

ادغام بدون نظارت دوربین و لیدار برای پیشنهاد ناحیه سریع

ارائه دهنده: بردیا اردکانیان
استاد راهنما: دکتر مهدی جوانمردی

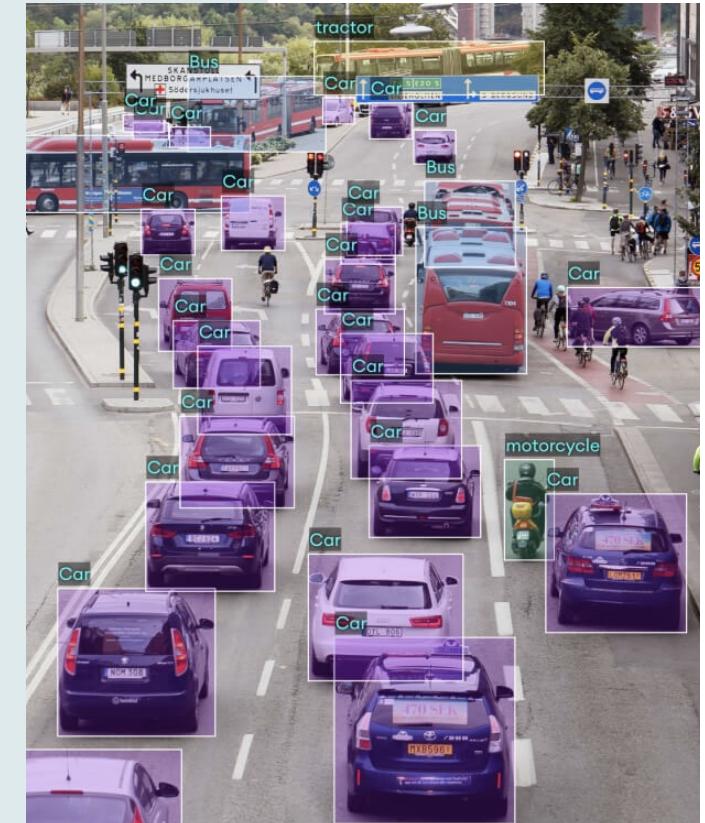
۱۴۰۳



دانشکده مهندسی کامپیوتر



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)



اهداف ارائه

ادغام داده‌ها

ادغام دوربین و لیدار
تاثیر ادغام بر تشخیص
چالش‌ها و مزایا

سنسورهای بینایی در خودرو خودران

دوربین
لیدار
محدودیت و مزایا

پیشنهاد ناحیه در تشخیص شیء

تعريف
تکنیک‌های رایج
اهمیت پیشنهاد ناحیه

تشخیص شیء در خودرو خودران

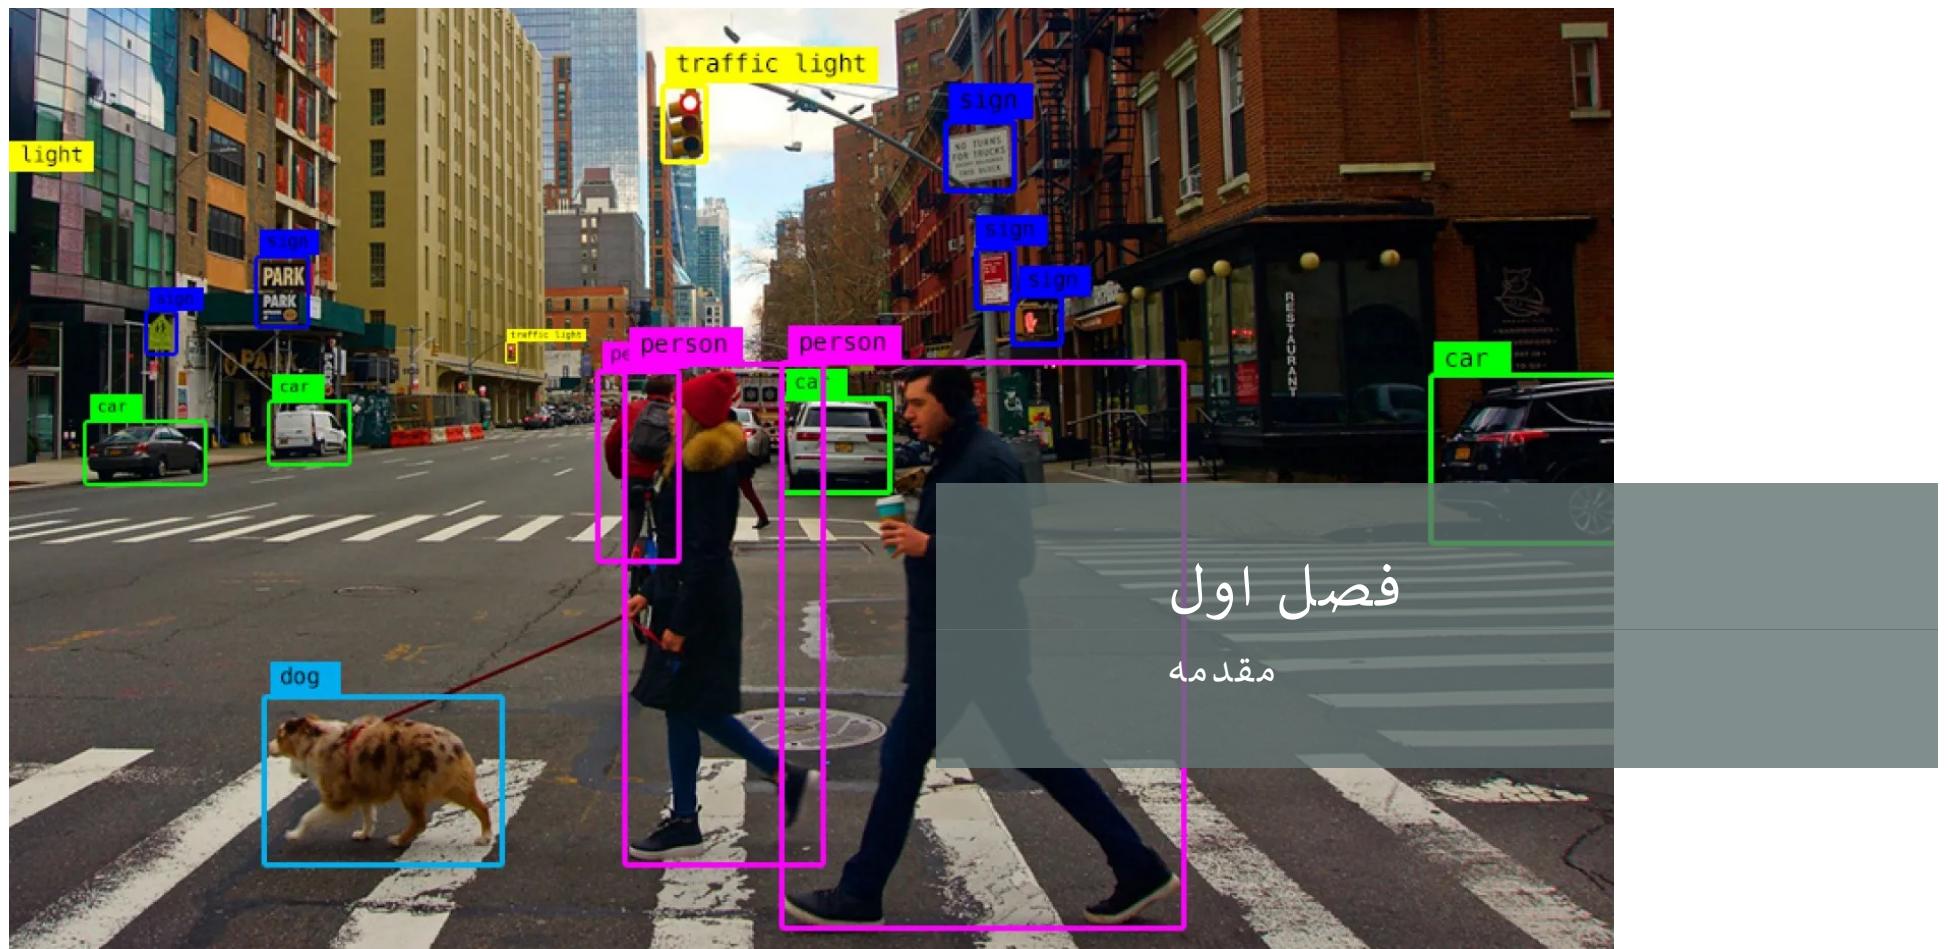
یک مرحله‌ای
- مدل YOLO
دو مرحله‌ای
- مدل RCNN
- مدل Fast-RCNN
- مدل Faster-RCNN

خودرو خودران

تعريف
اهمیت
اجزای اصلی

سیر مطالب

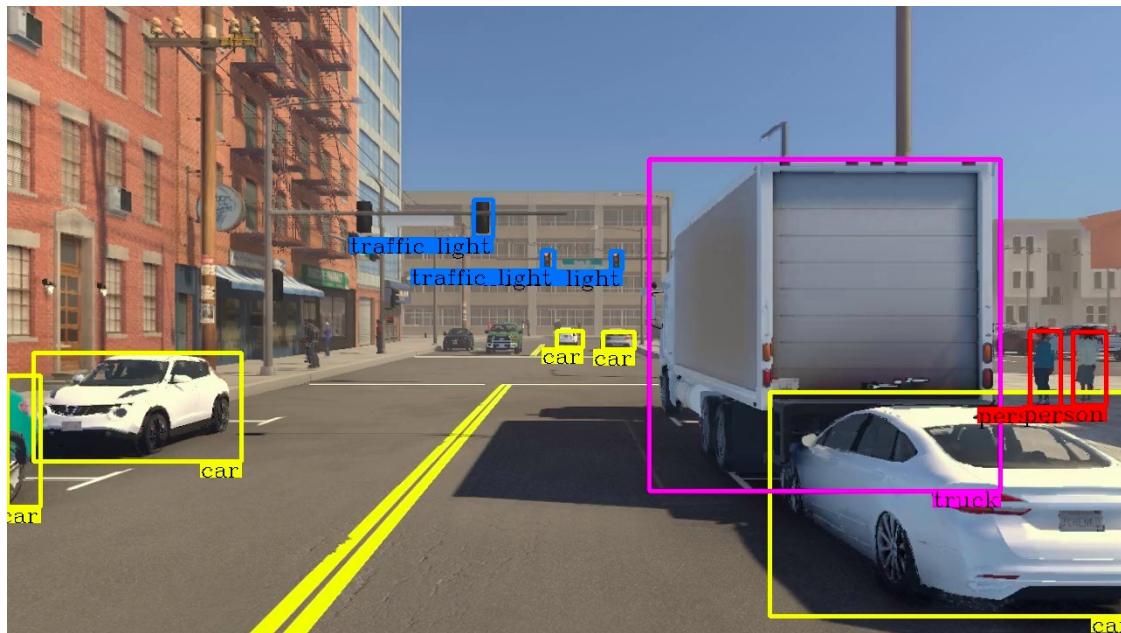




مقدمه

تشخیص شی

تشخیص شی فرآیندی است که در آن موقعیت و نوع اشیاء در تصاویر یا ویدئوهای شناسایی و مشخص می‌شود.



