

導入

背景

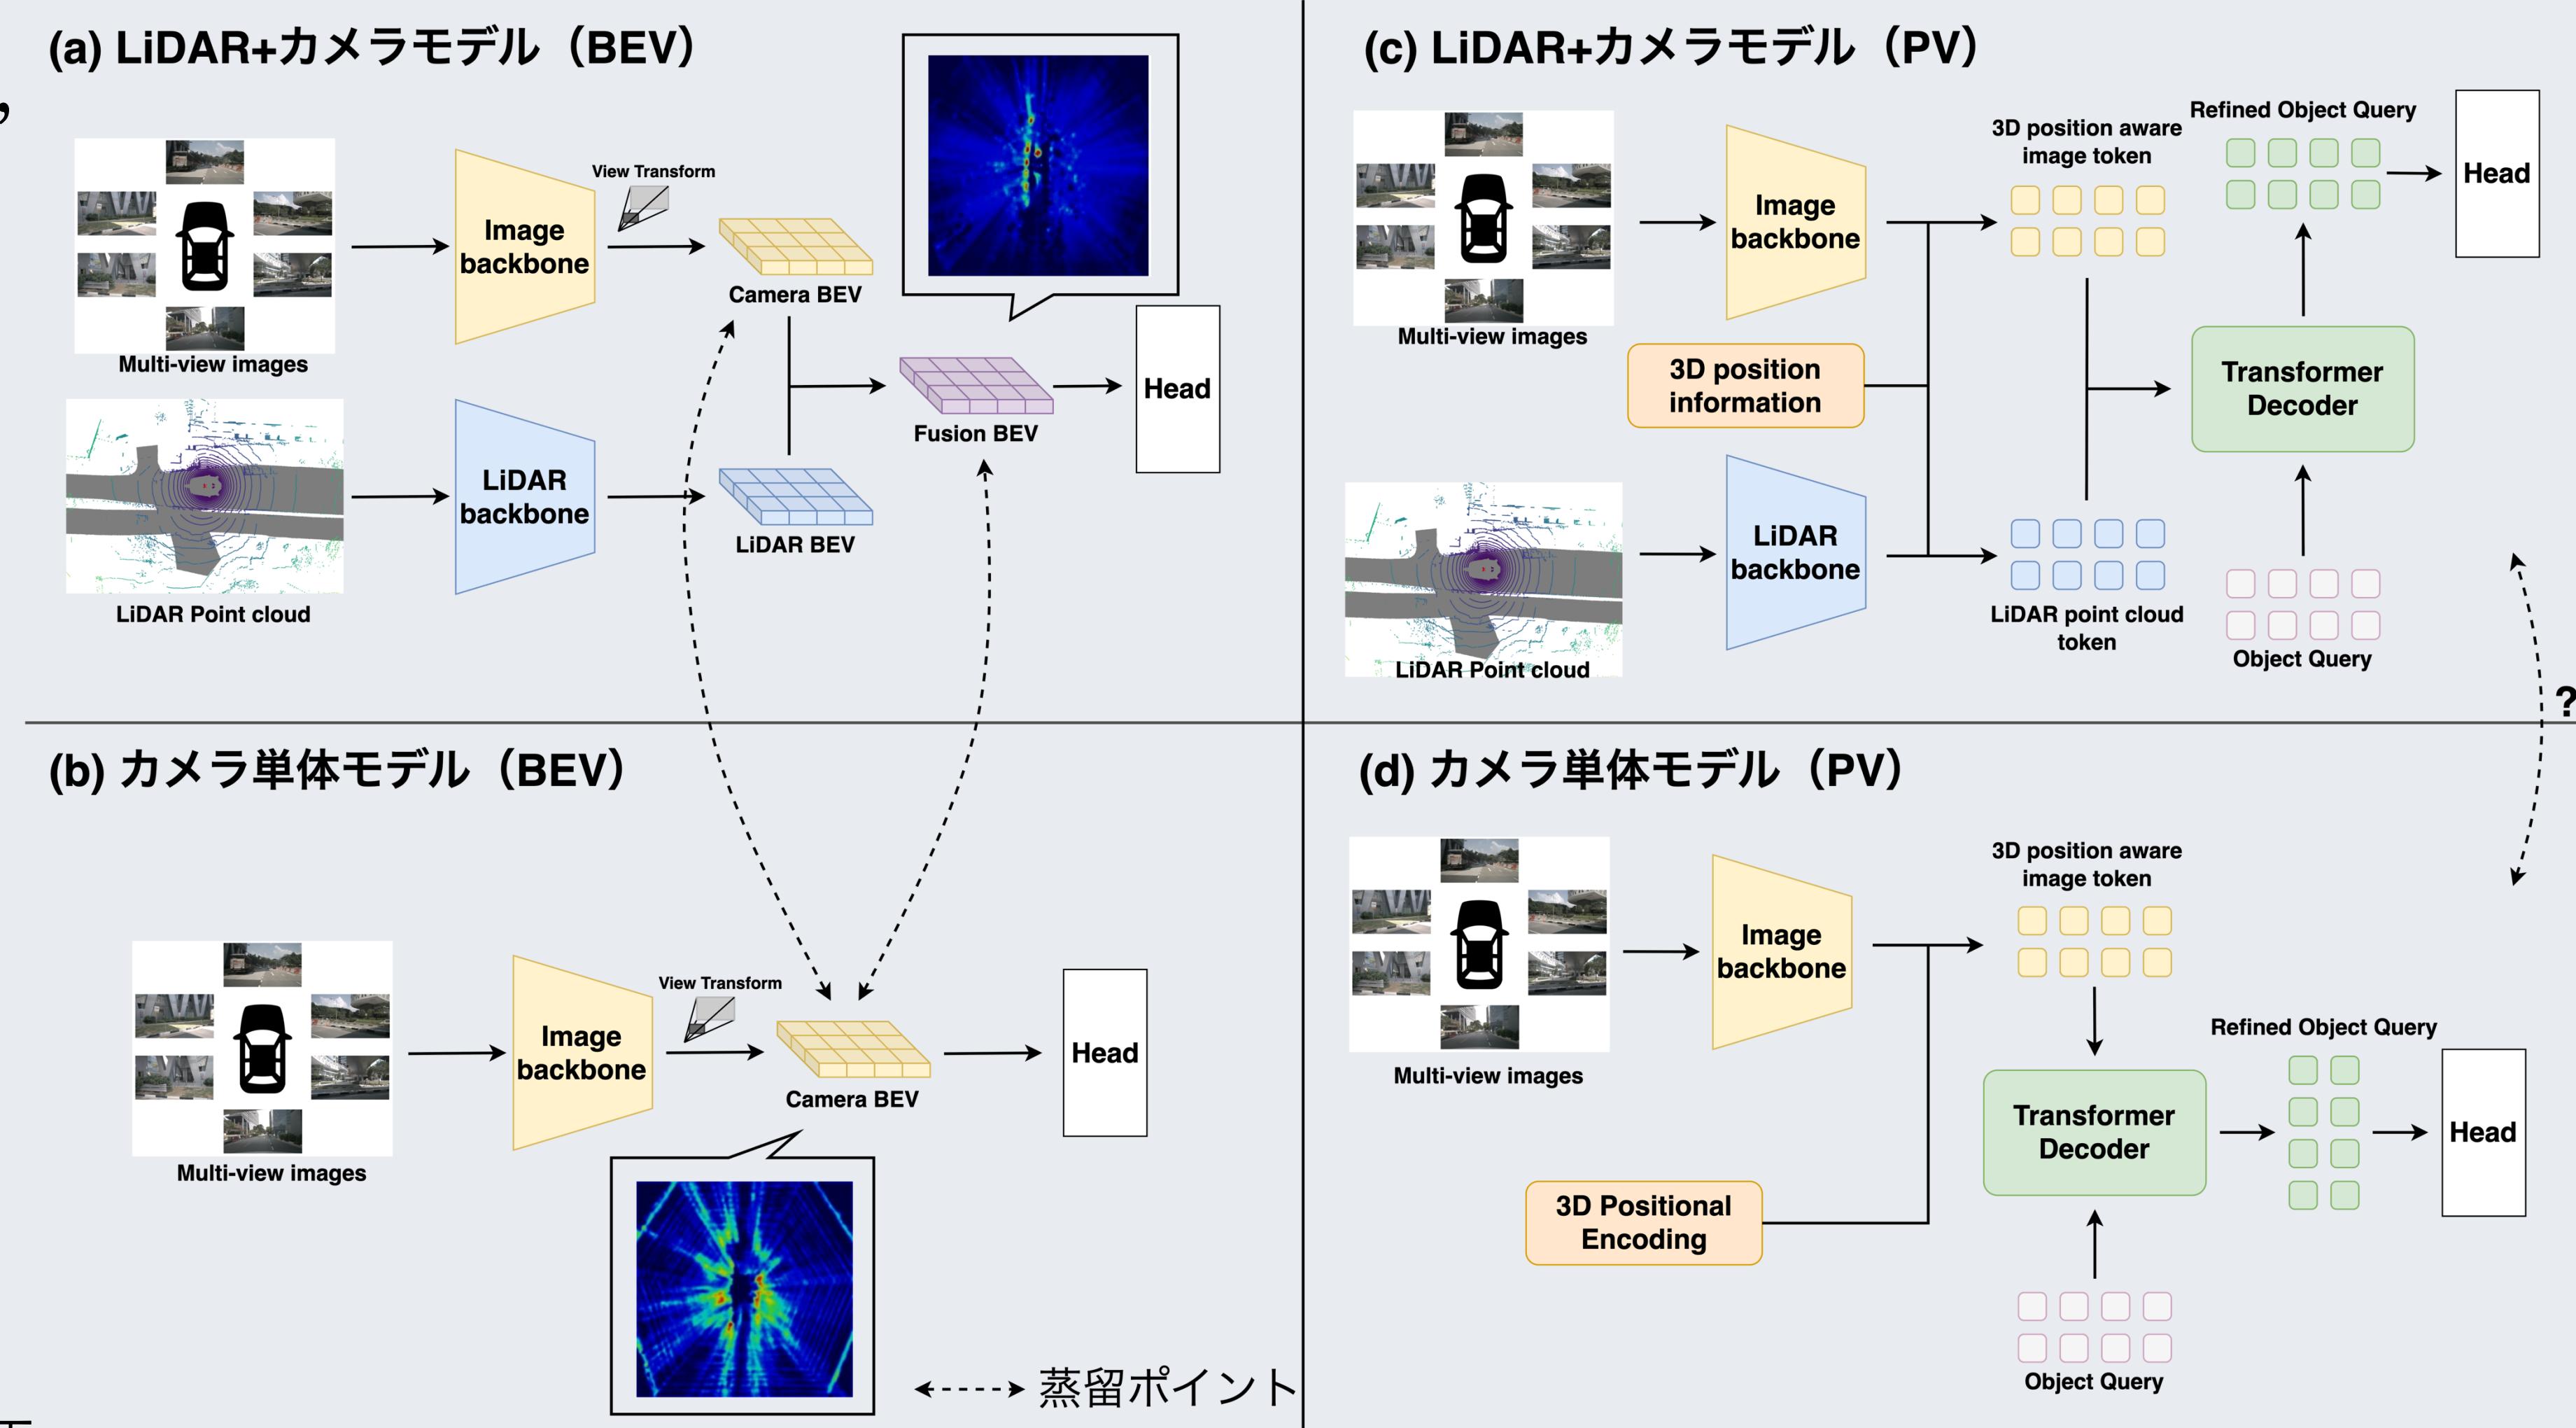
- カメラのみの3D物体検出は低コストな反面、位置推定精度が課題。
- LiDAR+カメラモデルからカメラ単体モデルへのクロスモーダル知識蒸留が有望視されている。

