



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于自适应多目标进化CNN的图像分割方法

王维, 王显鹏, 宋相满

引用本文:

王维, 王显鹏, 宋相满. 基于自适应多目标进化CNN的图像分割方法[J]. *控制与决策*, 2024, 39(4): 1185–1193.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.1061>

您可能感兴趣的其他文章

Articles you may be interested in

一种基于MOEA/D的组合权重方法

A combination weight method based on MOEA/D

控制与决策. 2021, 36(12): 3056–3062 <https://doi.org/10.13195/j.kzyjc.2020.0592>

基于弱关联的自适应高维多目标进化算法

A weak association-based adaptive evolutionary algorithm for many-objective optimization

控制与决策. 2021, 36(8): 1804–1814 <https://doi.org/10.13195/j.kzyjc.2019.1723>

考虑批量分割的单元装配系统工作量平衡联合决策模型

Joint decision model of Seru production system balancing considering lot-splitting

控制与决策. 2021, 36(10): 2517–2527 <https://doi.org/10.13195/j.kzyjc.2020.0167>

基于多种群分解预测的动态多目标引力搜索算法

Dynamic multi-objective gravitational searching algorithm based on multi-population decomposition prediction

控制与决策. 2021, 36(12): 2910–2918 <https://doi.org/10.13195/j.kzyjc.2020.1002>

基于MobileNet的多目标跟踪深度学习算法

Deep learning algorithm based on MobileNet for multi-target tracking

控制与决策. 2021, 36(8): 1991–1996 <https://doi.org/10.13195/j.kzyjc.2019.1424>

基于自适应多目标进化CNN的图像分割方法

王 维^{1,2}, 王显鹏^{2,3†}, 宋相满^{1,2}

- (1. 东北大学 工业智能与系统优化国家级前沿科学中心, 沈阳 110819;
2. 东北大学 智能工业数据解析与优化教育部重点实验室, 沈阳 110819;
3. 辽宁省智能工业数据解析与优化工程实验室, 沈阳 110819)

摘要: 卷积神经网络已经成为强大的分割模型,但通常为手动设计,这需要大量时间并且可能导致庞大而复杂的网络. 人们对自动设计能够准确分割特定领域图像的高效网络架构越来越感兴趣,然而大部分方法或者没有考虑构建更加灵活的网络架构,或者没有考虑多个目标优化模型. 鉴于此,提出一种称为AdaMo-ECNAS的自适应多目标进化卷积神经网络搜索算法,用于特定领域的图像分割,在进化过程中考虑多个性能指标并通过优化模型的多目标适应特定的数据集. AdaMo-ECNAS可以构建灵活多变的预测分割模型,其网络架构和超参数通过基于多目标进化的算法找到,算法基于自适应PBI实现3个目标进化问题,即提升预测分割的 F_1 -score、最大限度减少计算成本以及最大限度挖掘额外训练潜能. 将AdaMo-ECNAS在两个真实数据集上进行评估,结果表明所提出方法与其他先进算法相比具有较高的竞争性,甚至是超越的.

关键词: 卷积神经网络; 神经架构搜索; 多目标优化问题; 基于分解的多目标进化算法; 自适应; 图像分割
中图分类号: TP273 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2022.1061

引用格式: 王维,王显鹏,宋相满. 基于自适应多目标进化CNN的图像分割方法[J]. 控制与决策, 2024, 39(4): 1185-1193.

An image segmentation method based on adaptive multi-objective evolutionary CNN

WANG Wei^{1,2}, WANG Xian-peng^{2,3†}, SONG Xiang-man^{1,2}

- (1. Frontier Science Center for Industrial Intelligence and Systems Optimization, Northeastern University, Shenyang 110819, China; 2. Key Laboratory of Data Analytics and Optimization for Smart Industry, Northeastern University, Shenyang 110819, China; 3. Liaoning Engineering Laboratory of Data Analytics and Optimization for Smart Industry, Shenyang 110819, China)

Abstract: Convolutional neural networks (CNNs) have become powerful segmentation models, but are usually designed manually, which requires extensive time and can result in large and complex networks. There is a growing enthusiasm for automatically designing efficient architectures that can accurately segment domain-specific images. However, most approaches either do not consider building more flexible network architectures or do not consider multiple objectives to optimize model. To cope with these issues, we propose an adaptive multi-objective evolutionary convolutional neural architecture search algorithm called AdaMo-ECNAS for domain-specific image segmentation, which considers multiple performance metrics during the evolutionary process and adapts to a specific dataset by optimizing multiple objectives. AdaMo-ECNAS can build flexible and versatile predictive segmentation models whose architecture and hyperparameters are found by a multi-objective evolutionary algorithm that is adaptively PBI-based tri-objective evolutionary to improve the F_1 -score of predictive segmentation, minimize the computational cost and maximize the additional training potential. The main contribution of this work is a fully exploited feature information of segmentation and automatic search for high-performance and efficient architectural models. AdaMo-ECNAS is evaluated on two real world datasets, and the proposed method is competitive and even superior to some advanced algorithms.

Keywords: convolutional neural networks (CNNs); neural architecture search (NAS); multi-objective optimization problem (MOP); decomposition-based multi-objective evolutionary optimization (MOEA/D); adaptive; image segmentation

收稿日期: 2022-06-16; **录用日期:** 2022-12-01.

基金项目: 国家自然科学基金重大项目(72192830, 72192831); 国家自然科学基金面上项目(62073067); 国家111项目(B16009); 中央高校基本科研业务费专项资金项目(N2128001).

责任编辑: 张国山.

†通讯作者. E-mail: wangxianpeng@ise.neu.edu.cn.

0 引言

图像分割可以为各种任务提供有价值的信息,例如缺陷检测、性能预测.然而,由于图像之间感兴趣区域的外观、形状和位置的固有可变性以及成像设备和采集协议的差异,实现准确的分割具有挑战性,针对特定问题手动设计合理的模型是一项极具依赖专业知识且在试错的过程中极其耗时的任务^[1-2].

迫切需求自动设计网络模型的方法促使了神经架构搜索(NAS)技术的发展,其目标是自动生成强大且性能良好的CNN架构,将其制定为优化问题,然后通过精心设计的优化算法加以解决^[3-4].结合研究问题的特点,基于种群的ENAS优化算法适用于解决以上提到的问题,该算法中每个个体都对网络的架构组件进行编码,并且只有最适合的成员才能生存和增殖.特别地,基于进化计算的NAS算法(ENAS)^[5-6]通常是全自动的,它们可以在没有任何人为介入的情况下实现神经架构搜索.

