

面向计算机网络监控的图像处理与识别算法研究

郝春云¹

HAO Chunyun

摘要

为实现公共场域下网络监控运动目标的跟踪识别,通常利用网络摄像机、红外传感器等装备采集不同时间点的帧图像。而后基于改进 SSD、CNN 或 DAN 深度学习算法模型,利用候选框框选待测图像目标像素、扩展卡尔曼滤波或图聚类法滤除干扰噪声,但以上卷积神经网络模型的目标跟踪监测,容易出现图像帧或像素特征提取的重复问题。基于此,选用 Faster-RCNN (faster region convolutional neural network) 深度学习算法模型,设置涵盖卷积层、池化层、全连接层的图像处理层级,基于 HOG (histogram of oriented gradient) 方向梯度直方图将红外传感器监测到目标图像转化为灰度图、提取监测物体的整体特征,而后基于 Faster-RCNN 深度学习算法作出图像动态目标的锚框特征谱输出、数据集学习分析,得到公共空间的物体运动位置,提高计算机网络监控的图像处理与识别准确率。

关键词

网络监控; 图像处理; 深度学习算法

doi: 10.3969/j.issn.1672-9528.2024.11.017

0 引言

复杂光照环境下,采用可见光传感器,摄像机采集的动态目标图像会产生纹理失真或噪声。但基于红外传感器的图像目标热成像识别,辅以 Haar 小波矩形特征提取运动目标的图像结构、对比度信息,可最大程度保留监测图像目标的细节。此外,传统基于光流法、帧间差法和背景差法的剔除图像背景监测方案,通常存在帧图像像素运算量大、图像内容监测与处理不全、目标噪声过多等问题,这一情况下引入 Faster-RCNN (faster region convolutional neural network) 卷积神经网络算法的模式分类目标识别方式,将大图像切割为小的切片,相邻小的切片间存在一定重合区域,针对重合区域是否存在目标对象,作出对检测框图像的筛选提取,对框定的帧图像目标完成多层卷积迭代、图像池化与归一化的处理运算,将处理识别后的帧图像数据点与基准图像作出匹配,以实现公共空间场域运动目标对象的筛选与识别操作。

1 计算机网络监控的红外运动目标图像感知与处理

1.1 基于红外传感器的网络监控目标图像感知

相比可见光摄像机的图像目标拍摄分析而言,基于热辐射成像原理的红外传感器目标对象感知识别,主要按照物体热辐射能量的高低显示图像部分的亮暗,红外图像转换为灰

度图后的像素灰度级少,灰度值更集中,一般包括图像监测、目标识别两个步骤,具有探测距离远、隐蔽性强及抗干扰能力强等优势。

基于红外传感器的网络图像监控感知,通常先根据前景目标,背景图像间的热量差,将感知目标发出的红外信号转换为电信号,然后经过信号放大、数据控制等处理后在电路传输,最后在计算机控制显示面板将电信号转换为红外图像信号。当利用红外传感器完成网络监控目标图像的感知后,更多基于深度学习的目标检测算法设置候选区域预测框,对候选框框定的目标对象作出复杂背景过滤、运动目标对象提取。

1.2 基于 HOG 方向梯度直方图的图像灰度化处理

根据红外传感器感知监测的 24 位真彩色高清图像,基于 HOG 方向梯度直方图对 R 、 G 、 B 三原色分量进行加权平均得到灰度值。按照 cv2.cvtColor 颜色空间转换 $G_{\text{ray}} = w_R R + w_G G + w_B B$ 的 RGB 灰度化处理公式,对输入单帧图像作出灰度化处理,计算特定图像区域的像素方向梯度值,若干个像素 (cell) 块可组合成重叠的黑块 (block),将多个重叠黑块作出梯度直方向量的组合,得出沿着某一方向的像素累积梯度值,这一梯度向量为大的 HOG 特征向量,由此完成 RGB 彩色图像到 GRAY 灰度图像的转换^[1]。一般红色、绿色和蓝色通道的权值分别设为 0.3、0.59 和 0.11,灰度化处理后的图像像素不受复杂光照条件影响。

