

doi: 10.7690/bgzdh.2019.07.004

目标检测网络在无人机视觉定位的应用

丁鹏程, 于进勇, 王超, 柳向阳
(海军航空大学, 山东 烟台 264001)

摘要: 针对当前无人机视觉定位准确性和稳定性的难题, 对目标检测网络在无人机视觉定位的应用进行分析。依据无人机视觉定位的特点和目标检测网络的优势, 以特征分层提取作为主体设计思路, 通过修改 SSD 网络结构, 设计损失函数、更改候选框筛选规则、合并归一化网络, 提出一种将改进 SSD 网络引入无人机视觉定位的算法, 得到无人机的位置信息, 并验证了算法的可行性。实验结果表明: 该网络能满足无人机视觉定位的要求, 有一定的理论及实用参考价值。

关键词: 目标检测; 深度学习; 视觉定位
中图分类号: TP751 **文献标志码:** A

Application of Object Detection Network in UAV Vision Location

Ding Pengcheng, Yu Jinyong, Wang Chao, Liu Xiangyang
(Navy Aviation University, Yantai 264001, China)

Abstract: Aiming at the difficulty of accuracy and stability of UAV vision positioning, the application of object detection network in UAV vision positioning is analyzed. According to the characteristics of UAV vision positioning and the advantages of object detection network, taking feature layer extraction as main design idea, an algorithm is proposed to introduce improved SSD network into UAV vision positioning by modifying the structure of SSD network, designing loss function, changing candidate box selection rules and merging normalized network. The location information of UAV is verified and the feasibility of the algorithm is verified. Experimental results show that the network can meet the requirements of UAV vision positioning, and has certain theoretical and practical reference value.

Keywords: object detection; deep learning; vision location

0 引言

传统的无人机视觉定位需要对获取的图像进行预处理、特征提取^[1-2]、状态估计^[3]、数据融合^[4]等, 对算法的准确性和实时性提出了大量的要求^[5]。由于人工提取信息特征的局限性对设计者经验要求高, 又严重受环境光影等影响, 特别是对拍摄图片中困难小样本和背景相似目标识别效果差, 导致后续无人机视觉定位的准确性和稳定性较差。近年来, 在已有的特征自学习与卷积神经网络^[6-7]结合的基础上, 将图像进行多尺度分解^[8], 并利用池化算法^[9]进行降维, 可以实现高精度的图像目标检测效果, 有效克服了环境光影等对图像检测的影响, 对小目标或遮挡变形目标的检测效果也远超传统图像处理算法。

笔者将深度学习的目标检测网络引入无人机视觉定位, 代替无人机视觉定位中图像处理模块。在保证图像处理速度的基础上, 通过改进网络, 将重点放在困难样本信息挖掘与相似背景检测。相比于

基于候选框的检测网络^[10-12], 基于端对端回归方法的目标检测网络(single shot multiBox detector, SSD)^[13]可以极大地缩短时间, 更加适应无人机实时性的要求, 在网络精度上有一定的提升。为了更好地解决 SSD 在小目标以及相似背景下检测精度不理想的问题, 笔者以加入反卷积和预测模块的 SSD 网络^[14]为结构基础, 通过设计损失函数^[15], 更改候选框筛选规则, 合并归一化网络等方法, 提出了改进 SSD 网络, 使其更好适应无人机视觉定位要求。笔者选定飞行实验区域, 制作自己的数据集——无人机视觉导航定位数据集(UAV vision navigation location dataset, UVNLD), 通过投影关系进行坐标转换, 得到无人机的位置信息, 提出了一整套无人机视觉定位算法, 并验证了算法的可行性。

1 SSD 原理及网络结构

1.1 SSD 基本原理

SSD 网络以特征分层提取作为主体设计思路, 进行回归和分类。低层次特征图语义分割质量高,

收稿日期: 2019-03-06; 修回日期: 2019-04-12

作者简介: 丁鹏程(1994—), 男, 山东人, 硕士, 从事目标检测、飞行器控制与制导研究。E-mail: 632875352@qq.com。

可以包含更多特征的细节, 适合学习小尺度目标; 高尺度特征语义分割更加光滑, 适合学习大尺度目标。结构上, SSD 在单一回归网络的基础上, 针对全图各位置, 使用多尺度区域特征进行目标回归, 既保证了端对端网络快速的特点, 又保留 Faster R-CNN^[12]对小目标精确的特性, 在 VOC2007 达到 72.1% mAP (mean average precision), 获得当年目标检测比赛的冠军。

1.2 SSD 结构改进

通过增加上下文信息来提高准确率是目标检测的常见方法之一。不同于传统 SSD 网络的 VGG16^[16]的卷积层扩展, 改进 SSD 选用 ResNet101^[17]作为卷积子网络结构, 保证深层特征图中特征提取的充分性。参考 FPN^[18]网络的思路, 利用反卷积网络模块扩充网络的上下文信息, 将图像深层特征传递下来并与浅层信息融合, 联系不同层级之间语义关系, 设计了预测模型, 多次反复形成多尺度检测框架。