在过去的几年里,ENAS算法由于其高鲁棒性、卓越的性能和完全自动设计神经网络架构的能力引起了人们极大的关注^[5,7].在ENAS中,提升准确率和降低资源消耗一直是要突破的难题.对于多个互相冲突的优化问题,多目标进化算法^[8-9]已被成功应用.在已有的多目标进化网络架构算法中,适用于分割应用的研究还是稀缺的,而存在的大量分类应用研究并不适合直接应用到分割问题上^[10].在已有的多目标进化获取分割预测模型的研究中,Baldeen-Calisto等^[11]在超参数构建的搜索空间上,解决最大化预期的分割准确率和最小化网络中的参数数量两个目标优化问题,提出了以具有固定均衡参数 θ 的PBI多目标优化方法为核心的MEA算法.随后,在MEA算法的前提下提出了自适应2D-3D FCN结构,并在搜索空间上执行最小化自定义损失函数和最小化参数数量两个目标任务^[12].Bosma等^[13]提出了Mixed-Block神经架构搜索,使用交叉验证的验证Dice分数平均值作为性能评估器实现了单目标优化网络结构.文献中研究的问题都具有自身的特殊性,提出的网络架构是完全切合实际问题的,在优化过程中考虑的目标多数是单目标或者双目标.

在上述观察的激励下,本文提出一种用于图像分割的自适应多目标进化卷积神经结构搜索(AdaMo-ECNAS)方法.不同的是,所提出方法用一个三目标函数表述CNN架构的构建问题,即最大化分割性能指标 F_1 -score、最小化网络计算消耗和最小化充分训练潜力指标,并进一步应用基于PBI的多目标进化算

法解决该问题.特别地,在基于PBI多目标算法中更好地利用种群信息,使其自适应更新参数 θ ,自适应参数在实际应用中的鲁棒性会更好.通过对DTLZ1和IMOP5问题的数值实验验证了其基于PBI的多目标进化中自适应参数的有效性,分别在钢铁数据集和视网膜血管数据集上执行提出的AdaMo-ECNAS算法并获得了理想的实验结果.

1 基于分解的多目标进化NAS问题

1.1 问题描述

多目标进化算法对于进化卷积神经架构的搜索是非常重要的,这是因为多目标限制其种群更新可以更好地反映个体的多种性能,在保证其进化个体性能的同时减轻计算负担.

1.2 问题模型

1.2.1 基于进化计算的NAS

基于进化计算的NAS(ENAS)^[3,6]算法是一种利用进化计算自动设计神经架构的技术.特别地,进化计算是一类基于种群的计算范式,模拟自然界中物种的进化或种群的行为来解决具有挑战性的优化问题,具有对局部最小值不敏感和不需要梯度信息的良好特性.在进化过程中,不断地对获得的网络模型进行评估,围绕所研究实际问题的目的将优化问题归纳为单目标^[5,14]或多目标^[15-16]的形式.

1.2.2 多目标优化问题

具有 m 个目标函数的多目标优化问题(MOP)描述为

$$\begin{aligned} \min_x F(x) &= (f_1(x), f_2(x), \dots, f_m(x))^T; \\ \text{s.t. } x &\in \Omega. \end{aligned} \quad (1)$$

其中: $f_i(x)$ 为第 i 个目标函数, $F(x)$ 为由 m 个实值目标函数形成的向量, Ω 为决策空间.

1.2.3 基于PBI的多目标优化方法

PBI方法定义如下:

$$\begin{aligned} \min g^{\text{pbi}}(x|\lambda, z^*) &= d_1 + \theta d_2; \\ \text{s.t. } d_1 &= \frac{\|(z^* - F(x))^T \lambda\|}{\|\lambda\|}, \\ d_2 &= \left\| F(x) - \left(z^* + \frac{d_1 \lambda}{\|\lambda\|} \right) \right\|. \end{aligned} \quad (2)$$

其中: x 为决策向量, $z^* = \min\{f_i(x)|x \in \Omega\}$ ($i \in \{1, 2, \dots, m\}$)为参考点, $\lambda = \{(\lambda_1, \lambda_2, \dots, \lambda_m)^T | \lambda_i \geq 0, i = 1, \dots, m, \sum_{i=1}^m \lambda_i = 1\}$ 为权重向量.这里计算了两个距离 d_1 和 d_2 ,分别控制种群的分布性和收敛性,可通过调节参数 θ 平衡两者的关系.

1.3 基于PBI自适应多目标优化NAS的分割问题

研究分割问题的根本是保证分割性能的提高,通常将 F_1 -score 提高作为图像分割的评价目标函数. 一般来说, F_1 -score 高的模型表明该模型具有较好的分割能力,有

$$\min f_1(x) = 1 - \frac{2 \times TP}{2 \times TP + FP + FN}. \quad (3)$$

为了衡量计算成本,采用 FLOPs 作为评价目标函数,一个 FLOPs 较小的模型意味着它消耗的存储和计算资源较少,有

$$\min f_2(x) = \text{FLOPs}. \quad (4)$$

要发现一个非充分训练的模型在推理中是有效的,具体而言,一个个体在没有充分训练的情况下有一定的指标表现是非常有希望的,有

$$\min f_3(x) = \frac{E - e_{\max}}{E}. \quad (5)$$

其中: E 为候选架构训练的最大 epochs 值, e_{\max} 为达到最大验证 F_1 -score 的 epochs 值. 当 $f_3(x)$ 接近 0 时,意味着它是一个非完全训练模型,否则意味着它是一个完全训练的模型,没有被深入开发的潜力.

综上所述,提出一个三目标优化问题,采用多目标进化方法获得具有鲁棒性的模型,克服单一目标不能完全保证其结果鲁棒性的缺点. 首先,在有限的 epochs 训练下, F_1 -score 不能绝对代表所得模型的性能,这是由优化过程中梯度变化限制的;其次,即使计算成本很低,模型泛化能力也不能完全保证,因为欠拟合和过拟合都是较常见的问题;最后,在有充分训练的情况下获得的最佳 F_1 -score 可以表明该模型是否有进一步发展的潜力. 因此,三者之间的相互制约可以更科学地保证进化出的模型的稳健性.

