

ED-NAS: 基于神经网络架构搜索的陶瓷晶粒SEM 图像分割方法

蔡超丽¹, 李纯纯², 黄琳¹, 杨铁军¹

(1. 桂林理工大学广西嵌入式技术与智能系统重点实验室, 广西桂林 541006;
2. 桂林理工大学材料科学与工程学院, 广西桂林 541006)

摘要: 为了提高深度卷积神经网络(Convolutional Neural Network, CNN)设计的自动化程度并进一步提高陶瓷晶粒扫描电子显微镜(Scanning Electron Microscope, SEM)图像分割的准确性,提出了一种基于神经网络架构搜索的陶瓷晶粒图像分割方法. 该方法设计多分支结构编码空间和链式结构解码空间,并构造多分支结构编码Cell和链式结构解码Cell;同时基于强化学习分别搜索最佳编码Cell和解码Cell;此外,基于编码-解码神经网络架构堆叠最佳Cell构建陶瓷晶粒图像分割CNN,并采用池化索引在解码阶段恢复丢失的细节信息. 实验在包含了629张的陶瓷晶粒SEM图像数据集上进行,搜索最佳Cell耗时约148 GPU-时. 与U-Net、SegNet等SOTA方法相比,该方法在陶瓷晶粒测试集上获得了更高的分割准确性(mIoU \approx 68.9%).

关键词: 神经网络架构搜索; 编码-解码神经网络架构; 陶瓷晶粒; 图像分割; 编码Cell; 解码Cell
中图分类号: TP389.1 **文献标识码:** A **文章编号:** 0372-2112(2022)02-0461-09
电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20201416

ED-NAS: Ceramic Grain Segmentation Based on Neural Architecture Search Using SEM Images

CAI Chao-li¹, LI Chun-chun², HUANG Lin¹, YANG Tie-jun¹

(1. Guangxi Key Laboratory of Embedded Technology and Intelligent System, Guilin University of Technology, Guilin, Guangxi 541006, China; 2. School of Materials Science and Engineering, Guilin University of Technology, Guilin, Guangxi 541006, China)

Abstract: In order to improve the automation degree of deep convolutional neural network(CNN) design and further improve the accuracy of ceramic grain segmentation using scanning electron microscope(SEM) images, a ceramic grain segmentation method is proposed based on neural architecture search. This method designs searching spaces including the ones of multi-branch structure for encoding and chain structure for decoding, where encoding cells(E-cell) and decoding cells(D-cell) are constructed. The best E-cell and D-cell are found using reinforcement learning. Moreover, an encoding-decoding neural architecture-based CNN is built for ceramic grain segmentation by stacking the best cells, and the pooling indices are adopted to recover the lost details in the decoding stage. The experiment was carried out on a dataset of 629 SEM images of ceramic grain, and the searching process took about 148 GPU-hours. Compared with SOTA methods such as U-Net and SegNet, the proposed method obtained higher segmentation accuracy(mIoU \approx 68.9%) on a ceramic grains test dataset.

Key words: neural architecture search; encoding-decoding neural architecture; ceramic grains; image segmentation; encoding cell; decoding cell

1 引言

陶瓷材料是一种多晶体材料,可以广泛应用于生物

医疗、民生和军工等多个领域^[1,2]. 研究人员通常利用扫描电子显微镜(Scanning Electron Microscope, SEM)对陶瓷样品扫描成像,通过分析图像中晶粒的尺寸分布来估

收稿日期:2020-12-11;修回日期:2021-10-19;责任编辑:李勇锋

基金项目:国家自然科学基金(No.61941202);广西自然科学基金(No.2018GXNSFBA281081);广西嵌入式技术与智能系统重点实验室开放基金(No.2020-2-2)

计陶瓷样品的性能^[3]. 图1展示了一种陶瓷材料SEM图像,由晶粒和晶界(晶粒间的空隙)组成,其中晶粒根据形状可分为圆柱状晶粒(实线标注)和板条状晶粒(虚线

标注). 晶粒的形状、大小、数量和分布对陶瓷材料性能有着直接的影响^[4],因此统计分析SEM图像中晶粒尺寸和分布对陶瓷材料的研究有重要的意义.




图1 陶瓷晶粒SEM图像

当前对陶瓷材料的SEM图像中的晶粒分析主要依靠人工手段,统计结果具有明显的局限性. 首先,一幅SEM图像包含大量的陶瓷晶粒,人工统计耗时耗力,效率低难度大;其次,晶粒形状不规则,对比度较低,人工统计易受到主观影响而导致统计结果出现偏差^[5],因此,研究晶粒尺寸分布的自动分析方法很有必要. 起初,基于边缘检测的算法^[6]被用于分割晶粒,但对于不清晰晶粒轮廓的提取并不理想;为了更好地提取晶粒的封闭轮廓,Qing等^[7]先对边缘信息进行增强,然后使用分水岭算法^[8]进行晶粒分割,但存在“过度分割”问题;因此,Heilbronner等^[9]提出了一种基于梯度滤波的自动晶界检测方法,但输入图像的质量和数量对结果影响较大. 这些方法采用传统的图像处理技术对晶粒进行分割,但是陶瓷晶粒SEM图像中的晶粒内部灰度不均匀,晶粒大小不一致且形状不规则,分割准确性并不高且无法区分不同的晶粒类型.