1. 南昌理工学院 江西南昌 330044

2 基于 Haar 小波矩形特征分类器、AdaBoost 算法的图像结构提取

Haar 小波矩形特征分类器为 AdaBoost 级联分类器中若干个弱分类器之一, 基于 Haar 小波的矩形特征提取图像运动目标的外形信息、纹理信息, 通过多个弱分类器级联的方式减少目标图像监测运行时间^[2]。假设输入灰度化处理后的图像像素的空间位置值为 $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 图像像素纹理特征标识为 $\{z_1, z_2, \dots, z_n\}$; 设置图像像素纹理特征标识的初始化权重为 $w_i=1/N$, 多个 Haar-like 弱分类器小波矩阵特征为 h_{iz} ; 且 Haar-like 弱分类器的特征阈值设置为 θ_i , 偏置方向设置为 $\text{pos}_i=\{1, -1\}$, 其中 1 或 -1 表示为矩形选框区域内图像像素分配的正向权重、反向权重, 用于控制图像像素纹理特征分类训练的方向; θ_i 表示弱分类器权重偏置预测的阈值, 则经由 Haar-like 弱分类器小波矩阵特征图像处理后得到的分类结果为:

$$\text{pos}_i = \begin{cases} 1 & \text{pos}_i h_{iz} < \text{pos}_i \theta_i \\ -1 & \text{pos}_i h_{iz} \geq \text{pos}_i \theta_i \end{cases} \quad (1)$$

式中: $\text{pos}_i=1$ 表示 Haar-like 弱分类器对图像像素纹理特征选择的方向正确, 则 $w_i(z)$ 为正权重, (x, y) 为待选择的图像区域位置; 否则表明 Haar-like 弱分类器的图像分类识别方向错误、待选择的图像像素不是目标图像区域。在 $w_i(z)$ 为正权重情况下, 基于 AdaBoost 集成学习算法组合多个弱分类器进行目标样本的分类训练, 组合前 t 个弱分类器为一个强分类器 $H_t(z)$, 图像像素纹理特征的样本作出 s 次循环迭代训练。假设图像像素为被选择目标图像的样本个数为 m , 被淘汰的图像像素非目标图像的样本个数为 l , 则得到第 i 个图像像素的纹理特征权值, 特征权值归一化后的计算结果^[3]为:

$$w_i(z) = \begin{cases} 1/(2m) \\ 1/(2l) \end{cases} \quad (2)$$

$$q_i(n) = w_i(z) / \sum_{i=1}^n [w_1(z) + w_2(z) + \dots + w_i(z)]$$

根据 AdaBoost 强分类器对不同图像像素分类的纹理特征权值, 将不属于目标图像的待选择图像像素加入到非真目标样本中, 对样本分类错误的特征权值作出加权累加, 得到强分类器计算的加权误差, 具体计算公式为:

$$\xi_i = \sum_{i=1}^n q_i(n) |w_i(x) - h_i(x)| \quad (3)$$

3 基于 Faster-RCNN 算法模型的网络监控图像目标识别

Faster-RCNN 算法是在 CNN 卷积神经网络算法基础上, 引入 RPN 网络生成高质量的区域候选框, 用于帧图像目标的框定与识别, 主要包括卷积层、池化层、全连接层等组成结构。将 Faster-RCNN 算法应用到帧图像像素目标的感知识别中, 通常涵盖卷积运算的特征提取、降采样池化运算、全连接分类运算的执行流程, 在池化处理完成后基于 Softmax 分类器

对帧图像检测目标的特征像素作出分类整合操作, 识别并得到图像目标对象的全局信息, 具体如图 1^[4] 所示。




图 1 基于 Faster-RCNN 算法模型的网络监控目标识别流程

3.1 卷积特征提取运算

以计算机网络监控的灰度图为主作出待测帧图像像素卷积计算, 假设输入的目标对象帧图像大小为 1280×720 , 首先根据前景目标像素的整体灰度, 设置合理的灰度阈值 T , 按照 $g(i,j) = \begin{cases} 0 & \text{Gray}(i,j) < T \\ 255 & \text{Gray}(i,j) \geq T \end{cases}$ 的计算公式作出灰度图像的二值化分割; 然后基于 Selective Search 选择性搜索方法作出图像区域分割, 分割后的区域基于卷积核对框选的像素作出卷积运算。

