

基于 U-Net 卷积神经网络的纳米颗粒分割

张芳^{1,2}, 吴玥¹, 肖志涛^{1,2*}, 耿磊^{1,2}, 吴骏^{1,2}, 刘彦北^{1,2}, 王雯^{1,2}

¹天津工业大学电子与信息工程学院, 天津 300387;

²天津市光电检测技术与系统重点实验室, 天津 300387

摘要 为了准确测量纳米颗粒的尺寸, 依据透射电子显微镜拍摄的纳米颗粒图像, 提出了一种基于 U-Net 卷积神经网络的颗粒自动分割方法。将 U-Net 部分网络结构与批量归一化层相结合, 减弱了网络对初始化的依赖, 提升了训练速度。对纳米颗粒图像进行半隐式偏微分方程滤波以增强图像边缘信息, 利用改进的 U-Net 网络训练纳米颗粒个体分割模型, 得到了分割结果。研究表明, 所提方法能准确分割出图像中的纳米颗粒, 对边缘模糊和强度不均的纳米颗粒的分割效果提升显著。

关键词 图像处理; 纳米颗粒分割; U-Net 卷积神经网络; 半隐式偏微分方程; 滤波

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP56.061005

Nanoparticle Segmentation Based on U-Net Convolutional Neural Network

Zhang Fang^{1,2}, Wu Yue¹, Xiao Zhitao^{1,2*}, Geng Lei^{1,2},

Wu Jun^{1,2}, Liu Yanbei^{1,2}, Wang Wen^{1,2}

¹ School of Electronics and Information Engineering, Tianjin Polytechnic University, Tianjin 300387, China;

² Tianjin Key Laboratory of Optoelectronic Detection Technology and System, Tianjin 300387, China

Abstract In order to accurately measure the size of nanoparticles, an automatic particle segmentation method based on U-Net convolutional neural network is proposed according to the nanoparticle images captured by the transmission electron microscopy. Combined with the Batch Normalization (BN) layer, it reduces the dependence of networks on initialization and thus speeds up training. The nanoparticle image is filtered by the semi-implicit partial differential equation to enhance the image edge information. The improved U-Net network is used to train the nanoparticle individual segmentation model and the segmentation result is obtained. The research results show that the proposed method can accurately segment the nanoparticles in the image, and the segmentation effect is especially obvious for the nanoparticles with edge blurs and uneven intensities.

Key words image processing; nanoparticle segmentation; U-Net convolutional neural network; semi-implicit partial differential equation; filtering

OCIS codes 100.2000; 150.1135; 160.4236; 200.4260

1 引言

纳米技术是当今社会上最具发展潜力的技术之一。目前, 纳米材料已被广泛应用于如光学、生物学、医药、制造业、轻工业等许多重要的科研领域, 而纳米材料的性能与纳米颗粒的尺寸密切相关。为了评价纳米材料的品质, 通常需要对纳米材料内部颗

粒的尺寸和形貌进行测量和表征。近年来, 纳米材料学科与光学和数字图像处理技术的交叉领域已经成为重点研究领域之一。借助透射电子显微镜 (TEM) 拍摄的纳米颗粒图像, 基于图像处理技术可以测量纳米颗粒的尺寸。在这个过程中, 对图像中颗粒的分割效果将直接决定颗粒测量的精度。因此纳米颗粒的准确分割对于纳米材料的性能评价和制

收稿日期: 2018-09-18; 修回日期: 2018-09-28; 录用日期: 2018-10-17

基金项目: 国家自然科学基金(61601325)、天津市科技重大专项(17ZXSCSY00060)、天津市高等学校创新团队培养计划(TD13-5034)

