

# 基于改进 YOLOv3 算法的公路车道线检测方法

崔文靓<sup>1</sup> 王玉静<sup>1</sup> 康守强<sup>1</sup> 谢金宝<sup>1</sup> 王庆岩<sup>1</sup> MIKULOVICH Vladimir Ivanovich<sup>2</sup>

**摘要** 针对 YOLOv3 算法在检测公路车道线时存在准确率低和漏检概率高的问题, 提出一种改进 YOLOv3 网络结构的公路车道线检测方法. 该方法首先将图像划分为多个网格, 利用 K-means++ 聚类算法, 根据公路车道线宽高固有点, 确定目标先验框数量和对应宽高值; 其次根据聚类结果优化网络 Anchor 参数, 使训练网络在车道线检测方面具有一定的针对性; 最后将经过 Darknet-53 网络提取的特征进行拼接, 改进 YOLOv3 算法卷积层结构, 使用 GPU 进行多尺度训练得到最优的权重模型, 从而对图像中的车道线目标进行检测, 并选取置信度最高的边界框进行标记. 使用 Caltech Lanes 数据库中的图像信息进行对比试验, 实验结果表明, 改进的 YOLOv3 算法在公路车道线检测中平均准确率 (Mean average precision, mAP) 为 95%, 检测速度可达 50 帧/s, 较 YOLOv3 原始算法 mAP 值提升了 11%, 且明显高于其他车道线检测方法.

**关键词** 车道线检测, 深度学习, YOLOv3, K-means++, 计算机视觉

**引用格式** 崔文靓, 王玉静, 康守强, 谢金宝, 王庆岩, MIKULOVICH Vladimir Ivanovich. 基于改进 YOLOv3 算法的公路车道线检测方法. 自动化学报, 2022, 48(6): 1560-1568

**DOI** 10.16383/j.aas.c190178

## Road Lane Line Detection Method Based on Improved YOLOv3 Algorithm

CUI Wen-Liang<sup>1</sup> WANG Yu-Jing<sup>1</sup> KANG Shou-Qiang<sup>1</sup> XIE Jin-Bao<sup>1</sup>  
WANG Qing-Yan<sup>1</sup> MIKULOVICH Vladimir Ivanovich<sup>2</sup>

**Abstract** Aiming at the problem that the YOLOv3 algorithm has low accuracy, high probability of missed detection when detecting road lane lines, a road lane detection method for improving YOLOv3 network structure is proposed. At first, the method divides the image into multiple grids, and uses the K-means++ clustering algorithm to determine the number of target priori boxes and the corresponding value according to the inherent characteristics of the road lane line width and height. Then, according to the clustering result, the network anchor parameter is optimized to make the training network have certain pertinence in lane line detection. At last, the features extracted by the Darknet-53 are spliced, the network structure of the YOLOv3 algorithm is improved, and the GPU is used for multi-scale training to obtain the optimal weight model, thereby detecting the lane line target in the image and selecting the bounding box with the highest confidence to mark. Using the image information in the Caltech Lanes database for comparison experiments, the experimental results show that the improved YOLOv3 algorithm's mean average precision is 95% in road lane detection, the improved detection speed can be achieved 50 frame/s, which is 11% higher than the original algorithm and significantly higher than other lane detection methods.

**Key words** Lane detection, deep learning, YOLOv3, K-means++, computer vision

**Citation** Cui Wen-Liang, Wang Yu-Jing, Kang Shou-Qiang, Xie Jin-Bao, Wang Qing-Yan, Mikulovich Vladimir Ivanovich. Road lane line detection method based on improved YOLOv3 algorithm. *Acta Automatica Sinica*, 2022, 48(6): 1560-1568

车道线检测是智能驾驶领域的关键技术之一,

收稿日期 2019-03-21 录用日期 2019-05-23

Manuscript received March 21, 2019; accepted May 23, 2019  
黑龙江省自然科学基金 (LH2019E058), 黑龙江省本科高校青年创新人才培养计划 (UNPYSCT-2017091), 黑龙江省普通高校基本科研业务专项基金资助项目 (LGYC2018JC022) 资助

Supported by Natural Science Foundation of Heilongjiang Province (LH2019E058), University Nursing Program for Young Scholars with Creative Talents in Heilongjiang Province (UNPY-SCT-2017091), and Fundamental Research Foundation for Universities of Heilongjiang Province (LGYC2018JC022)

本文责任编辑 白翔

Recommended by Associate Editor BAI Xiang

1. 哈尔滨理工大学电气与电子工程学院 哈尔滨 150080 中国  
2. 白俄罗斯国立大学 明斯克 220030 白俄罗斯

1. School of Electrical and Electronic Engineering, Harbin University of Science and Technology, Harbin 150080, China 2. School of Belarusian State University, Minsk 220030, Belarus

广泛应用于汽车辅助驾驶系统、车道偏离预警系统以及车辆防碰撞系统中. 随着计算机科学、人工智能和目标检测技术的飞速发展, 研究端到端的智能化车道线检测方法是自动驾驶领域的一条全新途径<sup>[1-6]</sup>. 因此, 研究基于深度学习的公路车道线检测方法对于提高公路交通安全具有重要意义.

