光电技术及应用

DOI: 10.16818/j.issn1001－5868.20250611002

基于改进UFLDv2的车道线检测方法

李玉峰，白　桦*，张龙生，周千惠
（沈阳航空航天大学 电子信息工程学院，沈阳 110136）

摘　要： 针对自动驾驶场景中车道线严重遮挡及光照条件差导致检测效率低的问题，文章提出一种改进UFLDv2网络道路检测方法。该方法核心在于构建轻量化主干网络，在特征提取阶段使用SNA，SNB等新型层结构，并结合轻量化注意力机制CBAM，增强特征表示能力；采用有序数学期望损失与原始交叉熵损失混合损失函数，有效平衡计算复杂度与检测准确度；使用混合锚点检测系统实现高效检测，并在CULane数据集上进行实测实验。结果表明，相比原始算法，改进算法所需FLOPs降低了57.5%，同时检测精度（总$F1$分数）提升了0.7%；同时，与其他主流车道线检测网络相比，改进后的网络在极端情况下的车道线检测取得了良好的效果。

关键词： 自动驾驶；道路线检测；混合锚点系统；轻量化网络
中图分类号： TP391.41　**文章编号：** 1001－5868(2025)05－0912－07

Lane Detection Method Based on Improved UFLDv2

LI Yufeng, BAI Hua, ZHANG Longsheng, ZHOU Qianhui
(**College of Electronic Information Engineering, Shenyang Aerospace University, Shenyang 110136, CHN**)

Abstract: Lane detection remains a major challenge in autonomous driving scenarios, particularly on conditions of severe lane occlusion and poor illumination. To improve efficiency and robustness, this paper proposes an enhanced road detection method based on UFLDv2. The approach introduces a lightweight backbone network that integrates SNA and SNB layer structures with the CBAM attention mechanism to strengthen feature representation. A hybrid loss function—combining ordered expectation loss with cross-entropy loss—is designed to balance detection accuracy and computational cost. In addition, a hybrid anchor-based detection framework is employed to further improve performance. Extensive experiments on the CULane dataset demonstrate that, relative to the original algorithm, the proposed method reduces FLOPs by 57.5% while increasing the overall $F1$ score by 0.7%. Compared with other mainstream lane detection networks, the improved method achieves superior performance under extreme conditions of lane occlusion and low illumination.

Key words: autonomous driving; lane detection; hybrid anchor system; lightweight network

0　引言

车道线检测是自动驾驶和高级驾驶辅助系统（ADAS）的关键任务，主要用于识别和定位车道标识，从而为自动驾驶导航提供路线规划，包括变道、转弯等操作[1-2]。然而，在实际应用中，高效且可靠地实现车道线检测仍面临诸多挑战，例如复杂的道路条件、雨雪和雾霾等天气状况，以及光照变化对车道线可见性和检测精度的影响。

深度学习技术的快速发展使得基于卷积神经网

收稿日期：2025－06－11.
基金项目：国家自然科学基金（61671310）；航空科学基金（2019ZC054004）.
*通信作者：白　桦

络(Convolutional Neural Networks, CNN)的车道线检测方法成为研究热点[3-8]。这些方法能够自动从数据中提取有效特征,从而显著提升检测精度。方法包括 UFLDv2[9],SCNN[10],RESA[11]和 LaneATT[12]。其中,UFLDv2 是一种结合锚点和排序分类的新方法,通过引入混合锚点系统,并且能根据不同的车道类型应用不同的锚点系统,有效解决了车道线定位误差放大的问题。SCNN 利用一种特殊的卷积操作来扩展像素级分割的感受野,通过处理切片特征来聚合信息。RESA 则通过递归特征移动操作聚合不同维度的信息,扩大分割网络的感受野。

以上网络都取得了较好的效果,但在部署时仍存在效率不足的问题,未能满足高效应用的需求。ConvNeXt[13],ShuffleNet[14-15]和 MobileNet[16-18]等系列的 CNN 网络高效化研究[19-20]为本文工作提供了重要启发。为解决效率较低的问题,提出了全新的层结构 ShuffnextA(SNA)和 ShuffnextB(SNB),并将其应用于网络主干结构的构建,从而平衡 FLOPs 与检测精度的关系;同时,引入轻量化的注意力机制 CBAM 和基于深度可分卷积的多维度融合头(MFH)[21],以增强网络对全局信息的利用能力,并保持较低的 FLOPs 开销;采用有序数学期望损失函数与原始交叉熵损失函数的混合损失函数,以解决检测精度的问题;在训练过程中,采用随深度加大 Droprate 的 Dropout 方法[22],有效降低过拟合风险;最后,利用混合锚点系统为驱动的高效检测头进行道路线检测。