* E-mail: xiaozhitao@tjpu.edu.cn

备工艺的改进具有非常重要的意义^[1]。

在图像目标分割方面,传统方法主要有阈值分割法^[2]、区域生长法^[3]、边缘检测法^[4]、基于水平集的分割方法^[5]、基于分水岭的分割方法^[6]等。以传统方法为基础,张博等^[7]提出了基于背景校正和图像分割定量分析的方法,对图像进行预处理后,使用最大类间方差法分割出目标与背景;王宇等^[8]提出了基于改进的模糊C均值聚类(FCM)算法的颗粒种子图像分割方法,在传统FCM算法的目标函数中加入惩罚项表征邻域像素值的影响,以提高分割准确性;吕镜瀑等^[9]提出了基于最大相关性准则的颗粒分割方法,利用相邻或者同一区域内的像素具有相关性的特点对颗粒进行分割,适用于目标内部灰度比较均匀的情况。然而以上方法在纳米颗粒分割方面存在一些不足:纳米颗粒图像中背景噪声比较大,并且部分颗粒内部亮度不均、边缘模糊,应用已有方法对纳米颗粒图像进行分割时会产生欠分割或过分割现象。此外,这些算法都需要根据不同的图片确定相应参数才能得到比较好的效果,易受到图像噪声的干扰,处理结果不容易控制。

近年来,深度学习算法通过组合浅层特征形成抽象的深层特征,并据此得到数据的分布式特征,在图像分割方面取得了重大突破。和传统方法相比,深度学习方法可以从观测数据中学习目标特征,根据学习结果自行解决分割问题。用于解决图像分割问题的网络包括全卷积神经网络(FCN)、SegNet、PixelNet、U-Net等。Shelhamer等^[10]提出了基于FCN的语义分割算法,该方法以Ground Truth作为监督信息训练网络,将图像级别的分类转变为像素级别的分类,从而实现语义分割。Badrinarayanan等^[11]提出的SegNet是一种基于FCN改进的语义分割网络,将最大池化指数转移至解码器中,改善了分割分辨率。Bansal等^[12]提出的PixelNet是一种从低级边缘检测到中级表面的高级语义分割,在复杂场景

分割中取得了成功。以上网络主要用于场景分割,能准确定位目标区域,但分割得到的区域边界并不准确,对于灰度分布不均的纳米颗粒分割结果并不理想。Ronneberger等^[13]对FCN进行改进,提出了针对生物医学细胞图像分割的U-Net网络,该网络赢得了2015年ISBI(The IEEE International Symposium on Biomedical Imaging)细胞追踪比赛的冠军。由于纳米颗粒与生物细胞在目标形态与边界特征上具有一定的相似性,因此本文引入U-Net网络模型对纳米颗粒图像进行分割,同时改进网络结构以提高纳米颗粒边缘分割的准确性。

2 图像预处理

针对TEM采集的球形纳米颗粒图像进行研究,提出基于U-Net网络的纳米颗粒图像分割方法,为球形纳米颗粒尺寸测量提供依据。

根据不同原理,TEM成像可分为3种情况:吸收像、衍射像和相位像。当电子射到纳米材料样品上时,主要的成像作用是散射。纳米颗粒的质量、密度较大,对电子的散射角大,导致穿透颗粒的电子较少,成像较暗,因此,纳米颗粒在其TEM图像中灰度值较低,属于亮背景下的暗目标。TEM拍摄出的球形纳米颗粒图像及其局部放大图如图1所示,对于内部质量不均匀的颗粒,采集到的图像中颗粒内部灰度分布不均匀,颗粒区域亮暗不同。此外,图像中存在大量噪声,严重影响分割效果,因此需要对图像进行预处理。为了减少噪声对后续分割的影响,采用偏微分方程对纳米颗粒图像进行滤波。

设 I 代表一幅灰度图像,像素点 (x, y) 处的灰度值为 $I(x, y)$,则图像演化过程可表示为

$$\frac{\partial u(x, y, t)}{\partial t} = \hat{F}[u(x, y, t)], u(x, y, 0) = I(x, y), \quad (1)$$




