arXiv:2602.01277v1 [cs.CV] 1 Feb 2026

TF-Lane：面向鲁棒车道感知的交通流模块

Yihan Xie†, *, Han Xia†, Zhen Yang
比亚迪有限公司aerocooc@gmail.com

摘要

自动驾驶系统需要具备鲁棒的车道感知能力，但现有基于视觉的检测方法在视觉传感器提供的线索不足时（例如遮挡或车道缺失场景）会出现显著的性能下降。虽然一些方法将高精地图作为补充信息，但这些方案面临订阅成本高、实时性能有限等挑战。为克服这些局限，我们探索了一种创新的信息来源：交通流，它具备实时能力且无需额外成本。本文提出一种交通流感知的车道感知模块（*TFM*），能够有效提取实时交通流特征，并无缝集成到现有车道感知算法中。该方案源于真实世界的自动驾驶工况，并随后在开源算法和数据集上得到验证。我们在四种主流模型和两个公开数据集（*NuScenes*和*OpenLaneV2*）上，采用标准评估指标进行了大量实验，结果表明*TFM*能够持续提升性能，在*NuScenes*数据集上最高可获得 +4.1% 平均精度均值的增益。

1. 引言

自动驾驶技术的快速发展凸显了其在智能交通系统中的关键作用。作为此类系统的核心组成部分，稳健的车道检测至关重要。现有的车道感知方法通常依赖单目或多视角视觉模型。然而，在交通拥堵或道路施工等复杂场景中，仅凭视觉传感器可能无法捕获充足的线索，从而导致性能下降。为解决这一问题，既有工作通常将先验知识作为辅助信息，其中高精地图是一种主流方案。然而，高精地图也存在局限性，包括订阅成本高以及实时性表现不佳。在本文中，我们观察到自动驾驶

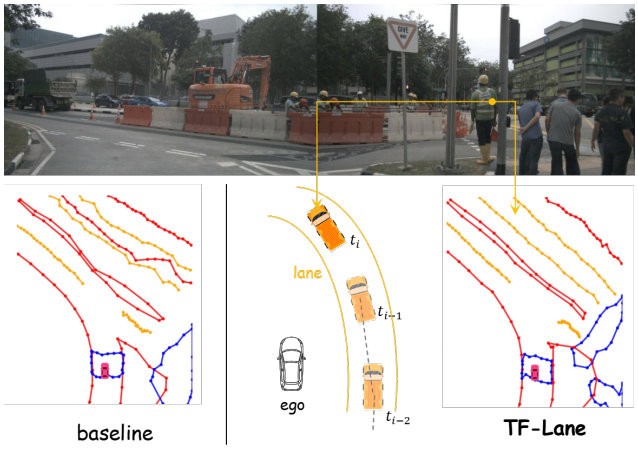


图 1. **交通流示意图**。 在存在遮挡或复杂场景中，交通流信息可通过提供实时先验信息，增强车道感知的鲁棒性。

作为一项综合性任务，还可以利用另一种用于道路结构感知的先验信息源：交通流。交通流无需额外成本，并具备实时能力。

在自动驾驶系统中，交通流可作为实时先验信息来源，由连续的车辆流构成，并广泛涵盖其他交通参与者（如行人）。交通流状态实时动态反映道路结构，因为它隐含着这样一种信息：在有限时间内，前车经过的区域可供自车通行，而行人密集区域在短期内不可通行。通过订阅动态目标检测与跟踪模块的内部系统节点，即可高效获取此类信息；这种方式实时性高，且无需额外投入资金，通信成本也低。因此，交通流为车道线检测提供了可靠且经济的辅助先验，尤其适用于视觉线索不足的复杂场景。

为增强车道检测在挑战性场景（例如，遮挡或车道线缺失）下的鲁棒性，我们提出TF-Lane，这是一个集成了交通

†† 贡献相同。* 通讯作者。

流特征融合模块（TFM）作为其核心组件。如图2所示，TFM以交通流数据作为输入，并首先通过轨迹解析器进行处理，将原始信息编码为交通流特征，包括目标类别和空间位置。随后应用区域采样策略，以聚焦于场景相关特征，确保高效且有针对性地利用交通流线索。

为应对真实自动驾驶场景中的遮挡和传感器不稳定问题，我们提出了一种时空双编码器架构。时间编码器构建相应的掩码，并处理连续帧之间的轨迹关联，同时补偿帧间断，通过时间建模捕捉交通流的动态演变。空间编码器在交通流实例与车道特征之间建立融合映射，将上下文交通流信息与视觉线索相结合，从而增强复杂场景下车道表示的鲁棒性。

为验证交通流模块（TFM）的有效性，我们将TFM 集成到四种主流车道检测模型中：TopoNet[2], LaneSegNet[13], Maptr[15],Maptrv2[16], 并在NuScenes[3] 和 OpenLaneV2[21] 数据集上进行评估。我们还提出了一种交通流数据集构建方法，可适用于多个开源数据集，并通过真实车辆验证确保其广泛适用性。为保证公平性，我们遵循各模型原有的评估指标。如图6所示，集成 TFM 后，所有模型的性能均得到稳定提升。消融研究进一步证实了 TFM 中各组成部分的贡献。

