面向低功耗嵌入式系统的实时车道线检测：高效特征对齐与协方差优化

Yian Liu[1] · Xiong Wang[2] · Ping Xu[1], Lei Zhu[1] · Ming Yan[1] · Linyun Xue[1]

摘要
由于 RGB 图像中的视觉信号微弱且稀疏，嵌入式系统中的实时车道线检测面临重大挑战，同时还常受计算资源和功耗有限的制约。尽管用于车道线检测的深度学习模型可分为基于分割、基于锚点和基于曲线的方法，但针对低功耗嵌入式环境的通用优化技术仍然十分有限。为此，我们提出一种创新的协方差分布优化（CDO）模块，专为高效实时应用而设计。该 CDO 模块使车道线特征分布与真实标签紧密对齐，在不增加计算复杂度的情况下显著提升检测准确率。我们在三类方法的六种不同模型上进行了评估，其中包括两种针对实时应用优化的模型和四种最先进模型，并在三个主要数据集 CULane、TuSimple 和 LLAMAS 上进行了全面测试。实验结果表明，准确率提升幅度为 0.01% 至 1.5%。所提出的 CDO 模块易于集成到现有系统中，无需修改其结构，并利用现有模型参数支持持续训练，因此在嵌入式系统的性能、能效和运行灵活性方面具有显著优势。

关键词 车道线检测·深度学习·嵌入式环境

1 引言

车道线检测或识别是自动驾驶、高级驾驶辅助系统（ADAS）以及更广泛的自主机器人应用领域中的一项关键任务。准确的车道线感知有助于决策过程，提供车道偏离预警（LDW），支持自适应巡航控制（ACC），并为碰撞规避提供导航引导 [1]。除汽车系统外，这项技术还可应用于在结构化或半结构化环境中运行的自主机器人，从而实现稳健的路径跟随、路径规划和安全导航 [2]。

由于车道线结构细窄、边缘边界受损或消失、其他车辆遮挡、道路标记错误以及光照条件差等问题，车道线检测在实践中极具挑战性 [3]。

✉Yian Liuyaliu@hdu.edu.cnXiong Wangfanyway@foxmail.comPing Xuxuping@hdu.edu.cnLei Zhuzhulei@hdu.edu.cnMing Yanyanming@hdu.edu.cnLinyun Xuexly@hdu.edu.cn[1] 杭州电子科技大学自动化学院，中国杭州[2] 杭州泰卡福科技有限公司，中国杭州

此外，在移动设备上部署时，图像实时处理的效率和模型的轻量化需求至关重要 [4]。不同于基于CNN的车道线检测方法，最新研究提出了许多新的网络结构，用于从全局上下文信息中提取高层车道线信息，例如车道线的线形、曲线参数和高层语义特征 [5]。尽管最先进（SOTA）网络框架相较于传统方法已展现出显著优势，但目前仍缺乏能够在所有三类方法中优化网络性能的通用方法。在实际应用中，通用优化方法不应增加推理时间，并且应能够通过提取全局上下文信息来抑制车道线误预测 [6]。

本文提出了一种协方差分布优化（CDO）模块，专为嵌入式系统中常见的轻量级配置而设计，因为低功耗至关重要。通过计算车道线特征与真实标签在垂直和水平方向上的协方差矩阵，CDO模块能够为实时车道线检测实现高效的特征对齐。该设计受到方差-不变性-协方差正则化（VICReg）的启发；VICReg在图像表征学习的自监督方法中取得了最先进的性能 [7]。协方差矩阵通过矩阵乘法计算，并用作车道线特征与真实标签之间的区域相似性描述符。矩阵的对角元素表示相应方向上的自相似性，而非对角元素则捕捉跨方向相关性，从而全面刻画空间特征对齐情况。协方差矩阵可以表示车道线特征与实际车道线位置之间的相似度，因此提高相似度能够有效改善车道线检测结果。如图1所示，CDO模块沿水平和垂直两个正交方向比较特征图与真实值（GT）标签掩码之间的相似度。由于相关算法能够考虑像素间的长距离关系，因此该方法在保持车道线整体几何特征的同时，可以克服车道线检测中的信号稀疏问题。通过这种方式，每条车道线的位置相关信息都能在特征图中得到强化，从而提高端到端车道线检测准确率。CDO的三项主要优势如下：第一，只要车道线之间距离不太近，就可以轻松地将CDO应用于任意特征图；第二，大多数车道线检测模型的总损失函数都可以轻松补充基于CDO的损失函数，而且CDO无需重新设计网络的原始结构；第三，CDO可以利用模型现有参数优化原始模型，且不会增加车道线推理时间。Th

e mai总结tributi结论本文本文的 b总结 ized as follows:

- 我们提出了一种轻量且具有良好泛化能力的协方差分布优化（CDO）模块，可无缝集成到各种最先进的车道线检测模型中，包括针对实时应用和嵌入式应用优化的模型；
- 通过采用协方差计算和对角凸估计，我们证明了优化车道线特征与标签掩码之间协方差矩阵的分布，能够显著提升现有车道线检测框架的性能；
- 所提出的CDO模块无需修改模型架构，即可使用现有参数训练模型，并能部署于现有车道线检测系统中，从而为嵌入式系统提供高效、低功耗的优化方案。

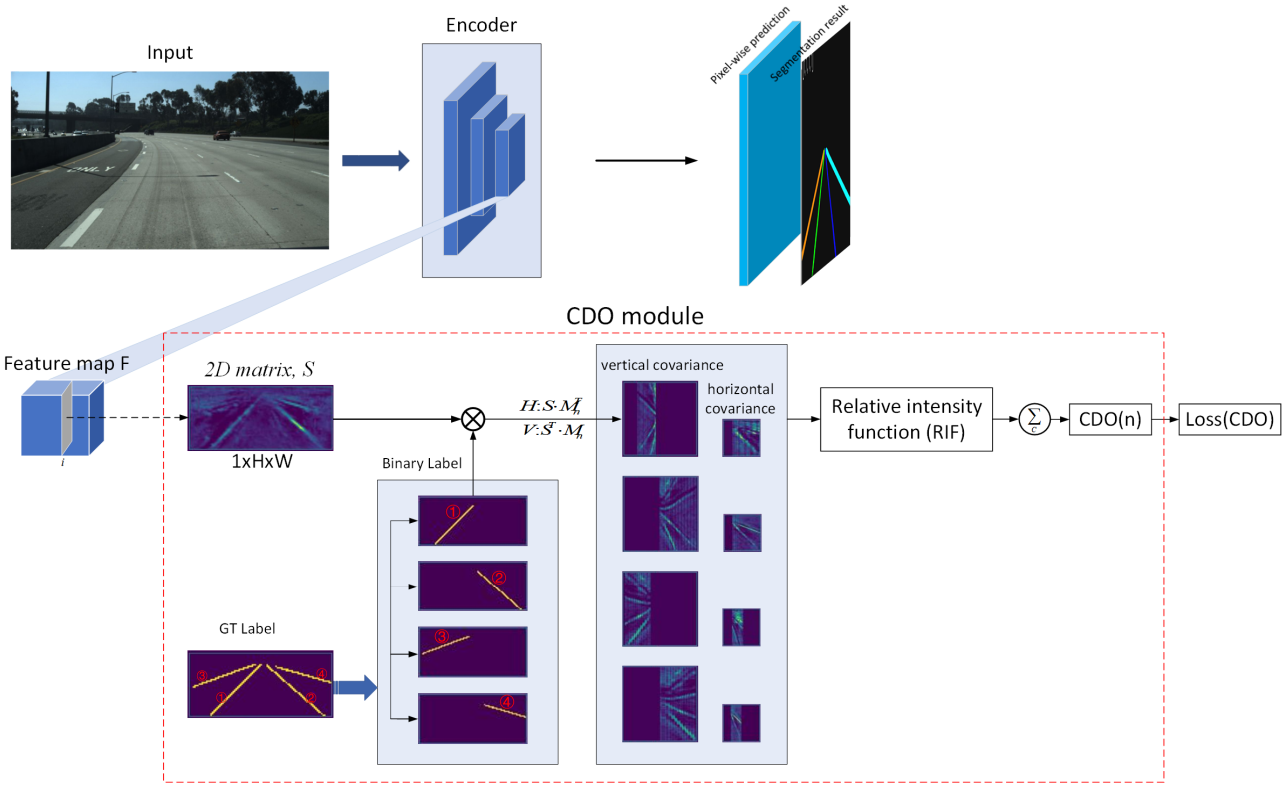

图1 CDO（即 CDO 模块）的架构设计基于协方差计算和 RIF。CDO 的工作流程如下：将每条车道线的特征图与标签掩码相乘，生成该车道线的垂直协方差矩阵和水平协方差矩阵。随后使用这些矩阵进行 RIF 计算。CDO(n) 使用 RIF 计算两个正交方向上车道线特征与标签的相似度。CDO 的损失用于优化原始车道线检测网络。

