

引用格式:李众,白瑞君,洪军,等. 基于自适应特征融合及多尺度输出的遥感图像飞机检测算法[J]. 微电子学与计算机, 2021,38(4):40-45. [LI Z,BAI R J,HONG J,et al. Aircraft detection algorithm of remote sensing image based on adaptive feature fusion and multi-scale output[J]. Microelectronics & Computer,2021,38(4):40-45.]

基于自适应特征融合及多尺度输出的 遥感图像飞机检测算法

李 众¹,白瑞君^{1,2},洪 军¹,李亚伦^{1,2},王 高³,杨 剑¹

(1 中北大学 软件学院,山西 太原 030051;2 山西省信息产业技术研究院有限公司,
山西 太原 030051;3 中北大学 信息与通信工程学院,山西 太原 030051)

摘 要:针对当前 YOLOv3 算法在遥感图像中复杂场景飞机漏检、误检等问题,提出一种基于自适应特征融合及多尺度输出的遥感图像飞机检测算法.该算法首先使用 K-means++ 代替 K-means 算法对数据集进行聚类,解决了 K-means 初始聚类中心不稳定性;然后,在 YOLOv3 网络基础上增加了一个含有分辨率信息的尺度,更有利于检测小目标飞机;最后,在网络模型四尺度输出前增加了自适应特征融合层,解决了不同尺度的特征融合不充分以及减少或消除反向传导受到负样本的影响.实验结果表明,改进的 YOLOv3 算法在遥感图像上飞机检测精度达到 96.17%,比 YOLOv3 算法精度提高了 2.6%.

关键词:自适应特征融合;多尺度;遥感图像;飞机检测

中图分类号: TP391.41;TP183

文献标识码: A

文章编号: 1000—7180(2021)04—0040—06

Aircraft detection algorithm of remote sensing image based on adaptive feature fusion and multi-scale output

LI Zhong¹,BAI Rui-jun^{1,2},HONG Jun¹,LI Ya-lun^{1,2},WANG Gao³,YANG Jian¹

(1 School of Software, North University of China, Taiyuan 030051, Shanxi China;

2 Shanxi Information Industry Technology Research Institute Limited Company, Taiyuan 030051, Shanxi China;

3 Collage of information and communication engineering, Taiyuan 030051, Shanxi China)

Abstract: In view of the problems such as missing detection and false detection of complex scene aircraft in remote sensing image by the YOLOv3 algorithm, an aircraft detection algorithm based on adaptive feature fusion and multiscale output is proposed. Firstly, K-means++ is used to cluster the data set instead of K-means algorithm, which solves the instability of the initial clustering center of k-means. Then, on the basis of YOLOv3 network, a scale with resolution information is added, which is more conducive to the detection of small target aircraft. Finally, an adaptive feature fusion layer is added before the four scale output of the network model, which solves the problem of insufficient feature fusion at different scales and reduces or eliminates the influence of negative samples on reverse conduction. The experimental results show that the detection accuracy of the improved algorithm reaches 96.17% in the remote sensing image, which is 2.6% higher than that of the algorithm.

Key words: adaptive feature fusion; Multiscale; remote sensing image; aircraft detection

1 引言

在遥感图像上做目标检测是遥感图像智能解译研究的重要课题之一。由于遥感图像上的待检测目标形态不一,大小不同,场景复杂等,使得遥感图像上的目标检测受到各种挑战。

面对遥感图像做检测任务,学者们已经相继提出了很多有价值的算法,目前主要可以分为两大类,一类是传统的目标检测算法,如基于统计的目标检测^[1]、基于模型的目标检测^[2]等。另一类是基于卷积神经网络的检测算法,如 Faster R-CNN、SSD 等算法^[3-7]。本文在 YOLOv3 网络框架的基础上提出一种自适应特征融合及多尺度输出的遥感图像飞机检测算法。

2 YOLOv3 算法思想

YOLOv3 是作者 Redmo 等人^[8]在他们原先设计的 YOLOv2 算法^[9]的基础上,融合了 ResNet 网络^[10]、FPN、二元交叉熵损失等思想,提出的 YOLOv3 算法。该算法检测速度快,识别率高,目前在工业目标检测领域是优秀的算法之一。