受到卷积神经网络(Convolutional Neural Network, CNN)^[10]在医学图像分割^[11]、遥感图像分割^[12]中的应用的启发,Jiang F等^[13]提出了一种基于神经网络和模糊聚类算法的砂岩晶粒分割方法;Boyuan等^[14]提出了一种改进的U-Net^[11]神经网络架构和加权损失函数,提高了晶粒边界检测结果且适用于多晶材料分割;雷涛等人^[4]将富卷积特征网络^[15]与分水岭算法结合实现了较准确的晶粒分割,但图像质量对分割结果影响较大. 这些方法在设计CNN模型时,需要进行大量的参数调优(如调整CNN的网络层数、拓扑结构和每层的卷积核大小、数量等).

神经网络架构搜索(Neural Architecture Search, NAS)^[16]促进了CNN架构设计的自动化. 该方法能针对分割任务自动构建高性能的CNN架构^[17,18]. NAS的关键过程包括搜索空间定义,制定搜索策略和性能评估策略^[19]. 搜索策略定义了使用怎样的算法可以快速

准确地找到最优的网络结构和参数配置,如基于强化学习^[20,21]和进化算法^[22]搜索最优架构. 性能评估策略定义了如何评估候选结构的性能以更高效地找到最佳网络架构,如网络映射^[23]等.

搜索空间用于定义可搜索的网络结构^[19],最终产生的网络体系结构的性能与搜索空间的定义密切相关. 早期NAS的搜索空间采用链式结构^[24],每一层的输出作为下一层的输入. 受到ResNet^[25]中跳跃连接的启发,多分支结构被提出以增加网络连接的多样性和融合不同尺度的特征. NAS可以直接搜索整个网络,但这种方式往往需要耗费巨大的计算资源^[16]. 为了提高搜索效率,NAS可以先搜索有效且可重复的子网络结构(如Cell或Block),再堆叠最佳Cell或Block构成整体的CNN^[26,27]. 目前,基于NAS自动构建的CNN在基础图像分类性能指标上已经超过人工设计的CNN^[21,27].

在陶瓷晶粒分割这样的图像分割任务中,由于晶粒的特征提取与空间定位是两种不同的任务,无法将图像分类的CNN方法直接迁移至图像分割. 基于编码-解码神经网络架构(Encoding and Decoding Neural Architecture, EDNA)的CNN考虑到了图像分割的特殊性,例如具有对称编码-解码结构的U-Net^[11]将深层语义特征与细粒度浅层信息融合,生成更准确的分割图像;使用多层转置卷积网络改善解码器的DeconvNet^[28]能更好的确定目标的粗略信息和细节信息;SegNet^[29]在编码阶段保留池化操作的空间位置信息,即池化索引(Pooling indices),然后在解码阶段利用Pooling indices恢复更加准确的目标位置. 这些手工设计的图像分割神经网络为基于NAS的图像分割模型提供了一定的神经网络架构基础.

为了提高CNN设计的自动化程度并进一步提高陶瓷晶粒图像分割的准确性,一种改进的基于编码-解码神经网络架构的NAS方法被提出. 本文的主要贡献如下:

(1)提出了一种针对陶瓷晶粒分割的NAS方法. 该方法基于EDNA定义搜索空间,将搜索空间分为编码空间和解码空间并且同时进行搜索. 其中,编码空间采用融合深层和浅层特征的多分支式结构,解码空间则采用精细捕获特征映射的简单链式结构. 然后,将搜索到的最佳Cell堆叠形成EDNA的CNN并应用于陶瓷晶粒分割. 我们将其命名为编码解码-神经网络架构搜索(Encoding and Decoding-Neural Architecture Search,ED-NAS).

(2)构建了一个陶瓷晶粒数据集,并且ED-NAS方法在该数据集上与一些人工设计的SOTA图像分割方法相比能够实现更好的CNN架构设计效率和具有竞争力的模型评估精度.

2 方法

该方法主要包括三个步骤:搜索空间定义,搜索最佳Cell和Cell堆叠与测试(如图2所示). 首先,为了能够更好地在图像分割任务中融合多尺度信息并恢复空间信息,基于EDNA定义搜索空间,其中编码Cell(Encoding cell,E-cell)采用多分支结构,解码Cell(Decoding cell,D-cell)采用链式结构;然后,采用强化学习^[30]方法分别搜索最佳的E-cell和D-cell;最后,将搜索到的最佳Cell堆叠起来形成EDNA的CNN,进行陶瓷晶粒分割测试.