反卷积模块是指高层特征和低层特征的融合模块。用于精细网络的反卷积模块在保证分解结构效率的同时, 可以达到和复杂网络一样的精度^[19]。首先, 在采样过程中, 采用基于学习的反卷积层代替简单的双线性插值。之后, 每个卷积层特别是低层特征后紧随一个归一化层^[20]。最后, 在通道融合过程中, 相乘计算可以比相加计算得到更高的准确率。在改进 SSD 网络中, 高层特征图的通道数将会被舍弃, 所有的卷积和反卷积操作中, 卷积个数都依赖于输入低特征图的通道数。

根据 MS-CNN^[21]网络中提升每个子任务的表现可以提高准确率的思路。如图 1 所示, 在反卷积模块之后, 候选框回归任务和分类任务之前加入预测模块网络结构。预测模型含有一个残差单元, 将残差旁路卷积处理后的原特征图与网络主干道特征图相加, 得到图片的检测精度比原始网络有了明显提升。

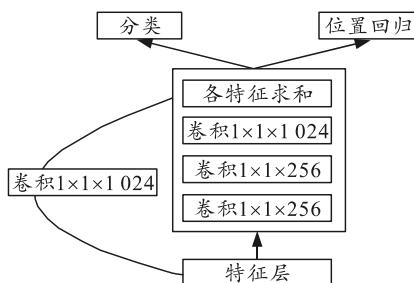


图 1 预测模块网络结构

加入反卷积模块和预测模块之后, 改进 SSD 网

络可以将深层的特征信息和低层信息融合, 在小目标和密集目标, 以及背景目标具有显著区分度的图片特征提取上都有了极大地提高, 也更加适合无人机拍摄图像中的目标检测。

2 改进 SSD 算法

通过上述结构改进, 一定程度上可以解决小目标和背景相似目标的特征提取, 但是对于困难样本的检测效果不足, 并不完全适合无人机视觉定位要求; 因此, 笔者针对具体问题, 在上述结构的基础上, 提出了改进 SSD 算法:

1) 为了进一步提高网络的识别精度, 在 SSD 网络的基础上设计损失函数, 通过降低对简单样本学习过程中的权重, 变相提高网络对困难样本学习重视度, 进而提高小目标困难样本的识别精度。

2) 修改候选框筛选规则, 将非极大值抑制操作更改为最大值操作, 更加适合本任务对无人机定位的需求, 提高了定位精度, 对网络的检测速度也有一定的帮助。

3) 为了抵消网络层数复杂引起的网络速度下降, 保证无人机定位导航实时性的要求, 通过将归一化层与卷积层合并, 可以缩短网络推理时间, 简化和加速测试过程。

2.1 设计损失函数

深度学习在目标检测中主要分化出基于候选区域和基于端对端这 2 个分支。前者注重准确率, 后者是在适当降低准确率的情况下获得速度的最大收益。针对 SSD 等端对端网络检测精度不如基于候选区域网络, He 等^[15]认为, 极度不平衡的正负样本比例以及占主导地位的简单样本, 是影响端对端目标检测效果的一个主要原因。笔者主要考虑 2 类简单负样本:

1) 不同于基于候选区域的检测网络, 端对端网络在图像检测过程中, 大量候选区域中只有很少位置含有目标, 导致大部分区域都是简单的负样本, 训练效率低。

2) 在所有的训练样本中, 不同类别的样本在总样本的数量各不相同, 某一类样本中数量占优时, 会使网络将更多的精力专注于此样本, 导致网络学习的模型泛化性降低。

上述 2 种简单样本的每一个损失值都比较小, 但是巨大的数量会主导最终的损失值, 影响网络对困难样本的识别精度。与以往通过困难样本挖掘或

者设计更复杂的抽样和加权方案不同，笔者通过降低简单样本权重，变相提高网络对困难样本学习重视度，进而提高小目标困难样本的识别精度。

2.1.1 调制系数设计

传统的交叉熵损失函数为：

$$CE(p, y) = \begin{cases} -\log(p) & \text{if } y=1 \\ -\log(1-p) & \text{otherwise} \end{cases} \quad (1)$$

其中： CE 为交叉熵； p 为预测样本属于 1 的概率； y 是真实标签值， $y \in \{\pm 1\}$ ，这里以二分类为例，多分类以此类推。为了简单表示，定义 p_t ：

$$p_t = \begin{cases} p & \text{if } y=1 \\ 1-p & \text{otherwise} \end{cases} \quad (2)$$

可以缩写为：

$$CE(p, y) = CE(p_t) = -\log(p_t) \quad (3)$$

如图 2 所示，根据交叉熵损失画出曲线。当 $\gamma=0$ 时，就是传统的交叉熵损失。观察最上面线条可以看到，对于预测概率大于 0.6 的样本，它们的损失值仍然不小，大量的损失值会对总体网络产生巨大影响。

