

基于深度学习算法的大尺寸铝合金中第二相的识别提取与定量统计分析

万卫浩^{1,3}, 孙丹丹², 李冬玲^{2,3}, 赵雷^{2,3}, 沈学静^{2,3}, 王海舟^{2,3}, 韩冰²

(1. 钢铁研究总院, 北京 100081)

(2. 钢研纳克检测技术股份有限公司, 北京 100081)

(3. 金属材料表征北京市重点实验室, 北京 100081)

摘要: 铝合金中第二相粒子是在铸造过程中产生并对材料的物理化学性能有着显著的影响。目前常用的第二相的定量表征方法存在人工工作量大和消耗时间过长的问题。本研究提出一种基于深度学习的大尺寸铝合金中第二相的快速提取与定量统计表征方法, 通过对图像中第二相特征的快速、智能化提取, 实现多角度精细化的定量统计。结果显示, 该方法的图像处理时间与软件批量处理时间一样为 0.4 s/张, 但图像分割精度从 42.74% 提升到 91.12%。从数据集制作方面, 本方法用 MIPAR 软件结合人工微调代替传统的手工标记, 大大节省了人工时间。为了满足精细化表征的要求, 对 3 万张包括 4 种类型的全视场 7B05 铝合金扫描电镜图像进行分割提取, 计算了第二相的长宽比、最短间距、面分布以及线分布等新的表征参数, 其中线分布结果证明, 与传统的随机选取视场的统计结果相比较, 本研究使用的全视场多角度的统计表征方式误差更小, 特征信息更全面。定量统计结果显示, 厚度为 6 mm 的铸轧 7B05-T4 铝合金截面, 在最近邻上下表面位置第二相的平均面积最小, 在厚度 3 mm 的位置存在波谷值; 将截面均分为 3 个区域, 第二相的平均面积分别为 1.98、2.17、1.83 μm^2 , 平均长宽比分别为 1.89、1.94、1.84, 第二相数量分别为 33 574、33 207、42 035 个。以上结果表明, 基于深度学习的铝合金中第二相的快速提取与定量统计表征方法可进行多角度的分析数据与挖掘, 为组织、性能研究提供依据。

关键词: 7B05 铝合金; 第二相; 深度学习; U-Net; 全视场定量统计

中图分类号: TG146.21

文献标识码: A

文章编号: 1002-185X(2022)02-0525-10

7B05 铝合金具有强度高、韧性好、密度低等优点, 可进行热处理强化, 目前已广泛应用于高速列车的牵引梁、枕梁和缓冲梁等结构件^[1-3]。高强铝合金在热轧过程中组织的演变机理十分复杂, 伴随着微观晶粒组织的演变, 既有粗大难溶相的碎化和弥散化, 又有其它相的析出过程^[4]; 变形温度、应变速率、停留时间等工艺都会对轧板中粗大难溶相的形态和分布产生重要的影响^[5-8]。研究表明^[1,9], 铝合金中未熔或难熔的第二相粒子在塑性变形时在相界面上容易形成孔隙, 产生微裂纹, 显著降低材料的断裂韧性; 此外, 由于微米级第二相与基体间存在微区电化学的差异, 容易发生点蚀、晶间腐蚀及应力腐蚀等局部腐蚀^[10]。随着高铁用铝合金材料的国产化进程的加速, 如何对第二相颗粒进行精确的定量表征与统计分析, 是目前亟需解决的问题。

目前常用的第二相的定量表征方法是使用人工参

与的图像处理软件从显微图像中提取第二相特征并对提取的特征进行统计^[11], 或者通过相关图像处理算法, 制定一系列图像分割算法完成对第二相的提取和统计^[12-14]。使用图像处理软件结合人工干预的方法, 可以获得一个较为准确的表征结果。但人工干预过程会导致花费时间过大, 不适用于大量第二相特征的提取与统计工作。所以该方法通常是对几个到几十个人工挑选的视场进行特征的提取与统计, 使用该结果代表不同区域第二相的分布趋势以及形貌差异情况^[15]。由于第二相分布的离散性, 使得对少量视场进行表征获得的有效信息极少, 导致第二相之间的形貌与尺寸差异无法进行有效对比, 另外随机选取视场的误差进一步导致该方法无法准确表征第二相的空间分布差异。通过制定有针对性的图像分割算法完成第二相的表征统计方法, 能大量减少人工参与的工作, 并实现数据的批量处理。但该方法对图像质量要求较为苛刻,

收稿日期: 2021-07-09

基金项目: 国家重点研发计划 (2017YFB0702303)

作者简介: 万卫浩, 男, 1989 年生, 博士生, 钢铁研究总院, 北京 100081, E-mail: wanghaizhou@ncschina.com

图像中的噪声、亮度、划痕等干扰以及背景的差异都会严重影响其分割精确度，同样不适合大批量数据的精确表征。目前常用的第二相定量表征参数较单一，仅对面积、个数等常见参数进行简单统计，缺乏对第二相的分布不均匀性的精细化表征以及第二相形貌特征的定量化表征。

