



时空轨迹数据的自监督学习方法研究

博士学位论文答辩

答辩人：林彦

指导教师：万怀宇

2024年3月11日

01

研究背景和意义

02

研究内容和主要贡献

(1)

访问时间感知的轨迹自监督学习方法

(2)

上下文感知的轨迹自监督学习方法

(3)

行程信息建模的轨迹自监督学习方法

(4)

多视图融合的轨迹自监督学习方法

(5)

面向通用模型的轨迹自监督学习方法

03

研究总结

01

研究背景和意义

02

研究内容和主要贡献

(1)

访问时间感知的轨迹自监督学习方法

(2)

上下文感知的轨迹自监督学习方法

(3)

行程信息建模的轨迹自监督学习方法

(4)

多视图融合的轨迹自监督学习方法

(5)

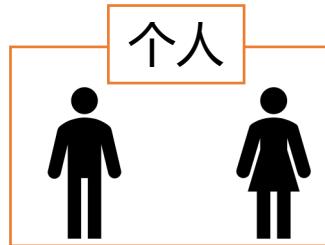
面向通用模型的轨迹自监督学习方法

03

研究总结

时空轨迹数据简介

- 由 (位置, 时间) 对组成的序列, 记录了车辆或个人的移动和出行行为

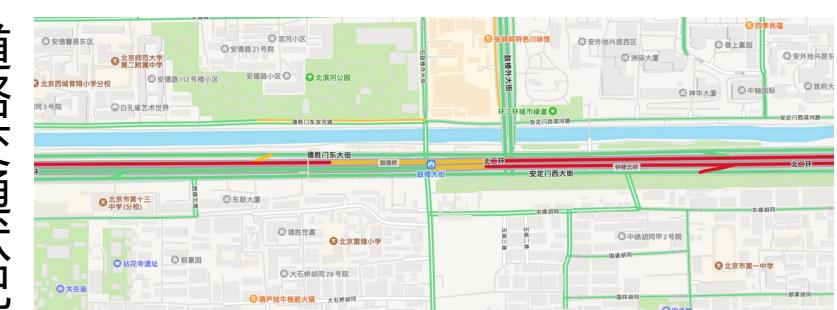


移动和出行



时空轨迹

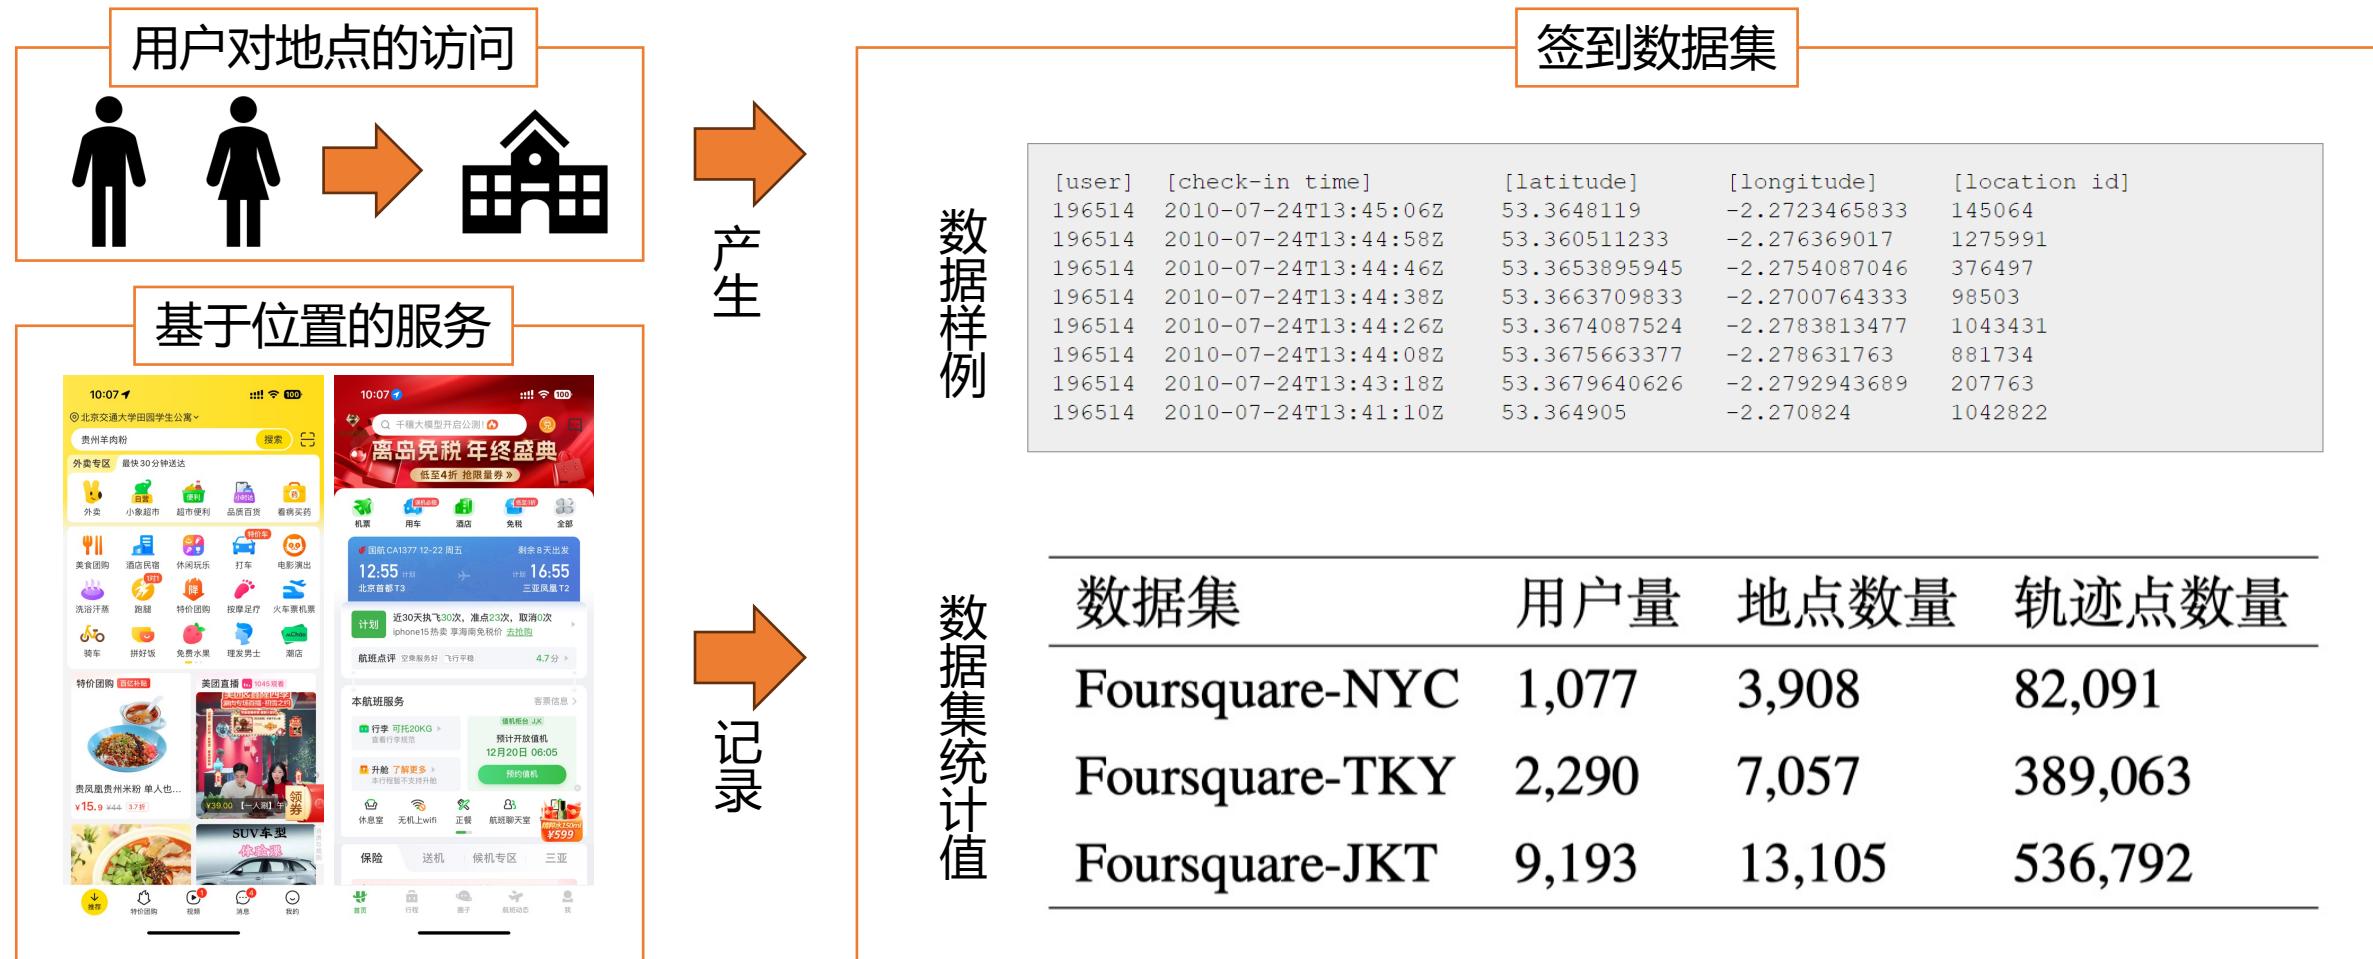
丰富的时空信息
地理位置的功能
车辆路径偏好
道路交通状况



时空轨迹数据简介

➤ 用户签到(Check-in)轨迹数据

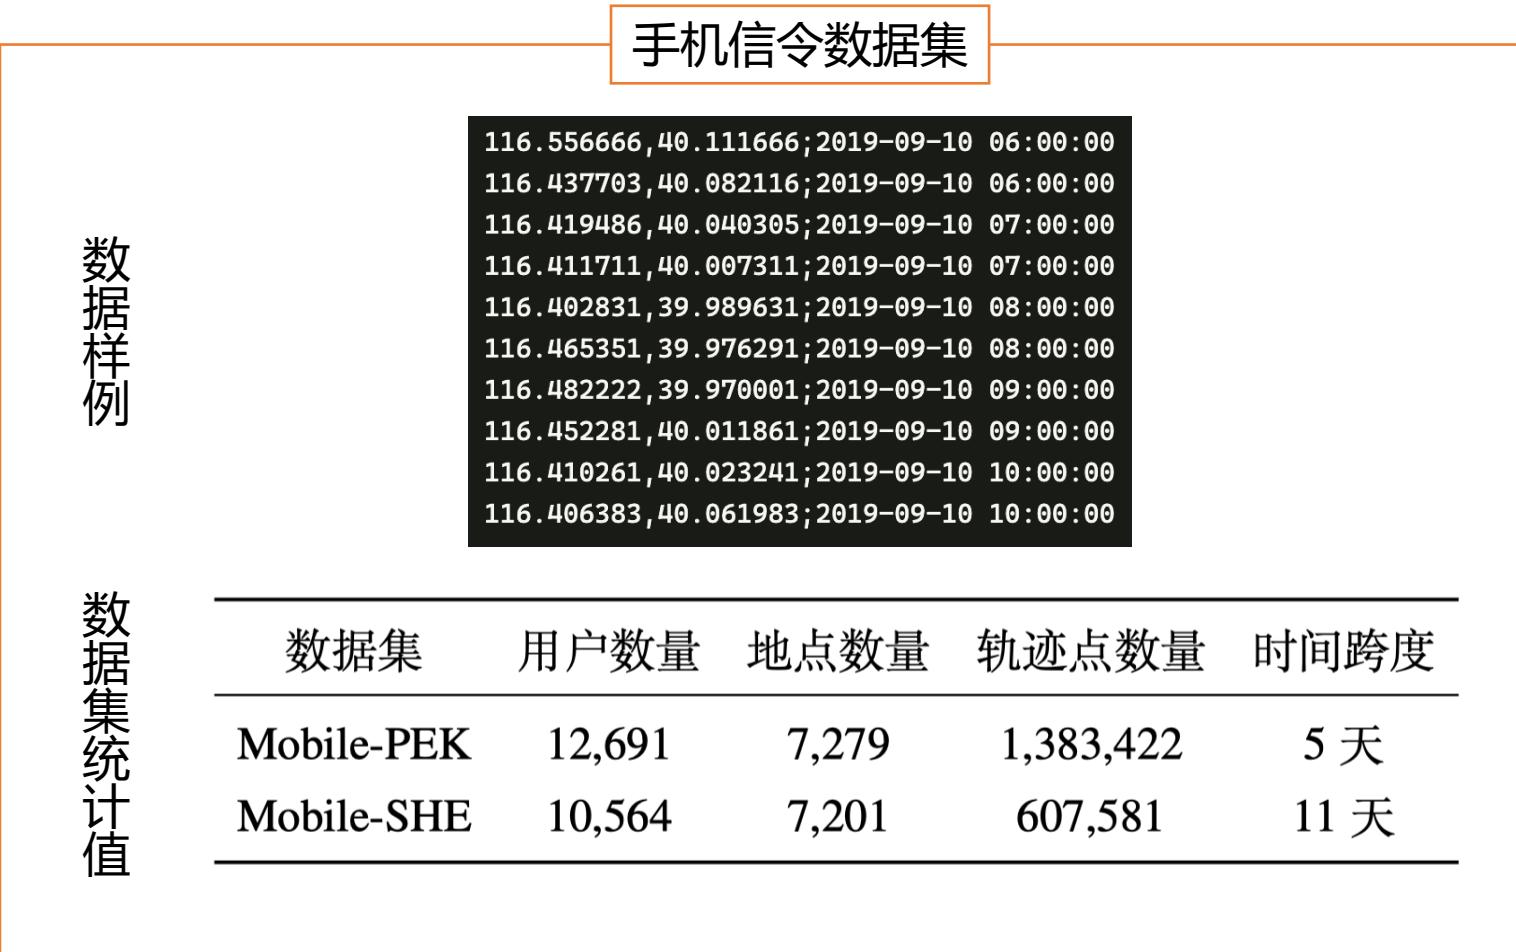
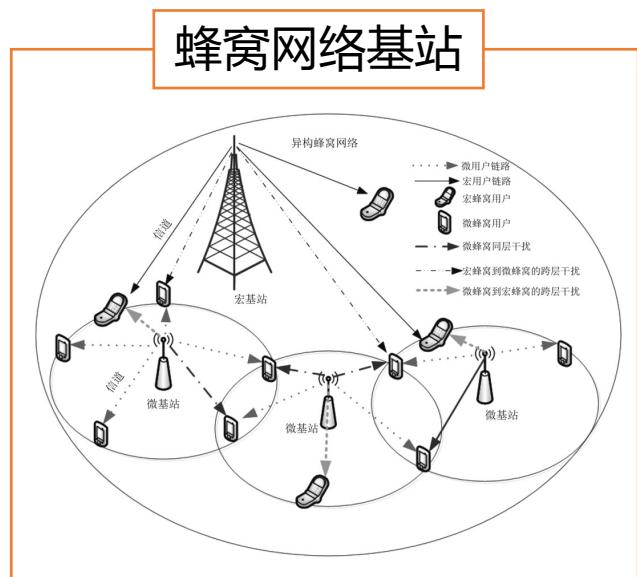
- 由用户对地点的访问记录构成



时空轨迹数据简介

➤ 手机信令轨迹数据

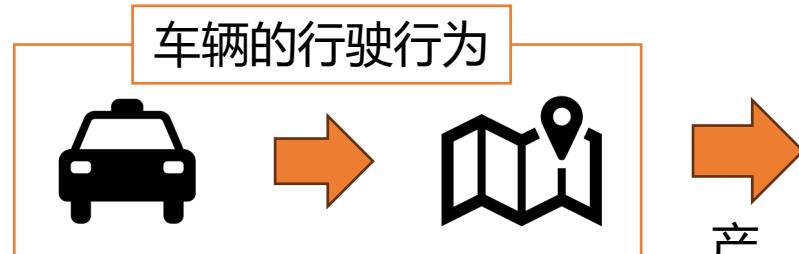
- 由手机在蜂窝网络基站间的切换记录构成



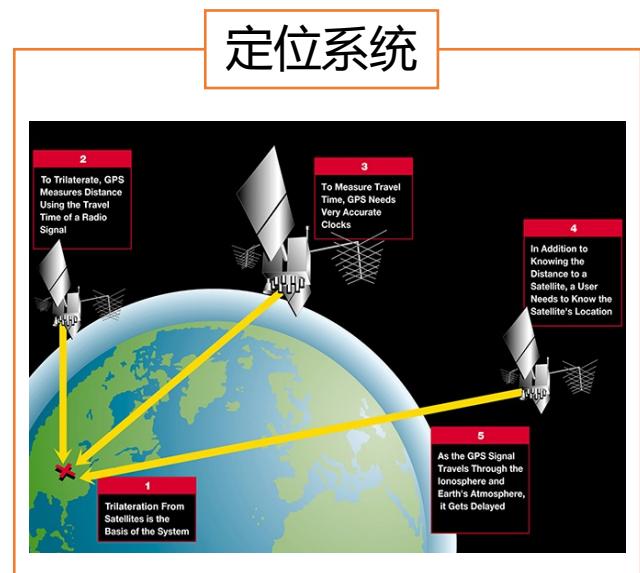
时空轨迹数据简介

➤ 车辆定位轨迹数据

- 由车载定位系统的记录点构成



产生



记录

车辆定位数据集

数据样例

	signal_id	day_num	vehicle_id	trip_id	time_stamp	latitude	longitude	speed
1	1	190.511826148	10	2400	0	42.2782011111	-83.7484502778	33.7599983215
2	2	190.511826148	10	2400	100	42.2782011111	-83.7484502778	33.7599983215
3	3	190.511826148	10	2400	1000	42.2782011111	-83.7484502778	31.5599994659
4	4	190.511826148	10	2400	1100	42.2782011111	-83.7484502778	31.5599994659
5	5	190.511826148	10	2400	1700	42.2782011111	-83.7484502778	31.5599994659
6	6	190.511826148	10	2400	2100	42.2782011111	-83.7484502778	29.4099998474
7	7	190.511826148	10	2400	2200	42.2782011111	-83.7484502778	29.4099998474
8	8	190.511826148	10	2400	2500	42.2784791667	-83.7483075	29.4099998474

数据集统计值

数据集	轨迹数量	路段数量	轨迹点数量
成都	298,995	3,791	7,025,468
西安	376,407	3,558	10,198,837
哈尔滨	614,830	3,704	12,692,468
波尔图	55,120	2,225	1,482,751

数据定义介绍

➤ 路网

- 支撑交通系统的核心要素，地理信息系统中的基础对象



路网构成

有向图 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$

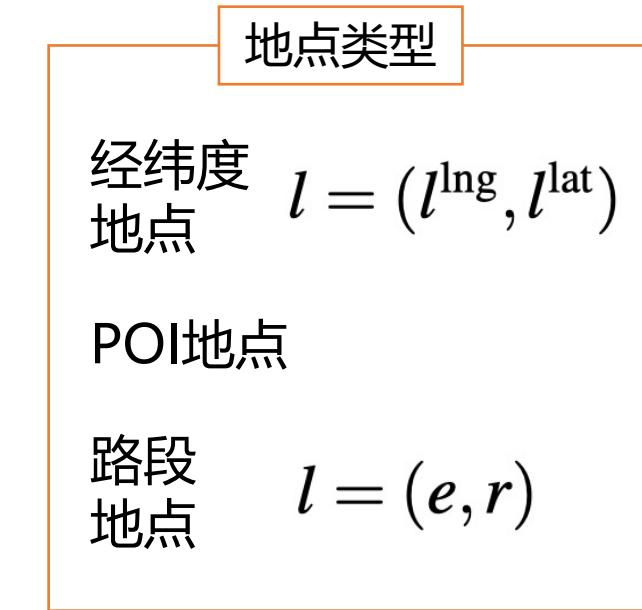
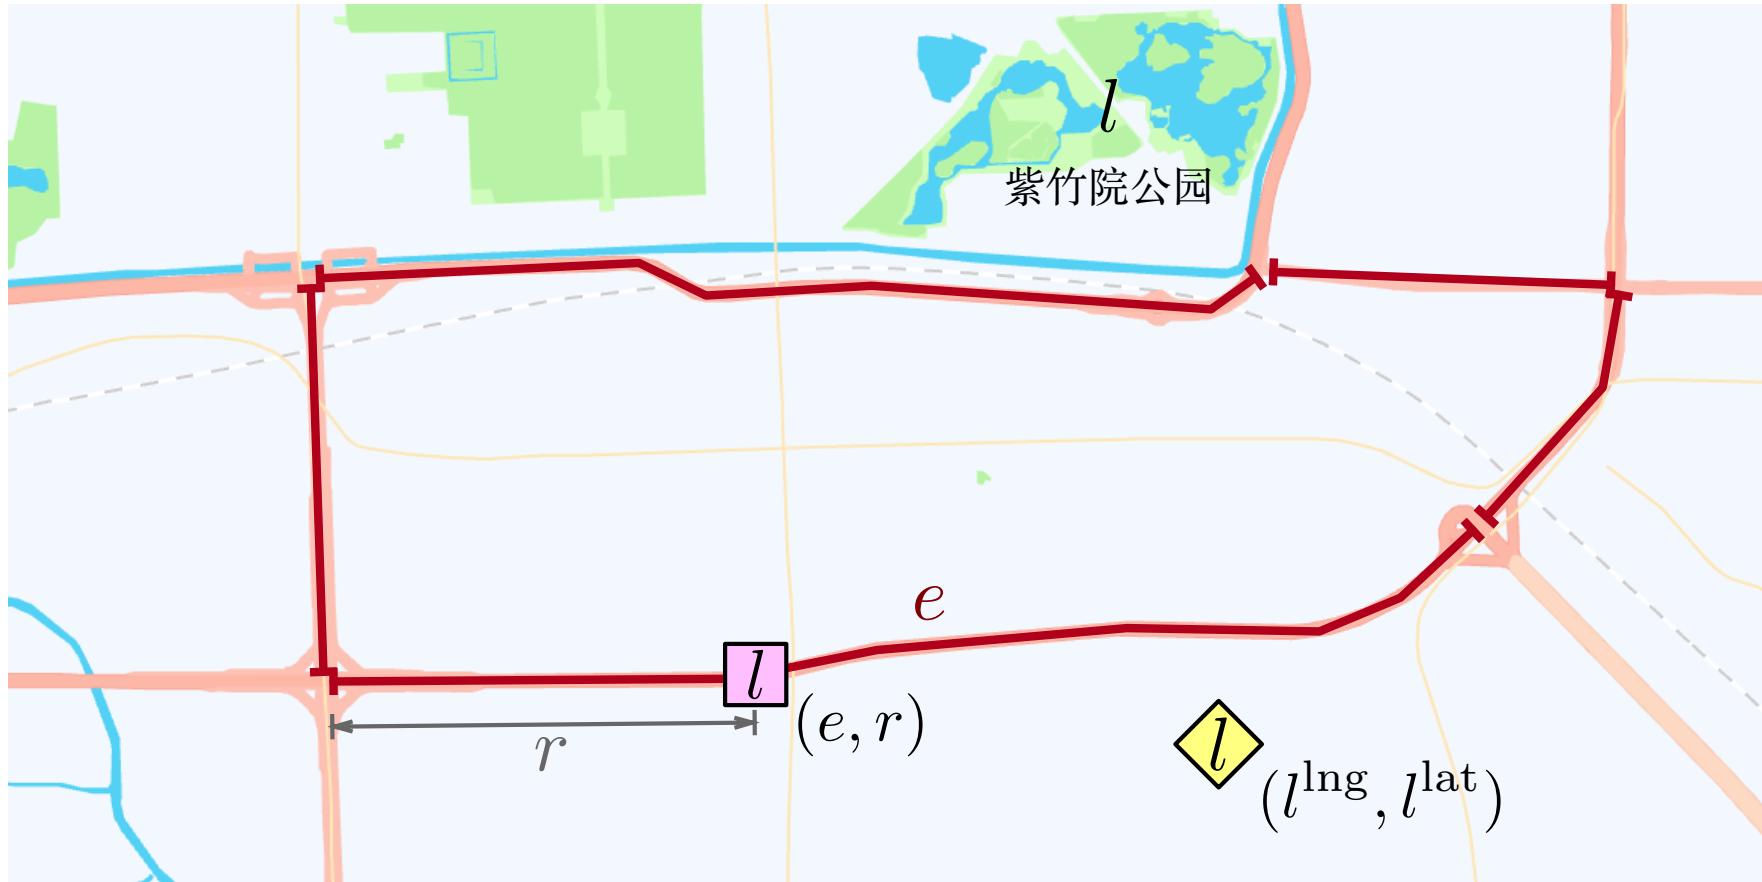
节点 $v_i \in \mathcal{V}$