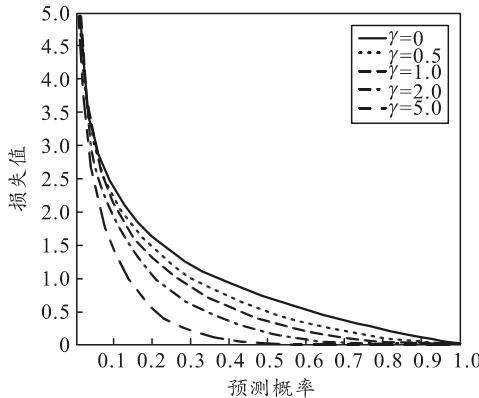


图 2 不同交叉熵损失曲线

在此基础上，从二元分类的交叉熵损失出发，引入调制系数 $(1-p_t)^\gamma$ ：

$$FL(p_t) = -(1-p_t)^\gamma \log(p_t) \quad (4)$$

其中 $\gamma \geq 0$ 。

由 p 的定义知， $(1-p_t) \in (0,1)$ 。当网络学习简单易分类样本时， $(1-p_t)$ 很小，加入调制系数 $(1-p_t)^\gamma$ 后，数值进一步减小，引起总损失值下降。随着 γ 的增加，调制系数增加，预测正确的简单样本的损失值下降变快，对总体损失值的影响变小，从而变相提高困难样本在损失函数中的权重，使模

型在训练过程中更加注重困难分类样本。

2.1.2 权重因子设计

针对第二类简单负样本，笔者在传统交叉熵函数的基础上引入权重因子 α ：

$$CE(p_t) = -\alpha \log(p_t) \quad (5)$$

其中 $\alpha \in [0,1]$ ，是根据各类样本数所占总样本数的倒数来设置。

但是，通过上述方法选取的权重因子往往因为过小，使得网络整体损失值偏低，影响网络收敛速率，所以进一步修改交叉熵函数为

$$CE(p_t) = -\alpha_t \log(p_t) \quad (6)$$

其中 $\alpha_t = \alpha t$ ， t 为倍数因子，通过实验得到。

综上所述，设交叉熵损失函数为

$$FL(p_t) = -\alpha_t (1-p_t)^\gamma \log(p_t) \quad (7)$$

在实际网络中，将新的损失函数与 Sigmoid 激活函数 $p = \sigma(x)$ 结合，可以得到最终损失函数：

$$L = \begin{cases} -\sigma^\gamma(-x) \log \sigma(x) & \text{if } y=1 \\ -\sigma^\gamma(x) \log \sigma(-x) & \text{otherwise} \end{cases} \quad (8)$$

其中 $1-\sigma(x) = \sigma(-x)$ 。

2.2 更改候选框筛选规则

训练过程中，改进 SSD 会实时计算每一个候选框的置信度，计算公式为

$$\Pr(O_{\text{object}}) \cdot R_{\text{pred}}^{\text{truth}} \quad (9)$$

其中： $\Pr(O_{\text{object}})$ 为改进 SSD 中是否存在目标； $R_{\text{pred}}^{\text{truth}}$ 为预测候选框与真实目标之间的重叠率。当目标出现在改进 SSD 候选框内， $\Pr(O_{\text{object}})$ 为 1，否则为 0。

将预测类别信息与改进 SSD 网络候选框置信度相乘，可以计算出每一个网络候选框的得分：

$$\Pr(C_i | O_{\text{object}}) \cdot \Pr(O_{\text{object}}) \cdot R_{\text{pred}}^{\text{truth}} = \Pr(C_i) \cdot R_{\text{pred}}^{\text{truth}} \quad (10)$$

式中 $\Pr(C_i | O_{\text{object}})$ 为预测类别概率得分。

根据上述公式求得每个候选框得分后，调整阈值让网络自行去除得分低的候选框，对得分高的候选框进行 NMS 处理^[22]，得到极大值检测结果。但是，根据无人机定位的实际任务要求，一个目标区域在一张航拍图像中最多只会出现一次。因此，调整 NMS 操作为最大值操作，让网络自行在检测过程中选取得分最大值，唯一确定候选框的位置及其预测类别^[23]，计算公式为

$$(i, p_{\text{pred}}) = \max_{i, p_{\text{pred}}} [\Pr(C_i) \cdot R_{\text{pred}}^{\text{truth}}], \Pr(C_i) \cdot R_{\text{pred}}^{\text{truth}} \geq T_{\text{threshold}}. \quad (11)$$

其中: p_{pred} 为网络预测的目标位置; i 为对应的预测类别; $T_{\text{threshold}}$ 为筛选阈值。

经过最大值操作的改进 SSD 网络, 可以有效避免网络对目标相似区域的误检, 更加适应无人机视觉定位中目标检测任务, 提高网络检测精度。

2.3 合并归一化网络

深度的 ResNet101 卷积网络可以充分提取图像特征, 通过预测模块和反卷积模块的加入进一步深化网络层数, 显著地提升对目标的检测效果; 但是, 网络的加深也会带来速度的下降。

为了保证无人机定位导航的实时性, 抵消网络层数复杂带来的检测延时影响, 将测试网络的批量归一化层与卷积网络合并, 缩短网络推理时间, 公式为

$$y = \text{scale} \left(\frac{(wx + b) - \mu}{\sqrt{\text{var} + \varepsilon}} \right) + \text{shift}. \quad (12)$$

