

改进的 Faster R-CNN 方法及其在电缆隧道积水定位识别中的应用

崔江静¹, 黄顺涛¹, 仇 炜¹, 裴星宇¹, 朱五洲¹, 孟安波²

(1. 广东电网公司珠海供电局, 广东 珠海 519000; 2. 广东工业大学 自动化学院, 广东 广州 510006)

摘要:针对电缆隧道内积水的问题,提出了一种改进的基于区域建议的卷积神经网络(Faster R-CNN)方法,并将其应用在电缆隧道积水定位识别中。考虑到 Softmax 分类方法的正则化参数选取会引起概率计算产生问题,改用支持向量机(SVM)进行图像分类,以增强分类的置信度。使用区域建议网络(RPN)提取隧道积水原图中的区域建议,然后用 Fast R-CNN 检测网络在建议框中进行图像识别、SVM 分类和位置精修。实验结果表明,所提方法计算速度快、识别精度高,在实际工程中表现出较高的效率。

关键词:电缆隧道;积水定位;区域建议;卷积神经网络;支持向量机

中图分类号:TP 183

文献标志码:A

DOI:10.16081/j.issn.1006-6047.2019.07.033

0 引言

电缆是由几根或几组导线围绕中心绞合而成的,每组导线之间相互绝缘,且外侧包有高度绝缘的覆盖层,因此电缆具有内通电、外绝缘的特征。电缆隧道是全封闭型的地下构筑物,其可容纳较多数量的电缆,并有供安装和巡视的通道。电缆隧道适用于地下水位低,电缆线路较集中的电力主干线,一般敷设 30 根以上的电力电缆。

鉴于架空输电线路占用过多地上空间,以及出于安全性方面的考虑,在 110 kV 及以下电压等级系统中,电缆隧道的应用日益广泛。但是,电缆隧道长期运行会因种种原因造成隧道内积水,如结构损伤造成渗漏、隧道接缝处防水处理不好、雨水倒灌等。电缆本体,尤其是电缆中间接头、T 接头长时间浸泡在水中运行,会造成电缆绝缘受潮,形成水树枝,加速绝缘老化,进而形成电树枝,引发绝缘击穿,造成电缆故障停电。除此之外,隧道积水还会使隧道内的空气湿度增大,腐蚀隧道内的附属设施,对电力电缆的正常安全运行构成威胁^[1]。因此,及时监控和识别出隧道积水具有十分重要的现实意义。

目前,国内外对于电缆隧道内的积水检测研究较少,只有基于水泵及水位的检测系统,其检测目标为电缆隧道内集水坑的水位,当水位超过预设值时会启动远程警报,隧道维护人员通过该信号确定水泵是否正常排水,并采取相关的应急措施^[2]。然而,这种检测方式只能将对象局限于集水坑,无法兼顾整个电缆隧道各个位置的积水情况,且反馈不够及时,难以实时监控电缆隧道内的积水情况,解决潮湿

问题。为改进电缆隧道内积水检测的以上缺陷,本文基于视频监控系统,采用数字图像处理技术和基于区域建议的卷积神经网络 Faster R-CNN (Faster Region-based Convolutional Neural Network) 算法进行电缆隧道积水的实时监控和图像定位识别。该算法先使用区域建议网络 RPN (Region Proposal Network) 提取积水位置区域建议,然后用检测网络在建议框中进行图像识别以及支持向量机 SVM (Support Vector Machine) 分类,最后对区域建议框进行位置精修。本文算法通过将传统 Faster R-CNN 中的 Softmax 分类方法替换为 SVM,避免了由 Softmax 正则化参数选取造成的概率计算近似结果,增强了分类的置信度。

1 基于区域建议的卷积神经网络

卷积神经网络^[3] CNN (Convolutional Neural Network) 已经被广泛应用于多个领域中,如目标检测^[4]和语音识别^[5]等。其中,Ross Girshick 等人在 2014 年提出的基于区域建议的卷积神经网络 R-CNN (Region-based Convolutional Neural Network) 表现出色,发展十分迅速。R-CNN 是使用区域建议方式进行图像识别的经典算法和基础方法,之后的 Fast R-CNN 和 Faster R-CNN 算法都是在 R-CNN 的基础上提出和改进得到的。