对于车道线检测问题, 国内外学者已开展了相关研究, 取得了一定的研究成果<sup>[7-9]</sup>. 基于传统方法的车道线检测实质是通过图像特征和车载传感器来感知车辆当前环境并进行建模<sup>[10]</sup>. 存在检测速度慢、检测精度差、抗环境干扰能力差等问题. 文献 [11]

在常见的直线模型、多项式曲线模型、双曲线模型和样条曲线模型等二维模型的基础上, 提出了基于车道线特征的检测方法. 文献 [12] 在霍夫变换的基础上使用道路拟合算法精确标出道路俯视图中的车道线位置, 该方法可有效改善图像中其他车辆位置对检测效果的影响. 文献 [13] 提出了基于立体视觉的路缘边线检测方法, 该方法在真实路况条件下具有较强的稳定性. 文献 [14] 提出了基于车道线颜色和方向的几何特征结构化检测方法, 综合颜色和方向两个方面的信息对车道线进行拟合, 实现了车道线的检测. 文献 [15] 提出了基于视觉更具有鲁棒性的检测方法, 通过并行约束和多路模型拟合的方法提高了车道线检测的准确性.

近年来, 卷积神经网络 (Convolutional neural network, CNN) 在图像分类、目标检测、图像语义分割等领域取得了一系列突破性的研究成果. 基于深度学习方法的的车道线检测常通过卷积神经网络对图像特征进行学习、分类和检测<sup>[16-17]</sup>. 文献 [18-20] 先后提出了区域卷积神经网络、快速区域卷积神经网络和超快区域卷积神经网络, 将网络应用到目标检测问题中, 并在检测速度和准确率方面不断提高. 文献 [21] 将改进的 CNN 应用在公路车道线检测方面, 测试效果较霍夫变换和随机抽样一致算法大幅提升. 为了进一步提高目标检测的速度, 文献 [22] 又提出了一种端到端的目标检测算法 YOLO (You only look once), 将目标检测问题转化为回归问题, 进而将目标和背景进行更好的区分. 文献 [23] 提出的 YOLOv2 算法在简化网络结构的同时提高了目标检测的准确率. 文献 [24] 将 YOLOv2 算法应用在无人机航拍定位领域并得到理想效果, 在一定程度上验证了算法的普适性. 文献 [25] 提出了一种端到端的可训练网络 VPGNet (Vanishing point guide network), 通过对大量图片的训练得到图像中的车道线位置, 为车道线检测问题提供了一种全新的解决思路. 文献 [26] 提出的 YOLOv3 算法借鉴了残差神经网络的思想, 成为目标检测算法中集检测速度和准确率于一身的优秀方法, 但其较 YOLOv2 算法相比, 网络结构更为复杂, 卷积层数目大幅增加, 加大了小目标在深层卷积过程中特征消失的风险.

为提高算法在车道线检测方面的适用性和准确性, 本文在 YOLOv3 算法的基础上进行改进, 采用随机性更小的 K-means++ 算法替代 K-means 算法对车道线标签进行聚类分析, 确定最优的聚类数目和相应的宽高值, 并据此修改 YOLOv3 算法中的 Anchor 参数. 针对车道线检测实时性和检测目标较小的特点, 改进 YOLOv3 算法卷积层结构, 在保

证检测准确率的同时, 提高算法的检测速度, 从而实现公路车道线的检测.

## 1 YOLOv3 算法

### 1.1 YOLOv3 算法原理

YOLOv3 算法将原输入图像划分为  $S \times S$  的网格, 分别在每个网格中预测  $B$  个边界框, 以对  $C$  类目标进行检测, 输出每类目标的边界框且分别计算每个边界框的置信度. 置信度由每个网格中包含检测目标的概率和输出边界框的准确度共同确定, 其中输出边界框的准确度定义为预测边界框与真实边界框的交并比 (Intersection over union, IOU), 其计算式为

$$conf = \Pr(obj) \times IOU_{\text{perd}}^{\text{truth}} \quad (1)$$

式中,  $conf$  为边界框的置信度,  $\Pr(obj)$  为网格中含有某类目标的概率.

每个网格预测的类别置信度为

$$\Pr(class_i | obj) \times \Pr(obj) \times IOU_{\text{perd}}^{\text{truth}} \quad (2)$$

式中,  $i = 1, 2, \dots, I$ ,  $I$  为检测类别数.

通过设定阈值, 将类别置信度低于阈值的边界框剔除, 并对类别置信度高于阈值的边界框进行非极大抑制后得到最终的边界框. 预测得到的边界框包含  $x$ ,  $y$ ,  $w$  和  $h$  四个参数, 为了加快网络学习速度、减少奇异样本数据的影响, 对以上四个参数进行归一化处理. 如图 1 所示, 设  $S = 7$ , 将整幅图像划分为  $7 \times 7$  的网格, 虚线区域为边界框位置, 点  $(x_0, y_0)$  为边界框中心点坐标, 中心点所在网格坐标为  $(row, col)$ ,  $width_{\text{img}}$  和  $height_{\text{img}}$  分别为整幅图像的宽度和高度,  $width_{\text{box}}$  和  $height_{\text{box}}$  分别为边界框的宽度和高度. 归一化过程如下.

1) 边界框宽高归一化处理

$$w = \frac{width_{\text{box}}}{width_{\text{img}}} \quad (3)$$

$$h = \frac{height_{\text{box}}}{height_{\text{img}}} \quad (4)$$

2) 中心点坐标归一化处理

$$x = x_0 \times \frac{s}{width_{\text{img}}} - col \quad (5)$$

$$y = y_0 \times \frac{s}{height_{\text{img}}} - row \quad (6)$$

归一化处理后, 由于在每个网格中可得到  $x$ ,  $y$ ,  $w$ ,  $h$ ,  $conf$  五个预测量和  $C$  个类别中的一类, 因此网络的输出大小为  $S \times S \times (5 \times B + C)$ .