其中 scale, shift 通过网络学习训练得到。

进一步简化和加速测试过程, 修改卷积层的权重和偏差公式为:

$$\hat{w} = \text{scale} \left(\frac{w}{\sqrt{\text{var} + \varepsilon}} \right); \quad (13)$$

$$\hat{b} = \text{scale} \left(\frac{b - \mu}{\sqrt{\text{var} + \varepsilon}} \right) + \text{shift}. \quad (14)$$

得到归一化网络合并后的卷积层计算公式为

$$y = \hat{w}x + \hat{b}. \quad (15)$$

3 无人机视觉定位

3.1 投影原理

无人机对获取的图像检测目标, 根据目标实际位置和图像中的位置, 经过投影关系和坐标转换获得无人机的位置信息。根据像素坐标系 (u, v) , 图像坐标系 (x, y) , 相机坐标系 (x_c, y_c, z_c) , 可得经典无人机投影变换方程为:

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} f_u & 0 & u_0 & 0 \\ 0 & f_v & v_0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \begin{bmatrix} \mathbf{R} & \mathbf{t} \\ 0^T & 1 \end{bmatrix} \begin{pmatrix} x_w \\ y_w \\ z_w \\ 1 \end{pmatrix}. \quad (16)$$

其中: (u_0, v_0) 是图像坐标系原点在像素坐标系中的坐标; f 为焦距, $f_u = f / dx$, $f_v = f / dy$ 。3 维正

交旋转矩阵 \mathbf{R} 和平移变换向量 \mathbf{t} 为世界坐标系中的点到相机坐标系的变换矩阵。

现实中, 摄像机镜头存在严重的畸变, 尤在远离图像中心处, 像差比较明显。为了提高计算精度, 需要考虑无人机镜头畸变。笔者根据张正友标定算法^[24], 运用莱文贝格-马夸特方法^[25]解决多参数非线性系统优化问题, 从而确定相机参数和畸变系数, 实现畸变矫正、图像校正和最终 3 维信息恢复。

3.2 无人机视觉定位算法

笔者通过将改进 SSD 网络的目标检测融入到视觉投影, 代替传统图像处理模块, 可以得到无人机的位置信息。算法流程如图 3。

- 1) 无人机在高空飞行时, 对地面图像进行采集。
- 2) 将当前拍摄图像经过张正友标定算法进行图像校正和 3 维信息恢复。
- 3) 将校正后的图像尺度修改为 513×513 大小, 并输入改进 SSD 网络。
- 4) 改进 SSD 网络将检测到的目标分类, 并以方框框出的形式标注出目标在图像中的位置, 同时得到方框 4 个顶点像素坐标。
- 5) 根据 4 个顶点的像素坐标, 得到目标中心在图像中的坐标。
- 6) 利用投影转换和已知目标的位置信息, 可以得到无人机自身位置信息。

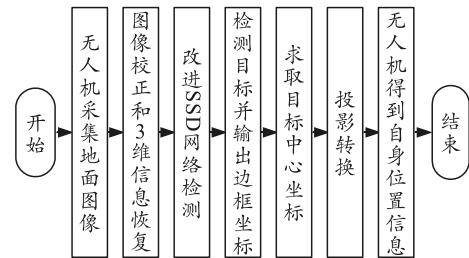


图 3 无人机视觉定位算法流程

4 对比仿真实验

4.1 实验数据

以烟台市芝罘区为中心的海边区域作为研究对象, 采用无人机进行数据采集。

无人机配置: 云台三角度控制, 俯仰角可控范围 $-90^\circ \sim +30^\circ$, 相机 1 240 万像素, ISO 范围为 100~3 200 (视频) 和 100~1 600 (照片), 照片分辨率 $4 000 \times 3 000$, 悬停垂直精度 $+/-0.1$ m, $+/-0.5$ m, 水平 1.5 mm, 上升速度 5 m/s, 下降速度 3 m/s, 飞行速度 16 m/s。

为了提高模型的适应性和鲁棒性, 笔者采集了

10 类特征比较明显的目标在不同观测角度和飞行高度下的图像，控制图像分辨率为 513×513 。通过旋转、调整亮度、加入噪声等方法扩大样本^[26]，模仿 Pascal voc2007 数据集的构造过程，得到自己的数据集 UVNLD。UVNLD 数据集包括 10 类目标，每类 2 000 幅。其中训练样本每类 1 000 幅，测试样本每类 1 000 幅，共计 20 000 幅。

4.2 实验配置与网络训练

在 64 位的 ubuntu14.04 系统，安装了 CUDA 8.0, cuDNN 5.0 和 python 2.7 的环境下，笔者选用 caffe 框架训练本文网络模型。CPU 为 8 个 Intel(R) Core(TM) i7-6770K @ 4.00 GHz $\times 8$, GPU 为 NVIDIA GTX1080。