路段 $e_i \in \mathcal{E}$

数据定义介绍

➤ 地点

- 地理信息系统中的静态组成部分，具有特定属性和含义的地点



数据定义介绍

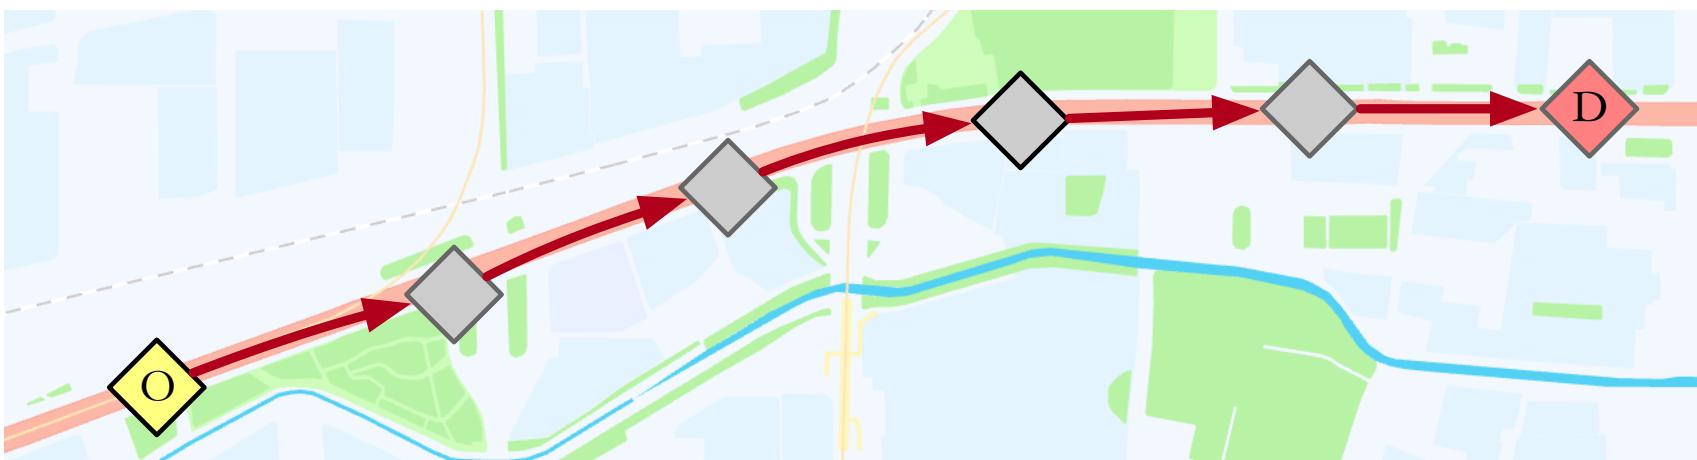
➤ 时空轨迹

- 带时间戳的地点构成的序列



➤ 起终点

- 轨迹的起点和终点



轨迹

$$\mathcal{T} = \langle (l_1, t_1), (l_2, t_2), \dots, (l_{|\mathcal{T}|}, t_{|\mathcal{T}|}) \rangle$$

起终点

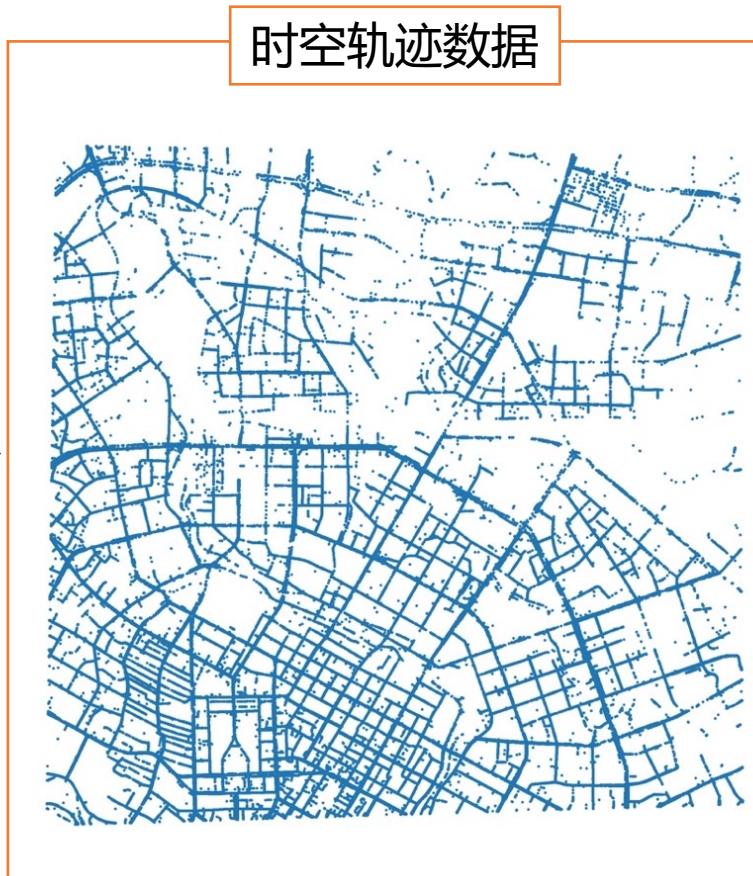
$$(l_o, l_d)$$

时空轨迹数据挖掘

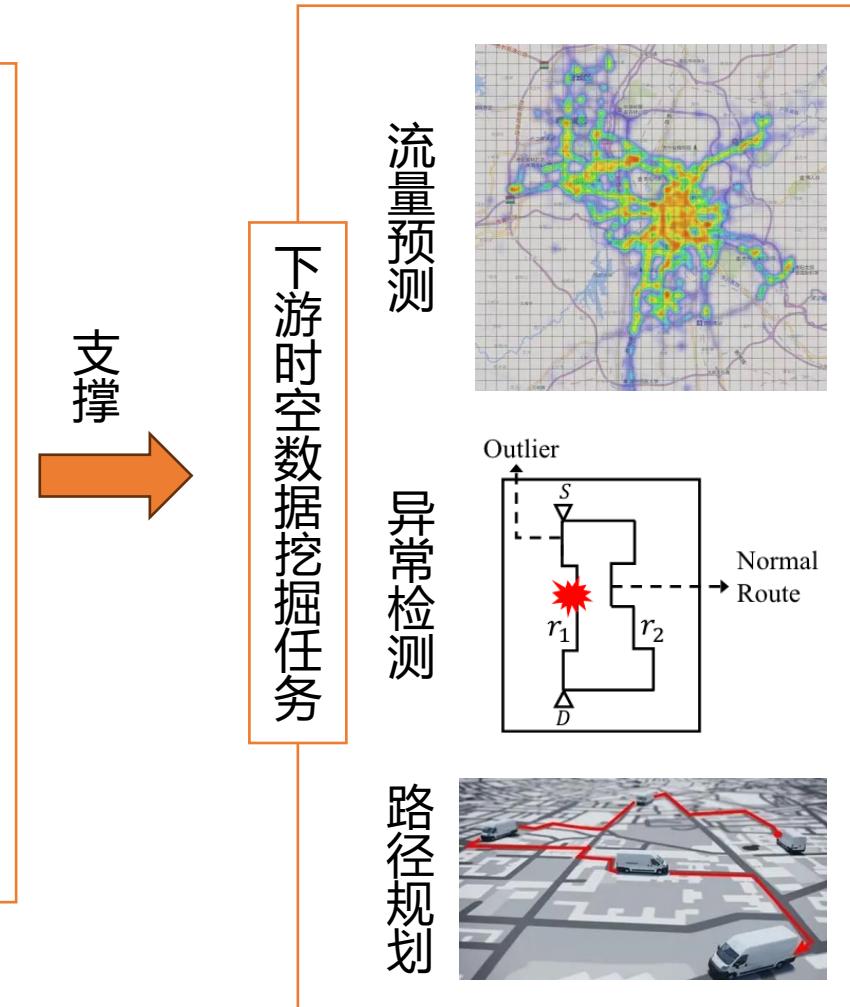
➤ 数据可用性强



产生



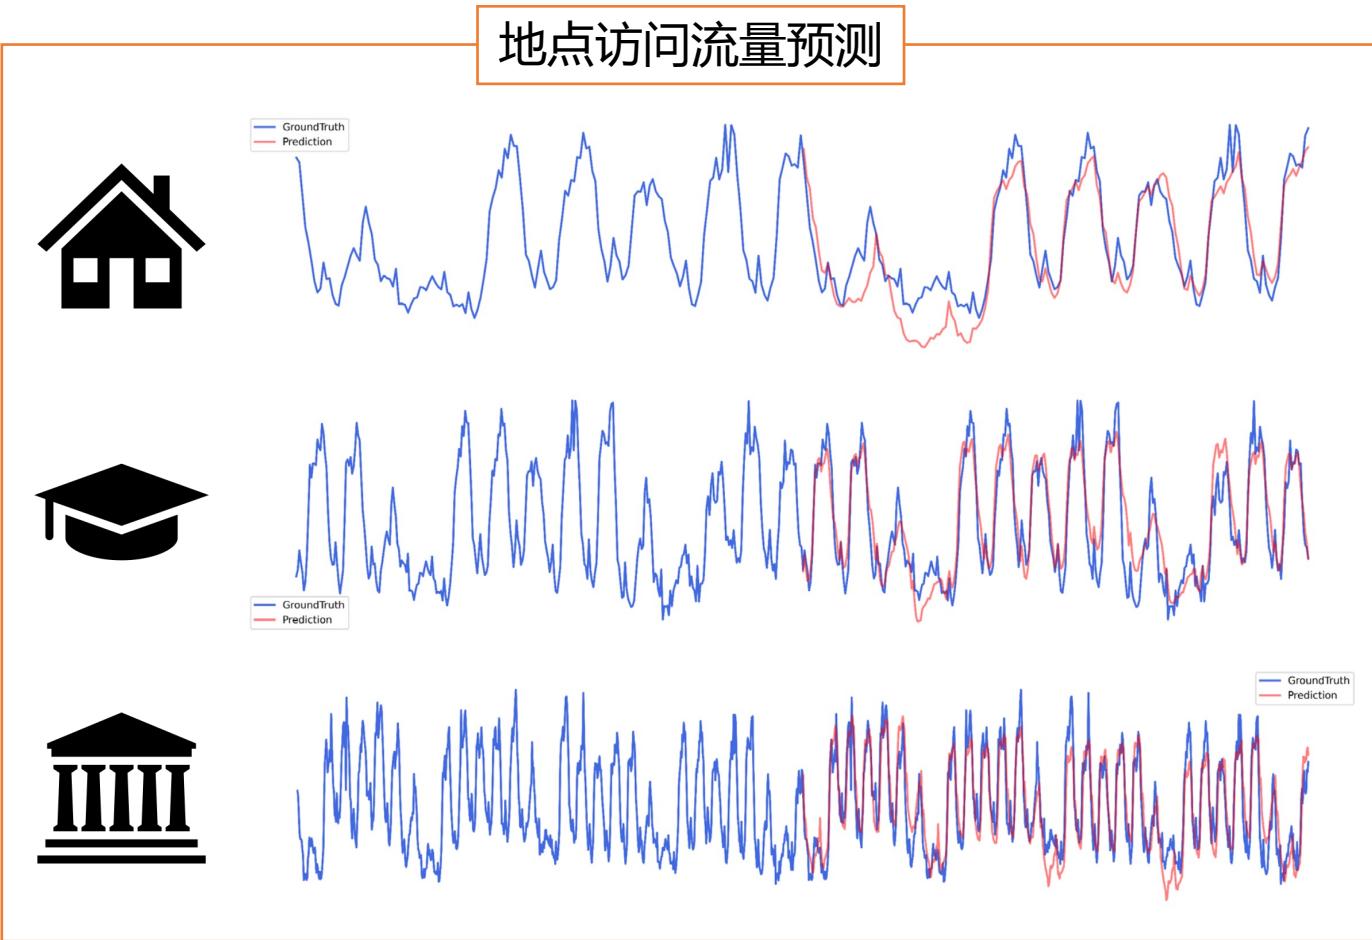
➤ 关键性地位



轨迹数据挖掘的下游任务

➤ 面向地点的任务

- 重点关注地点的功能特征



轨迹数据挖掘的下游任务

➤ 面向起终点的任务

- 重点关注起终点对应的出行目的与行程路线

起终点行程生成



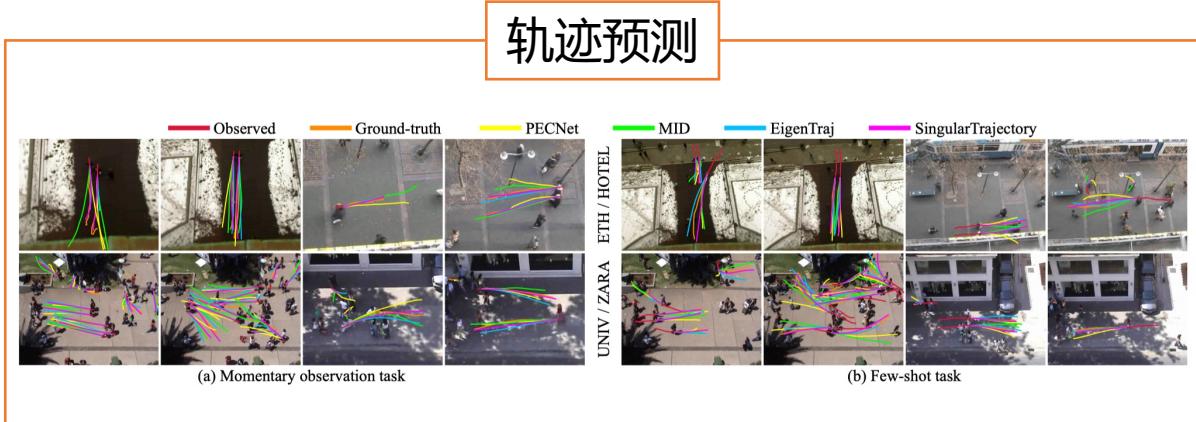
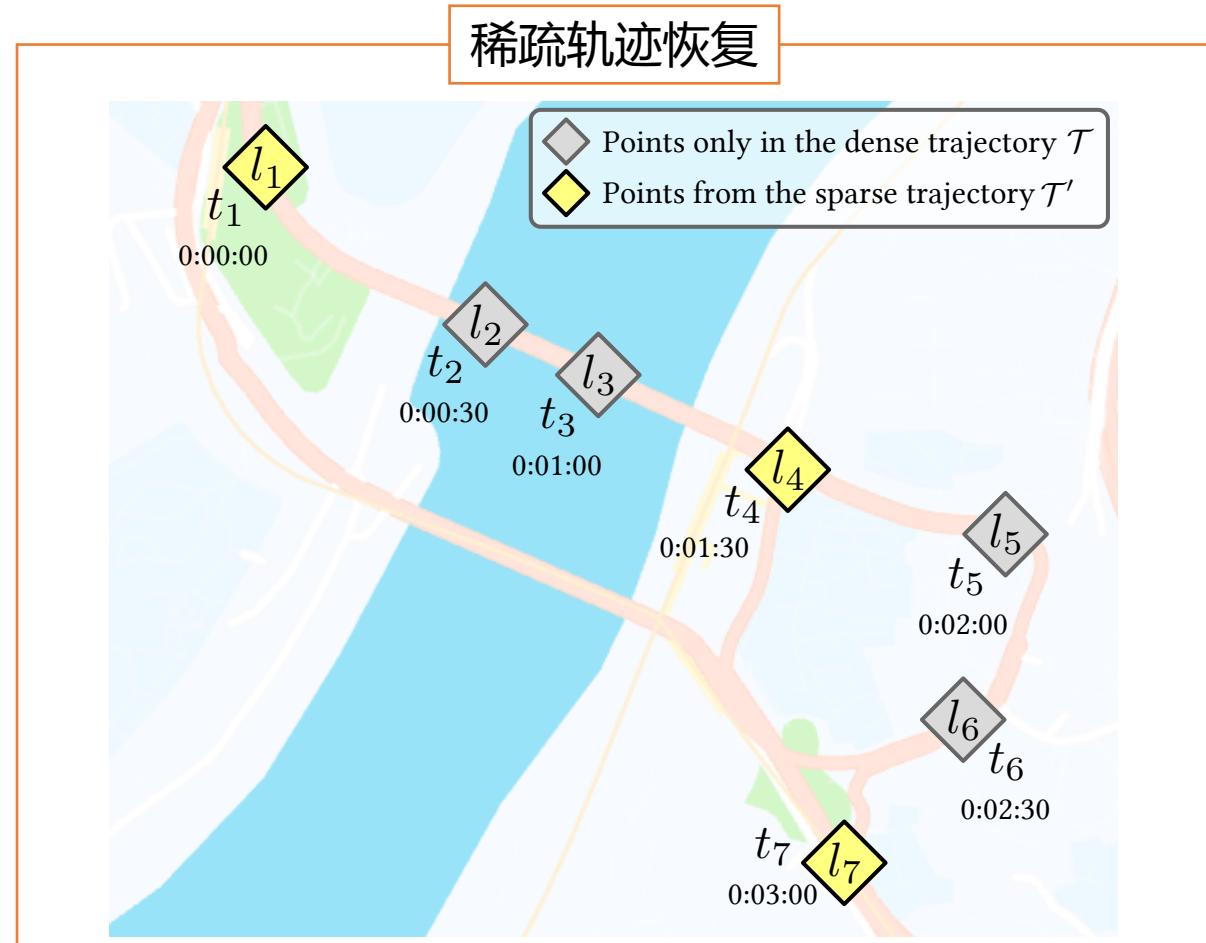
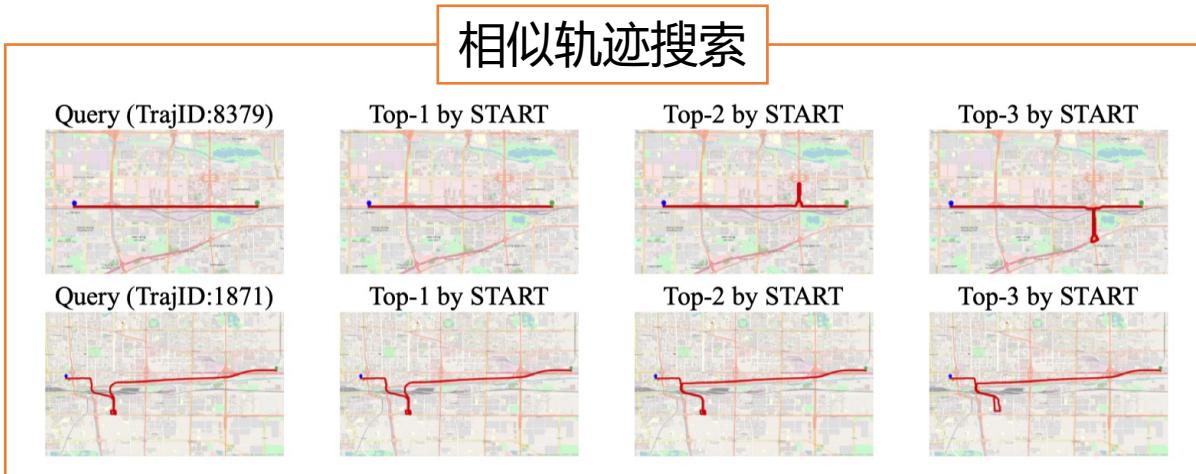
起终点旅行时间估计



