

基于改进 CNN 的多目标生猪检测算法

刘 岩 孙龙清 罗 冰 陈帅华 李 玥
(中国农业大学信息与电气工程学院, 北京 100083)

摘要: 为了在复杂环境下对视频目标生猪进行精确、快速检测,提出一种基于改进卷积神经网络(CNN)的多目标生猪检测算法。利用生猪图像的二值化规范梯度(BING)训练两级线性SVM,以生成高质量的候选区域,利用改进的CNN模型对候选区域进行分类识别,最后利用非极大值抑制算法剔除冗余窗口,减少训练样本和训练参数的数量。对CNN网络结构和参数进行优化实验,分析网络训练效率和目标检测效果。实验结果表明,与传统CNN模型相比,本文算法训练时间更短,且具有更快的收敛速度和更强的鲁棒性,对生猪图像前景和背景的分类正确率为96%,高于传统CNN模型的72.29%。对误检率、漏检率和平均检测时间的分析表明,本文算法的检测性能优于Faster RCNN和Yolo算法;本文算法目标跟踪成功率平均值为89.17%,中心点平均误差为6.94像素,表明该检测算法在生猪跟踪上的有效性和稳定性。

关键词: 生猪; 目标检测; 卷积神经网络

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2019)S0-0283-07

Multi-target Pigs Detection Algorithm Based on Improved CNN

LIU Yan SUN Longqing LUO Bing CHEN Shuaihua LI Yue
(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: In order to detect pigs accurately and quickly in complex environments, a multi-target pigs detection algorithm based on improved convolutional neural network (CNN) was proposed. Two-level linear SVM was trained to generate high-quality candidate regions by using binarized normed gradients (BING) of pig images. The improved CNN model was used to classify and identify candidate regions. Finally, the non-maximum suppression (NMS) algorithm was used to eliminate redundant windows. The proposed algorithm reduced the number of training samples and parameters. Through the experiment of CNN network structure and parameter optimization, the efficiency of network training and the effect of target detection were analyzed. Experiments showed that compared with the traditional CNN model, the improved CNN model had shorter training time, faster convergence speed and stronger robustness. The classification accuracy of foreground and background of pig images was 96%, which was higher than 72.29% of the traditional CNN model. Through the analysis of false detection rate, missed detection rate and average detection time, the detection performance of this algorithm was slightly better than Faster RCNN and Yolo algorithm. The average success rate of pig tracking based on this detection algorithm was 89.17%, and the average error of center point was 6.94 pixels, which showed the effectiveness and stability of the detection algorithm in pig tracking. Using this detection algorithm, it can lay a foundation for the future research on extracting the motion parameters of pigs to judge the health status of pigs.

Key words: pig; objection detection; convolution neural network

0 引言

随着生猪养殖规模不断扩大,养殖密度不断增

加,大大增加了生猪感染病患的风险,加快了病害传播感染的速度,增大了猪病防控的难度。养殖环境对生猪的生长发育极为重要,对视频图像目标生猪

进行精确且快速的检测,可有助于发现生猪异常行为,及时采取应对措施,降低疾病发生率^[1-2]。目标检测利用视频图像识别技术,根据目标区别于背景的特征将目标从图像中自动识别并进行定位^[3]。准确有效的生猪检测算法是生猪行为分析和养殖决策的基础^[4-6]。

传统的目标检测算法包括 Hog + SVM^[7-8]、DPM^[9]等算法,由于目标本身及其周围环境的改变,常出现目标姿态变化、光照强度变化、目标间互相遮挡等问题,难以对目标进行精确、快速检测。近几年,基于深度学习的卷积神经网络(CNN)因其对图像强大的特征表达能力^[10-11],已成为计算机视觉领域的研究热点,在图像分类识别、目标检测等领域取得了丰硕成果。

基于深度学习的目标检测主要分为两类:one-stage 检测算法和 two-stage 检测算法。one-stage 检测算法不需要候选区域(Region proposal)提取阶段,直接产生物体的类别概率和位置坐标值,经过单次检测即可直接得到最终检测结果,因此该算法检测速度快,但精确度较低^[12-15]。two-stage 检测算法将检测划分为两个阶段,首先产生候选区域,然后对候选区域分类,最后再对位置进行精修,因此检测精确度高,但速度较慢^[16-18]。