1　研究方法

改进后的网络结构如图 1 所示,整体网络由特征提取主干和混合锚点检测头组成。特征提取采用自上而下的逐层递进方式,有效保留了空间特征。网络输出为 $N_{\text{lane}} \times N_{\text{row}} \times N_{\text{dim}}$ 的特征矩阵,其中,N_{lane} 是预测的道路线数量,N_{row} 是每条道路的行锚点个数,N_{dim} 是每个行锚点的类个数。网络预测的车道线坐标通过公式(1)进行计算,网络的具体结构如表 1 所示,Conv 表示一个 4×4 的卷积层,步幅为 4。

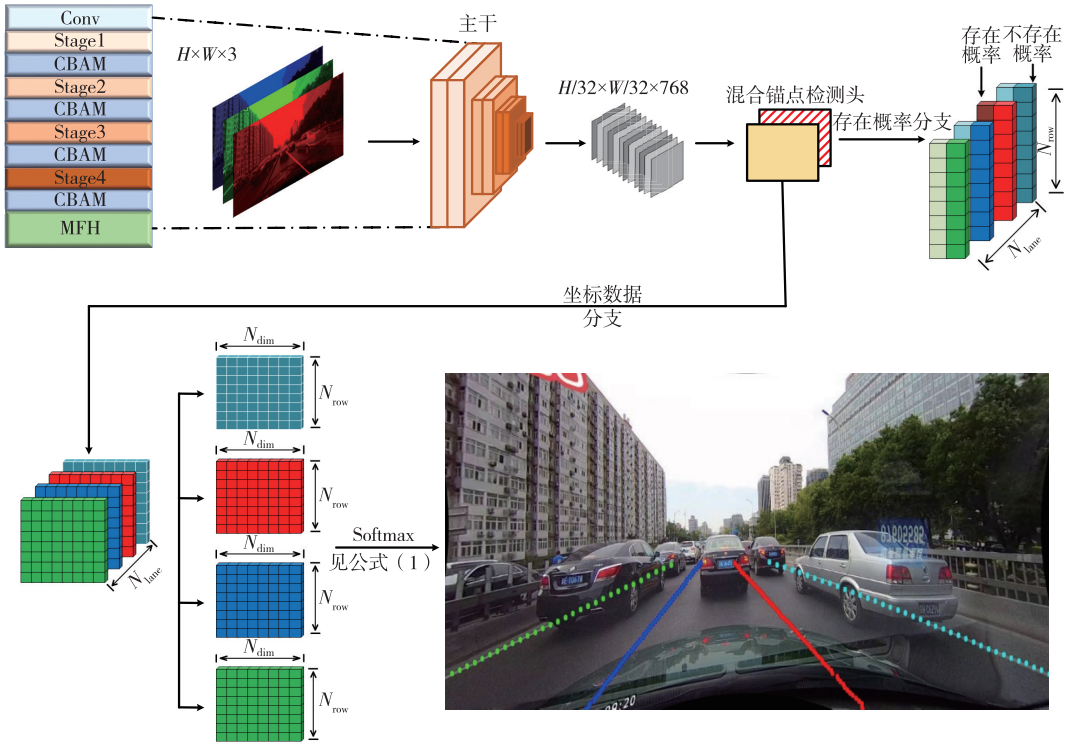


图 1　整体网络框架

$$Loc_{i,j}^{\text{r}}=\begin{cases}\sum_{k=1}^{N} Prob_{i,j}^{\text{r}}[k]\cdot k, & \text{if } E_{i,j}^{\text{r}}[2]>E_{i,j}^{\text{r}}[1]\\ -1, & \text{otherwise}\end{cases} \tag{1}$$

1.1　SNA 模块设计

SNA 的结构如图 2 所示,其设计过程是基于 ShuffleNetV2。首先调整卷积核的大小,实验确定最佳大小为 5×5 以适应较大分辨率的图像;其次减

表1 整体网络构成

名称	SNB数量	SNA数量	输入/输出维度
Conv	0	0	3/96
Stage1	0	2	96/96
Stage2	1	2	96/192
Stage3	1	8	192/384
Stage4	1	2	384/768