標準的な特徴表現の方式

- Bird's-Eye View上の特徴表現を利用するもの('BEV')
- BEVを介さないPerspective View上の特徴表現を利用するもの('PV')

検討方針

- BEV方式とPV方式の有効性の見極め
- PV方式を用いた知識蒸留手法の開発・評価



既存研究調査：BEV方式 - PV方式

調査範囲

- 主に2021~2025年にCV系トップ会議で発表された論文のうちnuScenesデータセットでの評価結果を調査した(右表1, 2)。

調査結果

- C単体では最新のPV方式とBEV方式の手法はほぼ同性能。
それぞれのSOTAであるRayDNとGeoBEVはどちらも0.52mAP, 0.61NDS程度
- C+Lでは、PV方式がBEV方式を上回る。
PV方式のSOTAであるSparseLIFは、BEV方式のSOTAであるBEVFusionに比べて+0.027mAP, +0.032NDS
- BEV蒸留を用いた生徒モデルは最新のPV方式の手法の性能には届いていない。
DistillBEV(S)はRayDNと比較して-0.068mAP, -0.057NDS
- PV方式はBEV方式に比べて速い推論速度になっている(右表2)。
StreamPETRはBEVDetに対して約1.6倍の推論速度

結論

BEV方式は異なるモダリティ同士の統合が容易だが計算負荷が大きく、より高速かつ高精度なPV方式の方が有力な選択肢である。

表1. nuScenesデータセットにおける3D物体検出評価結果

Method	Reference	Modality	Backbone		validation set mAP ↑ NDS ↑	
			Camera	LiDAR		
BEV	BEVDet	C	ResNet101	-	0.302 0.381	
BEVFormer	ECCV2022		ResNet101	-	0.416 0.517	
BEVDepth	AAAI2023		ResNet101	-	0.412 0.535	
GeoBEV	AAAI2025		ResNet101	-	0.526 0.615	
BEVFusion	ICRA2023		Swin-T	VoxelNet	0.685 0.714	
PV	DETR3D	C	ResNet101	-	0.349 0.434	
PETR	ECCV2022		ResNet101	-	0.370 0.442	
PETRv2	ICCV2023		ResNet101	-	0.421 0.524	
StreamPETR	ICCV2023		ResNet101	-	0.504 0.592	
RayDN	ECCV2024		ResNet101	-	0.518 0.604	
CMT	ICCV2023		C+L	V2-99	VoxelNet	0.703 0.729
SparseFusion	ICCV2023		C+L	Swin-T	VoxelNet	0.710 0.731
SparseLIF	ECCV2024		C+L	V2-99	VoxelNet	0.712 0.746
BEV 蒸留	UniDistill(S)	C	ResNet50	-	0.265 0.378	
DistillBEV(S)	ICCV2023		ResNet101	-	0.450 0.547	
SimDistill(S)	AAAI2024		C	Swin-T	-	0.404 0.453

※CはCameraを表し、LはLiDARを表している。また、BEV蒸留の欄の(S)は生徒モデルを表す。

表2. BEV方式とPV方式のFPS比較

Method	Frames	FPS ↑
BEVDet	1	16.7
BEVDepth	2	15.7
PETRv2	2	18.9
StreamPETR	8	27.1

手法の開発方針

- 既存研究調査の結果からPV方式による手法は高速かつ高精度であることが確認できた。
→ PV方式を基盤とした知識蒸留を検討する。
- LiDAR教師の幾何的情報を、BEV表現を介さずにCameraベース生徒へ伝達するクロスモーダル蒸留を設計する。

今後の計画

生徒モデルの構造の選定

教師の豊富な幾何情報を効率的に取り込めるPV方式のモデルを選定する。

蒸留損失の適用箇所の検討

蒸留を適用する層を探索的に選定する。