随着材料显微组织研究精细化以及大尺寸表征的迫切需求^[16]，如何快速、精确地提取与全面、可靠地定量统计分析，是目前亟需解决的问题。随着电子显微镜技术与计算机视觉算法的发展，快速的图像采集仪器结合智能计算机视觉算法的处理方式开始出现^[17-21]，为定量统计分析大尺寸中微观特征提供了有力的技术支持。而这种处理方式因其测量的全面性、准确性、智能化以及直观性成为目前定量分析显微特征的有效手段^[22]。本研究提出一种基于深度学习的大尺寸铝合金中第二相特征的定量识别与统计方法，使用 U-Net 语义分割网络^[23]从大尺寸铝合金样品的显微图像中快速、准确地提取第二相特征，并结合数字图像处理^[24]以及数学统计方法对提取的特征进行深度挖掘。

本研究选用的 U-Net 网络结构使用完全对称的编码-解码结构，为了恢复降采样中丢失的浅层信息，U-Net 使用跳跃连接将编码过程中各层特征信息融合到解码过程中对应层特征中。与其他图像分割网络(如 FCN^[25])相比，U-Net 使用堆叠融合的方法代替操作方法实现跳跃连接，堆叠融合的方式保证了解码出的

图像既包含了更多的浅层信息，也使得不同尺度的特征得到了融合，另外 U-Net 网络参数量较小，这些设计都有利于通过一个小数据量的训练数据得到一个性能较好的分割模型，所以 U-Net 在医学图像和显微图像中有更广泛应用。

本研究通过对大区域全视场中所有第二相的数量、面积、面分布、线分布、长宽比等信息进行统计，为进一步的数据挖掘与分析提供了更全面、更准确的信息，为研究组织与成分、性能的对应关系提供更加真实的分析数据。

1 实验

1.1 实验材料与数据

选用的材料为 4 种不同规格的铸轧枕梁用铝合金，按照热处理工艺及轧板厚度，将 4 种铝合金分别标记为 T4-6、T4-15、T5-10、T5-15，成分如表 1 所示。

本实验从 4 种商用 7B05 铝合金轧板中分别取垂直于轧制方向的截面，所取试样长、宽分别为 10 mm，高为轧板厚度。试样厚度分别为 T4-6: 6 mm、T4-15: 15 mm、T5-10: 10 mm、T5-15: 15 mm，使用 Navigator-OPA 高通量扫描电镜分别对 4 块抛光后的样品进行全视场显微组织特征图谱自动采集，分别得到 3362、11508、7056、10668 张像素尺寸为 4096×4096 的 SEM 图像数据。各样品的特征图像如图 1 所示。

表 1 4 种铝合金样品的化学成分

Table 1 Chemical composition of four aluminum alloy samples (wt%)

Sample	Zn	Mg	Cu	Fe	Si	Mn	Cr	Zr	Ti
T4-6	4.53	1.1	0.23	0.17	0.088	0.34	0.18	0.12	0.046
T4-15	4.39	1.38	0.022	0.16	0.067	0.35	0.084	0.071	0.02
T5-10	4.31	1.01	0.15	0.17	0.062	0.37	0.23	0.097	0.05
T5-15	4.23	1.09	0.16	0.17	0.058	0.37	0.22	0.11	0.048




图 1 各样品的特征图像

Fig.1 Characteristic images of each sample: (a) T4-6, (b) T4-15, (c) T5-10, and (d) T5-15

1.2 实验方法

本项目的目的是实现一种铝合金中第二相颗粒的定量统计表征方法，实验过程分为图像数据处理过程和数据挖掘过程，具体实施过程如图 2 所示。

1.2.1 显微图像处理

分别从 4 种 7B05 铝合金的 SEM 图像中各随机挑选 200 张图像，以这 800 张 SEM 图像作为原始数据集，对比验证 U-Net 与 MIPAR 对第二相的自动提取效果。其中 MIPAR 是一种集成多种常用的图像处理算法并且主要针对显微图像进行处理的软件，可以实现对图

像的人工交互式处理和批量自动化处理。根据铝合金中第二相的特征，本实验通过 MIPAR 制定了一系列图像处理操作，实现了显微图像的批量处理，处理流程如图 3 所示。另外，为了得到深度学习的训练图像以及对比实验中的参照数据，本实验通过相关专家对批量处理的结果进行人工筛选和精细微调等交互式处理，半自动地对 800 张原始数据进行标记。图 4 为 MIPAR 处理结果与人工微调后的结果，对比看出，人工微调后的结果修改了批量处理结果中的部分误差。