2 相关工作

传统车道线检测技术存在诸多缺点，例如，复杂的手工特征选择流程仅适用于光照正常、遮挡较少的简单驾驶场景 [8]。近年来，基于深度学习的方法以端到端的方式展现出优异的车道线检测性能 [9]。这些方法通常将车道线检测分为三类：基于分割的方法、基于锚点的方法和基于曲线的方法 [10]。

2.1 基于分割的车道线检测

基于分割的方法通常将车道线检测视为逐像素分割任务。这些方法通常结合两个独立模块：编码器和解码器 [11]。编码器模块利用一系列卷积层提取深层特征。解码器模块则从特征中恢复空间细节。许多近期发表的基于分割的方法尝试改进编码器，以提高车道线检测的精度。SCNN在编码器的隐藏层中采用消息传递机制，对离散车道线像素中的空间信息进行聚合 [12]。LaneNet在编码器中提出了二元分割分支和实例分割分支，使车道线检测方法能够适应道路平面变化 [13]。RESA提出了实时循环特征移位聚合器，使网络能够收集全局特征并提升性能 [14]。自适应多车道线检测方法提出了一种将实例分割与车道线中心估计相结合的方法，可提取用于前景提取的判别特征 [15]。

2.2 基于锚点的车道线检测

基于锚点的模型将车道线检测视为基于点的目标检测问题，并利用锚点进行特征池化。Line-CNN在车道线检测中使用预定义的一级线锚点。锚点结构将Faster R-CNN中的基于区域的目标表示转换为基于线的表示 [16]。LaneATT提出了一种基于线锚点的单阶段注意力机制，其特征池化操作与Fast R-CNN类似 [17]。该方法取得了最先进的结果，同时展现出更高的效能和效率。UFAST将车道线检测表述为基于行锚点的分类问题。对于每一行，UFAST都会预测车道线位置，并采用轻量级骨干网络来实现较高的推理速度 [18]。CondLaneNet提出了循环实例模块（RIM），以解决密集线条和分叉线条等复杂车道线拓扑结构带来的问题 [19]。CondLaneNet采用基于行锚点的表述方式，并根据动态核参数预测线形。CLRNet采用FPN结构获取车道线先验特征，并提出ROIGather模块以捕获全局上下文信息 [20]。

2.3 基于曲线的车道线检测

基于曲线的方法将车道线视为多项式曲线，并通过回归曲线参数来表示车道线。PolyLaneNet采用多项式表示车道线，并通过全连接层预测多项式系数 [21]。LSTR将Transformer引入车道线检测任务，基于DETR结构以端到端的方式预测车道线形状的多项式 [22]。BézierLaneNet使用经典的三次贝塞尔曲线对线形进行建模，并在训练过程中最小化真实曲线与预测车道线之间的距离 [5]。BézierLaneNet的优点是模型易于收敛，且对超参数不太敏感。

3 方法

尽管基于分割、基于锚点和基于曲线的车道线检测方法已得到广泛研究，但在真实场景中实现稳健的车道线检测仍是一项重大挑战。其主要局限包括：分割方法中的表示错位、基于锚点的方法对人工设计的特定于数据集的锚点高度依赖，以及基于曲线的模型中高阶多项式系数导致的不稳定性，这可能会不可预测地扭曲车道线几何形状。为解决这些问题，我们提出了一种适用于这三类车道线检测模型的统一端到端优化策略。我们的方法围绕以下关键目标进行设计：

- **轻量化集成：**优化方法应尽量减少对原始网络架构的修改，并避免显著增加参数数量，从而确保其兼容资源受限的嵌入式系统。
- **上下文感知学习：**该方法应具备较大的感受野，以有效捕获非局部上下文特征，从而能够检测被遮挡或不连续的车道线，同时保持不同车道实例之间清晰的区分。
- **效率与准确率：**该优化技术必须易于实现，并能够在提高车道检测准确率的同时保持较高的推理速度，从而支持在低功耗环境中实时部署。

3.1 协方差矩阵与注意力相关性

整体模型架构如图1所示。CDO 的输入是一个中间特征图。F 的每个通道都可以视为一个二维矩阵。$F \in R^{P \times H \times W}$ 在训练数据集中，每幅输入图像都有一个二值车道线掩码。$S \in H \times W$ 随后，使用 OpenCV 的 resize 函数和最近邻插值，将该掩码缩放为新的掩码 M_n，其尺寸为 $H \times W$。为计算水平和垂直车道线特征及掩码的协方差矩阵，我们分别计算矩阵 S 的每一行与 M_n 的每一行之间的协方差，以得到水平协方差矩阵；并计算S 的每一列与 M_n 的每一列之间的协方差，以得到垂直协方差矩阵。这两个矩阵定义如下：

$$COV_n^{\theta} = \begin{bmatrix} s_{11} & s_{12} & \cdots & s_{1W} \\ s_{21} & s_{22} & & s_{2W} \\ \vdots & \vdots & \ddots & \vdots \\ s_{H1} & s_{H2} & \cdots & s_{HW} \end{bmatrix} \begin{bmatrix} m_{11} & m_{12} & \cdots & m_{1W} \\ m_{21} & m_{22} & & m_{2W} \\ \vdots & \vdots & \ddots & \vdots \\ m_{H1} & m_{H2} & \cdots & m_{HW} \end{bmatrix}^T = \begin{bmatrix} h_{11} & h_{12} & \cdots & h_{1H} \\ h_{21} & h_{22} & & h_{2H} \\ \vdots & \vdots & \ddots & \vdots \\ h_{H1} & h_{H2} & \cdots & h_{HH} \end{bmatrix} \quad (1)$$

$$COV_n^{\phi} = \begin{bmatrix} s_{11} & s_{12} & \cdots & s_{1W} \\ s_{21} & s_{22} & & s_{2W} \\ \vdots & \vdots & \ddots & \vdots \\ s_{H1} & s_{H2} & \cdots & s_{HW} \end{bmatrix}^T \begin{bmatrix} m_{11} & m_{12} & \cdots & m_{1W} \\ m_{21} & m_{22} & & m_{2W} \\ \vdots & \vdots & \ddots & \vdots \\ m_{H1} & m_{H2} & \cdots & m_{HW} \end{bmatrix} = \begin{bmatrix} v_{11} & v_{12} & \cdots & v_{1W} \\ v_{21} & v_{22} & & v_{2W} \\ \vdots & \vdots & \ddots & \vdots \\ v_{W1} & v_{W2} & \cdots & v_{WW} \end{bmatrix} \quad (2)$$