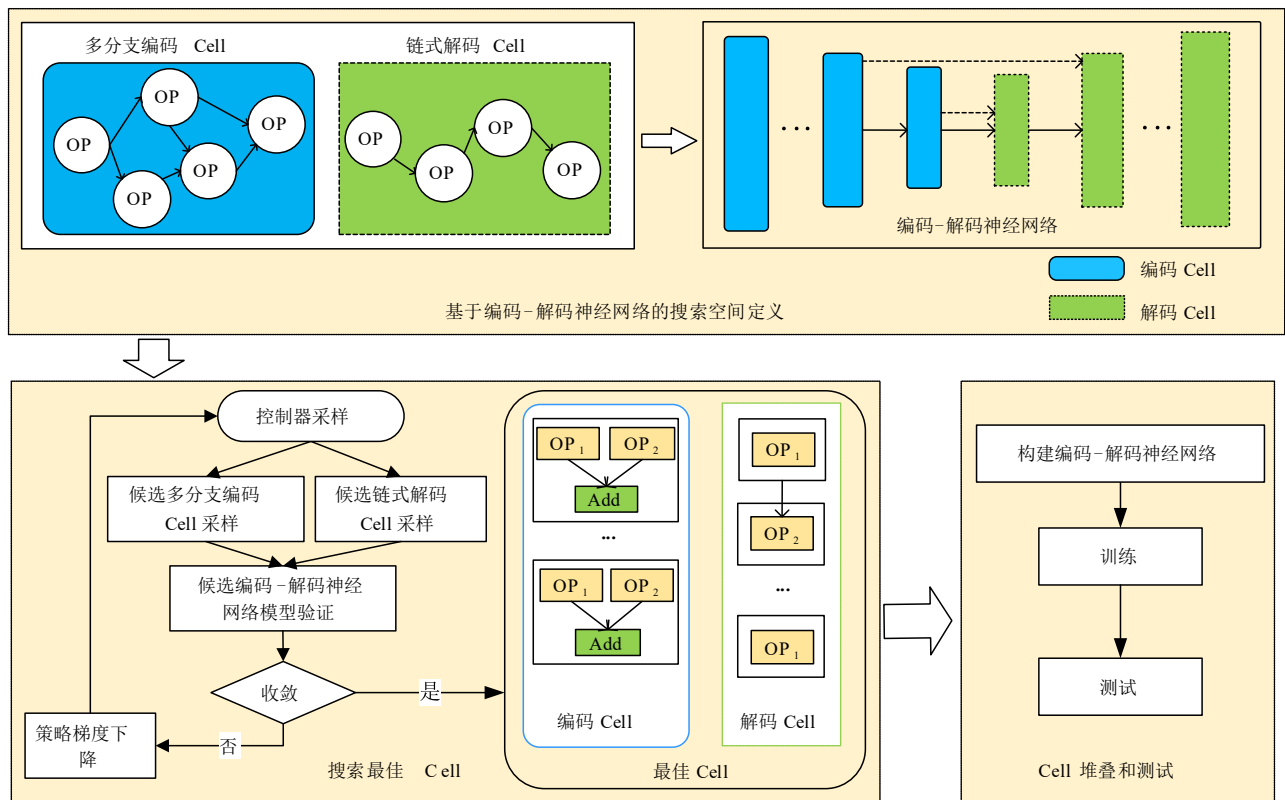


图2 ED-NAS方法总体流程图

2.1 定义搜索空间

基于EDNA的CNN主要由编码器和解码器组成,编码器提取不同尺度的图像特征,解码器将编码器中的抽象特征恢复为原始图像大小并逐步修复图像细节,实现像素级分类. 受到U-Net^[11]、SegNet^[29]等的启发,ED-NAS的候选网络也采用了EDNA.

首先,多尺度信息的充分融合对分割准确性有较大的影响^[31]. 为了充分提取到图像的多尺度特征,可采用具有跳跃连接的多分支结构^[25]. 因此,在NAS中搜索具有多分支结构的子网络作为E-cell.

解码器主要捕获特征映射中的多尺度信息并分层

逐级实现每个像素的类别标注^[11],因此,在解码阶段,预期使用简单的链式结构更好地恢复空间位置信息. 与其它NAS的搜索空间不同的是,我们的候选网络不仅仅使用一种空间结构(只有链式结构^[16]或者只有多分支结构^[17]),而是搜索两种类型的Cell. 在编码阶段,采用多分支结构的搜索空间,即搜索E-cell;在解码阶段,采用链式结构的搜索空间,即搜索D-cell.

一个E-cell中通常包含多个Block,每个Block是一个双分支结构,将来自前面Cell的两个输入张量映射为一个输出张量. Block的输入和操作的选择由控制器决定. 如图3(a)所示,E-cell中的Block可以使用一个四

元组编码 $\{I_1, OP_1, I_2, OP_2\}$ 表示, 其中 I_1, I_2 代表一个 Block 的两个分支输入; $OP_1, OP_2 \in O$ 代表 Block 两个分支的操作, O 代表候选操作集合.

