

基于模拟多曝光融合的夜间车道线检测方法

李晓旋¹
LI Xiaoxuan

摘要

光照条件是影响车道线检测的重要干扰因素。针对夜间行车图像对比度低、噪声大、暗处细节不清晰等问题，文章提出一种基于模拟多曝光融合的夜间车道线检测方法。首先，利用模拟多曝光融合的图像增强方法处理输入的夜间车道线图像。然后，使用编码-解码器进行语义分割，并按规则取点连线，完成车道线的预测和拟合。实验结果表明，所提方法能够有效地提升夜间行车图像的视觉效果和车道线检测的精度。

关键词

车道线检测；图像增强；曝光融合；语义分割

doi: 10.3969/j.issn.1672-9528.2025.06.014

0 引言

车道线作为道路环境中普遍存在的交通标志，用于管制和引导交通。准确、鲁棒地感知车道线有利于车辆定位，对于提高自动驾驶汽车的安全性和推动发展智能网联、车路协同有着重要的意义。虽然车道线检测的相关研究已取得了良好的进展，但夜间道路各种光源交错使得车道线亮度分布不均，可见度和对比度下降，为车道线检测带来一定的挑战。

传统车道线检测方法常依赖边缘、颜色、亮度、纹理等视觉特征来提取车道像素点，并利用直线或多项式曲线进行车道线拟合。如刘悦等人^[1]基于车道线的纹理特征获取动态车道线 ROI 区域的图像消失点，并利用一种结合梯度和统计平均相对差的蚁群算法求解车道线。

相较于传统的车道线检测方法，基于深度学习的语义分割方法具有很强的全局语义特征提取与表示能力，被广泛应用于车道线检测中。陈立潮等人^[2]将 ERFNet^[3] 网络应用于车道线检测中，并引入车道预测分支和辅助训练分支，该模型在 CULane 数据集上的 F_1 -measure 平均值可以达到 73.44%。

为了提高夜间图像的质量，基于深度学习的图像增强方法已被广泛应用在目标检测与识别等任务中，主要分为有监督和无监督两大类。有监督方法多依赖成对的图像进行监督训练，但获取、标注成对数据集耗时又费力。因此，Zero-DCE^[4] 等无监督的方法被提出。然而，基于深度学习的图像增强方法对样本数据依赖性较高，且无法通用地处理各种图像增强任务，需要针对每个任务进行特定的模型训练，这大大增加了训练成本。

鉴于上述考虑，本文提出了一种基于模拟多曝光融合的夜间车道线检测方法，流程图如图 1 所示。




图 1 车道线检测流程图

1 模拟多曝光融合的图像增强方法

夜间行车图像局部动态范围小，呈高亮区、过渡区和阴影区 3 种分布。由于车灯及其他道路照明设施的辐射，近景区域亮度相对较高，而远离照明设施的道路两侧区域亮度较低，导致可提取的信息减少。针对此问题，提出了一种模拟多曝光融合的图像增强方法。

1.1 增强曝光图像生成

为提升图像的亮度和对比度，采用图像的信息熵来衡量

1. 长安大学 陕西西安 710064

图像的像素亮度。像素灰度值集合用公式表示为:

$$\mathbf{Q} = \{V(x) | V(x) < \tau\} \quad (1)$$

式中: $V(x)$ 是输入图像的亮度分量; τ 是区分图像像素值曝光度的灰度阈值, 本文取值 0.5。

曝光度无法满足要求的像素点信息熵为:

$$I(\mathbf{Q}) = -\sum_{i=1}^N p_i \cdot \log_2 p_i \quad (2)$$

式中: p_i 是图像像素灰度值集合 $\mathbf{Q}$ 中灰度值 i 出现的概率。

接着, 利用最大熵阈值图像分割理论, 计算图像的最佳曝光率 δ_{opt} 为:

$$\delta_{\text{opt}} = \arg \max_{\delta} I(g(\mathbf{Q}, \delta)) \quad (3)$$

式中: $g(\cdot)$ 为灰度映射函数, 其公式为:

$$g(\mathbf{Q}, \delta) = \beta \mathbf{Q}^\gamma = e^{b(1-\delta^a)} \mathbf{Q}^{(\delta^a)} \quad (4)$$

