

引用格式:宋灿,吴谨,朱磊,等. 针对遥感图像大棚提取的深度学习模型研究[J]. 微电子学与计算机, 2021, 38(1): 51-56.
[SONG C, WU J, ZHU L, et al. Greenhouse segmentation of remote sensing images based on deep learning[J]. Microelectronics & Computer, 2021, 38(1): 51-56.]

针对遥感图像大棚提取的深度学习模型研究

宋 灿, 吴 谨, 朱 磊, 邓慧萍

(武汉科技大学 信息科学与工程学院, 湖北 武汉 430081)

摘 要: 大棚面积统计是蔬菜业进行科学管理的客观需求, 通过深度学习自动获取大棚面积能更好地降低人工成本. 为了准确获取大棚面积, 本文使用基于深度学习的模型框架来解决这一问题. 首先, 使用金字塔池化模块和链式池化模块分别处理大尺度和小尺度的高层特征, 在保持分辨率和避免退化的情况下提取多尺度的语义信息; 然后, 使用递归残差模块交替融合高层和低层信息, 进一步优化分割结果. 通过和三种较新的算法进行比较, 实验结果表明本文的方法取得了最优的结果.

关键词: 遥感图像; 大棚提取; 深度学习; 多尺度; 递归残差学习

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2021)01-0051-06

Greenhouse segmentation of remote sensing images based on deep learning

SONG Can, WU Jin, ZHU Lei, DENG Hui-ping

(College of Information Science and Technology, Wuhan University of
Science and Technology, Wuhan 430081, China)

Abstract: Greenhouse area statistics is the objective requirement of scientific management of vegetable industry. It can reduce labor costs better to acquire greenhouse area automatically through deep learning. In order to obtain the greenhouse area accurately, a framework based on deep learning is proposed to solve this problem. First of all, pyramid pooling module and chain pooling module are used to deal with high-level features of large scale and small scale respectively, and multi-scale semantic information is extracted under the condition of maintaining resolution and avoiding degradation. Then, the recursive residual module is used to alternately fuse the high-level and low-level information to further optimize the segmentation results. Comparing with three newer algorithms, the experimental results show that the proposed method has achieved the best results.

Key words: remote sensing; greenhouse segmentation; deeplearning; multi-scale; recursive residual learning

1 引言

近年来,随着我国国民经济和人民生活水平的高速发展,大棚产业呈现不断发展之势. 菜地面积的不断增长,给我国蔬菜业的供需管理也带来了巨大的挑战. 因此,快速、准确的获取大棚面积是一个极

具研究价值的问题. 目前,大棚面积的统计已经由传统的实地调查^[1]转向基于遥感图像的分割提取. 基于遥感图像的地物提取为农林业带来了巨大的价值,因此,很多学者对遥感图像分割进行了研究. 黄振国等人^[2]提出了一种基于光谱特征的遥感图像分割方法. 徐旭等人^[3]提出了一种基于感知器神经网络

络进行决策的分割方法. 冯朝晖等人^[4]提出了一种基于改进分水岭的分割方法. 陈前等人^[5]提出了一种基于深度学习的分割方法.

在以上的遥感图像分割算法中,大量的方法^[1-4]都是基于传统的图像分割策略,基于深度学习^[5]的分割研究还相对较少,尤其是针对大棚分割的研究. 虽然目前在遥感图像上基于深度学习的方法并不多,但是在自然场景图上深度学习的研究却受到了很多学者的关注. 为了进行端到端的训练,Long 等人^[6]第一次在深度学习引入了全卷积网络. 在文献^[7]中,Zheng 等人将基于 CRFs(Conditional Random Fields)的概率图模型以 RNN(Recurrent Neural Network)的形式嵌入到深度学习模型中,将像素之间的相关性融入到了 CNNs(Convolutional Neural Networks)中. 文献^[8]则是通过交替融合高层信息和低层信息来替身模型的性能.