轨迹数据挖掘的下游任务

➤ 面向轨迹序列的任务

- 重点关注轨迹的连续时空特征、出行目的、行程路线等



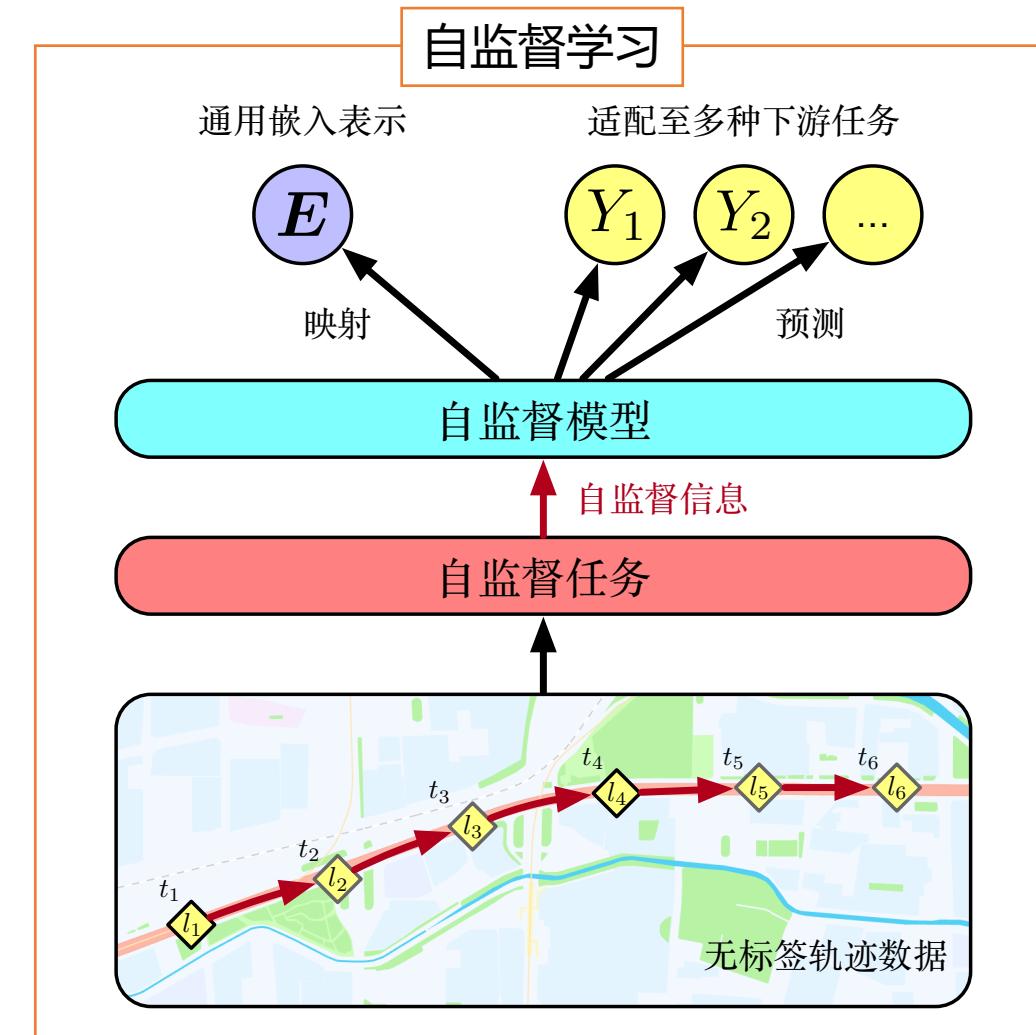
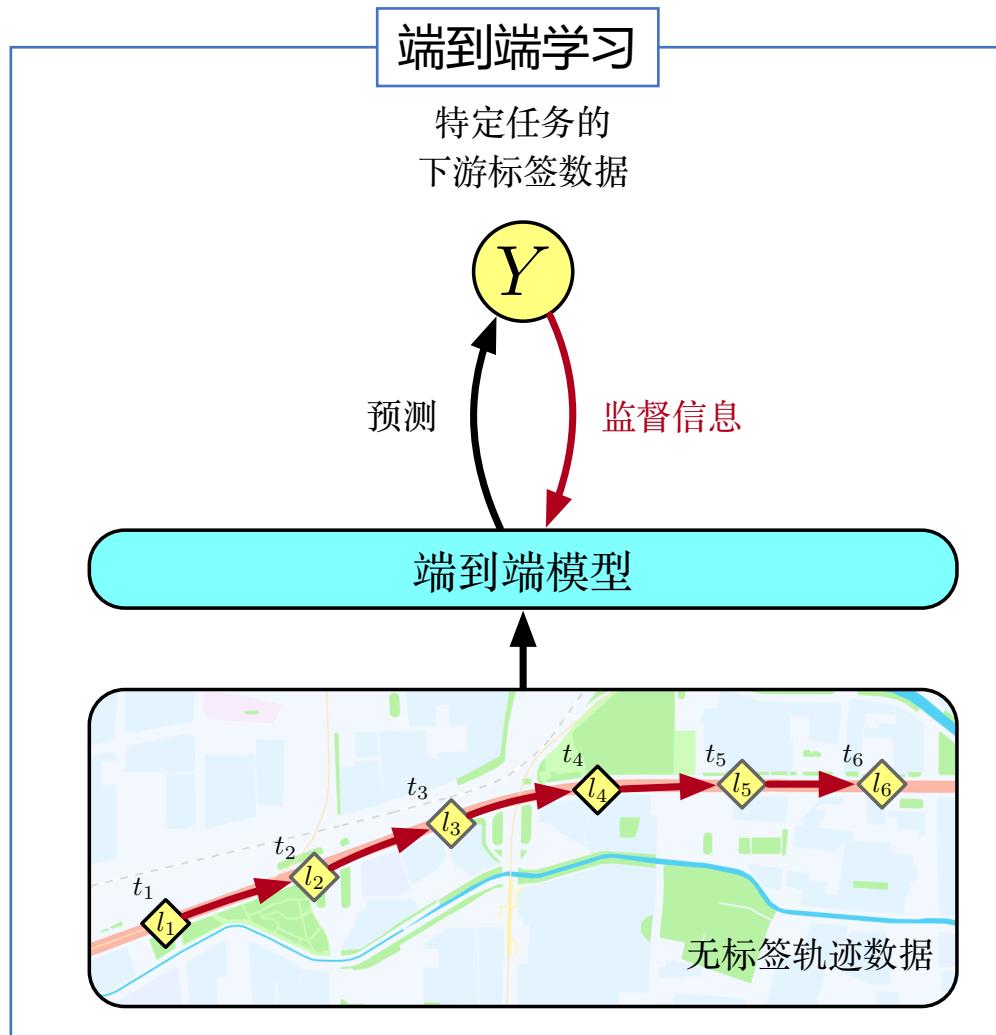
时空轨迹数据挖掘

- 深度学习算法能够**自动化**且有效地抽取轨迹数据的**复杂特征**



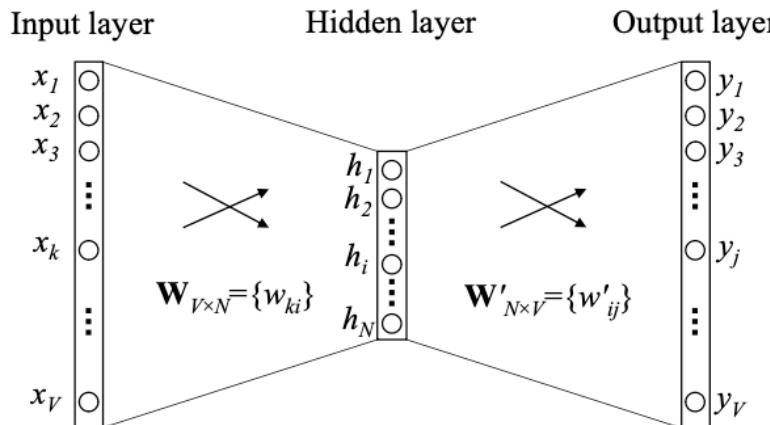
自监督学习

- 从无标签数据中提取监督信息，学习能在多种任务间迁移的自监督模型

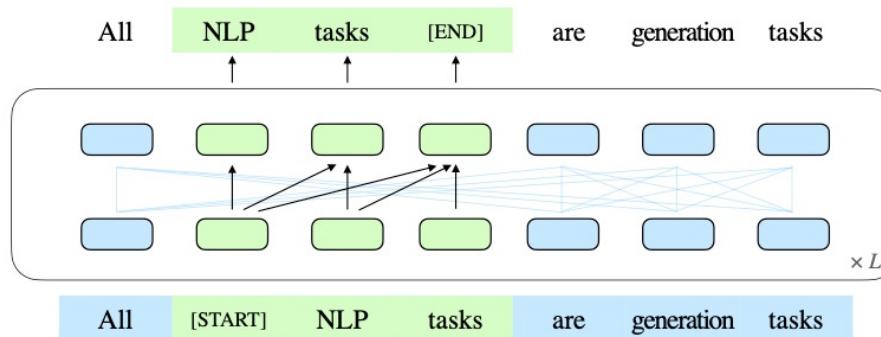


自监督学习

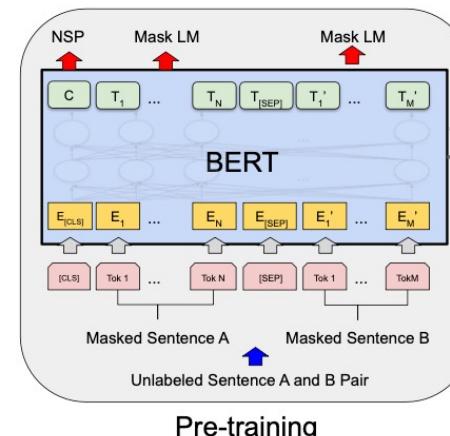
- 在自然语言与视觉领域已被广泛用于强化模型的理解能力与泛化性能



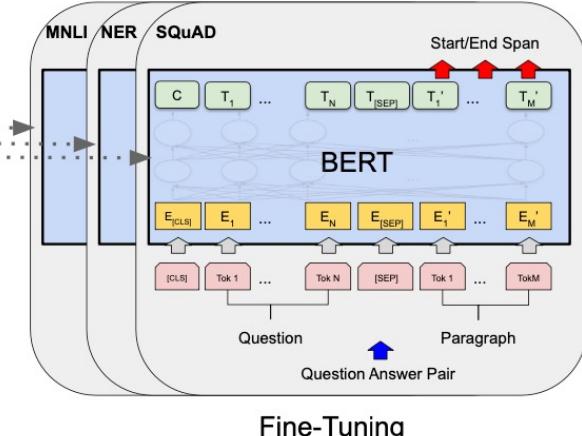
基于上下文的自然语言理解



基于自回归生成的自然语言理解

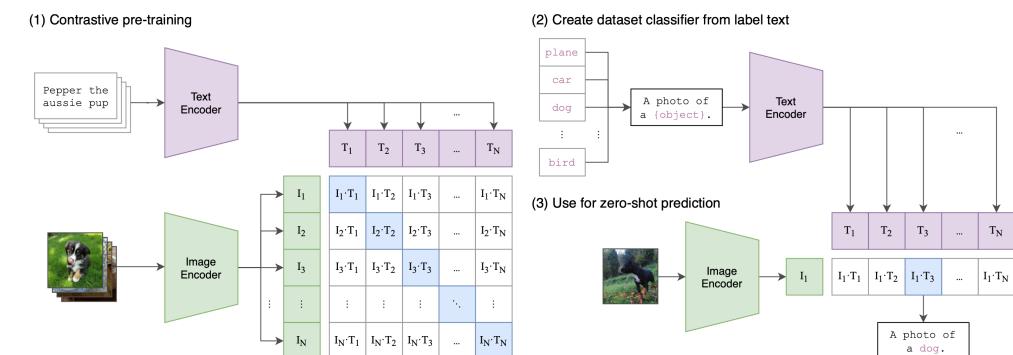


Pre-training



Fine-Tuning

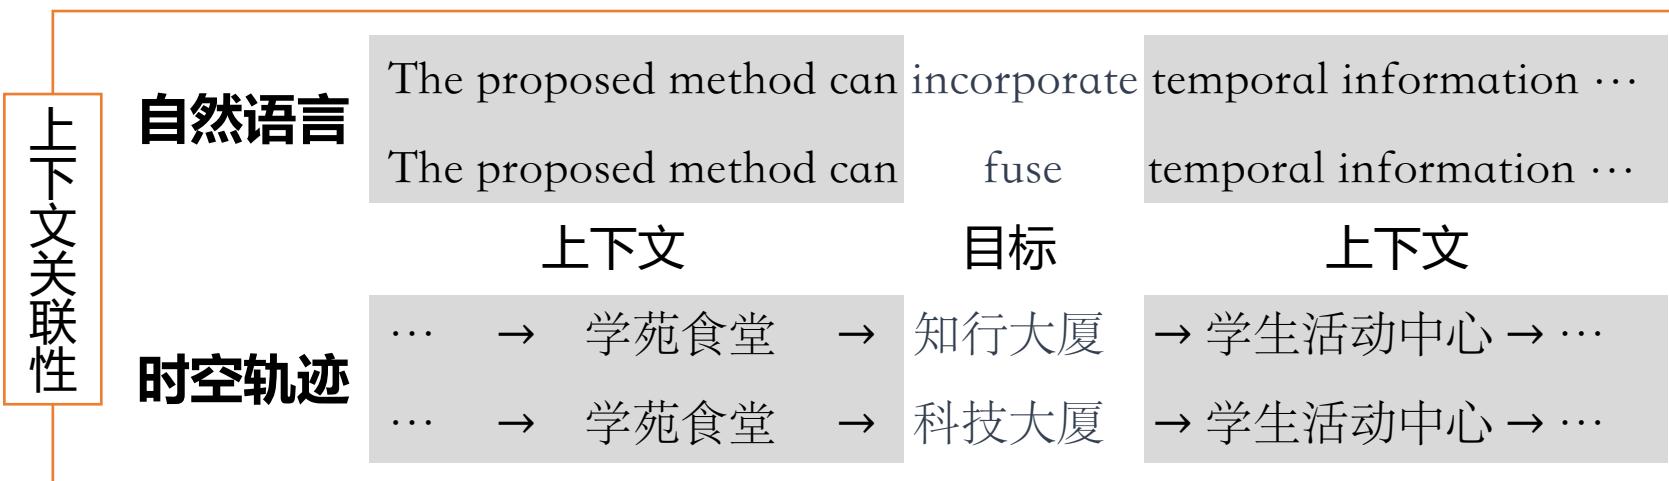
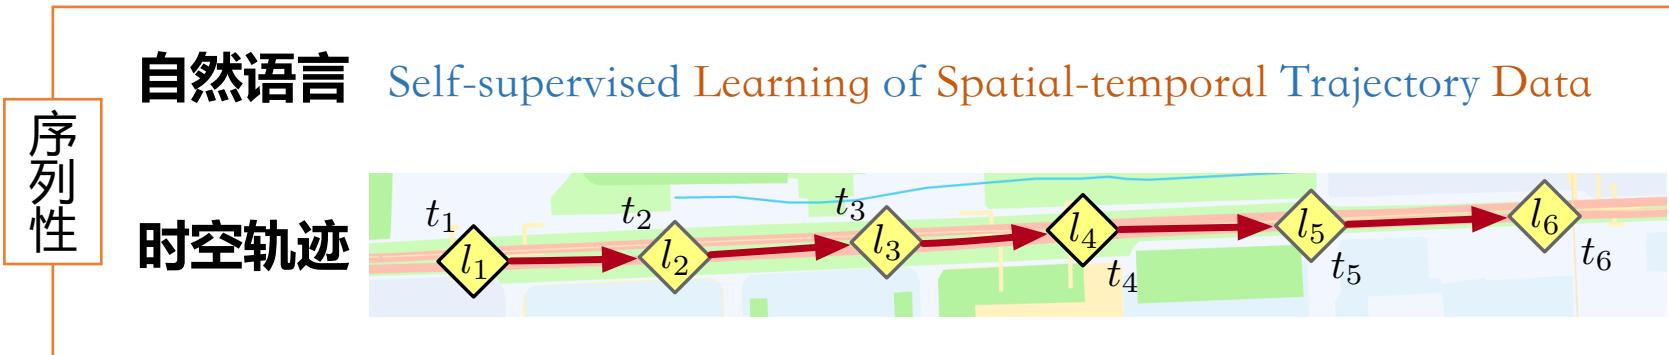
基于掩码的自然语言理解



基于对比学习的语言-视觉理解

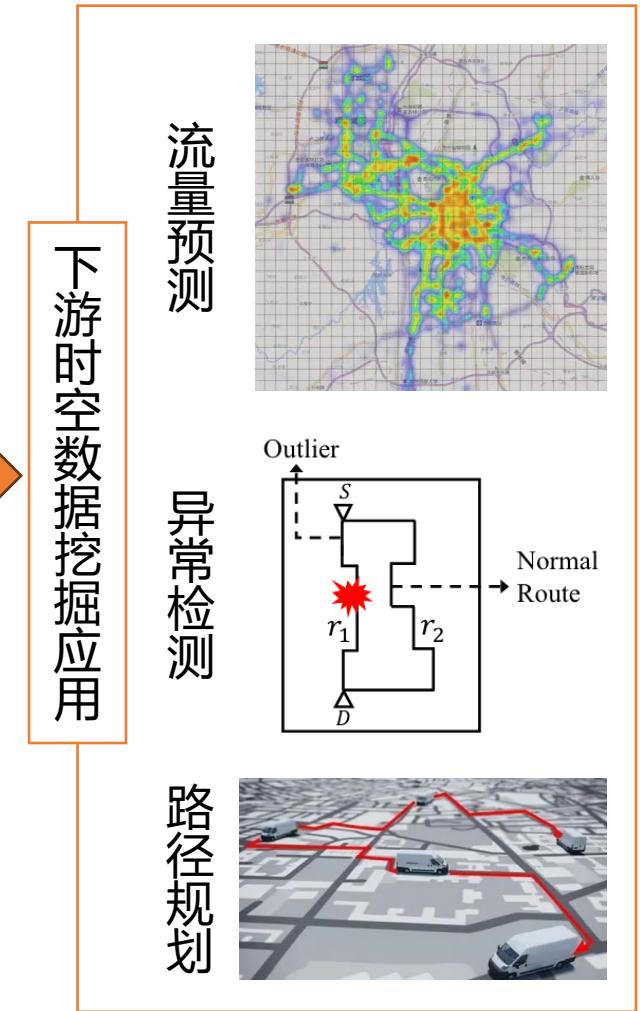
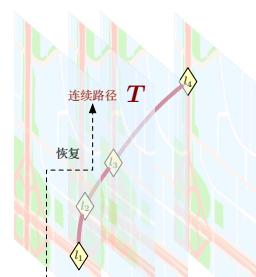
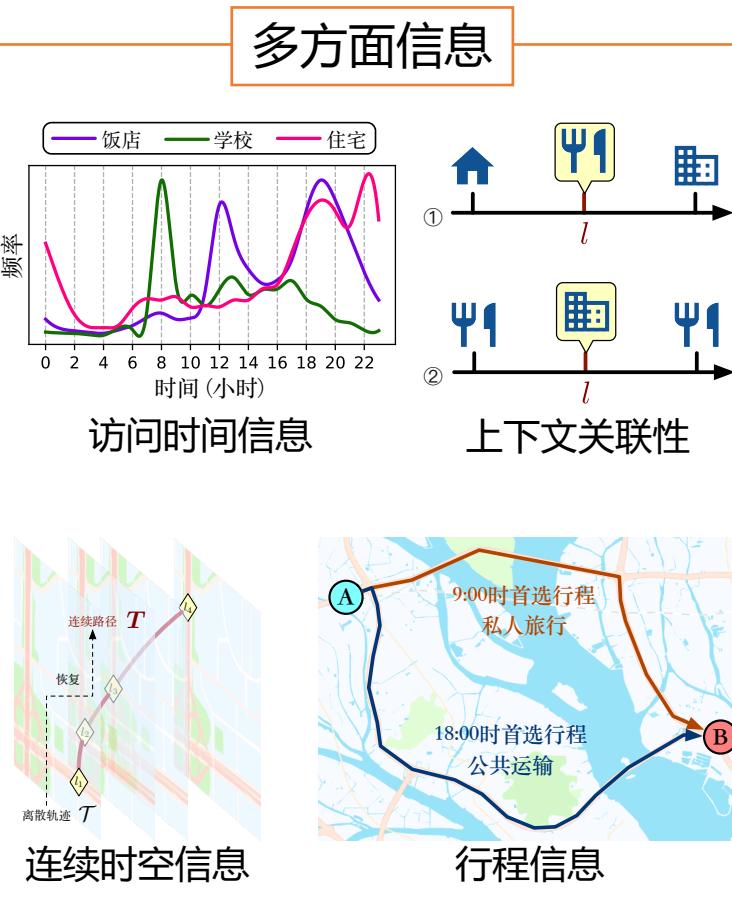
轨迹自监督学习

- 时空轨迹与自然语言具有相似性



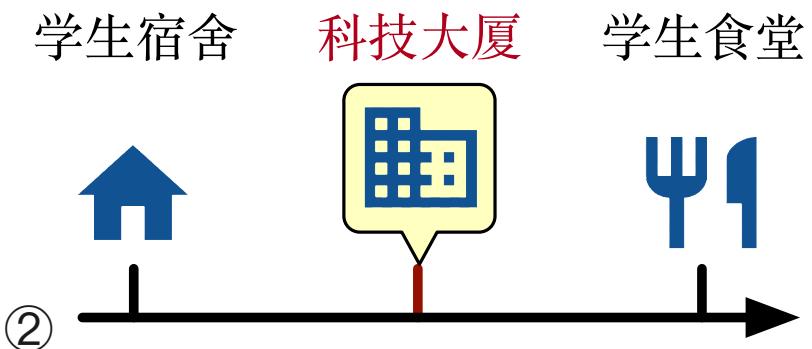
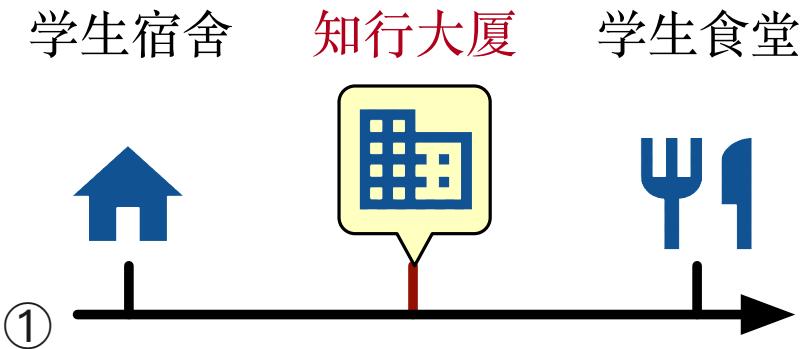
轨迹自监督学习的挑战

- 设计自监督学习方案，有效、全面挖掘轨迹数据中包含的多方面信息

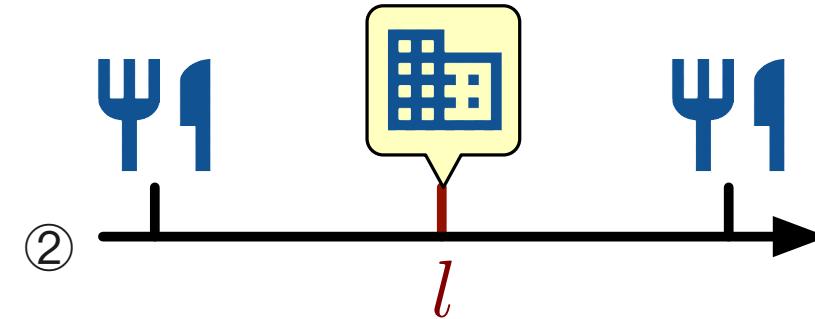
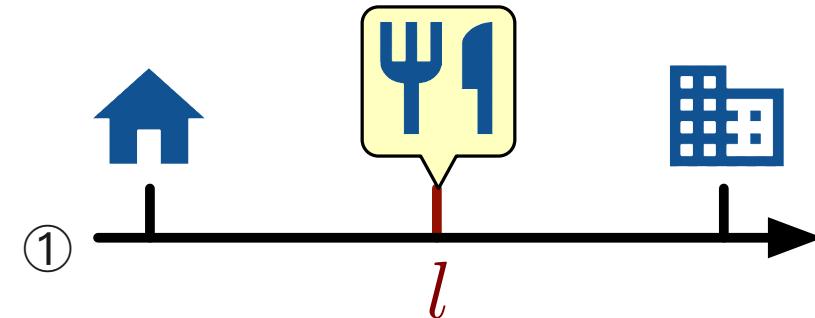


