

商用车智能驾驶车道线检测算法研究

陈振, 梁丰收, 兰璐, 陈启元, 张世玉

(比亚迪汽车工业有限公司, 广东深圳 518118)

摘要:本文基于商用车的应用场景,针对车道线被遮挡和光线变化的特定环境问题,提出一种改进的UFLD算法。该算法能够较好地检测出完整车道线,在保证快速检测的同时,对多种不同场景的检测准确率高于其他同类网络,能更好地适用于商用车的智能驾驶环境,对乘用车运行环境也具有一定的移植和应用价值。

关键词:智能驾驶;深度学习;车道线检测;行分类;均值滤波

中图分类号:U469.72; TP391.4 文献标志码:A DOI:10.15917/j.cnki.1006-3331.2025.03.001

Research on Intelligent Sensing Lane Detection Algorithm for Commercial Vehicles

CHEN Zhen, LIANG Fengshou, LAN Lu, CHEN Qiyuan, ZHANG Shiyu

(BYD Automotive Industry Co., Ltd., Shenzhen 518118, China)

Abstract: Aiming at specific environmental problems such as lane occlusion and light change, this paper proposes an improved UFLD algorithm based on the application scenario of commercial vehicles. This algorithm can detect complete lane lines well, ensuring fast detection while maintaining higher accuracy than similar networks in detecting different scenarios. It can better adapt to the intelligent driving environment of commercial vehicles and have transplant and application value for passenger car operating environments.

Key words: intelligent driving; deep learning; lane detection; row classification; mean value filtering

相比于乘用车,商用车的运行场景更加固化,主要集中在公交场站、园区、港口等特定区域。因此,其对智能驾驶技术的需求更加迫切。智能驾驶商用车有望成为未来物流、城市配送、长途运输等领域的主流,推动整个商用车行业向更加智能、安全的方向发展。

在智能驾驶的感知系统中,车道线检测不仅是实现低阶智驾功能(如车道偏航警告系统、车道偏离修正)的基础,更是实现高阶智驾功能(如车道保持、自动变道)必不可少的前提^[1-2]。乘用车侧重快速检测车道线的变换,以应对频繁的变道和交通拥堵情况。而商用车行驶里程更长,为减少疲劳驾驶带来的风险,对不同场景车道线检测的稳定性和精度要求更高。

本文针对商用车的应用场景,提出一种改进的快速车道线检测(Ultra Fast Lane Detection, UFLD)算

法。该算法在确保快速检测的同时,重点解决商用车在复杂运行环境中面临的车道线缺失及光线变化问题,提升车道线检测精度和稳定性。即使在车道线存在部分遮挡(如被车辆覆盖)或道路缺失车道线标记(如道路严重破损无车道线信息)的情况下,该算法也能实现精准检测,能够更好地满足商用车在实际道路运行中的需求。

1 车道线检测方法现状及主要问题

针对车道线检测课题,国内外学者已经进行了相关研究,并取得了一定成果^[3-5],其方法可分为传统的图像处理方法和深度学习方法^[6]。

1) 传统的图像处理方法又可分为两类,一类是对车道线从颜色、强度、宽度以及边缘梯度进行特征

收稿日期:2025-01-24。

第一作者:陈振(1987—),男,硕士,工程师,主要从事新能源商用车产品技术研究工作。E-mail:chen.zhen2@byd.com。

通信作者:兰璐(1998—),女,硕士,工程师,主要从事新能源商用车智能驾驶设计研发工作。E-mail:lan.lu@byd.com。

提取。文献[7]将 RGB (Red、Green、Blue, 红色、绿色、蓝色) 图像转化为 HSV (Hue、Saturation、Value, 色相、饱和度、亮度) 图像以进行颜色提取处理, 这种方法采集不同光照强度条件下的黄色车道线像素作为样本值, 适用于标记清晰的黄色车道线检测。在实际场景中, 由于路况复杂、道路两旁树影变化因素的影响, 该方法的鲁棒性较差, 且未涉及白色车道线的检测。另一类是建立适当的几何模型拟合出车道线。文献[8]采用基于几何矩采样的方法对车道线进行检测, 并克服了车道线检测中的噪声干扰, 但仅能识别采样窗中的车道, 没有考虑车道间地标、标示牌的检测。

2) 深度学习方法推动了车道线检测精度的进步, 但其检测速度和计算复杂度问题仍有待解决。当前自动驾驶通常配备多个摄像头, 要求每个摄像头输入的计算成本应尽可能低, 算力占用应尽可能少。目前基于深度学习的方法分为三种: 基于参数回归的检测、基于行锚的检测和基于分割的检测^[9]。

在基于参数回归的车道线检测方法中, 文献[10]提出了一种基于深度多项式回归的车道检测新方法, 实现了端到端的估计。但由于车道检测评估指标的局限性和数据样本不平衡, 该方法缺乏泛化性。