图像分割属于密集预测任务,需要进行主要逐像素的预测. 深度学习更适合做图像分类和目标检测这种高级的视觉任务,对于语义分割这种像素级标记任务存在巨大的挑战. 由于深度神经网络的感受野非常大,生成的像素级结果会非常粗糙^[7]. 因此,这需要使用抽象的高层特征进行分类,得到目标类别这种高层次的信息,并结合低层的高分辨率特征,得到精细的逐像素分割结果. 文献^[6]简单的使用双线性插值获取高分辨率的分割结果,该模型作为最早将深度学习引入语义分割的网络之一,为后续许多网络提供了思路和方法. 文献^[7]则是通过 CRFs 进行精细分割,以此获取更优的结果. 文献^[8]通过反复融合高层信息和低层信息,进行精确的图像分割.


高层特征具有丰富的语义特征,适用于分类任务,但是分辨率低;而低层特征分辨率高,适用于精细化的逐像素分割,但是低层特征感受野小,不足以获取目标的所有信息. 因此,图像分割这类任务必须同时结合高层信息和低层信息才能得到准确的精细分割结果. 受到上述文献的启发,本文提出了一个使用池化模块提取大感受野的目标特征,并融合高层特征和低层特征进行优化的模型. 首先,使用金字塔池化模块^[9]和链式池化模块^[10]分别处理大尺度和小尺度的高层特征,在不同的感受野上提取多尺度的语义信息;然后,使用递归残差模块^[11]交替融合高层和低层信息,进一步优化分割结果.

2 流程框架

大棚分割本质上是一个语义分割任务,这是计

算机视觉基础研究方向之一. 其目的是给图像中的每一个像素预测一个类别标签,也就是说它是一个密集预测任务. 相比图像分类和目标检测而言,它的难度更高. 这不仅需要预测类别这种抽象的信息,还需要能准确的处理位置信息,做到逐像素分割. 在很多图像处理任务中,目标检测的位置并不需要做到像素级的精度,比如目标计数. 但是语义分割的结果却是取决于像素级的精度,比如大棚分割,每个像素分错都会影响最终的面积计算. 因此,本文提出了一个框架来处理大棚分割任务,首先通过金字塔池化和链式池化来获取抽象的类别信息,然后使用递归残差模块提高像素精度.

ResNet^[12]作为一个优秀的深度模型,被很多研究者选为各项任务的骨干网络. 基于该网络优异的性能,本文选取 ResNet50 作为基础网络,并从 1/4 和 1/32 分辨率的数据层中抽取特征作为后续网络的输入. 如图 1 所示,首先,抽取 1/32 分辨率的高层特征,使用金字塔池化和链式池化分别处理大尺度和小尺度的目标,得到初始的分割结果. 然后,使用递归残差模块交替融合低层特征和高层特征,将初始分割结果进一步优化.



征分辨率为原图像的 $1/32$, 大小即为 16×16 . 在全局特征提取上, 使用跨分辨率的三层金字塔池化, 感受野以此为高层特征的 $1/5$, $1/3$ 和 $1/1$. 局部特征则使用通分辨率的链式池化提取, 随着池化层的深度增加, 感受野逐步增大. 最后使用卷积将各尺度的特征融合起来, 得到目标级类别信息.

3.1 金字塔池化

全局的场景信息对于大棚提取是非常重要的. 准确的上下文场景信息能更好的帮助模型提取大棚区域. 例如常见的城市区域, 湖泊区域和植被区域, 很明显大棚只可能在植被区域. 如果能判断该区域属于城市或者是湖泊区域, 那么在此间和大棚相似的目标就能排除, 有效的降低误检率. 此外, 通过上下文关系也能提升大棚分割的准确性. 比如同为植被, 农田旁边的区域是大棚的可能性就要高一些, 而森林旁边的区域是大棚的可能性就会低一些. 因此, 提取全局的大尺度的场景上下文信息是非常有必要的.