值得注意的是，尽管 TF-Lane 框架支持在训练和推理阶段显式输入交通流，但实验表明，即使推理时不提供交通流，模型的表现仍优于基线。这凸显了交通流在训练过程中能够提供有效的隐式监督，从而增强车道线表征的鲁棒性。

主要贡献总结如下：

• 本文率先将交通流信息融入车道感知任务，提出一种创新先验，利用其实时性强、零成本的优势，提升基于视觉的方法在遮挡或车道线缺失等复杂场景中的鲁棒性。

•我们提出了 TF-Lane，这是一种通过交通流感知模块（TFM）融合交通流与视觉特征的框架。该框架采用时空双编码器架构，高效提取并融合特征，从而能够灵活适配多种车道线检测任务。它显著提升了模型在复杂环境中的感知鲁棒性，并在多个基准测试中取得了一致的量化提升——

结果。

2. 相关工作

2.1. 基于视觉的方法

早期的车道线检测方法主要采用基于分割的范式，将任务建模为语义分割 [18] 或实例级分割 [20]。例如，SCNN 将每条车道线视为一个独立类别进行逐像素分类，而 Prior-Lane 则引入结构先验以提升几何一致性，为后续的地图先验融合方法奠定了基础。然而，这些方法需要预先设定车道线数量上限，限制了其在动态场景中的灵活性。

为克服这些限制，研究转向自底向上实例分割策略。LaneNet [22]和 LaneAF[1] 通过聚类二值车道背景掩码，无需预设数量即可实现实例判别。随着自动驾驶对三维感知的需求日益增长，车道线检测也拓展到了三维空间。3D- LaneNet[7]首次提出端到端三维车道检测框架，后续的 Gen-LaneNet[8]和 3D-LaneNet+[6] 等方法则通过逆透视映射（IPM）将图像特征投影到鸟瞰图（BEV）空间。为减轻 IPM 的几何先验误差，近期研究采用可学习视图变换模块（如 LSS[19], 、BevDet[10], 和 BevFormer[14]），以实现更稳健的 BEV特征构建。

与此同时，车道结构建模也成为另一项重要研究方向。TopoNet[2] 率先实现端到端车道拓扑推理，LaneSegNet[13]联合优化几何结构与语义元素，而基于变换器的 MapTR系列[15, 16] 则通过查询机制直接输出矢量化车道表示，显著提升了结构化输出的效率和准确性。尽管这些纯视觉方法在理想条件下表现出色，但在传感器线索有限的复杂环境中，例如严重遮挡或极端光照条件下，其感知鲁棒性仍面临挑战。

2.2. 基于先验的方法

复杂环境中车载传感器的感知不确定性促使人们融合先验知识，以增强检测鲁棒性。地图先验凭借其表征道路结构的固有能力，已成为主流选择。

在隐式地图编码方面，MapLite2.0 [17]通过融合标准定义（SD）地图与在线传感器数据，构建局部高精地图（HD）表示。PriorLane [20] 将SD地图编码为二值图像，并通过关键点对齐模块（KEA）将其与自车坐标系对齐，以便与视觉特征融合。

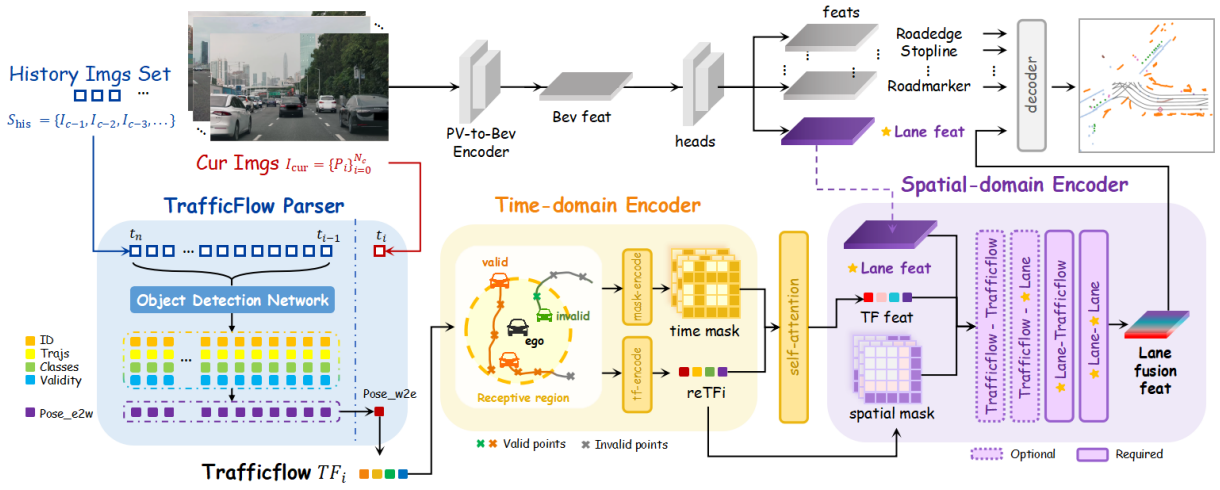


图 2. **TF-Lane 总体架构**。 所提出的 TFM 模块由三个关键部分组成：交通流提取、时序特征编码和空间特征融合。随后，解码器对融合车道特征进行处理，以获得场景中的最终车道感知结果。