就基于 PBI 的多目标优化方法而言,已知具有自适应惩罚参数 θ 的 PBI 方法表现良好. 受文献[17]的启发,给出考虑种群信息的自适应参数

$$\theta = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N \left(\frac{\lambda^j \cdot F^i}{\|F^i\|} \right), \quad (6)$$

其中 θ 取决于特定问题的数据. 相比其他方法而言,式(6)是更加简洁粗略的表达形式,既不需要依赖经验设定惩罚参数 θ ,也不需要理解极具理论性的自适应参数方式. 总之,此自适应参数可以保持设置固定参数时算法程序简洁性的同时提升算法的有效性.

2 自适应多目标进化NAS算法

针对图像分割的自适应多目标进化卷积神经网络搜索问题,提出自适应多目标进化NAS算法(AdaMo-ECNAS)进行求解.

2.1 算法回顾

构建的网络结构对特定图像数据集的适应过程被建模为一个多目标优化问题,其基本思想是通过权衡多个目标进化种群,具体算法流程见算法1. 更多细节在下节阐述. 构建一个三目标优化问题,考虑 F_1 -score、模型大小和深化训练潜力,通过多目标优化进化出具有优良个体的种群. 首先,随机产生由 N 个个体组成的种群 P ,同时产生一组均匀分布的权重向量;然后,对给定的数据集进行评估,为种群 P 中的每个个体分配目标值;接着,从邻域中随机选择一对解,并将其作为父代繁殖后代,所有被评估的后代都将被基于 PBI 的目标函数所选择;最后,在满足最大代数的情况下,产生具有优良个体的种群. AdaMo-ECNAS 总体框架如图1所示.

算法1 AdaMo-ECNAS 算法框架.

输入: 种群大小 N , 邻近区域权重个数 T , 最大代数 G , 目标数 M ;

输出: 生成种群 P .

1. $P_0 \leftarrow$ 随机生成初始种群 $\{x_0^1, x_0^2, \dots, x_0^N\}$, 生成个体评估指标 $\{F_0^1, \dots, F_0^N\}$, $F_0^i = [f_1(x_0^i), \dots, f_M(x_0^i)]$, 索引 $\{\text{key}_0^1, \text{key}_0^2, \dots, \text{key}_0^N\}$, $P_0^i = \{\text{key}_0^i : x_0^i, F_0^i\}$, $P_0 = \{P_0^1, P_0^2, \dots, P_0^N\}$.

2) $P \leftarrow P_0$.

3) for g in range (1, G):

4) $z^* \leftarrow$ 参考点 $z^* = \{z_1^*, \dots, z_M^*\}$, 其中 $z_m^* = \min\{f_m(x^1), \dots, f_m(x^N)\}$, $m \in \{1, 2, \dots, M\}$.

5) $\lambda \leftarrow$ 均匀分布的权重向量 $\lambda = \{\lambda^1, \lambda^2, \dots, \lambda^N\}$, 其中 $\lambda^i = \{\lambda_1^i, \lambda_2^i, \dots, \lambda_M^i\}$, $i \in \{1, 2, \dots, N\}$.

6) $B \leftarrow$ 定义 λ^i 的 T 个邻域权重向量 $[\lambda_1^i, \dots, \lambda_T^i]$, 其索引集为 $B(i) = \{i1, \dots, iT\}$, 根据欧氏空间距离的方式测量其邻域.

7) $\theta \leftarrow$ 更新参数 $\theta = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N \left(\frac{\lambda^j \cdot F^i}{\|F^i\|} \right)$

8) for i range (N):

9) $x_g^k, x_g^l \leftarrow$ 在对应领域的索引集 B 上任意选择两个索引号 k 和 l 作为父代个体.

10) $x_g^{y1}, x_g^{y2} \leftarrow$ 将父代个体 x_g^k 和 x_g^l 进行多点交叉和每代固定概率 $p_m(g) = 1/g$ 变异产生两个新的个体.

11) $p_g^{y1}, p_g^{y2} \leftarrow$ 评估生成个体 F_g^{y1} 、 F_g^{y2} 的适配值, $p_g^{y1} = \{\text{key}_g^{y1} : x_g^{y1}, F_g^{y1}\}$, $p_g^{y2} = \{\text{key}_g^{y2} : x_g^{y2}, F_g^{y2}\}$.

12) $z^* \leftarrow$ 更新 z^* .

13) $x_g^y \leftarrow$ 如果 p_g^{y1} 支配 p_g^{y2} , 则 $p_g^y = p_g^{y1}$; 否则, $p_g^y = p_g^{y2}$.