根据以上分析, 本文在整个框架中使用了场景信息提取模块——金字塔池化. 这个模块的目的是为了更有效的提取先验的全局上下文信息. 相比于一般的目标, 场景特征的感受野要大得多. 在深度学习中, 感受野的大小可以根据网络模型进行粗略估计. 虽然理论上 ResNet 的感受野已经比输入图像更大, 但是实际感受野要远小于理论上的感受野^[13], 尤其是在网络的高层. 这种现象使得很多网络没有足够的感受野来获取场景级别的信息. 以此, 本文使用金字塔池化来增大感受野, 以便提取大尺度的特征信息.

提取全局场景信息的简单方式是全局池化, 但是这种方式有它自身的缺陷. 在图像分类中, 通常一张图像仅包含一个目标, 使用全局池化提取目标信息是合理的, 比如 ResNet 在 ImageNet 数据集上分类时, 就使用了全局池化. 但是在语义分割中, 场景和目标都不是唯一的, 由于分辨率过低的原因全局池化会丢失位置信息. 因此, 本文使用多尺度的金字塔池化来平衡分辨率和感受野. 在多尺度金字塔池化中, 感受野越大的池化操作, 得到的特征分辨率就越低, 通过多个尺度的池化, 在小尺度上融合高分辨率的特征, 在大尺度上融合大感受野的特征.

详细的金字塔池化模块设计如图 2 所示. 整个模块的输入为 16×16 的高层语义特征, 通过三个池化操作分别得到 1×1 , 3×3 和 5×5 的全局信息. 然后使用卷积操作对提取到的大尺度场景信息进行




图 2 金字塔池化模块设计

降维处理, 降低数据量. 最后通过上采样操作将 1×1 , 3×3 和 5×5 的特征图映射到 16×16 的输入特征图大小, 再沿着通道维度叠加起来组成输出特征图.

3.2 链式池化

在上一届的金字塔池化模块中, 使用跨分辨率的池化操作提取全局的场景信息. 在本节中, 使用同分辨率的池化操作来提取不同尺度大小的前景目标. 对于语义分割任务, 目标的尺寸是连续变化的, 这就需要在多种尺度上提取对应的目标. 在大棚分割任务中, 前景目标的尺寸分布在一个很大的范围上. 这就需要网络的感受野分布在一个近似连续的空间上.

根据以上分析, 本文在一个连续的感受野空间上, 使用链式池化提取各种尺度的前景目标. 通常情况下, 可以通过不断叠加卷积操作构造一个近似连续的尺度空间. 但是, 根据 Zhou 等人^[13]的研究, 多层卷积在经过学习后, 时间上的感受野和理论上的感受野并不是一致的. 更重要的是, 在感受野过大后, 网络会产生退化现象^[11]. 当感受野过大时, 在边缘处计算特征图时, 有很大一部分输入数据都会填充零以保证分辨率不变, 这种填充零的操作会减小有效卷积的数量. 与此不同的是, 池化操作可以看做固定卷积核的卷积操作, 在网络学习过程中并不会产生变化, 也就不会出现退化现象.

具体的链式池化模块设计如图 3 所示. 整个模块是一个同分辨率的网络模型, 每层网络的特征图分辨率均为 16×16 . 网络的设计类似 ResNet 的残差学习, 在图 3 所示的结构中, 上侧分支是残差学习, 获取不同尺度的特征, 下侧分支是恒等变换. 在上侧的分支中, 从左到右通过池化操作逐步增大感受野, 并使用卷积操作学习对应尺度的特征. 需要注意的是, 图中的标记符号 $\oplus$ 是求和操作.

4 像素级细节优化

语义分割作为一个像素级标记的任务, 在目标




图3 链式池化模块设计

边缘处的处理是很重要的. 语义分割同时兼具高层和低层的计算机视觉处理特性, 既需要获取类别这种高层特性, 也需要像素级标记这种低层特征. 对于深度神经网络而言, 它具有极强的高层特征表示能力, 但是由于大感受野的扩散效应, 高层特征容易被过度平滑, 难以在像素级标记任务上取得令人满意的结果^[7]. 因此, 提高像素级的预测精度还需要融合低层细节信息, 充分低层特征的高分辨率特性和高层特征的语义特性.