YOLOv3 网络框架如图 1 所示,YOLOv3 输入的图片尺寸为 416×416 像素大小,使用了类似 FPN 网络的尺度金字塔结构输出三种尺度进行预

测,每种预测尺度上会根据特征图大小分别划分为 13×13 、 26×26 、 52×52 大小的单元格。每个输出尺度上的单元格又存在 3 个锚点框,每个锚点框又负责预测检测目标的边框的 4 个坐标,1 个置信度,以及目标的类别。

3 改进 YOLOv3 算法思想

为得到更好的检测算法,本文在 YOLOv3 网络框架基础上进行改进。

3.1 自适应特征融合及多尺度输出

YOLOv3 网络是经过类似于特征金字塔特征融合后进行的三尺度输出,面对遥感图像上的飞机检测,这样的输出对较小的飞机目标检测效果不好,这是因为在特征融合时缺少部分分辨率信息,为解决此问题,本文在 YOLOv3 网络基础上增加一个含有分辨率特征的尺度,更好完成较小飞机的检测,最终形成四尺度输出预测。原 YOLOv3 网络在不同尺度的特征融合都是通过简单拼接或相加操作进行的特征融合,这种方式会融合一些不同层的特征,但是并没有充分利用多尺度的特征,对此,本文在四尺度输出预测前会增加一层自适应特征融合 (Adaptively Spatial Feature Fusion, ASFF) 层,使得不同尺度特征更好融合,本文提出的自适应特征融合及多尺度输出网络结构图如图 2 所示。




图 1 YOLOv3 网络框架

如图 2 所示,网络结构在 YOLOv3 网络的基础上增加了一个含有分辨率信息的尺度,并在每个尺度预测前增加了一层自适应特征融合层 ASFF 层,若设 x^1 、 x^2 、 x^3 、 x^4 分别为 Level1、Level2、Level3、Level4 这四层的特征,然后 Level1、Leve2、Leve3、Leve4 这四个层的特征分别乘以自适应权重参数 α 、

β 、 γ 、 λ 并求和,就能得到新的特征融合,即自适应特征融合,此过程可以用公式(1)表示如下:

$$y_{ij}^l = \alpha_{ij}^l \cdot x_{ij}^{1 \rightarrow l} + \beta_{ij}^l \cdot x_{ij}^{2 \rightarrow l} + \gamma_{ij}^l \cdot x_{ij}^{3 \rightarrow l} + \lambda_{ij}^l \cdot x_{ij}^{4 \rightarrow l} \quad (1)$$

式中, y_{ij}^l 表示在 y^l 通道输出特征图位于 (i, j) 处的特征向量; $x_{ij}^{n \rightarrow l}$ 表示从 Level n 的特征缩放到 Level l

的特征尺寸大小后在 (i, j) 处的特征向量, $a_{ij}^l, \beta_{ij}^l, \gamma_{ij}^l, \lambda_{ij}^l$ 是四个不同尺度的特征与其中某尺度特征融合时相对应的自适应权重参数, 自适应参数要满足 $a_{ij}^l + \beta_{ij}^l + \gamma_{ij}^l + \lambda_{ij}^l = 1$ 且 $a_{ij}^l, \beta_{ij}^l, \gamma_{ij}^l, \lambda_{ij}^l \in [0, 1]$.

下面证明自适应特征融合层的有效性, 如图 2 所示, 假设没有自适应特征融合层 ASFF 层时, 以 Level 1 层为例, 通过链式法则可以得到反向传导时的梯度计算公式如式(2) 所示.