一般而言,R-CNN 算法可以分为 4 个步骤:①候选区域生成;②特征提取;③类别判断;④位置精修。即首先使用视觉方法生成大量候选区域,再用 CNN 方法通过卷积运算形成这些区域的高维特征向量,然后将这些特征向量送入某种分类器,如简单的逻辑回归和 Softmax 回归等,计算候选区域得分 (Object Score) 和候选框 (Bounding Box) 的重叠度 IoU 后,进行候选框的位置精修,从而实现对象识别和定位^[6]。

与使用滑动窗依次判断所有可能区域的原始目

收稿日期:2018-08-18;修回日期:2019-04-23

基金项目:广东电网有限责任公司科技项目(GDKJXM20162047)
Project supported by the Science and Technology Project of Guangdong Power Grid Corporation(GDKJXM20162047)

标检测算法相比,R-CNN 算法预先提取了一系列较可能是物体的候选区域,然后仅在这些候选区域上(采用 CNN)提取特征进行判断,有效减少了后续特征向量的计算量,可较好地应对尺度问题;CNN 在实现上采用 GPU 并行计算,计算速度和效率得到了提高;此外,外围框的回归步骤使得目标定位的准确性也得到了提高。

2 基于 Faster R-CNN 的积水定位识别

尽管 R-CNN 成为了图像识别领域的典型算法,但其第一步区域建议生成耗时长是该算法亟待解决的瓶颈问题。针对该缺陷,Faster R-CNN 应运而生,针对该算法提出了一种 RPN,它是一个基于全卷积的网络^[7],能够同时预测输入图片每个位置的目标区域框和目标得分,旨在高效生成高质量的区域建议框。它的出现替代了之前的 Selective Search^[8]和 Edge Boxes^[9]等方法,其与检测网络共享全图的卷积特征,使得区域建议检测几乎不耗费时间^[10-11]。因此,本文以 Faster R-CNN 为主体、以 ZFnet 为基础、用 SVM 替代 Softmax 分类方法,来实现电缆隧道内的积水定位识别。

2.1 积水定位识别的网络训练

Faster-RCNN 算法中包含 2 个 CNN:RPN 和 Fast R-CNN 检测网络。本文采用 ZFnet 对 CNN 进行预训练,用作 RPN 和 Fast R-CNN 检测网络的初始化。训练过程如图 1 所示。




图 1 积水定位识别的网络训练过程

Fig.1 Network training process for water accumulation identification

(1) 预训练 CNN。

本文使用 ZFnet 进行预训练,典型的 ZFnet 结构如附录 A 中的图 A1 所示。它包含 5 个卷积层 CONV(CONVolutional layer) 和 2 个全连接层 FC(Fully Connected layer),部分卷积层的后面还添加了池化层,每层滤波器尺寸和卷积步长略有不同。如图 A1 所示,ZFnet 的最后一个卷积层 CONV5 输出 256 通道的特征图(Feature Map),全连接层 FC6 将 256 个通道内的全部特征进行串联,生成一个 4 096 维的单通道高维特征向量。不同类别的图像在深层特征上的差异很大,对经过 CONV5、FC6、FC7 输出的特征向量使用分类器(本文使用的是 SVM),能够输出较好的图像识别效果。本文使用 PASCAL

VOC2011 Example Images 对 ZFnet 进行预训练,用于 RPN 和 Fast R-CNN 检测网络的初始化。本质上,本文使用的 RPN 和 Fast R-CNN 检测网络就是在 ZFnet 的基础上,加上特定功能的层得到的,具体方式将在下文进行介绍。

(2) 训练 RPN。

使用之前预训练得到的 ZFnet 对 RPN 进行初始化,在原 CONV5 的后面额外增加一个特定功能的小卷积层 CONV6,在该层上对 CONV5 输出的 Feature Map(与原始图像相互映射)进行滑窗式的卷积运算,对于图像的每个位置,考虑 9 个固定尺度和长宽比(1:1、1:2、2:1)的候选窗口。CONV6 的输出作为 2 个独立的全连接层——box 回归层和 box 分类层的输入,最终得到每个位置上 9×2 个窗口属于目标/背景的概率,以及 9×4 个平移缩放参数。RPN 训练流程如图 2 所示。