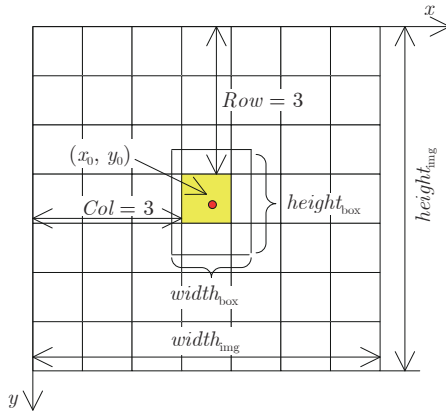


图 1 边界框参数归一化处理

Fig.1 The normalization of boundary box parameters

## 1.2 YOLOv3 算法损失函数的计算

损失函数用来表征模型的预测值与真实值间的不一致程度,是决定网络效果的重要参数之一. YOLOv3 算法的损失函数的设计主要从边界框坐标预测误差、边界框的置信度误差、分类预测误差这三个方面进行考虑. 损失值越小说明模型的鲁棒性越好. YOLOv3 损失函数计算式为

$$\begin{aligned}
 Loss = & \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbf{1}_{ij}^{\text{obj}} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] + \\
 & \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbf{1}_{ij}^{\text{obj}} [(\omega_i - \hat{\omega}_i)^2 + (h_i - \hat{h}_i)^2] + \\
 & \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbf{1}_{ij}^{\text{obj}} (C_i - \hat{C}_i)^2 + \\
 & \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbf{1}_{ij}^{\text{noobj}} (C_i - \hat{C}_i)^2 + \\
 & \sum_{i=0}^{S^2} \mathbf{1}_i^{\text{noobj}} \sum_{c=0}^C [p_i(c) - \hat{p}_i(c)]^2
 \end{aligned} \quad (7)$$

式中,  $S$  为图像的划分系数,  $B$  为每个网格中所预测的边界框个数,  $C$  为总分类数,  $p$  为类别概率,  $c = 0, 1, \dots, C$  为类别序号,  $i = 0, 1, \dots, S^2$  为网格序号,  $j = 0, 1, \dots, B$  为边框序号,  $x_i$  为第  $i$  个网格中的边界框中心点横坐标,  $y_i$  为第  $i$  个网格中的边界框中心点纵坐标,  $\omega_i$  为第  $i$  个网格中的边界框的宽度,  $h_i$  为第  $i$  个网格中的边界框的高度,  $\lambda_{\text{coord}}$  为权重系数,  $\lambda_{\text{noobj}}$  为惩罚权重系数.

## 2 YOLOv3 算法网络改进

### 2.1 Darknet-53 特征提取网络结构

YOLOv3 算法在 Darknet-19 和 ResNet 网络

结构的基础上提出了新的特征提取网络 Darknet-53. 该特征提取网络由 52 个卷积层和 1 个全连接层组成, 交替使用  $3 \times 3$  和  $1 \times 1$  大小的卷积核进行卷积, 其网络结构如图 2 所示.

Type	Filters	Size	Output	
Convolutional	32	$3 \times 3$	$256 \times 256$	
Convolutional	64	$3 \times 3/2$	$128 \times 128$	
Convolutional	32	$1 \times 1$		×1
Convolutional	64	$3 \times 3$		
Residual			$128 \times 128$	
Convolutional	128	$3 \times 3/2$	$64 \times 64$	
Convolutional	64	$1 \times 1$		×2
Convolutional	128	$3 \times 3$		
Residual			$64 \times 64$	
Convolutional	256	$3 \times 3/2$	$32 \times 32$	
Convolutional	128	$1 \times 1$		×8
Convolutional	256	$3 \times 3$		
Residual			$32 \times 32$	
Convolutional	512	$3 \times 3/2$	$16 \times 16$	
Convolutional	256	$1 \times 1$		×8
Convolutional	512	$3 \times 3$		
Residual			$16 \times 16$	
Convolutional	1024	$3 \times 3/2$	$8 \times 8$	
Convolutional	512	$1 \times 1$		×4
Convolutional	1024	$3 \times 3$		
Residual			$8 \times 8$	

图 2 Darknet-53 网络结构

Fig.2 The network structure of Darknet-53

Darknet - 53 网络与 Darknet - 19、ResNet-101、ResNet-152 网络相比, 在 Top-1 准确率、Top-5 准确率和每秒钟浮点运算次数三个方面均具有明显优势<sup>[26]</sup>.

### 2.2 YOLOv3 算法网络结构改进

YOLOv3 算法采用 Darknet-53 特征提取网络, 较 Darknet-19 网络相比, 通过加深网络层数提高了特征提取能力. 然而, 随着网络层数的加深, 在提高目标检测的准确性和召回率的同时也会带来如特征消失等问题, 两者存在着一定的相互制衡关系. 为得到更适合车道线目标的深度学习网络, 降低车道线小目标在复杂背景下的漏检风险, 精简 YOLOv3 网络结构, 分别去掉三个 yolo 层前的两组卷积层. 改进后的 YOLOv3 算法共 101 层, 由 69 层卷积层、23 层残差层、4 层特征层、2 层上采样层和 3 层 yolo 层构成, 其网络结构如图 3 所示.