SMERF [5] 从SD地图中提取地面元素，通过专用地图编码器生成结构化特征，并利用地图交叉注意力机制，使鸟瞰视角特征与地图线索交互，从而增强对道路结构的感知。类似地，MapEX [9]和 P-MapNet [12] 通过可学习的查询向量实现地图先验的隐式融合。为解决地图匹配中的定位误差，U-BEV [4]引入模板匹配机制，通过识别最佳匹配点来提高融合精度。

然而，高精地图固有的缺点（如订阅费用高昂、更新延迟）推动了对替代先验的探索。Autograph [24]率先使用车辆轨迹数据进行推理，但依赖于基于鸟瞰视角离线构建数据。Jia等人 [11]通过融合众包轨迹与地图先验降低了对高精地图的依赖，但仍需承担额外的数据订阅成本，且实时性能有限。这些方案在实际车载部署中仍面临成本与时效性两方面的挑战。

3. 方法

为了解决现有方法的局限性，我们提出了 TF-Lane，这是一种通过交通流感知模块（TFM）有效融合交通流与视觉特征的框架，具有零额外成本和实时性能高的优势。本节将详细介绍整体框架、数据准备和模型架构。

3.1. 总体框架

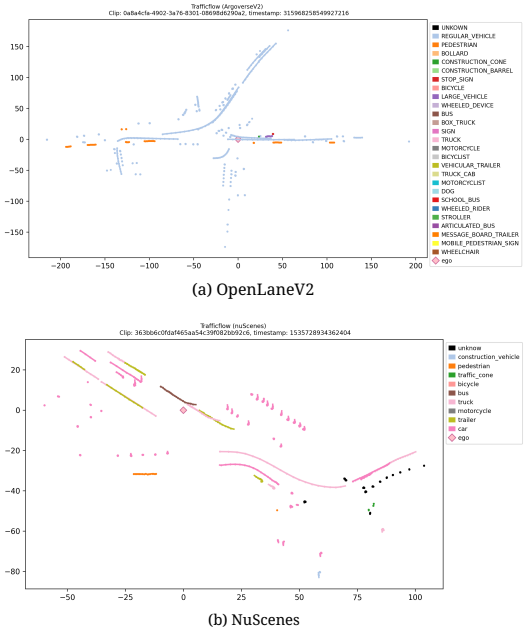
如图2所示，TF-Lane 框架由三个核心组件组成：

交通流提取： 以历史 n帧传感器数据为输入，我们首先利用目标检测算法获取交通参与者的属性。随后，基于定位数据，将连续的历史信息转换至当前帧的坐标系中，从而得到原始交通流表示 TF_i。此过程利用车载系统固有的通信节点，无需额外订阅数据。

时序特征编码： 将 TF_i 输入时序编码器，以提取自车感知范围内的有效特征。通过设计的掩码机制，过滤因跟踪中断而产生的无效帧，从而引入经过精炼的交通流特征 $reTF_i$ 和时序掩码。该模块采用自注意力增强特征表征，并生成相应的空间掩码。

空间特征融合： 通过跨模态交互，将时序交通流特征 TF$_{feat}$ 与车道的视觉特征融合。融合后的特征传入解码器，生成最终的场景感知结果。这种设计确保在视觉线索不足时，交通流特征能够提供互补的道路结构先验。

3.2. 数据准备



(a) OpenLaneV2

(b) NuScenes

图 3. **数据集中交通流的可视化**

我们针对不同数据集采用不同方式处理交通流数据：对于 OpenLaneV2[21]，，我们通过令牌索引 Argoverse 2[23]场景信息以编码交通流；对于 NuScenes[3]，，我们则通过实例令牌直接检索场景数据。具体而言，给定当前感知帧 f_i 及其点云范围 $\mathcal{R}_p = [x_{\min}, x_{\max}] \times [y_{\min}, y_{\max}]$，我们从历史帧序列中提取场景信息，包括跟踪 ID、类别、轨迹和遮挡状态$\{f_{i-1}, f_{i-2}, ..., f_{i-n}\}$。帧间位姿变换矩阵：

$$\mathbf{T}_{i-k}^{i} = \mathbf{Pose}_{i}^{-1} \cdot \mathbf{Pose}_{i-k} \tag{1}$$

用于将历史交通流信息变换至当前帧的坐标系中，从而获得对齐的交通流表示 TF_i。如图3所示，我们将两个数据集中的交通流分量进行可视化，可以清楚地看到，交通流的空间分布有助于推断场景中道路网络的结构信息。

具体而言，我们保留所有有效的交通流信息，不进行人为平滑，既避免了额外的计算开销，又确保网络接收到最新的原始数据。这一设计源于我们的核心洞见：交通流应当补充而非取代视觉感知，其价值在传感器线索有限的复杂场景中尤为突出。