近年来, 在提高输出结果的精细程度上有很多研究. 例如 UNet^[14], 通过 U 型结构的网络直接将低层细节信息引到高层的网络. 在文献^[7]中, 则使用条件随机场作为后处理, 融合像素将的位置和颜色信息优化分割结果. 文献^[8]通过将低层特征和高层特征交替融合的方式, 获取一个高分辨率的语义特征图来进行像素级的分割. 文献^[15]则交替使用高层特征和低层特征学习残差, 对初步的分割结果进行优化.

经过上一节的处理后, 已经可以使用的池化模块提取一个初步的分割结果. 因此, 本文使用递归残差模块交替使用高层特征和低层特征对分割结果做进一步的优化. 整个模块如图 4 所示, 初始结果为池化模块的输出, 高层特征和低层特征分别从骨干网络中提取(如图 1). 需要注意的是初始结果和高层特征都需要经过上采样操作, 将分辨率变为低层特征大小, 以便后续操作. 整个模块交替使用低层特征和高层特征结果先前的分割结果学习残差.




图4 递归残差模块设计

5 结果评估

5.1 实验数据

实验数据源自 ZY-3 和 GF-1 卫星拍摄的遥感图片. 这两颗卫星是我国的高分图像获取卫星, 其像素精度为 2 m. 在经过标记后, 所有的遥感图片被分割成了 $1\,024 \times 1\,024$ 的图片. 遥感图片存在大量的背景区域, 容易造成数据分布极度不平衡. 为了更好的训练网络, 对数据进行的清洗, 使得前景和背景的比例约为 1:3. 清洗后的图像数量为 4 627 张, 随机选取 3 854 张作为训练集, 773 张图片作为测试集, 训练集和测试集的比例约为 5:1.

5.2 实验设置

限于显存容量, 为方便比较, 所有的实验均将输入图片缩小为 512×512 . 特别的, 在本文提出的方法, 训练过程中 batchsize 设为 1, 学习率为 0.000 05, 使用 Adam 优化方法. 其他对比的方法 DeepLabv3^[16], PSPNet^[17], Unet^[14] 则使用默认的设置.

5.3 实验对比

5.3.1 平均交并比 mIoU

平均交并比在语义分割结果的评估上被广泛使用. 该评价指标有一个明显的优点, 得分不会随前景目标大小改变. 每个前景目标的评估结果由预测值和真实值这两个集合的交并比决定,

$$\text{mIoU} = \frac{1}{N} \sum_{i=1}^N \frac{\|\{\tilde{y}_i = 1\} \cap \{y_i = 1\}\|_0}{\|\{\tilde{y}_i = 1\} \cup \{y_i = 1\}\|_0} \quad (1)$$

公式中符号 $\|\{\cdot\}\|_0$ 表示集合 $\{\cdot\}$ 中元素的个数. $\tilde{y}_i$ 是模型预测结果, y_i 为人工标记的真实值, 仅可取 0 或 1, 其中 0 位背景, 1 为前景大棚. N 代表测试集的大小, 在大棚数据集中为 773.

5.3.2 准确率、召回率和 F-Measure

准确率、召回率和 F-Measure 是衡量分割性能的常用指标. 准确率 Precision 表示的是预测正确的大棚面积与所有预测大棚面积的比率, 反映的是模型的查准率. 召回率 Recall 表示的是预测正确的大棚面积与实际大棚面积的比率, 反映的是查全率. 而 F-Measure 表示的是准确率和召回率的加权调和, 反映的是两者的综合效果. Precision, Recall 和 F-Measure 的计算方法如式(2)~(4)所示:

$$\text{Precision} = \frac{1}{N} \sum_{i=1}^N \frac{\|\{\tilde{y}_i = 1\} \cap \{y_i = 1\}\|_0}{\|\{\tilde{y}_i = 1\}\|_0} \quad (2)$$

$$\text{Recall} = \frac{1}{N} \sum_{n=1}^N \frac{\|\{\hat{y}_i = 1\} \cap \{y_i = 1\}\|_0}{\|\{y_i = 1\}\|_0}$$

(3)

$$F_a = \frac{(1 + \alpha^2) \times \text{Precision} \times \text{Recall}}{\alpha^2 \times \text{Precision} + \text{Recall}}$$

(4)

需要注意的是,为了强调准确率 Precision,和大多数文献中的设置保持一致, α^2 设为 0.3.