$$\begin{aligned} \frac{\partial L}{\partial x_{ij}^1} &= \frac{\partial y_{ij}^1}{\partial x_{ij}^1} \cdot \frac{\partial L}{\partial y_{ij}^1} + \frac{\partial x_{ij}^{1 \rightarrow 2}}{\partial x_{ij}^1} \cdot \frac{\partial y_{ij}^2}{\partial x_{ij}^{1 \rightarrow 2}} \cdot \frac{\partial L}{\partial y_{ij}^2} + \\ &\frac{\partial x_{ij}^{1 \rightarrow 3}}{\partial x_{ij}^1} \cdot \frac{\partial y_{ij}^3}{\partial x_{ij}^{1 \rightarrow 3}} \cdot \frac{\partial L}{\partial y_{ij}^3} + \frac{\partial x_{ij}^{1 \rightarrow 4}}{\partial x_{ij}^1} \cdot \frac{\partial y_{ij}^4}{\partial x_{ij}^{1 \rightarrow 4}} \cdot \frac{\partial L}{\partial y_{ij}^4} \end{aligned} \quad (2)$$

式中, $\frac{\partial L}{\partial x_{ij}^1}$ 表示损失函数 L 对 Level 1 的特征图 (i, j) 像素处求导, 在图 2 中的网络结构中, 不同尺度的特征层之间的尺度变化通常是上采样和下采样, 而 $\frac{\partial x_{ij}^{1 \rightarrow l}}{\partial x_{ij}^1}$ 为采样倍数, 通常是固定值, 为简化公式(2), 设置 $\frac{\partial x_{ij}^{1 \rightarrow l}}{\partial x_{ij}^1}$ 项为 1, 则公式简化后如式(3) 所示.

$$\begin{aligned} \frac{\partial L}{\partial x_{ij}^1} &= \frac{\partial y_{ij}^1}{\partial x_{ij}^1} \cdot \frac{\partial L}{\partial y_{ij}^1} + \frac{\partial y_{ij}^2}{\partial x_{ij}^{1 \rightarrow 2}} \cdot \frac{\partial L}{\partial y_{ij}^2} + \frac{\partial y_{ij}^3}{\partial x_{ij}^{1 \rightarrow 3}} \cdot \frac{\partial L}{\partial y_{ij}^3} + \\ &\frac{\partial y_{ij}^4}{\partial x_{ij}^{1 \rightarrow 4}} \cdot \frac{\partial L}{\partial y_{ij}^4} \end{aligned} \quad (3)$$

式中, $\frac{\partial y_{ij}^l}{\partial x_{ij}^1}$ 项为输出特征通过激活函数的操作, 所以该项导数也是固定值, 同理, $\frac{\partial y_{ij}^l}{\partial x_{ij}^{1 \rightarrow l}}$ 项也是固定值, 为

了继续简化式(3), 将该项也设置为 1, 则简化后的表达式如式(4) 所示.

$$\frac{\partial L}{\partial x_{ij}^1} = \frac{\partial L}{\partial y_{ij}^1} + \frac{\partial L}{\partial y_{ij}^2} + \frac{\partial L}{\partial y_{ij}^3} + \frac{\partial L}{\partial y_{ij}^4} \quad (4)$$

如式(4), 假设 Level 1 的特征图 (i, j) 处对应的恰巧是有物体且为正样本的一个中心点, 那么 $\frac{\partial L}{\partial y_{ij}^1}$ 项就是来自正样本的梯度, 再假设其他 Level 2, Level 3, Level 4 的特征对应的 (i, j) 处恰巧为负样本, 那么 $\frac{\partial L}{\partial y_{ij}^2}, \frac{\partial L}{\partial y_{ij}^3}, \frac{\partial L}{\partial y_{ij}^4}$ 就是来自负样本的梯度, 则反向传导的梯度中就会既有正样本梯度又有负样本梯度, 这种不一致性会干扰 $\frac{\partial L}{\partial y_{ij}^1}$ 项的正样本梯度, 最终影响训练效率. 若存在自适应特征融合层 ASFF 层时, 反向传导的梯度表达式会变成公式(5).

$$\frac{\partial L}{\partial x_{ij}^1} = a_{ij}^1 \cdot \frac{\partial L}{\partial y_{ij}^1} + a_{ij}^2 \cdot \frac{\partial L}{\partial y_{ij}^2} + a_{ij}^3 \cdot \frac{\partial L}{\partial y_{ij}^3} + a_{ij}^4 \cdot \frac{\partial L}{\partial y_{ij}^4} \quad (5)$$

如式(5) 所示, 若同样出现式(4) 遇到的情况时, 因为有自适应权重参数的存在, 将自适应参数 a^2, a^3, a^4 都设置为 0, 就可以解决负样本梯度对正样本梯度的干扰. 因此, 四尺度输出预测前增加一层自适应特征融合层, 使得不同尺度特征更好融合是有效的.