图 2 RPN 训练过程

Fig.2 Training process of RPN

(3) 训练 Fast R-CNN 检测网络。

同样使用预训练得到的 ZFnet 对检测网络进行初始化,将 RPN 得到的区域建议作为检测网络的输入,同样进行 5 层卷积提取特征,并通过相应的池化层进行特征图压缩运算,得到 256 通道的特征图,然后经过 FC6 和 FC7 的全连接层串联,最后通过 SVM 进行分类,最终得到该区域建议框内是否存在隧道积水和该积水区域框的位置。多次使用样本进行训练和微调,在误差反向传播的过程中更新层连接权重矩阵 ω 、偏差矩阵 b 的参数,最终得到适合用于电缆隧道积水定位识别的检测网络。

(4) RPN 与 Fast R-CNN 检测网络共享卷积层。

经过以上训练后,2 个网络还是彼此独立的,因此需要通过共享卷积层来使得特征既可作为区域建议框的生成,又可用作目标检测。具体方法是:

a. 使用 ZFnet 独立训练生成 RPN;

b. 使用 a 中 RPN 生成的区域建议和网络参数训练 Fast R-CNN 检测网络;

c. 利用 Fast R-CNN 检测网络的参数初始化 RPN,注意此时要将 RPN 和 Fast R-CNN 检测网络共享的卷积层的学习率设置为 0,即不更新这些卷积层,仅更新 RPN 特有的那些网络层,并重新训练。则 RPN 和 Fast R-CNN 检测网络就共享了所有公共的卷积层,使得区域建议几乎不耗费时间,有效缩短了算法耗时。

2.2 SVM 方法

SVM 是一种以统计学习理论为基础的机器学习

习方法^[12]。主要通过寻求结构化风险最小实现经验风险和置信范围的最小化,使系统在样本数量不大时也能得到较好的统计规律。与传统的模式识别方法相比,SVM 推广能力很强并能保证全局最优^[13]。SVM 算法的核心思想是寻找一个满足分类要求的最优分类超平面 H ,使得 H 不仅能将不同类的样本正确分开,而且不同类样本中每个点到 H 的距离最小值之和达到最大^[14-15]。

用 \mathbf{x} 表示待分类数据, $\mathbf{x} \in \mathbf{R}^n$, 线性分类器的学习目标是在 n 维数据空间中寻找一个分类超平面,将数据分为 2 类。超平面用 $\boldsymbol{\omega}^T \mathbf{x} + \mathbf{b} = 0$ 来表示,其中 $\boldsymbol{\omega}^T$ 和 \mathbf{b} 是通过大量样本训练得到的。

在线性可分的情况下,用 y 表示分类类别,如式(1)所示。

$$y_i = \begin{cases} 1 & \boldsymbol{\omega}^T \mathbf{x} + \mathbf{b} > 1 \\ -1 & \boldsymbol{\omega}^T \mathbf{x} + \mathbf{b} < -1 \end{cases} \quad (1)$$

此时的分类间隔 d 为:

$$d = \frac{2}{\|\boldsymbol{\omega}\|} \quad (2)$$

则使 d 最大的问题可转化为:

$$\min \frac{1}{2} \|\boldsymbol{\omega}\|^2 \quad (3)$$

采用 Lagrange 优化法求解上述问题,定义目标函数为:

$$L(\boldsymbol{\omega}, \mathbf{b}, \alpha_i) = \frac{1}{2} \|\boldsymbol{\omega}\|^2 - \sum_{i=1}^n \alpha_i [y_i (\boldsymbol{\omega}^T \mathbf{x}_i + \mathbf{b}) - 1] \quad (4)$$