3.3. 模型架构

尽管进行了数据预处理，专门的网络设计对于有效学习和利用交通流先验仍然至关重要。为此，我们提出了一种时空双编码器架构，可高效融合交通流特征与车道特征。

时域编码器 我们设计了一种时域编码器，用于建模交通流的序列特性，同时过滤无效信息。该编码器首先将交通流中的信息截断至感知区域 $\mathcal{R}_t$，仅保留与当前场景相关的元素。对于历史 N 帧，我们设置了有效性阈值 $tole_{pts}$：仅当连续 N 帧中至少有 $tole_{pts}$ 帧包含有效交通流时，才认为某个实例有效。

考虑到自运动的特性以及交通流的空间分布模式，我们采用以自车为中心的加权策略。具体而言，位于自车前方 60° 扇区内的交通流被赋予最高权重，而其他区域则根据相对位置逐步降低权重。通过这种对空间敏感的机制，我们从场景中提取最具代表性的 T_{top} 交通流实例。

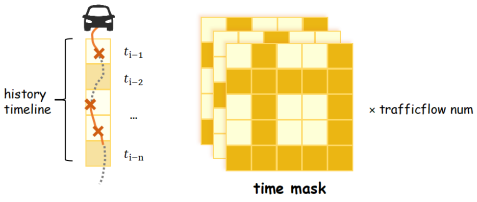


图4. **时序掩码**。 该机制关注交通流实例时域内历史帧的有效性，有效应对帧丢失和遮挡等现实世界中的挑战。

在实现中，我们为每帧的交通流实例数设置上限 $T_{\max}$。当有效实例超过 $T_{\max}$ 时，我们根据权重进行筛选；数量不足时，则填充至 $T_{\max}$。这样既能确保输入一致，又能避免冗余。

除了生成精细的交通流特征 $reTF_i$外，时间编码器还会生成相应的时间掩码，如图 4 所示。当时间帧出现遮挡或信息丢失时，这些掩码会被停用。这种掩码机制在真实场景推理中展现出很强的鲁棒性，能够有效应对传感器通信故障和部分遮挡导致的跟踪中断，从而确保在复杂环境中的稳定性能。

空间域编码器 时间编码器会输出增强特征 TF_{Feat} 和时间掩码，随后由空间域编码器进行处理。如图 5 所示，该编码器通过设计的空间掩码机制，实现了交通流特征与车道特征之间的结构化融合。

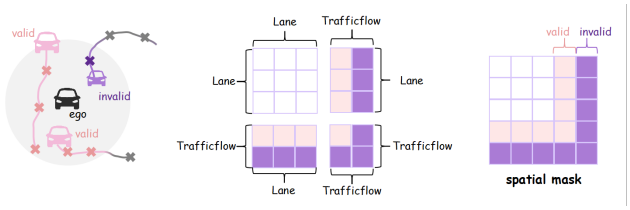


图5。**空间掩码**。该机制可在当前空间分区内识别交通流和车道结构中的有效实例，从而有效应对复杂场景和实例分布稀疏等挑战。

设 L 和 T 分别表示车道和交通流表示的特征维度。空间掩码矩阵 $M_s \in \mathbb{R}^{(L+T)\times(L+T)}$ 分为四个逻辑区域：

- $M_{L\to L}$：车道内注意力掩码，复用上游网络中已有的设计
- $M_{L\to T}$：从车道到交通流的跨模态注意力掩码
- $M_{T\to L}$：从交通流到车道的跨模态注意力掩码
- $M_{T\to T}$：车道内交通流注意力掩码，根据实例有效性生成

该掩码机制显式建模模态之间的交互模式，同时确保关注有效信息。具体而言，我们将空间掩码M_s、交通流特征 TF_{Feat} 和车道特征 L_{Feat} 拼接后，输入四个融合模块：

$$F_{\text{fused}}^{(i)} = \mathcal{F}_{\text{fusion}}\left(\mathrm{L}_{Feat}^{(i)}, \mathrm{TF}_{Feat}^{(i)}; M_s^{(i)}\right), i = 1, \ldots, 4 \quad (2)$$

其中，每个模块对应掩码矩阵的一个不同分区。融合车道特征通过范式感知特征组合模块与原始特征集成。该过程可表示为：

$$\mathrm{L}_{Feat}^{'} = \mathcal{T}(F_{\text{fused}}^{(4)}) + I(Q_{\text{type}}) \odot \mathrm{L}_{Feat} \quad (3)$$

其中，$I(Q_{\text{type}})$是一个指示变量：对于基于实例的查询，其值为 0；对于点级查询或其他会破坏结构的查询，其值为 1；$\mathcal{T}$表示特征变换。该设计将变换后的融合特征 $\mathcal{T}(F^{(4)}_{\text{融合}})$作为主要输入，同时仅在需要保留结构信息时，才有选择地将原始 L_{Feat} 作为残差加入。随后，增强特征 L_{Feat} 将传递给解码器，以完成最终的车道感知。