式中: δ 是曝光率, $a=-0.3293$, $b=1.1528$ 。

然后, 对输入图像进行非线性灰度映射调整, 得到增强曝光图像:

$$\tilde{V} = g(V, \delta_{\text{opt}} + \Delta\delta) \quad (5)$$

式中: 曝光率变化量 $\Delta\delta=1$ 。

最后, 将处理的 V 分量和 H 、 S 分量合成 HSV 图像, 并转回 RGB 颜色空间作为增强曝光图像 I_2 。

1.2 中等曝光图像生成

受模拟多曝光融合方法启发, 利用曝光插值法对弱曝光图像与增强曝光图像进行像素级别的融合处理, 生成中等曝光图像。

设 $I_1(p)$ 为弱曝光图像、 $I_2(p)$ 为增强曝光图像、 $I_3(p)$ 为中等曝光图像。 $I_1(p)$ 和 $I_2(p)$ 的累积直方图分别 H_1 和 H_2 , 则 $I_1(p)$ 到 $I_2(p)$ 和 $I_2(p)$ 到 $I_1(p)$ 的强度映射函数 $F_{12}(z)$ 和 $F_{21}(z)$ 计算式为:

$$\begin{cases} F_{12}(z) = H_1^{-1}(H_2(z)) \\ F_{21}(z) = H_2^{-1}(H_1(z)) \end{cases} \quad (6)$$

式中: z 为强度值。

图像 $I_1(p)$ 、 $I_2(p)$ 与 $I_3(p)$ 之间的亮度映射函数 $F_{13}(z)$ 和 $F_{23}(z)$, 其计算公式为:

$$\begin{cases} F_{13}(z) = (zF_{12}(z))^{0.5} \\ F_{23}(z) = (zF_{21}(z))^{0.5} \end{cases} \quad (7)$$

两幅中间图像 $\tilde{I}_1(p)$ 、 $\tilde{I}_2(p)$ 分别为:

$$\begin{cases} \tilde{I}_1(p) = F_{13}(I_1(p)) \\ \tilde{I}_2(p) = F_{23}(I_2(p)) \end{cases} \quad (8)$$

$\tilde{I}_1(p)$ 、 $\tilde{I}_2(p)$ 得到中等曝光图像 $I_3(p)$:

$$I_3(p) = \frac{w_1(I_1(p))\tilde{I}_1(p) + w_2(I_2(p))\tilde{I}_2(p)}{w_1(I_1(p)) + w_2(I_2(p))} \quad (9)$$

权重函数 w_1 和 w_2 分别定义为:

$$w_1(z) = \begin{cases} 0, & 0 \leq z < \xi_L \\ 1 - 3h_1^2(z) + 2h_1^3(z), & \xi_L \leq z < 55 \\ 1, & \text{otherwise} \end{cases} \quad (10)$$

$$w_2(z) = \begin{cases} 1, & 0 \leq z < 200 \\ 1 - 3h_2^2(z) + 2h_2^3(z), & 200 \leq z < \xi_U \\ 0, & \text{otherwise} \end{cases}$$

式中: ξ_L 和 ξ_U 为常数, $h_1(z)$ 和 $h_2(z)$ 定义为:

$$h_1(z) = \frac{55-z}{55-\xi_L}, h_2(z) = \frac{z-200}{\xi_U-200} \quad (11)$$

1.3 融合权重

以对比度、曝光度和色彩饱和度作为图像融合的 3 个测度因子。其中, 第 k 个图像 $I_k(x, y)$ 融合时的权重 $W_k(x, y)$ 为:

$$W_k(x, y) = C_k(x, y) \times E_k(x, y) \times S_k(x, y) \quad (12)$$

式中: $C_k(x, y)$ 为对比度。

采用 Laplace 算子对图像进行卷积操作, 以实现图像梯度信息的提取, 并基于梯度值计算对比度 $C_k(x, y)$ 。采用高斯曲线对图像进行加权, 将各通道强度值的高斯概率值的乘积作为曝光度 $E_k(x, y)$, 即:

$$E_k(x, y) = e^{-\frac{\sum_{C \in \xi} (I_k^C(x, y) - 0.5)^2}{2\sigma^2}} \quad (13)$$

$$\xi = R, G, B$$

式中: σ 为方差, 取值为 0.2。

以 R 、 G 、 B 三通道的标准差来计算色彩饱和度 $S_k(x, y)$, 其公式为:

$$S_k(x, y) = \sqrt{\frac{\sum_{C \in \xi} (I_k^C(x, y) - M_k(x, y))^2}{3}} \quad (14)$$

$$\xi = R, G, B$$

式中: $M_k(x, y) = \frac{I_k^R(x, y) + I_k^G(x, y) + I_k^B(x, y)}{3}$, 表示 R 、 G 、 B

三通道的平均值。

根据上述方法, 对弱曝光图像进行图像增强, 生成的多曝光图像序列如图 2 所示。



(a) 弱曝光图像 (b) 中等曝光图像 (c) 增强曝光图像

图 2 本文方法生成的多曝光图像

2 车道线检测与拟合

2.1 车道线检测

车道线检测网络以 ERFNet 为原型, 在不对称的编码-解码器结构后添加车道预测分支, 其网络结构如图 3 所示。编码器对输入图像进行高层次的抽象和特征提取, 输出低分辨率的特征图; 解码器利用反卷积将编码器提取的特征映射回原图像尺寸, 输出车道概率图; 车道预测分支与解码器并行工作, 用于判断车道线是否存在。