本研究主要使用基于深度学习的语义分割算法

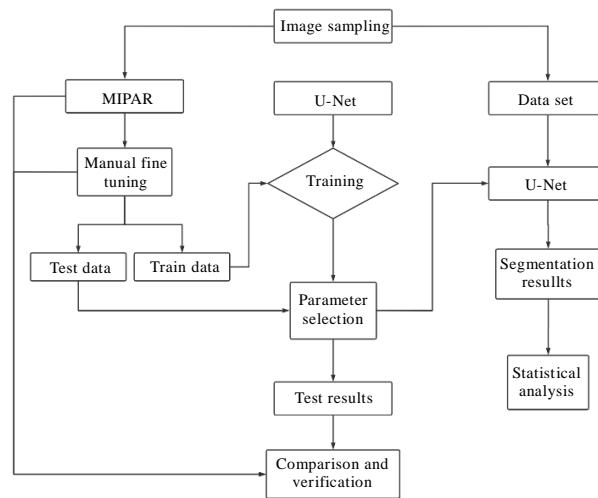


图 2 铝合金中第二相特征的定量表征流程

Fig.2 Quantitative characterization process of the second phase in aluminum alloy




图 3 MIPAR 软件处理流程图

Fig.3 Flow chart of MIPAR software processing

U-Net 从铝合金的电镜显微图像中自动、高速地提取第二相特征。U-Net 属于有监督学习算法^[26-28]，需要大量人工标记样本作为训练数据。而人工制作标记图像需要花费大量的人工时间，为了提升标记效率，本实验在训练过程使用上述 MIPAR 处理后人工微调的结果作为训练集。

U-Net 主要优点是网络体量小、速度快、对细小特征识别精确度高。与常用的图像分割^[29-31]算法不同，U-Net 通过网络对特征进行自学习与提取，并在反向传播的过程中对该过程不断优化，这个过程通过对大量待提取特征的深度信息的自动学习，既减少了人工参与引起的主观误差，又提高了该方法的泛化能力从而达到提高整体数据的分割准确性。如图 5 为使用的 U-Net 网络框架。U-Net 主要由两部分组成：前面一部分是普通的卷积操作，主要由 3×3 卷积层、最大池化层下采样、激活函数等组成，这一部分任务主要是抓取图像中高层特征信息；后面一部分是与第 1 部分对称的操作组成，主要有卷积层、转置卷积、激活函数




图 4 MIPAR 处理结果与人工微调结果

Fig.4 MIPAR processing results and manual fine-tuning results: (a) original image, (b) MIPAR processing results, and (c) manual fine-tuning results

等，目的是输出基于像素的分割结果。另外两部分之间还通过特征融合进行跳跃连接，将前半部分的得到特征和后半部分对应位置的特征进行融合以便获取更加准确的上下文信息，提高了图像分割效果。

本实验随机从标记数据中挑选 200 张图像，这 200 张图像作为最终测试数据不参与 U-Net 的任何训练过程以及 MIPAR 制定批量处理的调参过程。剩余的 600 张图像作为 U-Net 的训练数据，因样本量有限，为了充分利用数据集信息，本实验在训练过程中使用 k 折交叉验证 (k-fold-cross-validation) 法，将 600 张图像 60 张一组随机分成互斥的 10 组数据，每次训练过程中，将 10 组数据按照 9:1 的比例划分训练集和验证集进行多次迭代训练。训练完成后，按照图 2 中流程，将待处理图像传入训练好的 U-Net 模型进行自动计算后，可以直接生成提取了第二相特征的二值图像。

为了量化不同方法的特征提取效果，本实验选用平均交并比(mean intersection over union, MIoU)对性能进行评估^[32]，MIoU 是计算所有分割结果的分区区的交并比(intersection over union, IoU)的平均值，可反映预测结果和真值结果的重合度。其中 IoU 计算公式如下：

$$IoU = \frac{|P \cap T|}{|P \cup T|} \quad (1)$$

其中， P 代表预测结果， T 代表真值(ground truth)。其思路是通过计算真值和预测结果的交集和并集的比值来反映预测结果和真值的匹配程度。

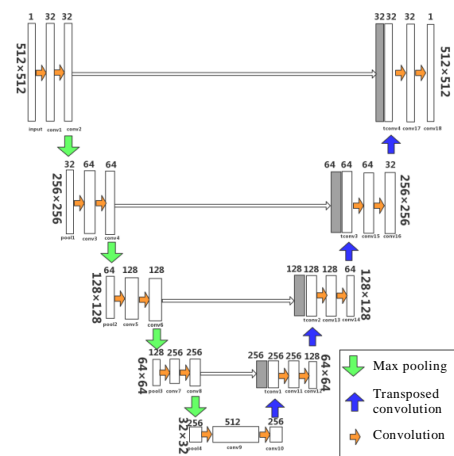


图 5 U-Net 网络框架

Fig.5 U-Net network framework

1.2.2 统计参数计算

针对第二相表征信息少的问题，本研究除了统计第二相的面积、数量、尺寸、位置信息等常用信息，还计算了第二相之间的最近邻欧氏距离、第二相粒子的长宽比等参数，并在大尺寸截面以及分区间截面上统计其空间分布情况。其中使用如下公式计算第二相颗粒长宽比：