首先, 将图像缩放为 3 通道长宽均为 416 的统一形式, 作为整个网络的输入. 其次, 通过 Darknet-53 网络进行特征提取, 交替使用  $3 \times 3$  和  $1 \times 1$  大小的卷积核进行卷积运算, 为避免随着卷积深度的加深导致的退化问题, 在原始 YOLOv3 网络的基础上适当减少卷积层数, 并在卷积过程中引入残差网

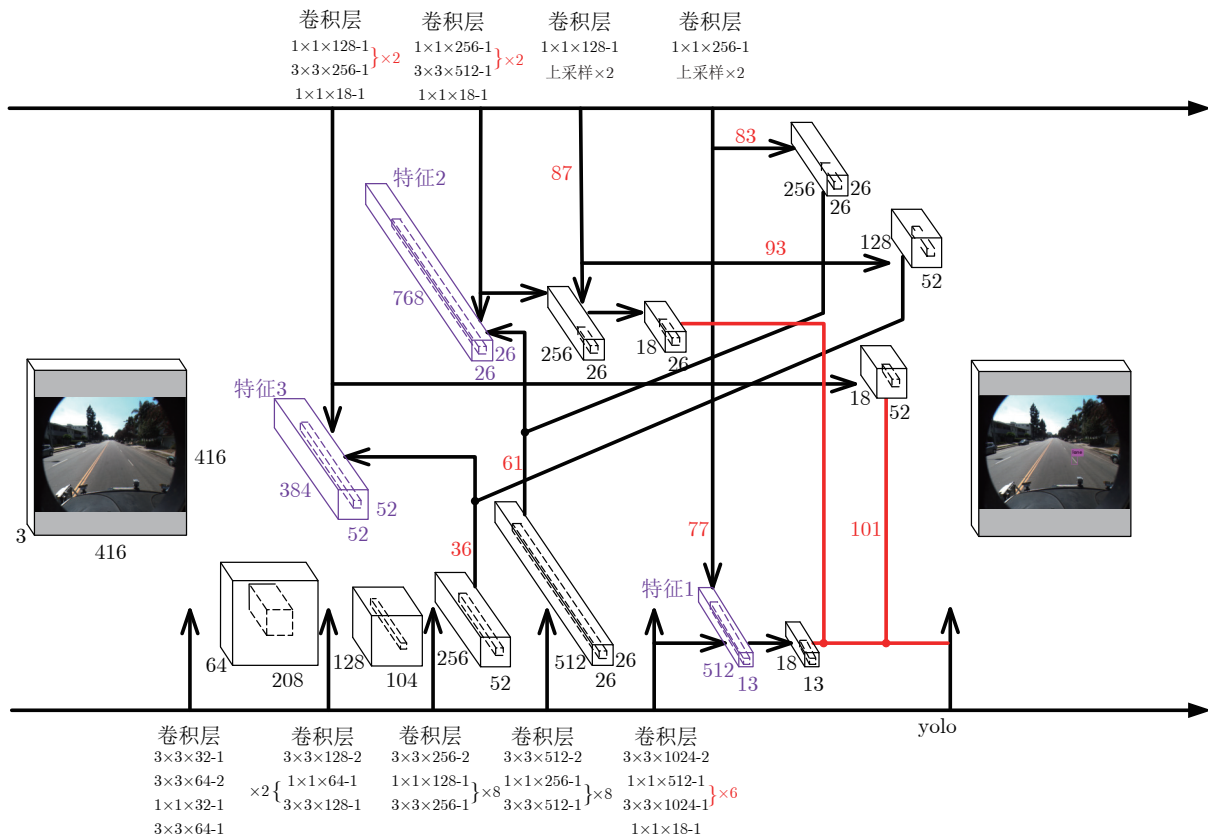


图3 改进 YOLOv3 算法的网络结构

Fig.3 The network structure of the improved YOLOv3 algorithm

络进行恒等映射. 分别将在 77、84 和 94 层得到  $13 \times 13 \times 512$  维、 $26 \times 26 \times 768$  维和  $52 \times 52 \times 384$  维的输出量作为三个特征, 降维后送入 yolo 层, 通过三个尺度的训练得到最终的权重模型. 最后, 将标记出车道线的测试图像进行输出.

### 2.3 YOLOv3 算法网络参数优化

YOLOv3 算法中引入了 Anchor 参数, Anchor 是一组宽高值固定的先验框. 在目标检测过程中, 先验框大小直接影响到检测的速度和准确度, 因此在对公路车道线数据进行训练时, 根据车道线标签固有特点设定网络参数就显得尤为重要. 为适应公路车道线标签的固有特点, 达到最优的训练效果, 使用 K-means++ 聚类算法代替 K-means 聚类算法对车道线标签进行维度聚类分析, 并进行比较. 上述两种算法均为典型的聚类算法, 由于考虑到 K-means 算法在初始聚类中心的选择上存在较大的随机性, 这种随机性会对聚类结果产生一定的影响. 因此, 使用随机性更小的 K-means++ 算法可以有效降低 K-means 算法由于随机选择初始聚类中心所带来的聚类结果偏差.

在使用 K-means 和 K-means++ 两种聚类算法

确定 Anchor 参数的过程中, 为减少由于先验框自身大小所带来的欧氏距离误差, 以车道线标签样本框与先验框间的交并比代替原始算法中的欧氏距离作为目标函数, 目标函数大小表示各个样本与聚类中心间的偏差, 目标函数值越小表示聚类效果越好. 目标函数  $D$  的计算式为

$$D = \min \sum_{i=0}^n \sum_{j=0}^k \left[ 1 - IOU^{box_i}_{cen_j} \right] \quad (8)$$

式中,  $box$  为样本标签的目标框,  $cen$  为聚类中心,  $n$  为样本数,  $k$  为类别数.

## 3 公路车道线检测方法

公路车道线检测方法以 YOLOv3 算法网络结构为基础, 为精简网络结构、减少在小目标检测时由于卷积层深度过深而导致的特征消失问题, 分别去掉三个 yolo 层前的两组卷积层, 使用改进后的网络结构进行训练和测试, 图 4 为公路车道线检测框图, 其检测具体流程如下.