少GeLU激活函数的使用，以降低非线性复杂度，使用单个GeLU激活函数可提升检测准确度；此外引入大小为1×1的升降维卷积[23]，但过高的升降维度并未完全适配网络的设计初衷，当维度过大时，会大幅增加运算开销，导致性价比降低。经实验验证，当维度为2时，网络在检测效率与计算开销间达到最佳平衡。将深度可分离卷积放置在分支前端，相比中间位置，这种设计更有利于提升检测性能。最后添加了Dropout层防止过拟合。

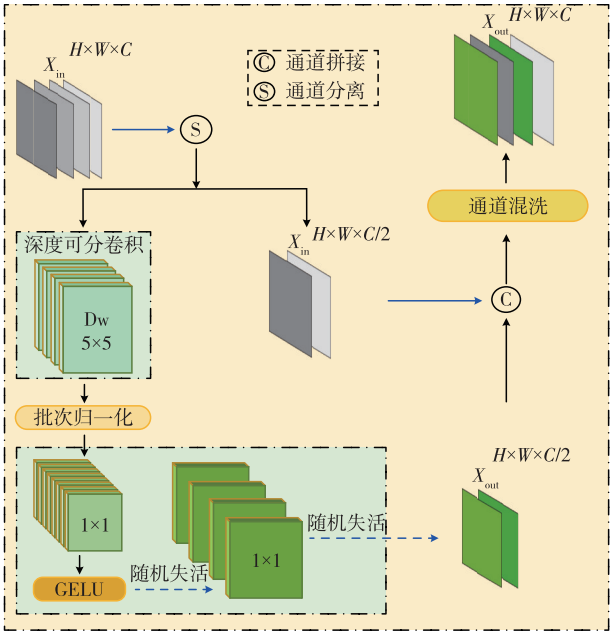


图2 SNA框架

1.2 SNB模块设计

SNB的结构如图3所示。在其设计过程中首先使用大小为2×2、步幅为2的卷积层替代传统的最大池化层[22]。实验表明，这一方案小幅提升了网络准确度。随后，使用深度可分离卷积层替代常规卷积以降低所需FLOPs。其中SNB需要翻倍输入特征图的通道数，因此为其添加一个新的分支。这一调整不仅降低了FLOPs，还提升了检测准确度。此外，通过实验分析两个分支中卷积核大小的最优组合，结果表明，当两个分支的卷积核大小均为5×5时，网络整体性能得到显著提升，同时FLOPs的增加幅度较小。

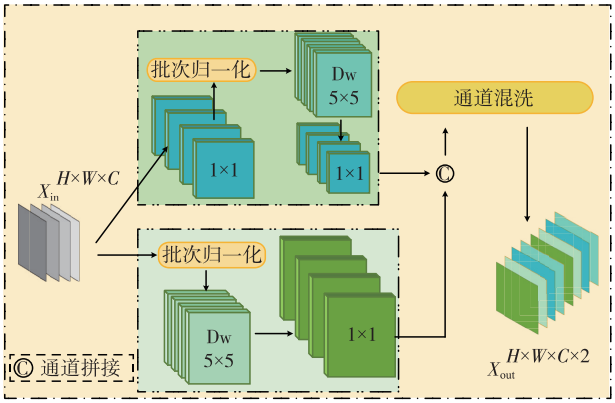


图3 SNB框架

1.3 MFH与CBAM模块

MFH结构如图4所示。由于多尺度融合头放置在网络的后端，输入的维度较大。因此MFH的主干采用深度可分离卷积设计，以平衡FLOPs与检测准确度之间的关系。此外，通过调整卷积核大小，进一步增强网络的感知能力。最后，在投影层中引入Dropout方法，以降低过拟合风险并提升模型的泛化能力。