$$LW_R = \frac{Fd^2}{S} \tag{2}$$

其中， LW_R 为长宽比， Fd 为费雷特直径， S 为面积。费雷特直径是通过一系列与颗粒相切的平行线之间距离的平均值计算所得，如公式 (3) 所示。

$$Fd = \frac{1}{n} \sum_{i=1}^n L_i \tag{3}$$

其中， n 为平行线组数， L_i 为第 i 组与多边形相切的平行线组之间的距离，如图 6 所示。

2 实验结果

2.1 模型性能

本实验使用上文中随机挑选的 200 张 7B05 铝合金 SEM 图像作为 MIPAR 以及 U-Net 提取第二相特征效果的测试数据，以人工半自动标记的结果作为本次

测试数据的真值 (ground truth, GT)。

使用 U-Net 对第二相进行提取的前提是通过训练获取一个性能较好的模型。在训练过程中，使用 k 折交叉验证法进行多次迭代训练，当损失值趋于稳定时停止迭代并保存参数。本轮训练共进行 1322 次迭代，迭代停止时验证集精确度为 94.21%。

基于深度学习的分割模型参数确定后，使用该模型对 200 张测试集进行处理，得到的分割结果与 GT 以及 MIPAR 处理结果进行对比，处理结果如图 7 所示。




图 6 费雷特直径示意图

Fig.6 Schematic of Ferret diameter




图 7 7B05 原始图像，人工微调图像，U-Net 处理结果，MIPAR 处理结果对比

Fig.7 Comparison of processing results: (a) original image, (b) manually fine-tuning image, (c) U-Net processing result, and (d) MIPAR processing result

由图 7 可以观察到 U-Net 算法对图像的分割结果和 GT 更加匹配, 为了定量对比 2 种方法处理效果, 分别计算 2 种方法处理结果的 MIoU, 计算结果如表 2 所示, 其中 U-Net 模型的 MIoU 达到 91.12%, 而 MIPAR 的 MIoU 只有 42.74%。表 2 中记录了 3 种方法处理单张数据的时间, 其中 MIPAR 和 U-Net 处理时间相差不大, 而通过人工微调时间远大于前 2 种批量处理算法的处理时间。图 7 和定量结果证明, 在相同的处理时间内, U-Net 对析出相的分割效果要远好于通过图像处理软件的批量处理方法, 而在 MIoU 可以满足需求的情况下, U-Net 处理时间远小于人工微调的时间。

为验证基于 U-Net 的第二相提取模型的泛化能力, 本实验选取商用 6 系铸轧铝合金材料 6N01。该材

料与所选 7B05 同为高速列车结构材料, 除了成分不同, 第二相的形态和分布与 7B05 相似。在 6N01 铝合金样品中随机选取部分区域采集 2424 张大小为 4096×4096 像素的 SEM 图像, 从中随机选取 200 张, 相关专家进行人工标记制作成验证数据集。使用上文中训练完成的第二相提取模型对 200 张验证数据进行测试, 并使用批量处理软件 MIPAR 对同一批数据进行处理, 处理结果如图 8。分别计算 U-Net 与 MIPAR 提取效果, 得到 MIoU 为 90.28% 与 41.23%。图 8 中 A 特征为细长条状第二相, B 特征为与第二相灰度相近的干扰项。对比图 8 中 U-Net 和 MIPAR 对 A、B 的处理效果, 其中 U-Net 能够较好地提取出 A 特征, 并且可以准确地排除 B 特征的干扰。统计 200 张验证集中第二相的总数量为 7635, 其中细长条状第二相(长宽比 >5)共计 970, U-Net 和 MIPAR 对细长条状第二相的漏检率分别为 3.7% 和 12.4%。另外, U-Net 与 MIPAR 误检 B 类特征数量分别为 0 个和 15 个。上述数据证明, 一方面通过 U-Net 网络在提取细长条状的第二相特征时更有利, 另一方面在排除灰度值相近的干扰方面基于深度学习的算法也有更好的表现。