3.2 目标边界框聚类改进




图 2 自适应特征融合及多尺度输出网络结构图

YOLOv3 网络通过 K-means 算法对数据集上人工标注好的目标框进行聚类分析, 产生需要使用

的锚框(anchor boxes)作为先验框对图像中目标进行检测。但是,K-means 算法在数据集上的初始聚类中心都是随机产生的,所以初始聚类中心对聚类结果有较大影响。K-means++算法的初始聚类中心之间的距离要尽可能远,相对于 K-means 随机产生的初始聚类中心来说,K-means++能产生更合适的初始聚类中心,得到比较好的结果,所以本文改用 K-means++算法对遥感图像数据集进行聚类来获得 anchor boxes。

K-means++算法对于两点间的距离度量计算常使用欧式距离、切比雪夫距离及曼哈顿距离等,直接使用这些距离计算公式,会使得目标大的边界框比小的边界框产生更多错误,而本文希望设置更好的 anchor boxes 来得到好的交并比(Intersection over Union, IOU),且 IOU 与样本的尺寸无关,因此为获得好的 IOU 本文采用新的距离计算公式进行计算,公式如(6)所示。

$$Distance(b, c) = 1 - IOU(b, c) \quad (6)$$

式中, b 为样本; c 为簇的中心; $IOU(b, c)$ 为簇中心框与聚类框的交并比。本文选取 $K=1, \dots, 20$, 通过 K-means++ 算法对遥感图像数据集进行聚类分析,得到锚点框个数与平均交并比的关系如图 3 所示,本文为了对小目标飞机能有好的检测能力,网络最终决定输出四种尺度,且经过平均交并比与锚点框个数分析,最终决定取 12 个锚点框,分别为(18, 20), (26, 28), (29, 36), (34, 37), (34, 43), (42, 45), (41, 50), (52, 54), (59, 63), (64, 80), (75, 78), (99, 106)。12 个锚点框会给 4 个尺度分别分配 3 个锚点框预测 3 个边界框。




图3 K-means++聚类结果图

3.3 损失函数

YOLOv3 网络模型采用的是一种多任务的损失函数进行优化目标的,本文采用同样的损失函数进行训练,总损失函数由定位边界框损失、IOU 损

失及类别损失组成,公式如下:

$$\begin{aligned} Loss &= L_{(x,y,w,h)} + L_{iou} + L_{class} \\ &= \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{obj} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \\ &\quad \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{obj} [(\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2] + \\ &\quad \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{obj} (C_i - \hat{C}_i)^2 + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B I_{ij}^{noobj} (C_i - \hat{C}_i)^2 + \\ &\quad \sum_{i=0}^{S^2} I_{ij}^{obj} \sum_{c \in classes} (P_i(c) - \hat{P}_i(c))^2 \end{aligned} \quad (7)$$

式中, S^2 表示网格数; B 表示锚框数; I_{ij}^{obj} 表示第 i 个网格的第 j 个锚框是否负责这个目标 object,若负责那么该参数为 1,否则为 0。为了保证总损失函数中每种类型损失函数贡献率相同,设定坐标损失权重 $\lambda_{coord} = 5$,计算 IOU 损失函数时,为了让 IOU 阈值的正负样本数量均衡,对不含目标格子的损失权重 $\lambda_{noobj} = 0.5$,减少不包含目标对包含目标格子的计算影响。

3.4 遥感图像飞机检测流程图

在训练阶段,先对需要训练的遥感图像做预处理工作,包括裁剪、数据增强等,然后对遥感图像上的飞机进行标注,获得图像上飞机的位置坐标和类别信息,进而训练模型,生成需要的遥感图像飞机检测模型。

在检测阶段,进行测试的遥感图像都会产生 N 个可能存在飞机的框图,使用训练阶段生成的遥感图像飞机检测模型对其进行真实坐标偏移和检测飞机得分计算,测试图像均能得到检测到的飞机检测结果,再通过非极大值抑制算法输出最终检测结果。遥感图像飞机检测整体流程如图 4 所示。