مقدمه

انواع تشخیص شیء

تشخیص شیء دومرحله‌ای

فرآیندی که ابتدا نواحی پیشنهادی را شناسایی کرده و سپس اشیاء را در این نواحی تشخیص می‌دهد.

تشخیص شیء تک مرحله‌ای

فرآیندی که به صورت مستقیم اشیاء را در یک مرحله تشخیص و مکانیابی می‌کند.

- ❖ مدل Faster-RCNN، مدل Fast-RCNN، مدل RCNN
- ❖ استفاده از شبکه پیشنهاد ناحیه
- ❖ دقت بالاتر در تشخیص اشیاء، به ویژه در اشیاء کوچک و پیچیده
- ❖ زمان بر بودن و پیچیدگی بالاتر معماری
- ❖ نیاز بیشتر به داده‌های آموزشی
- ❖ مدل YOLO
- ❖ سریع و کارآمد
- ❖ مناسب برای کاربردهای بلادرنگ
- ❖ دقت کمتری نسب به روش‌های دومرحله‌ای
- ❖ مشکلات در تشخیص اشیاء کوچک و نزدیک

مقدمه

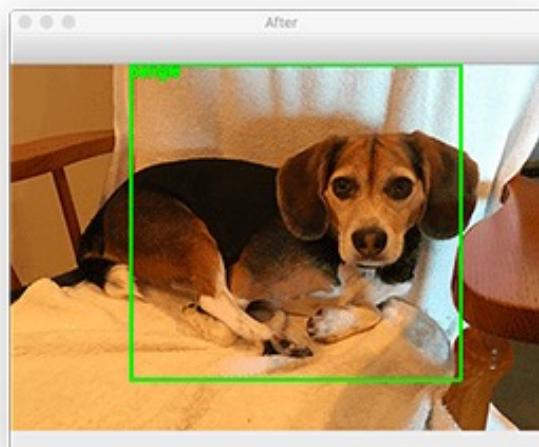
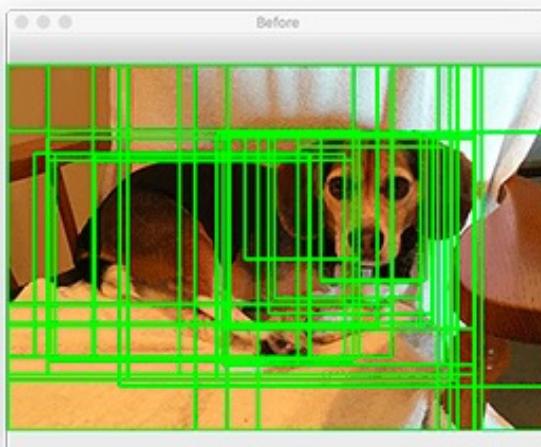
اهمیت و تعریف پیشنهاد ناحیه

فرآیندی برای شناسایی و تعیین نواحی محتمل در تصویر که ممکن است اشیاء باشند.

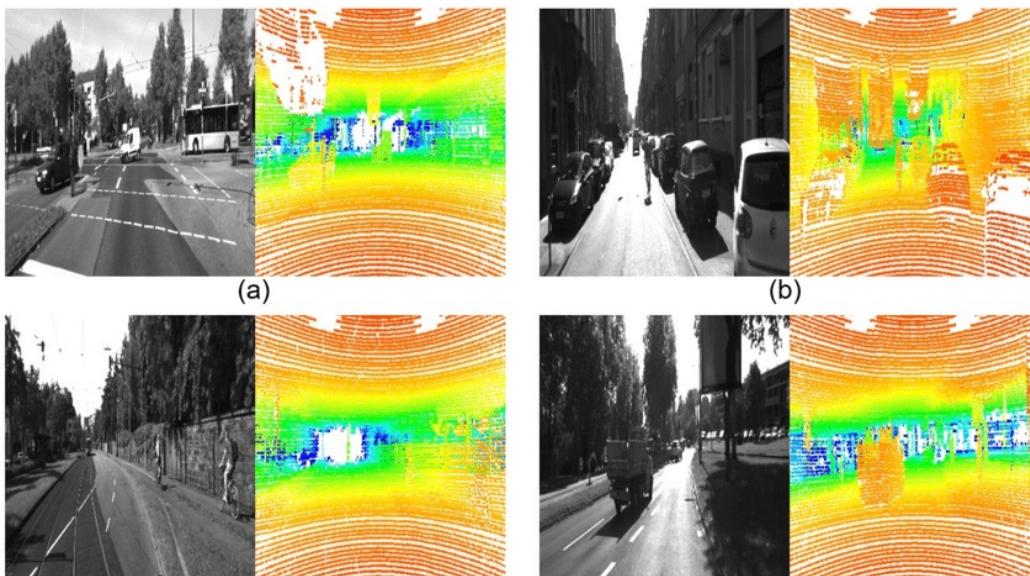
مزایای استفاده از پیشنهاد ناحیه:

❖ افزایش دقت

❖ بهبود کارایی مدل‌های تشخیص شیء



مقدمه



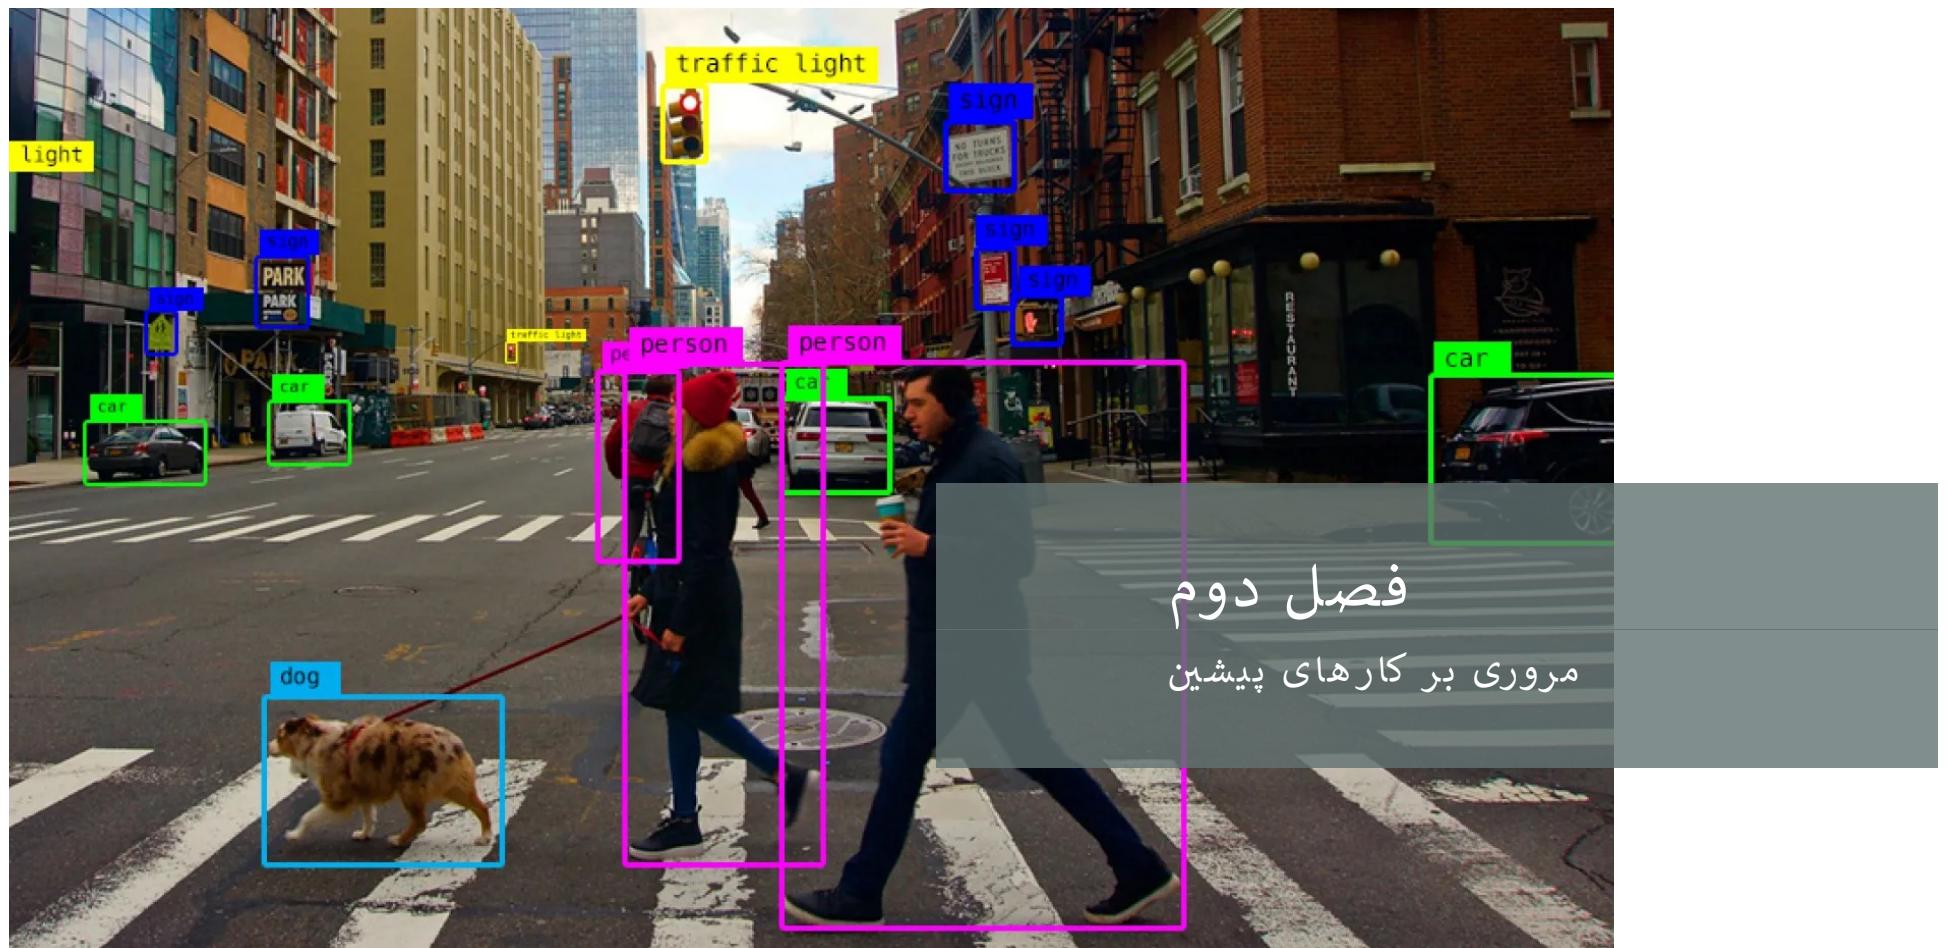
حسگرهای کلیدی در خودروهای خودران

دوربین:

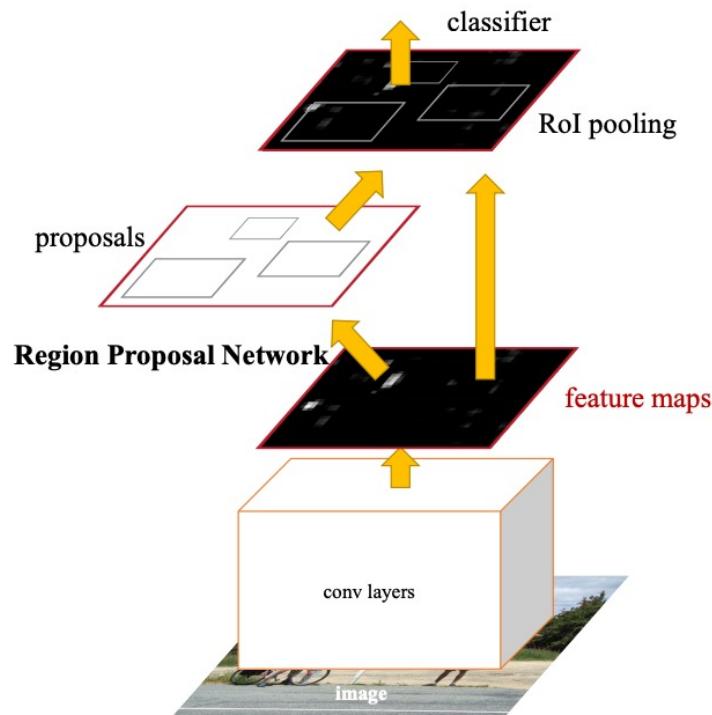
- ❖ فراهم آوری اطلاعات بصری دقیق از محیط
- ❖ هزینه پایین، وضوح بالا، قابلیت تشخیص ویژگی‌های بصری
- ❖ حساس به شرایط نوری، مشکلات در تشخیص عمق

لیدار:

- ❖ اندازه‌گیری فاصله و ایجاد نقشه‌های سه‌بعدی از محیط
- ❖ دقت بالا در اندازه‌گیری فاصله، عملکرد در تاریک
- ❖ هزینه بالا، حساسیت به شرایط آب و هوایی



تشخیص شیء دو مرحله‌ای

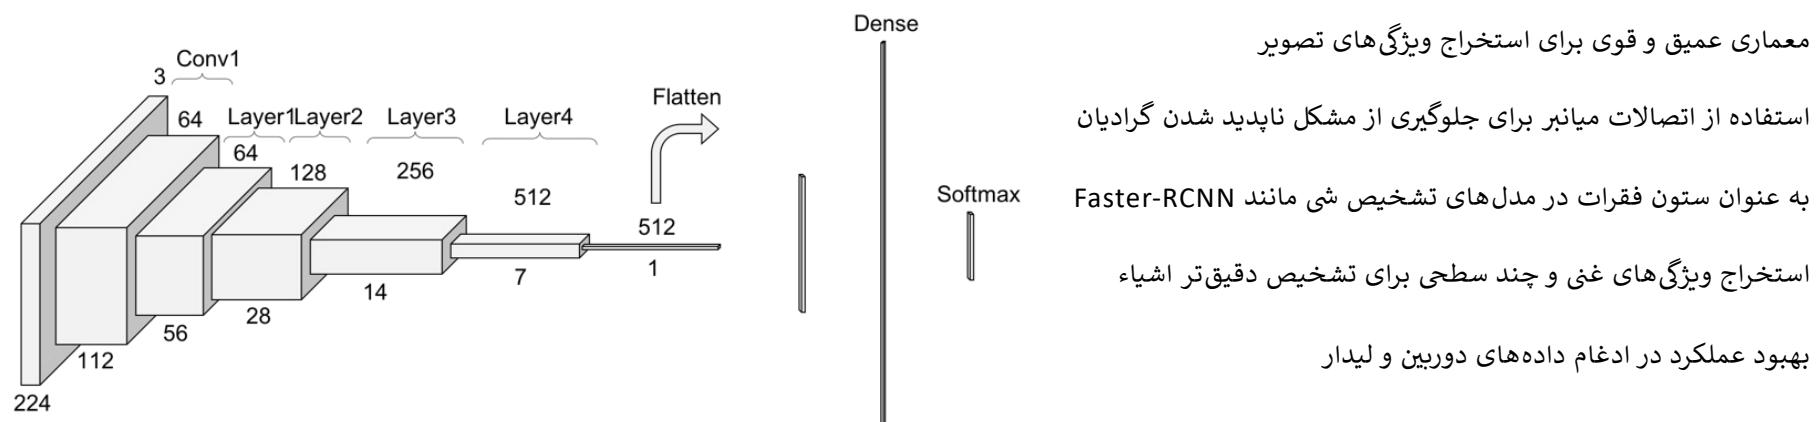


معماری مدل Faster-RCNN

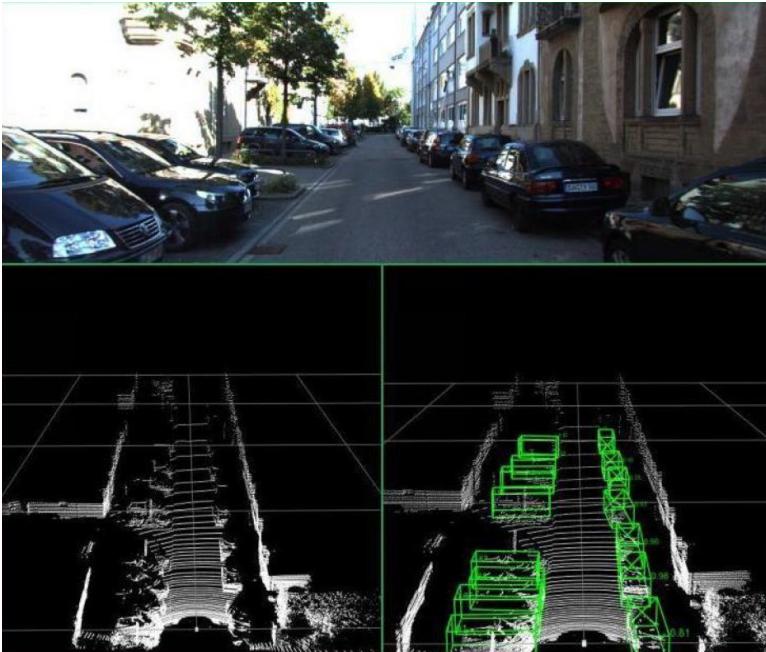
- ❖ دو مرحله اصلی: پیشنهاد ناحیه و تشخیص/طبقه‌بندی
- ❖ استفاده از ResNet به عنوان ستون فقرات برای استخراج ویژگی‌ها
- ❖ شبکه پیشنهاد ناحیه برای شناسایی نواحی محتمل اشیاء
- ❖ دقیق بالاتر در تشخیص اشیاء نسبت به روش تک مرحله‌ای