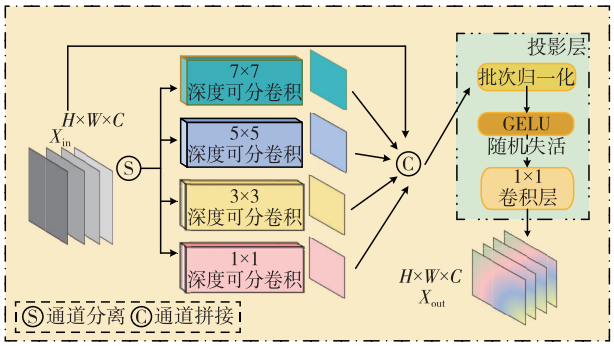


图4 MFH框架

CBAM[24]是一种用于增强卷积神经网络性能的注意力机制模块，结构如图5所示。CBAM由两个子模块组成：通道注意力模块（CAM），其作用是增强不同通道之间的特征交互；空间注意力模块（SAM），其作用是增强特征图中不同空间位置的特征响应。CBAM模块可以显著提升模型在复杂数据集上的性能表现，同时对网络计算量的需求造成的影响极小。

1.4 混合锚点检测头

混合锚点检测头由两部分组成：行锚点与列锚点系统。以行锚点系统为例进行介绍，列锚点系统原理与行锚点系统类似。行锚点系统通过提取输入图像中特定的N_{row}个行，在提取的行上对N_{lane}条车道线进行分类（预测坐标），分类类别总数为N_{dim}。

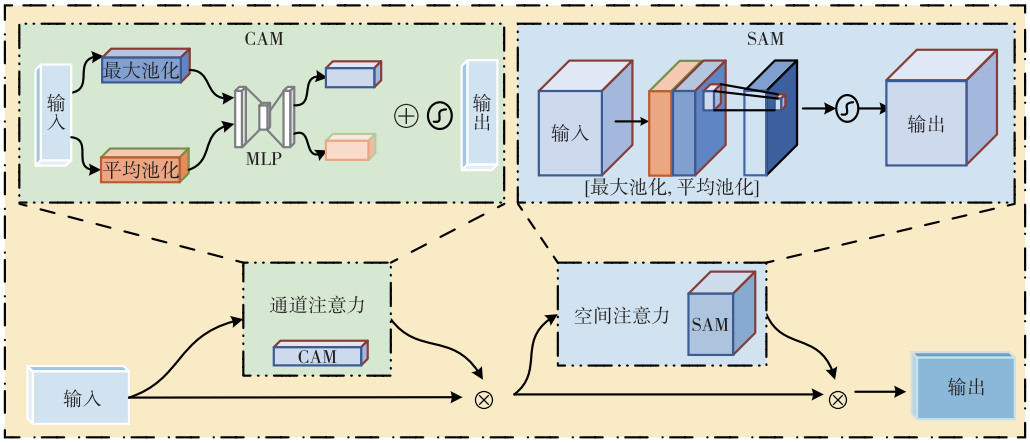


图 5　CBAM 框架

最终输出的特征矩阵为 $N_{\text{lane}} \times N_{\text{row}} \times N_{\text{dim}}$。借助行锚点系统，可以将车道线坐标预测任务转化为：针对 N_{lane} 条车道线在 N_{row} 特定行上，类别个数为 N_{dim} 的分类任务。具体过程如图 6 所示。行锚点检测系统会将 N_{dim} 个类映射为有序的且在空间上具有连续性的类，分类的映射表达式如公式(2)所示：

$$T^{\text{r}}_{\text{cls},i,j}=\left\lfloor T^{\text{r}}_{i,j} N^{\text{r}}_{\text{dim}} \right\rfloor \quad i\in\{1,\cdots,N_{\text{row}}\},j\in\{1,\cdots,N_{\text{lane}}\} \tag{2}$$

式中，$T^{\text{r}}_{i,j}$ 的数值是从 0～1 的归一化数据或－1 的两种情况：－1 表示不存在车道线，从 0～1 表示真实的车道线坐标在行坐标中的归一化数据。$N^{\text{r}}_{\text{dim}}$ 是每行的行锚数量。$\lfloor\cdot\rfloor$ 是向下取整操作，$T^{\text{r}}_{\text{cls},i,j}$ 是第 i 行，第 j 列元素的对应分类类别。