表 2 MIPAR 与 U-Net 处理结果的 MIoU 对比

Table 2 MIoU comparison of MIPAR and U-NET processing results

Method	MIPAR	U-Net	Manual
MIoU/%	42.74	91.12	100
Time/s	0.4016	0.4031	60

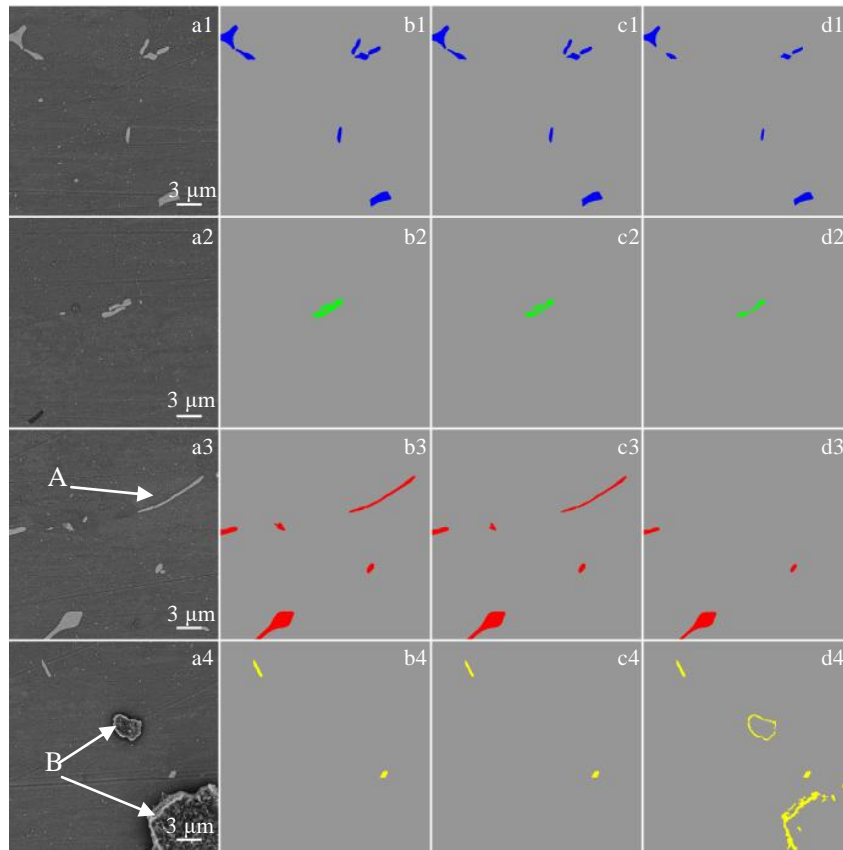


图 8 6N01 原始图像, 人工微调图像, U-Net 处理结果, MIPAR 处理结果对比

Fig.8 Processing results of 6N01: (a) original image, (b) manually fine-tuning image, (c) U-Net processing result, and (d) MIPAR processing result

通过对不同种类的铝合金中第二相进行测试，测试结果表明在相同的处理时间内通过基于深度学习的第二相提取模型比普通的第二相提取方法有更好的提取效果；另外使用未参加训练的 6N01 铝合金 SEM 图像进行测试，证实基于深度学习的第二相提取模型有较好的泛化能力。

2.2 7B05 铝合金第二相统计结果

第二相的空间分布、统计分布与材料的性能、工艺变化有着密切关系，对提取的第二相特征进行多角度的数据挖掘与分析是研究第二相特征的重要手段。经过 U-Net 分割后的图像中的特征区域通过联通区域法进行分区提取与统计，得到样品中整个截面上第二相面积、第二相总数量、单位面积中第二相数量、第二相平均面积以及长宽比等信息，统计结果如表 3 所示。

研究铝合金中显微组织的分布情况，通常沿轧板截面的厚度方向研究其从上表面到下表面的分布规律，常用的方法是从上表面、中心部位、下表面取部分特征图像进行统计分析，划分方式如图 9 所示。以 T4-6 样品为代表，研究第二相在轧制方向上的空间分布规律。

分别从 T4-6 上表面、中心层、下表面随机挑选 10 个视场并统计其中第二相特征平均面积，统计结果如图 10 所示。通过对不同区域取点统计，能在一定程度上获取第二相在整个截面上的分布规律，如图 10 中 A 表明，在铝合金中心部位，其第二相特征颗粒较大，上下表面处颗粒较小。但是随机选取的少量视场在表征分布差异时，因选取视场的误差性导致不同视场的选择呈现不同的统计结果，如图 10 中 B 所示，从上、中、下层随机选取的另一组同样数量的视场进行统计，其结果与图 10 中 A 结果互相矛盾。

为了解决上述随机选取视场引起的统计分析的误差，本研究通过对全视场第二相特征进行全面统计表征。图 11 是根据提取出的第二相的面积、数量以及位置信息，得到的 T4-6 的空间分布情况，该图显示了




图 9 研究不溶相分布差异的常用划分方式

Fig.9 Common division methods used to study the difference of phase distribution: (a) mosaic image of T4-6 feature scanning region and (b) corresponding division method, in which the blue area is the upper surface, the green area is the middle part, and the red area is the lower surface




图 10 T4-6 不同部位第二相的平均面积

Fig.10 Average area of the second phase in different parts of T4-6 (A and B are obtained by calculating the average area of the second phase in two randomly selected fields of view)

T4-6 轧板截面 60 mm² 范围内第二相的数量、面积的空间分布规律。由图 11a 可得，截面上下表面存在的第二相数量较多，中间部位第二相的数量相对较少。由图 11b 可知中间层第二相分布较稀疏，但存在面积较大第二相。