本文根据图像目标生猪和背景轮廓不同这一特征,采用 two-stage 算法,利用生猪图像的二值化规范梯度(Binarized normed gradients,BING)特征训练两级线性 SVM 模型,产生高质量的候选区域,再训练 CNN 网络模型进行分类,最后使用非极大值抑制算法(NMS)^[19]剔除得分低的窗口,保留得分高的窗口。BING 算法由 CHENG 等^[20]提出,发现物体的最大特点是有完整、闭合的边界,而背景则是杂乱无章的。利用 BING 算法提取图像候选区域已被广泛使用^[21-22]。传统的 CNN 模型提取的特征虽具有比人工提取特征更强的鲁棒性,但是需要海量的样本数据,效果好的 CNN 模型网络结构复杂,具有大量的参数,在训练网络时需要占用大量计算资源,耗时长,且容易陷入局部最优。针对传统 CNN 模型的局限性和生猪图像自身的特点,本文提出改进 CNN 模型算法^[23]。

1 材料和方法

1.1 样本数据集

本实验的生猪养殖场为山东省临沂市金锣牧业有限公司第十七种猪养殖场,养殖场用摄像头实时拍摄。本文训练集由截取的养殖场真实视频图像和部分 ImageNet 数据库生猪图像组成。构建本文实

验数据集的步骤如下:

- (1)选取 5 000 幅生猪养殖场真实视频图像和 3 000 幅 ImageNet 数据库生猪图像,如图 1a 所示。
- (2)对选取的图像进行人工标注,制作 XML 文件以确定目标生猪在图像中的位置。
- (3)根据 VOC2007 数据集格式构建 BING 算法训练数据集。
- (4)由于原始图像大部分属于背景区域,根据标注,将含有目标生猪的区域裁剪,构建 CNN 模型训练数据集的正样本,如图 1b 所示,随机裁剪背景区域作为负样本,如图 1c 所示。



图 1 训练数据集

Fig. 1 Training data sets

1.2 算法原理

1.2.1 BING 算法

将包含物体与非物体的窗口规整为 8 × 8,计算梯度特征,每一点梯度值均变换到[0,255],得到的 64 维梯度特征称为规范梯度(Normalized gradient, NG)特征,物体与非物体之间的 64 维梯度特征有着明显的差别^[24]。根据物体和非物体 NG 特征的不同,BING 算法利用两级线性 SVM 提取图像中的候选区域。

BING 算法先将原图像缩放到预定义尺寸,利用 8 × 8 的滑动窗口扫描缩放后的图像,计算滑动窗口

的梯度特征。训练第 1 级 SVM 线性模型 ω ,利用 ω 计算滑动窗口的滤波分数,计算公式为

$$c_a = \langle \omega \cdot g_a \rangle \tag{1}$$

$$a = (i, k_x, k_y) \tag{2}$$

式中 c_a ——滑动窗口滤波分数
 ω ——64 维向量
 g_a ——滑动窗口 64 维 NG 特征向量
 a ——滑动窗口坐标
 i ——图像缩放尺度
 (k_x, k_y) ——滑动窗口位置
 $\langle \cdot \rangle$ ——向量内积

