签。本文采用Procreate软件绘制金相图像的晶界标签,得到的金相图像晶界标签与原始金相图像大小相同($1536 \text{ pixel} \times 2048 \text{ pixel}$),为二值化图像(晶粒像素值为0,晶界像素值为1),原始金相图像及手绘的晶界标签示例分别如图5(a)及图5(b)所示。




图3 预处理操作对比图:(a) 原始金相图像;
(b) 预处理操作后的金相图像

Fig.3 Comparison chart of pre-processing operations:

(a) Original metallographic image;
(b) Metallographic image after pre-processing operation




图4 原始金相图像和预处理后图像的局部对比:
(a) 原始金相图像局部;(b) 预处理后图像局部

Fig.4 Local comparison of the original metallographic image and the pre-processed image:

(a) Partial original metallographic image;
(b) Partial image after pre-processing




图5 原始金相图像和手绘的晶界标签图像:
(a) 原始金相图像;(b) 手绘晶界标签图像

Fig.5 Original metallographic image and hand-drawn image of grain boundary labels:

(a) Original metallographic image;
(b) Hand-drawn grain boundary label image

单张原始金相图像的尺寸太大,不易于 CNN 的训练,且手绘标签十分复杂,不能通过人工手绘获得大量的数据集,因此需要对金相数据集进行扩充。本文采用按有重叠裁剪的方式进行数据集扩充,即将 10 张原始金相图像(1536 pixel×2048 pixel)及对应的晶界标签图像按每隔 128 pixel 裁剪成一张 512 pixel×512 pixel 大小的图像,得到训练集数据集共 1170 张。

由于上述有重叠的裁剪策略导致数据集中部分图像会出现区域重叠,不能按比例划分为训练集和验证集(防止训练集与验证集数据重合),本文对独立的一张金相图像绘制相应的晶界标签,通过预处理及裁剪后得到验证集图像共 117 张。训练集和验证集比例为 10:1。预处理裁剪后的金相图像和对应的晶界标签示例如图 6(a)及图 6(b)所示。




图 6 训练集图像示例:(a) 裁剪后的金相图像;
(b) 晶界标签

Fig. 6 Example of training set images:
(a) Cropped metallographic image;
(b) Grain boundary labels

2.2 对比实验设置

实验采用 Pytorch 框架部署前述 U-net、U-net++ 及改进的轻量型 U-net CNN,学习率设置为 0.0001,批大小为 1,训练迭代 30 个轮次,在 8 G 的 Nvidia Xp GPU 上分别对上述图像分割网络进行对比训练实验,统计其相关网络评价指标结果。

2.3 相关评价指标

对于晶界分割任务,预测输出仅包含晶粒和晶界两类,该过程可以看作一个二分类任务(晶界像素值为 1,晶粒像素值为 0),晶界为正类别。结合其对应的像素值预测结果及手绘的标签像素值,生成相应的混淆矩阵,其中,TP 代表预测值为 1,标签值为 1;TN 代表预测值为 0,标签值为 0;FP 代表预测值为 1,标签值为 0;FN 代表预测值为 0,标签值为 1。

对下列参数指标进行计算统计。

2.3.1 准确率

准确率(Accuracy)是分类正确的样本数和总样本数的比值(即在混淆矩阵中预测对的样本点个数占总像素点数的比例)。通常来说,准确率越高分类器网络模型越好,其计算式为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

2.3.2 平均像素准确度

平均像素准确度(mean pixel accuracy,MPA)是各个类别的像素准确率的和与总的类别数的比值,在类别不均衡时,MPA 值能更好地反应网络的分类效果,其计算式为:

$$MPA = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij}} \quad (8)$$

式中, p_{ii} 表示标签为 i ,预测为 i 的总数, p_{ij} 表示标签为 i 、预测为 j 的总数, k 为类别数(此处晶界为目标类别,晶粒为背景, k 为 1)。

2.3.3 Dice 系数

Dice 系数是集合相似度的度量指标,用于计算两个样本(即晶界和晶粒)的相似度。该系数取值范围为 $[0,1]$,取值越高说明分割结果越好,其计算式为:

$$Dice = \frac{2TP}{FP + FN + 2TP} \quad (9)$$

2.4 晶界分割实验及结果

用上述训练集分别训练 U-net、U-net++ 以及改进的 U-net 图像分割网络各 30 个轮次,在对应网络上对验证集进行预测,保存在各个网络上对验证集最优的训练权重,并对其最优参数结果进行统计,如表 1 所示。