为了充分提高网络模型的参数利用率，采用三段式网络训练方法。

1) 训练将基础网络改成 ResNet101 的 SSD 模型，以学习率为 0.001 迭代 2×10^4 次，再以学习率为 0.000 1 和 0.000 01 分别训练 2×10^4 次和 10^4 次，得到训练好的 SSD 网络。

2) 固定 SSD 参数，初始化改进 SSD 网络，以学习率为 0.001 和 0.000 1 分别迭代 2×10^4 和 10^4 次只训练反卷积模型。

3) 取消固定 SSD 参数，以学习率 0.001 和 0.001 分别迭代 2×10^4 次训练全部网络。

网络训练损失值与迭代次数如图 4 所示。数据集通过不同高度不同角度采集，使得目标在图像中的大小位置差距明显，特别是包含大量小目标等困难样本，导致一开始网络损失值较大。结果表明：通过在不同阶段采用不同的学习率，网络学习成果显著，各参数变化基本稳定，最终损失值下降到 0.3，结果比较理想。

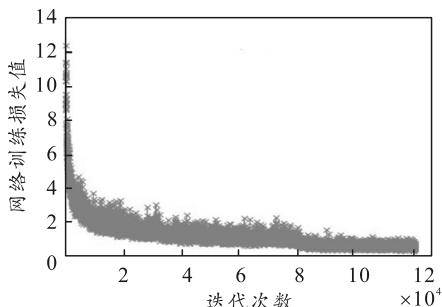


图 4 网络训练损失值与迭代关系

4.3 仿真对比

4.3.1 调制系数与权重因子

由图 2 可知：网络调制系数越大，负样本的损

失函数越小，大量候选区域的简单负样本对网络总的损失值影响越小。实验中发现，当调制系数不断增大时，会影响网络的收敛速率，也会对网络的精度带来一定的影响。

在网络的训练和测试过程中，权重因子的选择也与调制系数的大小密切相关。为了更符合无人机导航的 UVNLD 数据集的要求，笔者通过实验选取调制系数和权重因子。在训练网络时，将设计的损失函数应用到所有候选区域里进行实验，结果见表 1。这里，检测任务的评价指标是 AP(average precision)，定义如下：

$$AP = \int_0^1 P(R) dR. \quad (17)$$

其中： R 为召回率； P 为精度。

通过实验结果得知，图像总的损失函数是所有候选区域的焦点损失之和。之后根据候选区域的数量归一化到真实边界框中。因为样本中大部分候选区域都是简单的负样本，带入新的损失函数之后可以忽略不计；所以候选区域的数量是根据实验指定的一个数，而不是网络的全部候选区域数量之和。

如表 1 所示，当 $\gamma=0$ 时，损失函数就是传统的交叉熵损失函数，因为大量负样本的存在，网络精度较低。随着 γ 的增大，简单样本损失值占总损失值的比重不断减小。这样会导致 2 种简单负样本损失函数的失衡，同时需要缩小 α_i 的值。通过不断权衡可以看到， $\gamma=2$ ， $\alpha_i=0.25$ ，平均精确度最高，达到了 87.7%，比传统交叉熵损失函数提高了 3.5%，效果显著。

表 1 调制系数与权重因子对网络的影响

γ	α_i	mAP
0	0.75	84.2
0.5	0.75	85.4
1.0	0.50	86.9
2.0	0.50	87.3
2.0	0.25	87.7
5.0	0.25	86.1

4.3.2 合并归一化网络

为了验证合并归一化网络对网络速度的影响，笔者分别测试了传统 SSD 网络、更改 ResNet101 作为卷积子网络的 SSD 网络、以及是否进行了归一化网络合并的改进 SSD 网络。这里评判标准 fps 是指网络检测可以达到的每秒帧数。

如表 2，加深网络层数，对网络精度有很大的提高，但也会导致网络检测速度的大幅下降。仅仅是将卷积子网络从 VGG16 改为 ResNet101，网络速

度就下降明显。在网络设计过程中, 虽然加入了反卷积模块和预测模块, 并通过修改候选框筛选规则, 采用最大值操作, 一定程度上可以抵消网络复杂带来的影响, 但是达不到无人机视觉定位的实时性要求。

表 2 网络速度比较

网络	卷积子网络	合并归一化网络	fps
SSD	VGG16	否	19
SSD	ResNet101	否	8
改进 SSD	ResNet101	否	9
改进 SSD	ResNet101	是	32

合并归一化网络, 将批量归一化层与卷积层合并后, 检测速度得到了明显提升, 达到了 32 帧/s。这是因为归一化网络合并后, 网络的复杂度大幅降低, 网络推理和测试速度提高, 可以使网络计算速度提高 1.2~1.5 倍。此外, 在实验中发现, 通过合并归一化网络, 网络内存占用减少了 30%, 降低了网络对硬件的要求。

除了合并归一化网络, 适当降低图像的分辨率, 在训练过程中引入多尺度训练等方法, 可以进一步提升改进 SSD 网络的检测速度。

4.3.3 几种网络性能对比

表 3 是为验证文中网络的有效性进行的几组实验的检测结果。其中: S 表示修改了网络结构的 SSD 网络; L 表示加入笔者设计的损失函数模块的网络, 改进 SSD 网络则是提出的目标检测网络。