1) 对训练集中的车道线数据进行图像预处理, 将处理后统一形式的图像作为整个训练网络的输入;



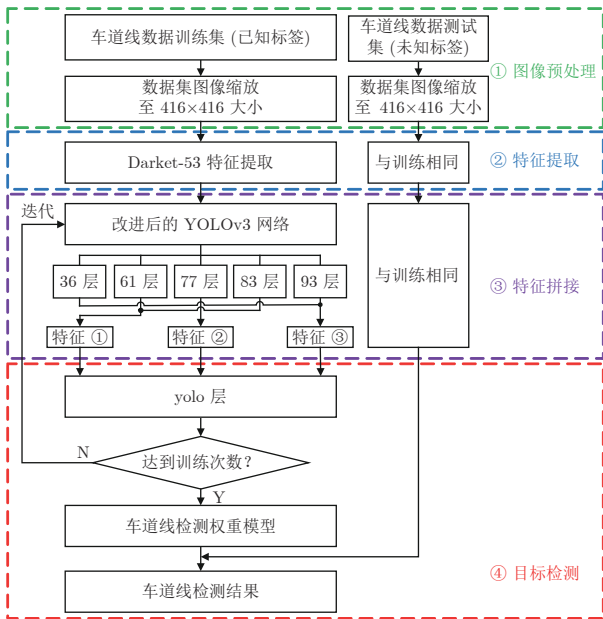


图 4 公路车道线检测框图

Fig.4 The flow chart of road lane line detection

2) 将处理后的图像送入 Darknet-53 网络进行车道线特征提取;

3) 提取第 77 层输出量作为第 1 个特征, 并对该特征进行一层卷积和一次上采样;

4) 将第 83 层输出量与第 61 层输出量进行特征拼接得到第 2 个特征, 并对该特征进行一层卷积和一次上采样;

5) 将第 93 层输出量与第 36 层输出量进行特征拼接得到第 3 个特征;

6) 分别将 3 个特征送入 yolo 层进行训练, 达到训练次数后停止迭代, 并生成最终的权重模型;

7) 将测试集图像输入同一网络, 调用训练得到的权重模型对测试集中图像进行车道线检测, 并输出检测结果.

### 4 实验与分析

#### 4.1 公路车道线数据集标签制作

在目标检测问题中, 训练数据集的选择和原始图像的标签制作是两个至关重要的步骤, 原始图像标签的准确性直接影响训练效果和测试的准确性. 实验中使用美国加利福尼亚理工大学车道线检测数据库作为数据集, 库内共包含 1225 幅公路图片, 分别在科尔多瓦和华盛顿两个地区对两组不同场景进行拍摄采集. 首先将数据库中的图像按照 VOC2007 数据集格式进行整理, 按比例将数据集中的图像随机分为训练集和测试集两类. 其次使用 labelImg 工

具对训练集中的图像进行逐一标记, 并生成与之对应的 xml 格式的目标框位置信息文件. 最后编写 python 程序将 xml 格式的目标框位置信息进行归一化处理并转化为 txt 格式, 作为公路车道线数据集标签.

#### 4.2 公路车道线数据集标签聚类分析

由于 VOC 数据集中并不含有与公路车道线相关的数据, 使用 YOLOv3 原始参数进行训练会对训练时间和训练准确度造成一定影响. 因此需要对公路车道线标签重新进行聚类分析, 从而得到针对车道线检测更具有代表性的 Anchor 参数.

分别使用 K-means 算法和 K-means++ 算法对车道线标签进行维度聚类分析, 随着 k 的不同取值, 目标函数 D 变化曲线如图 5 所示, K-means++ 算法聚类后得到的先验框宽高如表 1 所示.

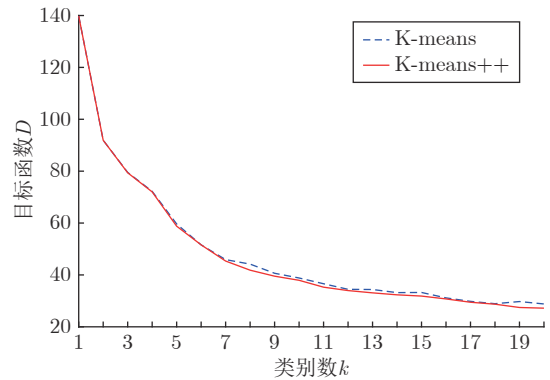


图 5 不同 k 值对应的目标函数

Fig.5 The objective function corresponding to different k values

由图 5 可以看出, 随着 k 值的增大, K-means 算法和 K-means++ 算法目标函数值均逐渐减小, 聚类效果逐渐提高. 然而, 在目标函数下降过程中, K-means++ 算法较 K-means 算法曲线更为平滑, 趋势更为稳定, 在一定程度上减小了聚类偏差. 同时由表 1 结果可以看出在 k 值超过 9 时会出现大小较为相近的聚类结果, 产生冗余, 由此取 k = 9 时的聚类结果作为改进后的参数. 该参数与 YOLOv3 算法原始参数 (10, 13), (16, 30), (33, 23), (30, 61), (62, 45), (59, 119), (116, 90), (156, 98) 和 (373, 326) 相比, 聚类结果较为集中, 且宽高明显小于原始参数, 因此使用 K-means++ 算法聚类得到 Anchor 参数替代原始参数进行训练和测试.