随机选取视场具有较大的随机误差，其中最主要的误差为随机选取视场带来的随机抽样误差，在随机抽样过程中随机样本过少会带来较大的误差，而传统的统计方法因统计成本较高，对第二相统计量较少，随机或者人为挑选视场都不可避免带来较大误差，而误差过大会给后续的分析研究带来较大难度。为准确

表 3 第二相信息统计结果

Table 3 Statistical results of the second phase information

Sample	T4-6	T4-15	T5-10	T5-15
Area/mm ²	0.216	0.472	0.286	0.602
Area fraction/%	0.425	0.391	0.387	0.539
Number	111249	305123	255955	390119
Number in 1 mm ²	2191.47	2528.57	3459.43	3487.50
Average area/μm ²	1.938	1.546	1.118	1.545
Aspect ratio	1.891	2.069	2.053	1.939




图 11 T4-6 中第二相数量和面积可视化结果

Fig.11 Visualization results of the number (a) and area (b) of the second phase in T4-6

量化其空间分布规律, 本实验将 T4-6 整个截面从上表面到下表面根据图 9b 均分成 3 个区域, 通过 U-Net 提取每个区域中的所有第二相, 对得到的二值图像使用连通区域计算并记录每个第二相的面积、长宽比和最短间距, 其中长宽比通过公式(2)计算得到, 第二相的最短间距定义为 2 个最近邻第二相中心的欧式距离。统计得到上、中、下 3 部分区域中第二相数量分别为 33 574、33 207、42 035, 对每个区域中所有第二相的面积、长宽比和最短间距求均值, 得到 3 个区域中第二相的平均面积、平均长宽比和平均最短间距, 如表 4 所示。其中, 第二相的平均面积分别为 1.98、2.17、1.83 μm^2 , 平均长宽比分别为 1.89、1.94、1.84, 第二相数量分别为 33 574、33 207、42 035 个。

通过 3 个区域中所有第二相计算各项参数的平均值, 计算过程中各个区域中所有特征都有相同的贡献, 所得结果相较随机选取视场更具有代表性。图 12 为 T4-6 各区域中部分视场与全视场中第二相平均面积对比图。其中 C 为 3 个区域的全视场中所有第二相的平均面积, A、B 为根据传统的统计方法, 分别通过

表 4 T4-6 中不同区域第二相特征参数统计结果

Table 4 Statistical results of second phase characteristic parameters in different regions of T4-6

Parameter	Average area/ μm^2	Number	Average aspect ratio	Average shortest distance/ μm
Upper	1.98	33574	1.89	5.34
Middle	2.17	33207	1.94	5.22
Lower	1.83	42035	1.84	5.10




图 12 T4-6 不同区域中部分视场与全视场中第二相平均面积
Fig.12 Average area of the second phase in the partial field of view and the full field of view in each region of T4-6 (samples A and B are the second phase of the two randomly selected field of view, sample C is the second phase of all fields of view in each region)

2 次随机抽样得到的平均面积, 每次从 3 个区域内分别随机选择 10 个视场。其中图 12 中 A、B、C 组视场的样本的平均标准偏差分别为 2.17、2.01 与 0.30。通过对图 12 中 3 组数据进行分析, 随机选取少量数据计算平均面积在本实验中得到的结果波动大、随机误差偏高, 对整个区域的第二相特征不具有代表性; 全视场数据样本的平均标准偏差远小于另外 2 组数据的标准偏差, 计算得到的第二相平均面积误差更小, 其趋势更具有代表性。

为了更加直观比较上下表面和中间层中第二相分布的变化趋势, 本研究通过对每一层第二相数据进行平均处理, 得到其沿厚度方向的第二相平均面积线分布, 如图 13 所示。图 13 详细地描绘了从上表面到

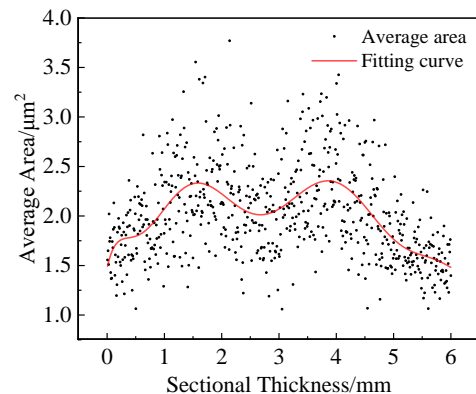


图 13 轧制方向平均面积线分布

Fig.13 Average area line distribution in rolling direction

中间层再到下表面中第二相颗粒大小的变化趋势, 从图中拟合曲线的波峰波谷的位置可以推断, 图 10 中矛盾的结论是因为视场选取引起的误差, 在材料 T4-6 中, 该方法不具有代表性。由表 4 统计结果以及图 13 的分布趋势可得, 与上下表面相比, 中间层第二相颗粒平均面积大、长宽比大, 数量少。通过全视场的定量统计, 可以快速、全面地定量第二相各项参数的面分布、线分布、平均值等信息, 为生产高性能的铝合金提供更全面的参考信息。