图 3 车道线检测网络结构图

2.1.1 编码器

编码器由下采样块和 Non-bt-1D 块组成。下采样块将最大池化操作后得到的特征图和卷积化操作后得到的特征图在通道维度上拼接, 详细结构如图 4 所示。




图 4 下采样块

Non-bt-1D 块采用非对称卷积, 并利用残差连接融合输入与输出的特征, 详细结构如图 5 所示。




图 5 Non-bt-1D 结构

2.1.2 解码器

解码器由反卷积块、Non-bt-1D 块、最大池化块和双线性插值构成。解码器对编码器提取的图像特征和语义信息进行上采样操作, 将特征图的分辨率恢复到原始输入图像的大小, 便于后续的车道线拟合。

2.1.3 车道预测分支

车道线分支由卷积块、最大池化块和全连接层组成, 并使用 Sigmoid 函数对是否存在车道线进行预测, 生成一个包含 n 个元素的向量, 代表 n 条车道线。

2.2 车道线拟合

若车道线存在, 则按如下规则进行车道线取点拟合:

- (1) 车道线上取点。首先遍历车道线概率分布图中的每一个像素, 完成整幅图像的均值滤波, 然后沿 y 坐标每隔 20 像素按行进行采样, 并找出该行概率值最高且大于 0.5 的采样点的坐标。
- (2) 判定车道线是否存在。对于每条车道线, 若采样点小于等于 3 个, 则判定车道线不存在, 否则继续执行车道线拟合步骤。
- (3) 车道线拟合。将采样的车道线坐标对在原图上进行 3 次样条拟合, 其中车道线的宽度设置为 30 像素。

3 结果与分析

3.1 数据集

实验采用开源的车道线数据集 CULane, 该数据集涵盖了多种光照条件和驾驶场景, 共计 133 235 张分辨率为 1 640 px $\times$ 590 px 的车道线图像。

3.2 实验结果与分析

3.2.1 图像增强方法对比

图 6 为各图像增强方法增强后的结果及局部细节放大图。可以看出, BPDHE^[5] 增强后的图像存在过曝现象, 细节丢失; JieP^[6] 增强后的图像亮度的提升效果差, 部分区域仍然偏暗; LIME^[7] 增强后的图像存在颜色失真现象, 且包含大量噪声; 而 Zero-DCE^[4] 增强后的图像颜色信息缺失, 整体上有灰蒙的视觉效果。相比之下, 本文方法增强后的图像在保留了整体视觉效果的基础上, 改善了图像的亮度。



(a) CULane 原图



(b) BPDHE 结果



(c) JieP 结果



(d) LIME 结果



(e) Zero-DCE 结果



(f) 本文方法结果

图 6 图像增强方法对比结果图

将图像增强后的结果图输入改进后的车道线检测模型 ERFNet, 实现车道线的预测和拟合, 结果如图 7 所示。可以看出, 本方法可以有效提升图像的亮度, 有利于检测出包含较多位置信息的车道线。



(a) 方法 1 (ERFNet)




(b) 方法 2 (BPDHE + ERFNet)



(c) 方法 3 (JieP + SA-ERFNet)



(d) 方法 4 (LIME + ERFNet)



(e) 方法 5 (Zero-DCE + ERFNet)



(f) 本文方法

图 7 车道线检测结果对比结果图

使用车道线检测的量化指标对低照度增强后的图像进行评价, 结果如表 1 所示。

表 1 与图像增强方法对比

方法	TP	FP	FN	Precision/%	Recall/%	F_1 /%
方法 1	13 486	6 024	6 914	69.12	66.11	67.58
方法 2	13 532	6 459	6 948	67.69	66.07	66.87
方法 3	14 205	6 215	6 988	69.56	67.03	68.27
方法 4	13 620	6 491	7 149	67.72	65.58	66.63
方法 5	14 034	4 807	7 091	74.49	66.43	70.23
本文方法	14 627	5 928	6 341	71.16	69.76	70.45

其中, TP、Precision、Recall 及 F_1 -measure 越大, 表示效果越好; FP、FN 越小, 表明效果越好。可以看出, 本文方法 F_1 -measure 达到了 70.45%, 高于其他方法, 表明在夜间低光照场景下, 具有较好的车道线检测能力。

3.2.2 多曝光融合方法对比

图 8 为各多曝光融合方法融合后的结果及局部细节放大图。可以看出, DUAL^[8] 融合后的结果色彩过饱和, 存在明显的光晕现象。而 DSIFT_EF^[9]、MEFDSIFT^[10]、DEM^[11] 融合后的结果区域局部对比度低, 细节丢失。相比之下, 本文方法融合后的图像细节纹理清晰, 且具有良好的视觉效果。