5.3.3 平均绝对误差 MAE

平均绝对误差 MAE 是二类分割常用的评价指标之一,它反映的预测类别概率与真实值之间的差异.在以上的评价指标中,大多数都没有考虑背景的准确率,而 MAE 则同时将前景和背景的准确率进行了统一表示.其计算方法如下.

$$\text{MAE} = \frac{1}{NHW} \sum_{i=1}^N \sum_{r=1}^H \sum_{c=1}^W |s_i(r, c) - \hat{y}_i(r, c)|$$

(5)

上式中 s_i 表示模型预测的大棚概率.

如表 1 所示,实验结果表明,本文的结果除了在 Recall 指标上低于 UNet,在其它指标均取得了最优结果.虽然 Unet 在召回率 Recall 上取得了不错的结果,但是我们发现,其精度 Precision 指标比 PSPNet 和本文的方法低了约 4 个百分点.这说明 Unet 虽然能提取更多的大棚区域,但是其准确度不够,发生了更多的误检,把大量的背景区域预测为大棚. F-Measure 作为一个平衡的方法,更能说明模型性能的好坏.本文的方法在 F-Measure 这一指标上取得了最优结果,说明本文的方法是有效的. mIoU 指标对目标的大小不敏感,从实验结果上可以看出,本文的方法可以更好的检测出多种尺度的目标.不同于精度只评估前景的准确度,MAE 是一个同时衡量前景和背景的指标,在这一指标上,本文的误差最小,这说明本文的方法对前景和背景的预测更精确.

表 1 实验结果对比

	mIoU	MAE	Precision	Recall	F-Measure
DeepLabv3	0.631 9	0.153 1	0.773 5	0.7262	0.762 0
UNet	0.783 2	0.091 0	0.800 8	0.872 2	0.816 2
PSPNet	0.796 9	0.056 6	0.840 6	0.818 3	0.835 3
OUR	0.807 2	0.051 7	0.844 5	0.837 1	0.842 8

6 结束语

针对遥感图像中的大棚分割问题,本文提出了一个新的深度学习框架.首先,通过金字塔池化模块和链式池化模块分别处理大尺度和小尺度的高层特征;然后,使用递归残差模块交替融合高层和低层信

息.实验结果表明,相比于较新的一些算法,本文的效果更好.在精度 Precision,前景和背景逐像素误差 MAE,平均交并比 mIoU 等指标上均取得了最优结果.

参考文献:

[1] 李静,赵庚星,李涛,等. TM 影像中大棚菜地信息提取技术研究[J]. 水土保持学报, 2004, 18(1): 126-129. DOI: 10.3321/j. issn:1009-2242. 2004. 01. 033. LI J, ZHAO G X, LI T, et al. Study on technique of extracting greenhouse vegetable information from Landsat TM image[J]. Journal of Soil and Water Conservation, 2004, 18(1): 126-129. DOI: 10.3321/j. issn:1009-2242. 2004. 01. 033.

[2] 黄振国,陈仲新,刘芳清,等. 基于 HJ-1 影像的大棚菜地遥感监测技术研究—以山东寿光市为例[J]. 中国农业资源与区划, 2013, 34(5): 102-106. DOI: 10.7621/cjarrp. 1005-9121. 20130516. HUANG Z G, CHEN Z X, LIU F Q, et al. Monitoring of greenhouse vegetables land using HJ-1 remotely-sensed imagery[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2013, 34(5): 102-106. DOI: 10.7621/cjarrp. 1005-9121. 20130516.

[3] 徐旭. 基于图像特征的遥感影像水体自动提取方案研究[J]. 安徽建筑, 2019, 26(9): 50-51. DOI: 10.16330/j. cnki. 1007-7359. 2019. 09. 020.