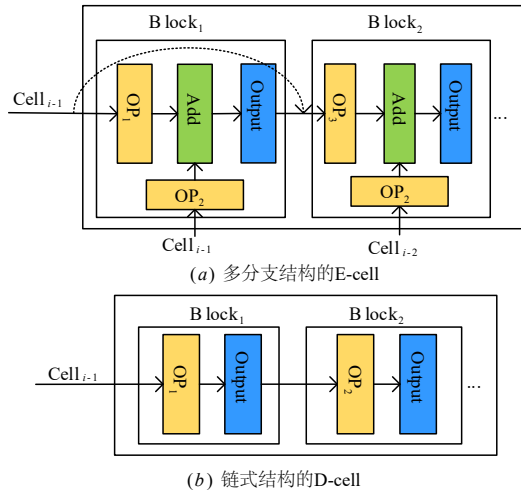


图3 Cell空间的表示

一个 D-cell 中也包含多个 Block, 但一个 Block 仅接受来自前面一个 Cell 的输入, 呈链式结构 (如图 3(b) 所示). D-cell 中的 Block 使用二元组编码 $\{I_1, OP_1\}$ 表示, 其中 I_1 代表 Block 的输入, $OP_1 \in O$ 代表 Block 的操作.

候选操作除了使用普通卷积 (conv) 之外, 还包括能够降低参数数量和运算成本的深度可分离卷积 (depth-wise separable convolution, dw conv) 以及能够增大感受野的空洞卷积 (dilated convolution, dl conv) 以及最大池化操作 (如表 1 所示).

表 1 候选操作集合

操作	操作码
3×3 dw conv	0
5×5 dw conv	1
3×3 conv	2
3×3 dl conv, dilation rate=2	3
3×3 max pooling	4

2.2 搜索最佳 Cell

采用与 ENAS^[30] 中相似的搜索策略搜索最佳 E-cell 和 D-cell. 首先, 基于循环神经网络^[32] 的控制器包含两个采样器, 分别对四元组编码的 E-cell 和二元组编码的 D-cell 同时进行采样. 1 个 E-cell 四元组编码对应 1 个 Block, 包含 2 个操作码 (见表 1), 1 个 D-cell 二元组编码仅包含 1 个操作码. 控制器采样 N 个 Block 编码构建 1 个 E-cell 或 D-cell, 通过堆叠多个 E-cell 和 D-cell 构建基于 EDNA 的候选网络, 使用随机梯度下降算法来进行训练, 并在验证集上进行验证. 根据候选网络的分割精度

(Mean Intersection over Union, mIoU), 采用基于策略梯度^[33] 的强化学习算法更新控制器的参数 (如候选操作的采样概率等). 之后, 进行新一轮的采样, 直到获得最优分割准确性的候选网络.

2.3 Cell 堆叠与测试

将搜索到的最佳 E-cell 和 D-cell 堆叠起来构建用于陶瓷晶粒分割的 CNN. 如图 4 所示, 我们分别堆叠 L 个 E-cell 和 D-cell 构建基于 EDNA 的神经网络. 为了不在搜索时引入更大的参数量, 我们将下采样 (Max-pooling) 操作固定在每个 E-cell 后面, 上采样 (Upsampling) 操作固定在每个 D-cell 前面. 为了保留编码阶段的空间位置信息, 在解码阶段的上采样中融合池化索引^[29] 来恢复目标的空间位置, 即将解码器生成的特征映射与池化索引相融合生成更准确的分割图像. 在神经网络的最后使用 Softmax 对最后一个解码器产生的高维特征映射进行类别转换得到最终的分割结果.

3 实验

实验采用 PyTorch 1.4.0 实现, 系统环境为 Win10, CPU Intel i7, DDR4 RAM 16 GB, GPU GTX1070 Ti 8 GB. 实验包括搜索和测试两个阶段. 在搜索阶段, 分别对比了不同 Block 数量 (N) 的候选网络分割准确性, 以确定最佳 Cell 包含的 Block 数量; 进一步, 对比了 D-cell 采用多分支和链式结构的候选网络分割准确性, 以验证 D-cell 的链式结构的优越性. 在测试阶段, 采用搜索到的最佳 Cell 构造基于 EDNA 的神经网络, 对比了不同 Cell 堆叠个数 (L) 的神经网络分割准确性, 并与 ERFNet^[34]、U-Net^[11]、ENet^[35]、FCN-16^[12]、DeepLabv3^[36] 和 SegNet^[29] 等 6 种 SOTA 方法进行了比较.

3.1 数据集

陶瓷晶粒图像采用日立 S-4800 冷场发射扫描电子显微镜拍摄, 采集的图像分辨率从 1 280×960 像素到 2 560×1 920 像素, 如图 5 左侧所示.

采集的 SEM 图像主要包括板条状和圆柱状 2 种形态的陶瓷晶粒. 由于单张图像中晶粒数目较多, 若直接在原始图像中标记, 那么一个样本需要手工标记几十个同类型的晶粒, 工作量很大. 为了提高手工标记的效率和减少同一样本中同类型对象的重复标记, 采用随机选择裁剪区域的方式, 且控制一个区域内的晶体数量为 2~3 个. 这样做还能增加样本数量的规模, 减少单个样本的数据量, 有利于后续的神经网络训练. 裁剪后的图像如图 5 右侧所示, 其中 3 张裁剪后的图像样本都包含完整的板条状和圆柱状晶粒, 每个样本包含的晶粒总数为 2~3.