图1 TEM拍摄出的球形纳米颗粒图像及其局部放大图。(a) TEM图像;(b)局部放大

Fig. 1 Spherical nanoparticle image taken by TEM and its partially enlarged view. (a) TEM image; (b) partially enlarged view

式中: t 为时间参数; $u(x, y, t)$ 表示任意时间的图像; \hat{F} 为不同的图像处理过程所对应的偏微分算子; $u(x, y, 0) = I(x, y)$ 表示将原始图像 I 作为迭代的初始条件。这样, 此微分方程的解 $u(x, y, t)$ 就是在时间参数 t 下处理后的图像^[14]。

采用正则化的 P-M(Perona-Malik) 方程

$$\begin{aligned} \frac{\partial u}{\partial t} &= \text{div} [g(|\nabla G_\sigma * u|) \nabla u], \\ u(x, y, 0) &= I(x, y), \end{aligned} \quad (2)$$

式中: div 为散度算子; ∇ 为梯度算子; $g(\cdot)$ 为一个平滑的非增函数, 称为扩散系数, 设 r 为 $g(\cdot)$ 的自变量, 则 $g(r) = 1 - \exp[-3.315 \cdot (r/k)^{-8}]$, k 为可调参数, 又称反差参数, 可以用来调节 g 随 r 变化的速度; G_σ 表示方差为 σ 的高斯函数; $*$ 为卷积运算。此方程保证非线性扩散是稳定的, 存在唯一的连续依赖于初值的解。

采用由 Weickert 等^[15] 提出的半隐式方案求解滤波结果, 有

$$\begin{aligned} u_s^{(n+1)} &= u_s^{(n)} + \\ \tau \sum_{p_i \in \Gamma_s} \frac{g_{p_i}^{(n)} + g_s^{(n)}}{2} (u_{p_i}^{(n+1)} - u_s^{(n+1)}), \quad n &= 1, 2, 3, 4, \end{aligned} \quad (3)$$

式中: s 为中心点; n 表示迭代次数; τ 表示时间步长, $\tau = t/n$; p_1, p_2, p_3, p_4 是 s 的四邻点; i 为邻点编号; Γ_s 表示以 s 为中心的四邻点集合。

$$\begin{cases} g_s^{(n)} = g(|\nabla u_s^{(n)} * G_\sigma|) \\ g_{p_i}^{(n)} = g(|\nabla u_{p_i}^{(n)} * G_\sigma|) \end{cases} \quad (4)$$

(3) 式用矩阵形式表示, 即

$$\mathbf{u}^{(n+1)} = \mathbf{u}^{(n)} + \tau \cdot \mathbf{A}^{(n)} \cdot \mathbf{u}^{(n+1)}, \quad (5)$$

式中: $\mathbf{u}^{(n+1)}$ 和 $\mathbf{u}^{(n)}$ 均为列向量, 尺寸是 $M \times N$ 维, 分别表示在 $(n+1)\tau$ 和 $n\tau$ 时刻的图像矢量; $\mathbf{A}^{(n)}$ 表示 $MN \times MN$ 维矩阵, $\mathbf{A}^{(n)}$ 为稀疏矩阵, 但并不是三对角阵。进一步推导得

$$\mathbf{u}^{(n+1)} = (\mathbf{I} - \tau \cdot \mathbf{A}^{(n)})^{-1} \mathbf{u}^{(n)}, \quad (6)$$

式中: \mathbf{I} 为 $MN \times MN$ 维的单位矩阵。

$$a_{s,p} = \begin{cases} \frac{g_s^{(n)} + g_p^{(n)}}{2}, & p \in \Gamma_s \\ -\sum_{p \in \Gamma_s} \frac{g_s^{(n)} + g_p^{(n)}}{2}, & p = s \\ 0, & \text{else} \end{cases} \quad (7)$$

式中: $a_{s,p}$ 为矩阵 $\mathbf{A}^{(n)}$ 的元素。为了克服系数矩阵大而求解困难的问题, Weickert 提出了加性算子分裂 (AOS) 算法。该方法将一次迭代过程分为两步, 首