其中, $\alpha_i (i=1, 2, \dots, n)$ 为各个样本的拉格朗日系数。

求解 $L(\boldsymbol{\omega}, \mathbf{b}, \alpha_i)$ 的最小值,即求解如下对偶问题:

$$\begin{cases} \max_{\alpha_i \geq 0} \left(\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right) \\ \text{s.t.} \quad \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (5)$$

求解式(5)得到线性可分情况的最优平面解。

对于线性不可分的情况,引入松弛变量 $\zeta_i > 0 (i=1, 2, \dots, n)$ 允许错分样本的存在,则样本集 (\mathbf{x}_i, y_i) 满足:

$$y_i (\boldsymbol{\omega}^T \mathbf{x}_i + \mathbf{b}) - 1 + \zeta_i \geq 0 \quad i=1, 2, \dots, n \quad (6)$$

其中, ζ_i 为训练样本关于最优分类超平面的偏差。

另外,增加一个惩罚因子 $C \geq 0$, 控制对错分样本的约束程度,则此时的最大间隔问题等价于:

$$\min_{\boldsymbol{\omega}, \mathbf{b}, \zeta_i} \left\{ \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{i=1}^n \zeta_i \right\} \quad (7)$$

接下来同样使用 Lagrange 优化法转化为求解对偶问题:

$$\begin{cases} \max_{0 \leq \alpha_i \leq C} \left(\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1, j=1}^n \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right) \\ \text{s.t.} \quad \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (8)$$

现实中的分类大多是非线性分类,本文中遇到的隧道积水图片识别分类同样也是非线性的,这时候可以通过空间变换,将非线性问题转化为某个高维空间中的线性问题,在变换后的高维空间中求其最优分类面或最优广义分类面。从线性不可分的低维空间映射到线性可分的高维空间要使用到核函数,常见的核函数有多项式核函数(Polynomial)、高斯径向基函数(RBF)和 S 形双曲正切(Sigmoid)函数等,本文在隧道积水定位识别算法中使用 RBF 核:

$$K(\mathbf{x}_1, \mathbf{x}_2) = \exp(-\gamma \|\mathbf{x}_1 - \mathbf{x}_2\|^2) \quad \gamma > 0 \quad (9)$$

积水识别是一个二分类问题,给定一组训练样本,将其分为 2 类进行标记,有积水为“+1”,无积水为“-1”,只需要 1 个 SVM 分类器。在实际操作中,可以通过下列步骤训练和使用 SVM 进行分类:

- (1) 对已分类的图片进行特征提取;
- (2) 采用简单的线性方法对特征向量实行归一化,防止大的数据波动主导数据波动、小的数据波动被忽略;
- (3) 选定核函数,本文使用的是 RBF 核;
- (4) 使用交叉验证法选取参数 C, γ ;
- (5) 采用最佳参数对训练集进行训练获取 SVM 分类模型;
- (6) 用训练得到的 SVM 模型对 FC7 输出的特征向量进行分类预测,将输出特征向量矩阵与 SVM 权重矩阵进行点乘,得到该区域建议框的得分,即该区域建议框中是否存在积水。

2.3 利用 Faster R-CNN 进行积水定位识别

由以上网络训练过程和 SVM 分类方法可知:使用 Faster R-CNN 进行积水定位识别的 2 个网络共享卷积层,因此整个检测过程只需完成系列卷积运算,实现了端到端的定位识别,解决了区域建议步骤耗时长的瓶颈问题,大幅缩短了算法时间;以 SVM 作为最后的分类器,实现了经验风险和置信范围的最小化,使分类器在样本数量不大时也能得到较好的统计规律。

积水定位识别的算法流程如下。

(1) 将样本图像输入 ZFnet 进行系列卷积运算,在 CONV5 卷积层上得到特征图。

(2) CONV5 得到的特征图进入区域建议网络 RPN,在特征图上生成大量区域建议框。需要注意的是,对于特征图的每个位置,本文考虑 9 个固定尺度和长宽比(1:1、1:2、2:1)的候选窗口。

(3) 对 RPN 生成的区域建议框进行非极大值抑

制(NMS),保留得分较高的 200 个框。

(4)由 Fast R-CNN 检测网络对区域建议框中的图像提取特征向量,输入全连接层,再输入 SVM 分类器计算各区域建议框的得分,并对区域建议框进行回归精修。