在每种尺度下,计算所有窗口的滤波分数,利用非极大值抑制算法剔除得分低的窗口。由于不同尺度的窗口包含目标的概率不同,训练第 2 级线性

SVM 模型参数 v_i, t_i ,校正滤波分数 c_a ,尺度 i 下窗口分数的计算公式为

$$o_a = v_i c_a + t_i \tag{3}$$

式中 o_a ——滑动窗口最终得分
 v_i ——尺度 i 下的线性参数
 t_i ——尺度 i 下的偏差项

根据分数 o_a 对窗口排序,选取分数高的窗口作为候选区域,并将这些区域输入到分类器中分类。

1.2.2 改进的 CNN 模型

本文算法引入离线训练方法,对样本集进行主成分分析(PCA),并将尺寸规整为 32×32 后,输送到网络中分类。

(1)CNN 网络结构设计

改进的 CNN 模型结构如图 2 所示。




图 2 改进的 CNN 网络结构图

Fig.2 Improved CNN network architecture diagram

高斯滤波用于消除高斯噪声和图像平滑,拉普拉斯算子用于锐化图像和增强图像对比度,Sobel 边缘算子用于检测图像边缘,本文用这 3 种算子初始化第 1 层卷积核。

卷积层设计:对于 C1 层,选择 2 个高斯卷积核、2 个拉普拉斯算子和 2 个 Sobel 边缘算子总计 6 个

卷积核;对于 C3 层,选择随机初始化方式进行初始化 16 个卷积核,权值范围为 $(-1,1)$ 。C1 和 C3 卷积核尺寸均为 5×5 。本文选择 ReLU 函数作为激活函数,C1 层经过 ReLU 函数变换后所得到的部分输出示例如图 3 所示。

下采样层设计:对于 S2 层,2 个高斯卷积核使




图 3 C1 层经 ReLU 函数变换后的特征图

Fig.3 Feature maps of C1 after ReLU transformation

用最大池化,2 个拉普拉斯算子使用均值池化,2 个 Sobel 边缘算子使用空间金字塔池化,经 ReLU 函数激活后的特征图像进行池化,所得到的部分输出示例如图 4 所示。

全连接层设计:采用 Dropout 操作避免训练过

拟合,这提高了网络的鲁棒性和泛化性。在训练时,Dropout 随机将隐含层 50% 的神经元输出置 0,输入层和输出层不作变动。

(2)CNN 网络训练优化

反向传播算法改进:采用权重衰减(L2 正则化)




图4 S2 层池化操作后的特征图

Fig.4 Feature maps after S2 pooling operation

的反向传播算法训练卷积神经网络的参数,防止网络出现过拟合现象,提高泛化能力。包含 M 个训练样本的集合权值衰减公式为

$$J(\mathbf{W},b)=\frac{1}{M}\sum_{m=1}^MJ(\mathbf{W},b;x^{(m)},y^{(m)})+\frac{\lambda}{2M}\sum_{l=1}^{l^*-1}\sum_{i=1}^{S_l}\sum_{j=1}^{S_{l-1}}(\mathbf{W}_{ij}^{(l-1)})^2=B+S\tag{4}$$

其中 $B=\frac{1}{M}\sum_{m=1}^M\left(\frac{1}{2}\parallel h(x^{(m)})-y^{(m)}\parallel_2^2\right)$ (5)

$$S=\frac{\lambda}{2M}\sum_{l=1}^{l^*-1}\sum_{i=1}^{S_l}\sum_{j=1}^{S_{l-1}}(\mathbf{W}_{ij}^{(l-1)})^2\tag{6}$$

- 式中 M ——训练样本数量
 $\mathbf{W}$ ——神经元节点权值矩阵
 b ——偏置
 $x^{(m)}$ ——第 m 个训练样本
 $h(x^{(m)})$ ——第 m 个训练样本的预测值
 $y^{(m)}$ ——第 m 个训练样本的真实值
 l ——网络层数
 l^* ——网络总层数
 $\mathbf{W}_{ij}^{(l-1)}$ ——第 $l-1$ 层第 i 个神经元与第 l 层第 j 个神经元连接权值矩阵
 B ——均方误差
 S ——权值衰减量
 S_l ——第 l 层神经元数量
 λ ——权重衰减系数

学习率改进:一般人工指定、固定的学习速率 α 容易导致 CNN 训练时间变长,收敛速度变慢。为此,本文采用在训练过程中动态变化的学习率,加快收敛速度。首先初始化一个小的学习率 0.01,当训练到设定的步数时, α 开始自动变化以使误差逐渐减小, α 变化公式为