استخراج ویژگی تصویر

استخراج ویژگی با استفاده از مدل ResNet

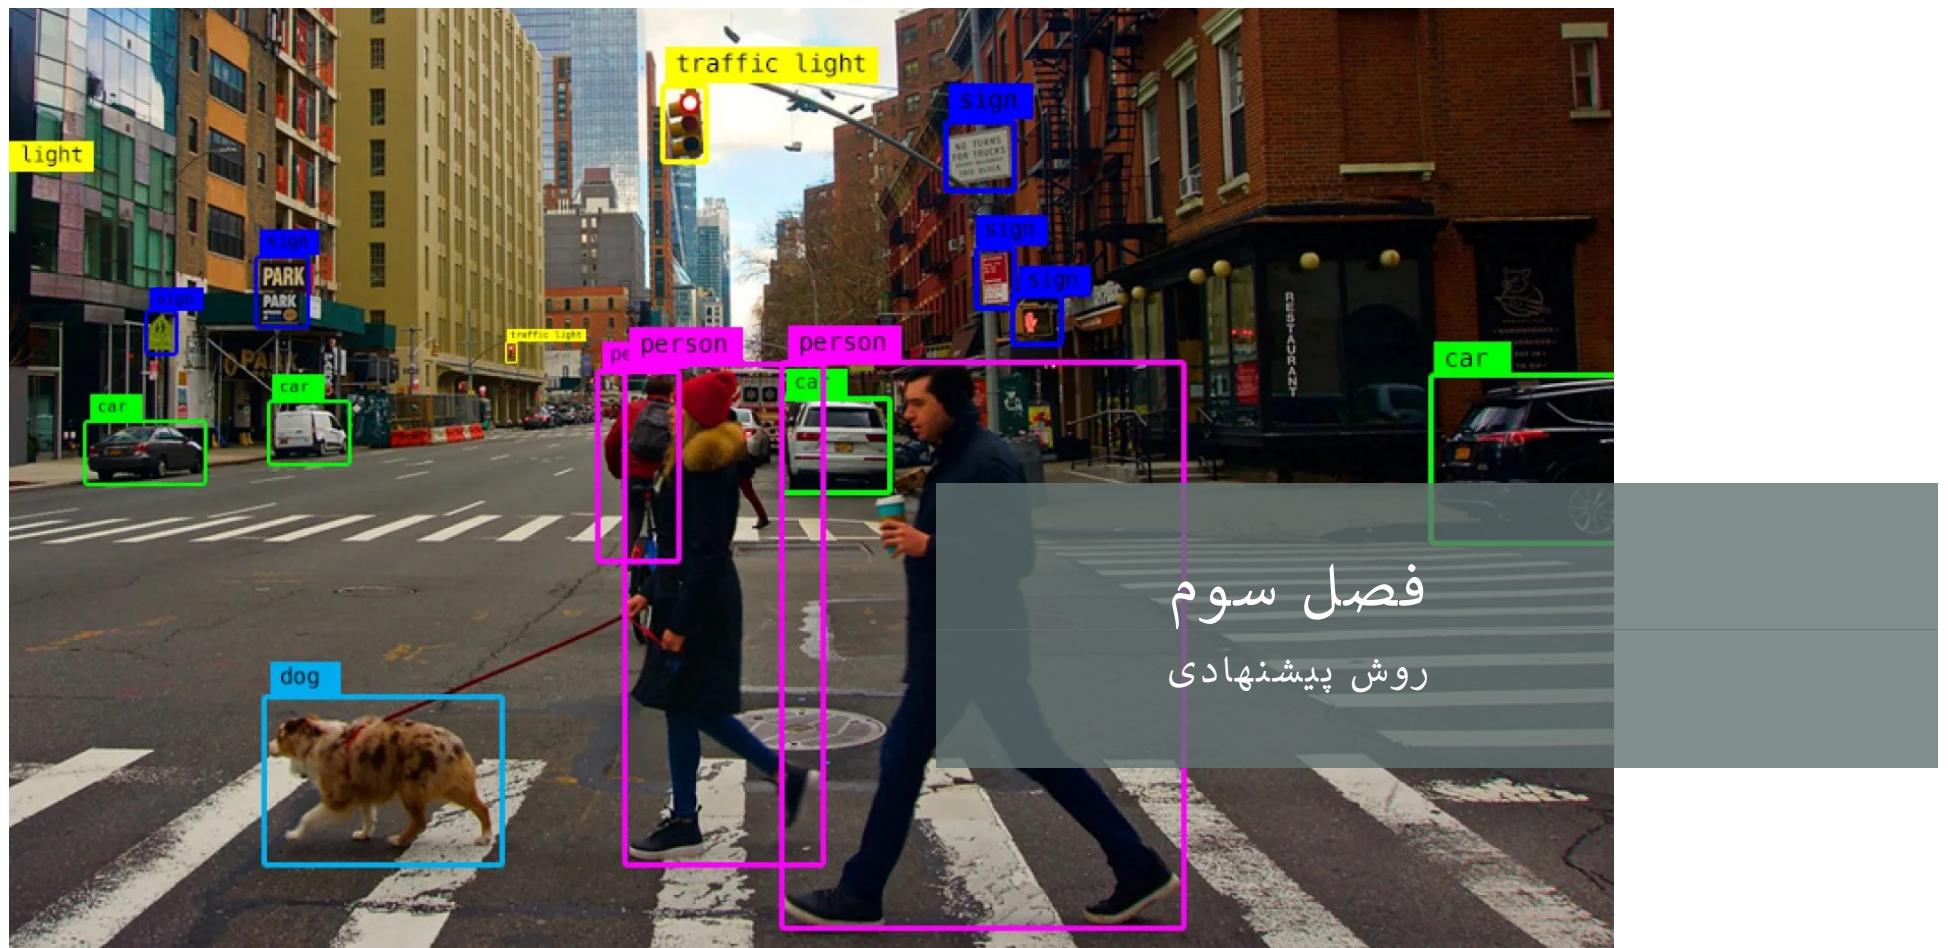


ادغام داده‌های دوربین و لیدار

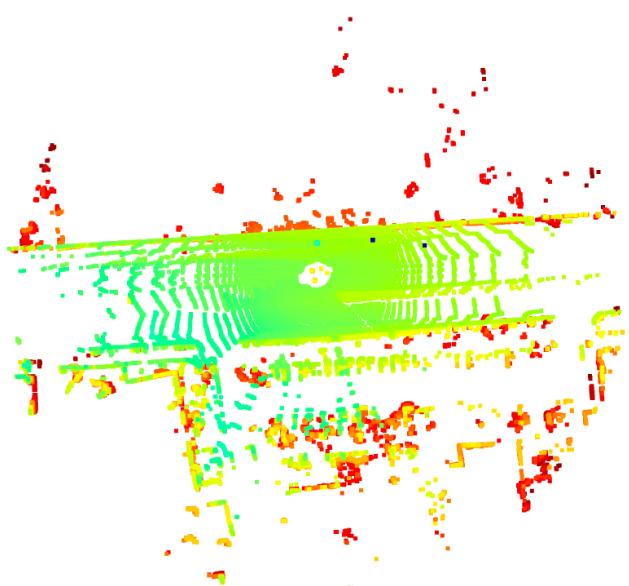


ادغام داده‌های دوربین و لیدار با Deep Fusion

- ❖ ادغام داده‌های دوربین و لیدار برای تشخیص شیء دقیق‌تر
- ❖ ترکیب ویژگی‌های بصری دوربین با داده‌های عمق لیدار
- ❖ استفاده از شبکه عصبی برای هم ترازی و ادغام داده‌ها
- ❖ افزایش دقیقت و قابلیت اطمینان در شرایط نوری و آب و هوایی متفاوت
- ❖ جبران نقاط ضعف هر حسگر با مزایای حسگرهای دیگر
- ❖ بهبود تشخیص اشیاء در سامانه‌های خودران



تبديل داده‌های خام لیدار به ابر نقاط



داده‌های خام لیدار:

- ❖ شامل مختصات سه‌بعدی نقاط و شدت بازتاب
- ❖ اندازه‌گیری فاصله با استفاده از پرتوهای لیزری

فرآیند تبدیل به ابر نقاط:

- ❖ حذف نویز و نقاط نامریوط
- ❖ تبدیل مختصات لیدار به سیستم مختصات خودرو
- ❖ ایجاد نمای بالا برای تحلیل بهتر محیط

هم ترازی داده‌ها با کالیبراسیون دوربین

2D Projected Points Overlaid on Image



❖ فیلتر کردن ابر نقاط موجود در تصویر

❖ استفاده از کالیبراسیون دوربین برای هم ترازی دقیق

❖ تطبیق مختصات سه بعدی لیدار با دوربین دوبعدی دوربین

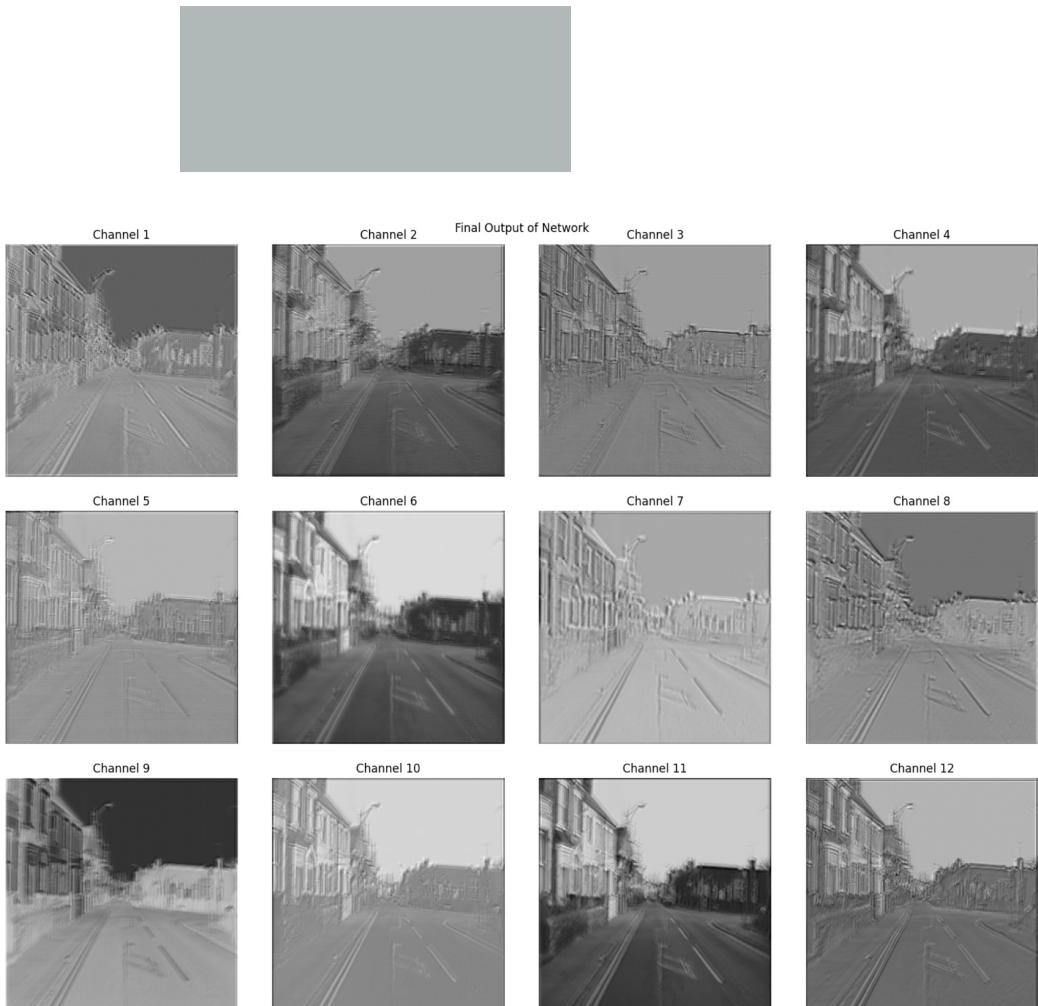
Original Image



2D Projected Points

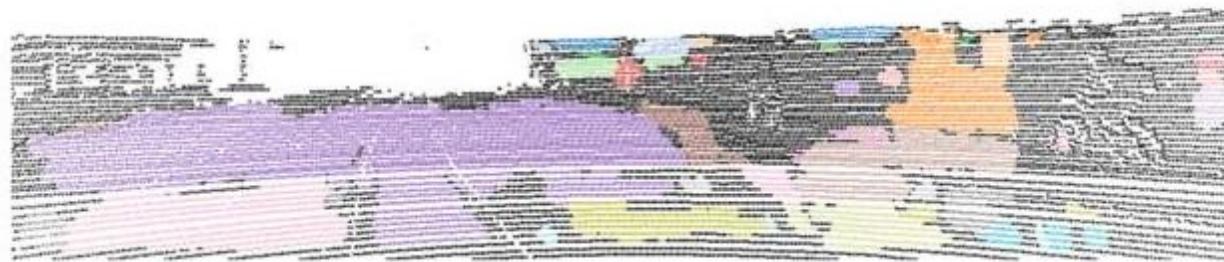


استخراج ویژگی‌های تصویر



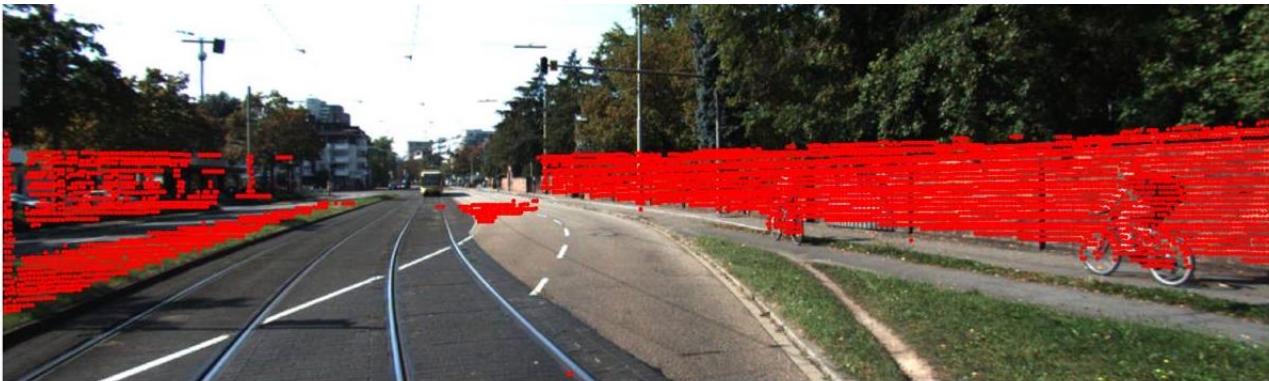
- ❖ استفاده از مدل‌های پایه مانند DeepLabv3 و ResNet
- ❖ استخراج ویژگی‌های چند سطحی و پیچیده از تصاویر دوربین
- ❖ نمونه افزایی ویژگی‌ها برای هم ترازی
- ❖ هماهنگ با ابعاد ابر نقاط لیدار
- ❖ امداده‌سازی برای ادغام داده‌ها