通常设置卷积核大小为 3×3 , 黑白像素值设为 0(1), 由卷积层滑动窗口候选框按照 $\text{stride}=1$ 的单位位移, 在被测目标特征图区域由左至右滑动, 将滑动框选的像素矩阵与卷积核相对应的数字相乘后求和, 得出一次卷积输出的像素特征提取值。然后仍按照 $\text{stride}=1$ 的步长长度重复该卷积计算步骤, 在识别到目标图像像素末端后, 回到下方起始位置继续该卷积计算过程。卷积核越小候选框卷积迭代的目标像素分辨率越高, 比较卷积计算前后目标图像区域特征像素点的变化情况, 计算公式为:

$$\text{conv}(x, y, g) = \sum_{p,q=3 \times 3} w \cdot (x - s_x, y - s_y, G - g) + b \quad (4)$$

式中: w 表示卷积核权重; (s_x, s_y) 表示多次滑动窗口卷积运算后得到的目标像素矩阵; G 和 g 分别表示目标图像像素的原始灰度特征矩阵、更新后的灰度特征矩阵; b 表示算法的偏置参量, 用于控制卷积运算的偏置。由于被测目标图像像素会受到光照强度的影响, 而发生像素灰度值的变化 (通常为灰度衰减), 所以引入 Sigmoid 激活函数的 Δleak 作为灰度特征变量, 更新以上的卷积计算特征提取结果^[5], 计算公式为:

$$\text{conv}(x, y, g) = \sum_{p,q=3 \times 3} \sum_t w \cdot (x - s_x, y - s_y) + w \cdot (G - g + \Delta\text{leak}) \quad (5)$$

3.2 降采样池化运算

在基于候选框完成图像目标像素的卷积提取运算后, 将提取的图像输入到层数为 2、步长 $\text{stride}=3$ 的池化层, 设置 kernel 池化核大小为 3×3 , 沿某一方向作出区域像素的最大

池化处理,完成卷积提取像素灰度上下左右相邻像素的池化聚合计算。在池化窗口内引入 F' 矩阵接收区域最大灰度特征值进行汇聚,映射与降维候选区域的采样目标图像维度,形成更新后目标图像新的位置信息 (x^{t+1}, y^{t+1}) 、像素灰度特征结果 F^{t+1} ,具体计算公式分别为:

$$(x^{t+1}, y^{t+1}) = (s_x^t, s_y^t) - \Delta\text{leak}^{t+1} \sum_g F^{t+1} \quad (6)$$

$$F^{t+1} = \alpha \cdot w_g^{t+1} \sum_g (G - g + \Delta\text{leak}) \quad (7)$$

式中: (x^{t+1}, y^{t+1}) 表示更新后目标图像的位置信息; (s_x^t, s_y^t) 表示在 t 时刻卷积运算后的目标像素矩阵; F^{t+1} 和 w_g^{t+1} 分别表示目标像素灰度的池化运算函数、池化权重; α 表示正的常数值,一般为 $[0,1]$ 之间的常量,池化后得到的灰度属性矩阵特征值具有平移不变性。

3.3 全连接层分类运算处理

在全连接层基于 Softmax 分类器工具设定像素灰度的分类标准,假设池化后目标像素的灰度等级为 m ,若池化像素类型 m 的概率分布服从 $p[(x', y') | g, \theta] = e^{\theta_m g} / \sum_{i=1}^m e^{\theta_i g}$ 的计算公式,这里 $e^{\theta_m g}$ 表示目标像素前向、后向传播时与特定类中心之间的距离, θ_m 表示目标像素偏离类中心的角度。那么基于 ReLU (rectified linear unit) 函数的 $f(g) = \max(0, g)$ 映射规则建立稀疏矩阵,设定目标像素前向、后向传播的阈值,将已赋予权值、小于灰度阈值的像素特征置为0,过滤掉目标像素特征值为0的冗余像素点,保留为正值的目标像素值^[6]。