在基于行锚的车道线检测方法中, 文献[11]为降低计算复杂度, 建立了行分类的检测网络模型, 并增加了单元格的感受野。该模型在阴影场景下的检测效果较好, 但其主干网络特征提取的能力较差。文献[12]结合了基于行锚和基于参数回归的方法, 通过行锚提供局部定位能力, 参数回归提供全局建模能力。然而, 该方法计算复杂度高、对硬件资源要求高、对数据标注依赖性强等缺点, 限制了其在不同场景中的应用。

基于分割的车道线检测方法中, 文献[13]通过自蒸馏提出了一种名为“SAD” (Self Attention Distillation) 的模型, 以解决快速检测的问题。虽然基于分割的 SAD 具有密集的预测特性, 但其计算量过大。文献[14]提出了一种算法融合的方法, 以 PINet (Point Instance Network) 网络为基础, 在骨干网络运算后对空间关联性进行了增强操作, 提升了模型的检测实时性, 但其对网络检测精度的提升较小。

鉴于上述问题, 针对商用车运行场景中常见的无车道线、车道线缺失、严重遮挡以及极端光照条件的情况, 需要一种新的解决方案来平衡计算速度和准确性, 从而实现更快、更准确的车道检测。本文提出一种改进的 UFLD 算法。该算法在快速检测车道线的基础上, 引入 CA (Coordinate Attention) 坐标注意力机制, 能够更好地聚焦于无车道线场景中车道线可能存在的区域; 在原有损失函数的基础上添加了 Dice 损失函数, 以充分利用车道线的先验信息; 在后处理部分引入均值滤波及多帧融合技术, 解决车辆变道过程中检测混乱的问题。

2 改进的 UFLD 算法

2.1 UFLD 公式

在车道线检测中, 将车道线检测转化为基于整张图像信息的行方向选择方法。在车辆前进的每个行方向上, 利用全局特征来选择正确的车道线位置。首先将待检测图像进行网格化处理, 在车道线可能存在的区域等间距划分成多行, 用于定位车道线在图像中的垂直分布。再将每一行上的位置信息划分为多个单元格, 每个单元格用于预测车道线在该行上的具体位置。图 1 为 UFLD 车道线检测单元格划分示意图。

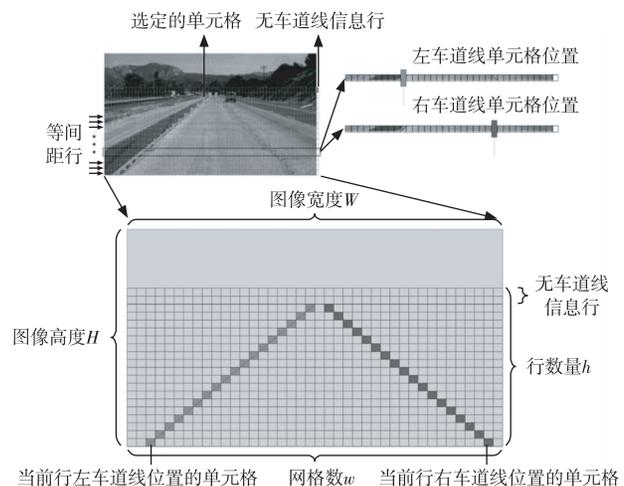


图 1 UFLD 车道线检测单元格划分示意图

在 UFLD 公式推导的过程中, 假设整张图像的高度为 H , 宽度为 W , 整张图像的信息特征表示为 X , 车道线在图像中前进方向行数量表示为 h , 每一行上的单元格数量表示为 w , 图像中最多车道线的数量为

C 。

$f^{i,j}$ 为在第 j 行中存在第 i 条车道线的概率, 表示为式(1):

$$P_{i,j} = f^{i,j}(X), i \in [1, C], j \in [1, h] \quad (1)$$

式中: $P_{i,j}$ 表示模型预测的第 i 条车道线在第 j 行的某个特定单元格为车道线的概率。

假设 $T_{i,j}$ 表示第 i 条车道线在第 j 行单元格的真实类别标签, 是一个标量值, 通常取值为 0 或 1, 其分类损失函数 L_{cls} 公式见式(2)。

$$L_{cls} = \sum_{i=1}^C \sum_{j=1}^h L_{CE}(P_{i,j}, T_{i,j}) \quad (2)$$

式中: L_{CE} 为交叉熵损失。

从式(1)可以看出, 通过图像整体的特征信息, 可以预测每行上所有位置的概率分布。依据这一概率分布能够选择正确的车道线位置。

此外, 由于不进行逐像素分割计算, 大大降低了模型的计算复杂度, 提高了算法的计算速度。如图 1 所示, 预定义的行数和网格数远小于图像的高度和宽度, 即 h 远小于 H , w 远小于 W 。因此, 分割公式需要进行 $(C+1)$ 维的 $H \times W$ 分类, 而上述方法只需要解决 $(w+1)$ 维的 $C \times h$ 分类问题。通过这种方式, 计算成本为 $C \times h \times (w+1)$, 而分割方法的计算成本是 $H \times W \times (C+1)$, 该方法大大降低了计算成本。例如, 使用 CULane 数据集的通用设置, 理想计算成本是 1.7×10^4 次计算, 而用分割方法的计算成本是 9.2×10^5 次计算, 其计算成本显著降低。