ادغام ویژگی‌های تصویر با ابر نقاط و خوشه بندی

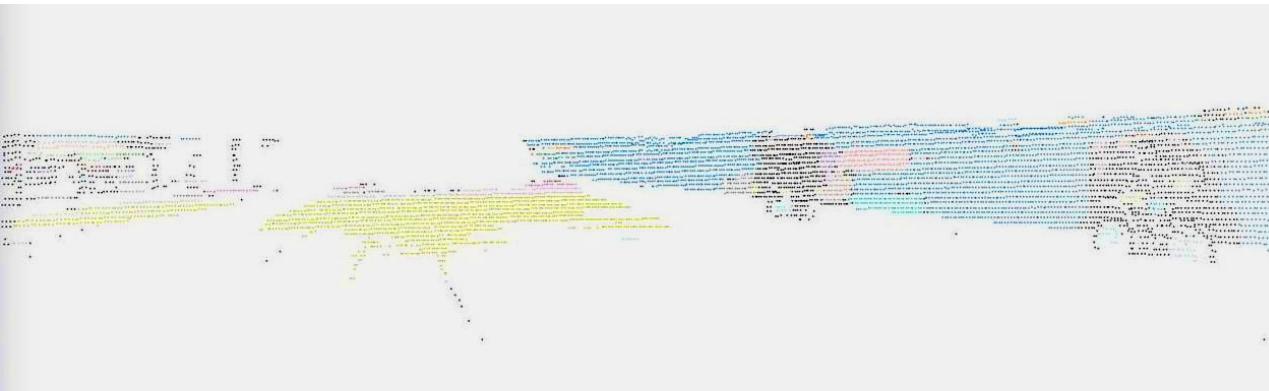


- ❖ ادغام ویژگی‌های استخراج شده از تصویر با ابر نقاط
- ❖ اعمال الگوریتم خوشه‌بندی DBSCAN بر روی داده‌های ادغام شده
- ❖ مشاهده نتایج اولیه خوشه‌بندی
- ❖ شناسایی مشکلات دقت و پراکندگی خوشه‌ها
- ❖ نیاز به بهبود عملکرد خوشه‌بندی
- ❖ عموم ابر نقاط مربوط به زمین می‌باشند
- ❖ نیاز به حذف نقاط زمین از ابر نقاط

حذف نقاط زمین



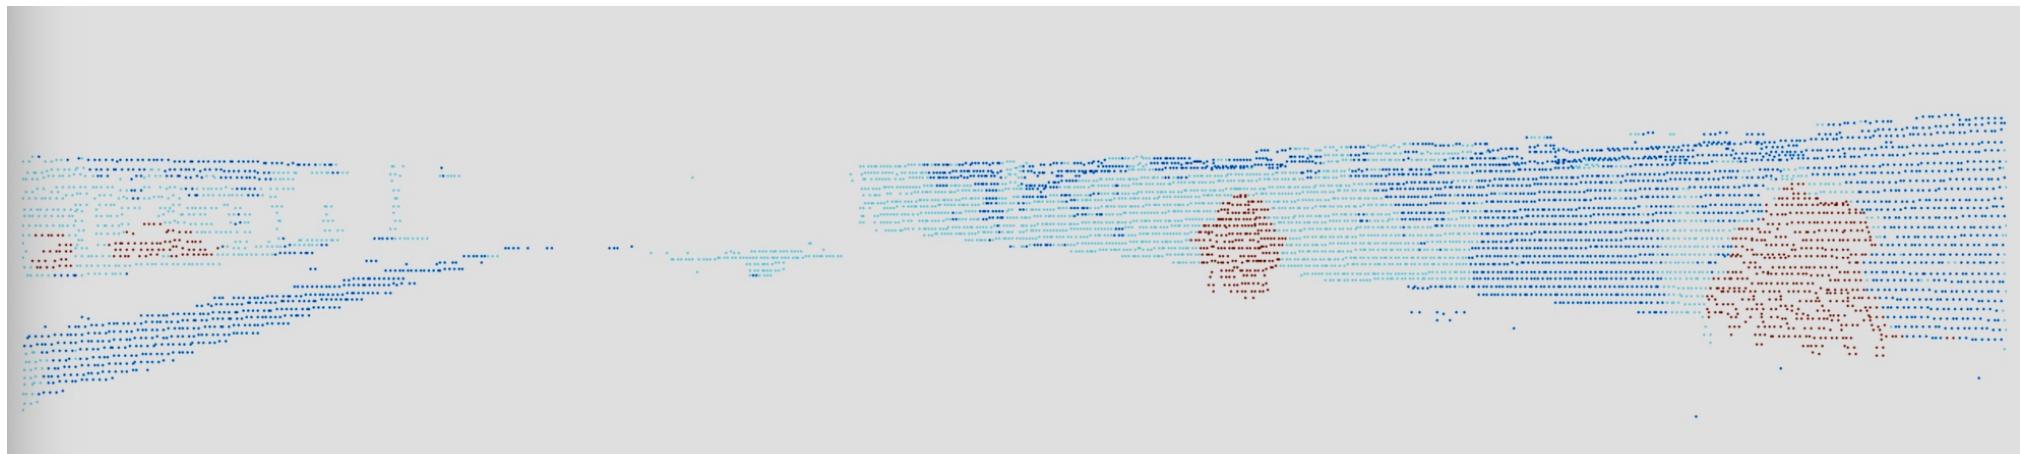
- ❖ شناسایی و حذف نقاط زمین از ابر نقاط
- ❖ استفاده از الگوریتم RANSAC برای تخمین صفحه زمین
- ❖ کاهش نویز و افزایش دقت خوشه بندی
- ❖ تمرکز بر نقاط مربوط به اشیاء واقعی



ادغام بدون نظارت دوربین و لیدار برای پیشنهاد ذاتیه سریع

تنظیم وزن بین ابر نقاط و ویژگی‌های تصویر

- ❖ استفاده از روش جستجوی شبکه‌ای برای بهینه‌سازی وزن‌ها
- ❖ توازن بین تأثیر ابر نقاط و ویژگی‌ها در خوش‌بندی
- ❖ بهبود دقیق خوش‌بندی با وزن‌های بهینه



خوشه‌بندی با الگوریتم‌های دیگر

❖ استفاده از الگوریتم K-Means برای خوشه‌بندی

❖ استفاده از الگوریتم Spatial برای خوشه‌بندی

❖ عملکرد بهتر الگوریتم K-Means در خوشه‌بندی در مقایسه با DBSCAN

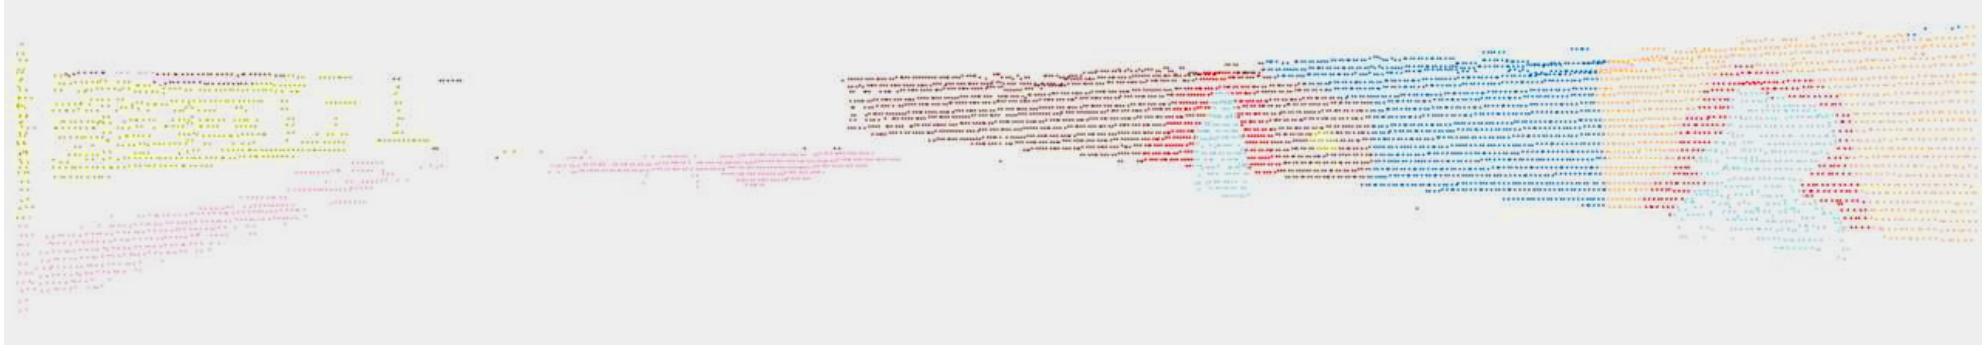
❖ عملکرد بهتر الگوریتم Spatial در خوشه‌بندی در مقایسه با دو الگوریتم