3 结 论

1) 采用基于深度学习的图像分割网络 U-Net 对 7B05 铝合金 SEM 图像进行快速分割提取, 和通过图像软件自动提取显微组织特征方法相比, 精确度从 42.74% 提高到 91.12%, 时间为 0.4 s/张, 处理数据量提升到 3 万余张图像, 为全面分析第二相特征提供了强大的数据依据。

2) 除了第二相的面积、数量等常规统计信息, 本方法计算了长宽比、最短间距、面分布以及线分布等多种新的表征参数, 其中线分布结果证明, 与传统的随机选取视场的统计结果相比较, 全视场多角度的统计表征方式误差更小, 特征信息更全面。

3) T4-6 大尺寸全视场的定量统计、面分布、线分布结果显示, 第二相从表面到中心部位存在尺寸变大、数目变少、长宽比变大等趋势。

参考文献 References

- [1] Song Xiaobin(宋肖滨), Jiang Yingjie(姜英杰). *China Metal Bulletin*(中国金属通报)[J], 2018, 995(8): 79
- [2] Zuo Jinrong(左锦荣), Hou Longgang(侯陇刚), Shi Jintao(史金涛) et al. *Acta Metallurgica Sinca*(金属学报)[J], 2016, 52(9): 1105
- [3] Liu Jing'an(刘静安), Li Dangjun(李党军), Shan Haizhen(单海珍). *Aluminum Fabrication*(铝加工)[J], 2015(1): 51
- [4] Zhang Xinming(张新明), Deng Yunlai(邓云来), Zhang Yong(张勇). *Acta Metallurgica Sinca*(金属学报)[J], 2015, 51(3): 257
- [5] Xu Zhen(徐振), Zhang Wei(张伟), Wang Hongbin(王洪斌) et al. *Rare Metal Materials and Engineering*(稀有金属材料与工程)[J], 2020, 49(11): 3692
- [6] Zhu Zhiyuan(朱志远), Shen Weidong(沈卫东), Zhang Fan(张帆) et al. *Journal of Central South University*(中南大学学报)[J], 2017, 6(48): 1473
- [7] Li Jichen(李吉臣), Feng Di(冯迪), Xia Weisheng(夏卫生) et al. *Acta Metallurgica Sinca*(金属学报)[J], 2020, 56(9): 1255
- [8] Shen Rujuan(沈茹娟), Xiao Daihong(肖代红). *Materials Science and Engineering of Powder Metallurgy*(粉末冶金材料科学与工程)[J], 2016, 21(1): 78
- [9] Li Ligang(李立刚), Zhao Hongmei(赵红美). *Hot Working Technology*(热加工工艺)[J], 2020, 49(22): 135
- [10] Li Ni(李妮), Dong Chaofang(董超芳), Man Cheng(满成) et al. *The Tenth National Corrosion Congress*(第十届全国腐蚀大会)[C]. Nanchang: Chinese Society for Corrosion and Protection, 2019
- [11] Zhang Yafeng(张雅峰). *Thesis for Master*(硕士论文)[D]. Beijing: North China University of Technology, 2016
- [12] Zhu Yonggang(朱永刚). *Thesis for Master*(硕士论文)[D]. Zhengzhou: Zhengzhou University, 2020
- [13] Wang Jianping(王建萍), Wang Jiaping(王家平), Xu Jianguang(许建广). *Materials Reports*(材料导报)[J], 2003, 17(1): 63
- [14] Shan Xiao(单萧). *Thesis for Master*(硕士论文)[D]. Shenyang: Northeastern University, 2013
- [15] Yu Jianhao(余剑豪). *Thesis for Master*(硕士论文)[D]. Jilin: Jilin University, 2020
- [16] Chao Daiyi(晁代义), Yu Fang(于芳), Li Hongping(李红萍) et al. *Materials Reports*(材料导报)[J], 2020, 34(S2): 1362
- [17] Zou Lingyun(邹凌云), Wu Shiqian(伍世虔), Fang Hongping(方红萍) et al. *Application Research of Computers*(计算机应用研究)[J], 2019, 36(10): 2894
- [18] Ma Boyuan(马博渊), Liu Chunni(刘楚妮), Gao Mingfei(高鸣飞) et al. *Chinese Journal of Stereology and Image Analysis*(中国体视学与图像分析)[J], 2020, 25(2): 120
- [19] Tsutsui K, Terasaki H, Uto K et al. *Materials Today Communications*[J], 2020, 25: 101 514
- [20] Kim H, Inoue J, Kasuya T. *Scientific Reports*[J], 2020, 10(1): 17 835
- [21] Ma W, Kautz E, Baskaran A et al. *Journal of Applied Physics*[J], 2020, 128(13): 134 901
- [22] Ban Xiaojuan(班晓娟), Su Yanjing(宿彦京), Xie Jianxin(谢建新). *Materials Science and Technology*(材料科学与工程)[J], 2020(3): 68
- [23] Ronneberger O, Fischer P, Brox T. *Medical Image Computing and Computer Assisted Intervention 18th International Conference*[C]. Munich, Germany: MICCAI, 2015
- [24] Gonzalez R C, Woods R E. *Digital Image Processing*[M]. London: Prentice Hall International, 2008
- [25] Jonathan Long, Evan Shelhamer, Trevor Darrell. *2015 IEEE Conference on Computer Vision and Pattern Recognition*[C]. New York: IEEE, 2015