#### 4.3 实验环境配置与模型训练结果

使用 Intel(R)-CPU-E5-2620-V4 处理器, 在

表 1 不同  $k$  值对应的先验框宽高

Table 1 The width and height of priori boxes corresponding to different  $k$  values

$k = 7$	$k = 8$	$k = 9$	$k = 10$	$k = 11$
(6, 9)	(6, 9)	(6, 9)	<b>(5, 12)</b>	(5, 7)
(10, 15)	(8, 12)	(9, 14)	<b>(5, 17)</b>	(7, 11)
(13, 21)	(11, 17)	(12, 18)	(7, 11)	<b>(10, 14)</b>
(19, 30)	(15, 24)	(15, 24)	(10, 14)	<b>(10, 18)</b>
(27, 44)	(20, 32)	(20, 32)	(11, 18)	(13, 20)
(36, 60)	(26, 43)	(26, 43)	(15, 24)	(16, 25)
(141, 10)	(36, 69)	(32, 51)	(20, 32)	(21, 32)
—	(141, 10)	(40, 69)	(27, 44)	(26, 43)
—	—	(141, 10)	(36, 60)	(32, 51)
—	—	—	(141, 10)	(40, 70)
—	—	—	—	(141, 10)

Ubuntu 16.04 操作系统下进行实验. 为了提高计算速度、减少训练时间, 使用 Nvidia GeForce GTX 1080 Ti 显卡、CUDA8.0 和 cuDNN6.0 调用 GPU 进行加速. 训练过程中, 对算法的各项指标进行动态记录, 随着迭代次数的不断增加, 平均损失函数的变化趋势如图 6 所示, 平均交并比变化趋势如图 7 所示.




图 6 平均损失变化曲线  
Fig.6 The change curve of average loss

由图 6 可以看出, 训练开始时的损失函数值约为 1.7, 随着训练迭代次数的增加, 损失值逐渐减小, 趋势逐渐平稳. 迭代至 50 000 次时的损失值在 0.1 上下浮动, 即达到理想效果.

由图 7 可以看出, 训练开始时的平均交并比为 0.58, 随着训练迭代次数的增加, 平均交并比逐渐增大, 说明模型的检测准确率在不断提高, 迭代至 10 000 次后, 平均交并比可保持在 90% 以上. 调用训练生成的权重文件对测试集图片进行测试, 测试后可自




图 7 平均交并比变化曲线  
Fig.7 The change curve of average IOU

动对测试图片中的同向白色实线车道进行标记, 并给出相应标签和置信度, 测试效果如图 8 所示.



图 8 车道线测试效果  
Fig.8 The result of lane line test

#### 4.4 YOLO 算法测试性能对比

对数据集中 250 幅城市路面图像进行分组, 剔除部分不包含车道线目标的图像后, 学习样本和测试样本共计 225 幅, 采用 5 倍交叉验证法, 即学习样本 180 幅, 测试样本 45 幅, 进行实验. 在确定训练权重模型的过程中, 为加快网络的训练速度, 有效防止过拟合, 根据经验设定网络中的权值衰减系数为 0.005, 初始学习率为 0.001, 阈值为 0.25, 迭代次数为 50 200, 类别数为 1, Anchor 参数为表 1 中使用 K-means++ 算法聚类分析后得到的宽高结果.

对相同车道线训练集分别使用 K-means 聚类算法优化 Anchor 参数的 YOLOv3 网络 (YOLOv3-107)、K-means 聚类算法优化 Anchor 参数并改进网络层数 (YOLOv3-101)、K-means++ 聚类算法优化 Anchor 参数 (YOLOv3-K-107)、K-means++ 聚

类算法优化 Anchor 参数并改进网络结构 (YOLOv3-K-101) 等四种网络进行 4 轮实验。

分别使用每轮训练最终生成的权重文件对测试集中 45 幅公路图像的车道线进行检测, 平均测试时间、平均漏检率和平均准确率 (Mean average precision, mAP) 统计结果如表 2 所示. 对单幅图像在 4 组不同网络中得到的测试准确率对比结果如图 9 所示.

表 2 不同网络结构测试性能对比  
Table 2 The test performance comparison of different network structures

网络	平均测试时间 (s)	平均漏检率 (%)	mAP (%)
Caltech <sup>[12]</sup>	—	—	72.3
VPGNet <sup>[25]</sup>	—	—	88.4
YOLOv3-107	0.021	8.9	84.4
YOLOv3-101	0.019	0	89.8
YOLOv3-K-107	0.021	2.2	91.4
YOLOv3-K-101	0.019	0	95.3




图 9 测试集图像在不同网络结构中的检测准确率  
Fig.9 The detection accuracy of test images in different network structures

由表 2 和图 9 可见, 改进网络结构的 YOLOv3-101 网络相比未改进的 YOLOv3-107 网络, 检测的平均测试时间缩短了 2 ms, mAP 提高了 5.4%, 且有效避免了车道线漏检情况; 使用 K-means++ 算法进行聚类的 YOLOv3-K-107 网络, 相比使用 K-means 算法进行聚类的 YOLOv3-107 网络, 平均漏检概率降低了 6.7% 且 mAP 值提高了 7%; 使用 K-means++ 算法进行聚类且精简网络结构的 YOLOv3-K-101 网络效果最优, 其 mAP 值为 95.3%, 测试速度达 50 帧/s 且有效避免了漏检.

## 5 结束语

本文提出了一种改进 YOLOv3 算法的公路车

道线检测方法. 首先使用 K-means++ 算法对 Anchor 参数进行优化, 其次利用 Darknet-53 网络进行特征提取, 最后通过改进的 YOLOv3-K-101 网络实现特征拼接进而实现公路车道线检测, 得到以下结论:

1) 提出了基于深度学习 YOLOv3 算法的公路车道线检测方法, 将深度学习方法与车道线检测问题相结合, 实现了对公路车道线的端到端检测.

2) 根据公路车道线目标自身特点, 使用随机性更小的 K-means++ 聚类算法替代 K-means 算法, 对 YOLOv3 算法中的 Anchor 参数进行优化. 实验表明, 优化后的 YOLOv3-K-107 网络比未优化的网络 mAP 值提高了 7%, 在一定程度上提高了车道线检测的准确性.

3) 针对公路车道线检测中漏检率高的问题, 精简 YOLOv3 网络结构, 改进后的 YOLOv3-101 网络较未改进前, 有效避免了车道线漏检情况, 同时 mAP 值提高了 5.4%, 平均测试时间缩短 2 ms.