پیشین

❖ کندر بودن الگوریتم Spatial برای خوشه‌بندی

❖ انتخاب کردن الگوریتم K-Means به عنوان بهینه‌ترین روش خوشه‌بندی

خوشه‌بندی با الگوریتم‌های دیگر



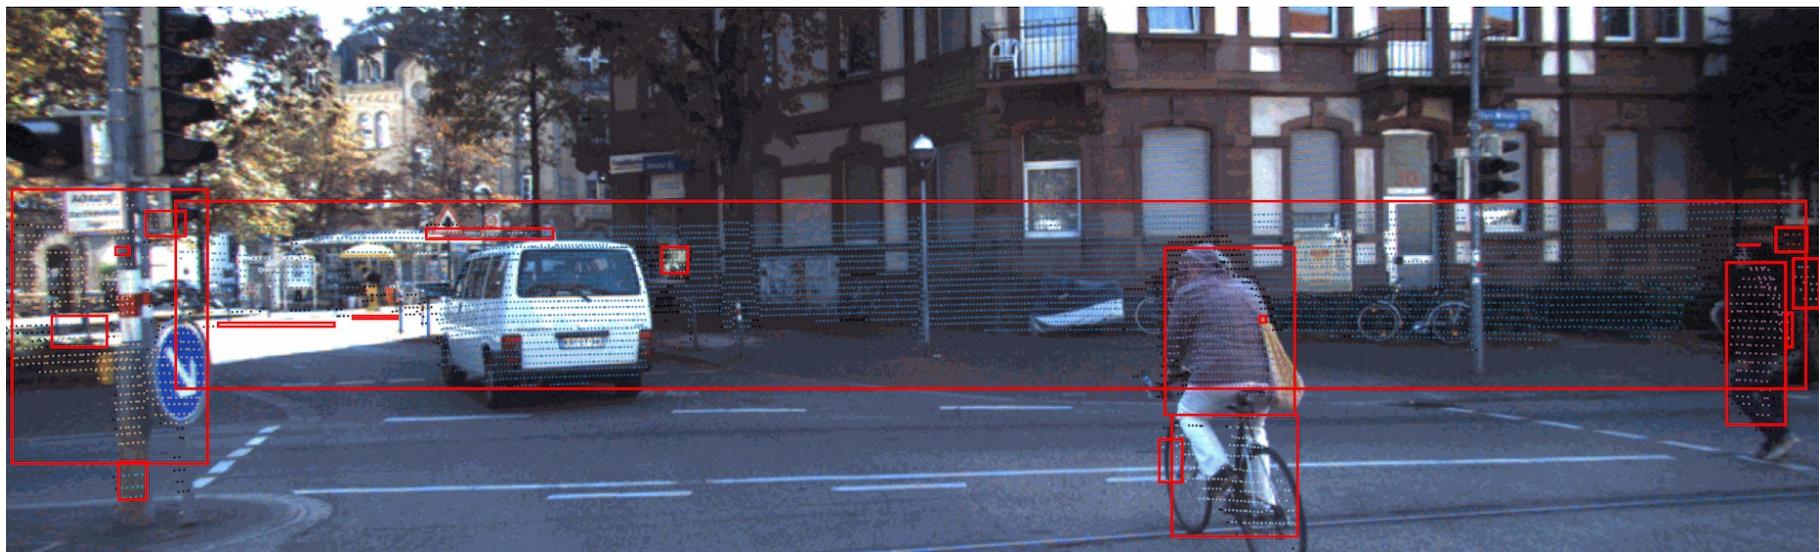
K-Means

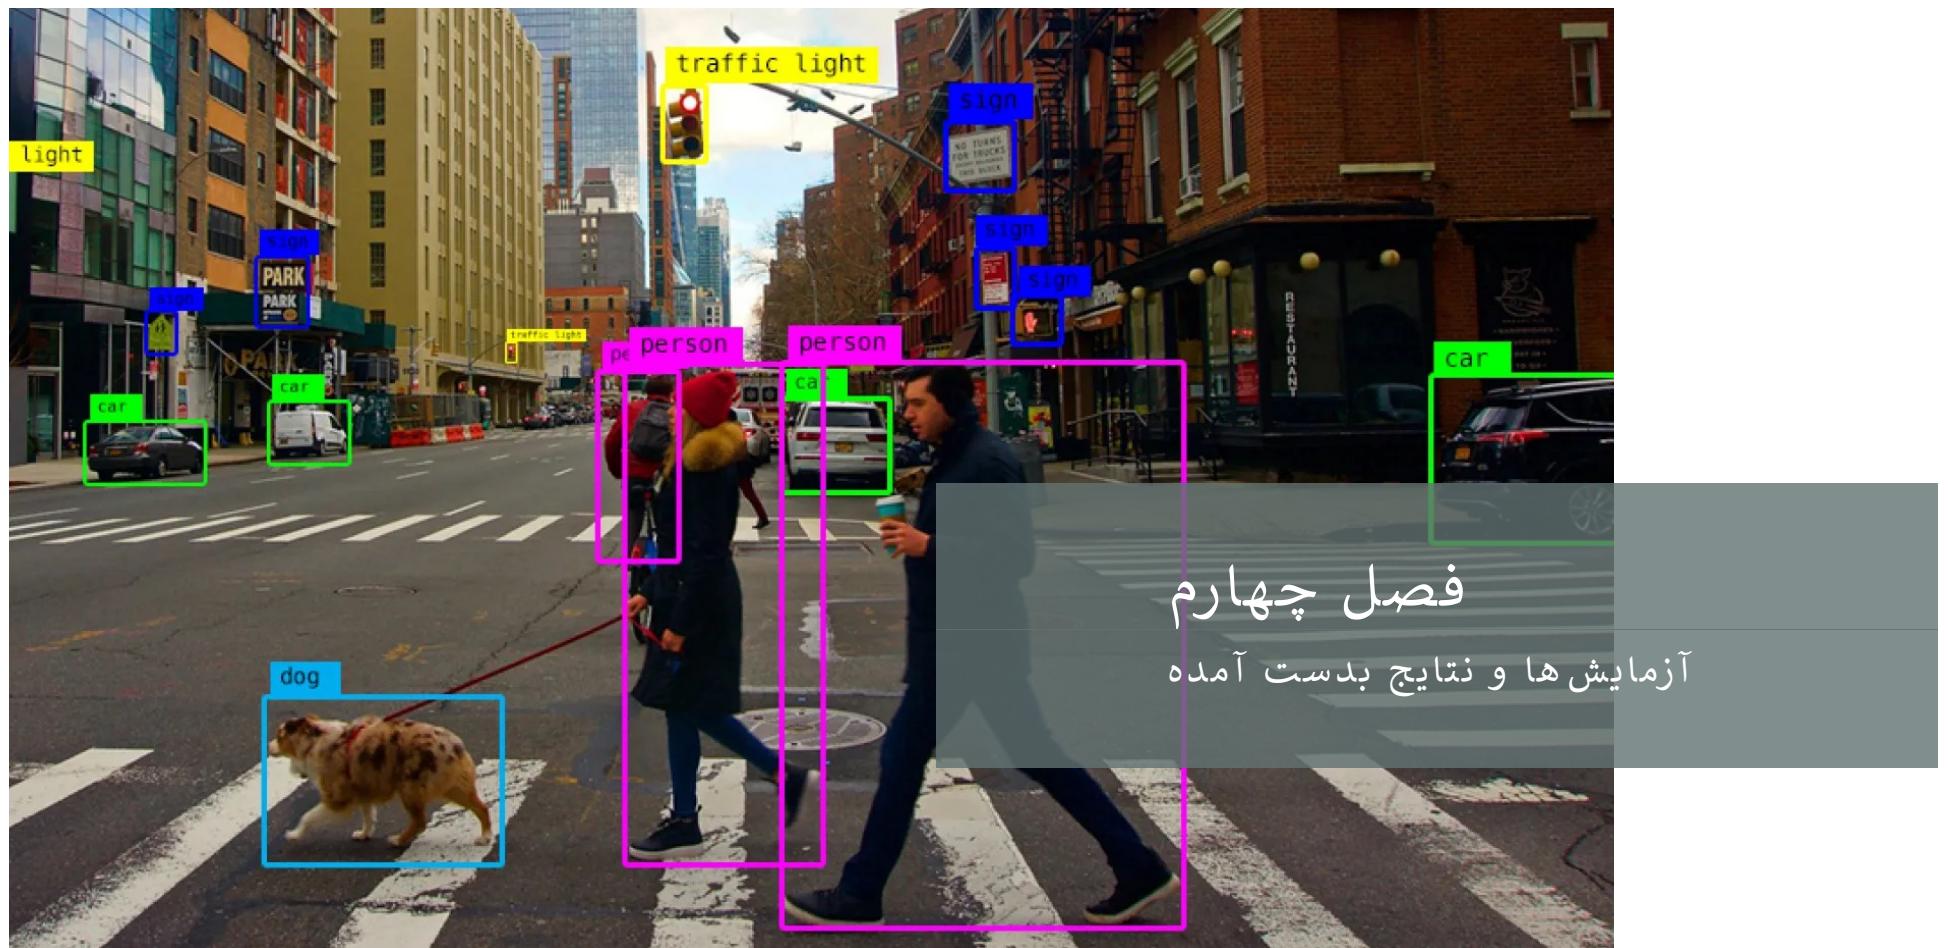


Spatial Clustering

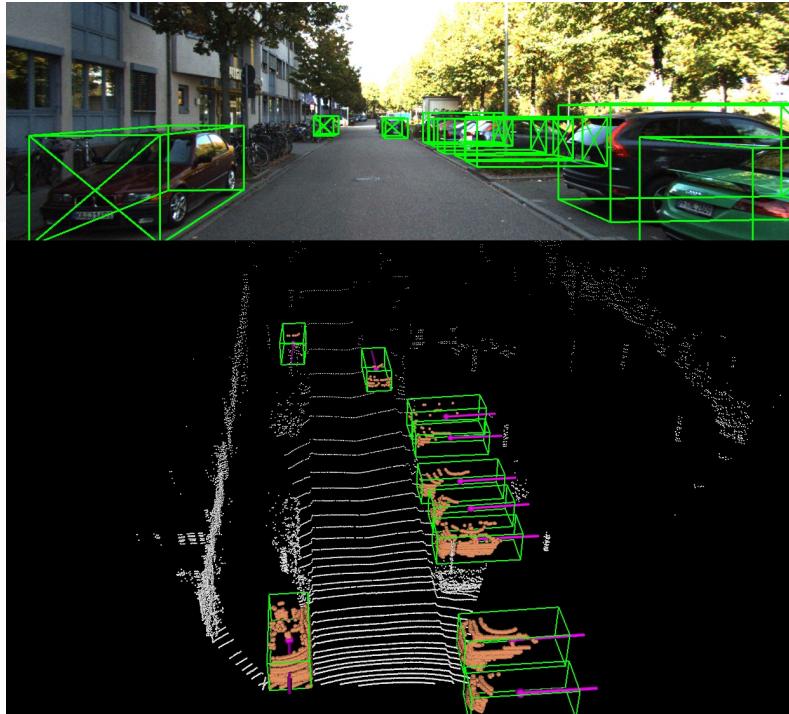
تبديل خوشه بندی به پیشنهاد ناحیه

- ❖ تعیین جعبه‌های محدودکننده برای هر خوشه
- ❖ تبدیل جعبه‌های محدودکننده به پیشنهاد ناحیه