分别训练和测试 4 种网络, 得到 UVNLND 数据库的测试结果。修改网络结构的 SSD 网络, 因为引入了上下文信息, 网络对小目标和密集目标的检测准确率有了提高, mAP 提高了 2%。引入新的损失函数后, 通过修改对样本的学习权重, 网络对困难样本和相似背景的小目标识别有了较大提升, mAP 提高了 3.5%, 改善显著。引入上述 2 种改进, 改进的 SSD 网络通过修改了候选框筛选规则, 还可以有效避免重检和背景相似区域对网络的误差影响, 各类目标的检测识别率基本在 85% 以上, 提高了网络的抗干扰能力。部分检测结果如图 5 所示, 根据像素坐标系的习惯, 设左上为原点(0,0), 右下为(500,500), 横纵坐标轴单位为像素(pt)。所得边界框 $[x_{\min}, y_{\min}, x_{\max}, y_{\max}]$ 与设定边界框平均误差为 2, mAP 提高了 6.3%。

表 3 几种网络精度

网络	mAP	1	2	3	4	5	6	7	8	9	10
SSD 513	81.4	85.9	87.3	80.4	78.5	73.1	84.4	81.0	86.1	75.4	81.7
SSD 513+S	83.4	83.4	87.9	83.7	81.6	74.0	85.1	84.0	89.2	75.4	84.4
SSD 513+L	84.9	87.9	89.3	84.1	80.5	77.6	86.8	85.2	89.9	81.0	86.6
改进 SSD	87.7	90.1	92.4	87.0	85.7	80.2	88.7	87.6	92.0	84.3	88.9

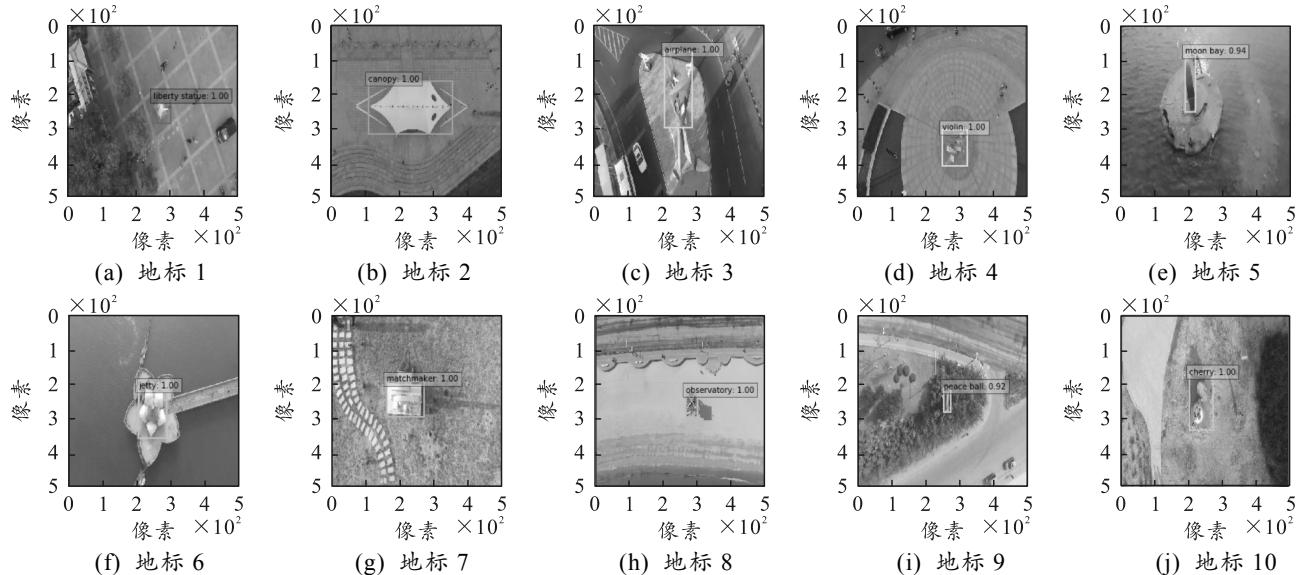


图 5 部分检测结果

4.4 无人机飞行实验

为了检验目标检测网络应用于无人机视觉定位的效果, 笔者在 UVNLND 数据集上又增加了验证集图片, 在保证无人机特定高度下, 收集相机拍摄角

度分别为 45°、60°、90° 的图片若干张, 同时记录无人机的当前实际位置信息。根据上述步骤, 将验证集图片导入, 对比网络求取的无人机位置信息与预先记录的无人机实际位置信息, 得到表 4。

表 4 不同角度下无人机定位精度

高低角/(°)	图像数量	正确区域检测率/%	无人机定位误差/m
45	350	89.2	±0.29
60	350	93.8	±0.27
90	400	95.6	±0.23