从感受野的角度看, 上述方法具有整个图像的感受野, 能够利用来自图像其他位置的上下文信息来解决车道线检测问题。从特征学习的角度看, 该方法还可以利用结构损失函数来学习车道线的形状、方向、类别、位置等先验信息。

2.2 结构损失函数

UFLD 网络中除了分类损失外, 还使用了其他两个损失函数, 旨在对车道线点的位置关系进行建模, 从而学习结构信息。第一个损失函数来源于车道线的连续性, 即相邻行锚点中的车道线点应该彼此靠近。由于车道线的位置由分类向量表示, 因此连续性属性是通过约束分类向量在相邻行上的分布来实现的。相似性损失函数 L_{sim} 公式见式(3)。

$$L_{sim} = \sum_{i=1}^C \sum_{j=1}^{h-1} \|P_{i,j} - P_{i,j+1}\|_1 \quad (3)$$

式中: $P_{i,j+1}$ 表示第 i 条车道线在第 $j+1$ 行的某个特定单元格被判断为车道线的概率; $\|\cdot\|_1$ 表示 L1 范数, 指的是两个概率值之间的绝对差值之和。

另一个结构损失函数关注车道线的形状, 车道线的几何特性在现实场景中通常表现为直线、缓弯或平滑的 S 形曲线, 这些形状特征反映了车道线的连续性和渐变性。为将这一先验知识编码到模型中, 通过二阶差分方程对车道线的曲率连续性进行数学约束。具体而言, 二阶差分方程通过建模相邻网格单元之间的位置变化关系, 强制相邻位置点的曲率(即方向变化率)逐渐过渡, 从而避免车道线出现不合理的突变或跳跃。例如, 在直线路段, 相邻位置的曲率差趋近于零; 在弯道区域, 曲率差会随透视效应平缓增大, 但不会剧烈波动。这种约束本质上是车道线的形状结构信息转化为可优化的损失函数(如形状损失), 使模型在预测车道线位置时, 不仅能结合局部视觉特征, 还能遵循全局几何规律。因此, 即便在遮挡或模糊场景下, 模型仍能基于形状约束输出平滑且符合现实物理规律的车道线轨迹。

二阶差分的形状损失函数 L_{shp} 公式见式(4)。

$$L_{shp} = \sum_{i=1}^C \sum_{j=1}^{h-2} \|(L_{i,j} - L_{i,j+1}) - (L_{i,j+1} - L_{i,j+2})\|_1 \quad (4)$$

式中: $L_{i,j}$ 是一个标量值, 表示第 i 条车道第 j 行上所有单元格的概率加权平均值, 反映车道线在第 j 行的期望位置。

$$L_{i,j} = \sum_{k=1}^m k \cdot P_{i,j,k} \quad (5)$$

式中: $P_{i,j,k}$ 表示第 i 个车道第 j 行第 k 个单元格位置是车道线的概率, 通过 softmax 函数计算得到。

车道线通常表现为低阶曲线, 其形状可表现为以下几种情况: ①在高速公路或城市道路中, 大部分直线车道线的曲率为零; ②在弯道或转弯处, 圆弧形车道线的曲率为常数; ③在直道和圆弧之间, 缓和曲线的曲率逐渐变化。由于车道线的曲率变化较为平缓, 没有剧烈的高频波动和突变, 因此采用低阶差分足以描述车道线的特性。相比之下, 高阶差分约束会强制

曲线在更高阶导数上保持平滑,从而导致车道线过度平滑,失去对实际车道线局部变化的捕捉能力,尤其在弯道处表现不佳。此外,低阶差分约束的计算复杂度较低,更适合快速的车道线检测任务。

低阶差分通常包含一阶差分和二阶差分,由于一阶差分在大多情况下不为零,本文算法中采用二阶差分,设置额外的参数来学习车道线位置一阶差分的分布。而且二阶差分的约束比一阶差分的约束弱,在车道不笔直时,二阶差分对车道线形状的限制影响较小。最后,结构损失函数 L_{str} 整体表示为:

$$L_{str} = L_{sim} + \lambda \cdot L_{shp} \quad (6)$$

式中: λ 为损失系数。

2.3 网络损失函数改进

损失函数是用来衡量网络模型预测值和真实值之间差异的函数,基于 UFLD 网络的损失函数包括分类损失函数 L_{cls} 、结构损失函数 L_{str} 和辅助分割损失函数 L_{seg} ,整体损失函数 L_{tot} 表示为:

$$L_{tot} = L_{cls} + \alpha \cdot L_{str} + \beta \cdot L_{seg} \quad (7)$$

式中: α 和 β 为损失系数。

在车道线检测任务中,各类车道线(如左车道、右车道和中间车道)在整张图像中通常只占据较小区域,导致类别间存在显著的不平衡。在这种标签不平衡的情况下,传统的交叉熵损失函数仅对每个像素独立计算损失,容易偏向背景类,从而在小目标区域上表现不佳,特别是在边缘区域容易出现预测模糊或断裂。为解决这一问题,本文引入多分类 Dice 损失函数,其通过衡量每一类别预测区域与真实区域的重叠程度,有效增强对小目标区域的整体结构监督,提升模型在类别不平衡场景下的分割性能。