4) 结合 2) 和 3), 优化网络参数且改进网络结构的 YOLOv3-K-101 网络, mAP 值达 95%, 较改进前提高了 11%, 检测速度达 50 帧/s, 同时也有效避免了车道线漏检现象.

由于所提方法在对倾斜的车道线检测方面存在局限性, 下一步将采用对竖直目标框进行图像变换的方法或结合语义分割的思路进一步深入研究.

## References

- Zhang Hui, Wang Kun-Feng, Wang Fei-Yue. Advances and perspectives on applications of deep learning in visual object detection. *Acta Automatica Sinica*, 2017, **43**(8): 1289-1305 (张慧, 王坤峰, 王飞跃. 深度学习在目标视觉检测中的应用进展与展望. *自动化学报*, 2017, **43**(8): 1289-1305)
- Yin Hong-Peng, Chen Bo, Chai Yi, Liu Zhao-Dong. Vision-based object detection and tracking: A review. *Acta Automatica Sinica*, 2016, **42**(10): 1466-1489 (尹宏鹏, 陈波, 柴毅, 刘兆栋. 基于视觉的目标检测与跟踪综述. *自动化学报*, 2016, **42**(10): 1466-1489)
- Editorial Department of China Journal of Highway and Transport. Review on China's automotive engineering research progress. *China Journal of Highway and Transport*, 2017, **30**(6): 1-197 (《中国公路学报》编辑部. 中国汽车工程学术进展综述. *中国公路学报*, 2017, **30**(6): 1-197)
- Tian Juan-Xiu, Liu Guo-Cai, Gu Shan-Shan, Ju Zhong-Jian, Liu Jin-Guang, Gu Dong-Dong. Deep learning in medical image analysis and its challenges. *Acta Automatica Sinica*, 2018, **44**(3): 401-424 (田娟秀, 刘国才, 谷珊珊, 鞠中建, 刘劲光, 顾冬冬. 医学图像分析深度学习研究方法研究与挑战. *自动化学报*, 2018, **44**(3): 401-424)
- Li Wen-Ying, Cao Bin, Cao Chun-Shui, Huang Yong-Zhen. A deep learning based method for bronze inscription recognition. *Acta Automatica Sinica*, 2018, **44**(11): 2023-2030 (李文英, 曹斌, 曹春水, 黄永祯. 一种基于深度学习的青铜器铭文



- 识别方法. 自动化学报, 2018, **44**(11): 2023–2030)
- 6 Tang Zhi-Wei. A review of driverless cars based on vision. *Manufacturing Automation*, 2016, **38**(8): 134–136  
(唐智威. 基于视觉的无人驾驶汽车研究综述. 制造业自动化, 2016, **38**(8): 134–136)
  - 7 He B, Ai R, Yan Y. Accurate and robust lane detection based on dual-view convolution neural network. In: Proceedings of the 2016 Intelligent Vehicles Symposium. Gothen, Sweden: IEEE, 2016. 1041–1046
  - 8 Li J, Mei X, Prokhorov D, Tao D C. Deep neural network for structural prediction and lane detection in traffic scene. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, **28**(3): 690–703
  - 9 Chen Wu-Wei, Hu Zhen-Guo, Wang Hong-Bo, Wei Zhen-Ya, Xie You-Hao. Study on extension decision and artificial potential field based lane departure assistance system. *Journal of Mechanical Engineering*, 2018, **54**(16): 134–143  
(陈无畏, 胡振国, 汪洪波, 魏振亚, 谢有浩. 基于可拓决策和人工势场法的车道偏离辅助系统研究. 机械工程学报, 2018, **54**(16): 134–143)
  - 10 Feng Xue-Qiang, Zhang Liang-Xu, Liu Zhi-Zong. Overview of the development of driverless cars. *Shandong Industrial Technology*, 2015, **2015**(5): 51  
(冯学强, 张良旭, 刘志宗. 无人驾驶汽车的发展综述. 山东工业技术, 2015, **2015**(5): 51)
  - 11 Yu Tian-Hong, Wang Rong-Ben, Gu Bai Yuan, Guo Lie. Survey on the vision-based recognition methods of intelligent vehicle road boundaries and lane markings. *Journal of Highway and Transportation*, 2006, **2006**(1): 139–142, 158  
(余天洪, 王荣本, 顾柏园, 郭烈. 基于机器视觉的智能车辆前方道路边界及车道标识识别方法综述. 公路交通科技, 2006, **2006**(1): 139–142, 158)
  - 12 Aly M. Real time detection of lane markers in urban streets. In: Proceedings of the 2008 Intelligent Vehicles Symposium. Eindhoven, the Netherlands: IEEE, 2008. 7–12
  - 13 Turchetto R, Manduchi R. Visual curb localization for autonomous navigation. In: Proceedings of the 2003 International Conference on Intelligent Robots and Systems. Las Vegas, USA: IEEE, 2003. 1336–1342
  - 14 Dang H S, Guo C J. Structure lane detection based on saliency feature of color and direction. In: Proceedings of the 2014 International Conference on Advances in Materials Science and Information Technologies in Industry. Xi'an, China: Science, 2014. 2876–2879
  - 15 Du X X, Tan K K, Htet K K K. Vision-based lane line detection for autonomous vehicle navigation and guidance. In: Proceedings of the 10th Asian Control Conference. Kota Kinabalu, Malaysia: IEEE, 2015. 1–5
  - 16 Li Yan-Dong, Hao Zong-Bo, Lei Hang. Survey of convolutional neural network. *Journal of Computer Applications*, 2016, **36**(9): 2508–2515  
(李彦冬, 郝宗波, 雷航. 卷积神经网络研究综述. 计算机应用, 2016, **36**(9): 2508–2515)
  - 17 Li Mao-Hui, Wu Chuan-Ping, Bao Yan, Fang Zhuo-Qun. On the application principle of YOLO algorithm in machine vision. *Journal of Computer Applications*, 2018, **5**(41): 174–176  
(李茂晖, 吴传平, 鲍艳, 房卓群. 论YOLO算法在机器视觉中应用原理. 教育现代化, 2018, **5**(41): 174–176)
  - 18 Girshick R, Donahue J, Darrell T, Malik J. Rich feature hierarchies for accurate object detection and semantic segmentation. In: Proceedings of the 2014 Conference on Computer Vision and Pattern Recognition. Columbus, OH, USA: IEEE, 2014. 580–587
  - 19 Girshick R. Fast R-CNN. In: Proceedings of the 2015 International Conference on Computer Vision. Santiago, Chile: IEEE, 2015. 1440–1448
  - 20 Ren S, He K, Girshick R, Sun J. Faster R-CNN: Towards real-time object detection with region proposal networks. *Pattern Analysis and Machine Intelligence*, 2017, **39**(60): 1137–1149
  - 21 Kim J, Lee M. Robust lane detection based on convolutional neural network and random sample consensus. In: Proceedings of the 2014 International Conference on Neural Information Processing. Springer, Cham: 2014. 454–461
  - 22 Redmon J, Divvala S, Girshick R, Farhadi A. You only look once: Unified, real-time object detection. In: Proceedings of the 2016 Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016. 779–788
  - 23 Redmon J, Farhadi A. YOLO9000: Better, faster, stronger. In: Proceedings of the 2017 Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017. 6517–6525
  - 24 Wei Yong-Ming, Quan Ji-Cheng, Hou Yu-Qing-Yang. Aerial image location of unmanned aerial vehicle based on YOLO v2. *Laser and Optoelectronics Progress*, 2017, **54**(11): 101–110  
(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. 激光与光电子学进展, 2017, **54**(11): 101–110)
  - 25 Lee S, Kim J, Yoon J S, Shin S, Bailo O, Kim N, et al. VP-GNet: Vanishing point guide network for lane and road marking detection and recognition. In: Proceedings of the 2017 International Conference on Computer Vision. Venice, Italy: IEEE, 2017. 1965–1973
  - 26 Redmon J, Farhadi A. YOLOv3: An incremental improvement. In: Proceedings of the 2018 Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: 2018. 1–4