这里，S和 M_n 进行矩阵乘法，其中n 表示图像中的第n^{th} 条车道线，$s_{i,j}$ 是矩阵 S中的一个元素，$m_{i,j}$ 是矩阵 M_n中的一个元素。H 和 W 分别表示特征图的尺寸，对应于水平协方差矩阵和垂直协方差矩阵的尺寸。h_{ij} 表示矩阵 S 的行向量与 M_n的行向量之间的关系。垂直协方差矩阵中的 $v_{i,j}$ 表示矩阵S 的列向量与 M_n的列向量之间的关系。 θ、 ϕ分别表示水平方向和垂直方向。水平协方差矩阵衡量水平方向上车道线特征与标签的相似度，因此对该方向上的变化更为敏感。同样，垂直协方差矩阵衡量垂直方向上车道线特征与标签的相似度，因此对该方向上的变化更为敏感。通过分析这两个矩阵，我们可以更全面地了解车道线空间分布的变化，并更准确地预测车道线的位置。协方差矩阵的对角元素可以表示行或列之间的相似度，非对角元素则表示它们之间的相关性。通过协方差计算，特征图中对应的车道线特征得到增强，而不相关信息则受到抑制。为了观察协方差矩阵中对角元素的显著性

, 我们定义一个简单函数 .

$$AVG(COV_n^{\theta}) = \frac{1}{H \times H} \sum_{i,j} h_{i,j} \quad (3)$$

$$AVG(COV_n^{\phi}) = \frac{1}{W \times W} \sum_{i,j} v_{i,j} \quad (4)$$

$$DIAG(COV_n^{\theta}) = \frac{1}{H} \sum_{i=j} h_{i,j} \quad (5)$$

$$DIAG(COV_n^{\phi}) = \frac{1}{W} \sum_{i=j} v_{i,j} \quad (6)$$

这里，AVG( ) 是用于计算矩阵均值的平均函数。DIAG( ) 是用于计算协方差矩阵对角元素均值的函数。

在 CDO 过程中，所有计算步骤都可以通过简单的数学运算完成。首先，我们计算协方差矩阵的 AVG( ) 和 DIAG( )。然后，使用方程（7）和（8）中定义的相对强度函数（RIF），计算矩阵中对角元素的显著性。最后，我们将所有通道上的 RIF 均值作为 CDO 的输出。该输出可以视为车道线显著性的定量测量。

$$RIF_{\theta}(n) = \frac{\left|DIAG\left(COV_n^{\theta}\right) - AVG(COV_n^{\theta})\right|}{max\left(DIAG\left(COV_n^{\theta}\right), AVG(COV_n^{\theta})\right)} \tag{7}$$

$$RIF_{\emptyset}(n) = \frac{\left|DIAG\left(COV_n^{\emptyset}\right) - AVG(COV_n^{\emptyset})\right|}{max\left(DIAG\left(COV_n^{\emptyset}\right), AVG(COV_n^{\emptyset})\right)} \tag{8}$$

$$CDO(n) = \frac{1}{2C}\left[\alpha \sum_{i=1}^{C} RIF_{\theta}(n,i) + \beta \sum_{i=1}^{C} RIF_{\emptyset}(n,i)\right] \tag{9}$$

在此处，$RIF_{\theta}(n)$ 和 $RIF_{\emptyset}(n)$ 分别根据水平协方差和垂直协方差计算 n^{th} 车道线的相对强度。在公式（9）中，$CDO(n)$ 计算 n^{th} 车道线的平均 RIF 值。α 和 β 分别表示水平方向和垂直方向的权重系数。我们可以设置 $\alpha+\beta=1$，而 α 和 β 的取值取决于检测中主车道的方向。α 和 β 的典型取值为 α=0.5 和 β=0.5。C 表示通道数。

3.2 将 AddCDO 添加到模型中

在为实际应用设计实时车道线检测模型时，必须牢记处理速度和尽可能减少计算资源的重要性。由于注意力机制仅依赖中间特征输出，CDO 可应用于结构各异的多种模型。CDO 的设计理念是提出一种更易于使用的方法，专注于挖掘特征的长程依赖，并通过协方差计算获取水平方向和垂直方向上的全局特征关系。与需要大量内存的非局部方法不同，CDO 仅使用矩阵乘法，所需计算资源非常有限。

我们选取了四种最先进的车道线检测模型和两种广泛使用的实时模型，以验证 CDO 的有效性（表1）。四种最先进模型分别是 RESA、LaneATT、CLRNet 和 BézierLaneNet。两种实时模型 ENet 和 ERFNet 则作为基线方法进行比较 [23][24]。表1展示了 CDO 在不同网络中的层位置。我们可以通过三个步骤将 CDO 添加到不同模型中。首先，找到适合作为 CDO 插入位置的层。然后，选择该层的特征图 F 作为 CDO 的输入。方程（1）和（2）中的垂直和水平协方差计算可通过矩阵乘法简单实现。水平协方差矩阵为 $H \times H$，垂直协方差矩阵为 $W \times W$。其次，根据方程（7）和（8）计算协方差矩阵的 RIF，以获得特征图中车道线特征的相对强度。第三，沿所有通道的水平轴和垂直轴计算 RIF 值的均值，从而定义一个衡量 CDO 输出与车道线存在情况 exist(n) 之间均方误差（MSE）损失的准则，如公式（10）所示。

$$Loss(CDO) = MSELoss(CDO(n), exist(n)) \tag{10}$$

车道线存在函数 exist(n) 输出 0 或 1，以表示 n^{th} 车道线是否存在。

3.3 总体损失

表1不同网络中 CDO 的层位置

Name	CDO 位置	类别	Year
ENet	第8层	基于分割	2016
ERFNet	第16层	基于分割	2018
RESA（ResNet-34）	第16层	基于分割	2020
LaneATT（ResNet-34）	第16层	基于锚点	2021
CLRNet（ResNet-34）	第16层	基于锚点	2022
BézierLaneNet（ResNet-34）	第16层	基于曲线	2022

表2 CDO 的损失

Name	总损失	带有 CDO 的总损失
ENet ERFNet RESA (ResNet-34)	$f_{seg} \cdot L_{seg} + f_{exist} \cdot L_{exist}$	$f_{seg} \cdot L_{seg} + f_{exist} \cdot L_{exist} + f_{CDO} \cdot L_{CDO}$
LaneATT (ResNet-34)	$f_{reg} \cdot L_{reg} + f_{cls} \cdot L_{cls}$	$f_{reg} \cdot L_{reg} + f_{cls} \cdot L_{cls} + f_{CDO} \cdot L_{CDO}$
CLRNet (ResNet-34)	$f_{cls} \cdot L_{cls} + f_{xytl} \cdot L_{xytl} + f_{seg} \cdot L_{seg} + f_{IoU} \cdot L_{IoU}$	$f_{cls} \cdot L_{cls} + f_{xytl} \cdot L_{xytl} + f_{seg} \cdot L_{seg} + f_{IoU} \cdot L_{IoU} + f_{CDO} \cdot L_{CDO}$
BézierLaneNet（ResNet-34）	$f_{cls} \cdot L_{cls} + f_{reg} \cdot L_{reg} + f_{seg} \cdot L_{seg}$	$f_{cls} \cdot L_{cls} + f_{reg} \cdot L_{reg} + f_{seg} \cdot L_{seg} + f_{CDO} \cdot L_{CDO}$

表3 三个数据集上6种模型的损失系数

Name	f_{seg}	f_{exist}	f_{cls}	f_{reg}	f_{xytl}	f_{IoU}	f_{CDO}
ENet	1	0.1	-	-	-	-	0.1
ERFNet	1	0.1	-	-	-	-	0.1
RESA (ResNet-34)	1	0.1	-	-	-	-	0.1
LaneATT (ResNet-34)	-	-	10	1	-	-	0.3
CLRNet (ResNet-34)	1	-	2/6/2	-	0.2/0.5/0.5	2/2/8	0.2
BézierLaneNet（ResNet-34）	0.75	-	0.1	1	-	-	0.05

不同模型的整体训练损失由不同的损失项组成。我们在所有基于分割的方法 [5] 中保留辅助车道线存在损失，并在 CLRNet 中保留分割损失 [20]。如表2所示，我们列出了 CDO 损失如何添加到六种不同模型的总损失函数中。参数 f_{seg}、f_{reg}、f_{exist}、f_{cls}、f_{IoU}、f_{xytl} 和 f_{CDO} 分别是分割损失（L_{seg}）、回归损失（L_{reg}）、存在损失（L_{exist}）、分类损失（L_{cls}）、线段 IoU 损失（L_{IoU}）、起点坐标损失（L_{xytl}）和 CDO损失（L_{CDO}）的系数。这些参数用于平衡不同损失对总损失的影响。