先对 $\mathbf{u}^{(n)}$ 进行行和列的一维扩散, 得到中间结果 $\mathbf{u}_1^{(n+1)}$ 和 $\mathbf{u}_2^{(n+1)}$, 有

$$\begin{cases} \mathbf{u}_1^{(n+1)} = (\mathbf{I} - 2\tau \cdot \mathbf{A}_x^{(n)})^{-1} \mathbf{u}^{(n)} \\ \mathbf{u}_2^{(n+1)} = (\mathbf{I} - 2\tau \cdot \mathbf{A}_y^{(n)})^{-1} \mathbf{u}_1^{(n+1)} \end{cases} \quad (8)$$

接着对 $\mathbf{u}_1^{(n+1)}$ 和 $\mathbf{u}_2^{(n+1)}$ 求平均值完成一次完整的迭代, 即

$$\mathbf{u}^{(n+1)} = \frac{1}{2} (\mathbf{u}_1^{(n+1)} + \mathbf{u}_2^{(n+1)}). \quad (9)$$

经过多次迭代后即可得到滤波结果。

由于半隐式差分格式所得到的方程组是线性的, 因此其数值计算方法简单, 并且也是绝对稳定的。对球形纳米颗粒原始图像进行偏微分方程滤波, 结果如图 2 所示。由图 2 可以看出, 滤波后图像中的噪声得到有效抑制, 颗粒边界更加清晰。




图 2 偏微分方程滤波结果。

(a) 原纳米颗粒图像; (b) 滤波结果图

Fig. 2 Filtering results by partial differential equation.

(a) Original nanoparticle image; (b) filtering result

3 基于 U-Net 的纳米颗粒图像分割

3.1 网络结构

Ronneberger 等^[13] 提出 U-Net 网络模型, 并实现了细胞图像的准确分割, 细胞的形态和边界特征与本文所研究的纳米颗粒相似, 因此将 U-Net 网络模型用于纳米颗粒图像分割。为了提高分割结果的准确性, 对 U-Net 网络进行改进。加入批量归一化 (BN: Batch Normalization) 后的网络结构图, 如图 3 所示, 将 U-Net 部分网络结构与 BN 层结合, 首先执行深度卷积, 增加网络宽度; 接着进行 1×1 卷积, 融合通道信息; 在卷积层后加入 BN 层, 以减少网络对初始化的依赖, 提升训练速度^[16]。

改进的 U-Net 网络在每一个卷积层的后面加入一个 BN 层, 网络的左半部分包含两组 Separable 卷积层, Depthwise 卷积核大小均为 3×3 , 在每层 Separable 卷积后使用 ReLU 函数进行激活, 每组 Separable 卷积后连接步长为 2 的 2×2 最大值池化