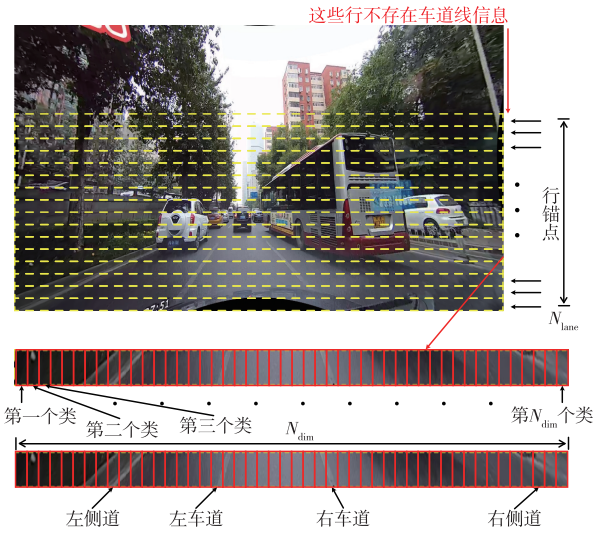


图 6　行锚点系统预测过程

同时网络会预测每个锚点是否存在车道线的概率，预测形式为二分类即存在与不存在的概率，表达式为：

$$T^{\text{r}}_{\text{ext},i,j}=\begin{cases}1, & \text{if } T^{\text{r}}_{i,j}\neq -1\\ 0, & \text{otherwise}\end{cases} \quad i\in\{1,\cdots,N_{\text{row}}\},j\in\{1,\cdots,N_{\text{lane}}\} \tag{3}$$

式中，$T^{\text{r}}_{\text{ext}}$ 是坐标存在性的类别标签，$T^{\text{r}}_{\text{ext},i,j}$ 是 $T^{\text{r}}_{\text{ext}}$ 中第 i 行，第 j 列的元素。

最终，网络的输出由两个主要分支决定：坐标分支和存在分支。其中，坐标分支负责输出车道线的具体坐标预测值，而存在分支则用于预测每条车道线的存在与不存在概率。在推理过程中，当存在分支的存在概率较大时，网络会基于此概率计算出车道线预测值的数学期望，从而获得网络预测的具体每条车道线的坐标信息。

1.5　损失函数

在传统分类任务中，相邻类别通常不相关，而本文中网络的特点是相邻的类具有相关性，为适应分类类别的有序关系，采用综合损失函数，结合基础分类损失、存在损失和有序数学期望损失，以优化有序分类任务。综合损失函数为：

$$L=L_{\text{cls}}+L_{\text{ext}}+L_{\text{exp}} \tag{4}$$

1.5.1　基本分类损失函数

基础分类损失函数如公式(5)所示：

$$L_{\text{cls}}=\sum_{i=1}^{N_{\text{lane}}}\sum_{j=1}^{N_{\text{row}}} L_{\text{CE}}\left(P^{\text{r}}_{i,j},\text{onehot}\left(T^{\text{r}}_{\text{cls},i,j}\right)\right) \tag{5}$$

式中，L_{CE} 是交叉熵损失，$P^{\text{r}}_{i,j}$ 是第 i 条车道第 j 行锚点的预测值，$T^{\text{r}}_{\text{cls},i,j}$ 是 $P^{\text{r}}_{i,j}$ 对应的分类标签，onehot(.)是onehot热编码函数。

1.5.2　存在损失函数

存在损失函数定义如公式(6)所示，用于预测某个锚点是否存在车道线：

$$L_{\text{ext}}=\sum_{i=1}^{N_{\text{lane}}}\sum_{j=1}^{N_{\text{row}}} L_{\text{CE}}\left(E^{\text{r}}_{i,j},\text{onehot}\left(T^{\text{r}}_{\text{ext},i,j}\right)\right) \tag{6}$$

式中，$E^{r}_{i,j}$是第i条车道第j行锚点的预测存在概率值，$T^{r}_{ext,i,j}$是第i行j列锚点的存在标签。

1.5.2 有序数学期望损失函数

为方便将期望表示为公式(7)，其中$prob^{r}_{i,j}[k]$中[•]代表索引操作。$prob^{r}_{i,j}[k]$的含义是第i条车道，第j行中第k个分类结果的预测概率，则$Exp^{r}_{i,j}$是相应的数学期望。其中$prob$定义为公式(8)所示。

$$Exp^{r}_{i,j}=\sum_{k=1}^{Ndim} prob^{r}_{i,j}[k]\cdot k \tag{7}$$

$$prob^{r}_{i,j}=\mathrm{soft\,max}\left(P^{r}_{i,j}\right) \tag{8}$$

$$L_{exp}=\sum_{i=1}^{N_{lane}}\sum_{j=1}^{N_{row}} L_1\left(Exp^{r}_{i,j},T^{r}_{cls,i,j}\right) \tag{9}$$