Dice 损失函数的核心在于通过衡量预测区域与真实区域的重叠程度来计算两者的相似度,并通过对重叠部分的加权来优化分割性能。其数学表达式见式(8)。

$$L_{dic} = 1 - \frac{1}{E} \sum_{E=1}^E \frac{2 \sum_{a=1}^n y_a \cdot t_a}{\sum_{a=1}^n y_a^2 + \sum_{a=1}^n t_a^2} \quad (8)$$

式中: L_{dic} 为 Dice 损失函数; E 为车道线和背景类别总数; n 为图像中的总像素数; a 为第 a 个像素的索引; y_a 为第 a 个像素对第 E 类的预测概率值; t_a 为第

a 个像素对第 E 类的真实标签,是 one-hot 编码的值,若该像素属于该类则为 1,反之为 0。

在本文算法中,采用 Dice 损失函数和交叉熵损失函数进行加权组合。其中,交叉熵损失函数关注每个像素的分类准确性,Dice 损失函数则关注整体预测与真实结果的相似性。将两者结合,既能优化目标一致性,又能通过 Dice 损失函数的梯度计算加速模型的收敛。特别是对于车道线这种目标区域较小的情况,这种组合方式能够更好地平衡分割结果的准确性和模型的收敛速度。改进后的损失函数见式(9)。

$$L_{tot} = (1-\lambda)L_{cls} + \lambda \cdot L_{dic} + \alpha \cdot L_{str} + \beta \cdot L_{seg} \quad (9)$$

2.4 CA-ResNet 骨干网络设计改进

CA 坐标注意力机制是一种新型的注意力机制。其核心在于将通道注意力分解为两个一维特征编码过程,分别沿着水平和垂直方向聚合特征,同时捕获长距离的空间依赖关系和精确的位置信息,并将位置信息嵌入到通道注意力中,以提高模型对车道线这类细长目标的特征提取能力。

CA 坐标注意力机制的核心步骤如下:首先对输入特征图进行全局平均池化,分别沿水平方向和垂直方向聚合空间信息,从而得到以下两个特征向量信息,见式(10)和式(11)。

$$z_h(h) = \frac{1}{W} \sum_{w=1}^W X(h, w) \quad (10)$$

$$z_w(w) = \frac{1}{H} \sum_{h=1}^H X(h, w) \quad (11)$$

式中: $z_h \in R^{C \times H}$,表示水平方向的空间信息; $z_w \in R^{C \times W}$,表示垂直方向的空间信息; X 表示输入的特征图。

将 z_h 和 z_w 拼接后通过卷积和非线性激活函数生成注意力权重,见式(12)。

$$f = \partial(F_1 |z_h, z_w|) \quad (12)$$

式中: F_1 为卷积操作; ∂ 为 Sigmoid 激活函数; $f \in R^{C \times (H+W)}$,为编码后的特征,将其分解为水平方向和垂直方向的注意力权重,能够动态调整通道特征的贡献,见式(13)和式(14)。

$$f_h = \partial(F_h |f_h|) \quad (13)$$

$$f_w = \partial(F_w |f_w|) \quad (14)$$

式中: F_h 和 F_w 为卷积操作; $f_h \in R^{C \times H}$ 、 $f_w \in R^{C \times W}$,为编码后的特征。

将生成的注意力权重应用到原始图像特征上, 见式(15)。

$$Y = X \cdot f_h \cdot f_w \quad (15)$$

式中: $Y \in R^{C \times H \times W}$, 为增强后的特征图。

CA 坐标注意力机制通过这种全局池化和坐标信息编码, 显式建模了空间位置关系, 增强了模型对车道线位置的敏感性。同时, 通过卷积和非线性激活函数生成通道注意力权重, 能够动态调整通道特征的贡献。在计算效率方面, 该方法通过分解通道注意力和空间注意力, 大大降低了计算复杂度。

本文采用的 CA-ResNet18 残差网络结构如下: 首先通过一个 7×7 的卷积层提取图像的初始特征, 接着经过一个 3×3 的最大池化层进一步降低特征图的空间维度, 再经过 4 组改进的残差块和全局平均池化、全连接层输出最终的车道线检测结果。每个改进的残差块在 2 个 3×3 的卷积层之后加入 CA 模块, 每个残差块中的 CA 模块能够自适应调整通道权重和空间位置权重, 增强了模型的特征表达能力和空间定位能力, 从而提升了整体性能。改进后的网络总体架构如图 2 所示。