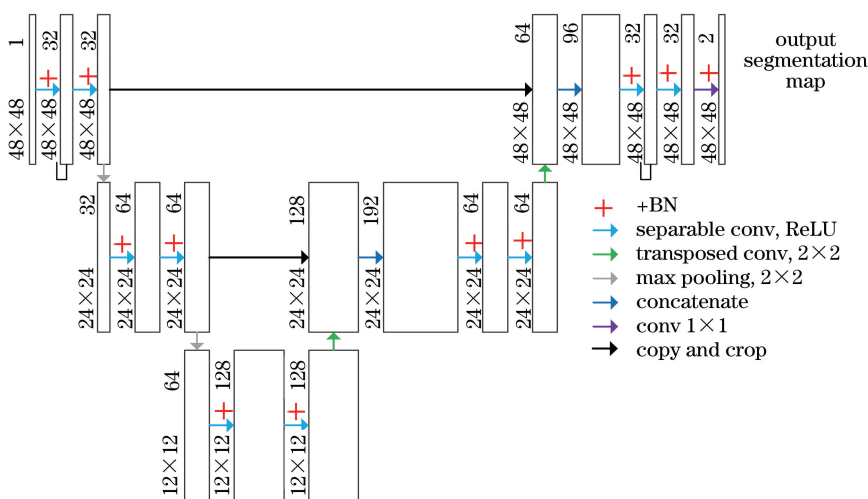


图3 加入BN后的网络结构图

Fig. 3 Network structure with BN

(max pooling)。为了减少特征信息的丢失,每次降采样后都将通道数量加倍。网络的右半部分包含两组反卷积(Transposed)层,核大小为 3×3 。再将上采样的结果与通道加权后的浅层高分辨率信息进行连接(concatenate)。每组连接后再进行两次Separable卷积,将Separable卷积通道的数量相比上采样的通道数量作减半处理,Depthwise卷积核大小均为 3×3 ,同样在每层Separable卷积后使用ReLU函数进行激活。最后一层使用卷积核大小为 1×1 的标准卷积(conv)将32个特征图(feature map)映射为2个特征图(feature map),实现纳米颗粒个体以及背景二分类。

3.2 BN层

BN网络层是批量归一化层,是一个可学习、有参数 (γ, β) 的网络层,其作用是将前一层输出的特征归一化为均值0、方差为1的数据,再输入到网络的下一层。假设该层有 d 维输入 $\mathbf{X} = (x^{(1)}, \dots, x^{(d)})$,引入可学习参数 γ, β ,采用变换重构方法对每一维特征进行归一化,可得

$$\begin{cases} y^{(k)} = \gamma^{(k)} \hat{x}^{(k)} + \beta^{(k)} \\ \gamma^{(k)} = \sqrt{\text{Var}[x^{(k)}]} \\ \beta^{(k)} = E[x^{(k)}] \end{cases}, \quad (10)$$

式中: $\text{Var}(\cdot)$ 表示取方差; $E(\cdot)$ 表示取平均值; $\hat{x}^{(k)}$ 表示对特征的回归值,是真实值的一种预测。

通过上面的参数重构,可以恢复出上一层网络所学到的特征,改善流经网络的梯度。在卷积层后加入BN层的优点包括:

1) 加入BN层后收敛速度较快,因此可以选择比较大的初始学习率,以提升训练速度;

2) 可以减弱网络对参数初始化的依赖性;

3) BN层作为正则化的一种形式,减少了对dropout的需求,可以解决过拟合中正则项参数的选择问题,提高网络的泛化能力;

4) 训练时无需对样本排序,并且可提升训练的精度。

3.3 Dropout层

深层的卷积网络具有大量的参数,计算量大,如果训练样本不充分则很容易导致过拟合。为了防止过拟合,在网络中引入dropout层,文献[17]详细阐述了神经网络的过拟合问题以及dropout技术的作用。在训练的过程中,根据一定的概率随机选中一部分神经元,使其只保留计算出的权重,并不更新,等待下次迭代的时候进行更新。随机设置某些节点不工作,可以避免某些特征只在固定组合下才生效,破坏了固定组合的相关性,有意识地让网络去学习一些普遍的共性,从而提高模型的泛化能力,阻止网络过拟合。训练时通常设定一个dropout ratio p' ,即每一个输出节点以概率 p' 置0,这里设置 $p' = 0.25$ 。dropout的表达形式为

$$y_{\text{train}} = \begin{cases} \frac{x}{1-p'}, & \text{if } \xi > p' \\ 0, & \text{otherwise} \end{cases}, \quad \xi \in U(0,1), \quad (11)$$

式中: ξ 为Bernoulli随机数。

4 实验结果与分析

4.1 实验对象

本文的实验对象为TEM采集到的100张分辨率为 $4008 \text{ pixel} \times 2672 \text{ pixel}$ 的球形纳米颗粒图像。