接下来, 使用 js-segment-annotator-master 对图像样本进行标注 (<https://github.com/kyamagu/js-segment-an>)




图4 堆叠Cell构建基于EDNA的神经网络(编码器采用多个E-cell堆叠构成,解码器采用相同数量的D-cell堆叠构成,每个E-cell紧跟一个Max-pooling层,并且将Pooling indices 复制给解码器对应的D-cell供其使用)





图5 原始图像(左侧)和裁剪后的图像(右侧)



(a) 图像样本 (b) 可视化后的GT

图6 可视化后的标注结果示例

notator). 板条状晶粒区域标记为1, 圆柱状晶粒区域标记为2, 其他区域(背景)标注为0. 图6展示了可视化后的标注结果示例. 标注后的数据集包含629个图像样本和对应的标注结果(Ground Truth, GT). 该数据集进一步按照7:1:2的比例被随机划分为训练集、验证集和测试集. 表2显示了数据集的数量分布及类别标签.

表2 数据集数量分布及标签

类别	训练集	验证集	测试集	总数	标签
板条状	422	60	119	601	1
圆柱状	435	63	125	623	2

3.2 参数设置

在搜索阶段, 控制器的学习率为0.003 5, 训练epochs为50, 优化算法采用Adam; 候选神经网络使用SGD进行训练, batch size为1, epochs为300, 学习率为0.05(指数型衰减), 其它参数与ENAS^[30]相同. 在测试阶段, 堆叠的神经网络采用Adam进行训练, batch size为2, 学习率为0.000 04, 共训练150个epochs. 搜索阶段采用训练集进行训练, 采用验证集评估候选网络分割准确性. 测试阶段同样采用训练集进行训练, 采用测试集评估搜索到的神经网络. 评估指标均采用mIoU.

3.3 搜索最佳Cell

首先, 对比在不同 N 值下, D-cell采用链式结构或多分支结构时候选网络分割准确性. 分别设置 $N=3, 4$, 对应的 $L=4, 3$ (保证在不同 N 值下候选网络的Block总数相当), D-cell分别采用链式和多分支结构, 多分支结构D-cell的编码形式与E-cell相同. $N=3, 4$ 时搜索到的最佳Cell分别命名为Best-cell _{$N=3$} 和Best-cell _{$N=4$} .

表3列举了这4种候选网络的最佳验证准确性.由表3可知,当 $N=4, L=3$, D-cell采用提出的链式结构时, mIoU最高(56.6%). 当 N, L 值相同, D-cell采用链式结构时均比多分支结构更高. 在相同的Block总数条件下, $N=4$ 比 $N=3$ 时更高.

表3 候选网络最佳验证准确性比较

候选网络	分割精度(mIoU)/%
$N=3, L=4$, 链式结构 D-cell	54.9
$N=4, L=3$, 链式结构 D-cell	56.6
$N=3, L=4$, 多分支结构 D-cell	51.3
$N=4, L=3$, 多分支结构 D-cell	53.5

这4种候选网络的最佳Cell结构分别如图7、图8所示. 图7展示了D-cell采用链式结构时 $\text{Best-cell}_{N=3}$ 和 $\text{Best-cell}_{N=4}$ 的结构, $\text{Best-cell}_{N=4}$ 的E-cell和D-cell均多1个Block, D-cell的一个Block的输入仅来自前一个Block的输出, 结构相对简单; $N=4$ 时, 连接和操作的更多选择使结构更丰富的E-cell能够捕获更全面的特征映射, 对应的D-cell恢复更精细的特征信息, 由表3可知, 其对应候选网络获得了更好的准确性. 图8展示了D-cell采用多分支式结构时 $\text{Best-cell}_{N=3}$ 和 $\text{Best-cell}_{N=4}$ 的结构, 与图7相比, 其D-cell与E-cell均采用多分支结构, 综合表3分析, 具有较为复杂的多分支结构D-cell候选网络获得的分割精度比链式结构的更低. 搜索多分支结构最佳Cell约耗费87 GPU-时, 远高于搜索简单链式结构最佳Cell(约61 GPU-时).

因此, 将采用多分支结构E-cell和链式结构D-Cell的EDNA神经网络在陶瓷晶粒数据集上进行测试.