3 实验结果

为验证本文算法在隧道积水识别中的有效性,在 PC 机上进行了仿真实验,PC 的基本配置如下:CPU 双核 2.8 GHz, GPU 采用单块 TitanX, 12 GB 显存, 32 GB 内存, Ubuntu 14.04 操作系统,深度学习采用 ZF 框架进行网络训练,训练时间共 22 h。

3.1 仿真步骤

(1)网络结构:本次实验使用 ZF-Faster R-CNN 的结构,以图 2 所示的 ZFnet 框架为主,根据 2.3 节的算法流程进行改造。输入先通过 5 层卷积层和 3 层池化层得到特征向量,然后在 RPN 中使用特定卷积层得到一系列区域建议及坐标,在 Faster R-CNN 中对上述区域建议取特征向量,最后输入全连接层进行 SVM 分类和建议框回归精修。

(2)训练算法:本文使用随机梯度下降法进行网络微调训练,初始学习率为 10^{-4} ,动量项为 0.9,权值衰减系数为 0.000 5,训练迭代次数为 6 000。

(3)训练数据:本文收集了 2 170 张珠海横琴隧道的积水图像,人工标定并以 8:2 的比例分配了训练和测试用的数据集,训练前没有对积水图像做任何处理,重复训练 10 次取平均值作为最终结果。

(4)方法比较:为了验证改进 ZF-Faster R-CNN 的优良性能,将本文提出的方法与 CNN 和 BPNN 方法进行对比实验。将训练集分别输入 ZF-Faster R-CNN、CNN、BPNN 进行训练,将训练得到的网络模型用于测试集测试,每组实验都取 10 次测试的平均值作为最终结果输出,3 种方法的训练集、测试集完全相同。

3.2 仿真结果

本文给出了纵向 6 幅电缆隧道积水识别的仿真实验结果,并在横向上将原图、本文方法结果、CNN 方法结果、BPNN 方法结果进行了比较,见附录 B 中的图 B1。本文采用的基于改进的 ZF-Faster R-CNN 的电缆隧道积水定位识别方法可以准确识别定位不同角度、不同环境的隧道积水状态,统计结果显示识别准确率高达 89.6% 以上,而 CNN、BPNN 方法在候选框的选取上会出现多框情况(如图 B1(c)、(d)所示),识别结果不够精准,有时还会出现识别错误。

在识别速度上,本文方法以 98 ms 的速度优于 CNN 方法(121 ms)和 BPNN 方法(127 ms)。

此外,附录 B 中的图 B2 给出了不同卷积层数下卷积中间层特征图的可视化结果。观察图 B2 可知,浅层的卷积层只能提取到一些低级的特征,如边

缘、线条和角等,而深层的卷积层则可以提取到更加复杂和抽象的特征。

本文方法的训练误差如图 3 所示。由图可见,在初始的 2 000 次迭代训练中,训练误差快速减小,3 000 次以后训练误差逐渐稳定,表示训练已经得到了较好的权重和参数,生成了较合适的网络模型。