4 实验结果与分析

4.1 数据集

本文的数据集是从谷歌地球上收集的 1 000 张不同地区、不同场景的机场遥感图像,通过 Label-Img 标注软件对遥感图像上飞机目标进行标注。数据集中遥感图像分辨率均为 $1\,044 \times 915$ 像素,为训练方便,其中 900 张图像通过滑动窗口的方式将图像切成 416×416 像素的切片,将含有飞机目标的切片作为训练数据来进行网络训练。通过图像切片和数据增强后,训练数据共 4 957 张 416×416 大小飞机图像,测试图像为剩余的 100 张 $1\,044 \times 915$ 大小的飞机图像。




图 4 遥感图像飞机检测流程图

表 1 三种算法检测结果统计

模型	精度(%)	召回率(%)	F1 值(%)	速度(f/s)
YOLOv2	88.04	62.68	73.23	46.7
YOLOv3	93.57	78.37	85.30	32.1
本文	96.17	94.05	95.10	28.2

4.2 实验环境

本文算法使用 Tensorflow 深度学习框架,训练与测试所用平台为 Ubuntu18.04, Tesla K80 GPU 服

务器.在训练阶段,采用动量为 0.9 的随机梯度下降法,每个 batch 包含 16 张图像,初始学习率为0.001,权值衰减率为 0.0005,最大迭代次数为 12 万次.

4.3 实验评估标准

本文中,使用精度、召回率、F1 值对飞机目标检测模型进行性能评价,其评价公式如下.

精度:
$$P = \frac{TP}{TP + FP}$$
 (8)

召回率:
$$R = \frac{TP}{TP + FN}$$
 (9)

F1 值:
$$F1 = \frac{2P \cdot R}{P + R}$$
 (10)

式中, TP 为正确检测出的飞机数量; FP 为误检飞机数量; FN 为漏检的飞机数量.

4.4 与其他目标检测算法比较

为证明本文基于自适应特征融合及多尺度输出的遥感图像飞机检测算法的有效性,本文通过与经典的神经网络目标检测方法如 YOLOv2、YOLOv3 进行比较.使用 4.1 节中的训练集分别对这两种方法进行训练,然后使用 100 张遥感图像进行测试,共包含 724 架飞机.实验结果如表 1 所示.可以看到本文提出的算法测试集中得到准确率为 96.17%,召回率为 94.05%,比 YOLOv2 和 YOLOv3 算法都要优异,这是因为,本文提出的算法,使用了多尺度,并




图 5 自适应特征融合及多尺度输出网络结构图

在增加的尺度上含有了分辨率信息,有利于小目标的检测,同时增加了自适应特征融合层,使得不同尺度间的特征更好的融合。一般来说,精度低的召回率未必会低,二者之间没有绝对的影响关系,所以此时就需要 F_1 值对精度和召回率综合考量, F_1 值越高检测效果就越好,可以看到本文提出的算法 F_1 值同样表现最好,但本文算法在检测速度上相对于 YOLOv2 和 YOLOv3 算法要慢一些,但也达到了实时检测的水平。

4.5 实验检测结果图

为了更好的展示本文基于自适应特征融合及多尺度输出的遥感图像飞机检测算法对遥感图像飞机检测的性能,本文在不同遥感图像场景进行测试,测试结果如图 5 所示(从左到右分别是本文方法, YOLOv3, YOLOv2 的检测结果)。经过测试得到的结果可以发现,本文方法在三种算法中能得到最好的检测性能,实验结果证明本文提出的算法具有一定的有效性。

5 结束语

针对 YOLOv3 算法对遥感图像上的飞机漏检、误检等问题,本文基于 YOLOv3 基本网络框架,使用 K-means++ 算法代替 K-means 算法对数据集进行了聚类分析,对网络多尺度输出进行了改进,并在网络输出预测前增加了自适应特征融合层,提出了基于自适应特征融合及多尺度输出的遥感图像飞机检测算法。经实验表明,本文算法效果提升显著,解决了 YOLOv3 对遥感图像的飞机漏检、误检、不同尺度特征融合不充分等问题。

参考文献:

[1] 王广学,黄晓涛,周智敏. 基于邻域统计分布变化分析的 UWB SAR 隐蔽目标变化检测[J]. 电子与信息学报, 2011, 33(1): 49-54. DOI: 10. 3724/SP. J. 1146. 2010. 00202.