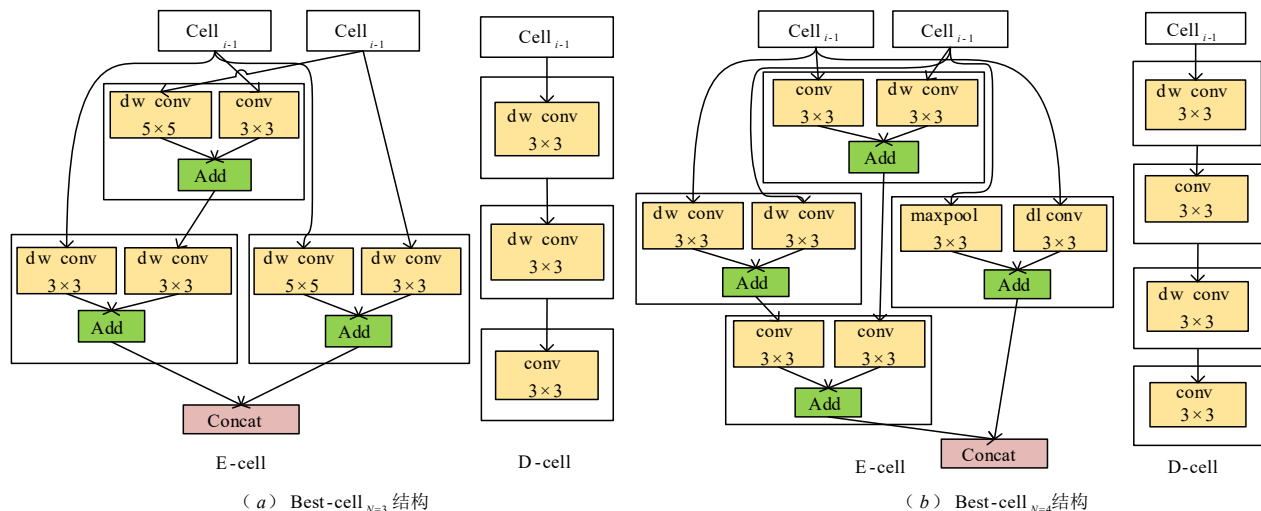


图7 D-cell采用链式结构, 不同 N 值时的最佳Cell结构

图10展示了ED-NAS和其它几种方法在陶瓷晶粒上分割结果的示例. 第1列为原始图像, 第2列为GT,

3.4 陶瓷晶粒分割结果

测试阶段, 堆叠更深的神经网络以获得最佳的分割准确性. 测试时, 分别设置 $L=3, 4, 5, 6$ 并采用图7中两种最佳Cell($\text{Best-cell}_{N=3}, \text{Best-cell}_{N=4}$)进行堆叠实验.

图9展示了两种最佳Cell在不同 L 值时构建的EDNA神经网络在陶瓷晶粒测试集上的分割准确性比较. 总体来看, L 从3增加为5时, mIoU随着 L 的增大而增加, 但当 L 继续增大到6时, mIoU均有所下降. 当 $L=3$ 时, $\text{Best-cell}_{N=3}$ 和 $\text{Best-cell}_{N=4}$ 构建的神经网络分割准确性很接近(mIoU ≈ 0.5); 当 L 增加至4, 5和6时, $\text{Best-cell}_{N=4}$ 的分割准确性均比 $\text{Best-cell}_{N=3}$ 高. 当 $L=5, N=4$ 时, 获得最优的分割准确性, 该神经网络将被选择在陶瓷晶粒数据集上进行测试并与其它方法进行比较.

表4展示了ED-NAS、ERFNet^[34]、U-Net^[11]、ENet^[35]、FCN-16^[12]、DeepLabv3^[36]和SegNet^[29]在陶瓷晶粒数据集上的分割准确性比较. 由表4可见, ED-NAS的分割准确性最高(mIoU=68.9%). SegNet略低于ED-NAS分割准确性(mIoU=68.0%), 它和ED-NAS均采用了EDNA和Pooling indices, 但ED-NAS中的E-cell使用跳跃连接融合了浅层和深层特征, 特征提取更加丰富精细, 从而整体分割准确性比SegNet更好. 虽然采用EDNA的U-Net在边界信息模糊的医学图像中表现出色, 但在陶瓷晶粒图像分割中其mIoU约为47.7%. 采用级联模块和金字塔池化框架的DeepLabv3能够扩大感受野提取多尺度信息, 但与ED-NAS相比, 对晶粒分割的整体准确性仍有欠缺. ERFNet和ENet的体系结构在神经网络深度或者宽度方面均有所欠缺, 导致网络性能不高, 其mIoU也都低于50%.