(a) CULane 原图



(b) DSIFT_EF 结果



(c) MEFDSIFT 结果



(d) DUAL 结果




(e) DEM 结果




(f) 本文方法结果

图 8 多曝光融合方法对比结果图


将图像融合后的结果图输入改进后的车道线检测模型 ERFNet, 实现车道线的预测和拟合, 结果如图 9 所示。可以看出, 本文方法处理后的车道线标志清晰, 干扰因素少, 检测到的车道线位置最为准确。




(a) 方法 1 (ERFNet)




(b) 方法 6 (DSIFT_EF+ ERFNet)




(c) 方法 7 (MEFDSIFT+ ERFNet)



(d) 方法 8 (DUAL+ERFNet)



(e) 方法 9 (DEM+ERFNet)



(f) 本文方法

图 9 多曝光融合方法对比结果图

使用车道线检测的量化指标对低照度增强后的图像进行评价,结果如表 2 所示。可以看出,相较于 ERFNet 方法, DUAL 方法的 F_1 -measure 降低了 2.25%, DSIFT_EF、MEFDSIFT、DEM 方法的 F_1 -measure 略有提升,而本文方法的 F_1 -measure 提升了 2.87%,这表明本文方法能更有效地检测出夜间场景下的车道线。

表 2 与多曝光融合方法对比

方法	TP	FP	FN	Precision/%	Recall/%	F_1 /%
方法 1	13 486	6 024	6 914	69.12	66.11	67.58
方法 6	13 998	6186	7 017	69.35	66.61	67.95
方法 7	14 268	6 149	7 164	69.88	66.57	68.19
方法 8	13 074	5 783	8 091	69.33	61.77	65.33
方法 9	14 210	6 131	7 152	69.87	66.52	68.15
本文方法	14 627	5 928	6 341	71.16	69.76	70.45

4 结语

本文提出了一种基于模拟多曝光融合的夜间车道线检测方法。首先,通过动态阈值划分曝光度无法满足要求的像素集,并利用最大信息熵和灰度映射函数合成模拟的增强曝光图像;其次,采用曝光插值法将弱曝光图像和增强曝光合成中等曝光图像;再次,基于图像对比度、曝光度和色彩饱和度 3 种因子对图像融合加权,并通过多尺度融合得到最终的增强结果图;最后,使用改进的 ERFNet 进行车道线的检测和拟合。实验结果表明,本文方法在夜晚场景下具有良好的性能表现。

参考文献:

- [1] 刘悦,杨桦,王青正.面向复杂光照环境的车道线检测方法[J].激光杂志,2024,45(6):94-99.
- [2] 陈立潮,徐秀芝,曹建芳,等.引入辅助损失的多场景车道线检测[J].中国图象图形学报,2020,25(9):1882-1893.

- [3] ROMERA E, ALVAREZ J M, BERGASA L M, et al. ERFNet: efficient residual factorized ConvNet for real-time semantic segmentation[J].IEEE transactions on intelligent transportation systems, 2017, 19(1): 263-272.
- [4] GUO C L, LI C Y, GUO J C, et al. Zero-reference deep curve estimation for low-light image enhancement[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).Piscataway:IEEE,2020:1780-1789.
- [5] IBRAHIM H, KONG N S P. Brightness preserving dynamic histogram equalization for image contrast enhancement[J]. IEEE transactions on consumer electronics, 2007,53(4): 1752-1758.
- [6] CAI B L, XU X M, GUO K L, et al. A joint intrinsic-extrinsic prior model for retinex[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017: 4000-4009.
- [7] GUO X J, LI Y, LING H B. LIME: low-light image enhancement via illumination map estimation[J]. IEEE transactions on image processing, 2016, 26(2): 982-993.
- [8] WANG Q T, CHEN W H, WU X M, et al. Detail-enhanced multi-scale exposure fusion in YUV color space[J]. IEEE transactions on circuits and systems for video technology, 2020, 30(8): 2418-2429.
- [9] LIU Y, WANG Z F. Dense SIFT for ghost-free multi-exposure fusion[J].Journal of visual communication and image representation, 2015, 31: 208-224.
- [10] LEE S H, PARK J S, CHO N I. A multi-exposure image fusion based on the adaptive weights reflecting the relative pixel intensity and global gradient[C]//2018 25th IEEE international conference on image processing (ICIP). Piscataway: IEEE, 2018: 1737-1741.
- [11] YING Z Q, LI G, REN Y R, et al. A new image contrast enhancement algorithm using exposure fusion framework[J]. Computer analysis of images and patterns, 2017: 36-46.

【作者简介】

李晓旋(1998—),女,安徽宿州人,硕士研究生,研究方向:计算机视觉、图像处理。

(收稿日期:2025-01-14 修回日期:2025-06-11)