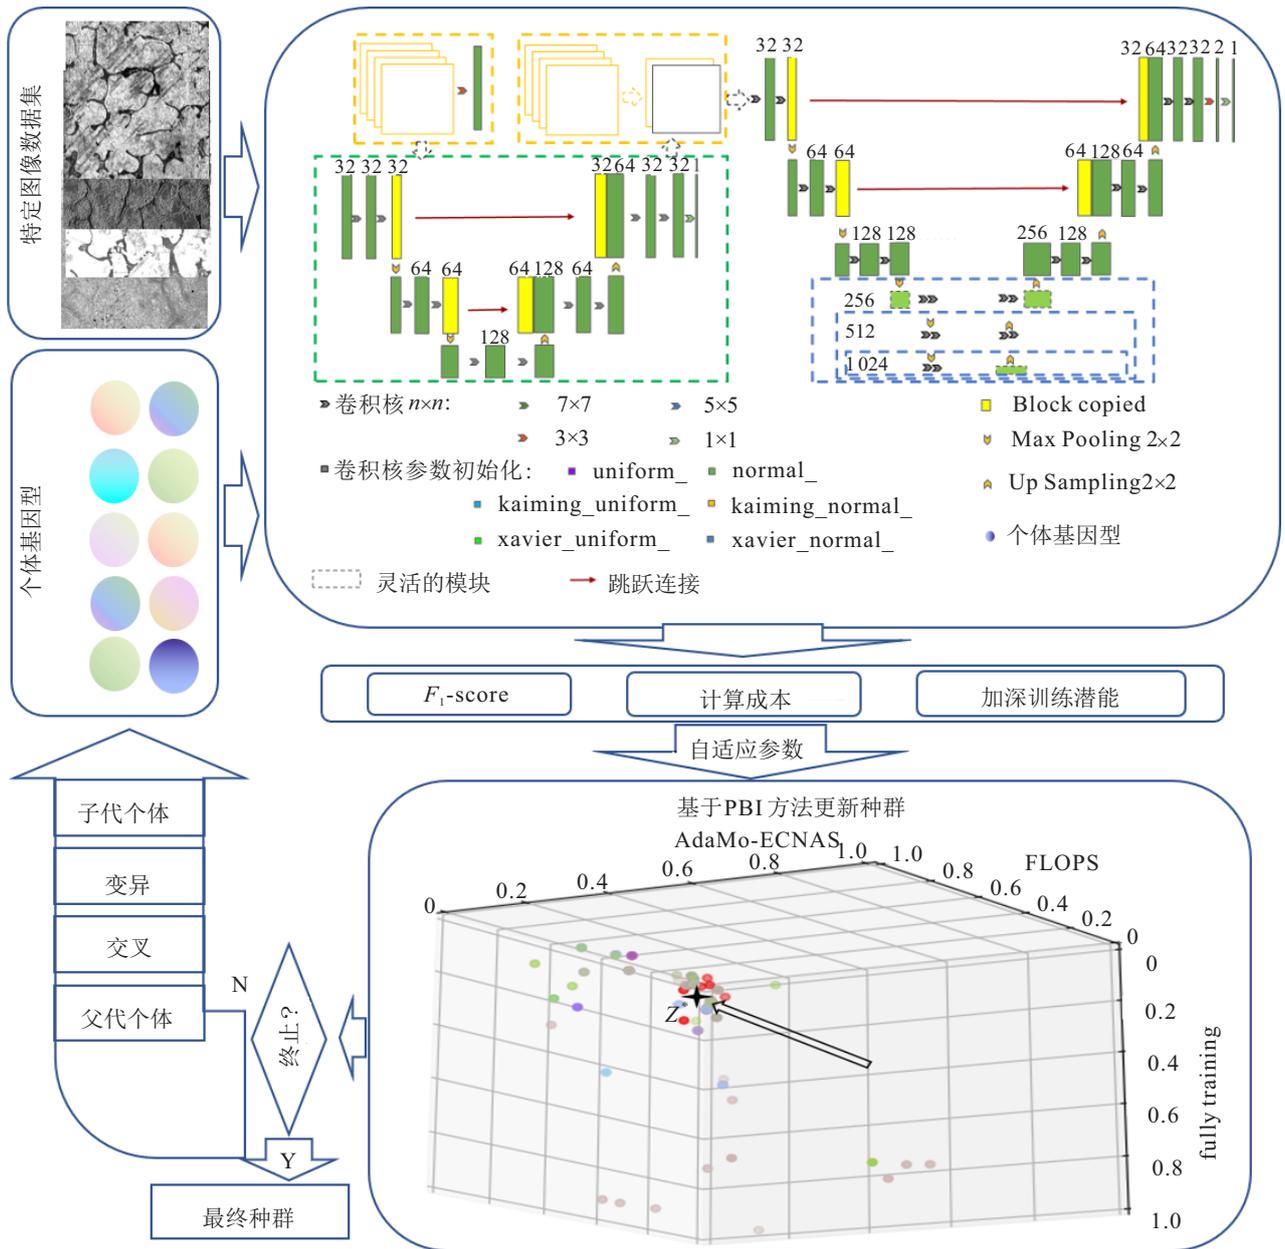


图1 提出的AdaMo-ECNAS的整体框架

14) $P \leftarrow$ 对于任何索引 $j \in B(i)$, 根据式(2), 若 $g^{pbi}(x_g^y | \lambda^j, z^*) < g^{pbi}(x_g^j | \lambda^j, z^*)$ 则将 p_g^j 替换为 p_g^y .

15) end

16) end

17) return P

2.2 编码解码策略

在卷积神经网络架构搜索过程中, 每个网络架构和超参数都可以被编码为一个个体. 相应地, 进化过程中产生的新个体也可以被解码为相应的网络架构. 架构骨架在图1中给出, 用于构建个体每个基因的候选值分别为: 激活函数(ReLU, ELU, Softplus, Hardsigmoid, LeakyReLU); 优化函数(RMSprop, Adam, SGD, Adagrad, Adadelta, Adamax,

AdamW); 学习率(0.0001, 0.001, 0.01, 0.1, 1.0), 核初始化方式(xavier_uniform, xavier_normal, uniform, kaiming_uniform, kaiming_normal, normal), 卷积网络预处理特征(Yes, No); 层数(3, 4, 5, 6); 滤波(Yes, No)和卷积核1-6(1x1, 3x3, 5x5, 7x7).

2.3 交叉变异策略

引入多点交叉重新组合来自选定亲本的基因类型, 其中交叉点数量和位置随机选择. 突变算子以一定概率应用于决策向量的随机位置. 在搜索开始时设置一个高的突变概率, 以保证种群多样化. 这允许算法探索搜索空间的不同区域, 避免过早地收敛到低质量区域. 随着代数的增加, 变异概率逐渐降低, 以允许更快的收敛. 每一代 g 的突变概率为 $p_m(g) = 1/g$.

2.4 进化过程和选择策略

首先,随机产生一个初始种群,并对其初始种群中的个体适配度进行评估;然后,整个种群在搜索空间内开始进化过程. 主要步骤如下: 1) 计算参考点 z^* ; 2) 随机生成均匀分布的权重向量 λ ; 3) 根据权重向量之间的欧氏距离选择每个权重向量的相邻权重向量; 4) 根据整个种群和权重向量给出基于PBI的平衡参数 θ ; 5) 对种群中每个个体的邻域都进行一次随机选择一对个体,通过交叉变异策略产生新的两个个体,选出具有非支配的个体,并用基于PBI的多目标函数进行个体筛选,更新种群. 种群在每次迭代中都要经历上述进化过程,直到满足停止标准. 具体过程已在算法1中描述.

3 实验结果

3.1 实验环境与参数设置

所提出的 AdaMo-ECNAS 算法在 PyTorch 中实现,所有实验均在单个 NVIDIA Tesla T4 上进行, CUDA 版本为 10.2.

考虑计算成本,种群大小 N 和最大代数 G 分别被经验性地设定为 20 和 10,批量大小设定为 1. 在进化过程中,训练过程的 epochs 设定为 80. 进化搜索后的最佳架构的微调在 900 epochs 中进行.

钢铁数据集包含 300 张图片,其中 250 张图片作为训练集,50 张图片作为测试集. 视网膜数据集

CHASE_DB1 有来自两位专家的不同注释,但只有第 1 位专家的注释被用作图像数据标签,其中前 20 张图片用于训练,其余 8 张图片用作测试集. 本文用 0.8 和 0.2 的比例将原始训练集分为训练集和验证集. 比较分割预测模型能力时,所使用的 5 个评价指标分别为准确率(Acc)、灵敏度(Sen)、 F_1 -score、计算浮点(FLOPs)和参数量(params).