有序数学期望损失如公式(9)所示。$T^{r}_{cls,i,j}$是对应于$P^{r}_{i,j}$的分类标签，$L_1(\cdot)$是平滑L_1损失函数。

2 实验设计

2.1 数据集与评价指标

为验证本文方法的有效性，在公开的车道检测数据集CULane上进行实验。该数据集包含超过10 000张分辨率为1 640×590的图像，九种典型的驾驶环境，包括拥挤路段、夜间路段、无车道线路段、阴影路段、箭头路段、强光路段、弯道、十字路口等。

实验采用CULane数据集的评估指标，通过计算真实值与预测值之间的交并比(IoU)来评估检测性能。当IoU大于0.5时，预测结果被认为是真阳性(TP)。主要评估指标为$F1$分数，其定义如公式(10)所示，其中FP代表假阳性，FN代表假阴性。

$$F1=\frac{2\times P\times R}{P+R}$$
$$P=\frac{TP}{TP+FP},R=\frac{TP}{TP+FN} \tag{10}$$

2.2 实验环境与实验策略

实验运行环境的硬件配置包括：13th Gen Intel(R) Core(TM) i7-13700F处理器、Nvidia RTX 4070 GPU(12 GB显存)、操作系统为Ubuntu 20.04。软件环境为PyTorch 1.10.0和CUDA 11.0。优化器采用SGD，初始学习率设置为0.005，并在第100个Epoch时将学习率降低至原来的1/10，总训练轮数为200。输入图像调整为1 600×320分辨率，批处理大小(Batch Size)设定为8。

2.3 消融实验

2.3.1 应用不同模块的结果对比

由表2分析可知，当使用ShuffleNetV2作为主干网络时，基准测试结果为Base。将SNA替代原本结构中的卷积层后，总$F1$分数提升至74.3%，同时FLOPs增加了403 M。当进一步引入SNB，MFH和CBAM方法后，总$F1$分数分别提升了0.4%，0.5%和0.2%，FLOPs增加了149 M，表明在提升性能的同时，较好地平衡了检测准确度与FLOPs之间的关系。最终，相较于UFLDv2，FLOPs减少了1.2 G，仅为原始模型的42.5%，而总$F1$分数提升至75.4%，实现了0.7%的增长。这一结果验证了改进方法的有效性。

表2 应用不同模块后的测试结果

模块	参数	
	MFLOPs	总$F1$/%
Base	310	72.2
Base+SNA	713	74.3
Base+SNA+SNB	798	74.7
Base+SNA+SNB+MFH	857	75.2
Base+SNA+SNB+MFH+CBAM	862	75.4

2.3.2 实验细节

表3展示了本次实验的具体内容。第一行为直接使用ShuffleNetV2作为主干网络的测试结果。第

表3 消融实验细节

Baseline	调整深度	调整层结构	卷积大小	升降倍数	SNB	Droprate	MFH	CBAM	*MFLOPs*	总$F1$/%
SNetV2	—	—	—	—	—	0	—	—	310	72.2
SNetV2	√	—	3	0	—	0	—	—	674	73.6
ADLR	√	√	3	0	—	0	—	—	583	73.4
ADLR	√	√	5	0	—	0	—	—	602	73.8
ADLR	√	√	5	0	√	0	—	—	583	74.2
ADLR	√	√	5	2	√	0	—	—	798	74.6
ADLR	√	√	5	2	√	0.2	—	—	798	74.7
ADLR	√	√	5	2	√	0.2	√	—	857	75.2
ADLR	√	√	5	2	√	0.2	√	√	862	75.4

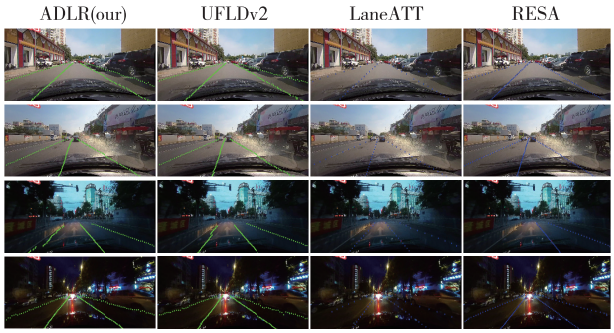
二行通过增加网络层深，总$F1$分数提升1.4%，但FLOPs增加364 M，说明单纯增加层深已无法显著提升性能。第三行则通过引入新的Stage1、降低层深并调整层间比例的方法来优化网络结构，网络性能进一步提升，总$F1$分数降低0.2%，同时FLOPs减少91 M。第四行的优化为调整卷积核大小为5（SNB和SNA），总$F1$分数提升0.4%，FLOPs仅增加19 M。第五行为引入了SNB后的结果，此时总$F1$分数提升0.4%，且FLOPs减少了19 M。随后在第六行中，为SNA加入了升降维度为2的1×1卷积层，对应的测试结果显示，总$F1$分数提升0.4%，同时FLOPs增加了215 M。