将 CDO 加入总损失后，模型可以使用现有超参数从任意轮次继续训练。通过最小化 CDO 的损失，全局上下文中的信息能够增强车道线特征。表3展示了三个不同数据集（CULane、TuSimple 和 LLAMAS）上六个模型的损失系数。为消除 CDO 对数据集的依赖，所有数据集均使用相同的 f_{CDO} 值。

3.4 车道线预测

在实践中，使用 CDO 优化车道线预测非常简单，且 CDO 只会改变训练过程。所有图像预处理、主程序框架和后处理均可保持不变。CDO 再训练过程优化得到的超参数可在实际应用中直接替换原始模型文件，无需担心代码修改和硬件支持。因此，车道线推理过程无需改变。

4 实验

4.1 数据集

实验中，采用了三个广泛使用的车道线检测数据集：CULane [12], 、TuSimple [25], 和 LLAMAS [26], , 用于评估六种模型在添加 CDO 前后的性能变化。

4.2 评估指标

对于每个不同的数据集，我们采用文献中列出的评估指标来确定 CDO 的有效性。**CULane**。我们分别用宽度为 30 像素的线连接预测车道点和标注车道点。随后计算预测车道线与标注车道线之间的交并比。交并比高于某一阈值（0.5）的预测车道线为真阳性（TP）。F1度量定义为：，其中和。FP 和 FN 分别是假阳性（FP）和假阴性（FN）。**TuSimple**。对于 TuSimple 数据集，评估指标为准确率，并在特定图像高度处评估各点。准确率定义为：，其中 C_{clip} 表示帧中的正确点数，S_{clip} 表示请求的点数。如果预测车道线与真实标注点之间的差值小于阈值，则将其视为真阳性（TP）。评估时，我们还会计算公式（11）中的假阳性（FP）和假阴性（FN）比例。FP 表示预测车道线未与任何真实标注车道线匹配。FN 表示预测结果中没有车道线与真实标注中的车道线匹配。

$$FP = \frac{F_{pred}}{N_{pred}}, FN = \frac{M_{pred}}{N_{gt}} \tag{11}$$

其中，F_{pred} 为预测错误的车道线数量，N_{pred} 为预测车道线总数。M_{pred} 为预测结果中漏检的真实车道线数量，N_{gt} 为真实车道线总数。

LLAMAS。作为一个新型大规模车道线检测数据集，LLAMAS 包含超过 10 万张图像。BOSCH 使用高分辨率地图自动生成标注，以发布车道线数据集，这使该数据集成为目前免费提供的最大规模高质量数据集之一。我们将车道线预测结果上传至 LLAMAS 网站，以获取测试集的基准测试结果。

4.3 实现细节

为在相同的软件框架下比较结果，我们采用了 Feng[26]提供的基于 mmcv 的框架。在预处理方面，CULane、TuSimple 和 LLAMAS 的输入分辨率分别为 288×800、360×640 和 360×640。为探究 CDO 本身的有效性，我们没有引入任何数据增强。将 CDO 应用于六种模型（表 4）后，我们使用上述三个数据集评估优化后的模型。为公平比较六种模型在原始结构下以及添加 CDO 模块后的表现，我们使用相同的优化器、学习率和训练轮数对它们进行训练。公式（9）中 α 和 β 的系数均设为 0.5。表 4 展示了实验所用的配置，其中针对三个数据集设置了不同的训练轮数。例如，“12/50/10”表示 CULane 训练 12 轮，TuSimple 训练 50 轮，LLAMAS 训练 10 轮。所有训练和测试均在单张 RTX 1080 Ti 上进行。计算机配置包括 Xeon(R) Gold 6132 CPU @ 2.60GHz 和 128GB 内存。

4.4 主要结果

表 4 训练配置与参数

模型	Opt.	学习率调度	训练轮数
ENet	SGD	带预热的多项式策略	12/50/10
ERFNet	SGD	带预热的多项式策略	12/50/10
RESA	SGD	带预热的多项式策略	12/50/10
LaneATT	Adam	余弦退火	15/100/15
CLRNet	Adam	余弦退火	15/70/20
BézierLaneNet	Adam	余弦退火	36/400/20

表5 在 CULane 测试集上采用 CDO 的不同模型的性能

模型 比例	普通 27.70%	拥挤 23.40%	夜晚 20.30%	无车道线 11.70%	阴影 2.70%	箭头 2.60%	弯道 1.20%	十字路口 9.00%	F1@50
ENet	89.27%	68.15%	62.98%	42.42%	68.65%	83.07%	63.23%	2465	69.9%
ENet-CDO	90.13%	70.57%	65.74%	43.58%	67.71%	84.32%	67.59%	2400	71.66% ↑
ERFNet	91.48%	71.27%	68.07%	46.76%	74.5%	86.12%	66.97%	2103	73.49%
ERFNet-CDO	92.31%	73.58%	70.26%	47.84%	74.77%	87.93%	68.6%	2472	74.93% ↑
RESA (ResNet-34)	91.32%	71.81%	67.55%	46.53%	72.64%	86.97%	67.22%	1700	73.66%
RESA-CDO (ResNet-34)	92.31%	72.7%	70.07%	47.26%	76.32%	88.89%	69.31%	1679	75.08% ↑
LaneATT (ResNet-34)	91.34%	73.72%	70.42%	48.4%	73.66%	86.8%	66%	964	75.8%
LaneATT-CDO （ResNet-34）	91.6%	73.59%	71.2%	48.2%	71.47%	86.83%	68.43%	992	75.89% ↑
CLRNet (ResNet-34)	93.35%	78.1%	74.94%	**52.92%**	**79.48%**	90.22%	70.46%	1068	79.6%
CLRNet-CDO (ResNet-34)	**93.38%**	**78.12%**	**74.95%**	52.28%	79.43%	**90.51%**	**70.72%**	1150	**79.61%** ↑
BézierLaneNet (ResNet-34)	91.67%	72.99%	70.15%	48.09%	75.74%	87.13%	62.05%	897	75.55%
BézierLaneNet- CDO(ResNet-34)	91.69%	73.07%	70.27%	48.31%	75.4%	86.98%	62.51%	**856**	75.65% ↑

CDO 可以在不修改原始结构的情况下添加到网络中。常见的层选项包括基于分割的模型的编码器最后一层，以及基于锚点和基于曲线的模型的骨干网络最后一层。模型经 CDO 优化后，更新后的参数文件可直接用于现有系统。我们比较了六种高效的实时模型，包括 ENet 和 ERFNet 这两种轻量级模型，以及 RESA、LaneATT、CLRNet 和 BézierLaneNet 这四种最先进模型。集成 CDO 模块后，检测结果显著优于基于原始结构的结果。考虑到 ENet 和 ERFNet 的参数量仅为其他最先进方法的 1%–10%，它们更适用于内存资源有限的移动设备。

4.4.1 CDO在不同数据集上的性能

CDO以独立模块的形式实现，可集成到各种模型的网络结构中。

CULane。表5展示了在CULane测试集上，将CDO添加到六种不同模型后的性能。对于所有道路场景类别，经CDO模块优化后，所有模型的性能均优于原始模型。其中，ENet-CDO的性能提升最为显著，达到了1.8%。此外，基于分割的方法这一类别的结果优于另外两类。

TuSimple。表6展示了在TuSimple测试集上，将CDO添加到六种不同模型后的性能。经过CDO优化后，大多数模型的车道线检测准确率均有所提升。尽管LaneATT的准确率有所下降，但假阳性和假阴性均显著改善，这表明CDO在减少错误预测方面仍然有效。在这六种模型中，RESA-CDO的提升幅度最大，准确率提高了0.32%。