轨迹中的多方面信息

- **上下文信息**: 目标地点在轨迹中的相邻地点所体现的信息



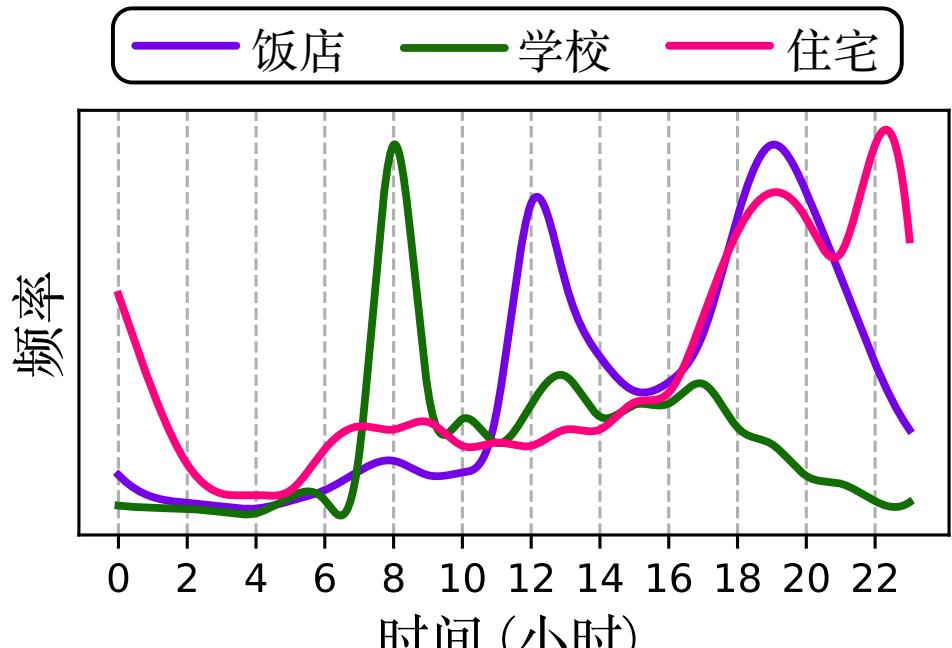
不同地点的功能相似性



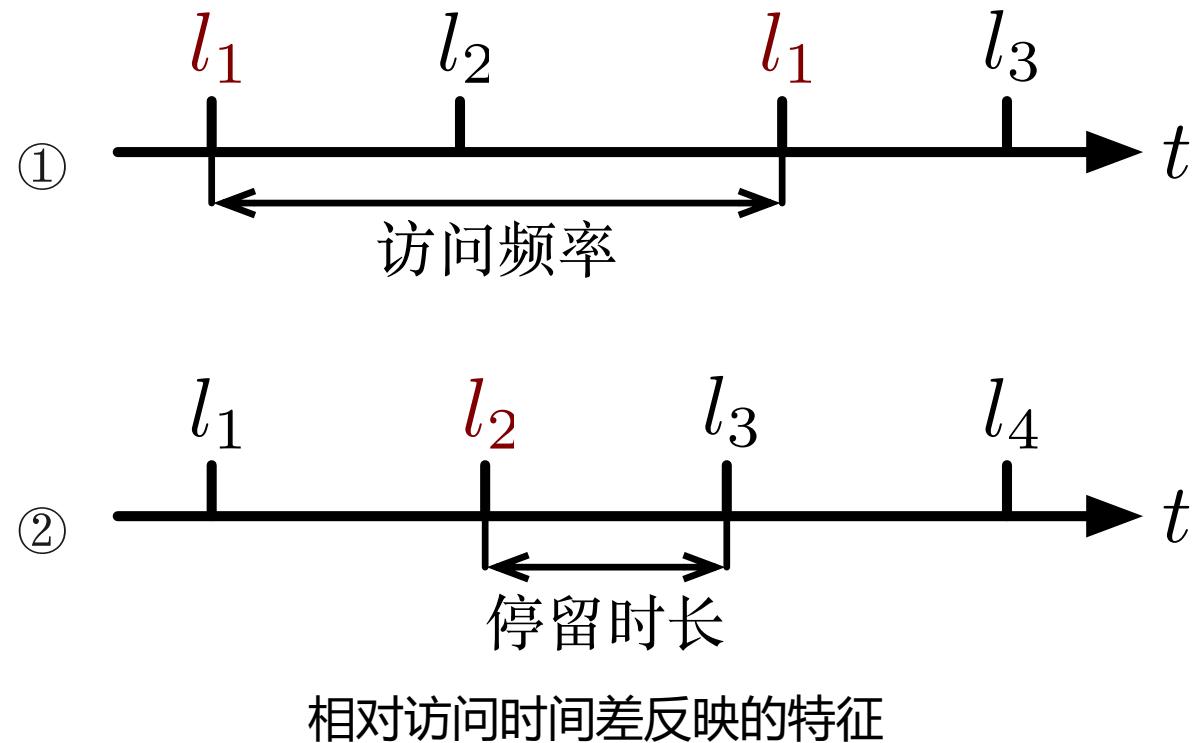
同一地点的多功能性

轨迹中的多方面信息

- 访问时间信息：地点在轨迹中被访问的时间所体现的信息



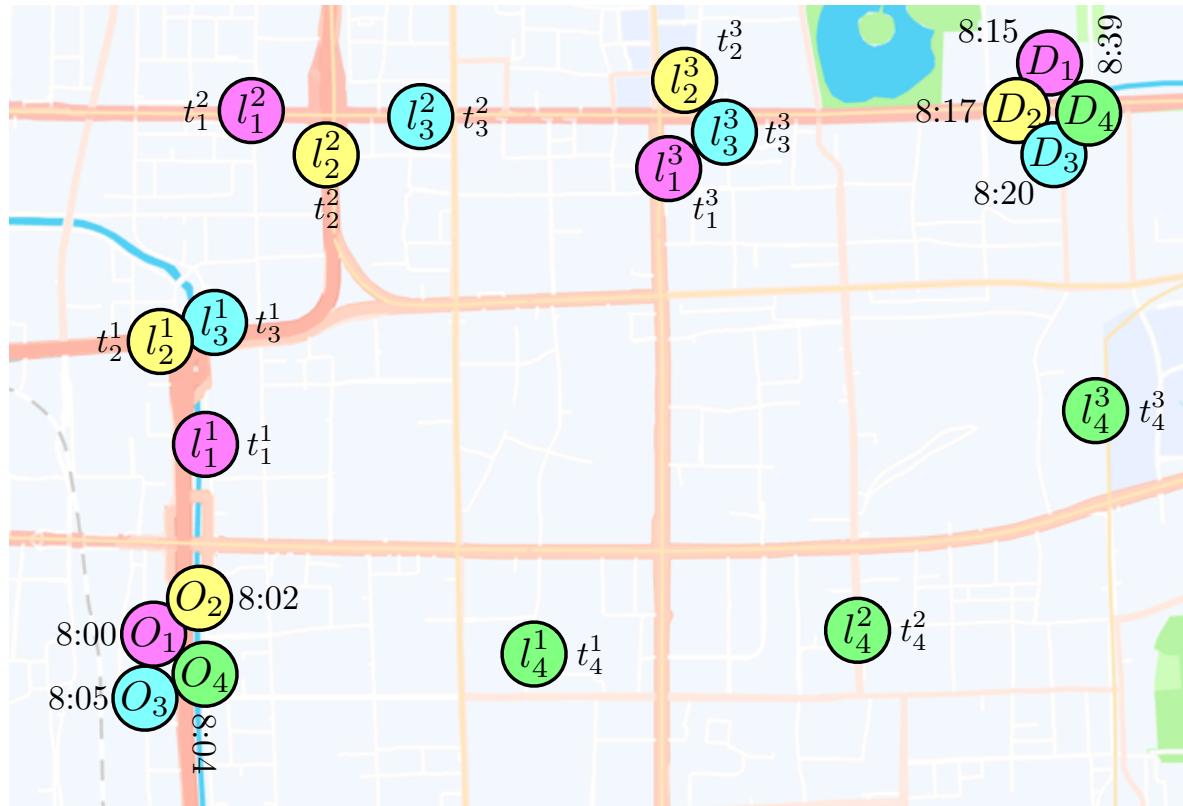
绝对访问时间反映的特征



相对访问时间差反映的特征

轨迹中的多方面信息

- 行程信息：轨迹序列所对应的某次行程中包含的信息



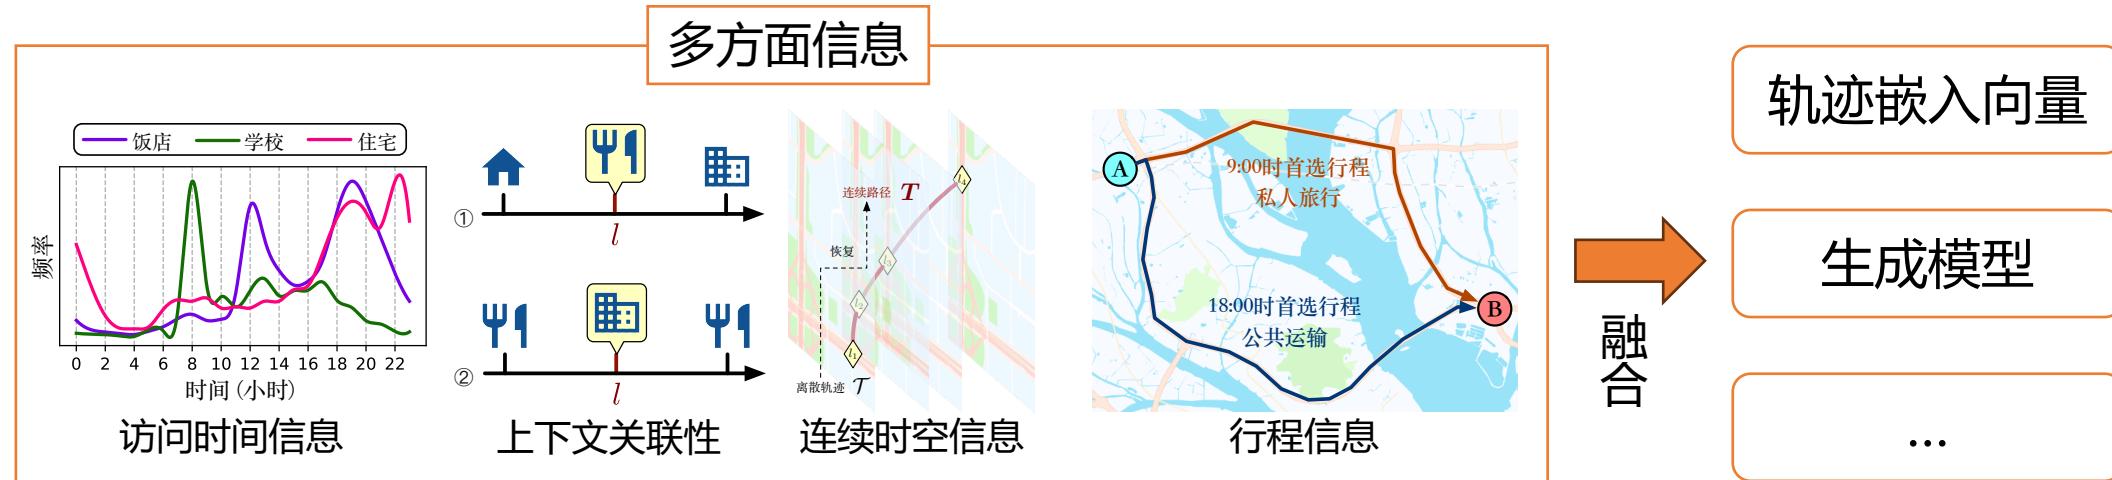
行程信息与旅行时间的关联性



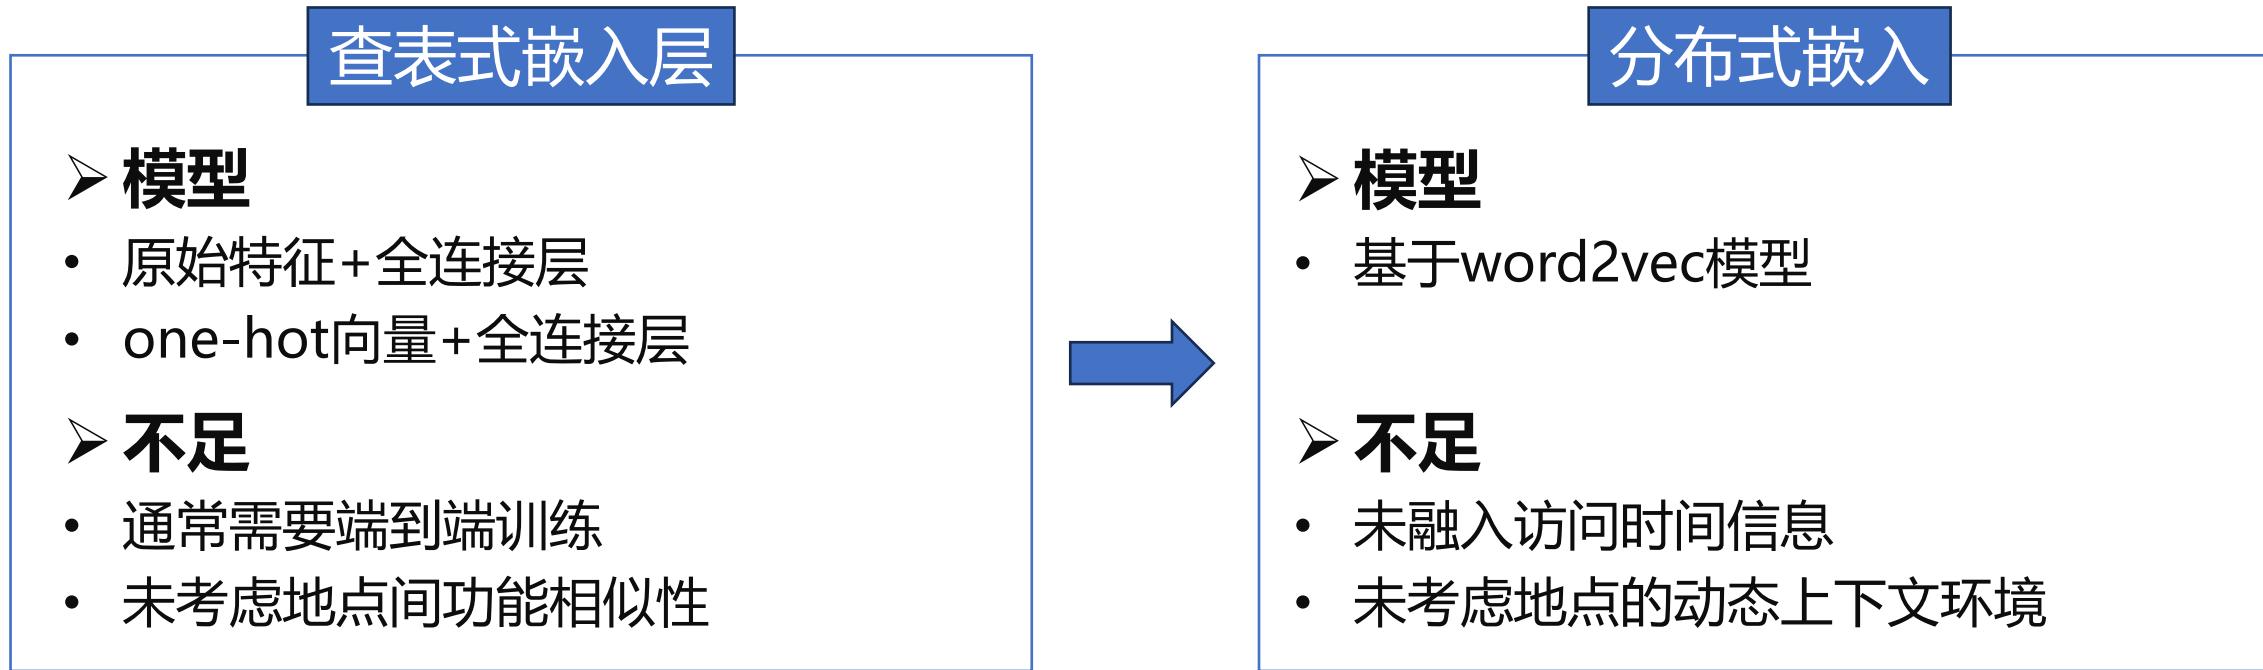
行程信息与路线偏好的关联性

轨迹自监督学习的挑战

- 有效融合轨迹数据中的多方面信息，灵活适应输入输出轨迹形式

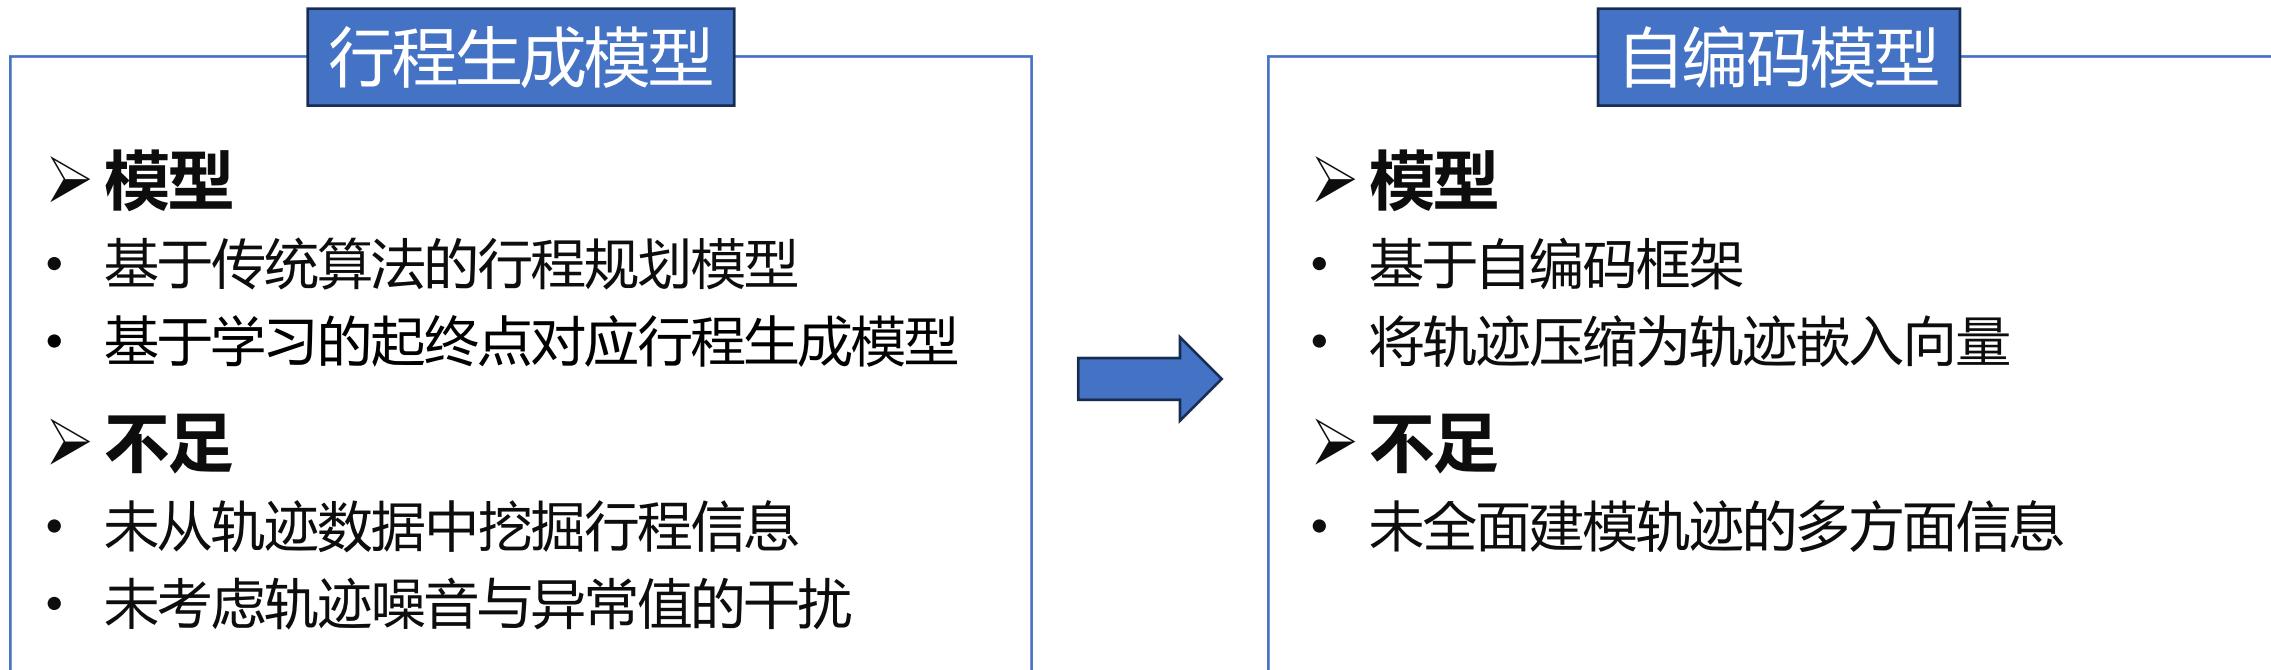


➤ 基于词嵌入的方法



- [1] S. Feng, G. Cong, B. An, and Y. M. Chee, "POI2Vec: Geographical Latent Representation for Predicting Future Visitors," *AAAI*, vol. 31, no. 1, Feb. 2017, doi: 10.1609/aaai.v31i1.10500.
- [2] H. Wang and Z. Li, "Region Representation Learning via Mobility Flow," in *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, Singapore Singapore: ACM, Nov. 2017, pp. 237–246. doi: 10.1145/3132847.3133006.
- [3] Z. Yao, Y. Fu, B. Liu, W. Hu, and H. Xiong, "Representing Urban Functions through Zone Embedding with Human Mobility Patterns," in *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence*, Stockholm, Sweden: International Joint Conferences on Artificial Intelligence Organization, Jul. 2018, pp. 3919–3925. doi: 10.24963/ijcai.2018/545.
- [4] S. Zhao, T. Zhao, I. King, and M. R. Lyu, "Geo-Teaser: Geo-Temporal Sequential Embedding Rank for Point-of-interest Recommendation," in *Proceedings of the 26th International Conference on World Wide Web Companion - WWW' 17 Companion*, Perth, Australia: ACM Press, 2017, pp. 153–162. doi: 10.1145/3041021.3054138.
- [5] Y. Zhou and Y. Huang, "DeepMove: Learning Place Representations through Large Scale Movement Data." *arXiv*, Jul. 12, 2018. Accessed: Jul. 12, 2022. [Online]. Available: <http://arxiv.org/abs/1807.04241>
- [6] T. Shimizu, T. Yabe, and K. Tsubouchi, "Learning Fine Grained Place Embeddings with Spatial Hierarchy from Human Mobility Trajectories." *arXiv*, Feb. 05, 2020. Accessed: Jul. 12, 2022. [Online]. Available: <http://arxiv.org/abs/2002.02058>

➤ 基于生成模型的方法



- [1] H. Yuan, G. Li, Z. Bao, and L. Feng, "Effective Travel Time Estimation: When Historical Trajectories over Road Networks Matter," in Proceedings of the 2020 ACM SIGMOD International Conference on Management of Data, in SIGMOD '20. New York, NY, USA: Association for Computing Machinery, Jun. 2020, pp. 2135–2149. doi: 10.1145/3318464.3389771.
- [2] Y. Li, K. Fu, Z. Wang, C. Shahabi, J. Ye, and Y. Liu, "Multi-task Representation Learning for Travel Time Estimation," in Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, in KDD '18. New York, NY, USA: Association for Computing Machinery, Jul. 2018, pp. 1695–1704. doi: 10.1145/3219819.3220033.
- [3] Z. Zou, H. Yang, and A.-X. Zhu, "Estimation of Travel Time Based on Ensemble Method With Multi-Modality Perspective Urban Big Data," IEEE Access, vol. 8, pp. 24819–24828, 2020, doi: 10.1109/ACCESS.2020.2971008.
- [4] S. Huang, Y. Wang, T. Zhao, and G. Li, "A Learning-based Method for Computing Shortest Path Distances on Road Networks," in 2021 IEEE 37th International Conference on Data Engineering (ICDE), Apr. 2021, pp. 360–371. doi: 10.1109/ICDE51399.2021.00038.
- [5] X. Li, G. Cong, and Y. Cheng, "Spatial Transition Learning on Road Networks with Deep Probabilistic Models," in 2020 IEEE 36th International Conference on Data Engineering (ICDE), Apr. 2020, pp. 349–360. doi: 10.1109/ICDE48307.2020.00037.