在基于 $p[(x', y') | g, \theta] = e^{\theta_m g} / \sum_{i=1}^m e^{\theta_i g}$ 的计算公式完成不同等级目标像素灰度的分类后,基于 Loss function 损失函数作出目标像素灰度与后台数据库基准图像的特征匹配分析,将相似度最大的候选区域设定为 $r_t = r_i \cup R$,计算公式为:

$$\text{Loss}(F^{t+1}) = \frac{1}{m} \sum_{i=1}^m [(x^{t+1}, y^{t+1}) \log(G' - g^t) + (1 - (x^{t+1}, y^{t+1})) \log(1 + g^t - G')] \quad (8)$$

式中: G' 表示后台数据库基准图像匹配的真实灰度值, g^t 表示 t 时刻的区域像素灰度值, m 表示训练样本的像素灰度分类数。当 G' 、 g^t 的值趋近于相等时, Loss(F^{t+1}) 损失函数值越小,交叉熵损失值越大。根据输出目标像素灰度误差与迭代学习率成正比的关系,可得只有 Loss(F^{t+1}) 的值越小,目标像素灰度与基准图像像素灰度的匹配误差才越小、分类精度越高。因此在得出相似度最大的候选区域 r_t 后,将候选区域 r_t 的像素添加至相似集合 O 中,并基于以上公式(6)(7)计算与候选区域 r_t 相邻的区域的相似度,重复这一迭代过程直到集合 O 的像素不再增加为止。

4 仿真实验及结果分析

4.1 实验环境设置

基于计算机网络监控摄像机,在公共现实空间拍摄1 min 内的多帧动态图像作为目标感知识别的对象,输入的

图像分辨率为 1280×720 ,依照 PASCAL VOC 数据集格式设置图像名称、类别、选框中心点,设置卷积单元层数 $M=5$,池化层数 $M=2$,池化值 $P=3$,全连接层数 $M=2$,光照强度下图像帧的灰度特征变量 $\Delta\text{leak}=[5,10]$ 。在 MATLAB R2022a 仿真软件支持下,基于 Faster-RCNN 深度学习算法的 RCNN 回归器,对目标图像像素灰度作出选框修正与特征提取,使用 Softmax 分类器将目标像素灰度与基准图像灰度作出特征匹配分析(如图2),记录迭代训练过程中目标像素点灰度值的动态变化情况,并引入 YOLO 深度卷积网络算法作为对比实验。




图2 基于 Faster-RCNN 深度学习算法的图像目标识别

4.2 实验结果分析

针对输入的计算机监控行人运动图像,设定算法最大迭代次数为100次,基于卷积层候选框进行滑动窗口的像素灰度特征提取,将提取图像输入层数为2、步长 $\text{stride}=3$ 的池化层作出下采样降维计算。然后利用多个分类器作出目标像素灰度的分类运算,将分类后的目标像素加权生成全体样本,得出目标像素灰度与基准图像灰度的特征匹配误差,损失函数值越小即表明算法在目标像素检测方面的误差越小,不同算法的帧图像目标像素识别的迭代训练结果如表1所示。

表1 输入行人检测事件的数据集图像特征提取训练结果

算法模型	Precision /%	AP /%	F-measure /%	Loss 损失值
YOLO 深度卷积网络算法	84.62	82.37	69.24	2.25
Faster-RCNN 深度学习算法	97.10	93.65	88.53	0.76

根据表1的仿真实验结果可得出,经过多次 Softmax 分类器迭代训练后得到的目标像素灰度识别精度为97.10%,平均精度值AP为93.65%,F值(F-measure)为88.53%,表明基于 Faster-RCNN 深度学习算法的图像目标像素灰度识别,在识别准确率、召回率方面均优于 YOLO 深度卷积网络算法。且多次迭代训练后, YOLO 深度卷积网络算法的目标监测损失函数值为2.25。基于 Faster-RCNN 算法的目标像素灰度损失函数值在1以内,因而本文算法的像素灰度分类准确率优于 YOLO 算法,可被用于计算机网络监控图像的处理与识别运算,具有明显的迭代训练优越性。