为了扩充实验数据并且使图片大小适应于网络训练,对原始图像进行重叠分割得到 1000 张大小为 $600 \text{ pixel} \times 600 \text{ pixel}$ 的训练图像,另随机选取 200 张球形纳米颗粒图像进行测试,测试集中图片与训练的 1000 张纳米颗粒图片均不重复。训练集和测试集中的每张图像都有对应目标有效区域的标准二值图像。由于没有公开的纳米颗粒图像库,这里使用的纳米颗粒标准二值图像均为人工标注。实验数据是通过对比这些标注的二值图像与实验所得的分割结果得到的。

分别使用水平集分割方法、PixelNet 网络、未加入 BN 层的 U-Net 网络及所提方法对测试集中 200 张球形纳米颗粒图像进行测试,训练网络及分割处理时输入的是偏微分方程滤波后的图像。

4.2 改进网络与原 U-Net 网络的 Loss 曲线对比

原 U-Net 网络的 Loss 曲线和改进的 U-Net 网络的 Loss 曲线的对比图如图 4 所示。从图中可看出,改进后的网络损失率更小,收敛更快。由此可以看出,在加入 BN 层后,BN 层对特征的归一化作用,使得网络性能很大改善,不仅收敛速度更快,而且得到了更小的损失函数值,即网络的分割性能更优。




图 4 Loss 曲线对比图

Fig. 4 Comparison chart of loss curves

4.3 所提方法与已有方法的主观对比结果

图 5~7 展示了 3 组测试图像的纳米颗粒图像分割结果。图 5(a)、图 6(a)和图 7(a)是基于水平集方法的分割结果轮廓;图 5(b)、图 6(b)和图 7(b)展示了 PixelNet 的分割结果;图 5(c)、图 6(c)和图 7(c)展示了原 U-Net 网络的分割结果;图 5(d)、图 6(d)和图 7(d)展示了改进后的 U-Net 网络的分割结果。为了便于直观对比,3 组图中均将分割轮廓叠加在原图上进行显示。

在图 5~7 中,从分割结果可以看出,对于同一待测图片,水平集算法受限于固定阈值的选择,对于内部灰度分布不均匀的颗粒分割效果较差,且受噪声影响,得到的颗粒边界不平滑。如图 5(b)和




图 5 分割效果对比图一。(a)水平集算法;(b) PixelNet;
(c)原 U-Net;(d)改进网络

Fig. 5 Comparison chart 1 of segmentation effect. (a) Level set algorithm; (b) PixelNet; (c) original U-Net; (d) improved network




图 6 分割效果对比图二。(a)水平集算法;(b) PixelNet;
(c)原 U-Net;(d)改进网络

Fig. 6 Comparison chart 2 of segmentation effect. (a) Level set algorithm; (b) PixelNet; (c) original U-Net; (d) improved network




图 7 分割效果对比图三。(a)水平集算法;(b) PixelNet;
(c)原 U-Net;(d)改进网络

Fig. 7 Comparison chart 3 of segmentation effect. (a) Level set algorithm; (b) PixelNet; (c) original U-Net; (d) improved network

图 6(b)所示, PixelNet 对于颗粒内部灰度不均的地方分割会产生孔洞现象; 如图 7(c)所示, 原 U-Net 网络对于内部灰度分布不均匀的情况有所改善, 但边界处检测效果不够理想, 常将背景中邻近颗粒的灰度较低的区域也作为目标区域, 或者将目标颗粒中与背景灰度接近的部分作为背景, 如图 5(c)和图 6(c)所示。如图 5(d)、图 6(d)和图 7(d)所示, 加入 BN 层的 U-Net 网络(所提方法)对颗粒中背景和目标的区分度更高, 边缘处分割更准确, 有利于提高纳米颗粒尺寸测量的精度。