➤ 基于对比学习的方法

端到端+对比学习模型

➤ 模型

- 利用对比学习强化特定任务性能

➤ 不足

- 难以迁移至其他任务



对比学习自监督模型

➤ 模型

- 基于对比学习框架学习轨迹嵌入向量

➤ 不足

- 难以有效融合轨迹多方面信息
- 难以适配各种下游任务

- [1] F. Zhou, Y. Dai, Q. Gao, P. Wang, and T. Zhong, "Self-supervised human mobility learning for next location prediction and trajectory classification," *Knowledge-Based Systems*, vol. 228, p. 107214, Sep. 2021, doi: 10.1016/j.knosys.2021.107214.
- [2] J. Jiang, D. Pan, H. Ren, X. Jiang, C. Li, and J. Wang, "Self-supervised Trajectory Representation Learning with Temporal Regularities and Travel Semantics." arXiv, Nov. 21, 2022. doi: 10.48550/arXiv.2211.09510.
- [3] T.-Y. Fu and W.-C. Lee, "Trembr: Exploring Road Networks for Trajectory Representation Learning," *ACM Trans. Intell. Syst. Technol.*, vol. 11, no. 1, pp. 1–25, Feb. 2020, doi: 10.1145/3361741.
- [4] P. Yang, H. Wang, Y. Zhang, L. Qin, W. Zhang, and X. Lin, "T3S: Effective Representation Learning for Trajectory Similarity Computation," in 2021 IEEE 37th International Conference on Data Engineering (ICDE), Chania, Greece: IEEE, Apr. 2021, pp. 2183–2188. doi: 10.1109/ICDE51399.2021.00221.
- [5] X. Li, K. Zhao, G. Cong, C. S. Jensen, and W. Wei, "Deep Representation Learning for Trajectory Similarity Computation," in 2018 IEEE 34th International Conference on Data Engineering (ICDE), Paris: IEEE, Apr. 2018, pp. 617–628. doi: 10.1109/ICDE.2018.00062.
- [6] A. Liu et al., "Representation Learning With Multi-Level Attention for Activity Trajectory Similarity Computation," *IEEE Trans. Knowl. Data Eng.*, vol. 34, no. 5, pp. 2387–2400, May 2022, doi: 10.1109/TKDE.2020.3010022.

01

研究背景和意义

02

研究内容和主要贡献

(1)

访问时间感知的轨迹自监督学习方法

(2)

上下文感知的轨迹自监督学习方法

(3)

行程信息建模的轨迹自监督学习方法

(4)

多视图融合的轨迹自监督学习方法

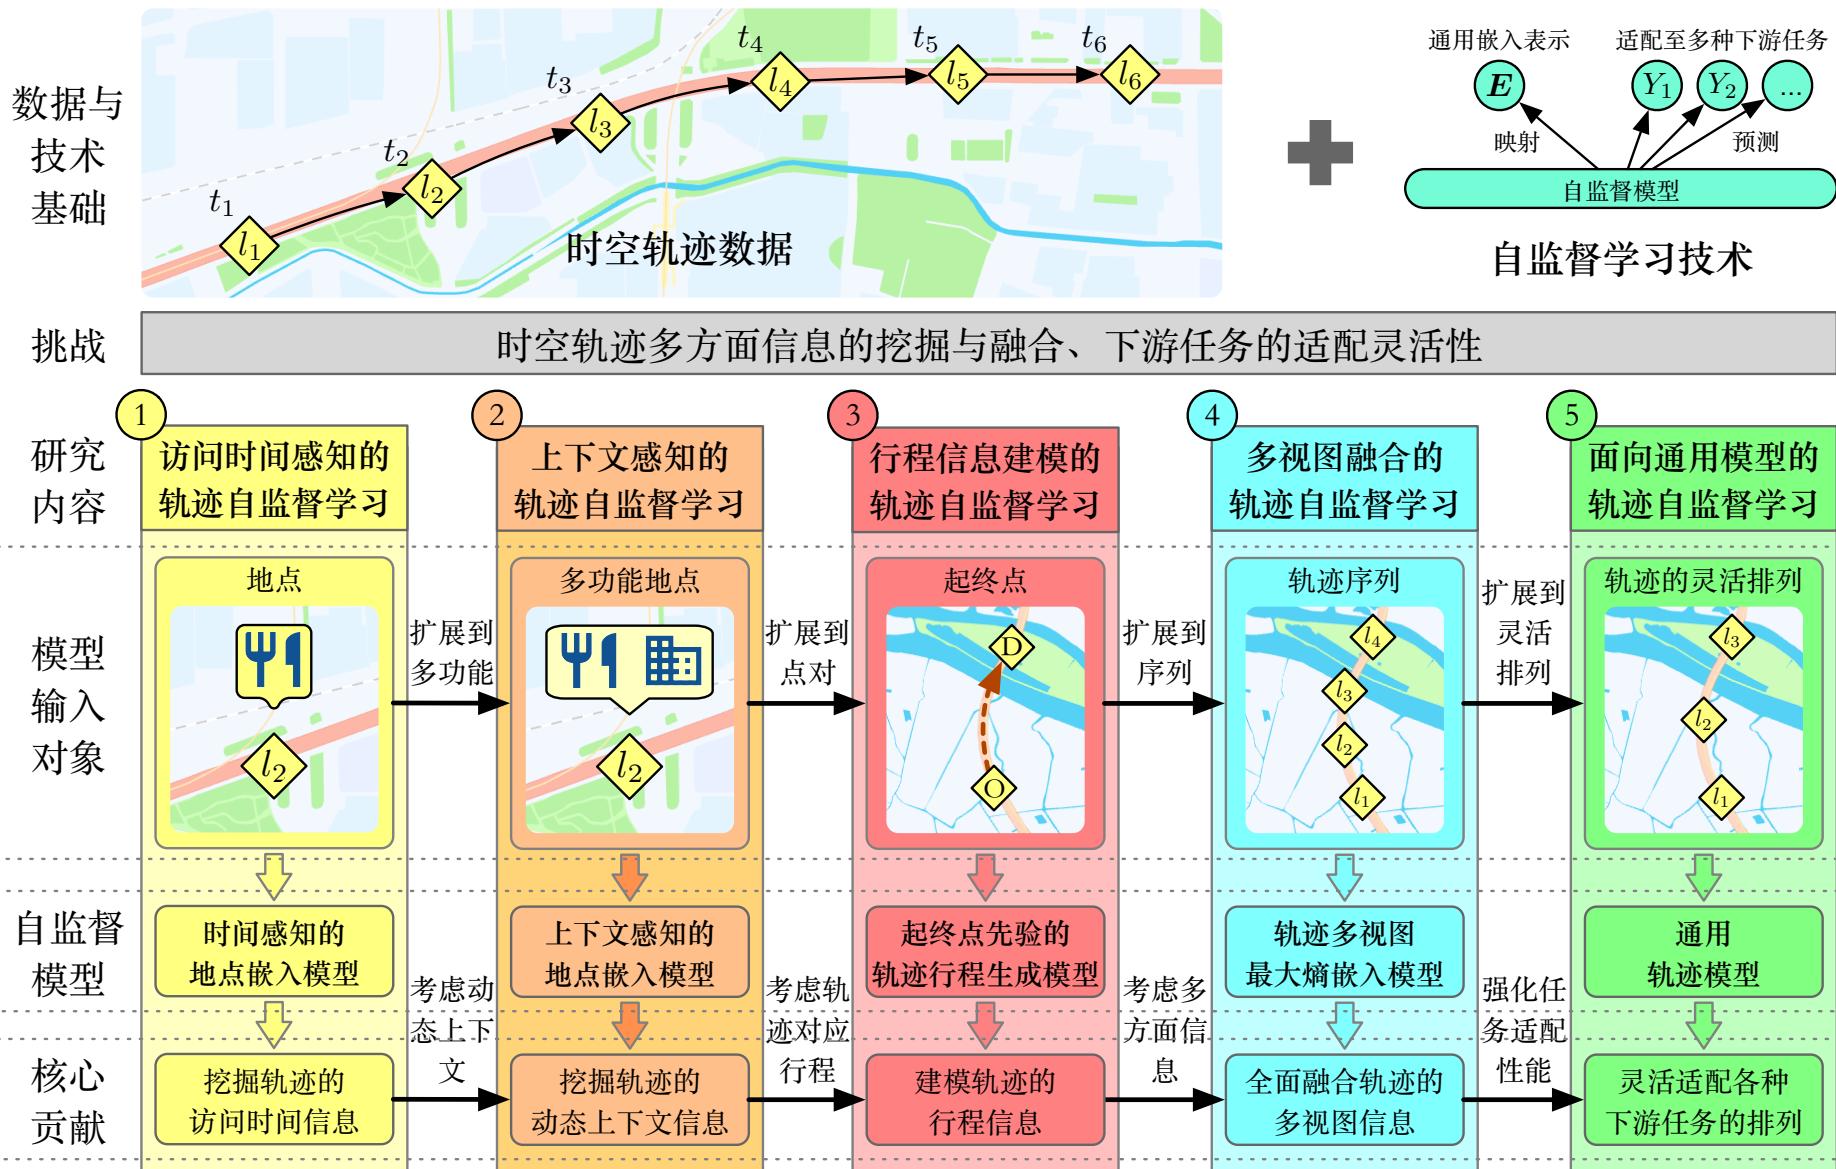
(5)

面向通用模型的轨迹自监督学习方法

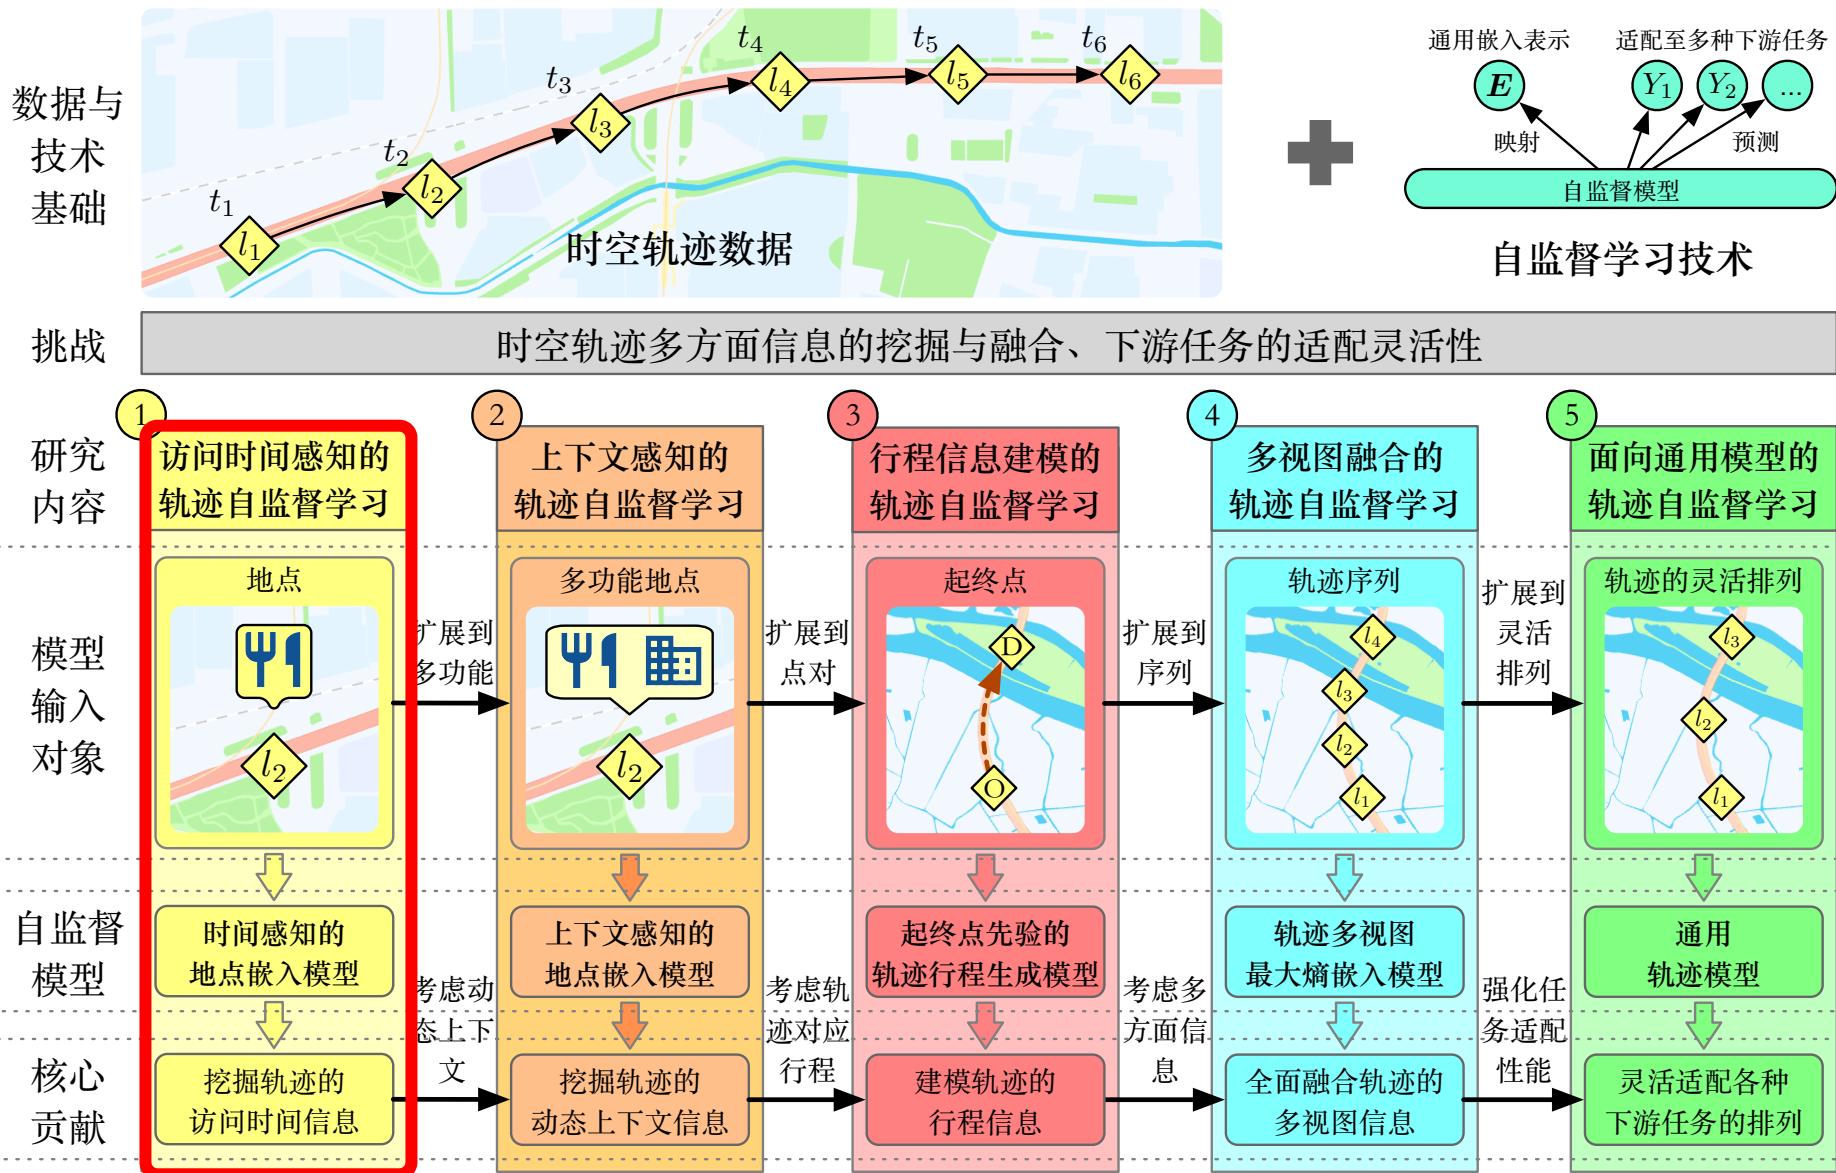
03

研究总结

研究内容框架



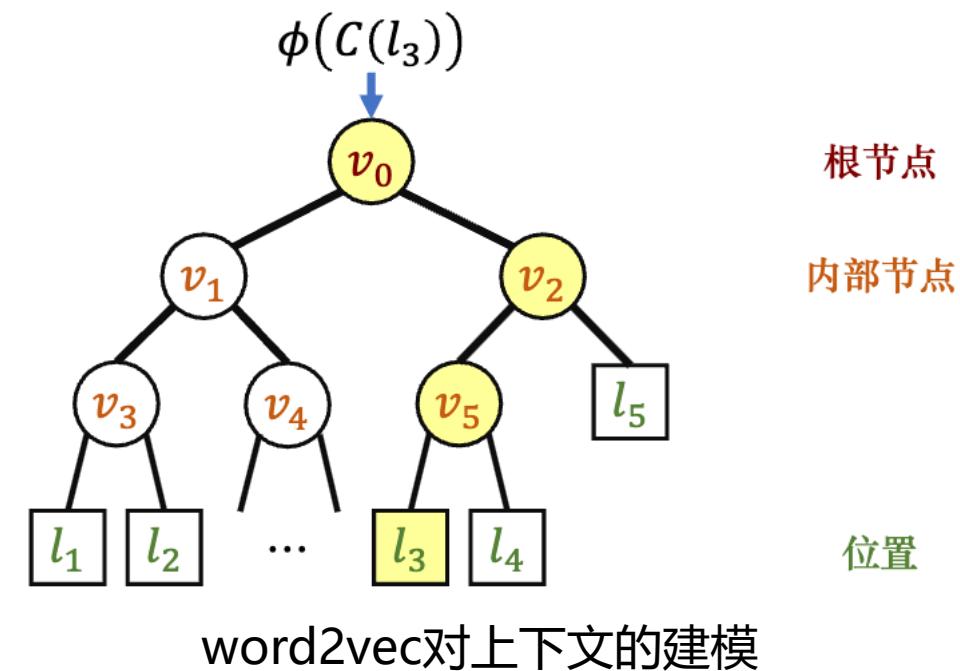
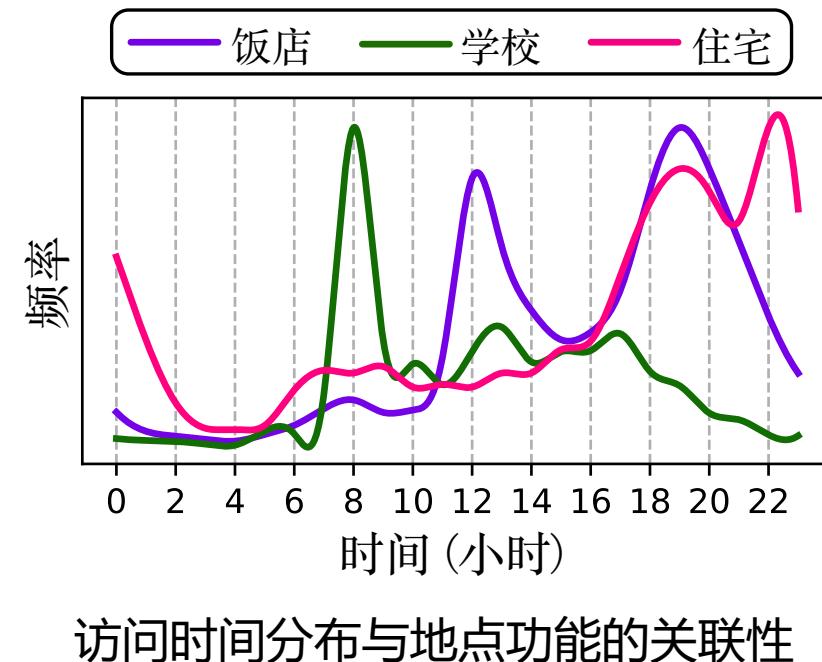
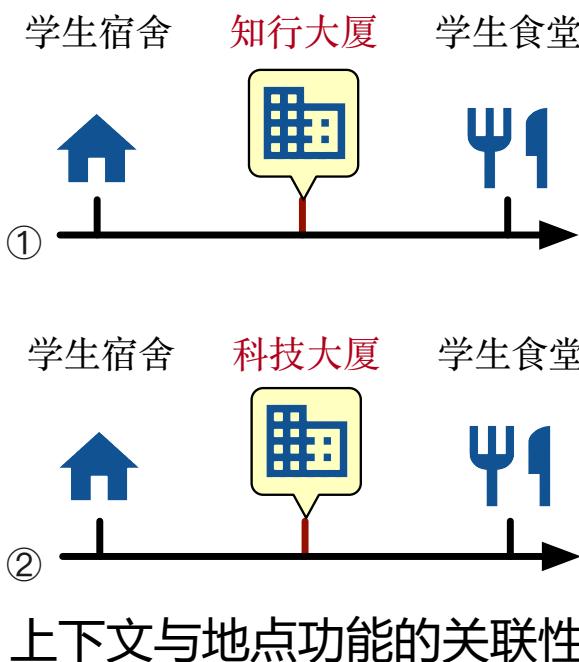
研究内容框架