一种依据簇首可选度进行簇首选举的车联网分簇算法

蒋守凤¹

JIANG Shoufeng

摘要

车联网中车辆的高速移动性导致网络拓扑具有强动态变化性,簇首的频繁更换会降低网络整体性能。为选举出相对稳定的簇首,考虑模糊理论与车联网分簇算法中多因素制约簇首选举的契合性,文章提出了一种依据簇首可选度进行簇首选举的车联网分簇算法,将车辆节点间距离、车辆相对移动速度和车辆的相对方向数作为簇首选举的影响因素,并对簇首选举、簇建立和簇维护过程进行了设计。仿真结果表明,所提的算法中簇首选举成功后维持时间相对较长,有利于车联网网络稳定性。

关键词

车联网; 车辆通信; 模糊理论; 簇首选举; 分簇算法

doi: 10.3969/j.issn.1672-9528.2024.11.018

0 引言

车联网(internet of vehicles, IoV)被定义为由车辆的位置、行驶路线、速度等信息构成的信息化交通网络,依靠移动通信技术,实现车与车、车与设备等其他事物的互联,网络规模庞大,是未来智能交通系统的重要组成部分^[1]。在城区交通系统中,道路状况相对复杂,特别是道路交叉地段

有十字、环路等路况,车辆有直行、转向和等待等情况,有数百甚至更多的车辆行驶、聚集^[2]会有数百甚至更多的车辆行驶和聚集,并具有速度快、移动性强等特点^[3],为缓解车辆对路边单元(road side unit, RSU)的信息交互,减少数据传输的压力,车联网中车辆之间经常采用车对车(vehicle-to-vehicle, V2V)通信,降低整个车联网的数据传输消耗。

车联网通信可通过分簇算法将车辆进行逻辑划分成簇,按某种方法选定簇首作为簇内车辆与RSU通信的媒介,寻找V2V和车辆与RSU之间最优路径,节省网络开销,满足车联网低时延、高可靠性的要求^[4]。由于车联网拓扑动态变化

1. 内蒙古电子信息职业技术学院 内蒙古呼和浩特 010070

[基金项目] 2022 年内蒙古电子信息职业技术学院科研项目“车联网分簇算法的研究”(KZY202203)

5 结语

随着城市公共空间智能计算机网络监控系统的部署,对于特定环境下目标对象的感知识别成为监控管理关注的重要问题。基于计算机网络监控摄像机、Faster-RCNN深度学习算法,将采集的帧图像转换为可识别像素特征的纹理图、灰度图,利用RCNN回归器作出目标图像像素的框选与灰度特征提取,在池化层按照设定的池化窗口大小、移动步长作出下采样降维计算,并使用Softmax分类器将目标像素灰度、基准图像灰度形成特征匹配,得到的目标像素灰度识别精度更高,损失函数值更优,能够实现更良好的网络监控目标识别效果。

参考文献:

[1] 周永丽. 基于大数据技术的视频监控应用探讨[J]. 现代工业经济和信息化, 2019, 19(5):63-64+77.

- [2] 李楠. 智慧监控在高速公路信息化中的应用[J]. 中国交通信息化, 2019(5):32-34.
- [3] 姜旭东, 宋本扬, 杜泽永, 等. 基于图像识别技术的龙溪口航电工程智能视频监控系统设计[J]. 水运工程, 2023(10):183-187.
- [4] 王景. 基于深度学习算法的视频监控人脸识别系统研究[J]. 长江信息通信, 2023, 36(8):128-131.
- [5] 赵杰. 基于深度学习的人脸识别算法在视频监控的应用研究[J]. 电子设计工程, 2023, 31(13):182-186.
- [6] 刘嘉敏, 郑超, 张丽梅, 等. 基于图像重构特征融合的高光谱图像分类方法[J]. 中国激光, 2021, 48(9):203-212.

【作者简介】

郝春云(1985—), 女, 河南周口人, 硕士, 讲师, 研究方向: 计算机科学与技术。

(收稿日期: 2024-06-06)