表 1 在上述 3 个网络上的相关实验结果
Tab. 1 Relevant experimental results on
the above three networks

Methods	Accuracy	MPA	Dice	Params/M
U-net	0.9373	0.8422	0.6972	7.77
U-net++	0.9376	0.8679	0.7025	9.04
Our network	0.9386	0.8689	0.7124	2.02

依据此实验结果,本文提出的轻量型 U-net 图像分割网络在本数据集上的像素准确率、MPA、Dice 系数值等均高于 U-net 及 U-net++ 图像分割网络,且其网络参数量仅为 2.02 M。相比于 U-net 及 U-net++ 网络,其网络参数量分别相对减少了 74.0%

和 77.7%。改进的轻量型 U-net 网络有效减少了网络模型的计算量,提高了对金相图像晶粒边界的分割速度。验证集示例图像 1 如图 7(a)所示,对应的晶界标签如图 7(b)所示,在上述网络上的晶界预测结果分别如图 7(c)、7(d)、7(e)所示;验证集示例图像 2 如图 7(f)所示,对应的晶界标签如图 7(g)所示,在上述网络上的晶界预测结果分别如图 7(h)、7(i)、7(j)所示。

2.5 晶界分割结果后处理

为了使预测得到的晶界更加准确且便于计算晶粒度等级,需要对图像分割网络输出的晶界预测图像进行后处理,首先采用大津法(Otsu)查找图像阈

值并进行二值化,将由网络模型预测得到的灰度晶界图像转换为二值图像;对该二值图像进行形态学闭运算(先膨胀再腐蚀)操作,填平图像的凹角,弥合小的裂缝,使得部分不封闭的晶界图像得以封闭;再对闭运算操作过后的图像设定面积阈值,剔除像素面积小于该阈值的孔洞,减少由小面积区域带来的测量误差影响,最后再对该图像采用 skeletonize 函数进行骨架化操作,细化图像中的晶界,便于计算读取预测的晶界图像与标准圆周的交点个数。测试图像如图 8(a)所示,由网络模型预测得到的晶界图像如图 8(b)所示,后处理操作后得到的二值化骨架晶界结果如图 8(c)所示。




图 7 不同网络上的分割结果:(a) 验证集图像 1; (b) 标签图像 1; (c) U-net 预测 1; (d) U-net++ 预测 1; (e) 轻量化 U-net 预测 1; (f) 验证集图像 2; (g) 标签图像 2; (h) U-net 预测 2; (i) U-net++ 预测 2; (j) 轻量化 U-net 预测 2

Fig. 7 Segmentation results on different networks:(a) Validation set image 1; (b) Label image 1; (c) U-net prediction 1; (d) U-net++ prediction 1; (e) Lightened U-net prediction 1; (f) Validation set image 2; (g) Label image 2; (h) U-net prediction 2; (i) U-net++ prediction 2; (j) Lightened U-net prediction 2




图 8 测试结果及后处理结果:(a) 测试图像; (b) 预测的晶界图像; (c) 后处理结果

Fig. 8 Test result and post-processing result:(a) Test image; (b) Predicted grain boundary image; (c) Post-processing result

2.6 截点法计算平均晶粒度等级

由于图像分割网络模型的输入输出设定大小为

512 pixel×512 pixel,对待测金相图像进行晶粒度等级预测时,先将一张 1 536 pixel×2 048 像素的原始

金相图像进行预处理并裁剪成 12 张 512 pixel×512 pixel 的子图,将各张子图依次送入网络模型,分别预测每张子图中的晶界。依据国家标准,采用普遍适用的单圆截点法来进行金相图像的晶粒度等级计算。首先选择半径 R 为 200 pixel 点的圆作为标准圆周网格,圆心坐标设定为 (256,256),标准圆周网格示例如图 9 所示。