3.2 基准测试问题

为了更直观地验证所提出基于自适应PBI的多目标优化算法的有效性,对多目标优化测试函数进行数值实验. 基于自适应PBI的优化方法(AdaMo)在问题 DTLZ 1 和 IMOP 5 上进行测试,测试问题 DTLZ 1 具有规则的 Pareto 前沿形状,而问题 IMOP 5 具有不连续的 Pareto 前沿形状.

从图2中可以看出,所提出方法得到的解集具有良好的分布性和收敛性. 具体而言,自适应均衡参数 θ 在执行三目标的 DTLZ 1 和 IMOP 5 问题时优于固定均衡参数的方法;在处理 DTLZ 1 问题时所提出方法与 $\theta = 5$ 实验结果相似且是最优结果;在处理 IMOP 5 问题时所提出方法与 $\theta = 0.5$ 实验结果相似,且所提出方法优于固定均衡参数 ($\theta = 0.5, 1, 5$) 的结果. 对于现实问题而言,一般不具有规则和均匀性,且所研究的 NAS 问题也是不连续问题,以上实验结果验证了所提出自适应方法更具有适应新问题的潜质.

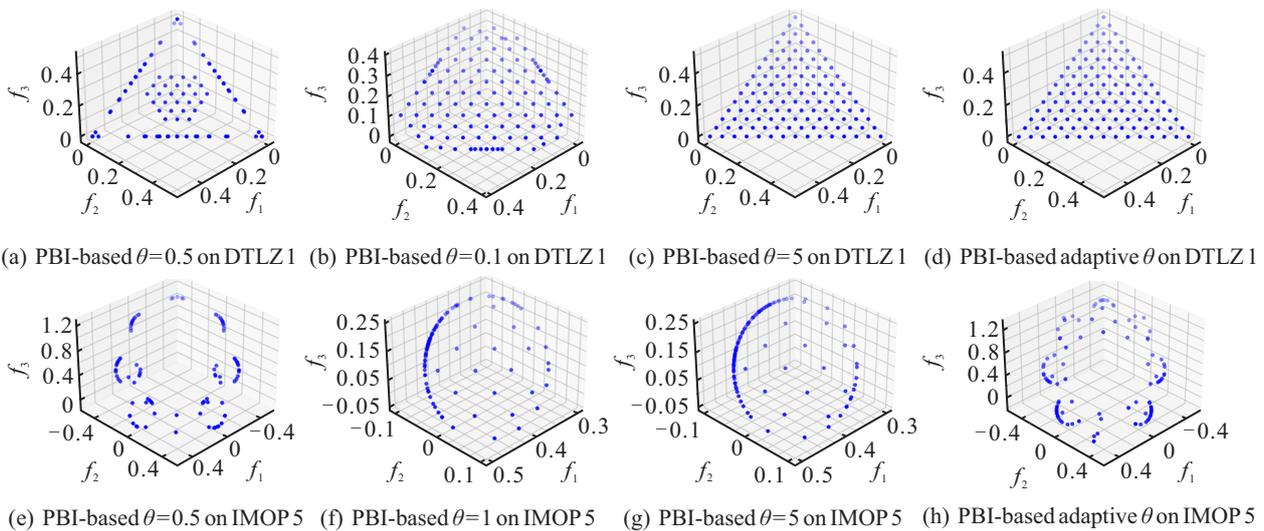


图 2 对应于不同 θ 值和自适应 θ 值的 DTLZ 1 和 IMOP 5 问题的近似集

3.3 钢铁数据集分割问题

首先研究所提出的 AdaMo-ECNAS 在钢铁微观结构(先共析渗碳体网状微观结构, PCNM)分割方面的性能,目的是获得具有较低计算成本和较好分割性能模型. 渗碳体的存在有助于 UHCS 的高硬度和

耐磨性,同时伴随的问题是脆性碳化物网络可能成为裂缝,而裂缝扩展提供了裂缝起始点和途径,降低了 UHCS 的韧性/延展性. 预测模型的确定分两部分实现,首先通过三目标进化种群得到最优候选者;然后对最优个体进行深度训练,得到具有优良预测能力

的模型.

在最终的种群中,根据PBI的三目标衡量指标筛选出最优个体,为了进一步验证获得个体的潜力,对相应的网络和超参数(通过解码方法获得)进行深度训练.进化搜索后的最佳网络结构微调为900轮迭代训练,实验结果如表1所示.

表1 多目标进化获得优良个体的性能与经典架构模型比较(PCNM)

architecture	Acc	Sen	F_1 -score	FLOPs	params
U-Net ^[18]	0.942	0.836	0.820	13.68 G	7.76 M
U-Net++ ^[19]	0.944	0.842	0.824	33.84 G	9.04 M
LANet ^[20]	0.936	0.808	0.797	8.17 G	23.78 M
SegNet ^[21]	0.926	0.810	0.777	40.05 G	29.43 M
AttU-Net ^[22]	0.944	0.826	0.817	66.55 G	34.87 M
AdaMo-ECNAS	0.943	0.844	0.823	7.17 G	0.46 M

从表1可以看到,进化获得的优良个体在各个指标上取得了与专业人员手动设计的模型相媲美的结果,甚至个别指标超越一些手动设计的模型,且模型

的计算浮点(FLOPs)和参数量(params)最小.特别地,获得的架构参数量是极小的且其他架构的参数量是其十几倍.这体现了多目标优化NAS具备降低计算成本的能力,即所提出方法选出的优良个体具有在降低计算成本情况下保证其性能的特性.

图3对分割结果的视图可视化直接展现了其分割效果,直观地比较了不同架构的分割结果.图像中蓝色像素表示未检测到的先共析渗碳体网状微结构,红色像素表示错误识别的先共析渗碳体网状微结构.可以看出,钢铁微观图像中的微观结构具有一定的复杂性,图中展示的3张图像特征各异,使得精准分割图像特征增加了难度,而所提出算法与其他算法的分割视觉对比发现其细节分割方面达到了较好的性能.仔细观察图3中各个方法的分割结果可以发现,5个指标中 F_1 -score指标与图像视觉效果是正相关的, F_1 -score是小目标检测问题最重要的指标.对比观察图3和表1发现,所提出算法的 F_1 -score达到了次优的水平,该结果是可观的.