$$\alpha^{(s)}=2^{\gamma}\alpha^{(s-1)}\tag{7}$$

其中 $\gamma=\text{sign}(J^{(l)}(\mathbf{W},b)J^{(l-1)}(\mathbf{W},b))$

- 式中 s ——训练步数
 γ ——符号函数
 $\alpha^{(s)}$ ——第 s 步的学习率
 $J^{(l)}$ ——第 l 层网络误差

1.2.3 候选框筛选

首先筛选掉较小的候选框,设定面积阈值 θ ,将面积小于 θ 的矩形框去掉,设定 θ 为图像面积的 1%。

去掉较小的矩形框后,图像仍然存在一些非目标矩形框,将候选框输入到训练好的 CNN 网络中分类,保留分类为生猪的候选框,剔除分类为背景的候选框。

保留下的一部分候选框会出现部分的重叠,本文利用非极大值抑制算法(NMS)解决,整个候选框的筛选策略如图 5 所示。




图5 候选框筛选策略

Fig.5 Candidate box selection strategy

2 实验与结果分析

采用 Ubuntu16.04 操作系统,基于 Python、Numpy、OpenCV3、TensorFlow 搭建卷积神经网络模型。

2.1 BING 算法效果分析

2.1.1 模型 ω

BING 算法第 1 级 SVM 模型 ω 可视化后如图 6 所示。由图 6 可知,中间目标区域的 BING 特征值较边缘处的 BING 特征值亮度低,具有特征包裹性,说明目标生猪处于训练样本中心附近。

2.1.2 召回率

召回率 r 的计算公式为




图6 模型 ω 可视化效果
Fig.6 Model ω visualization

$$r = \frac{T_p}{T_p + F_n} \times 100\% \tag{8}$$

式中 T_p ——候选框预测为目标,实际为目标的数量
 F_n ——候选框预测为背景,实际为目标的数量
BING 算法的召回率曲线如图 7 所示。




图7 召回率曲线
Fig.7 Recall rate curve

如图 7 所示,当候选窗口数量为 300 时,召回率为 96.4%,当候选窗口数量小于 300 时,召回率随候选框数量增加快速提高,当候选窗口数量大于 300 时,召回率提高缓慢,本文选择前 300 个候选窗口作为检测目标。

2.2 CNN 模型策略选择分析

2.2.1 训练效率分析

为了使网络性能更加直观化,本文采用均方根误差 (RMSE) 分析的方法,将训练样本的误差数据在网页中显示。设置批量大小为 10,所有数据训练 10 次,以最大迭代次数 800 来结束程序。生猪识别训练过程损失值 (loss) 变化如图 8 所示。由图 8 可知,当迭代次数为 300 次时,损失值收敛,在 0.4 左右振动,本文方法训练 5 h,时间较短且具有较快的收敛速度。对 2 000 幅测试图像 (正负样本各占 50%) 进行测试,统计本文算法分类正确率为 96%,高于传统模型的 72.29%,从而表明本文算法在生猪图像前景和背景分类上具有明显效果。




图8 生猪识别的训练误差曲线
Fig.8 Training error curve of pig recognition

2.2.2 检测效果分析

为了检验本文算法的有效性,将视频图像 (与训练样本不重叠) 经 BING 算法生成候选区域输入到本文训练好的 CNN 模型中进行分类,经非极大值抑制后,验证效果如图 9 所示。




图9 本文算法效果
Fig.9 Effect diagram of improved CNN

由图 9 可知,在不同检测场景下,本文算法能够较准确地将目标生猪检测出,准确分辨背景和目标,说明本文算法可以排除复杂背景的干扰,对光照变化具有较强的鲁棒性。为了进一步评估本文检测算法的性能,分别使用 Faster RCNN 与 Yolo 算法检测生猪视频图像,统计误检率、漏检率和平均检测时间,结果如表 1 所示。

表1 本文算法与 Faster RCNN、Yolo 算法检测性能对比结果

Tab.1 Comparison of detection performance between proposed algorithm and Faster RCNN and Yolo algorithms			
性能指标	本文算法	Faster RCNN	Yolo 算法
漏检率/%	10.5	10.1	14.0
误检率/%	19.3	20.7	25.9
平均检测时间/s	0.71	0.75	0.42

根据表 1 可知,本文算法的漏检率略高于 Faster RCNN,误检率低于 Faster RCNN,说明本文算法与 Faster RCNN 在生猪检测上的效果相近,然而本文算法检测时间略小于 Faster RCNN,说明本文算法的综合检测性能略优于 Faster RCNN。在误检率、漏检率上,本文算法均低于 Yolo 算法,说明本文算法的检测效果优于 Yolo 算法,Yolo 算法的平均检测