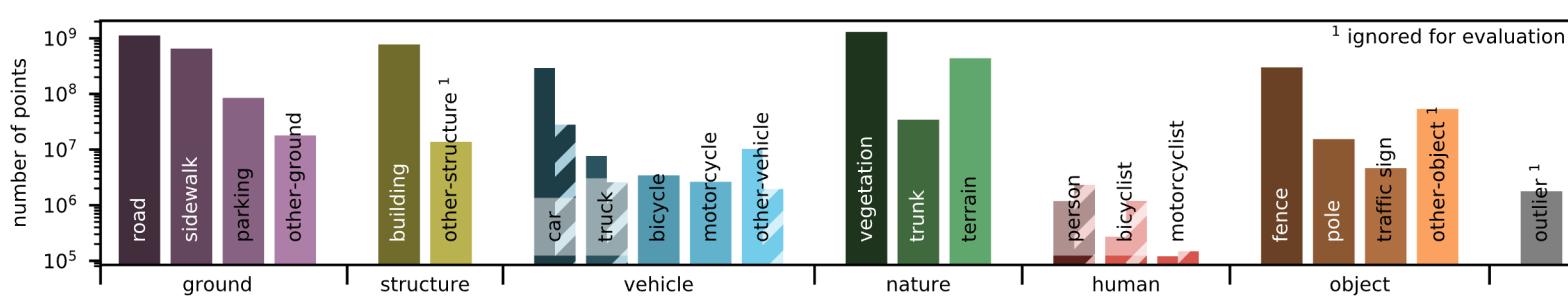


معرفی دادگان



مجموعه داده KITTI

- ❖ یکی از معتبرترین منابع کامپیوت خودران
- ❖ ۵۰۰۰ تصویر برچسب گذاری شده برای آموزش
- ❖ ۲۴۱۸ تصویر آزمایشی بدون برچسب
- ❖ شامل ۲۸ کلاس
- ❖ استفاده از تمامی ۵۰۰۰ تصویر آموزش برای ارزیابی روش پیشنهادی



معیارهای ارزیابی

معیارهای ارزیابی پیشنهاد ناحیه

تعداد مثبت واقعی، منفی واقعی، و منفی کاذب

دقت: نسبت مثبت‌های واقعی به مجموع مثبت‌های واقعی و کاذب

بازخوانی: نسبت مثبت‌های واقعی به مجموع مثبت‌های واقعی و منفی‌های کاذب

UAI: میزان همپوشانی بین جعبه‌های پیشنهادی و واقعی

زمان اجرا

معیارهای ارزیابی خوشبندی

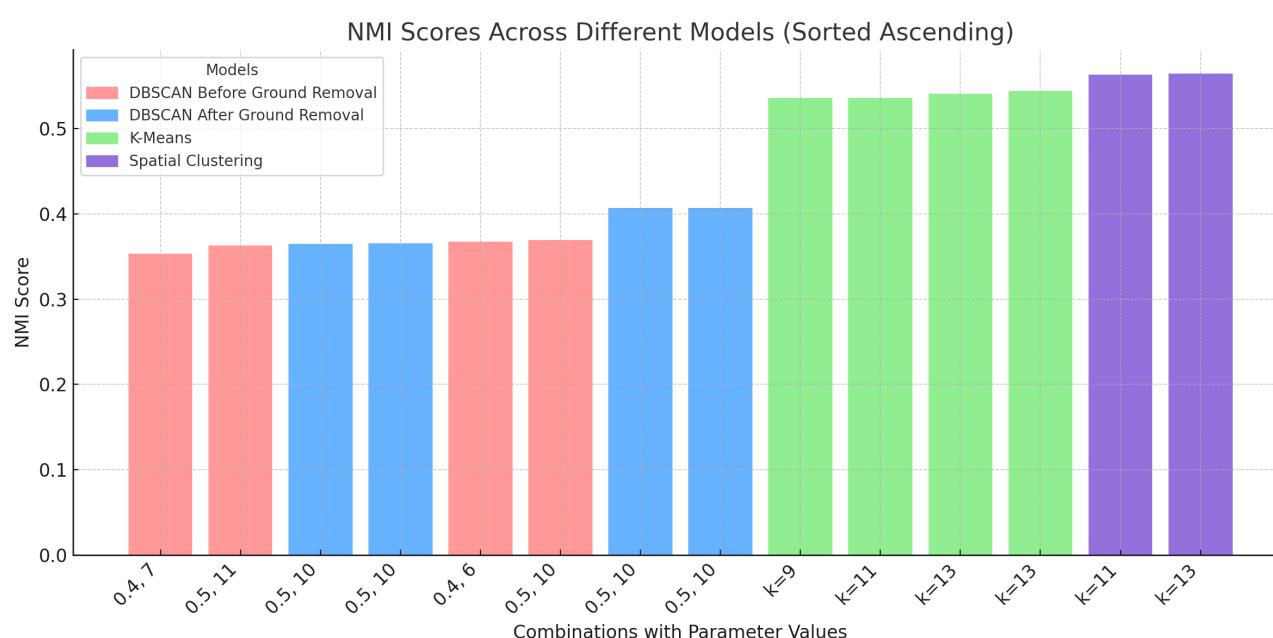
NMI: ارزیابی کیفیت خوشبندی با استفاده از مدل SAM به عنوان داده واقعی

استفاده از مدل SAM برای بدست آوردن تقسیم‌بندی معنایی

مقایسه خوشبندی انجام شده با تقسیم‌بندی معنایی مدل SAM

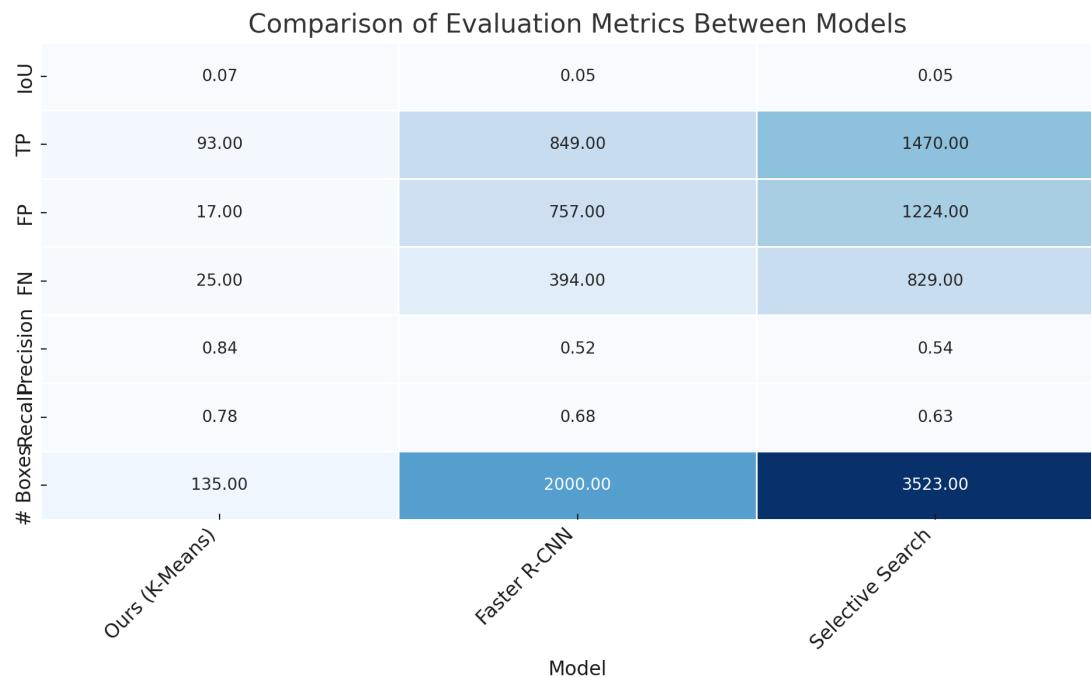


ارزیابی خوشبندی با جستجوی شبکه‌ای



- ❖ مدل Spatial Clustering بهترین عملکرد را نشان داد
- ❖ مدل Spatial Clustering پنج برابر از K-Means کند تر بود
- ❖ مدل K-Means بهترین تعادل را بین عملکرد و زمان اجرا نشان داد
- ❖ مدل DBSCAN ضعیف ترین عملکرد را بین دیگر مدل‌ها نشان داد

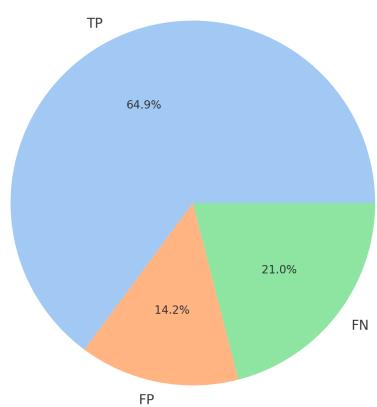
مقایسه روش پیشنهادی با مدل‌های پایه - میانگین



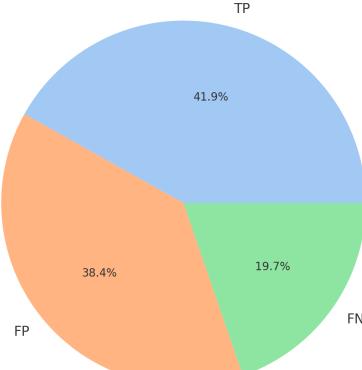
- ❖ روش پیشنهادی به صورت میانگین تعداد کمتری پیشنهاد ناحیه انجام داده
- ❖ روش پیشنهادی به صورت میانگین ۱۵۰ بالاتری داشته
- ❖ روش پیشنهادی به صورت میانگین دقیق بالاتری داشته
- ❖ روش پیشنهادی به صورت میانگین بازخوانی بالاتری داشته