最后三行分别为引入Dropout方法、MFH模块和CBAM模块后的实验结果。综合以上所有改进方法，最终的网络性能达到最佳水平：与原始网络UFLDv2相比，总$F1$参数提升了0.7%，同时FLOPs降低了1.2 G。进一步验证了本文方法的有效性。

2.4　与其他模型的检测效果对比

2.4.1　可视化结果对比

为进一步验证本文网络相较于其他网络的有效性，分别与UFLDv2[9]，RESA[11]与LaneATT[12]进行对比试验，各网络的检测结果如图7所示。分别展示了正常、道路拥挤与夜间拥堵情况下的检测结果。可以观察到：RESA在图7第三行中出现了漏检现象，而LaneATT和UFLDv2在同一场景下的最左侧的车道线均发生了右偏。然而本文网络的大部分检测点仍然保持了正确的位置，表明本文提出的网络结构能够利用更多信息，显著提升检测精度。



（a）本文网络运行结果　（b）UFLDv2运行结果　（c）LaneATT运行结果　（d）RESA运行结果

图7　运行可视化结果

2.4.2　网络参数对比

本文网络与其他网络的具体运行参数结果见表4，所提出的网络在车道线检测效果上优于表中列出的其他六种网络。在仅需0.86 GFLOPs的前提下，总$F1$分数达到了75.4%。此外在正常路段、拥挤路段、阴影路段、无标线路段和夜间路段的检测中，均取得了最高的$F1$分数。与UFLDv2对比，改进后的网络在总$F1$分数上提升了0.7%，并且在各类路段的$F1$分数上均有所提高。此外，FLOPs减少了1.2 G，计算需求显著降低。实验结果验证本文改进方法的有效性和鲁棒性。

表4　网络参数对比

方法	正常	拥挤	强光	阴影	无标线	箭头	弯道	夜间	*GFLOPs*	总$F1$
SCNN	90.6	69.7	58.5	66.9	43.4	84.1	64.4	66.1	9.9	71.6
RESA（Res34）	91.9	72.4	66.5	72.0	46.3	88.1	68.6	69.8	4.0	74.5
RESA（Res50）	92.1	73.1	**69.2**	72.8	47.7	**88.3**	**70.3**	69.9	11.5	75.3
LaneATT	91.1	72.9	65.7	70.9	48.3	85.4	63.3	68.9	1.8	75.1
UFLDv1	87.7	66.0	58.4	62.8	40.2	81.0	57.9	62.1	1.9	68.4
UFLDv2	91.7	73.0	64.6	74.7	47.2	87.6	68.7	70.2	2.0	74.7
ADLR(our)	**92.4**	**73.9**	67.4	**76.1**	**48.6**	88.1	69.7	**70.4**	**0.9**	**75.4**

注：总$F1$是综合了所有环境下的$F1$分数。2～8列为不同环境下的$F1$分数，加粗内容为最佳结果。

3　结论

本文针对自动驾驶领域中道路线检测效率较低的问题，提出一种改进的UFLDv2网络用于道路线检测。该方法依托基于全局特征的轻量化网络主干，通过自上而下的层次结构提取特征，并通过混合锚点系统对车道线信息进行学习与预测。相较于原始的UFLDv2网络，本方法替换了主干网络，采用了全新的轻量化结构，结合了SNA和SNB等模块，在平衡准确性与计算开销方面表现优秀。同时，引入离散多尺度融合头增强网络对全局信息的利用能力，并采用轻量化注意力机制CBAM模块进一步提升检测能力。通过大量实验验证，本文方法相较于UFLDv2提高了0.7%的总$F1$分数，同时FLOPs降低至原始模型的42.5%，在道路线检测中

展现了较好的鲁棒性与泛化能力。

参考文献：

[1] Burleigh N, King J, Braunl T. Deep learning for autonomous driving[C]//2019 Digital Image Computing: Techniques and Applications (DICTA), 2019: 1-8.