随后几列为各种方法的分割结果. RfNet、U-Net和FCN-16的分割结果与GT有很大偏差; ENet和Deep-

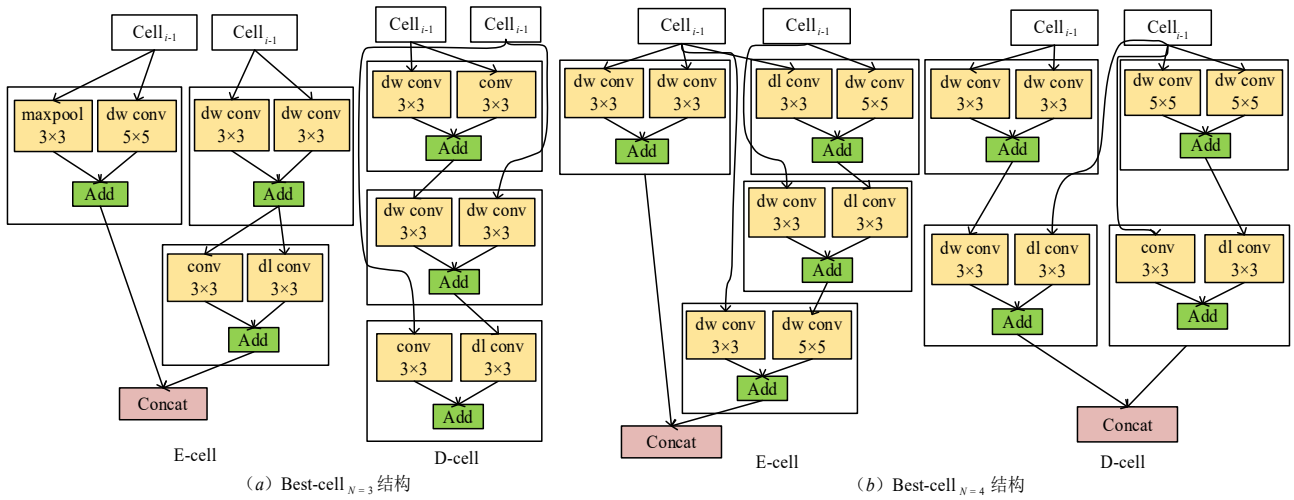


图 8 D-cell采用多分支结构,不同N值时的最佳Cell结构




图 9 不同N值下堆叠L个最佳Cell的EDNA神经网络的准确性比较

Labv3对有些图像的预测结果有较高的准确度,但对只有一种晶粒类别图像的预测有较大偏差;SegNet的结果相对比较准确,但在有些图像的边界像素点的预测上仍存在一定误差,而ED-NAS在一定程度上消除了这

表 4 不同方法在陶瓷晶粒数据集上的分割准确性

方法	分割精度 (mIoU)/%
ERFNet ^[34]	40.4
U-Net ^[11]	47.7
ENet ^[35]	48.8
FCN-16 ^[12]	58.1
DeepLabv3 ^[36]	59.1
SegNet ^[29]	68.0
ED-NAS	68.9




图 10 几种方法在陶瓷晶粒数据集上的分割结果示例

种误差,取得了更好的分割准确性。

4 总结

本文提出了一种基于NAS的陶瓷晶粒SEM图像分割方法.该方法能够根据陶瓷晶粒数据集,自动搜索多分支结构的E-cell和链式结构的D-cell,并采用堆叠方式构建基于EDNA的神经网络取得了较高的分割准确度.此外,该方法在实验结果上表明多分支结构E-cell和链式结构D-Cell的候选网络准确度更高于多分支结构的E-cell和D-cell候选网络.所提出的方法能够为陶瓷晶粒数据集自动设计有效的CNN模型,与先进的手工设计的神经网络相比,表现出了具有竞争力的结果.为进一步提高陶瓷晶粒分割准确率,下一步研究将考虑添加能够捕获更多上下文信息的操作模块(如注意力模块)来改善搜索空间,并改进搜索策略以获得更好分割性能的神经网络架构.

参考文献

- [1] 张伟儒,李伶,王坤.先进陶瓷材料研究现状及发展趋势[J].新材料产业,2016,(1):2-8.
ZHANG Weiru, LI Ling, WANG Kun. Research status and development trend of advanced ceramic materials[J]. New Materials Industry, 2016, (1): 2-8. (in Chinese)
- [2] CHEN Y W, MOUSSI J, DRURY J L, et al. Zirconia in biomedical applications[J]. Expert Rev Med Devices, 2016: 945-963.
- [3] VIOLA G, CHONG K B, ERIKSSON M, et al. Effect of grain size on domain structures, dielectric and thermal depoling of Nd-substituted bismuth titanate ceramics[J]. Applied Physics Letters, 2013, 103(18): 899.
- [4] 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,2020,46(x):1-16. DOI:10.16383/j.aas.c200277.
LEI Tao, LI Yuntong, ZHOU Wenzheng, et al. Grain segmentation of ceramic materials using data-driven jointing model-driven[J]. Acta Automatica Sinica, 2020, 46(x): 1-16. DOI:10.16383/j.aas.c200277. (in Chinese)
- [5] BODNAR J L, NICOLAS J L, CANDORÉ J C. Non-destructive testing by infrared thermography under random excitation and ARMA analysis[J]. International Journal of Thermophysics, 2012, 33(10-11): 2011-2015.
- [6] ZHANG L X, XU Z, WEI S, et al. Grain size automatic determination for 7050 Al alloy based on a fuzzy logic method[J]. Rare Metal Materials and Engineering, 2016, 45: 548-554.
- [7] LI Q, NI X, LIU G. Ceramic image processing using the second curvelet transform and watershed algorithm[C]//IEEE International Conference on Robotics and Biomimetics(ROBIO). Sanya, China: IEEE, 2007: 2037-2042.
- [8] VINCENT L, SOILLE P. Watersheds in digital spaces: An efficient algorithm based on immersion simulations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, 13(6): 583-598.
- [9] HEILBRONNER R. Automatic grain boundary detection and grain size analysis using polarization micrographs or orientation images[J]. Journal of Structural Geology, 2000, 22: 969-981.
- [10] SCHMIDHUBER J. Deep learning in neural networks: An overview[J]. Neural networks, 2015, 61: 85-117.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [EB/OL]. (2015-05-18). <https://arxiv.org/abs/1505.04597>.
- [12] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA: IEEE, 2015: 3431-3440.
- [13] JIANG F, GU Q, HAO H, et al. Feature extraction and grain segmentation of sandstone images based on convolutional neural networks[C]//24th International Conference on Pattern Recognition(ICPR). Beijing, China: IEEE, 2018: 2636-2641.
- [14] MA B, LIU C, WEI X, et al. WPU-Net: Boundary learning by using weighted propagation in convolution network[EB/OL]. (2019-05-22). <https://arxiv.org/abs/1905.09226>.
- [15] LIU Y, CHENG MM, HU X, et al. Richer convolutional features for edge detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 3000-3009.
- [16] ZOPH B, LEQ V. Neural architecture search with reinforcement learning[EB/OL]. <https://arxiv.org/abs/1611.01578>, 2017-02-15.
- [17] LIU C, CHEN LC, SCHROFF F, et al. Auto-deeplab: Hierarchical neural architecture search for semantic image segmentation[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Long Beach, CA, USA: IEEE, 2019: 82-92.
- [18] ZHANG Y, QIU Z, LIU J, et al. Customizable Architecture Search for Semantic Segmentation[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Long Beach, CA, USA: IEEE, 2019: 11633-11642.
- [19] ELSKEN T, METZEN J H, HUTTER F. Neural architecture