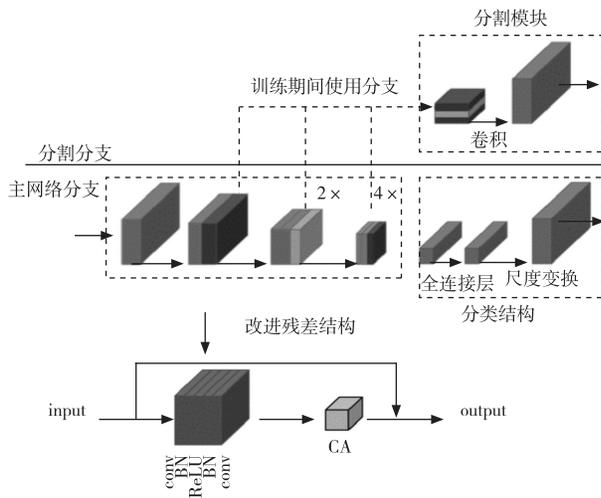


图2 改进后的网络总体架构图

3 试验及结果分析

3.1 试验参数设置

数据集由数据采集车及智驾域控平台采集, 涵盖高速道路、城区道路和乡镇道路, 包含正常光照、曝光、树荫遮挡、傍晚等场景。共截取 44 286 张视频帧

图片, 其中训练集 40 000 张, 测试集 3 700 张, 验证集 586 张, 图片分辨率为 $1\,920 \times 1\,536$ 像素。车道线数据集使用 Labelme 标注软件进行标注, 并将生成的 json 文件转换为 CULane 数据集格式, 用于模型训练和验证。自制数据集的行锚点数量与 CULane 数据集一致, 设置 18 个行, 201 个网格。

图像在训练前进行预处理: 按照网络输入格式调整大小至 288×800 像素, 并进行归一化处理, 然后将其作为模型输入。模型使用 Adam 优化器进行训练, 采用初始学习率为 $4e-4$ 的余弦衰减学习率策略, 损失函数中的损失系数 λ 和 β 都设置为 0.3, α 设置为 0.1。批训练 Batch size 设置为 32, 训练 epoch 总数设置为 50。所有模型均使用 PyTorch 深度学习框架和 Nvidia GTX A2000 GPU 进行训练和测试。

3.2 后处理

由于该模型在车辆变道过程中车道线检测存在误差, 在后处理中增加了均值滤波来修正检测结果。通常情况下, 车辆行驶过程中的车道线是连续的, 且车道线的宽度相对固定。因此, 基于车道线检测结果, 将车道线建模为互相平行且笔直的直线。通过计算车道线检测离散点的方差来衡量检测结果的稳定性, 方差 σ 的计算公式见式(16)。

$$\sigma = \sum_{i=1}^n (x_i - \bar{x})^2 / n \quad (16)$$

式中: x_i 为当前车道线检测车身坐标值; \bar{x} 为同一条车道线检测出所有点的均值; n 为输出的车道线的点数。

方差越小, 表示车道线越趋于稳定。由于基于图像坐标系检测出的车道线离散点不具有物理意义, 因此需要将这些点从图像坐标系转换到世界坐标系。通过张正友标定法获得相机的内参, 再利用 solvePnP 函数求得外参, 深度值 s 的计算公式见式(17)。

$$s = t_3 + r_{31} \cdot x + r_{32} \cdot y + r_{33} \cdot z \quad (17)$$

式中: x, y 为图像坐标, 假设相机与目标平面平行, z 表示齐次坐标中的辅助变量, 固定值为 1; r 为旋转矩阵; t 为平移矩阵。

像素坐标系与世界坐标系的转换关系见式(18)。

$$\mathbf{R}^{-1}\mathbf{M}^{-1}\mathbf{s} \begin{bmatrix} u \\ v \\ Z_{\text{con}} \end{bmatrix} = \begin{bmatrix} X \\ Y \\ Z_{\text{con}} \end{bmatrix} + \mathbf{R}^{-1}\mathbf{t} \quad (18)$$

式中: \mathbf{R} 为旋转矩阵; \mathbf{M} 为内参矩阵; Z_{con} 为目标点在世界坐标 Z 方向的值,此处为0; $[u, v]$ 为像素坐标; $[X, Y]$ 为世界坐标。

将像素坐标转换为世界坐标后,根据透视效应,物理上的车道线是平行的,可以根据车道宽度设定阈值来修正车道线。在车辆变道过程中,模型检测出的车道线往往会在车辆跨越中线时变得混乱。将车道线离散点转换为世界坐标后,其方差通常很大,而正确的车道线在物理上是一条平滑的直线,方差很小,故可以通过设置方差阈值来修正车道线。

车道线后处理流程如图3所示,其中 B 表示车道线宽度, B_{\min} 和 B_{\max} 为设定的车道线宽度最小和最大值, V 为设定的方差值, V_{ar} 为计算得到的方差值, C_{err} 为检测的错误帧数量, N_{err} 为设定的错误帧阈值上限。