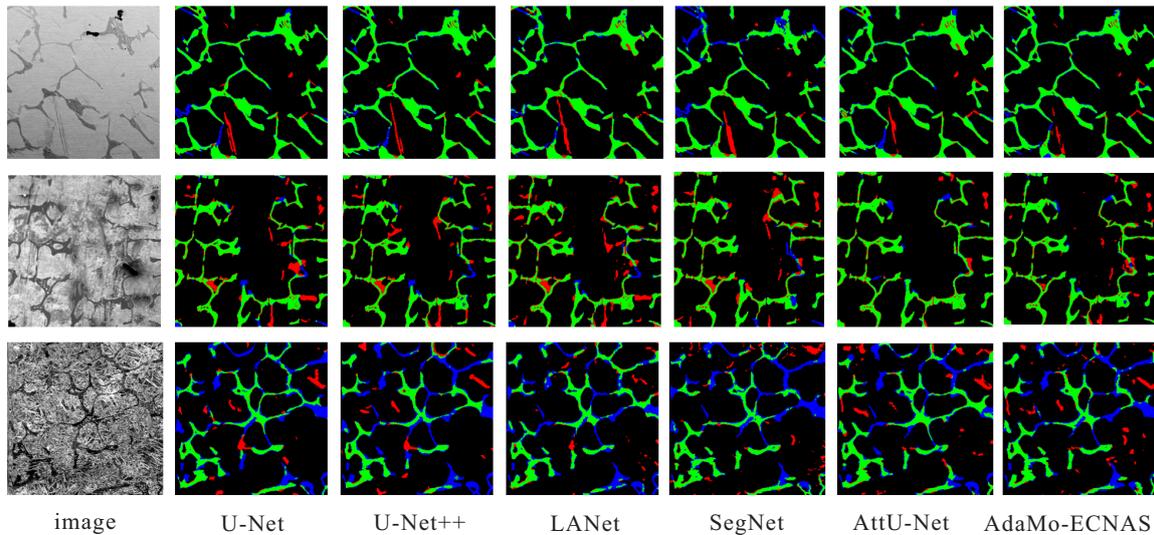


图3 分割结果的视图可视化

3.4 视网膜数据集分割问题

为了进一步验证所提出方法的有效性和普适性,使用CHASE_DB1数据集进行分割性能评估.首先验证有效性,将AdaMo-ECNAS进化获得的最佳架构与已发表文章中报告的架构进行比较.实验结果分为两部分:一部分源于已发表文献,算法在CHASE_DB1数据集上进行验证,具体数值比较如表2第1~第7行所示;另一部分是对表1中具有代表性的经典模型重新训练获得的评估指标,具体数值比较如表2第8~第10行所示.为了更客观地分析实验结果,图4给出了视网膜的可视化分割结果.

表2 在CHASE_DB1数据集上与现有最先进方法比较

model	Acc	Sen	F_1 -score	FLOPs	params
Li等 ^[23]	0.958	0.750	N/A	—	—
Fan等 ^[24]	0.957	0.765	N/A	—	—
Mou等 ^[25]	0.964	0.827	N/A	—	—
Alom等 ^[26]	0.963	0.775	0.792	—	—
DUNet ^[27]	0.961	0.763	0.788	—	—
Yang等 ^[28]	0.963	0.817	0.799	—	—
CC-Net ^[29]	0.971	0.820	0.781	—	—
U-Net++	0.973	0.828	0.789	541.04 G	9.04 M
SegNet	0.965	0.726	0.718	640.88 G	29.43 M
AttU-Net	0.974	0.834	0.793	1 064.90 G	34.87 M
AdaMo-ECNAS	0.973	0.810	0.794	114.62 G	0.46 M