时间略小于本文算法,说明在检测时间相近的情况下,本文算法的综合检测性能优于 Yolo 算法。

2.2.3 跟踪有效性分析


为了评估检测算法在生猪跟踪上的有效性,本文采用跟踪成功率和中心点误差这两个指标来分析算法的效果。

(1)成功率:判断算法在某时刻是否检测到生猪,用预测边框和真实边框的交并比衡量。

$$H_u = \frac{R_g \cap R_t}{R_g \cup R_t} \quad (u = 1, 2, \cdots, U) \quad (9)$$

$$H_{avg} = \frac{\sum_{u=1}^U H_u}{U} \quad (10)$$

式中 R_g ——目标生猪的预测边框面积
 R_t ——目标生猪的真实边框面积
 U ——检测到的目标生猪总数量
 H_u ——第 u 只目标生猪的检测成功率



H_{avg} ——该视频帧中目标生猪检测成功率均值
(2)中心点误差:衡量算法在某时刻目标跟踪的准确性,误差越小准确度越高。

$$e_u = \sqrt{(h_e - h_f)^2 + (y_e - y_f)^2} \quad (u = 1, 2, \cdots, U) \quad (11)$$

$$e_{avg} = \frac{\sum_{u=1}^U e_u}{U} \quad (12)$$

式中 h_e, y_e ——目标生猪预测边框的中心点坐标值
 h_f, y_f ——目标生猪真实边框的中心点坐标值
 e_u ——第 u 只生猪的中心点误差
 e_{avg} ——中心点误差均值

本文选择某天 09:00—09:30、13:00—13:30、18:00—18:30 时段视频,3 段视频分别计算跟踪成功率和中心点误差,结果如图 10 所示。




图 10 基于检测的跟踪分析对比结果

Fig. 10 Detection-based tracking analysis comparison results

根据图 10 可知,本文检测算法在每段视频下的平均跟踪成功率分别是 90.07%、88.98% 和 88.46%,均高于传统检测算法的 78.30%、79.17% 和 77%。3 段视频总体跟踪成功率平均值是 89.17%,高于传统算法的 78.16%。通过对跟踪成功率的统计,说明本文算法跟踪效果比传统算法稳定。本文算法在每段视频下的中心点平均误差分别为 6.20、7.30、7.31 像素,均低于传统算法的 7.71、8.67、8.65 像素。3 段视频总体跟踪中心点平均误差为 6.94 像素,低于传统算法的 8.34 像素。通过对跟踪目标中心点误差的计算,说明本文算法在生

猪目标跟踪上具有比传统算法更高的准确度。通过对跟踪成功率和跟踪中心点误差的分析,说明本文算法在生猪跟踪上有效且稳定。

3 结论

(1)基于 BING 算法提取图像候选区域,通过改进 CNN 模型对候选框分类,最后利用非极大值抑制算法剔除冗余候选框,实现对生猪精确检测。
(2)实验结果表明,本文算法对生猪图像前景和背景的分类正确率为 96%,高于传统 CNN 模型的 72.29%。本文算法漏检率、误检率和平均检测

时间分别是 10.5%、19.3% 和 0.71 s, 通过对比 Faster RCNN 和 Yolo 算法, 表明本文算法在生猪检测上具有良好的性能。利用本文算法对视频生猪跟踪成功率平均值为 89.17%, 中心点平均误差为 6.94 像素, 说明本文算法对生猪跟踪有良好的效果。