1-访问时间感知的轨迹自监督学习方法

➤ 挑战

- 从轨迹中上下文信息和访问时间信息提取地点的功能特征

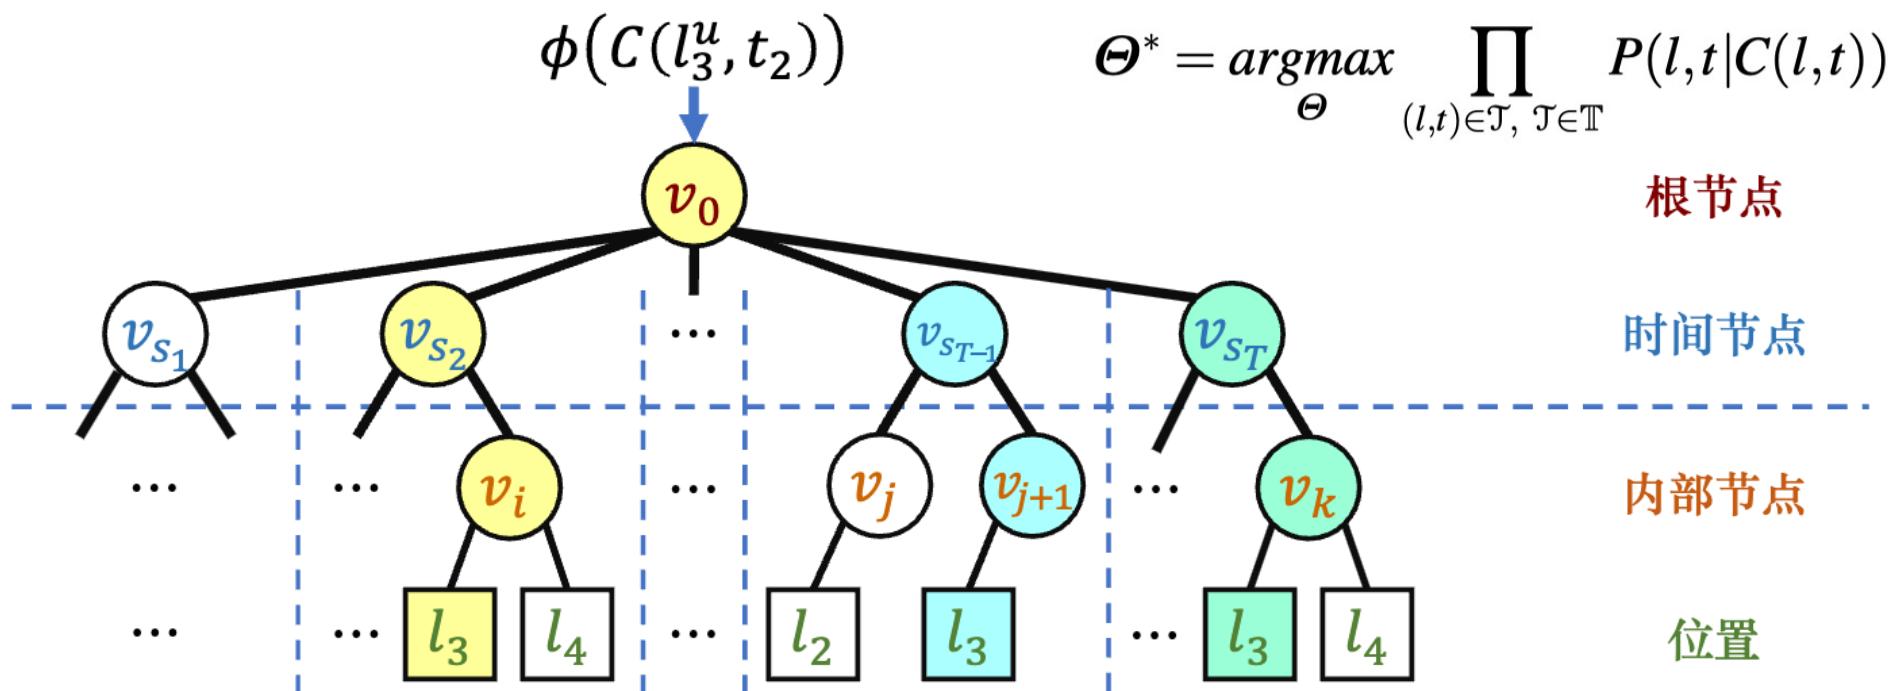


- word2vec自监督学习框架能够对上下文关联性进行建模，但忽略了访问时间信息

1-访问时间感知的轨迹自监督学习方法

➤ 时间感知的地点嵌入 (TALE) 模型

- 提出新颖的**时间哈夫曼树**结构，提取轨迹中的**访问时间信息并融入地点嵌入向量**

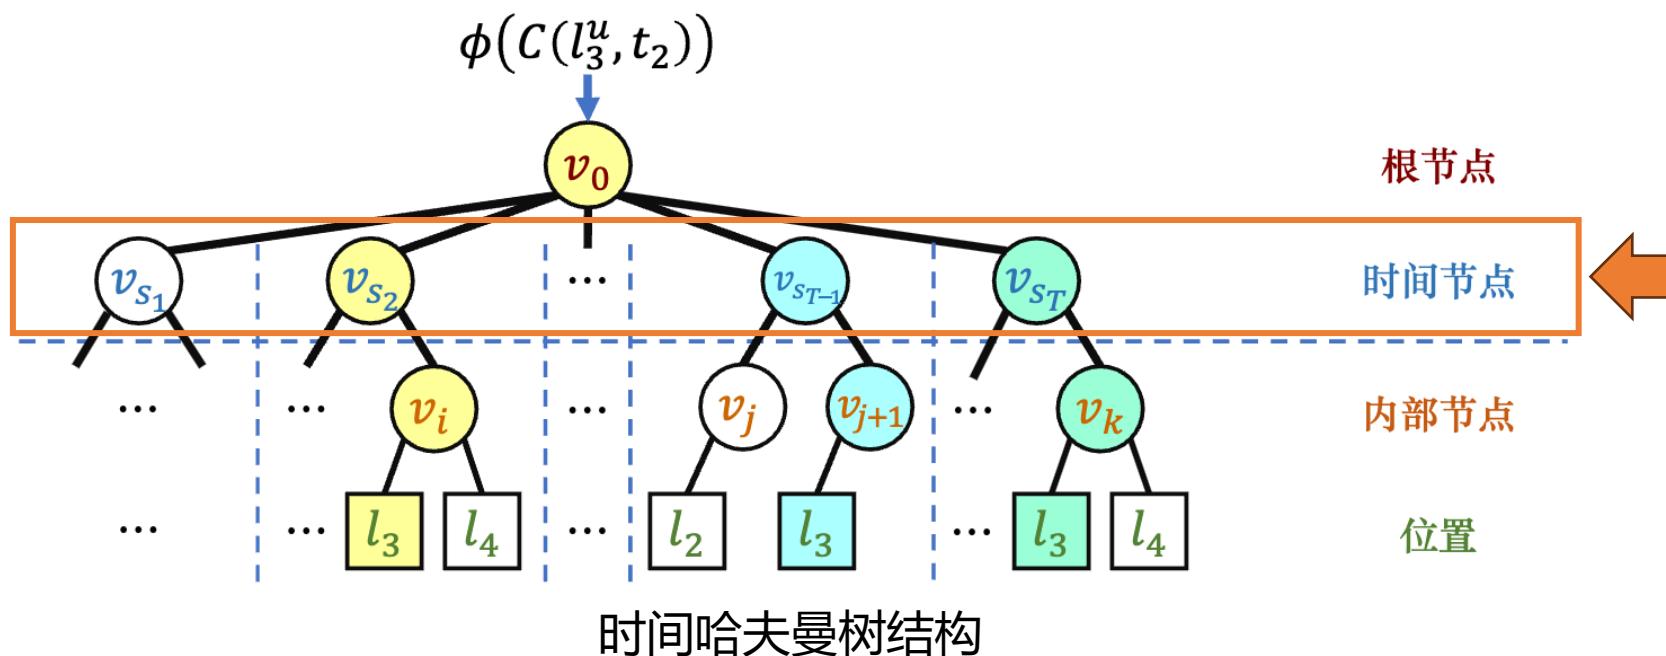


Huaiyu Wan, Yan Lin, et al. Pre-training time-aware location embeddings from spatial-temporal trajectories. *IEEE Transactions on Knowledge and Data Engineering (TKDE)*, 2021, 34 (11), 5510-5523.

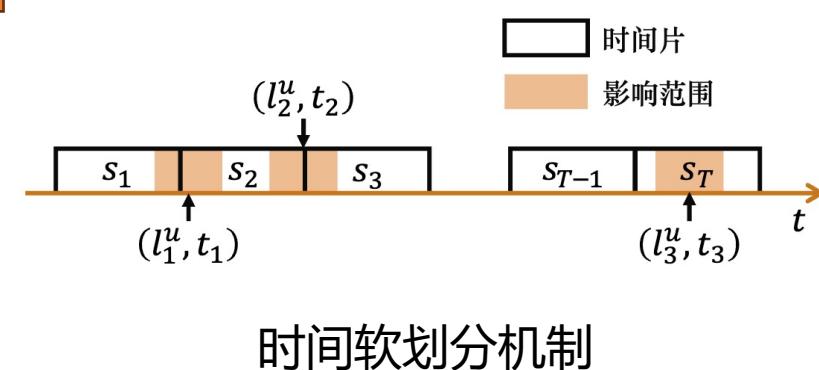
1-访问时间感知的轨迹自监督学习方法

➤ 时间感知的地点嵌入 (TALE) 模型

- 提出时间软划分机制，进一步提升访问时间信息建模的准确性



$$\mathbb{H}_\tau = \{(l_i, t_i) | (l_i, t_i) \in \mathcal{T}, \mathcal{T} \in \mathbb{T}, [t - t_{\text{influ}}/2, t + t_{\text{influ}}/2] \cap [\tau \cdot t_{\text{slice}}, (\tau + 1) \cdot t_{\text{slice}}] \neq \emptyset\}$$



1-访问时间感知的轨迹自监督学习方法

➤ 实验设计

基线地点嵌入模型

- CBOW: 基础word2vec模型
- Skip-gram: word2vec的另一种实现
- POI2Vec: 融合了空间相关性的地点嵌入
- Geo-Teaser: 融合了工作日/周末区分的地点嵌入

下游任务与下游预测模型

➤ 地点分类

- FC: 全连接网络
- kNN: 聚类

➤ 轨迹预测

- GRU: 循环神经网络
- DeepMove

➤ 访问流量预测

- seq2seq: 序列预测框架

轨迹数据集

- 用户签到数据集
- 手机信令数据集

1-访问时间感知的轨迹自监督学习方法

综合性能对比

- 所提出模型能够提升三种下游任务的准确率

预测模型		GRU					DeepMove				
指标		Acc@1 (%)	Acc@5 (%)	Acc@10 (%)	Acc@20 (%)	macro-F1 (%)	Acc@1 (%)	Acc@5 (%)	Acc@10 (%)	Acc@20 (%)	macro-F1 (%)
数据集	嵌入方法										
Foursquare-NYC	Skip-gram	5.466±0.23	11.870±0.33	14.986±0.34	18.878±0.37	1.254±0.12	6.170±0.21	13.351±0.52	16.555±0.58	20.310±0.56	1.354±0.16
	CBOW	5.248±0.22	10.849±0.22	13.522±0.16	16.367±0.30	1.203±0.09	6.191±0.10	13.282±0.47	16.304±0.49	19.814±0.40	1.556±0.11
	POI2Vec	5.935±0.19	12.529±0.35	15.910±0.30	19.961±0.31	1.471±0.10	6.357±0.28	13.786±0.25	17.239±0.22	21.237±0.31	1.515±0.12
	Geo-Teaser	6.209±0.32	13.677±0.43	17.602±0.37	21.996±0.39	1.533±0.11	7.007±0.28	15.472±0.41	19.458±0.17	23.741±0.56	1.717±0.08
	TALE	6.918±0.39	14.874±0.44	18.911±0.34	23.018±0.31	1.685±0.20	7.410±0.40	16.455±0.41	20.447±0.29	24.711±0.19	1.867±0.10
Foursquare-TKY	Skip-gram	10.705±0.17	25.417±0.27	32.986±0.30	40.944±0.34	1.650±0.08	13.173±0.14	28.965±0.23	36.651±0.28	44.529±0.32	2.269±0.07
	CBOW	10.373±0.10	23.899±0.21	30.690±0.24	37.899±0.23	1.720±0.09	12.823±0.18	27.391±0.42	34.340±0.43	41.528±0.39	2.350±0.15
	POI2Vec	11.425±0.13	26.785±0.22	34.570±0.26	42.854±0.26	2.023±0.04	14.306±0.11	30.532±0.21	38.533±0.17	46.665±0.15	2.958±0.01
	Geo-Teaser	12.024±0.18	28.696±0.38	37.176±0.40	45.851±0.45	2.413±0.10	14.669±0.15	32.231±0.28	41.989±0.44	50.540±0.60	3.150±0.10
	TALE	12.637±0.16	29.753±0.39	38.476±0.40	47.239±0.37	2.848±0.10	15.443±0.18	33.453±0.27	40.720±0.42	49.077±0.47	3.622±0.07
Foursquare-JKT	Skip-gram	5.524±0.17	14.100±0.17	19.853±0.20	26.840±0.14	0.776±0.07	5.713±0.15	14.423±0.23	20.498±0.26	27.654±0.15	0.835±0.13
	CBOW	5.290±0.07	13.773±0.25	19.367±0.31	26.055±0.35	0.898±0.09	5.736±0.16	14.309±0.22	19.965±0.27	26.815±0.29	1.025±0.15
	POI2Vec	5.876±0.17	15.356±0.24	21.650±0.27	29.392±0.19	0.846±0.09	6.229±0.11	15.904±0.07	22.350±0.32	30.029±0.43	1.076±0.16
	Geo-Teaser	6.376±0.13	16.740±0.30	23.808±0.50	32.148±0.37	1.025±0.12	6.533±0.11	17.225±0.40	24.248±0.31	32.300±0.30	1.444±0.07
	TALE	6.278±0.20	17.901±0.28	25.424±0.44	34.132±0.38	1.374±0.09	7.056±0.13	18.640±0.17	25.997±0.09	34.711±0.31	1.469±0.07
Mobile-PEK	Skip-gram	7.994±0.09	22.574±0.14	31.232±0.18	40.819±0.20	3.453±0.10	8.650±0.10	23.564±0.09	31.703±0.17	40.486±0.22	3.996±0.07
	CBOW	8.458±0.07	22.796±0.16	30.418±0.18	38.517±0.19	4.122±0.05	8.895±0.05	23.980±0.14	31.778±0.16	39.923±0.17	4.632±0.09
	POI2Vec	9.535±0.09	25.761±0.03	34.883±0.14	44.416±0.14	4.789±0.14	9.762±0.15	26.254±0.06	34.977±0.05	44.151±0.16	5.044±0.10
	Geo-Teaser	9.351±0.08	25.680±0.15	34.791±0.17	44.508±0.26	4.523±0.12	9.639±0.06	25.856±0.12	34.517±0.14	43.711±0.21	4.819±0.20
	TALE	10.939±0.06	29.319±0.13	38.860±0.19	48.490±0.22	5.010±0.12	10.942±0.07	28.479±0.29	37.802±0.42	47.301±0.54	5.524±0.22

下一位位置预测任务性能比较

数据集	指标	预测模型				FC				kNN	
		嵌入方法	Acc@1 (%)	Acc@5 (%)	Acc@10 (%)	Acc@20 (%)	macro-F1 (%)	Acc@1 (%)	macro-F1 (%)	Acc@1 (%)	macro-F1 (%)
Foursquare-NYC	Skip-gram	18.465±0.19	33.453±0.47	44.220±0.52	58.798±0.82	1.626±0.15	6.266±0.72	1.811±0.22			
	CBOW	18.414±0.36	33.542±0.57	43.811±0.33	57.583±0.64	1.651±0.18	6.532±0.89	1.694±0.27			
	POI2Vec	19.587±0.34	36.019±0.46	47.187±0.66	61.179±0.64	1.954±0.26	7.015±0.92	1.749±0.24			
	Geo-Teaser	21.723±0.81	39.290±0.62	49.457±0.93	62.852±0.79	2.606±0.38	7.399±0.33	1.918±0.33			
	TALE	22.232±0.43	41.176±1.11	51.005±0.75	64.194±0.55	2.664±0.35	7.709±0.62	2.228±0.39			
Foursquare-TKY	Skip-gram	17.783±0.55	39.542±0.65	53.864±0.45	68.288±0.60	4.196±0.42	13.031±0.56	2.607±0.24			
	CBOW	17.057±0.38	39.324±0.55	53.432±0.96	67.601±0.95	3.855±0.52	12.535±0.57	3.595±0.17			
	POI2Vec	18.944±0.56	40.667±0.89	54.171±0.70	68.670±0.51	4.584±0.61	13.414±0.65	3.556±0.41			
	Geo-Teaser	19.283±0.36	41.053±0.43	55.043±0.84	69.795±0.89	4.547±0.35	14.164±0.17	3.086±0.19			
	TALE	20.516±0.52	42.408±0.85	55.645±1.02	70.534±0.66	4.793±0.66	15.492±0.66	4.090±0.31			
Foursquare-JKT	Skip-gram	5.914±0.39	19.210±0.29	30.485±0.53	45.345±0.94	1.106±0.07	2.724±0.15	0.955±0.14			
	CBOW	5.779±0.28	19.233±0.50	31.251±0.59	46.578±0.56	1.251±0.12	2.772±0.10	1.042±0.17			
	POI2Vec	6.620±0.41	20.382±0.66	32.125±0.60	47.222±0.48	1.456±0.43	2.943±0.26	1.123±0.13			
	Geo-Teaser	6.725±0.32	21.302±0.76	33.216±0.84	48.595±0.84	1.666±0.23	2.976±0.26	1.009±0.21			
	TALE	7.044±0.37	21.576±0.23	33.766±0.65	48.522±0.27	1.578±0.39	3.256±0.32	1.198±0.21			

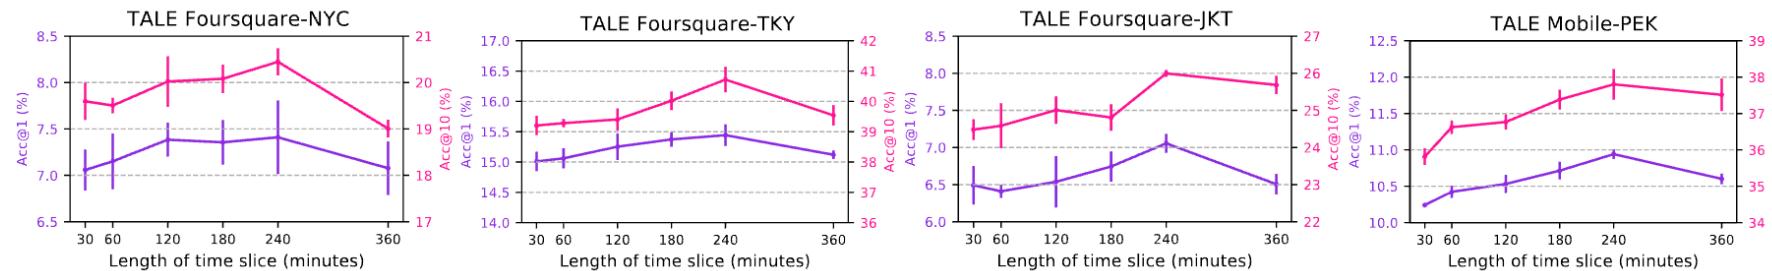
位置分类任务性能比较

指标	预测模型		FC		kNN	
	嵌入方法	MAE	RMSE	嵌入方法	MAE	RMSE
Skip-gram		2.835±0.01	4.258±0.03			
CBOW		2.771±0.01	4.143±0.02			
POI2Vec		2.599±0.01	3.871±0.03			
Geo-Teaser		2.535±0.01	3.773±0.02			
TALE		2.399±0.01	3.560±0.02			

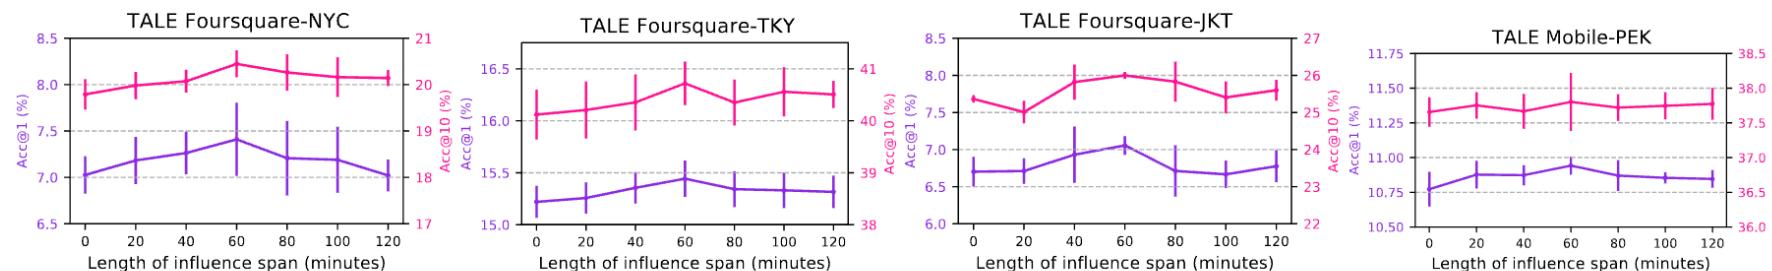
访问流量预测任务性能比较

1-访问时间感知的轨迹自监督学习方法

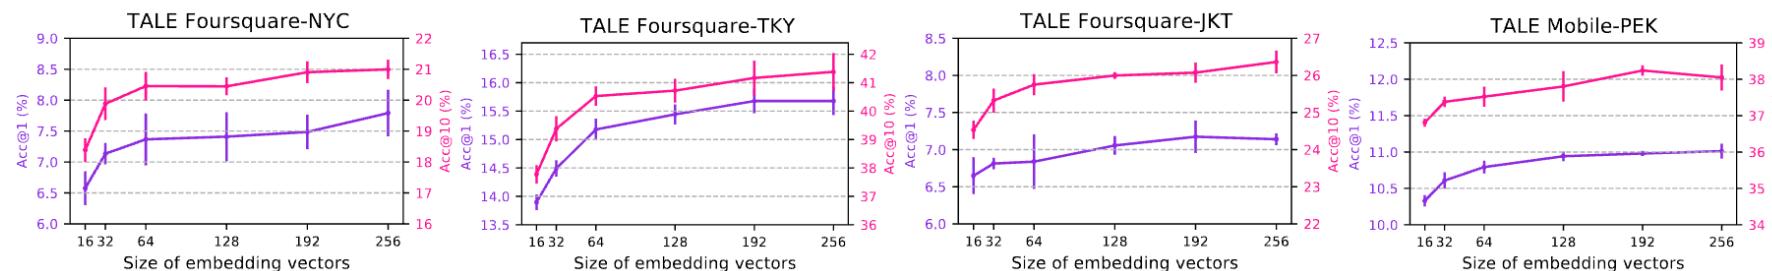
➤ 超参数效果分析



(a) 时间片长度的效果



(b) 影响范围长度的效果

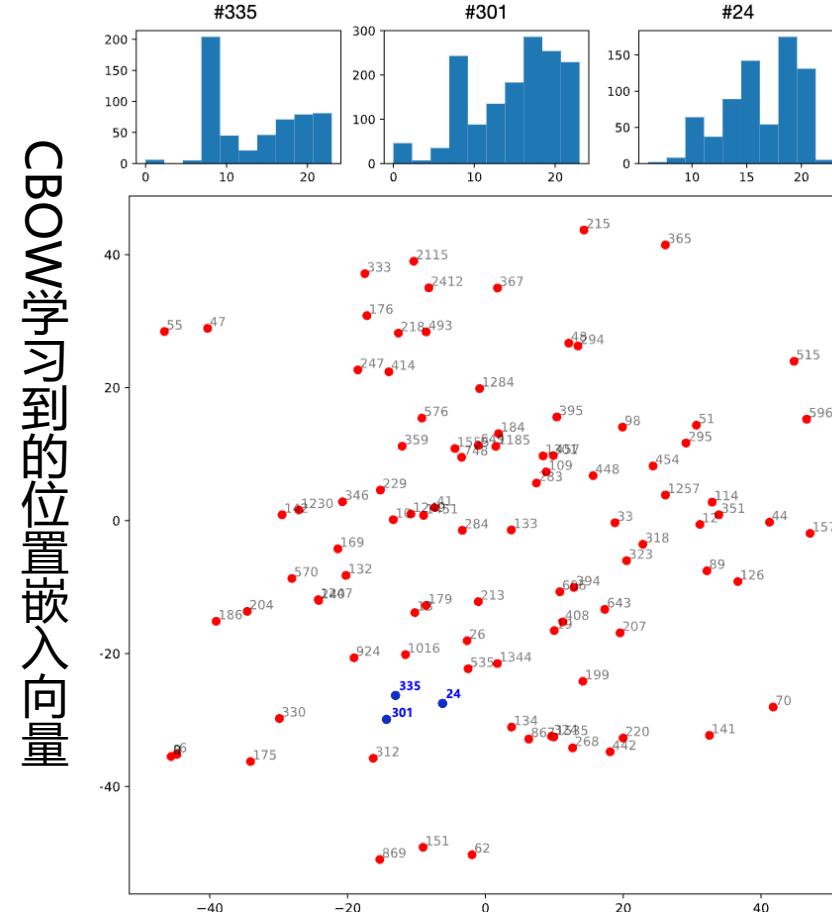
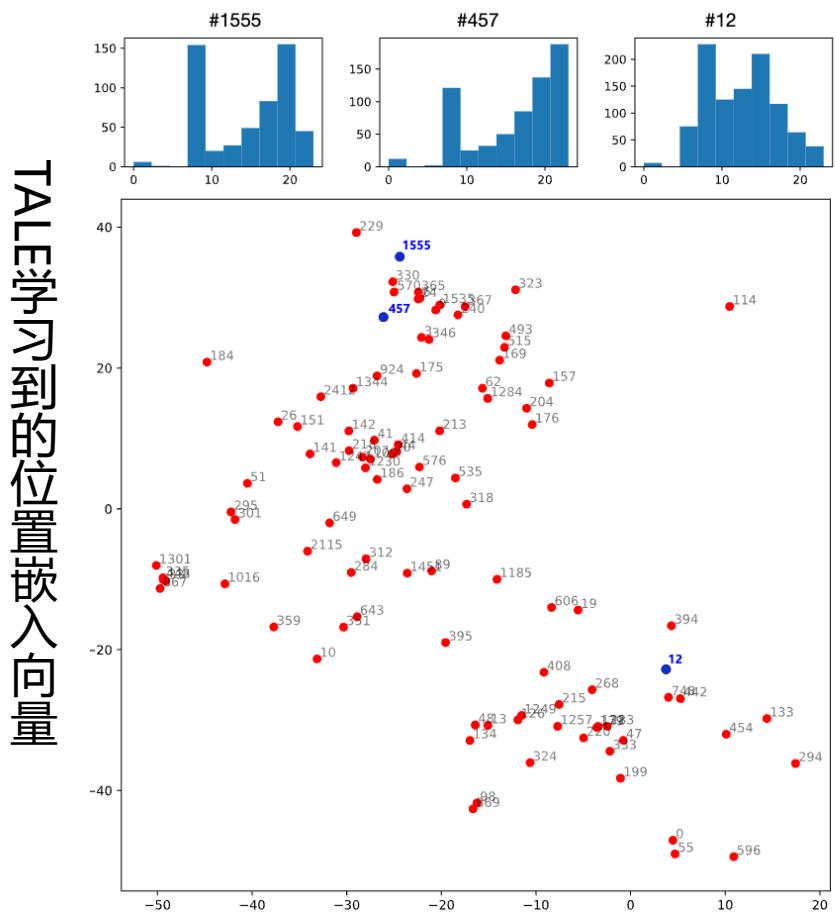