[2] Al Mamun A, Ping E P, Hossen J, et al. A comprehensive review on lane marking detection using deep neural networks [J]. Sensors, 2022, 22(19): 7682.

[3] 常振廷，肖智豪，张文军，等. 基于网格分类与纵横向注意力的城市道路车道线检测方法[J]. 交通信息与安全，2023，41(3)：92-102，110.
Chang Zhenting, Xiao Zhihao, Zhang Wenjun, et al. A method for detecting edge lines of traveling lanes of urban roads based on grid classification and vertical-horizontal attention[J]. Journal of Transport Information and Safety, 2023, 41(3): 92-102, 110.

[4] 王碧瑶，韩　毅，崔航滨，等. 基于图像的道路语义分割检测方法[J]. 山东大学学报(工学版)，2023，53(5)：37-47.
Wang Biyao, Han Yi, Cui Hangbin, et al. Image-based road semantic segmentation detection method [J]. Journal of Shandong University (Engineering Science), 2023, 53(5): 37-47.

[5] 丁　玲，肖进胜，李必军，等. 基于语义分割与道路结构的车道线检测方法[J]. 交通信息与安全，2023，41(3)：103-110.
Ding Ling, Xiao Jinsheng, Li Bijun, et al. Lane detection method based on semantic segmentation and road structure[J]. Journal of Transport Information and Safety, 2023, 41(3): 103-110.

[6] Sapkal A, Arti, Pawar D, et al. Lane detection techniques for self-driving vehicle: comprehensive review [J]. Multimedia Tools and Applications, 2023, 82(22): 33983-34004.

[7] Li J. Lane detection with deep learning: methods and datasets [J]. Information Technology and Control, 2023, 52(2): 297-308.

[8] Dewangan D K, Sahu S P. Lane detection in intelligent vehicle system using optimal 2- tier deep convolutional neural network [J]. Multimedia Tools and Applications, 2023, 82(5): 7293-7317.

[9] Qin Z, Zhang P, Li X. Ultra fast deep lane detection with hybrid anchor driven ordinal classification [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(5): 2555-2568.

[10] Zhao H, Sun X, Yan J, et al. Spatial as deep: spatial CNN for traffic scene understanding [C]//AAAI Conference on Artificial Intelligence, 2018: 7276-7283.

[11] Zheng T, Fang H, Zhang Y, et al. RESA: recurrent feature-shift aggregator for lane detection[J]. AAAI Conference on Artificial Intelligence, 2021, 35(4): 3547-3554.

[12] Tabelini L, Berriel R, Paixão T M, et al. Keep your eyes on the lane: real-time attention-guided lane detection[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 294-302.

[13] Liu Z, Mao H, Wu C Y, et al. A ConvNet for the 2020s [C]//Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 11966-11976.

[14] Zhang X, Zhou X, Lin M, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.

[15] Ma N, Zhang X, Zheng H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [C]//Computer Vision – ECCV 2018, 2018: 122-138.

[16] Howard A G, Zhu M L, Chen B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint, 2017: arXiv:1704.04861.

[17] Sandler M, Howard A, Zhu M, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.

[18] Howard A, Sandler M, Chu G, et al. Searching for MobileNetV3 [C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 1314-1324.

[19] Zhang L, Zhang L, Song C, et al. Hyperspectral image compression sensing network with CNN – transformer mixture architectures [J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 5506305.

[20] Tan M, Le Q V. MixNet: Mixed depthwise convolutional kernels[J]. arXiv preprint, 2019: arXiv:1907.09595.

[21] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation [J]. arXiv preprint, 2017: arXiv:1706.05587.

[22] Tan M, Le Q V. EfficientNetV2: smaller models and faster training [C]//Proceedings of the 38th International Conference on Machine Learning, 2021: 10096-10106.

[23] Liu Z, Lin Y, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows [C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), 2021: 9992-10002.

[24] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module [C]//Computer Vision – ECCV 2018, 2018: 3-19.

作者简介：

李玉峰(1969—)，男，吉林省德惠市人，教授，硕士生导师，主要研究方向为信号与信息处理，机器视觉与导航等；

白　桦(2000—)，男，河北省保定市人，硕士研究生，主要从事图像处理，自动驾驶方向的研究。