[4] 冯朝晖,李芹,韩留生,等. 改进分水岭方法下的遥感图像水体提取[J]. 测绘通报, 2019(6): 11-15. DOI: 10.13474/j. cnki. 11-2246. 2019. 0175. FENG Z H, LI Q, HAN L S, et al. Remote sensing image water body extraction based on improved watershed[J]. Bulletin of Surveying and Mapping, 2019(6): 11-15. DOI: 10.13474/j. cnki. 11-2246. 2019. 0175.

[5] 陈前,郑利娟,李小娟,等. 基于深度学习的高分遥感影像水体提取模型研究[J]. 地理与地理信息科学, 2019, 35(4): 43-49. DOI: 10.3969/j. issn. 1672-0504. 2019. 04. 007. CHEN Q, ZHENG L J, LI X J, et al. Water body extraction from high-resolution satellite remote sensing images based on deep learning[J]. Geography and Geo-Information Science, 2019, 35(4): 43-49. DOI: 10.3969/j. issn. 1672-0504. 2019. 04. 007.

[6] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 2015: 3431-3440. DOI: 10.1109/

- CVPR, 2015, 7298965.
- [7] ZHENG S, JAYASUMANA S, ROMERA-PAREDES B, et al. Conditional random fields as recurrent neural networks[C]//Proceedings of 2015 IEEE International Conference on Computer Vision. Santiago, Chile: IEEE, 2015: 1529-1537. DOI: 10.1109/ICCV.2015.179.
- [8] SUN K, ZHAO Y, JIANG B R, et al. High-resolution representations for labeling pixels and regions[J]. arXiv: 1904.04514, 2019.
- [9] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848. DOI: 10.1109/TPAMI.2017.2699184.
- [10] LIN G S, MILAN A, SHEN C H, et al. RefineNet: multi-path refinement networks for high-resolution semantic segmentation[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 5168-5177. DOI: 10.1109/CVPR.2017.549.
- [11] CHEN L C, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation[EB/OL]. [2019-05-23]. <https://arxiv.org/pdf/1706.05587.pdf>.
- [12] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770-778. DOI: 10.1109/CVPR.2016.90.
- [13] ZHOU B L, KHOSLA A, LAPEDRIZA A, et al. Object detectors emerge in deep scene CNNs[J]. arXiv: 1412.6856, 2014.
- [14] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich, Germany: Springer, 2015: 234-241. DOI: 10.1007/978-3-319-24574-4_28.
- [15] DENG Z J, HU X W, ZHU L, et al. R3Net: recurrent residual refinement network for saliency detection[C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2018: 684-690. DOI: 10.24963/ijcai.2018/95.
- [16] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[EB/OL]. [2019-05-28]. <https://github.com/tensorflow/models/tree/master/>.
- [17] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 2881-2890. DOI: 10.1109/CVPR.2017.660.

作者简介:

宋 灿 男,(1992-),硕士研究生.研究方向为深度学习和语义分割.

吴 谨 女,(1967-),博士,教授.研究方向为图像处理与模式识别.

朱 磊(通讯作者) 男,(1982-),博士,副教授.研究方向为语义分割、目标检测、显著性检测等.

E-mail:838994872@qq.com.

邓慧萍 女,(1983-),博士,副教授.研究方向为图像处理和多媒体通信.

(上接第 50 页)

- [11] ZHANG D L, LI S Y, SONG Y K. Design and implementation of dual-port network on chip[C]//Proceedings of the 12th IEEE International Conference on Solid-State and Integrated Circuit Technology (ICSICT). Guilin, China: IEEE, 2014. DOI: 10.1109/ICSICT.2014.7021161.

作者简介:

朱新宇 男,(1995-),硕士研究生.研究方向为高性能 NoC 设计与测试. E-mail:383099959@qq.com.

王晓蕾 女,(1978-),博士,副研究员.研究方向为高性能 SoC/NoC 体系结构与实现.

宋宇鲲 男,(1975-),博士,副研究员.研究方向为面向数据密集与计算机密集应用的 SoC/MPSoC 体系结构与实现.

张多利 男,(1976-),博士,教授.研究方向为多核处理器体系结构与设计方法.