LLAMAS。LLAMAS数据集仅在四条中心线上进行测试，包含 100,042 张标注图像。我们在其验证集和测试集上评估了 CDO 模块。验证集在本地服务器上运行，分别采用 0.5 和 0.75 的交并比阈值；测试集则在官方测试服务器 [26] 上运行。表7展示了通过 CDO 优化后的模型结果。在大多数情况下，F1分数均有所提升。ENet-CDO 的提升最大，F1@75 提高了 7.07%；而 LaneATT-CDO 的 F1@75 则下降了 0.26%。

如图所示。　　2，在三个数据集上，六种不同模型的 F1 值提升均有所累积。这表明 CDO 能够

表6 不同模型在 TuSimple 测试集上使用 CDO 的性能

模型	准确率	FP	FN
ENet	95.62%	6.54%	5.02%
ENet-CDO	95.72% ↑	5.85%	4.68%
ERFNet	96.03%	5.91%	3.65%
ERFNet-CDO	96.09% ↑	6.57%	3.59%
RESA（ResNet-34）	95.15%	6.92%	5.92%
RESA-CDO（ResNet-34）	95.47% ↑	5.66%	5.36%
LaneATT (ResNet-34)	95.46%	12.77%	3.26%
LaneATT-CDO（ResNet-34）	95.25% ↓	7.93%	3.09%
CLRNet（ResNet-34）	96.8%	2.18%	2.08%
CLRNet-CDO (ResNet-34)	96.83% ↑	2.21%	2.08%
BézierLaneNet（ResNet-34）	95.65%	5.15%	3.87%
BézierLaneNet-CDO (ResNet-34)	95.75% ↑	3.91%	3.46%

显著提升模型在三个数据集几乎所有车道线检测类别上的检测结果。对于基于分割的方法，提升约为 1.7%–2.4%；对于基于锚点的方法，F1 值提升约为 0.1%–0.5%；对于基于曲线的方法，性能提升约为 0.5%。

该结果表明，与基于锚点或基于曲线的方法相比，CDO 对基于分割的方法更加有效。我们推测，通过最小化公式（10）所述的 CDO损失，基于分割的方法更有可能在特征提取过程中，通过增强特征图与标签掩码之间的空间相似性来保留全局信息。当网络参数经过 CDO 优化后，模型的空间关系感知能力将得到增强，从而提升整体车道线识别能力。尽管 CDO 对基于锚点和基于曲线的网络效果较弱，但它仍能通过在高语义层级提取空间层级相关信息，帮助这些网络提升性能。

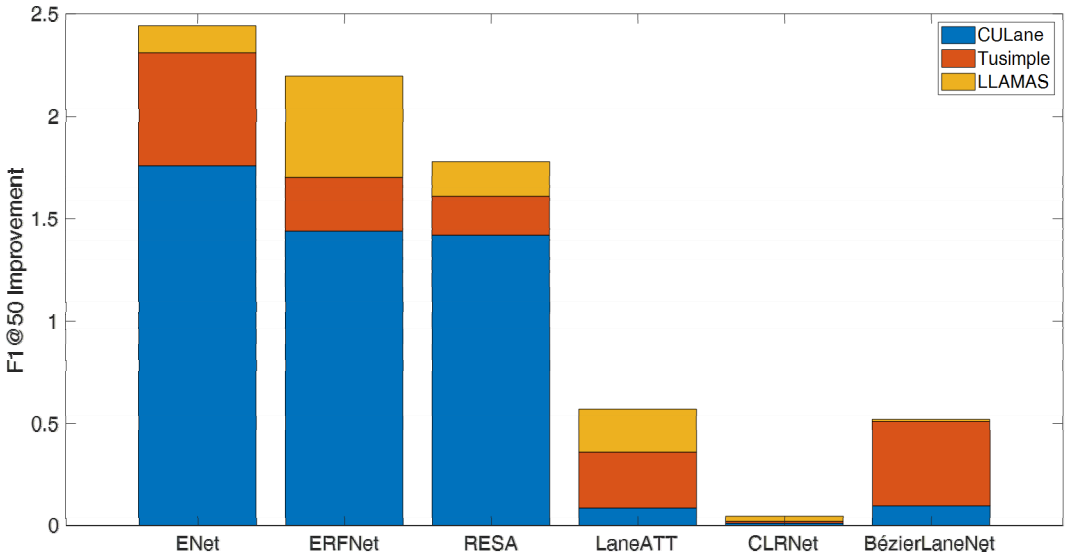

图 2 不同模型经过 CDO优化 后在三个数据集上的 F1分数 变化情况。不同颜色表示不同数据集上的 F1分数 改进幅度，柱形的总高度表示各模型的 总体改进效果。

表7 LLAMAS 测试服务器上采用 CDO 的不同模型的性能

模型	有效	Test	
	F1@50	F1@75	F1@50
ENet	96.13%	73.52%	94.43%
ENet-CDO	96.26% ↑	80.59% ↑	95.5% ↑
ERFNet	95.83%	76.65%	94.8%
ERFNet-CDO	96.33% ↑	80.73% ↑	95.21% ↑
RESA（ResNet-34）	96.28%	76.93%	95.32%
RESA-CDO（ResNet-34）	96.45% ↑	80.15% ↑	95.53% ↑
LaneATT (ResNet-34)	90.45%	60.09%	93.74%
LaneATT-CDO (ResNet-34)	90.68% ↑	59.83% ↓	93.79% ↑
CLRNet (ResNet-34)	96.48%	84.98%	96.08%
CLRNet-CDO（ResNet-34）	96.51% ↑	84.99% ↑	96.15% ↑
BézierLaneNet（ResNet-34）	93.63%	64.23%	94.91%
BézierLaneNet-CDO(ResNet-34)	93.64% ↑	64.46% ↑	94.96% ↑

表8 不同模型与 CDO 的推理速度（帧每秒）和参数对比

模型	参数（M）	MAdd	GFLOPs	内存（MB）	推理速度（帧每秒）
ENet-CDO	0.35	3.68	1.81	378	69
ERFNet-CDO	2.06	23.66	11.47	343	110
RESA-CDO（ResNet-34）	11.39	96.81	47.69	651	62
LaneATT-CDO（ResNet-34）	22.12	34.39	18.02	174	165
CLRNet-CDO（ResNet-34）	21.87	38.04	20.79	199	88
BézierLaneNet-CDO（ResNet-34）	8.90	28.69	14.36	176	185

4.4.2 与最先进方法的比较

我们选择 ResNet-34 作为 RESA、LaneATT、CLRNet 和 BézierLaneNet 的骨干网络，以确保所有最先进方法都在相同条件下进行比较。对于基于分割的方法（如 RESA），CDO 集成在模型编码器的最后一层。对于基于锚点和基于曲线的方法，CDO 可插入骨干网络输出的最后一层（详情见表1）。表5、表6和表7展示了将 CDO 添加到基线方法和最先进方法后的结果。图3中黄色矩形标示的区域表明，CDO 能够提升所有类别车道线检测模型的车道线检测性能。与许多需要重新设计编码器的基于分割的方法不同，CDO 不会为模型引入额外结构，只是在原始网络中添加 CDO损失函数。同时，CDO 不依赖任何预先设计的结构，例如锚点。在实验过程中，我们使用单块 RTX 1080 Ti 评估了五项关键指标的性能，包括参数量、乘加运算（MAdd）、GFLOPs、内存和帧每秒（FPS）。由于 CDO 仅在训练期间增加计算时间，因此在推理过程中，添加 CDO 与未添加 CDO 的模型在这些指标上没有差异。结果表明，所有网络都实现了实时性能（>50帧每秒），如表8所示。

表9 SAD和CDO在CULane数据集上的F1值比较

模型	原始	SAD	CDO
ENet	69.9%	70.8%	71.66%
ERFNet	73.49%	73.61%	74.67%
MobileNetV2	67.41%	67.40%	68.77%
DeepLabV1 (ResNet-34)	69.92%	70.41%	70.9%
SCNN（ResNet-34）	72.70%	72.61%	74.01%
RESA（ResNet-34）	73.66%	73.50%	75.08%