(c) 嵌入向量维度的效果

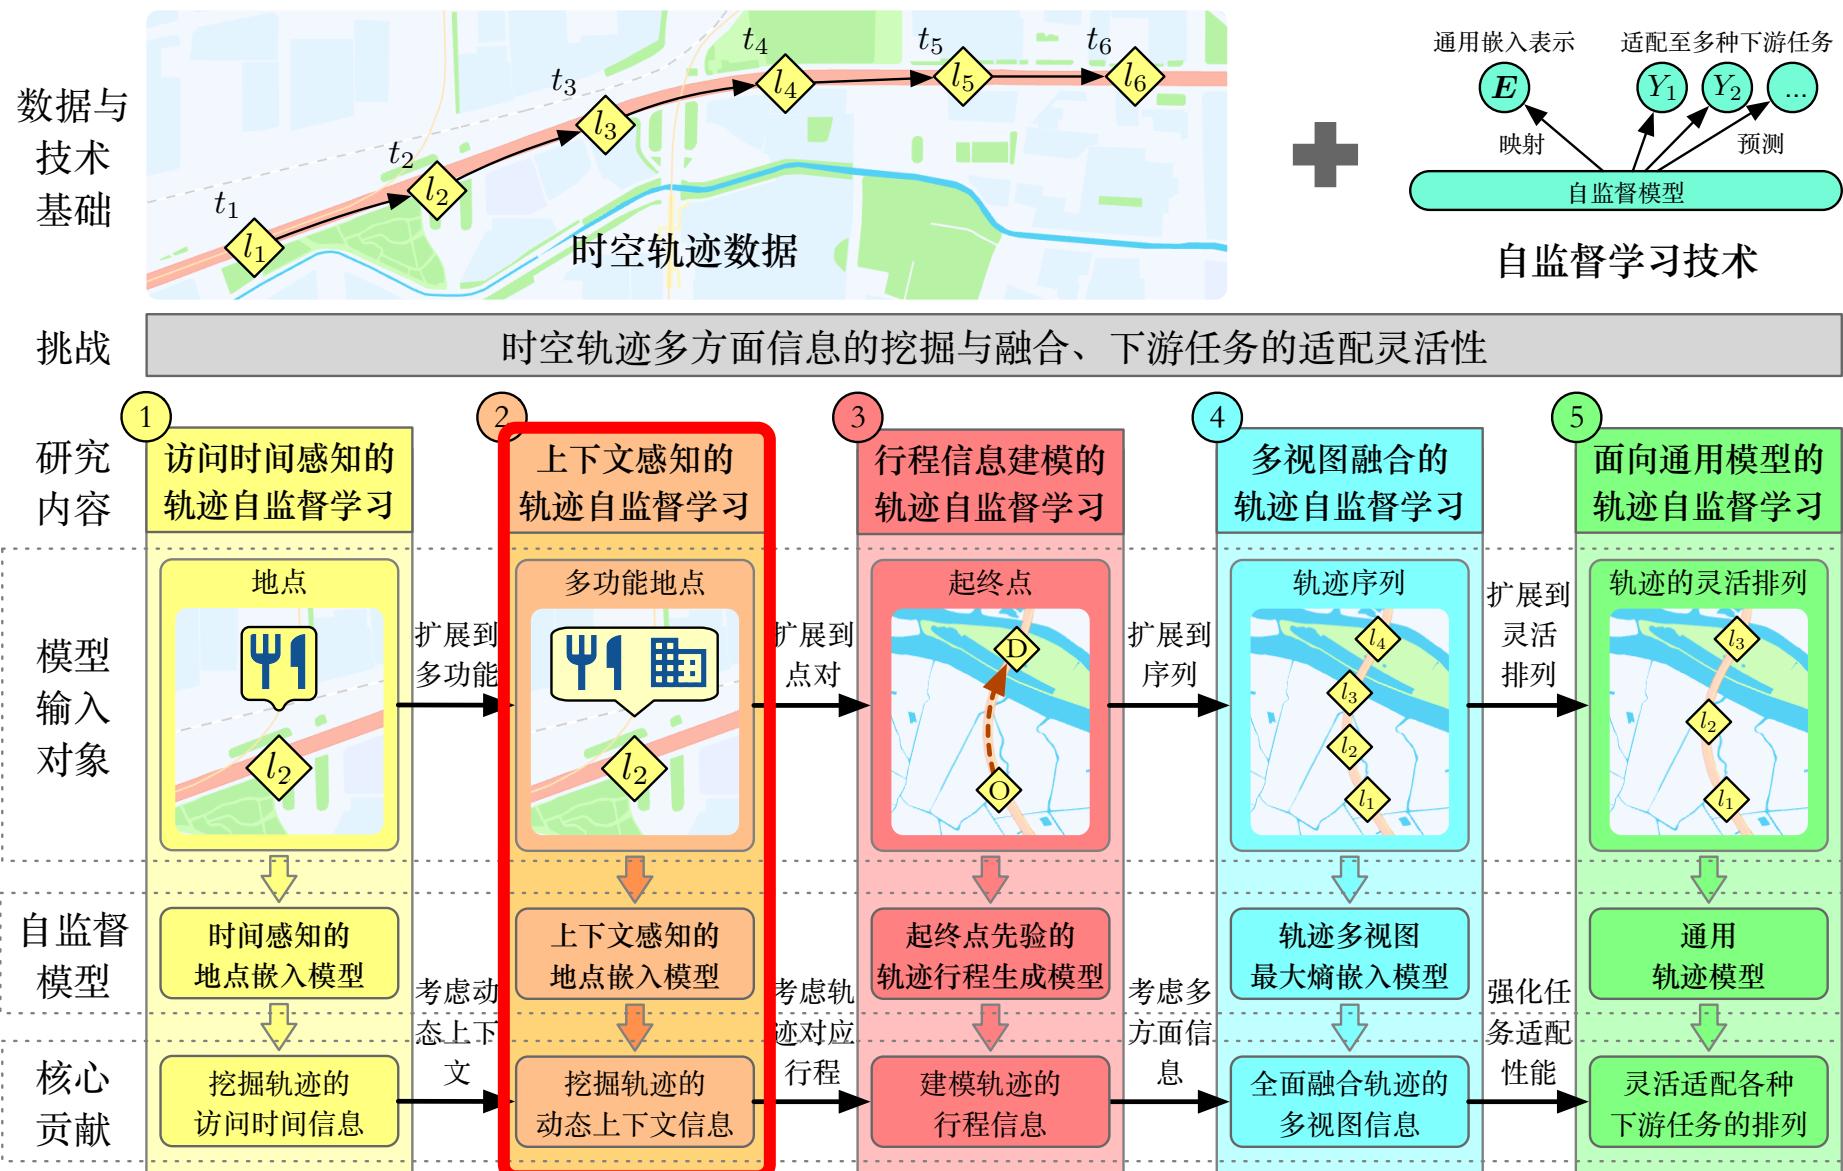
1-访问时间感知的轨迹自监督学习方法

➤ 嵌入向量可视化

- 为访问时间分布相似的地点学习相近的嵌入向量，将访问时间信息融入地点嵌入向量中



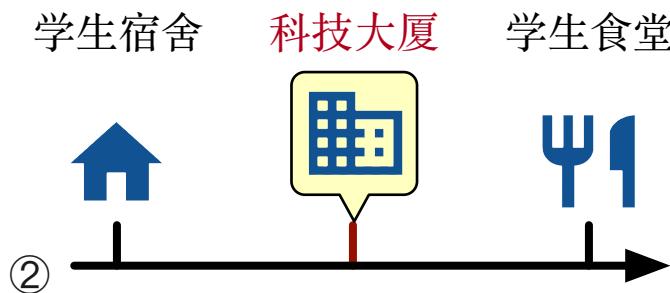
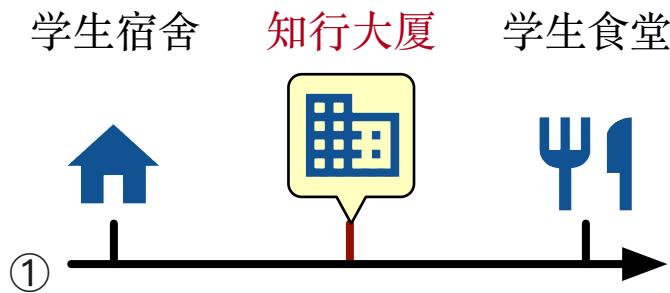
研究内容框架



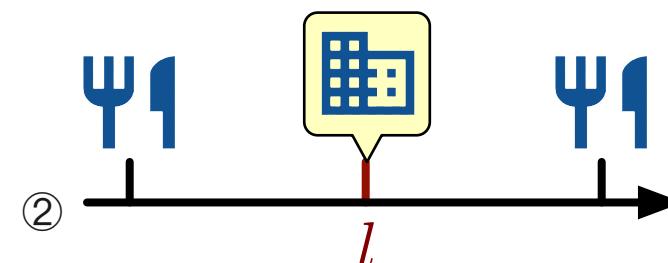
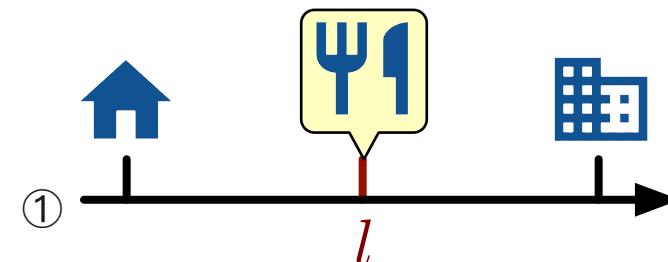
2-轨迹上下文感知的位置表示

➤ 挑战

- 同一地点在不同**上下文环境**中体现不同的功能性



上下文相似性体现的地点功能相似性



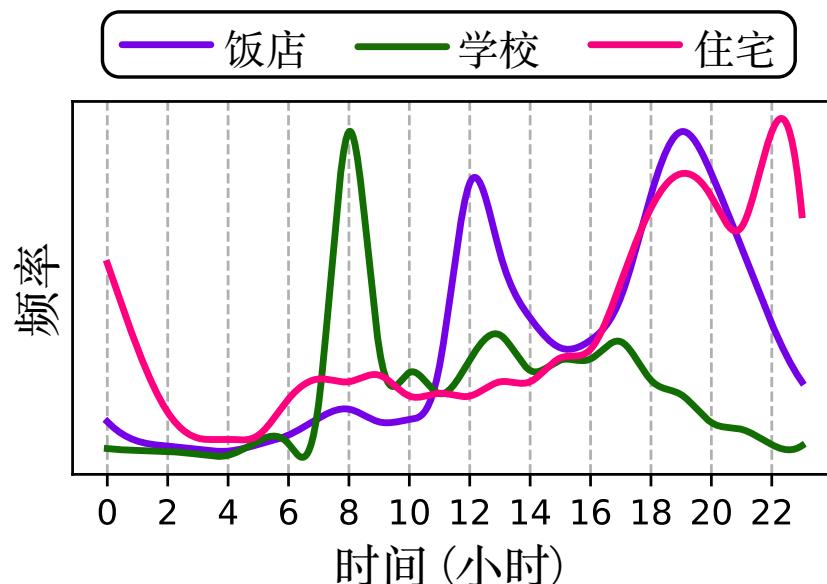
上下文环境体现的地点多功能性

- 现有地点嵌入方法**难以体现上下文环境的动态性**

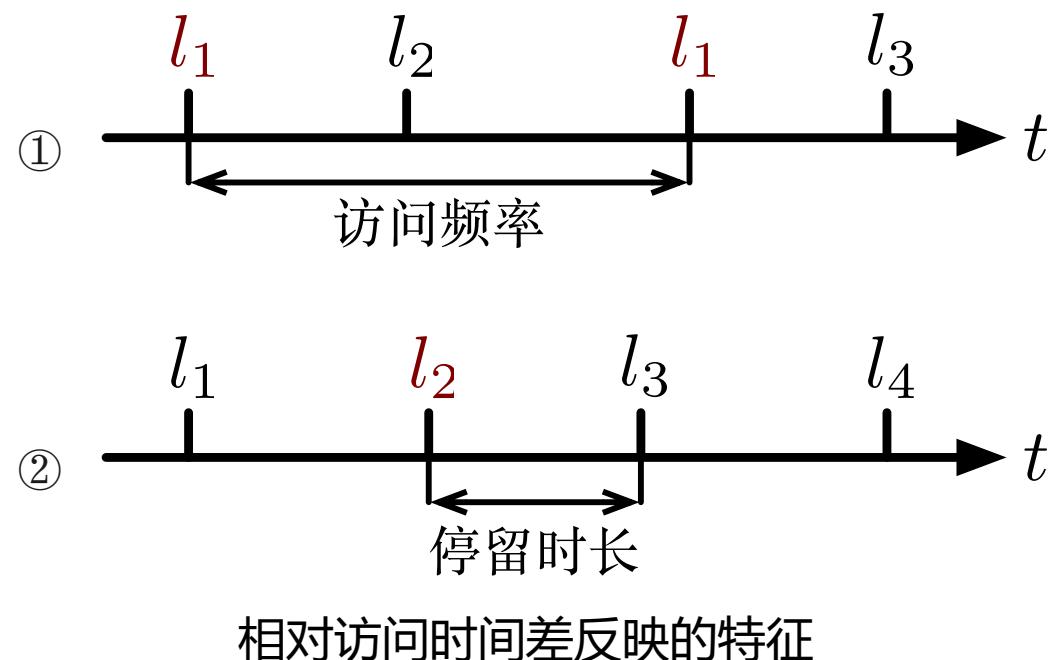
2-轨迹上下文感知的位置表示

➤ 挑战

- 地点的**两方面时间信息**体现不同的特征



绝对访问时间反映的功能特征



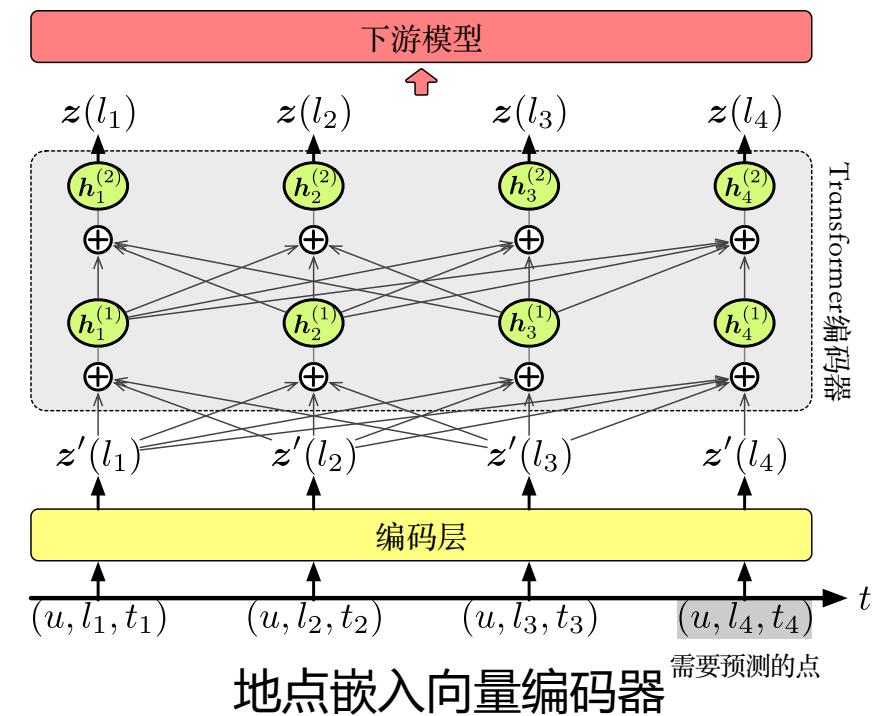
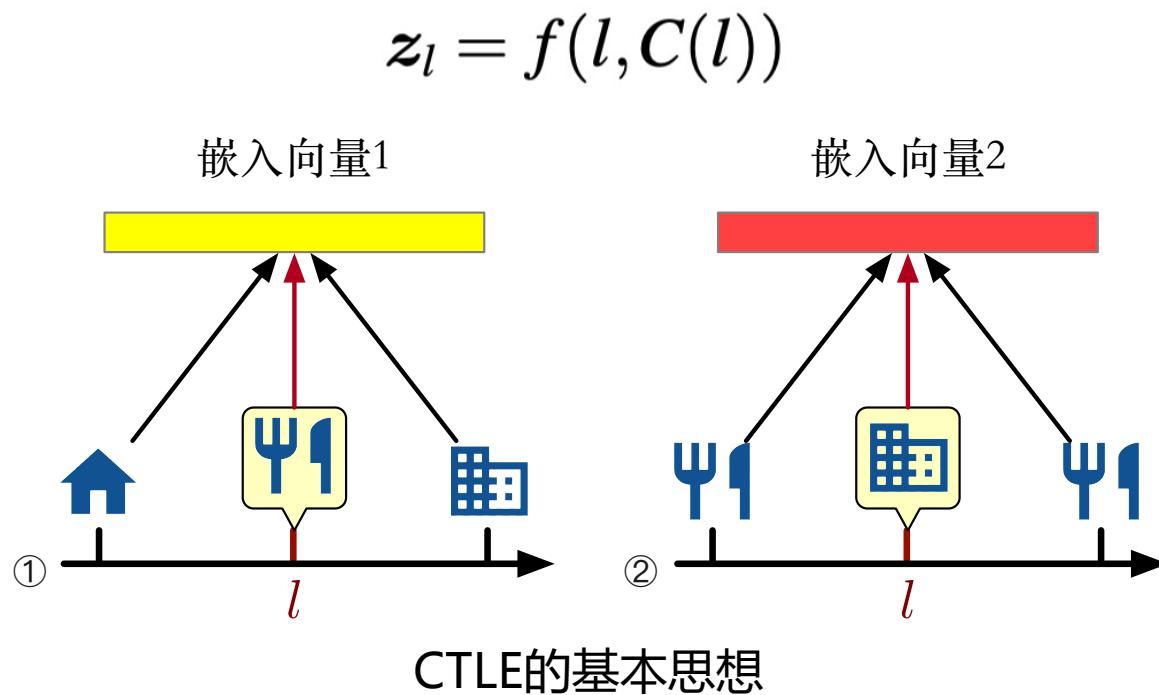
相对访问时间差反映的特征

- 现有地点嵌入方法**难以建模相对访问时间差信息**

2-轨迹上下文感知的位置表示

➤ 上下文与时间感知的地点嵌入 (CTLE) 模型

- 根据地点的上下文动态生成嵌入向量，学习更准确的位置表示
- 提出了基于Transformer的地点嵌入向量编码器，建模位置与上下文的动态关联性



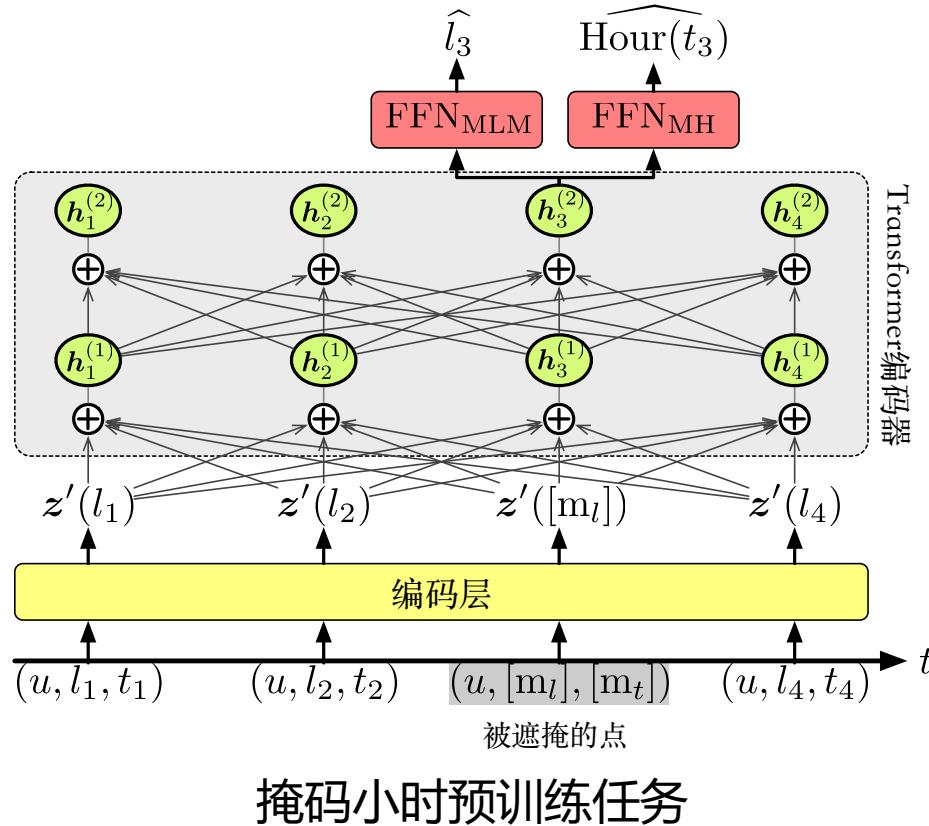
Yan Lin, Huaiyu Wan, et al. Pre-training Context and Time Aware Location Embeddings from Spatial-Temporal Trajectories for User Next Location Prediction. *The 35th AAAI Conference on Artificial Intelligence (AAAI)*, 2021, 35(5), 4241-4248.