值得注意的是，$T \to T^{(1)}$ 和 $T \to L^{(2)}$ 模块是可选组件，而 $L \to T^{(3)}$ 和 $L \to L^{(4)}$ 模块对于车道特征增强至关重要。实际部署表明，仅启用后两个模块便能在降低计算开销的同时显著提升性能。这种模块化设计提供了部署灵活性，可适应各种资源受限的场景。

所提出的交通流感知模块（TFM）能够在保留原始网络架构的同时，实现高效的多模态特征融合。这种设计具备架构兼容性、部署灵活性和场景鲁棒性，可为车道线检测提供可靠的环境先验，从而显著提升模型在复杂道路场景中的感知可靠性。

4. 实验

为验证我们方法的有效性，我们在四种主流开源模型和两个公开数据集上进行了全面评估。我们展示了所有基线模型均取得稳定的性能提升，通过对具有挑战性的场景进行定性分析，展现交通流信息的价值，并开展消融研究以验证各个组件的贡献。

4.1. 实现细节

指标与数据集为进行全面评估，我们选取了四种经典开源模型作为基线，并严格遵循其原始评估指标和数据集配置，以确保比较公平：

- **TopoNet**：在 OpenLaneV2 上进行评估，采用感知指标（Det_t、Det_l）、拓扑推理指标（Top_{ll}、Top_{lt}）以及总体指标 OLS。
- **LaneSegNet**：在 OpenLaneV2 上进行评估，采用综合指标 mAP、车道感知指标（AP_{ls}、AP_{pred}）以及拓扑推理指标 TOP_{ll}。
- **MapTR系列**：在 NuScenes 上进行评估，采用总体指标 mAP 和地图元素指标（$AP_{\text{分隔线}}$、$AP_{\text{人行横道}}$、$AP_{\text{边界}}$）。

数据集的选择与各模型的原始论文保持一致，以确保结果具有可比性。

实现细节 所有基线模型均使用16个阿里巴巴平头哥PPU训练和评估60个训练轮次，以确保充分收敛。优化器和学习率超参数遵循官方实现。对于交通流模块，我们将交通流实例的最大数量设为 $N_t = 30$，历史轨迹帧数设为 $f_t = 20$。更多训练细节见附录。

表1。**LaneSegNet 对比实验**。交通流结构与原始基线之间的对比结果。

方法	训练轮次	**mAP**	AP_{ls}	AP_{pred}	TOP_{ll}
基线	60	32.99	32.75	33.24	27.02
Ours	60	**35.02**	34.90	35.15	27.83
基线	50*	34.65	34.04	35.26	26.76
Ours	46*	**35.66**	34.52	36.79	27.50

表 2. **TopoNet 对比实验**。 交通流结构与原始基线的对比结果。

方法	训练轮次	**OLS**	Det_l	Det_t	Top_{ll}	TOP_{lt}
基线	60	41.12	31.08	44.22	15.44	24.89
Ours	60	**42.29**	31.27	47.20	15.97	25.74
基线	55*	41.22	31.06	44.62	15.45	24.91
Ours	56*	**42.39**	31.22	47.44	15.97	25.96

4.2. 对比

为验证TFM的泛化能力，我们对四种主流基线模型进行了系统比较。如表 1至4所示，集成TFM后，TF-Lane的性能均取得稳定提升，其中MapTR基线的提升幅度最大，达到 $+4.1\%$ 平均精度均值，展现了交通流信息显著的先验价值。

为减轻训练随机性对评估的影响，我们采用双重评估策略：同时报告最终训练轮次（60）的性能和训练期间的最佳结果（*）。这一设计确保了性能比较的统计可靠性，并避免单次评估带来的随机偏差。实验表明，TFM 在所有基线模型和评估指标上均呈现一致的提升趋势，验证了其架构设计的普适性和有效性。

表 3. **MapTR 对比实验**。 交通流结构与原始基线之间的对比结果。

方法	训练轮次	**mAP**	AP_{div}	AP_{cross}	AP_{bd}
基线	60	51.51	53.92	47.76	52.86
Ours	60	**55.61**	59.28	50.05	57.52
基线	56*	51.63	54.12	47.86	52.91
Ours	50*	**55.80**	58.75	51.10	57.57

4.3. 消融研究

架构组件 我们对 LaneSegNet 进行消融研究，以验证 TFM 的有效性，具体比较不同的交叉注意力层配置：使用全部四个空间交叉注意力层，或仅使用最后一个

表 4. **MapTRv2 对比实验**。交通流结构与原始基线的比较结果。

方法	训练轮次	**mAP**	AP_{div}	AP_{cross}	AP_{bd}
基线	60	62.19	63.39	59.00	64.18
Ours	60	**63.50**	63.65	61.76	65.09
基线	60*	62.19	63.39	59.00	64.18
Ours	60*	**63.50**	63.65	61.76	65.09

两层，以及加深网络层和引入归一化坐标的效果。如表 5所示，当网络深度过大（例如 Abla1）时，模型会过拟合；而优化网络深度（Abla2-Abla4）则能显著提升性能。此外，将输入编码为与 BEV空间对齐的归一化坐标（Abla5），可进一步提升模型鲁棒性。