5 消融研究

5.1 SAD 和 CDO

自注意力蒸馏（SAD）使模型能够从自身学习，并在无需额外监督或标签的情况下获得显著提升 [27]。SAD 的其他优点包括易于集成到任何前馈卷积神经网络（卷积神经网络）中，且不会增加推理时间。因此，本文选择 SAD 与 CDO 进行比较，并观察这两种不同注意力模块的优化效果。由于 SAD 仅适用于基于分割的模型，我们选择了六种基于分割的方法，分别加入 CDO 和 SAD 进行比较，以探究它们在车道线检测中的有效性。在实验中，我们假设模型已经完成一半训练，然后将 SAD 或 CDO 加入训练过程。

如表9所示 , 在全部六个模型中，CDO 带来的性能提升都比 SAD 更大 . 我们将此归因于
其次，在使用注意力图提取用于车道线检测的上下文信息时，SAD 的选择取决于网络结构，通常仅适用于前馈式卷积神经网络架构。第三，SAD 可能会与其他注意力机制（如循环注意力或空间卷积神经网络）产生潜在的冲突影响，而 CDO 则能够兼容不同的注意力模块。

5.2 关于协方差分布的消融研究

经过 CDO 训练过程后，协方差分布的改善将改变特征图中车道线特征的空间精度。当协方差矩阵中对角元素的相对强度增加时，车道线预测准确率也会提高，结果如图5(b)所示。在 CDO 重新训练过程中，公式(7)中所述的 RIF 显著增加。

随着训练轮次的增加，RIF 也随之提高，CDO 的注意力机制使车道线特征在上下文中更加清晰。随着车道线特征与其实际位置之间相关性的增强，假阳性和假阴性预测也会减少。

车道线预测点的误分类（图5(a)中的红色虚线）也有所减少。将 CDO 添加到总损失后，协方差分布似乎能够抑制非车道线特征，减少无关信息对车道线预测的干扰，并且模型不需要任何后处理步骤。

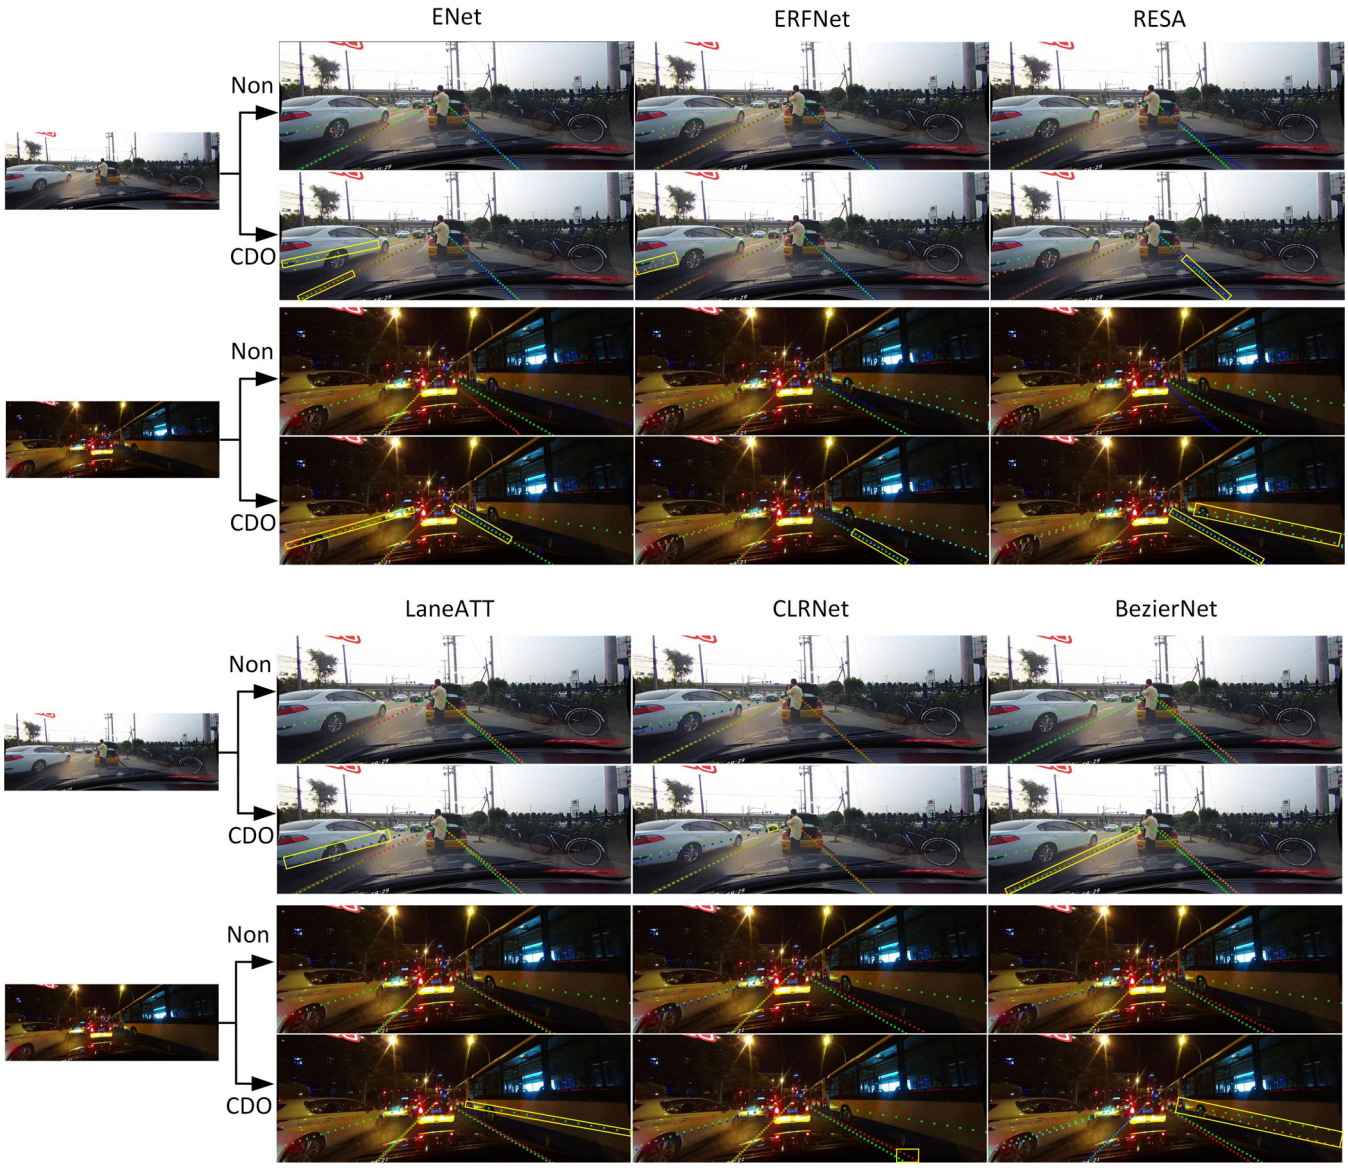

图3 不同模型在使用和不使用 CDO 的情况下于 CULane 测试集上的可视化结果。绿色点表示真实标注，其他颜色表示不同的车道实例。图中使用黄色矩形框突出显示车道检测准确率得到提升的区域。