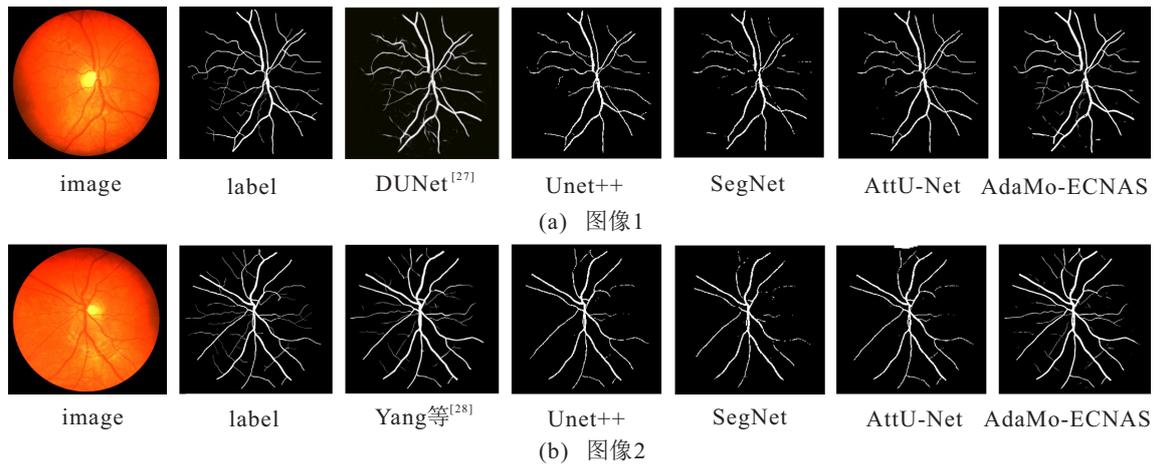


图 4 可视化分割结果

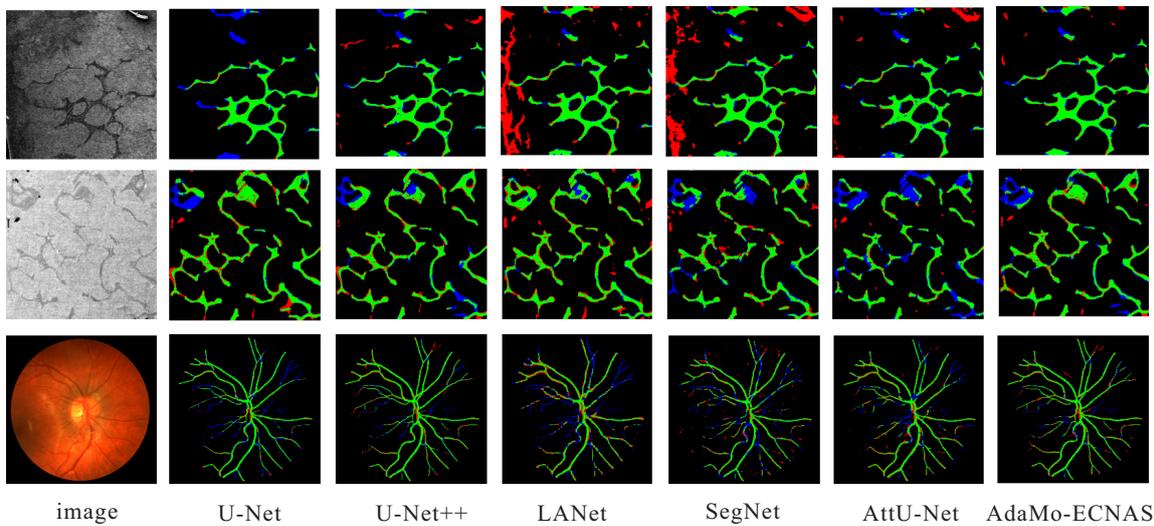


图 5 可视化在混合数据集上获得的模型的分割结果

观察表2中准确率(Acc)、灵敏度(Sen)和 F_1 -score三个指标发现,所提出方法自动设计的模型与专业人员专门手动设计的模型相比,结果毫不逊色,与各个指标的最优值较为接近,即自动设计的网络架构接近于手动设计模型的分割性能. 具体而言,表2中 F_1 -score指标达到了次优水平,浮点运算次数(FLOPs)和参数(params)都是最小的,表明所提出算法构建的网络模型在保证分割性能的基础上,复杂度是最低的,参数是最少的,即所提出算法实现了自动设计轻量化模型的目的. 另一方面,对比表1和表2可以发现,在不同数据集上取得最优 F_1 -score的模型是不同的. 相比而言,所提出AdaMo-ECNAS方法具有较好的普适性. 对比观察数值指标和视觉分割结果可以更好地证实所提出方法获得的分割预测模型是具有竞争性的,甚至超越了人工设计的网络架构的性能. 由图4中视觉对比可以看出,所提出算法与不同算法的视觉比较中其细节信息的保留效果是略优的,这也表明所提出算法对新实例问题的可视化分割结

果的预测模型构建是可行的.

综上,依据表2和图4的观察结果,与其他现有先进方法相比,所提出方法可以归结为具有3个方面优势:1)通过多目标进化算法实现了网络架构的自动设计,同时算法所设计的模型能够达到专家手动设计模型的性能水平;2)能够在保证分割性能的基础上,获得规模更小的网络架构模型,从而显著降低对计算资源的需求;3)具有一定的普适性,能够用于不同问题的网络架构自动设计.

3.5 数据集混合实验

根据实际问题收集制作的数据集具有不同的数据集特点,涉及不同且相似的问题设计一个万能模型值得进一步探究和分析. 本节将PCNM和CHASE_DB1整合成一个混合数据集对其进行训练学习获得预测分割模型,然后对模型进行测试. 表3给出了不同测试集的各个性能指标. 由表3可以发现,所提出方法的自适应性优于其他方法. 在PCNM+CHASE_DB1测试数据集上对比不同方法

发现,所提出方法在 Acc、Sen 和 F_1 -score 三项指标上达到最优,证实了方法的适用性是良好的.为了更好地比较所提出方法对于不同来源数据的分割效果,对 PCNM 测试数据集和 CHASE_DB 1 测试数据集的分割结果分别进行分析.由表 3 可以看出,所提出算法对 PCNM 测试集的分割结果是较好的,相比于其他方法而言获得的性能指标保持在最优或次优的水平.相应的视觉效果如图 5 所示.

表 3 多目标进化获得优良个体的性能与经典架构模型
的比较(PCNM+CHASE_DB 1 混合数据集)

test data sets	architecture	Acc	Sen	F_1 -score
PCNM (50 images)	U-Net	0.945	0.849	0.830
	U-Net++	0.945	0.828	0.824
	LANet	0.936	0.833	0.802
	SegNet	0.932	0.801	0.785
	AttU-Net	0.937	0.810	0.798
	AdaMo-ECNAS	0.947	0.839	0.832
CHASE_DB1 (8 images)	U-Net	0.974	0.740	0.776
	U-Net++	0.974	0.816	0.794
	LANet	0.957	0.651	0.643
	SegNet	0.964	0.646	0.685
	AttU-Net	0.966	0.730	0.718
	AdaMo-ECNAS	0.972	0.826	0.780
PCNM + CHASE_DB1 (58 images)	U-Net	0.949	0.834	0.823
	U-Net++	0.949	0.826	0.820
	LANet	0.939	0.808	0.781
	SegNet	0.936	0.780	0.772
	AttU-Net	0.941	0.799	0.787
	AdaMo-ECNAS	0.950	0.837	0.825

下面对比 AdaMo-ECNAS 方法在单一数据集和混合数据集上获得的实验结果,即 PCNM 测试数据集(表 1 中 AdaMo-ECNAS 和表 3 中 PCNM 的 AdaMo-ECNAS)和 CHASE_DB 1 测试数据集(表 2 中 AdaMo-ECNAS 和表 3 中 CHASE_DB1 的 AdaMo-ECNAS).注意到,混合数据集获得的模型在测试集上获得的性能指标更高一些,该结果是出乎意料的.结合数据集规模以及整合两个数据集时统一化处理的特点进一步分析不难发现,PCNM 和 CHASE_DB1 的图像数据量规模比为 300:28,为了实现两个数据集共同训练模型,将 CHASE_DB 1 数据集处理为与 PCNM 相同属性的图像数据集.以上两点表明,在混合数据集中 PCNM 数据集是更占优势的,在混合数据集中占小比例的 CHASE_DB 1 数据集的存在在某种程度上相当于在训练模型时添加了干扰信息,这个干扰信息起到了提升模型鲁棒性的效果.以上分析表明,数据集混合实验获得的结果是合理的.

4 结论

CNN 已广泛应用于人工智能,然而手动设计适合实际问题的架构是一项繁琐的任务,因此阻碍了

其发展.受神经架构搜索和多目标优化的启发,提出了 AdaMo-ECNAS 方法用于进化 CNNs 模型,采用三目标优化范式,以最大限度地提高预测分割的 F_1 -score,最小化计算成本,并最大限度地提高额外的训练潜力.特别地,通过基于自适应 PBI 的方法在较小的 epochs 运行中发现一组具有综合性能的优良个体,为根据实际情况选择满意的个体提供灵活性.在钢铁微观结构数据集、视网膜数据集以及两者混合数据集上进行实验以表明 AdaMo-ECNAS 的有效性.实验结果表明,AdaMo-ECNAS 能够获得具有较好综合性能指标的个体.通过将 AdaMo-ECNAS 与其他方法进行比较,进一步验证了所提出方法的优越性.