- [26] Li Xiaojuan(李小娟), Han Meng(韩 萌), Wang Le(王 乐) *et al.* *Application Research of Computers*(计算机应用研究)[J], 2020(9): 351
- [27] Li Heng(李 恒), Zhang Liming(张黎明), Jiang Meirong(蒋美容) *et al.* *Laser & Optoelectronics Progress*(激光与光电子学进展)[J], 2020, 57(8): 081 015
- [28] Yang Shengchun(杨盛春), Jia Linxiang(贾林祥). *Journal of Xuzhou Institute of Architectural Technical*(徐州建筑职业技术学院学报)[J], 2006, 6(3): 55
- [29] Wang Qian(王 茜), Peng Zhong(彭 中), Liu Li(刘 莉). *Transactions of Beijing Institute of Technology*(北京理工大学学报)[J], 2003(4): 521
- [30] Xiang Rihua(向日华), Wang Runsheng(王润生). *Journal of Software*(软件学报)[J], 2003(7): 1250
- [31] Zhang Yifan(张一凡), Kang Yan(康 雁), Lin Ying(林 英). *Electronic Technology and Software Engineering*(电子技术与软件工程)[J], 2016, 75(1): 109
- [32] Xu Shengjun(徐胜军), Ouyang Puyan(欧阳朴衍), Guo Xueyuan(郭学源) *et al.* *Optical and Precision Engineering*(光学精密工程)[J], 2020, 28(7): 1588

Identification and Quantitative Statistical Analysis of Second Phase in Aluminum Alloy Based on Deep Learning Algorithm

Wan Weihao^{1,3}, Sun Dandan², Li Dongling^{2,3}, Zhao Lei^{2,3}, Shen Xuejing^{2,3}, Wang Haizhou^{2,3}, Han Bing²

(1. Central Iron & Steel Research Institute, Beijing 100081, China)

(2. NCS Testing & Technology Co., Ltd, Beijing 100081, China)

(3. Beijing Key Laboratory of Metal Materials Characterization, Beijing 100081, China)

Abstract: The second phase particles in aluminum alloy are produced in the casting process and have a significant effect on the physical and chemical properties of the material. At present, the commonly used quantitative characterization methods of the second phase have the problems of too much manual work and time consumption. In this research, a fast extraction and quantitative statistical characterization method of the second phase in large-scale aluminum alloy based on deep learning was proposed. This method can achieve multi angle refined quantitative statistics by fast and intelligent extraction of the second phase features in the image. The results show that the image processing time of this method is the same as that of software batch processing, which is only 0.4 s/sheet, but the image segmentation accuracy is improved from 42.74% to 91.12%. In terms of data set making, this method uses MIPAR software combined with manual fine tuning to replace traditional manual marking, greatly saving the manual work time. In order to meet the requirements of fine characterization, 30000 full field SEM images of 7B05 aluminum alloy, including four types, were segmented and extracted. The new characterization parameters of the second phase, such as aspect ratio, shortest distance, surface distribution and line distribution, were calculated. The results of line distribution show that the full field multi angle method used in this research is better than the traditional statistical results of randomly selected field of view. This method shows that the error of statistical representation is smaller and the feature information is more comprehensive. The quantitative statistical results show that the average area of the second phase is the smallest at the nearest upper and lower surface of the cast rolled 7B05-T4 aluminum alloy section with a thickness of 6 mm, and there is a trough value near the thickness of 3 mm. The section are divided into three areas, and the average area of the second phase is 1.98, 2.17 and 1.83 μm^2 , the average aspect ratio is 1.89, 1.94 and 1.84, and the number of the second phase is 33 574, 33 207 and 42 035. The above results show that the rapid extraction and quantitative statistical characterization method of the second phase in aluminum alloy based on deep learning can carry out multi angle data analysis and mining, and provide the basis for the study of microstructure and properties.

Key words: 7B05 aluminum alloy; the second phase; deep learning; U-Net; full field of view quantitative statistics

Corresponding author: Wan Weihao, Candidate for Ph. D., Central Iron & Steel Research Institute, Beijing 100081, P. R. China, E-mail: wanghaizhou@ncschina.com