表5。**架构消融**。 评估固定数据设置下 TFM 的结构设计（ $N_t = 30, tole_{pts} = 5$）。

设置	管道。	Dep.	Norm.	**mAP**	AP_{ls}	AP_{pred}	顶部$_{ll}$
基线	-	-	-	32.99	32.75	33.24	27.02
Abla1	All	3	F	32.98	32.97	33.00	27.98
Abla2	All	1	F	34.24	34.37	34.10	27.82
消融3	LT/LL	3	F	33.98	32.75	35.22	27.04
消融4	LT/LL	1	F	33.09	32.48	33.71	27.46
Abla5	**LT/LL**	**1**	**T**	**35.02**	34.90	35.15	27.83

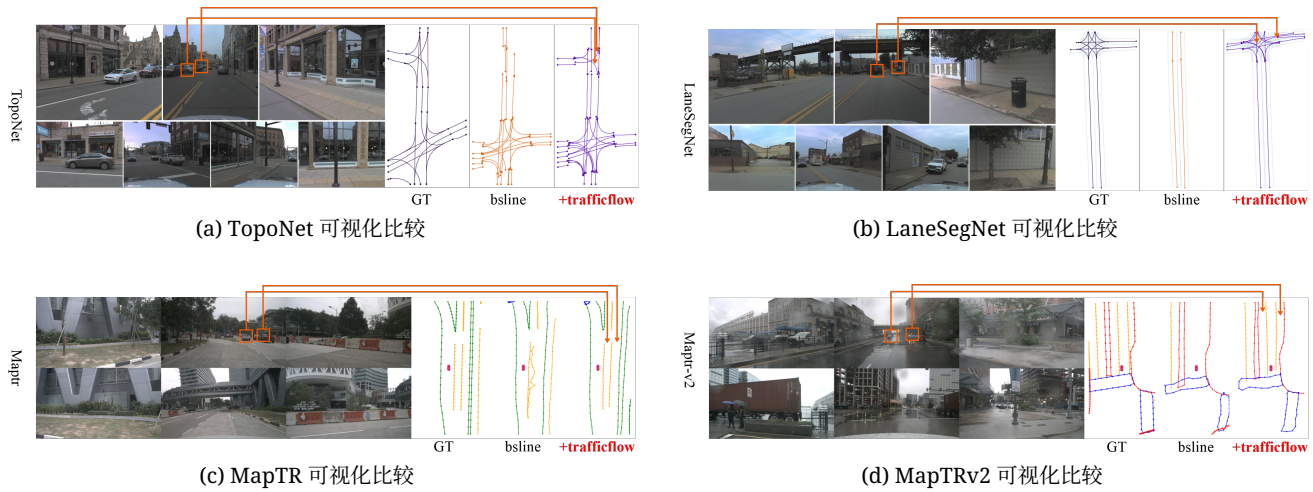
表6. **数据消融**。 在固定架构设置（Pipe.= LT/LL、Dep.=1、Norm.=T）下评估 TFM 的数据组件

设置	N_t	$tole_{pts}$	**mAP**	AP_{ls}	AP_{pred}	TOP_{ll}
基线	-	-	32.99	32.75	33.24	27.02
Abla6	20	5	34.04	32.05	36.04	27.55
Abla7	**30**	**5**	**35.02**	34.90	35.15	27.83
Abla8	30	10	33.90	34.55	33.24	27.55

表 7. **泛化消融**。 通过在固定数据和架构参数下构建不同的推理场景，评估模型的推理适应能力。

设置	训练$_{N_t}$	评估$_{N_t}$	**mAP**	AP_{ls}	AP_{pred}	TOP_{ll}
基线	-	-	32.99	32.75	33.24	27.02
Abla9	30	**30**	**35.02**	34.90	35.15	27.83
Abla10	30	**0**	**34.32**	33.54	35.10	27.82

数据解析策略除了架构设计之外，我们还分析了数据解析策略。这里， N_t 表示训练期间引入的交通流实例数量（数量不足时进行填充）， $tole_{\text{pts}}$ 则定义了每个交通流实例的有效帧阈值，超过该阈值



(a) TopoNet 可视化比较

(b) LaneSegNet 可视化比较

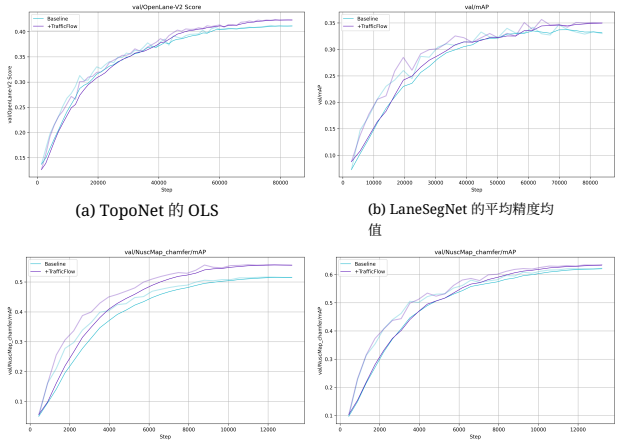
(c) MapTR 可视化比较

(d) MapTRv2 可视化比较

图 6. **对比可视化**。四种具有挑战性的场景并排对比：(a) T形路口分流，(b) 存在大量车辆遮挡的路口，(c) 远处的交通灯路口，以及 (d) 雨天道路状况。