مقایسه روش پیشنهادی با مدل‌های پایه - تجمعی

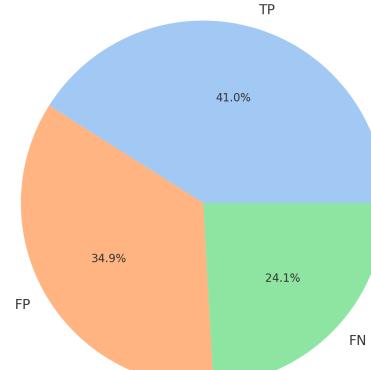
Ours (K-Means) Proposals Breakdown



Faster R-CNN Proposals Breakdown



Selective Search Proposals Breakdown



❖ به طور کلی ۱۴۸۱۱ شیء در
دادگان وجود دارد

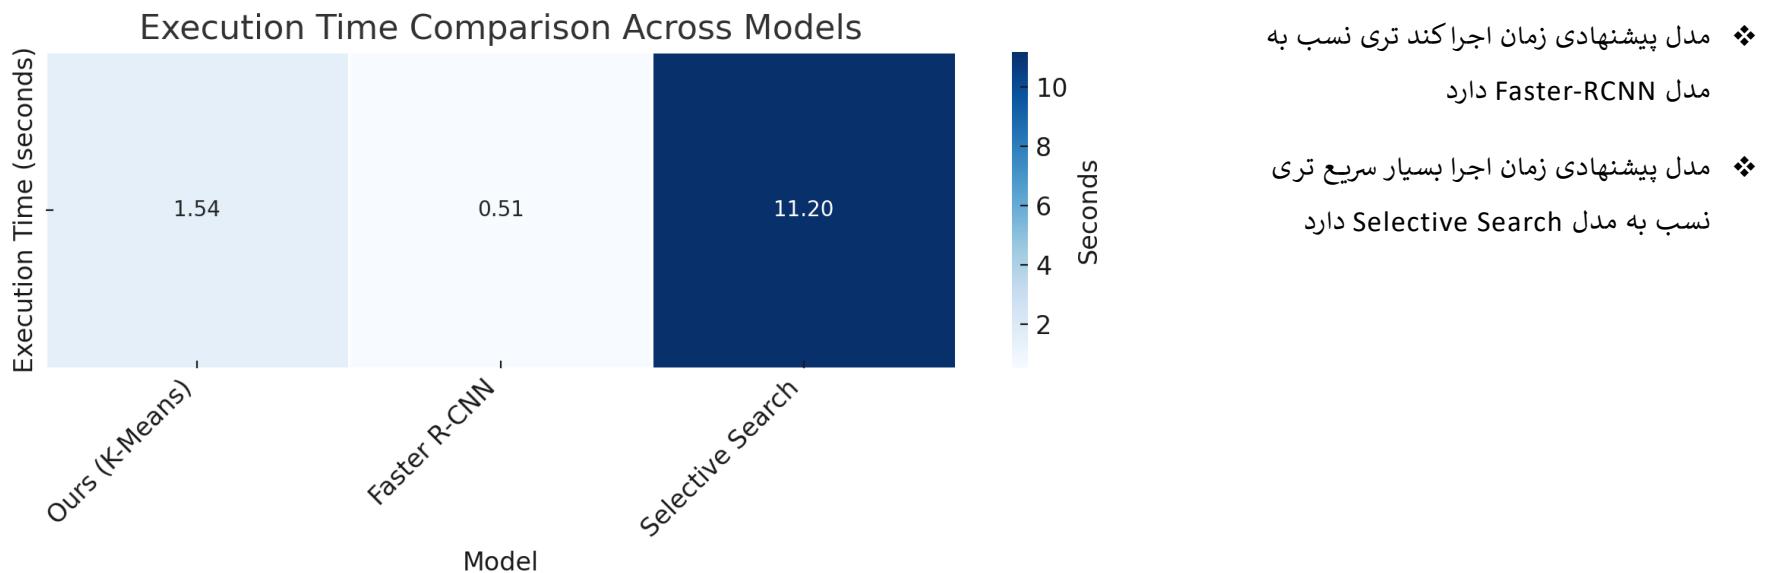
❖ روش پیشنهادی نسبت مثبت
واقعی مشابه‌ای به مدل‌های پایه
دارد.

❖ روش پیشنهادی نسبت منفی کاذب
و منفی واقعی کمتری به مدل‌های
پایه دارد

❖ مدل پیشنهادی تعداد پیشنهاد
ناحیه کمتری در مقایسه با
مدل‌های پایه دارد

Model	Total Proposals	TP	FP	FN	FP + FN
Ours (K-Means)	685137	10058	2197	3253	5450
Faster R-CNN	10000000	10071	9227	4740	13967
Selective Search	17612358	9332	7932	5479	13411

مقایسه روش پیشنهادی با مدل‌های پایه - زمان اجرا



جمع بندی

- ❖ تعریف مسئله پیشنهاد ناحیه و چالش‌های آن
- ❖ مروری بر مسائل مرتبط و بررسی نقاط قوت و ضعف هرکدام
- ❖ ارائه مدل‌های پیشنهادی جهت ارزیابی کارایی ادغام بدون نظارت در پیشنهاد ناحیه
- ❖ مقایسه مدل‌های ارائه شده با مدل‌های پایه



آموزش مدل تشخیص شیء با روش پیشنهادی

❖ نظری آموزش مدل Faster-RCNN با پیشنهاد ناحیه پیشنهاد
شده

پیشنهادها

استفاده از تکمیل عمق برای بهبود کیفیت پیشنهادات ناحیه
Sparse2Dense و Depth Completion ❖

مراجع

- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 779–788.
- Ren, S., He, K., Girshick, R., & Sun, J. (2016). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149.
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 580–587.
- Meschtscherjakov, A., Tscheligi, M., Pfleging, B., Borojeni, S. S., Ju, W., Palanque, P., ... & Kun, A. L. (2018). Interacting with autonomous vehicles: Learning from other domains. *Extended Abstracts of the 2018 CHI Conference on Human Factors in Computing Systems (CHI EA '18)*, 1–8.
- Pomerleau, D. (1989). Alvinn: An autonomous land vehicle in a neural network. *Proceedings of Neural Information Processing Systems*, 305–313.
- Thrun, S., Montemerlo, M., Dahlkamp, H., Stavens, D., Aron, A., Diebel, J., ... & Mahoney, P. (2006). Stanley: The robot that won the DARPA grand challenge. *Journal of Field Robotics*, 23(9), 661–692.
- Levinson, J., Askeland, J., Becker, J., Dolson, J., Held, D., Kammel, S., ... & Thrun, S. (2011). Towards fully autonomous driving: Systems and algorithms. *2011 IEEE Intelligent Vehicles Symposium*, 163–168.
- Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., & Pietikäinen, M. (2020). Deep learning for generic object detection: A survey. *International Journal of Computer Vision*, 128(2), 261–318.

مراجع

- Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1, I-511–I-518.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single shot multibox detector. In B. Leibe, J. Matas, N. Sebe, & M. Welling (Eds.), *Computer Vision – ECCV 2016* (pp. 21–37). Cham, Switzerland: Springer International Publishing.
- Uijlings, J. R. R., van de Sande, K. E. A., Gevers, T., & Smeulders, A. W. M. (2013). Selective search for object recognition. *International Journal of Computer Vision*, 104(2), 154–171.
- Zitnick, C. L., & Dollár, P. (2014). Edge boxes: Locating object proposals from edges. In D. Fleet, T. Pajdla, B. Schiele, & T. Tuytelaars (Eds.), *Computer Vision – ECCV 2014* (pp. 391–405). Cham, Switzerland: Springer International Publishing.
- Girshick, R. (2015). Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision*.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. In I. Guyon, U. von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 30).
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., & Zagoruyko, S. (2020). End-to-end object detection with transformers. In A. Vedaldi, H. Bischof, T. Brox, & J.-M. Frahm (Eds.), *Computer Vision – ECCV 2020* (pp. 213–229). Cham, Switzerland: Springer International Publishing.

مراجع

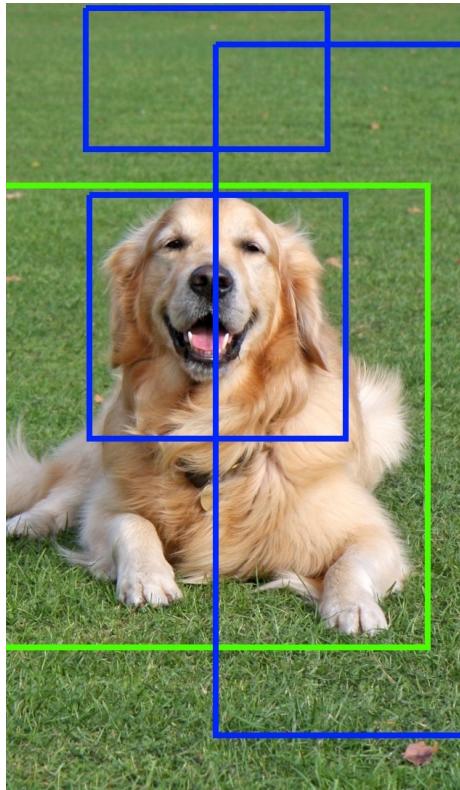
- Liu, S., Li, F., Zhang, H., Yang, X., Qi, X., Su, H., & Zhang, L. (2022). DAB-DETR: Dynamic anchor boxes are better queries for DETR. *International Conference on Learning Representations*.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770–778).
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *Clinical Orthopaedics and Related Research*, abs/1409.1556.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Eds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (pp. 234–241). Cham, Switzerland: Springer International Publishing.
- Chen, L.-C., Papandreou, G., Schroff, F., & Adam, H. (2017). Rethinking atrous convolution for semantic image segmentation. *arXiv preprint arXiv:1706.05587*.
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In V. Ferrari, M. Hebert, C. Sminchisescu, & Y. W. M. Weiss (Eds.), *Computer Vision – ECCV 2018* (pp. 833–851). Cham, Switzerland: Springer International Publishing.
- Tian, H., Chen, Y., Dai, J., Zhang, Z., & Zhu, X. (2021). Unsupervised object detection with lidar clues. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 5958–5968.

مراجع

- Zhang, L., Yang, A. J. J., Xiong, Y., Casas, S., Yang, B., Ren, M., & Urtasun, R. (2023). Towards unsupervised object detection from lidar point clouds. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 9317–9328). Vancouver, Canada: IEEE.
- Bai, X., Hu, Z., Zhu, X., Huang, Q., Chen, Y., Fu, H., & Tai, C.-L. (2022). Transfusion: Robust lidar-camera fusion for 3D object detection with transformers. In *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 1080–1089).
- Li, Y., Yu, A. W., Meng, T., Caine, B., Ngiam, J., Peng, D., ... & Tan, M. (2022). Deepfusion: Lidar-camera deep fusion for multi-modal 3D object detection. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 17161–17170). New Orleans, USA: IEEE.
- Liu, L., He, J., Ren, K., Xiao, Z., & Hou, Y. (2022). A lidar–camera fusion 3D object detection algorithm. *Information*, 13(4).
- Geiger, A., Lenz, P., Stiller, C., & Urtasun, R. (2013). Vision meets robotics: The KITTI dataset. *International Journal of Robotics Research*.
- Fischler, M. A., & Bolles, R. C. (1981). Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 24(6), 381–395.
- Bergstra, J., Bardenet, R., Bengio, Y., & Kégl, B. (2011). Algorithms for hyper-parameter optimization. In J. Shawe-Taylor, R. Zemel, P. Bartlett, F. Pereira, & K. Q. Weinberger (Eds.), *Advances in Neural Information Processing Systems*(Vol. 24).
- Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., ... & Girshick, R. B. (2023). Segment anything. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 3992–4003.

مراجع

- Strehl, A., & Ghosh, J. (2002). Cluster ensembles – a knowledge reuse framework for combining multiple partitions. *Journal of Machine Learning Research*, 3, 583–617.
- Ma, F., Cavalheiro, G. V., & Karaman, S. (2019). Self-supervised sparse-to-dense: Self-supervised depth completion from lidar and monocular camera. *Proceedings of the International Conference on Robotics and Automation*, 3288–3295.
- Uhrig, J., Schneider, N., Schneider, L., Franke, U., Brox, T., & Geiger, A. (2017). Sparsity invariant CNNs. In *Proceedings of the International Conference on 3D Vision* (pp. 11–20).
- Comaniciu, D., & Meer, P. (2002). Mean shift: A robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(5), 603–619.
- Frey, B. J., & Dueck, D. (2007). Clustering by passing messages between data points. *Science*, 315(5814), 972–976.
- Lin, T.-Y., Maire, M., Belongie, S. J., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. In *Proceedings of the European Conference on Computer Vision*.



با تشکر از توجه شما

Email: bardia.ardakanian@gmail.com