- ture search: A survey[EB/OL]. (2019-04-26). <https://arxiv.org/abs/1808.05377>.
- [20] ZHONG Z, YAN J, WU W, et al. Practical block-wise neural network architecture generation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 2423-2432.
- [21] ZOPH B, VASUDEVAN V, SHLENS J, et al. Learning transferable architectures for scalable image recognition [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 8697-8710.
- [22] CHEN LC, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Proceedings of the European Conference on Computer Vision(ECCV). Munich: Springer, 2018: 801-818.
- [23] ELSKEN T, METZEN J H, HUTTER F. Simple and efficient architecture search for convolutional neural networks[EB/OL]. (2017-11-13). <https://arxiv.org/abs/1711.04528>.
- [24] BAKER B, GUPTA O, NAIK N, et al. Designing neural network architectures using reinforcement learning[EB/OL]. (2017-03-22). <https://arxiv.org/abs/1611.02167>.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Seattle, WA, USA: IEEE, 2016: 770-778.
- [26] REAL E, AGGARWAL A, HUANG Y, et al. Regularized evolution for image classifier architecture search[EB/OL]. (2019-02-16). <https://arxiv.org/abs/1802.01548>.
- [27] LIU C, ZOPH B, SHLENS J, et al. Progressive neural architecture search[EB/OL]. (2018-07-26). <https://arxiv.org/abs/1712.00559>.
- [28] NOH H, HONG S, HAN B. Learning deconvolution network for semantic segmentation[C]//IEEE International Conference on Computer Vision(ICCV). Santiago, Chile: IEEE, 2015: 1520-1528.
- [29] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39: 2481-2495.
- [30] PHAM H, GUAN M Y, ZOPH B, et al. Efficient neural architecture search via parameter sharing[EB/OL]. (2018-02-12). <https://arxiv.org/abs/1802.03268>
- [31] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Honolulu, HI, USA: IEEE, 2017: 6230-6239.
- [32] ZAREMBA W, SUTSKEVER I, VINYALS O. Recurrent neural network regularization[EB/OL]. (2015-02-19). <https://arxiv.org/abs/1409.2329>.
- [33] SUTTON R S, MCALLESTER D, SINGH S, et al. Policy gradient methods for reinforcement learning with function approximation[J]. Advances in Neural Information Processing Systems, 1999, 12: 1057-1063.
- [34] ROMERA E, ALVAREZ J M, BERGASA L M, et al. ERFNet: Efficient residual factorized convnet for real-time semantic segmentation[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(1): 263-272.
- [35] PASZKE A, CHAURASIA A, KIM S, et al. ENet: A deep neural network architecture for real-time semantic segmentation[EB/OL].(2016-06-07). <https://arxiv.org/abs/1606.02147>.
- [36] CHEN LC, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation [EB/OL]. (2017-12-05). <https://arxiv.org/abs/1706.05587>.

作者简介



蔡超丽 女,1996年11月出生,湖北十堰人。现为桂林理工大学信息学院硕士研究生,主要研究方向为计算机视觉、深度学习。

E-mail: kiko.c@qq.com



杨铁军(通讯作者) 男,1979年6月出生,湖南宁乡人。桂林理工大学信息学院教授,硕士生导师,研究方向为计算机视觉、深度学习。

E-mail: yattie@foxmail.com