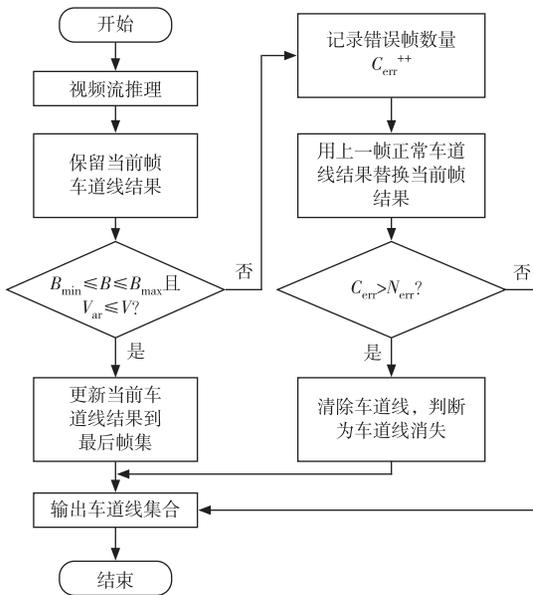


图3 车道线后处理流程图

3.3 模型评价指标

1) CULane数据集的评价指标F1综合考虑了精确率(P)和召回率(R),用于评估模型的整体性能。其中,精确率是指预测为正且交并比(Intersection over Union, IoU)大于阈值的样本中实际为正的比例;召回率是指实际为正且IoU大于阈值的样本中预测为正的比例。IoU用于计算真实车道线和预测车道

线之间交并比,设置IoU阈值为0.5。F1计算公式见式(19)。

$$F1 = 2 \times [P \times R / (P + R)] \quad (19)$$

$$P = M_{\text{TP}} / (M_{\text{TP}} + M_{\text{FP}}) \quad (20)$$

$$R = M_{\text{TP}} / (M_{\text{TP}} + M_{\text{FN}}) \quad (21)$$

式中: M_{TP} 为被车道线模型检测正确的样本数; M_{FP} 为被检测为车道线的负样本数; M_{FN} 为未被模型检测的车道线样本数。

2) 检测速度是衡量算法运行速度的重要指标,表示每秒处理的帧数。检测速度值越大,则模型的处理速度越快。

3.4 结果分析

在车道线缺失、光线变化的特定园区环境下的检测结果如图4所示:在图4(a)中,光线良好,车道线在本车道的检测效果良好;图4(b)中有不规则阴影遮挡部分车道线,导致路面明暗变化较大,同一条车道线在不同位置存在较大差异,本文算法能够准确检测并输出整条车道线;在图4(c)中,遇到人行斑马线时,算法能够屏蔽多条人行直线的干扰,准确输出连续的车道线;在图4(d)中,算法能够准确抵抗行人和多车辆的干扰,准确提取当前车道和左右两侧车道线信息。



(a) 光线良好场景



(b) 阴影遮挡部分车道线场景



(c) 人行道多线条干扰场景



(d) 骑行者、多车辆场景

图4 车道线不同场景检测结果

由于模型是基于预先定义好的车道线标签进行训练,其在车辆变道场景下无法准确检测车道中线,导致中线识别混乱和坐标点漂移,如图5所示。



图5 车道线混乱检测情况

通过提取车辆变道场景视频中车道线的坐标点,逐帧输出车道线检测结果,并利用式(16)计算出每一帧车道线的方差。图6为当前车道检测坐标值的方差。从图6可知,方差存在高峰波动,有少部分帧的方差超过了1 000。为防止离散点偏离过大,设定方差阈值为500,过滤掉离散点方差超过500的点。针对变道场景,通过均值滤波后处理修正车道线,使车道线检测结果在不同帧之间更加稳定、平滑,避免了因变道离散点的存在而导致检测结果大幅波动的情况。其后处理修正后的车道线结果如图7所示。

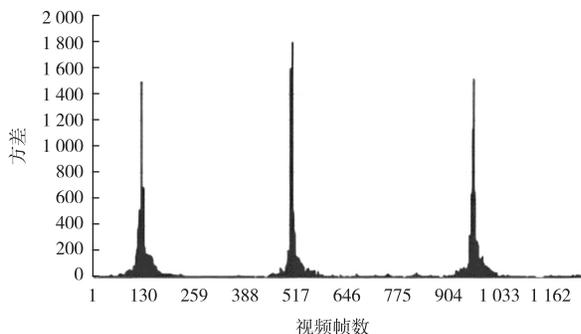


图6 车道线方差

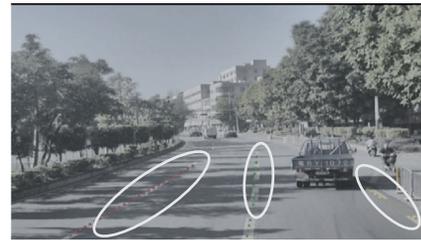


图7 后处理修正后的车道线检测结果

为了进一步验证本文算法的有效性,在 CULane 数据集上进行了消融试验和其他主流网络模型对比试验。表1为消融试验的参数情况。对于 UFLD 网络模型,F1 的评分为 68.4%。在 UFLD 模型的基础上增加 CA 注意力机制,F1 的评分为 70.4%,比 UFLD 的评分高出 2%,检测效果提升明显,验证了 CA 注意力机制的有效性,说明其能够使算法更加关注图像中的车道线位置信息和通道信息。在 UFLD 网络模型的基础上增加 Dice 损失函数,F1 的评分为 69.8%,比 UFLD 网络模型的评分高出 1.4%,说明 Dice 损失函数能够使模型关注车道线像素。将 CA 注意力机制和 Dice 损失函数都增加到 UFLD 网络模型中进行改进,其 F1 的评分为 71.3%,比 UFLD 网络模型的评分高出 2.9%,证明了两者的结合方法的有效性。