表中结果表明：通过引入目标检测网络代替传统的图像处理模块，进行无人机视觉定位，基本可以实现无人机定位误差在 0.3 m 以内，满足无人机视觉定位的需求。特别是当无人机相机垂直角度采集数据时，网络正确检测的区域准确率达到了 95.6%，定位误差缩小到 0.23 m，可满足无人机视觉定位的要求。

无人机在相机不同高低角对正确区域检测率和无人机定位误差的影响，主要体现在相机非垂直拍摄时，目标在图像会有一定的投影误差。高低角越低，投影误差越明显，目标检测框误差也会越大，进而影响无人机的定位误差。适当提高无人机拍摄高度，可以一定程度上减小投影误差的影响，从而提高无人机定位精度。

5 结束语

笔者提出的改进 SSD 网络，既可以提高网络对于小目标的检测，又可以大幅提高对困难样本的检测，对网络的总体检测准确率有了较大的提升。经过数据采集并自建数据库学习，改进 SSD 网络对图像的目标检测精度稳定在 87.7%。笔者将此网络引入无人机视觉定位，代替传统图像处理模块。在考虑相机畸变的情况下，设计了一整套无人机视觉定位算法。试飞实验结果表明：无人机视觉定位误差稳定在 0.3 m 以内的检测率达到 89% 以上，满足了无人机视觉定位的要求。

参考文献：

- [1] HARRIS C J. A combined corner and edge detector[J]. Proc Alvey Vision Conf, 1988, 1988(3): 147–151.
- [2] SMITH S M, BRADY J M. SUSAN-A New Approach to Low Level Image Processing[J]. International Journal of Computer Vision, 1997, 23(1): 45–78.
- [3] TANG D, ZHANG H. Vision Based Navigation Algorithm for Autonomic Landing of UAV without Heading & Attitude Sensors[C]. Third International IEEE Conference on Signal-Image Technologies and Internet-Based System. IEEE Computer Society, 2007: 972–978.
- [4] LUDINGTON B, JOHNSON E, VACHTSEVANOS G. Augmenting UAV autonomy[J]. IEEE Robotics & Amp Automation Magazine, 2006, 13(3): 63–71.
- [5] 吴显亮, 石宗英, 钟宜生. 无人机视觉导航研究综述 [J]. 系统仿真学报, 2010, 22(s1): 62–65.
- [6] SERMANET P, CHINTALA S, LECUN Y. Convolutional neural networks applied to house numbers digit classification[C]//International Conference on Pattern Recognition. IEEE, 2013: 3288–3291.
- [7] HUBEL D H, WIESEL T N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex[J]. Journal of Physiology, 1962, 160(1): 106–154.
- [8] ALVAREZ J M, LECUN Y, GEVERS T, et al. Semantic Road Segmentation via Multi-scale Ensembles of Learned Features[C]//International Conference on Computer Vision. Springer-Verlag, 2012: 586–595.
- [9] BOUREAU Y L, PONCE J, LECUN Y. A Theoretical Analysis of Feature Pooling in Visual Recognition[C]. International Conference on Machine Learning. DBLP, 2010: 111–118.
- [10] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2014: 580–587.
- [11] GIRSHICK R. Fast R-CNN[C]//IEEE International Conference on Computer Vision. IEEE, 2015: 1440–1448.
- [12] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. IEEE Trans Pattern Anal Mach Intell, 2015, 39(6): 1137–1149.
- [13] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single Shot MultiBox Detector[C]//European Conference on Computer Vision. Springer, Cham, 2016: 21–37.
- [14] FU C, LIU W, RANGA A, et al. DSSD : Deconvolutional Single Shot Detector[C]//Computer Vision and Pattern Recognition, 2017: 771–782.
- [15] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, PP(99): 2999–3007.
- [16] YAN Z, ZHANG H, PIRAMUTHU R, et al. HD-CNN: Hierarchical Deep Convolutional Neural Networks for Large Scale Visual Recognition[C]//IEEE International Conference on Computer Vision. IEEE, 2016: 2740–2748.
- [17] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2016: 770–778.
- [18] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature Pyramid Networks for Object Detection[C]//IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 936–944.
- [19] PINHEIRO P O, LIN T Y, COLLOBERT R, et al. Learning to Refine Object Segments[C]//European Conference on Computer Vision. Springer, Cham, 2016: 75–91.

- [9] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks[C]. In: Advances in Neural Information Processing Systems. 2007, 19: 153.
- [10] 包演, 刘磊, 荆涛. 复杂电磁环境下的作战、训练、保障与军事运筹研究: 基于 FVA 的海军武器装备体系关键技术决策分析方法[C]. 北京: 蓝天出版社, 2007.
- [11] 刘磊, 荆涛, 朱一凡. 基于 SBCP 的武器装备体系演化分析方法[J]. 系统仿真学报, 2009, 21(21): 6734–6739.