图 9 标准测量网格
Fig. 9 Standard measurement grid




图 10 单圆截点法操作结果
Fig. 10 Results of the single circle intercept point method

表 2 截点数统计结果

Tab. 2 Results of intercept point statistics

Serial number	(a)	(b)	(c)	(d)	(e)	(f)
Number of intercept points	31	24	34	32	32	35
Serial number	(g)	(h)	(i)	(j)	(k)	(l)
Number of intercept points	35	38	33	36	33	34

然后将网络模型预测得到的晶界图像经后处理操作后分别与标准圆周网格相交,统计其与标准圆周网格的交点个数即为截点个数,再求出平均的截线长度,据此计算出金相图像的晶粒度等级。图 10 (a)—10(l)为对一张 1 536 pixel×2 048 pixel 的测试图像裁剪后的 12 张子图进行晶界预测、后处理再与标准圆周相交的操作结果。

设计程序自动读取 12 张子图中每张子图与标准圆周网格的截点个数并统计,如表 2 所示。

考虑到每张子图中的晶粒大小差异不大,为了使测试结果更加准确可靠,在对统计结果进行计算的过程中,剔除一个截点最大计数值(38)及一个截点最小计数值(24),对剩余 10 个截点计数值进行求和并取平均值,得到待测图像的平均截点个数为 33.5 个。本文所使用的金相图像的放大倍数统一为 200 倍,其像素比例尺为 0.29 mm/pixel,得出标准圆周网格的圆周长 C 的计算式为:

$$C = 2 \cdot \pi \cdot R \cdot 0.29。$$

(10)

根据标准圆周网格的半径及平均截点个数计算出标准圆周的周长 C 为 364.24 μm ,平均截线长度为 10.87 μm 。设计程序,将此计算结果与国家标准中均匀、各向同性的等轴晶粒显微晶粒度关系表格(如表 3 所示)及其可视化图(见图 11)中的相关数据进

表 3 均匀、各向同性的等轴晶粒显微晶粒度关系

Tab. 3 Microscopic grain size relationships for homogeneous, isotropic equiaxed grains

Grain size grade G	Average intercept $\bar{l}$ / μm	Grain size grade G	Average intercept $\bar{l}$ / μm	Grain size grade G	Average intercept $\bar{l}$ / μm	Grain size grade G	Average intercept $\bar{l}$ / μm
00	452.5	0	320	0.5	269.1	1	226.3
1.5	190.3	2	160.0	2.5	134.5	3	113.1
3.5	95.1	4	80.0	4.5	67.3	5	56.6
5.5	47.6	6	40.0	6.5	33.6	7	28.3
7.5	23.8	8	20.0	8.5	16.8	9	14.1
9.5	11.9	10	10.0	10.5	8.4	11	7.1
11.5	5.9	12	5.0	12.5	4.2	13	3.5
13.5	3.0	14	2.5				

行自动对比,得出待预测金相图像的晶粒度等级结果为 9.5 级,该预测结果与人工专家绘制晶界并采用比较法所得到的预测结果一致,程序完成一张金相图像的晶粒度等级预测过程平均耗时仅需要 8.3 s。与人工评定过程相比,本文提出的晶粒度等级预测方法具有快速性和高效性。




图 11 显微晶粒度关系表可视化

Fig. 11 Visualization of the microscopic grain size relationship table

3 结 论

本文提出一种基于深度学习的钢材金相图像晶粒度等级预测方法,建立了金相图像晶粒分割数据集,改进了 U-net 网络的下采样层数并添加了跳跃连接从而在上采样过程中融入更多的特征层信息,强化网络的浅层特征提取能力,使得网络模型对晶界的预测结果更加准确、网络参数量更少。采用形态学操作对晶界预测结果进行后处理并结合国家标准中截点法评定钢材的金相晶粒度等级。与现有方法相比,本方法具有准确性、可重复性和高效性。

参考文献:

[1] DANG H R, Wu G Z, DING K, et al. Measurement of grain

size and research of oxidation resistance of X20Cr13 steel[J]. Shanghai Metals, 2021, 43(4): 13-18.

党浩然, 吴贯之, 丁凯, 等. X20Cr13 钢的晶粒度测定及其抗氧化性能研究[J]. 上海金属, 2021, 43(4): 13-18.

[2] ORTEGON J, LEDESMA-ALONSO R, BARBOSA R, et al. Material phase classification by means of support vector machines [J]. Computational Materials Science, 2018, 148: 336-342.