的样本将被视为有效。如表 6所示，增加交通流量（例如 Abla7）可带来更大的性能提升。有效实例的阈值可根据自动驾驶系统的目标检测模块动态调整，以平衡数据质量和模型泛化。

泛化能力为进一步研究 TFM 的泛化能力，我们设计了部分模态推理测试：使用交通流数据进行训练，但在推理时不使用交通流数据。如表7所示，即使推理时没有交通流信息，TFM 相较于基线仍能实现稳定提升，这表明交通流特征可作为辅助监督信号，增强表征学习。该结果验证了 TFM 不仅适用于显式端到端模型，也能提升隐式网络的性能（推理时不输入交通流数据）。



(a) TopoNet 的 OLS

(b) LaneSegNet 的平均精度均值

(c) MapTR 的平均精度均值

(d) MapTRv2 的平均精度均值

图7。**验证集指标比较**。四种基线模型在关键评估指标上的性能曲线。

4.4. 定性可视化

为验证 TFM 的泛化能力，我们对四种基准模型的推理结果进行了可视化比较。与基线方法相比，集成 TFM 的模型在所有测试场景中均表现出更稳健的感知性能。我们特别选取了四种具有挑战性的场景进行推理和可视化（如图 6 所示）：存在大型车辆遮挡的路口（LaneSegNet）、T形路口分流（TopoNet）、远处的交通灯路口（MapTR），以及雨天道路状况（MapTRv2）。可视化结果表明，通过引入实时性极高的交通流先验，TFM 显著增强了模型对遮挡、恶劣天气状况等复杂场景的适应能力，生成的感知结果也更符合实际道路结构。

并验证了我们模块设计的有效性。

5. 结论

本文提出了一种基于交通流先验的车道线检测增强方法。通过引入零订阅成本且具有高度实时性的交通流特征，所提出的TFM模块能够兼容广泛的现有检测框架，有效解决遮挡和车道线缺失等复杂场景中的感知性能下降问题。在两个公开数据集和四种主流模型上开展的大量实验表明，在标准评估指标下，该方法能够显著提升性能（例如在NuScenes上平均精度均值最高提升 +4.1%）；消融研究进一步证实了模块架构和数据策略的稳健性。

架构和数据策略。

我们的工作源于真实世界自动驾驶系统的实际需求，并已通过闭环验证成功部署于工业应用中，展示了从工业实践到学术贡献的完整路径。

参考文献

[1] Hala Abualsaud、Sean Liu、David B Lu、Kenny Situ、Akshay Rangesh 和 Mohan M Trivedi。LaneAF：利用亲和场实现稳健的多车道检测。IEEE机器人与自动化快报，6(4)：7477–7484，2021年。2[2] Tarek Ben Charrada、Hedi Tabia、Aladine Chetouani 和 Hamid Laga。Topo Net：任意亏格物体三维重建的拓扑学习。载于《计算机图形学论坛》，第336–347页。Wiley Online Library，2022年。2[3] Holger Caesar、Varun Bankiti、Alex H Lang、Sourabh Vora、Venice Erin Liong、Qiang Xu、Anush Krishnan、Yu Pan、Giancarlo Baldan 和 Oscar Beijbom。NuScenes：用于自动驾驶的多模态数据集。载于《IEEE/CVF计算机视觉与模式识别会议论文集》，第11621–11631页，2020年。2, 4[4] Andrea Boscolo Camiletto、Alfredo Bochicchio、Alexander Liniger、Dengxin Dai 和 Abel Gawel。U-BEV：具备高度感知能力的鸟瞰图分割与基于神经地图的重定位。载于2024年IEEE/RSJ智能机器人与系统国际会议（IROS），第5597–5604页。IEEE，2024年。3[5] Daniel Duckworth、Peter Hedman、Christian Reiser、Peter Zhizhin、Jean-François Thibert、Mario Lučić、Richard Szeliski 和 Jonathan T Barron。SMERF：用于实时大型场景探索的可流式、内存高效辐射场。《ACM图形学汇刊》（TOG），43(4)：1–13，2024年。3[6] Netalee Efrat、Max Bluvstein、Shaul Oron、Dan Levi、Noa Garnett 和 Bat El Shlomo。3D-LaneNet：使用半局部表示的无锚点车道检测。arXiv预印本 arXiv:2011.01535，2020年。2[7] Noa Garnett、Rafi Cohen、Tomer Pe'er、Roee Lahav 和 Dan Levi。3D-LaneNet：端到端三维多车道检测。载于《IEEE/CVF计算机视觉国际会议论文集》，第2921–2930页，2019年。2[8] Yuliang Guo、Guang Chen、Peitao Zhao、Weide Zhang、Jinghao Miao、Jingao Wang 和 Tae Eun Choe。Gen-LaneNet：一种通用且可扩展的三维车道检测方法。载于《欧洲计算机视觉会议》，第666–681页。Springer，2020年。2[9] Cherie Ho、Seungchan Kim、Brady Moon、Aditya Parandekar、Narek Harutyunyan、Chen Wang、Katia Sycara、Graeme Best 和 Sebastian Scherer。MapEX：利用全局地图预测的概率信息增益进行室内结构探索。载于2025年IEEE机器人与自动化国际会议（ICRA），第13074–13080页。IEEE，2025年。3[10] Junjie Huang、Guan Huang、Zheng Zhu、Yun Ye 和 Dalong Du。BEVDet：高性能多摄像头三维物体检测