表1 CULane 数据集上的消融试验结果对比

UFLD	CA-ResNet18	Dice 损失函数	F1/%
✓			68.4
✓	✓		70.4
✓		✓	69.8
✓	✓	✓	71.3

表2展示了 SCNN (Spatial CNN)^[15]、ENet-SAD^[13]、Ufld ResNet18 (Ultra-Fast-Lane-Detection ResNet18)^[11]等不同车道线检测算法下 F1 和检测速度的比较。其中 IoU 阈值设置为 0.5,从结果可以看出,本文算法的检测精度高于 ENet-SAD、Ufld-ResNet18、Res34-SAD、Res50-seg^[16]、FD-50^[17]、FCASPP 这6种网络模型;本文算法的精度略低于 SCNN 模型,但 SCNN 采用复杂的空洞卷积和后处理步骤,其计算成本较高,检测速度较慢,无法做到精度和速度之间的有效平衡。

表2 模型在 CULane 数据集评估结果对比分析

项目	SCNN	ENet-SAD	Ufld-ResNet18	Res34-SAD	Res50-seg	FD-50	FCASPP	本文算法
正常场景精确率/%	90.6	90.1	87.7	89.9	87.4	85.9	89.2	91.3
拥挤场景精确率/%	69.7	68.8	66.0	68.5	64.1	63.6	68.2	72.9
夜间场景精确率/%	66.1	66.0	62.1	64.6	60.6	57.8	64.5	67.1
无线场景精确率/%	43.4	41.6	40.2	42.2	38.1	40.6	42.9	45.4
阴影场景精确率/%	66.9	65.9	62.8	67.7	60.7	59.9	64.2	68.8
箭头场景精确率/%	84.1	84.0	81.0	83.8	79.0	79.4	83.8	84.1
眩光场景精确率/%	58.5	60.2	58.4	59.9	54.1	57.0	59.7	58.5
弯道场景精确率/%	64.4	65.7	57.9	66.0	59.8	65.2	59.5	69.6
拥堵路段/个	1 990	1 998	1 743	1 960	2 505	7 013	2 336	2 017
F1/%	71.6	70.8	68.4	70.7	66.7	69.7	70.1	71.3
检测速度/fps	7.5	71.6	322.5	19.8	77.3	90.3	298.4	173.4

同时对比了不同场景下的检测精确率,以 Ufld-ResNet18 模型为对比基准,其正常场景提升了 3.6%,拥挤场景提升了 6.9%,夜间场景提升了 5.0%,无线场景提升了 5.2%,阴影场景提升了 6.0%,箭头场景提升了 3.1%,眩光场景提升了 0.1%,弯道场景提升了 11.7%,F1 提升了 2.9%,检测速度由原来的 322.5 fps 变为 173.4 fps。尽管检测速度有所降低,但 173.4 fps 在车道线检测领域已经属于较快的速度,该速度能够满足大多数实时应用场景的需求,快速响应路况变化。

4 结束语

本文提出了一种改进的 UFLD 算法,在骨干网络中增加 CA 注意力机制,在原有损失函数基础上增加了 Dice 损失函数,在保持车道线检测速度的同时提高了检测精度。考虑到车辆变道场景,引入均值滤波后处理修正混乱离散的车道线。通过消融实验验证了改进效果,改进后的算法 F1 相较于 UFLD 模型提高了 2.9%。为验证改进算法的检测效果,在 CULane 数据集上进行了多种网络模型对比分析,综合检测精度和检测速度,验证了本文改进方法的有效性。

本文提出的车道线检测算法在结构化道路、车道线缺失、光线变化场景中的检测效果都有提升,但在弯道和无车道的复杂场景仍有改进空间。为提高车道线在复杂场景中的检测准确性和实时性,将从以下方面进行提升:①对于道路崎岖、颠簸、阴雨天气、弯道等场景,采用摄像头、激光雷达、组合导航等多种传

感器数据融合检测;②在实时性方面,通过使用更轻量化的骨干网络减少计算量,利用 GPU 加速处理提高算法的实时性;③通过引入对抗训练和数据增强技术,提升算法在复杂场景下的鲁棒性,增强模型的泛化能力。

参考文献:

- [1] 穆柯楠. 基于车-路视觉协同的行车环境感知方法研究[D]. 西安:长安大学,2016.
- [2] LIANG D, GUO Y C, ZHANG S K, et al. Lane detection: a survey with new results[J]. Journal of Computer Science and Technology, 2020, 35(3): 493-505.
- [3] 崔文靓,王玉静,康守强,等. 基于改进 YOLOv3 算法的公路车道线检测方法[J]. 自动化学报, 2022, 48(6): 1560-1568.
- [4] HE B, AI R, YAN Y, et al. Accurate and robust lane detection based on dual-view convolution neural network[C]//IEEE. 2016 IEEE Intelligent Vehicles Symposium (IV). New York: IEEE, 2016: 1041-1046.
- [5] LI J, MEI X, PROKHOROV D, et al. Deep neural network for structural prediction and lane detection in traffic scene[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(3): 690-703.
- [6] 刘富强,张姗姗,朱文红,等. 一种基于视觉的车道线检测与跟踪算法[J]. 同济大学学报(自然科学版), 2010, 38(2): 223-229.
- [7] 王怀涛,曹明伟,邢皎玉. 基于 HSV 颜色空间与边缘特征的黄色车道线检测[J]. 北京汽车, 2017(3): 14-18.