图 3 训练误差

Fig.3 Training error

本文方法在识别效果准确率和识别速度上相较于其他方法具有优势,这是因为新提出的方法在区域建议预训练中得到了较为理想的权重和偏置,使得后续训练时网络更容易收敛。

4 结论

本文将图像处理技术和深度学习方法应用于电缆隧道积水图像的识别和分析中,提出了一种改进的 Faster R-CNN 方法,并在电缆隧道积水定位识别中进行了应用。该实验在实践上是对积水检测方法效果和时效的创新,在理论上则主要对分类环节进行了改进。本文以 SVM 替代传统 Faster R-CNN 中的 Softmax 分类方法,避免了 Softmax 正则化参数选取可能导致的概率计算近似结果,使系统在样本数量不大时也能得到较好的统计规律,保证了全局最优,提高了分类置信度。在电缆隧道的特殊环境下,通过对积水的识别,能够实现对早期隧道积水的快速检测,为及时采取相应的排水措施提供了可能,防止电缆由于绝缘受损导致电力安全运行受到威胁。该方法可基于电缆隧道内原有的视频监控系統,也可基于智能巡检机器人实现电缆隧道内的积水检测。实验结果表明,该方法具有非常快的识别速度和较高的识别准确率,为电缆隧道的安全运行提供了有效保障,是图像处理技术在电力行业应用上的一次创新尝试。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 费斐. 电力隧道监控系统设计[J]. 科技信息:科学教研, 2007(23):386,373.
FEI Fei. The design of electric tunnel monitoring system[J]. Science and Technology Information: Science Teaching and Research, 2007(23):386,373.
- [2] 朱丽梅. 基于 PLC 的电缆隧道无线分布式监控系统[J]. 电力自动化设备, 2004, 24(9):71-73.
ZHU Limei. PLC-based cable tunnel wireless distributed monitoring

- system[J]. Electric Power Automation Equipment, 2004, 24(9): 71-73.
- [3] CUN Y L, BOSER B, DENKER J S, et al. Handwritten digit recognition with a back-propagation network[C]//Advances in Neural Information Processing Systems. [S.l.]: Morgan Kaufmann Publishers Inc., 1990: 396-404.
- [4] HE Kaimin, ZHANG Xiangyu, REN Shaoqing, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1906.
- [5] HINTON G, LI Deng, YU Dong, et al. Deep neural networks for acoustic modeling in speech recognition; the shared views of four research groups[J]. IEEE Signal Processing Magazine, 2012, 29(6): 82-97.
- [6] 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. Columbus, OH, USA: IEEE, 2014: 580-587.
- [7] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA: IEEE, 2015: 3431-3440.
- [8] ZITNICK C L, DOLLÁR P. Edge Boxes: locating object proposals from edges[C]//European Conference on Computer Vision. Cham, Switzerland: Springer, 2014: 391-405.
- [9] 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 & Machine Intelligence, 2017, 39(6): 1137-1149.
- [10] 桑军, 郭沛, 项志立, 等. Faster-RCNN 车型识别分析[J]. 重庆大学学报, 2017, 40(7): 32-36.
SANG Jun, GUO Pei, XIANG Zhili, et al. The analysis of the model identification of Faster-RCNN[J]. Journal of Chongqing University, 2017, 40(7): 32-36.
- [11] 王万国, 田兵, 刘越, 等. 基于 RCNN 的无人机巡检图像电力小部件识别研究[J]. 地球信息科学学报, 2017, 19(2): 256-263.
WANG Wanguo, TIAN Bing, LIU Yue, et al. Research on the identification of UAV patrol image based on RCNN[J]. Journal of Earth Information Science, 2017, 19(2): 256-263.
- [12] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000, 26(1): 32-42.
ZHANG Xuegong. On statistical learning theory and support vector machine[J]. Journal of Automation, 2000, 26(1): 32-42.
- [13] 张哲, 赵文清, 朱永利, 等. 基于支持向量回归的电力变压器状态评估[J]. 电力自动化设备, 2010, 30(4): 81-84.
ZHANG Zhe, ZHAO Wenqing, ZHU Yongli, et al. State evaluation of power transformers based on support vector regression[J]. Electric Power Automation Equipment, 2010, 30(4): 81-84.
- [14] 张懿议, 焦健, 汪可, 等. 基于帝国殖民竞争算法优化支持向量机的电力变压器故障诊断模型[J]. 电力自动化设备, 2018, 38(1): 99-104.
ZHANG Yiyi, JIAO Jian, WANG Ke, et al. Power transformer fault diagnosis model based on imperial colonial competition algorithm optimized support vector machine[J]. Electric Power Automation Equipment, 2018, 38(1): 99-104.
- [15] 郭明玮, 赵宇宙, 项俊平, 等. 基于支持向量机的目标检测算法综述[J]. 控制与决策, 2014, 29(2): 193-200.
GUO Mingwei, ZHAO Yuzhou, XIANG Junping, et al. Overview of target detection algorithm based on support vector machine[J]. Control and Decision, 2014, 29(2): 193-200.