[3] TSUTSUI K, TERASAKI H, MAEMURA T, et al. Microstructural diagram for steel based on crystallography with machine learning [J]. Computational Materials Science, 2019, 159: 403-411.

[4] GAI X, YE P, WANG J, et al. Research on defect detection method for steel metal surface based on deep learning [C]//2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC), June 12-14, 2020, Chongqing, China. New York: IEEE, 2020: 637-641.

[5] DECOST B, LEI B, FRANCIS T, et al. High throughput quantitative metallography for complex microstructures using deep learning: a case study in ultrahigh carbon steel [J]. Microsc Microanal, 2019, 25(1): 21-29.

[6] LONG J, SHELHAMER E, DARRELL T, et al. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.

[7] ZHOU N N. Research on image semantic segmentation method based on deep convolution neural network [D]. Qinhuangdao: Yanshan University, 2019: 14-22.

周南南. 基于深度卷积神经网络的图像语义分割方法研究 [D]. 秦皇岛: 燕山大学, 2019: 14-22.

[8] GENG S. The application of digital image processing to metallographic analysis [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2018: 6-12.

- 庚嵩. 数字图像处理在金相分析中的应用[D]. 南京: 南京航空航天大学, 2018: 6-12.
- [9] ZHU J D. Research on the algorithm used for grain boundary extraction from metallographic images and design of intelligent rating software[D]. Zhenjiang Jiangsu University, 2018: 5-20.
- 朱建栋. 钢材金相图像晶界提取算法研究及智能评级软件设计[D]. 镇江: 江苏大学, 2018: 5-20.
- [10] AZIMI S M, BRITZ D, ENGSTLER M, et al. Advanced steel microstructural classification by deep learning methods [J]. Scientific Reports, 2018, 8(1): 2128.
- [11] BAO J Y. Research on automatic segmentation and rating of metallographic image based on fully convolutional neural network [D]. Zhenjiang: Jiangsu University, 2020: 3-21.
- 包金叶. 基于全卷积神经网络的金相图像自动晶界分割与评级方法研究[D]. 镇江: 江苏大学, 2020: 3-21.
- [12] ZHANG Q. Research on a new method for automatic metallographic rating based on ensemble learning [D]. Zhenjiang: Jiangsu University, 2018: 7-25.
- 张琦. 基于集成学习的金相组织自动评级方法研究 [D]. 镇江: 江苏大学, 2018: 7-25.
- [13] CAI C L, LI C C, HUANG L, et al. ED-NAS: ceramic grain segmentation based on neural architecture search using SEM images[J]. Acta Electronica Sinica, 2022, 50(2): 461-469.
- 蔡超丽, 李纯纯, 黄琳, 等. ED-NAS: 基于神经网络架构搜索的陶瓷晶粒 SEM 图像分割方法[J]. 电子学报, 2022, 50(2): 461-469.
- [14] LEI T, LI Y T, ZHOU W Z, et al. Grain segmentation of ceramic materials using data-driven jointing model-driven [J]. Acta Automatica Sinica, 2022, 48(4): 1137-1152.
- 雷涛, 李云彤, 周文政, 等. 数据与模型联合驱动的陶瓷材料晶粒分割[J]. 自动化学报, 2022, 48(4): 1137-1152.
- [15] CHINA IRON & STEEL ASSOCIATION. Bibliography: Part 4 Non-book Information; GB/T 6394-2017: Determination of estimating the average grain size of metal[S]. Beijing: China Standards Press, 2017.
- 中国钢铁工业协会. 文献著录: 第4部分 非书资料: GB/T 6394-2017: 金属平均晶粒度测定方法[S]. 北京: 中国标准出版社, 2017.
- [16] ZHOU Z, SIDDIQUEE M, TAJBAKHSH N, et al. UNet++: A nested U-Net architecture for medical image segmentation[C]//4th Deep Learning in Medical Image Analysis Workshop, September 20, Granada, Spain. New York: IEEE, 2018: 3-11.

作者简介:

胡海军 (1978—), 男, 博士, 副教授, 硕士生导师, 主要从事过程装备与控制、过程系统的可靠性与风险分析及维修优化方面的研究。