型、压降一致性模型进行综合评判。

3 结束语

新能源汽车大数据平台采集的 BMS 电池报警数据^[11]仅适用于紧急处理,无法实现动力电池故障的提前预警。本文提出的预警方法能够弥补 BMS 预警功能的不足,降低车辆电池事故的发生率,提高整车安全性。后续研究需进一步提高预警识别的准确率。

参考文献:

- [1] 郑州宇通客车股份有限公司. 一种基于数据挖掘的车辆故障诊断方法及系统:201610279367.0[P]. 2018-09-25.
- [2] 张亮,桂康哲,王兴月,等. 基于新能源汽车大数据的蓄电池亏电预警研究[J]. 时代汽车,2020(15):62-63.
- [3] 刘木林,卜凡涛,林辉,等. 电动汽车动力电池热失控过程分析及预警机制设计[J]. 汽车实用技术,2020(5):15-17.
- [4] 赖银麟,杨凯,刘皓,等. 锂离子电池安全预警方法综述[J]. 储能科学与技术,2020,9(6):1926-1932.
- [5] 李丹,刘继红,周恩飞,等. 基于 BP 神经网络的动力电池热失控预警方法研究[J]. 客车技术与研究,2024,46(5):7-10.
- [6] 王丹璐,吴刘仓,郑桂芬. 基于偏正态数据下位置、均值回归模型的参数估计[J]. 应用数学,2021,34(3):590-599.
- [7] 中国电力科学研究院有限公司,国家电网有限公司,国网浙江省电力有限公司. 一种电池模组的预警方法及预警装置:202010358987.X[P]. 2020-08-11.
- [8] 时玉帅,熊金峰,樊海梅. 动力电池常见故障分析与预警方法[J]. 广东化工,2019,46(13):115-116.
- [9] 余承其,张照生,刘鹏,等. 大数据分析技术在新能源汽车行业的应用综述——基于新能源汽车运行大数据[J]. 机械工程学报,2019,55(20):3-16.
- [10] 天津市捷威动力工业有限公司. 一种锂离子电池安全预警装置:202022994891.0[P]. 2021-08-03.
- [11] 浙江吉利控股集团有限公司,吉利汽车研究院(宁波)有限公司. 一种新能源车动力电池预警法及系统:202110476497.4[P]. 2022-11-22.
- [8] 宋锐,陈辉,肖志光,等. 基于几何矩采样的车道检测算法[J]. 中国科学:信息科学,2017,47(4):455-467.
- [9] 邓天民,谢鹏飞,余洋,等. 双分支特征自适应融合的车道线检测方法[J/OL]. 吉林大学学报(工学版). <https://doi.org/10.13229/j.cnki.jdxbgxb.20240397>.
- [10] TABELINI L, BERRIEL F R, PAIXÃO M T, et al. Polylanenet: lane estimation via deep polynomial regression[C]//ICPR. 2020 25th International Conference on Pattern Recognition (ICPR). IEEE, 2021: 6150-6156.
- [11] QIN Z, WANG H Y, LI X. Ultra fast structure-aware deep lane detection[C]//University of Edinburgh. Computer Vision - ECCV 2020. Lecture Notes in Computer Science. Berlin: Springer, 2020: 276-291.
- [12] HONDA H, UCHIDA Y. CLRerNet: improving confidence of lane detection with LaneIoU [C]//IEEE. 2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). New York: IEEE, 2024: 1165-1174.
- [13] HOU Y N, MA Z, LIU C X, et al. Learning lightweight lane detection cnns by self attention distillation[C]//IEEE. 2019 IEEE/CVF International Conference on Computer Vision (ICCV). New York: IEEE, 2019: 1013-1021.
- [14] 范英,石磊,苏伟伟,等. 基于 PINet+RESA 网络的车道线检测算法[J]. 江苏大学学报(自然科学版), 2023, 44(4): 373-378.
- [15] PAN X G, SHI J P, LUOP, et al. Spatial as deep: Spatial CNN for traffic scene understanding [C]//AAAI. Proceedings of the AAAI Conference on Artificial Intelligence, 32. Palo Alto: AAAI Press, 2018: 7276-7283.
- [16] CHEN L C, PAPANDEOU G, KOKKINOS I, et al. Deeplab: semantic image segmentation with deep convolutional nets, atrousconvolution, and fully connected crfs [J]. IEEE transactions on pattern analysis and machine intelligence, 2018, 40(4): 834-848.
- [17] PHILION J. Fastdraw: addressing the long tail of lane detection by adapting a sequential prediction network [C]//IEEE. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New York: IEEE, 2019: 11582-11591.

(上接第8页)