4.4 所提方法与已有方法的客观对比结果

为了对所提方法的性能进行客观评价, 这里采用交并比 R_{IOU} (Intersection over Union) 和准确率 R_{ACC} (Accuracy) 两个评价指标对所提方法与已有方法进行对比。在目标检测的评价体系中, R_{IOU} 是一个重要的评价指标参数, 它是指模型产生的目标窗口和标记窗口的交叠率, 可以简单理解为检测结果 I_{DR} (Detection Result) 与真值图 I_{GT} (Ground Truth) 的交集与它们的并集的比值, 即

$$R_{IOU} = \frac{I_{DR} \cap I_{GT}}{I_{DR} \cup I_{GT}}. \quad (12)$$

R_{IOU} 衡量了每个颗粒个体的分割准确性。若 $R_{IOU} > 0.9$, 则记为分割正确, 在此基础上所提分割方法的准确率 R_{ACC} 为

$$R_{ACC} = \frac{N_{Correct}}{N_{Sum}}, \quad (13)$$

式中: N_{Sum} 为总的样本个数; $N_{Correct}$ 为在样本总量为 N_{Sum} 的分割准确率达到 90% 以上的样本个数。相比于 R_{IOU} , R_{ACC} 是对分割结果的整体评价, 更能反映分割结果的实用性。

实验中共测试了 3470 个颗粒, 测试结果的客观指标如表 1 所示。从表 1 可以看出, 所提方法的 Mean R_{IOU} 和 Mean R_{ACC} 均优于原 U-Net 网络 and 水平集方法。这说明无论是颗粒个体的分割精确性, 还是整幅图像分割结果的实用性, 所提方法均有良好的性能。

另外, 对比了所提方法与其他几种网络的耗时, 平均耗时对比如表 2 所示。实验所采用的计算机硬件配置为 Intel (R) Core (TM) i7-7700 CPU、NVIDIA GeForce GTX 1080 GPU, 操作系统为 Ubuntu 16.04, 使用基于 Python 接口的 Caffe 卷积神经网络框架对 600 pixel \times 600 pixel 的图片进行测试, 计算平均耗时。由表 2 可以看出, 所提网络相对于原 U-Net 网络和 PixelNet 计算耗时有降低,

计算效率明显提高。

表 1 测试结果的客观指标

Table 1 Objective indexes of testing results

Method	Number of samples	Mean R_{IOU}	Mean R_{ACC}
Level set method	3470	0.8562	0.8775
PixelNet	3470	0.9187	0.9405
Original U-Net	3470	0.9222	0.9472
Improved U-Net	3470	0.9402	0.9630

表 2 平均耗时对比

Table 2 Comparison of average time consumption

Method	Levelset method	PixelNet	Original U-Net	Improved U-Net
Time consumption / ms	438	315	276	288

5 结 论

提出了一种基于深度学习的纳米颗粒个体分割方法, 通过在 U-Net 网络中加入 BN 层, 使得改进后的网络在纳米颗粒分割任务中取得了良好的分割效果。该方法可以有效克服颗粒图像噪声大、颗粒内部灰度不均以及颗粒边缘模糊对颗粒分割的不利影响, 避免了传统算法中边缘模糊颗粒的过分割和欠分割问题, 提高了网络的训练速度, 减弱了网络对参数初始化的依赖性。分割结果和专家指导标注结果作为标准相比, 平均 R_{IOU} 达到 0.94, 平均准确率达到 96.3%, 实验结果证明了所提方法准确可靠。

参 考 文 献

- [1] Pan L C, Ge B Z, Zhang F G. Laser particle size measurement based on annular sample cell [J]. Acta Optica Sinica, 2017, 37(10): 1029001.
潘林超, 葛宝臻, 张福根. 基于环形样品池的激光粒度测量方法 [J]. 光学学报, 2017, 37(10): 1029001.
- [2] He F L, Guo Y C, Gao C. Improved PCNN method for human target infrared image segmentation under complex environments [J]. Acta Optica Sinica, 2017, 37(2): 0215003.
贺付亮, 郭永彩, 高潮. 复杂环境下用于人体目标红外图像分割的改进 PCNN 方法 [J]. 光学学报, 2017, 37(2): 0215003.
- [3] Fang J X. Study based on the variational level set methods for image segmentation [D]. Shanghai: Shanghai Jiao Tong University, 2012: 20-28.
方江雄. 基于变分水平集的图像分割方法研究 [D]. 上海: 上海交通大学, 2012: 20-28.
- [4] Liu X B. The study on the segmentation of circle-like