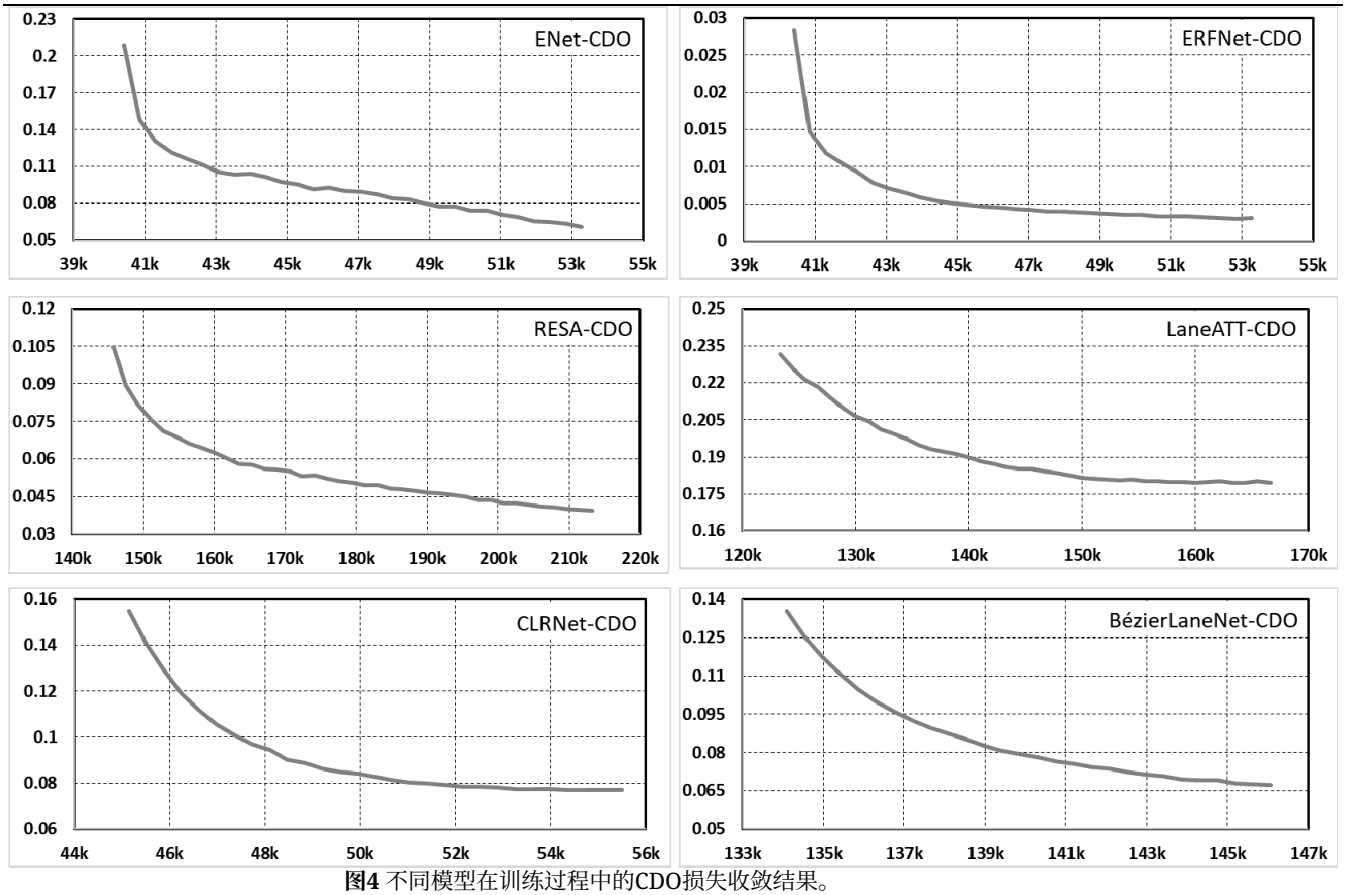

图4 不同模型在训练过程中的CDO损失收敛结果。

5.3 CDO损失的消融研究

在CDO训练过程中，CDO损失是总损失的一部分。在实际应用中，CDO损失的权重取决于车道线检测的类别。对于同一类别，表2中的CDO损失系数可以保持不变。随着CDO损失降低，训练后的模型会更加关注车道线整体是否存在、车道线的细微线形以及车道线的空间精度。在进行CDO优化之前，原始网络对车道线的局部特征更加敏感。加入CDO后，网络会更加关注整体线条结构的完整性以及车道线空间位置的正确性。图4显示，将CDO模块添加到网络后，随着训练轮次增加，CDO损失逐渐降低并收敛。在实验中，我们在总训练过程完成75%后，将CDO分支添加到模型中。将CDO插入模型并继续训练后，方程（7）和（8）中的RIF会随着训练轮数增加而增大（图5(c)），全局车道线特征提取也会得到改善。在图5(c)中，左侧在训练轮次=10 时缺失的车道线，会在训练轮次=11 和12时被检测到。同样，由于假阳性而被错误检测出的最右侧车道线标记也被正确排除。此外，中心车道线的空间精度显著提高。

此外，我们还研究了不同f_{CDO} 对模型性能的影响。为避免其他超参数变化对实验结果的影响，我们在实验中保持表3中的超参数不变，并通过改变f_{CDO}的值来观察模型性能的变化。

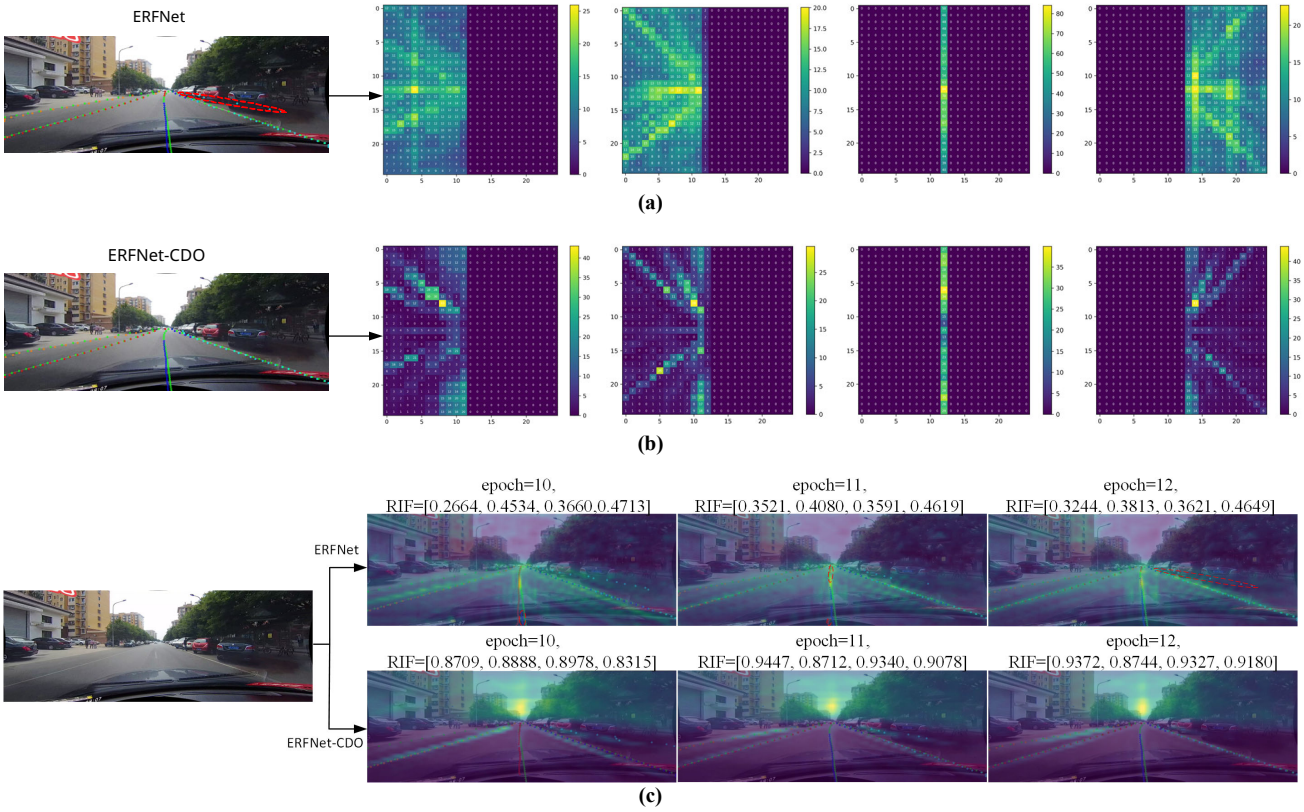

图5 ERFNet 与 ERFNet-CDO 的协方差分布对比。(a) ERFNet 的车道线预测以彩色点标示，真实车道线以绿色点表示。红色虚线圆圈标出一个假阳性车道线实例。左侧是四条不同车道线的协方差分布图。(b) ERFNet-CDO 的车道线预测比 ERFNet 更准确。其协方差矩阵中的对角元素比 ERFNet 的协方差矩阵更加明显。(c) ERFNet-CDO 的 Grad-CAM 可视化图。将 CDO 引入重新训练过程后，公式(7)中描述的 RIF 显著增加。