鸟瞰视图中的检测。arXiv预印本 arXiv:2112 11790，2021 2 。 .[11] Peijin Jia、Ziang Luo、Tuopu Wen、Mengmeng Yang、Kun Jiang、Le Cui 和 Diange Yang。利用众包轨迹先验增强车道段感知与拓扑推理。IEEE机器人与自动化快报，2025年。 3[12] Zhou Jiang、Zhenxin Zhu、Pengfei Li、Huan-ang Gao、Tianyuan Yuan、Yongliang Shi、Hang Zhao 和 Hao Zhao。P-mapnet：同时利用sdmap和hdmap先验增强的远距离地图生成器。IEEE机器人与自动化快报，2024年。 3[13] Tianyu Li、Peijin Jia、Bangjun Wang、Li Chen、Kun Jiang、Junchi Yan 和 Hongyang Li。Lanesegnet：利用车道段感知进行自动驾驶地图学习。arXiv预印本 arXiv:2312.16108，2023年。 2[14] Zhiqi Li、Wenhai Wang、Hongyang Li、Enze Xie、Chong- hao Sima、Tong Lu、Qiao Yu 和 Jifeng Dai。Bevformer：通过时空变换器从激光雷达-相机数据中学习鸟瞰视图表示。IEEE模式分析与机器智能汇刊，2024年。 2[15] Bencheng Liao、Shaoyu Chen、Xinggang Wang、Tianheng Cheng、Qian Zhang、Wenyu Liu 和 Chang Huang。Maptr：用于在线矢量化高精度地图构建的结构化建模与学习。arXiv预印本 arXiv:2208.14437，2022年。 2[16] Bencheng Liao、Shaoyu Chen、Yunchi Zhang、Bo Jiang、Qian Zhang、Wenyu Liu、Chang Huang 和 Xinggang Wang。Maptrv2：用于在线矢量化高精度地图构建的端到端框架。国际计算机视觉杂志，133(3):1352–1374，2025年。 2[17] Teddy Ort、Jeffrey M Walls、Steven A Parkison、Igor Gilitschenski 和 Daniela Rus。Maplite 2.0：利用先验标准精度地图进行在线高精度地图推断。IEEE机器人与自动化快报，7(3):8355–8362，2022年。 2[18] Angshuman Parashar、Minsoo Rhu、Anurag Mukkara、An- tonio Puglielli、Rangharajan Venkatesan、Brucek Khailany、Joel Emer、Stephen W Keckler 和 William J Dally。Scnn：一种压缩稀疏卷积神经网络加速器。ACM SIGARCH计算机体系结构新闻，45 (2):27–40，2017年。 2[19] Jonah Philion 和 Sanja Fidler。Lift, splat, shoot：通过隐式反投影到三维空间，对来自任意相机组的图像进行编码。在欧洲计算机视觉会议中，第194–210页。Springer，2020年。 2[20] Qibo Qiu、Haiming Gao、Wei Hua、Gang Huang 和 Xi- aofei He。Priorlane：一种基于变换器、由先验知识增强的车道线检测方法。arXiv预印本 arXiv:2209.06994，2022年。 2[21] Huijie Wang、Tianyu Li、Yang Li、Li Chen、Chonghao Sima、Zhenbo Liu、Bangjun Wang、Peijin Jia、Yuting Wang、Shengyin Jiang 等。Openlane-v2：统一三维高精度地图构建的拓扑推理基准。神经信息处理系统进展，36:18873–18884，2023年。2, 4[22] Ruihao Wang、Jian Qin、Kaiying Li、Yaochen Li、Dong Cao 和 Jintao Xu。Bev-lanedet：一种高效的三维车道线检测

基于虚拟相机和关键点。在 *IEEE/CVF*计算机视觉与模式识别会议论文集，第1002–1011页，2023年。 2[23]Benjamin Wilson、William Qi、Tanmay Agarwal、John Lambert、Jagjeet Singh、Siddhesh Khandelwal、Bowen Pan、Ratnesh Kumar、Andrew Hartnett、Jhony Kaesemodel Pontes 等。Argoverse 2：面向自动驾驶感知与预测的下一代数据集。 *arXiv*预印本 *arXiv:2301.00493*，2023年。 4[24] Jannik Z¨urn、Ingmar Posner 和 Wolfram Burgard。Autograph：根据交通观测预测车道图。 *IEEE*机器人与自动化快报，9(1):73–80，2023年。3