作者简介:



崔江静

崔江静(1973—),男,广东电白人,高级工程师,硕士,主要从事输电技术管理工作(E-mail: cuijiangjing@vip.sina.com);

黄顺涛(1974—),男,广东澄海人,高级工程师,主要从事输电技术管理方面的工作(E-mail: 1784154624@163.com);

仇 炜(1983—),男,宁夏平罗人,高级工程师,硕士,主要研究方向为高电压与绝缘技术(E-mail: qiuwei211314@163.com);

裴星宇(1982—),男,贵州惠水人,高级工程师,硕士,主要从事电力系统自动化方面的研究工作(E-mail: 13923364252@139.com);

朱五洲(1975—),男,广东河源人,高级工程师,主要从事输电电缆运维工作(E-mail: 1103466520@qq.com);

孟安波(1971—),男,重庆梁平人,教授,博士,通信作者,主要研究方向为人工智能(E-mail: menganbo@vip.sina.com)。

Improved Faster R-CNN method and its application in recognition of cable tunnel water accumulation

CUI Jiangjing¹, HUANG Shuntao¹, QIU Wei¹, PEI Xingyu¹, ZHU Wuzhou¹, MENG Anbo²

(1. Zhuhai Power Supply Bureau of Guangdong Power Grid, Zhuhai 519000, China;

2. School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Aiming at the water accumulation problem in cable tunnel, an improved Faster R-CNN (Faster Region-based Convolutional Neural Network) method is proposed and applied in the recognition of cable tunnel water accumulation. Considering that the regularization parameter selection of Softmax may have problems with calculating the probability, the SVM (Support Vector Machine) is used to classify images to improve the classification accuracy. The RPN (Region Proposal Network) is used to extract proposals from the original images of cable tunnel water accumulation, and then the detection network of Fast R-CNN is used to carry out image recognition, SVM classification and location refining. The experiment results show that the proposed algorithm has the advantages of fast calculation speed, high recognition accuracy and high efficiency in practical engineering.

Key words: cable tunnel; water accumulation recognition; region proposal; convolutional neural network; support vector machines

附录 A

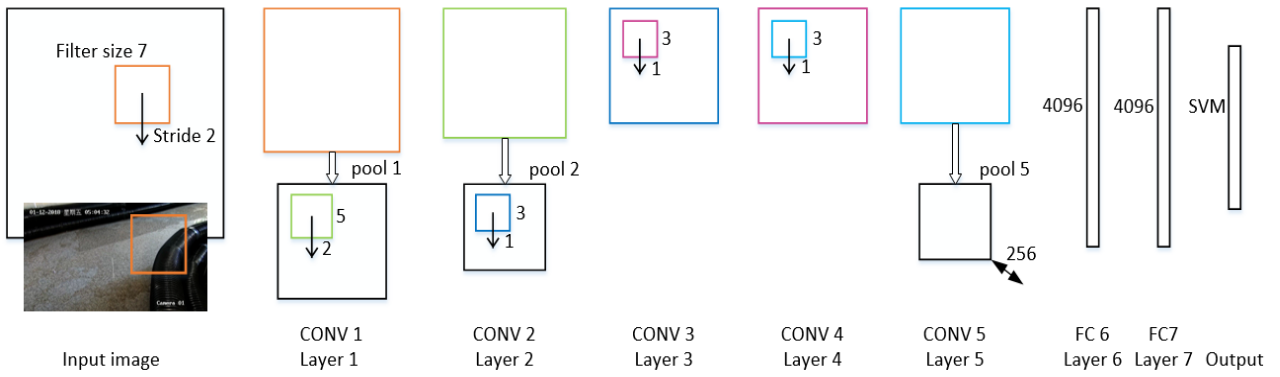


图 A1 典型的 ZFnet 结构图

Fig.A1 Typical ZFnet structure

附录 B





图 B1 积水定位识别结果

Fig.B1 Water Recognition Result



卷积层数增加

图 B2 卷积中间层特征图可视化输出

Fig.B2 Visual feature map of intermediate convolutional layer