6 结论

本文提出了一种协方差分布优化（CDO）方法，以提升实时车道线检测模型的性能，尤其是在低功耗嵌入式环境中。所提出的CDO模块利用特征图与真实标签之间的协方差关系，构建了一种新颖的损失函数。具体而言，该方法利用分别沿水平方向和垂直方向计算的协方差矩阵的对角元素，使每个像素都能聚合全局上下文信息，从而改善空间特征对齐。

我们在六种具有代表性的模型上评估了 CDO，涵盖车道线检测方法的三大类别——基于分割、基于锚点和基于曲线。在所有情况下，与原始模型架构相比，集成 CDO 都能持续提升车道检测准确率。值得注意的是，CDO 无需从头开始重新训练模型，也不需要引入额外的网络参数。只需将 CDO 损失项添加到总体损失函数中，并相应更新模型参数，即可将其无缝集成到现有系统中。

在三个广泛使用的基准数据集——CULane、TuSimple 和 LLAMAS 上进行的全面实验，证明了我们方法的有效性；在所有评估的最先进模型中，均观察到稳定的性能提升。未来，我们计划将 CDO 的适用范围扩展至 3D车道线检测框架和鸟瞰视图（BEV）表示，从而进一步拓展其在先进自主感知系统中的应用价值。

致谢

本研究得到中国浙江省自然科学基金资助，项目编号为 LGG21F030008。

参考文献

1 Sato, T., Chen, Q.A.：《面向车道线检测模型的面向驾驶的度量指标》，载于《IEEE计算机学会计算机视觉与模式识别会议论文集》（2022），第17132–17141页。2 Yurtsever, E., Lambert, J., Carballo, A., Takeda, K.：《自动驾驶综述：常见实践与新兴技术》*IEEE Access*，2020年，**8**，第58443–58469页。3 Tang, J., Li, S., Liu, P.：《基于深度学习的车道线检测方法综述》模式识别，2021年，**111**，第107623页。4 Bar Hillel, A., Lerner, R., Levi, D., Raz, G.：《道路与车道线检测的最新进展：综述》*Mach. Vis. Appl.*，2014年，**25**，（3），第727–745页。5 Feng, Z., Guo, S., Tan, X., Xu, K., Wang, M., Ma, L.：《通过曲线建模重新思考高效车道线检测》*IEEE*计算机学会计算机视觉与模式识别会议论文集，2022年，**2022年-六月**，第17041–17049页。6 Liu, Y., Xu, P., Zhu, L., Yan, M., Xue, L.：《用于实时交通线检测的强化注意力方法》*J. Real-Time Image Process.*，2022年，**19**，（5），第957–968页。7 Bardes, A., Ponce, J., LeCun, Y.：《VICReg：用于自监督学习的方差-不变性-协方差正则化》2021年，（2020年），第1–23页。8 Zakaria, N.J., Shapiai, M.I., Ghani, R.A., Yassin, M.N.M., Ibrahim, M.Z., Wahid, N.：《自动驾驶车辆车道线检测：系统综述》*IEEE Access*，2023年，**11**，（一月），第3729–3765页。9 Lee, D.H., Liu, J.L.：《用于实时自动驾驶的车道线检测与路径预测端到端深度学习》*Signal, Image Video Process.*，2022年，第1–5页。10 Xiao, L., Li, X., Yang, S., Yang, W.：《ADNet：通过锚点分解进行车道线形状预测》*Proc. IEEE/CVF Int. Conf. Comput. Vis.*，2023年，第6404–6413页。11 Wang, Z., Ren, W., Qiu, Q.：《LaneNet：用于自动驾驶的实时车道线检测网络》2018年。12 Pan, X., Shi, J., Luo, P., Wang, X., Tang, X.：《空间即深度：用于交通场景理解的空间卷积神经网络》*32nd AAAI Conf. Artif. Intell. AAAI 2018*，2018年，第7276–7283页。13 Neven, D., De Brabandere, B., Georgoulis, S., Proesmans, M., Van Gool, L.：《迈向端到端车道线检测：一种实例分割方法》*IEEEIntell. Veh. Symp. Proc.*，2018年，**2018年-六月**，（六月），第286–291页。14 Zheng, T., Fang, H., Zhang, Y., *et al.*：《RESA：用于车道线检测的循环特征移位聚合器》*35th AAAI Conf. Artif. Intell. AAAI 2021*，2021年，**4B**，第3547–3554页。15 Sun, Y., Li, J., Xu, X., Shi, Y.：《基于鲁棒实例分割的智能车辆自适应多车道线检测》*IEEE Trans. Intell.Veh.*，2023年，**8**，（1），第888–899页。16 Li, X., Li, J., Hu, X., Yang, J.：《Line-CNN：借助线提议单元进行端到端交通线检测》*IEEE Trans. Intell. Transp. Syst.*，2020年，**21**，（1），第248–258页。17 Tabelini, L., Berriel, R., Paixão, T.M., Badue, C., de Souza, A.F., Oliveira-Santos, T.：《专注车道：实时注意力引导的车道线检测》，载于《IEEE计算机学会计算机视觉与模式识别会议论文集》（2021），第294–302页。18 Qin, Z., Wang, H., Li, X.：《超快速结构感知深度车道线检测》2020年，第1–16页。19 Liu, L., Chen, X., Zhu, S., Tan, P.：《CondLaneNet：基于条件卷积的自上而下车道线检测框架》*Proc. IEEE Int. Conf*

计算机视觉，2021年，第3753–3762页。20 Zheng, T., Huang, Y., Liu, Y., 等："CLRNet：用于车道线检测的跨层细化网络"*IEEE*计算机学会计算机视觉与模式识别会议论文集，2022年，**2022年-6月**，（c），第888–897页。21 Tabelini, L., Berriel, R., Paixão, T.M., Badue, C., de Souza, A.F., Oliveira-Santos, T.："PolyLaneNet：通过深度多项式回归进行车道线估计"国际模式识别会议论文集，2020年，第6150–6156页。

22 Liu, R.,Yuan, Z., Liu, T., Xiong, Z.：“使用 Transformer 进行端到端车道线形状预测”《*2021* 年 *IEEE* 冬季计算机视觉应用会议论文集》，*WACV 2021*，2021 年，第 3693–3701 页。23 Paszke, A., Chaurasia, A., Kim, S., Culurciello, E.：“ENet：用于实时语义分割的深度神经网络架构”2016 年，第 1–10 页。24 Romera, E., Alvarez, J.M., Bergasa, L.M., Arroyo, R.：“ERFNet：用于实时语义分割的高效残差因式分解卷积网络”《*IEEE* 智能交通系统汇刊》，2018 年，**19**，(1)，第 263–272 页。25 Tusimple：“TuSimple：车道线检测挑战赛（数据集）”（2017 年）26 Behrendt, K., Soussan, R.：“使用地图进行无监督标注车道标记”《*2019* 年国际计算机视觉会议研讨会论文集》，*ICCVW 2019*，2019 年，第 832–839 页。27 Hou, Y., Ma, Z., Liu, C., Loy, C.C.：“通过自注意力蒸馏学习轻量级车道线检测卷积神经网络”《*IEEE* 国际计算机视觉会议论文集》，2019 年，**2019**-**10** **月**，第 1013–1021 页。