WANG G X, HUANG X T, ZHOU Z M. UWBSAR change detection of target in foliage based on local statistical distribution change analysis[J]. Journal of Electronics & Information Technology, 2011, 33(1): 49-54. DOI: 10. 3724/SP. J. 1146. 2010. 00202.

[2] 曹家梓,宋爱国. 基于马尔科夫随机场的纹理图像分割方法研究[J]. 仪器仪表学报, 2015, 36(4): 776-786. DOI:10. 19650/j. cnki. cjsi. 2015. 04. 008.

CAO J Z, SONG A G. Research on the texture image segmentation method based on Markov random field

[J]. Chinese Journal of Scientific Instrument, 2015, 36(4): 776-786. DOI: 10. 19650/j. cnki. cjsi. 2015. 04. 008.

[3] CHENG G, ZHOU P C, HAN J W. Learning rotation-invariant convolutional neural networks for object detection in VHR optical remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(12): 7405-7415. DOI: 10. 1109/TGRS. 2016. 2601622.

[4] 王思雨,高鑫,孙皓,等. 基于卷积神经网络的高分辨率 SAR 图像飞机目标检测方法[J]. 雷达学报, 2017, 6(2): 195-203. DOI: 10. 12000/JR17009.

WANG S Y, GAO X, SUN H, et al. An aircraft detection method based on convolutional neural networks in high-resolution SAR images[J]. Journal of Radars, 2017, 6(2): 195-203. DOI: 10. 12000/JR17009.

[5] YANG X, SUN H, FU K, et al. Automatic ship detection in remote sensing images from Google earth of complex scenes based on multiscale rotation dense feature pyramid networks[J]. Remote Sensing, 2018, 10(1): 132. DOI: 10. 3390/rs10010132.

[6] CHEN Z, ZHANG T, OUYANG C. End-to-end airplane detection using transfer learning in remote sensing images[J]. Remote Sensing, 2018, 10(1): 139. DOI: 10. 3390/rs10010139.

[7] 王金传,谭喜成,王召海,等. 基于 Faster R-CNN 深度网络的遥感影像目标识别方法研究[J]. 地球信息科学学报, 2018, 20(10): 1500-1508. DOI: 10. 12082/dqxxkx. 2018. 180237.

WANG J C, TAN X C, WANG Z H, et al. Faster R-CNN deep learning network based object recognition of remote sensing image[J]. Journal of Geo-Information Science, 2018, 20(10): 1500-1508. DOI: 10. 12082/dqxxkx. 2018. 180237.

[8] REDMON J, FARHADI A. YOLOv3: An Incremental Improvement[EB/OL]. Computer Vision and Pattern Recognition. (2018-04-08) [2020-05-19]. <https://arxiv.org/abs/1804.02767>.

[9] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 6517-6525. DOI: 10. 1109/CVPR. 2017. 690.

[10] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778. DOI: 10. 1109/CVPR. 2016. 90.

作者简介:

胡悦女,(1996-),硕士研究生.研究方向为云计算安全.
E-mail:hy_2750637032@163.com.

林果园男,(1975-),博士,副教授.研究方向为云计算,信息安全.
蔚国莹女,(1995-),硕士研究生.研究方向为信息安全.

(上接第 45 页)

作者简介:

李众男,(1974-),博士,副教授.研究方向为机器学习、软件工程等.
白瑞君(通讯作者)男,(1992-),硕士.研究方向为深度学习、计算机视觉. E-mail:1066193265@qq.com.

洪军男,(1979-),博士,讲师.研究方向为云计算安全等.
李亚伦男,(1994-),硕士.研究方向为深度学习.
王高男,(1973-),博士,教授.研究方向为图像处理等.
杨剑男,(1979-),博士,讲师.研究方向为计算机视觉及人工智能等.