参 考 文 献

- [1] 段玉瑶, 马丽, 刘刚. 基于物联网的生猪运动行为及猪舍环境远程监控系统[J]. 农业工程学报, 2015, 31(增刊2): 216–221.
DUAN Yuyao, MA Li, LIU Gang. Remote monitoring system of pig motion behavior and piggery environment based on Internet of Things[J]. Transactions of the CSAE, 2015, 31(Supp. 2): 216–221. (in Chinese)
- [2] 李亿杨, 孙龙清, 孙鑫鑫. 基于多特征融合的粒子滤波生猪采食行为跟踪[J]. 农业工程学报, 2017, 33(增刊1): 246–252.
LI Yiyang, SUN Longqing, SUN Xinxin. Automatic tracking of pig feeding behavior based on particle filter with multi-feature fusion[J]. Transactions of the CSAE, 2017, 33(Supp. 1): 246–252. (in Chinese)
- [3] 李劲菊, 朱青, 王耀南. 一种复杂背景下运动目标检测与跟踪方法[J]. 仪器仪表学报, 2010, 31(10): 2242–2247.
LI Jinju, ZHU Qing, WANG Yaonan. Detecting and tracking method of moving target in complex environment[J]. Chinese Journal of Scientific Instrument, 2010, 31(10): 2242–2247. (in Chinese)
- [4] 孙龙清, 李玥, 邹远炳, 等. 基于改进 Graph Cut 算法的生猪图像分割方法[J]. 农业工程学报, 2017, 33(16): 196–202.
SUN Longqing, LI Yue, ZOU Yuanbing, et al. Pig image segmentation method based on improved Graph Cut algorithm[J]. Transactions of the CSAE, 2017, 33(16): 196–202. (in Chinese)
- [5] 邹远炳, 孙龙清, 李玥, 等. 基于分布式流式计算的生猪养殖视频监测分析系统[J]. 农业机械学报, 2017, 48(增刊): 365–373.
ZOU Yuanbing, SUN Longqing, LI Yue, et al. Video monitoring and analysis system for pig breeding based on distributed flow computing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 365–373. (in Chinese)
- [6] LI Yiyang, SUN Longqing, ZOU Yuanbing, et al. Individual pig object detection algorithm based on Gaussian mixture model[J]. International Journal of Agricultural & Biological Engineering, 2017, 10(5): 186–193.
- [7] ZHU Qiang, AVIDAN S, YEH M C, et al. Fast human detection using a cascade of histograms of oriented gradients[C]//Computer Vision and Pattern Recognition. IEEE, 2006: 1491–1498.
- [8] XU Fen, XU Feng. Pedestrian detection based on motion compensation and HOG/SVM classifier[C]//International Conference on Intelligent Human-Machine Systems and Cybernetics. IEEE, 2013: 334–337.
- [9] FELZENSZWALB P F, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part-based models[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(9): 1627–1645.
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84–90.
- [11] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Computer Vision and Pattern Recognition. IEEE, 2016: 770–778.
- [12] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Computer Vision and Pattern Recognition. IEEE, 2016: 779–788.
- [13] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//Computer Vision and Pattern Recognition. IEEE, 2017: 6517–6525.
- [14] REDMON J, FARHADI A. YOLOv3: an incremental improvement[EB/OL]. [2018–04–08]. <https://arxiv.org/pdf/1804.02767.pdf>.
- [15] LIU Wei, ANGUELOV D, ERHAN D, et al. SSD: single shot multiboxdetector[C]//European Conference on Computer Vision. Springer International Publishing, 2016: 21–37.
- [16] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Computer Vision and Pattern Recognition. IEEE, 2014: 580–587.
- [17] GIRSHICK R. Fast R-CNN[C]//Conference on Computer Vision. IEEE, 2015: 1440–1448.
- [18] REN Shaoqing, HE Kaiming, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137–1149.
- [19] NEUBECK A, VAN GOOL L. Efficient non-maximum suppression[C]//International Conference on Pattern Recognition. IEEE Computer Society, 2006: 850–855.
- [20] CHENG Mingming, ZHANG Ziming, LIN Wenyan, et al. BING: binarizednormed gradients for objectness estimation at 300fps[C]//Computer Vision and Pattern Recognition. IEEE, 2014: 3286–3293.
- [21] ZHANG Caiyou, DAI Bo, JIANG Hongcheng, et al. A moving target detection algorithm based on BING objectness and background estimation[C]//Chinese Control Conference. IEEE, 2017: 10795–10800.
- [22] LI Lexing, SHI Zelin, LIU Yunpeng. Fast infrared sea ship target detection based on improved BING algorithm[C]//Chinese Society for Optical Engineering (CSOE). Bellingham, USA: SPIE, 2017: 1–6.
- [23] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278–2324.
- [24] 贾涛, 周利莉, 陈健, 等. 基于 BING 和 GS 的图像目标检测中的快速候选框生成算法[J]. 信息工程大学学报, 2017, 18(3): 294–298.
JIA Tao, ZHOU Lili, CHEN Jian, et al. BING and GS-based fast proposal generation algorithm[J]. Journal of Information Engineering University, 2017, 18(3): 294–298. (in Chinese)