参考文献(References)

- [1] Meng C, Sun K, Guan S Y, et al. Multiscale dense convolutional neural network for DSA cerebrovascular segmentation[J]. Neurocomputing, 2020, 373: 123-134.
- [2] 石雪,李玉,赵泉华.层次混合模型快速遥感影像分割算法[J].控制与决策,2020,35(6):1316-1322.
(Shi X, Li Y, Zhao Q H. Hierarchical Gaussian mixture model for fast remote sensing image segmentation[J]. Control and Decision, 2020, 35(6): 1316-1322.)
- [3] Vargas-Hákim G A, Mezura-Montes E, Acosta-Mesa H G. A review on convolutional neural network encodings for neuroevolution[J]. IEEE Transactions on Evolutionary Computation, 2022, 26(1): 12-27.
- [4] Tang L X, Meng Y. Data analytics and optimization for smart industry[J]. Frontiers of Engineering Management, 2021, 8(2): 157-171.
- [5] Sun Y N, Xue B, Zhang M J, et al. Automatically designing CNN architectures using the genetic algorithm for image classification[J]. IEEE Transactions on Cybernetics, 2020, 50(9): 3840-3854.
- [6] Xie L X, Yuille A. Genetic CNN[C]. The IEEE International Conference on Computer Vision. Venice, 2017: 1388-1397.
- [7] Liu Y Q, Sun Y N, Xue B, et al. A survey on evolutionary neural architecture search[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(2): 550-570.
- [8] 邓武,蔡幸,周永权,等.一种基于多策略差分进化的分解多目标进化算法[J].控制与决策,2022,37(2):387-392.
(Deng W, Cai X, Zhou Y Q, et al. A novel decomposition multi-objective evolutionary algorithm based on differential evolution model with multi-strategy[J]. Control and Decision, 2022, 37(2): 387-392.)
- [9] 李二超,魏立森.基于指标和自适应边界选择的高维多目标优化算法[J].控制与决策,2022,37(5):1183-1194.
(Li E C, Wei L S. An indicator-based many-objective evolutionary algorithm with adaptive boundary selection[J]. Control and Decision, 2022, 37(5):

- 1183-1194.)
- [10] Lu Z C, Whalen I, Dhebar Y, et al. Multiobjective evolutionary design of deep convolutional neural networks for image classification[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(2): 277-291.
- [11] Baldeon-Calisto M, Lai-Yuen S K. AdaResU-Net: Multiobjective adaptive convolutional neural network for medical image segmentation[J]. *Neurocomputing*, 2020, 392: 325-340.
- [12] Baldeon-Calisto M, Lai-Yuen S K. AdaEn-Net: An ensemble of adaptive 2D-3D fully convolutional networks for medical image segmentation[J]. *Neural Networks*, 2020, 126: 76-94.
- [13] Bosma M, Dushatskiy A, Grewal M, et al. Mixed-block neural architecture search for medical image segmentation[J/OL]. 2022, arXiv: 2202.11401.
- [14] Zhang M, Li H Q, Pan S R, et al. Convolutional neural networks-based lung nodule classification: A surrogate-assisted evolutionary algorithm for hyperparameter optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(5): 869-882.
- [15] Wen Y W, Peng S H, Ting C K. Two-stage evolutionary neural architecture search for transfer learning[J]. *IEEE Transactions on Evolutionary Computation*, 2021, 25(5): 928-940.
- [16] Tong L, Du B. Neural architecture search via reference point based multi-objective evolutionary algorithm[J]. *Pattern Recognition*, 2022, 132: 108962.
- [17] Wei Z H, Yang J M, Hu Z H, et al. An adaptive decomposition evolutionary algorithm based on environmental information for many-objective optimization[J]. *ISA Transactions*, 2021, 111: 108-120.
- [18] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[M]. *Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2015: 234-241.
- [19] Zhou Z W, Siddiquee M M R, Tajbakhsh N, et al. UNet++: Redesigning skip connections to exploit multiscale features in image segmentation[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(6): 1856-1867.
- [20] Ding L, Tang H, Bruzzone L. LANet: Local attention embedding to improve the semantic segmentation of remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(1): 426-435.
- [21] 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.
- [22] Wang S H, Li L, Zhuang X H. AttU-NET: Attention U-net for Brain tumor segmentation[M]. Cham: Springer International Publishing, 2022: 302-311.
- [23] Li Q L, Feng B W, Xie L P, et al. A cross-modality learning approach for vessel segmentation in retinal images[J]. *IEEE Transactions on Medical Imaging*, 2016, 35(1): 109-118.
- [24] Fan Z, Mo J J. Automated blood vessel segmentation based on de-noising auto-encoder and neural network[C]. *International Conference on Machine Learning and Cybernetics*. Jeju, 2017: 849-856.
- [25] Mou L, Chen L, Cheng J, et al. Dense dilated network with probability regularized walk for vessel detection[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(5): 1392-1403.
- [26] Alom M Z, Yakopcic C, Hasan M, et al. Recurrent residual U-net for medical image segmentation[J]. *Journal of Medical Imaging*, 2019, 6(1): 014006.
- [27] Jin Q G, Meng Z P, Pham T D, et al. DUNet: A deformable network for retinal vessel segmentation[J]. *Knowledge-Based Systems*, 2019, 178(C): 149-162.
- [28] Yang L, Wang H X, Zeng Q S, et al. A hybrid deep segmentation network for fundus vessels via deep-learning framework[J]. *Neurocomputing*, 2021, 448: 168-178.
- [29] Yang D X, Zhao H D, Han T C. Learning feature-rich integrated comprehensive context networks for automated fundus retinal vessel analysis[J]. *Neurocomputing*, 2022, 491: 132-143.

作者简介

王维(1990—), 女, 博士生, 从事进化算法、卷积神经网络及其图像分割应用等研究, E-mail: wangwei_4821@163.com;

王显鹏(1980—), 男, 教授, 博士生导师, 从事基于机器学习的工业生产过程建模、操作优化、进化算法等研究, E-mail: wangxianpeng@ise.neu.edu.cn;

宋相满(1986—), 男, 讲师, 博士, 从事工业智能数据解析、计算智能优化算法、图像理解与物联传感技术及相关应用等研究, E-mail: songxiangman@ise.neu.edu.cn.