**崔文靓** 哈尔滨理工大学电气与电子工程学院硕士研究生. 主要研究方向为目标检测与计算机视觉.

E-mail: cuiwliang@163.com

**(CUI Wen-Liang** Master student at the College of Electrical and Electronic Engineering, Harbin University of Science and Technology. His research interest covers target detection and computer vision.)



**王玉静** 哈尔滨理工大学电气与电子工程学院副教授. 2015年获哈尔滨工业大学博士学位. 主要研究方向为非平稳信号处理, 故障诊断, 状态评估与预测技术, 模式识别.

E-mail: mirrorwyj@163.com

**(WANG Yu-Jing** Associate professor at the College of Electrical and Electronic Engineering, Harbin University of Science and Technology. She received her Ph.D. degree from Harbin Insti-



tute of Technology in 2015. Her research interest covers non-stationary signal processing, fault diagnosis, state assessment and prediction technology, and pattern recognition.)



**康守强** 哈尔滨理工大学电气与电子工程学院教授. 2011 年获得白俄罗斯国立大学博士学位. 主要研究方向为非平稳信号处理, 故障诊断, 状态评估与预测技术, 模式识别.

E-mail: kangshouqiang@163.com

**(KANG Shou-Qiang** Professor at the College of Electrical and Electronic Engineering, Harbin University of Science and Technology. He received his Ph.D. degree from Belarusian State University, Minsk, Belarus in 2011. His research interest covers non-stationary signal processing, fault diagnosis, state assessment and prediction technology, and pattern recognition.)




**谢金宝** 哈尔滨理工大学电气与电子工程学院副教授. 2012 年获得白俄罗斯国立大学博士学位. 主要研究方向为计算机视觉和自然语言处理.

E-mail: xjbpost@163.com

**(XIE Jin-Bao** Associate professor at the College of Electrical and Electronic Engineering, Harbin University of Science and Technology. He received his Ph.D. degree from Belarusian State University, Minsk, Belarus in 2012.

His research interest covers computer vision and natural language processing.)



**王庆岩** 哈尔滨理工大学电气与电子工程学院讲师. 2018 年获得哈尔滨工业大学工学博士学位. 主要研究方向为图像处理与模式识别, 遥感图像处理. 本文通信作者.

E-mail: wangqy@hrbust.edu.cn

**(WANG Qing-Yan** Lecturer at the College of Electrical and Electronic Engineering, Harbin University of Science and Technology. He received his Ph.D. degree from Harbin Institute of Technology in 2018. His research interest covers image processing and pattern recognition, and remote sensing image processing. Corresponding author of this paper.)



**MIKULOVICH Vladimir Ivanovich** 白俄罗斯国立大学教授. 1975 年获白俄罗斯国立大学博士学位. 主要研究方向为非平稳信号处理, 故障诊断, 状态评估与预测技术, 模式识别.

E-mail: falcon@tut.by

**(MIKULOVICH Vladimir Ivanovich** Professor of Belarusian State University, Minsk, Belarus. He received his Ph.D. degree from Belarusian State University, Minsk, Belarus in 1975. His research interest covers non-stationary signal processing, fault diagnosis, state assessment and prediction technology, and pattern recognition.)