- particle images [D]. Changsha: Hunan University, 2006.
- 刘相滨. 类圆形颗粒图像分割技术研究 [D]. 长沙: 湖南大学, 2006.
- [5] Ni K, Wu Y Q, Geng S. Segmentation of metallographic image based on improved CV model integrated with local fitting term [J]. *Acta Optica Sinica*, 2018, 38(4): 0411009.
倪康, 吴一全, 庚嵩. 基于改进区域项 CV 模型的金相图像分割 [J]. *光学学报*, 2018, 38(4): 0411009.
- [6] Li C M, Kao C Y, Gore J C, *et al.* Minimization of region-scalable fitting energy for image segmentation [J]. *IEEE Transactions on Image Processing*, 2008, 17(10): 1940-1949.
- [7] Zhang B, Ni K Z, Wang L J, *et al.* New algorithm of detecting optical surface imperfection based on background correction and image segmentation [J]. *Acta Optica Sinica*, 2016, 36(9): 0911004.
张博, 倪开灶, 王林军, 等. 基于背景校正和图像分割定量分析光学元件表面疵病的新算法 [J]. *光学学报*, 2016, 36(9): 0911004.
- [8] Wang Y, Chen J, Wang G. Particle seed images segmentation method based on the improved fuzzy C-means clustering algorithm [J]. *Journal of North University of China(Natural Science Edition)*, 2018, 39(2): 177-182.
王宇, 陈婧, 王高. 基于改进的模糊 C 均值聚类算法的颗粒种子图像分割方法 [J]. *中北大学学报(自然科学版)*, 2018, 39(2): 177-182.
- [9] Lü J C, Wang L P, Zhang Q Q. Research on the background segmentation method based on nanoparticles images [J]. *Journal of Baicheng Normal University*, 2017, 31(12): 1-6.
吕镜潺, 王丽萍, 张倩倩. 基于纳米颗粒图像的背景分割方法探究 [J]. *白城师范学院学报*, 2017, 31(12): 1-6.
- [10] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.
- [11] 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(12): 2481-2495.
- [12] Bansal A, Chen X L, Russell B, *et al.* PixelNet: representation of the pixels, by the pixels, and for the pixels [EB/OL]. (2017-02-27) [2018-11-23]. <https://arxiv.org/abs/1702.06506>
- [13] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation [C] // *International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015)*, October 5-9, Munich, Germany. Switzerland: Springer, 2015: 234-241.
- [14] Xiao Z T, Yuan Q, Zhang F, *et al.* The oriented partial differential equation based on the discontinuities measure for electronic speckle pattern interferometry [J]. *Journal of Electronics & Information Technology*, 2014, 36(11): 2600-2606.
肖志涛, 袁泉, 张芳, 等. 结合非连续性测度的方向偏微分方程在电子散斑干涉中的应用 [J]. *电子与信息学报*, 2014, 36(11): 2600-2606.
- [15] Weickert J, Schar H. A scheme for coherence-enhancing diffusion filtering with optimized rotation invariance [J]. *Journal of Visual Communication and Image Representation*, 2002, 13(1/2): 103-118.
- [16] Zhang Y G, Yi B S, Wu C Y, *et al.* Low-dose CT image denoising method based on convolutional neural network [J]. *Acta Optica Sinica*, 2018, 38(4): 0410003.
章云港, 易本顺, 吴晨玥, 等. 基于卷积神经网络的低剂量 CT 图像去噪方法 [J]. *光学学报*, 2018, 38(4): 0410003.
- [17] Gao W, Zhou Z H. Dropout Rademacher complexity of deep neural networks [J]. *Science China Information Sciences*, 2016, 59(7): 072104.