(上接第 13 页)

$$\begin{aligned}\Delta \bar{d}_1 &= \frac{1}{3}(\Delta d_1 + \Delta d_2 + \Delta d_3) \\ \Delta \bar{\beta}_1 &= \frac{1}{3}(\Delta \beta_1 + \Delta \beta_2 + \Delta \beta_3)\end{aligned}\quad (8)$$

使校射后的弹着点 c 与目标点 a 的偏差量满足效力射要求。

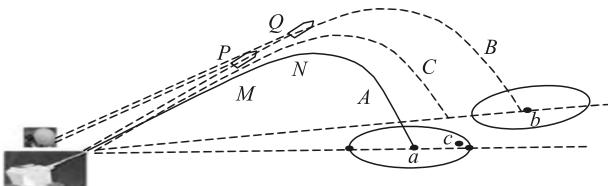


图 4 无人艇对岸射击基本原理

3 实验结果

利用岸基无人艇射击装置试射 35 发弹, 按照时间先后记录理论弹着点和实际弹着点间的距离偏差量, 利用 Minitab 软件处理实验数据, 得到如图 5 所示的数据处理结果。结果表明: 随着射击过程的进行, 实际弹着点和理论弹着点之间的距离偏差量不断缩小, 证明射击装置的自主校验设计是有效果的, 符合理论预期。

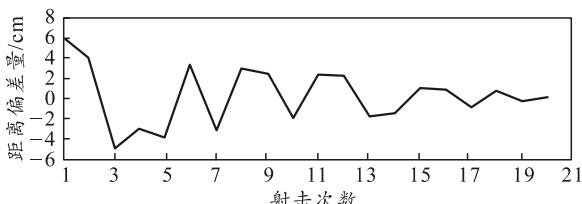


图 5 距离偏差量与射击次数关系

(上接第 20 页)

- [20] LIU W, RABINOVICH A, BERG A C. ParseNet: Looking Wider to See Better[Z]. Computer Science, 2015.
- [21] CAI Z, FAN Q, FERIS R S, et al. A Unified Multi-scale Deep Convolutional Neural Network for Fast Object Detection[C]//European Conference on Computer Vision, 2016: 354–370.
- [22] NEUBECK A, GOOL L V. Efficient Non-Maximum Suppression[C]. International Conference on Pattern Recognition. IEEE Computer Society, 2006: 850–855.

- [12] 李学龙, 龚海刚. 大数据系统综述[J]. 中国科学(信息科学), 2015, 45(1): 1–44.
- [13] 刘军. Hadoop 大数据处理[M]. 北京: 人民邮电出版社, 2013: 45–60.
- [14] 冯登国, 张敏, 李昊. 大数据安全与隐私保护[J]. 计算机学报, 2014, 37(1): 246–258.
- [15] 毕长剑. 大数据时代建模与仿真面临的挑战[J]. 计算机仿真, 2014, 31(1): 1–3.

4 结束语

对岸火力支援无人艇采用双体船结构并配有对岸火力支援武器装置, 不仅稳定性好, 而且具备高精度快速清除定点目标的能力。笔者结合高精度定位系统, 在火控解算模块中合理运用观测偏差法, 可以大幅度提高命中概率。该无人艇制作简单, 费用较低, 可以为登陆作战部队战术运用提供参考。

参考文献:

- 贾志安, 张宁, 陈桂秋. 舰炮武器系统的总体配置方案及关键技术[J]. 指挥控制与仿真, 2006(4): 82–85.
- 汪德虎, 谭周寿, 王建明. 舰炮射击基础理论[M]. 北京: 海潮出版社, 1998: 2–4.
- 王金云, 周晖杰. 基于 GPS 和外弹道实时解算下的舰炮对岸射击新方法[J]. 火炮发射与控制学报, 2009(4): 4–7.
- 石章松, 傅冰, 胡献君. 基于增程修正弹的同时弹着火控机理[J]. 海军工程大学学报, 2013, 25(3): 7–12.
- 潘红华, 余家祥, 胡家升. 舰炮对岸射击稳定诸元计算方法[J]. 火力与指挥控制, 2001(4): 51–52, 58.
- 杨青, 李若, 蔡振宁. 六自由度外弹道方程组的快速数值方法[J]. 高等学校计算数学学报, 2014, 36(3): 253–270.
- 董志勇, 刘洋, 贾成江. 弹道逼近及其在炮兵校射系统中的应用[J]. 测试技术学报, 2008, 22(5): 434–437.
- 黄义, 黄景德, 由佳. 一维弹道修正弹多发同时弹着火控新算法[J]. 兵工自动化, 2018, 37(5): 6–7.
- 李元生, 陈礼国. 舰炮弹道拟合对岸校射方法研究[J]. 火炮发射与控制学报, 2016, 37(4): 25–28, 34.

- 魏湧明, 全吉成, 侯宇青阳. 基于 YOLO v2 的无人机航拍图像定位研究[J]. 激光与光电子学进展, 2017, 54(11): 95–104.
- ZHANG Z. A flexible new technique for camera calibration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(11): 1330–1334.
- MORE J J. The Levenberg-Marquardt algorithm: Implementation and theory[J]. Lecture Notes in Mathematics, 1978, 630(1): 105–116.
- 刘大伟, 韩玲, 韩晓勇. 基于深度学习的高分辨率遥感影像分类研究[J]. 光学学报, 2016, 36(4): 298–306.