2-轨迹上下文感知的位置表示

➤ 上下文与时间感知的地点嵌入 (CTLE) 模型

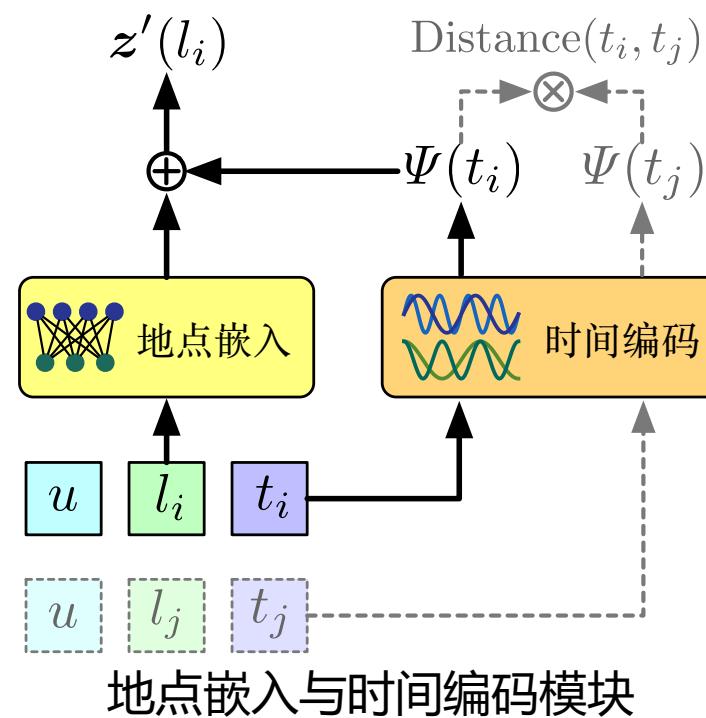
- 提出建模绝对访问时间的掩码小时预训练任务，以及建模相对访问时间差的时间编码模块

$$O_{\text{MH}} = \arg \max_{\theta} \sum_{t_m \in \Gamma} P(\text{Hour}(t_m) | \text{FFN}_{\text{MH}}(f(\tilde{\mathcal{T}})_m))$$



$$\Psi(t) = [\cos(\omega_1 t), \sin(\omega_1 t), \dots, \cos(\omega_d t), \sin(\omega_d t)]$$

$$\Psi(t) \cdot \Psi(t + \delta) = \cos(\omega_1 \delta) + \cos(\omega_2 \delta) + \dots + \cos(\omega_d \delta)$$



2-轨迹上下文感知的位置表示

➤ 实验设计

基线地点嵌入模型

- FC: 全连接网络
- Skip-gram: word2vec的一种实现方案
- POI2Vec: 融合了空间相关性的位置嵌入
- Geo-Teaser: 融合了工作日/周末区分的位置嵌入
- TALE: 研究内容1中提出的方法
- HIER: 基于N-gram的位置嵌入

下游任务与下游预测模型

➤ 轨迹预测

- ST-RNN: 融合时空特征的循环神经网络
- ERPP: 时空点过程模型
- ST-LSTM: 融合时空特征的长短期记忆模型

轨迹数据集

- 手机信令数据集

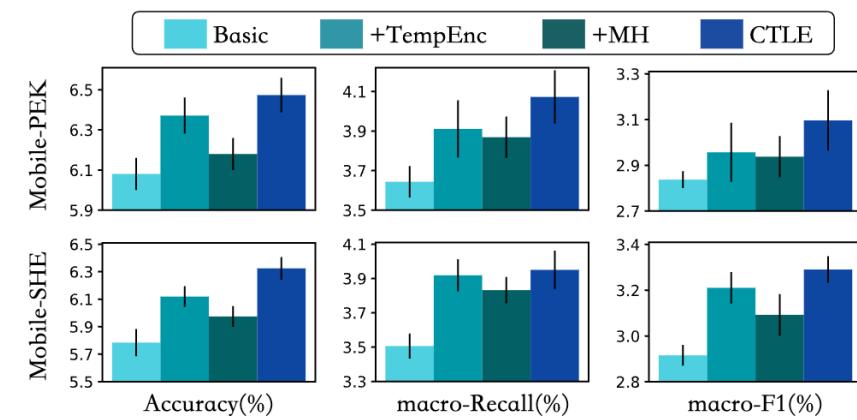
2-轨迹上下文感知的位置表示

实验结果

- 所提出模型能够提升轨迹预测任务的准确率

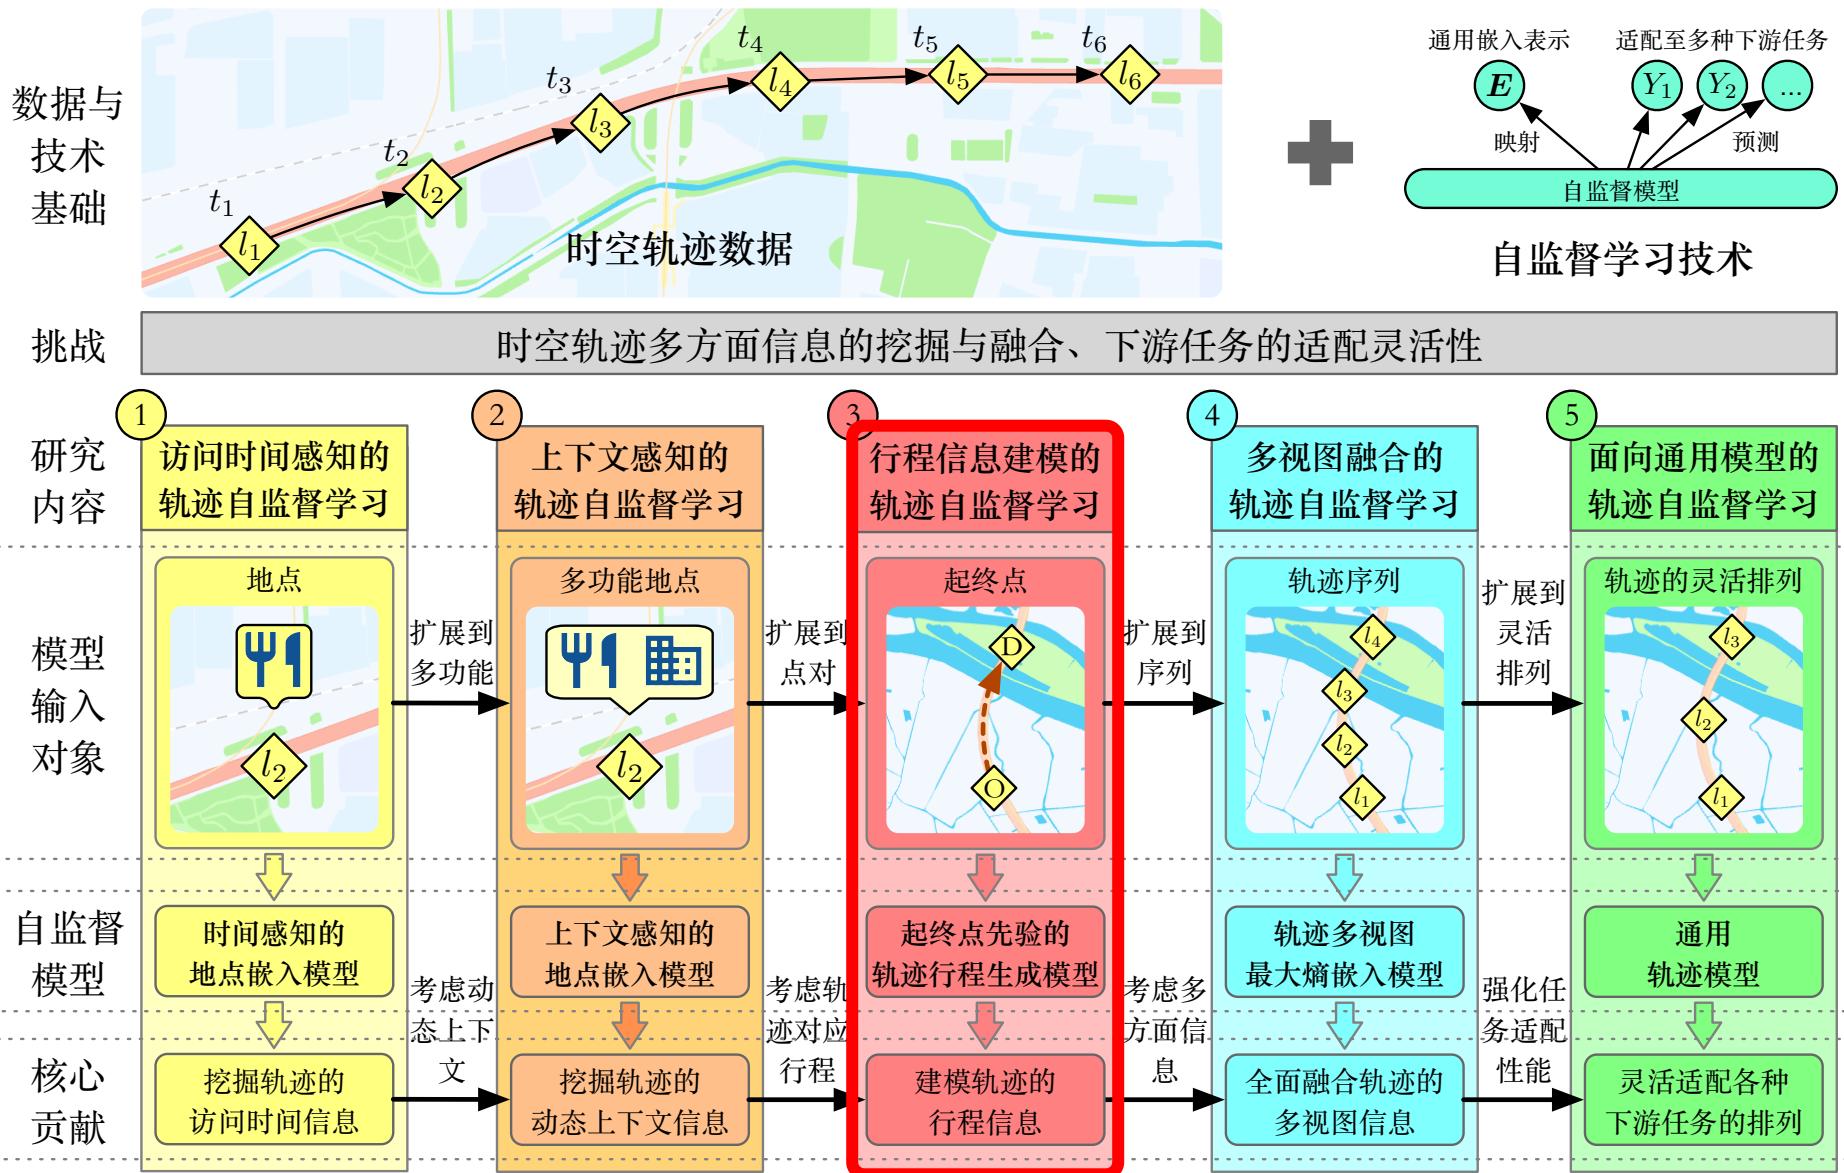
预测模型		ST-RNN			ERPP			ST-LSTM		
指标		Accuracy (%)	macro-Recall (%)	macro-F1 (%)	Accuracy (%)	macro-Recall (%)	macro-F1 (%)	Accuracy (%)	macro-Recall (%)	macro-F1 (%)
数据集	嵌入模型									
Mobile-PEK	FC Layer *	3.744±0.10	1.739±0.06	1.449±0.19	4.373±0.14	2.017±0.04	1.595±0.05	4.542±0.15	2.092±0.09	1.689±0.07
	Skip-gram	3.671±0.11	1.777±0.11	1.423±0.05	4.611±0.01	2.368±0.07	1.779±0.04	4.877±0.05	2.586±0.06	1.947±0.04
	POI2Vec	3.992±0.08	2.281±0.08	1.838±0.06	5.024±0.08	2.595±0.07	2.035±0.06	5.163±0.10	2.682±0.08	2.077±0.10
	Geo-Teaser	3.998±0.13	2.166±0.07	1.796±0.07	5.159±0.05	2.671±0.08	2.039±0.03	5.305±0.05	2.739±0.04	2.084±0.02
	TALE	4.199±0.05	2.240±0.07	1.815±0.06	5.457±0.03	3.237±0.07	2.587±0.03	5.511±0.05	3.152±0.10	2.486±0.13
	HIER	4.339±0.04	2.440±0.07	1.862±0.08	5.607±0.09	2.870±0.08	2.176±0.04	5.589±0.15	2.839±0.11	2.165±0.02
	CTLE (ours)	5.068±0.05	2.890±0.11	2.312±0.02	6.481±0.05	4.002±0.04	3.066±0.06	6.473±0.09	4.072±0.13	3.097±0.13
Mobile-SHE	FC Layer *	3.674±0.07	2.408±0.07	1.946±0.05	4.343±0.18	2.454±0.10	2.037±0.09	4.416±0.20	2.450±0.14	2.005±0.11
	Skip-gram	3.646±0.05	2.278±0.08	1.809±0.05	4.405±0.06	2.459±0.06	1.974±0.05	4.508±0.05	2.507±0.07	1.998±0.07
	POI2Vec	3.936±0.04	2.605±0.04	2.084±0.03	4.923±0.06	2.992±0.02	2.408±0.02	4.930±0.07	2.890±0.10	2.305±0.08
	Geo-Teaser	4.006±0.05	2.455±0.03	1.897±0.02	4.932±0.12	2.895±0.02	2.410±0.07	5.130±0.15	2.754±0.07	2.245±0.06
	TALE	4.689±0.10	3.444±0.09	2.761±0.08	5.179±0.09	3.446±0.06	2.883±0.04	5.204±0.06	3.399±0.11	2.787±0.11
	HIER	4.539±0.22	3.117±0.15	2.521±0.09	5.624±0.16	3.273±0.17	2.708±0.18	5.672±0.09	3.252±0.07	2.680±0.05
	CTLE (ours)	5.124±0.20	3.392±0.11	2.720±0.07	6.311±0.04	3.984±0.05	3.340±0.07	6.325±0.08	3.950±0.11	3.291±0.06

轨迹预测任务性能比较



组件分析

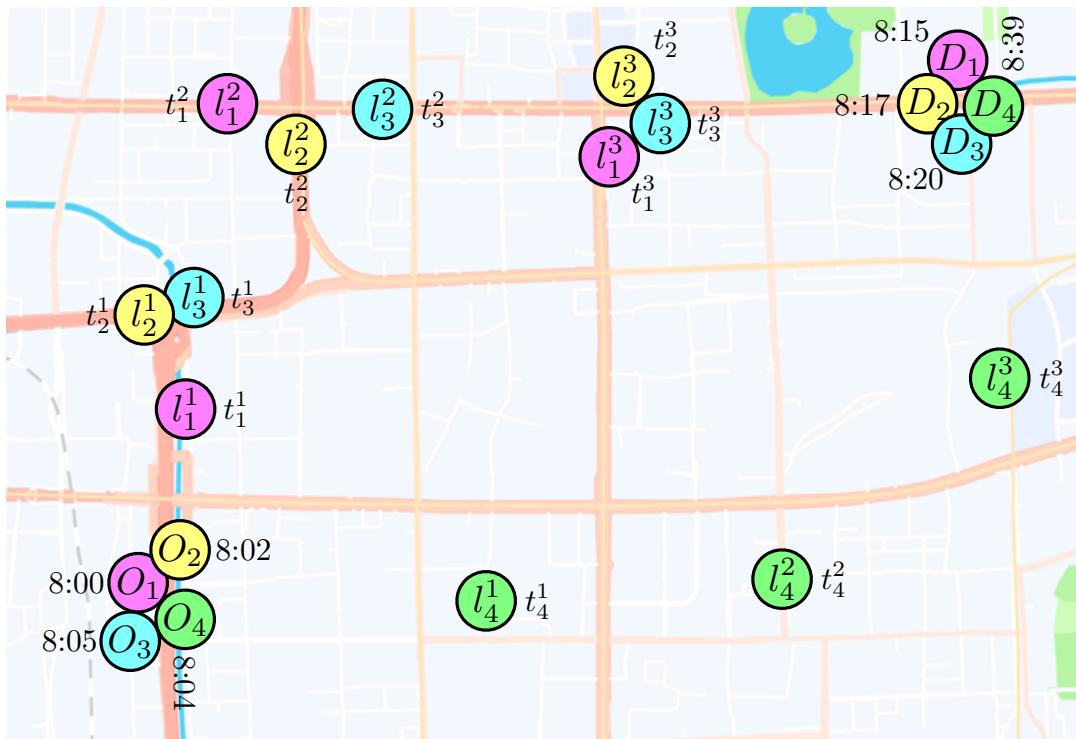
研究内容框架



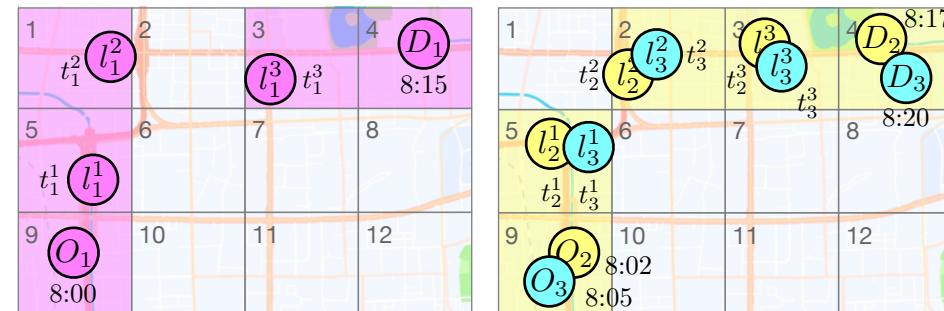
3-行程信息建模的轨迹自监督学习

➤ 挑战

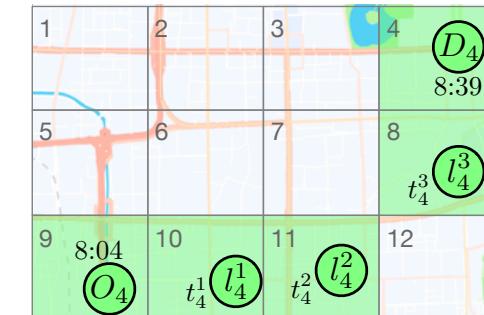
- 从轨迹行程中挖掘旅行时间、路线偏好等信息



行程信息与旅行时间的关联性



相似但包含噪音的轨迹行程



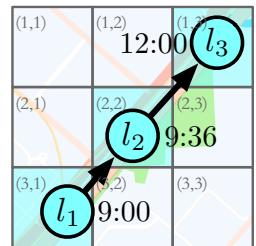
异常的轨迹行程

- 轨迹中包含噪音和异常值，影响模型建模轨迹行程的有效性

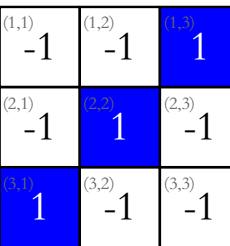
3-行程信息建模的轨迹自监督学习

➤ 像素化轨迹

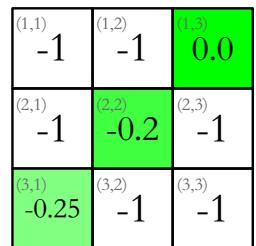
- 将轨迹行程表示为像素化轨迹 (PiT)，增强对轨迹点噪音和异常值的鲁棒性



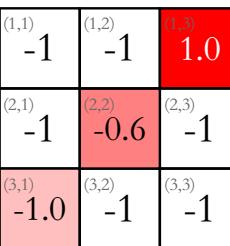
轨迹



(1) 掩码

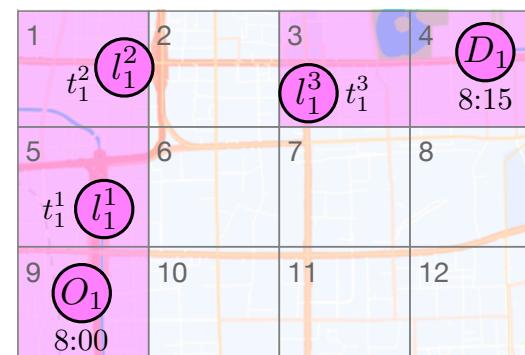


(2) 一天中的时间

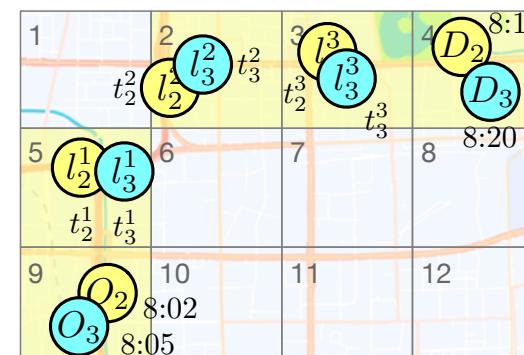


(3) 时间偏移

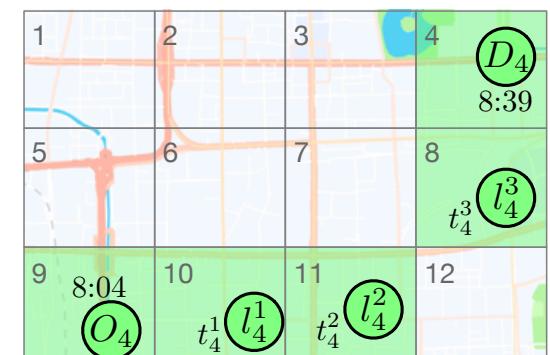
像素化轨迹的特征通道



(a) PiT of \mathcal{T}_1



(b) PiT of $\mathcal{T}_2, \mathcal{T}_3$



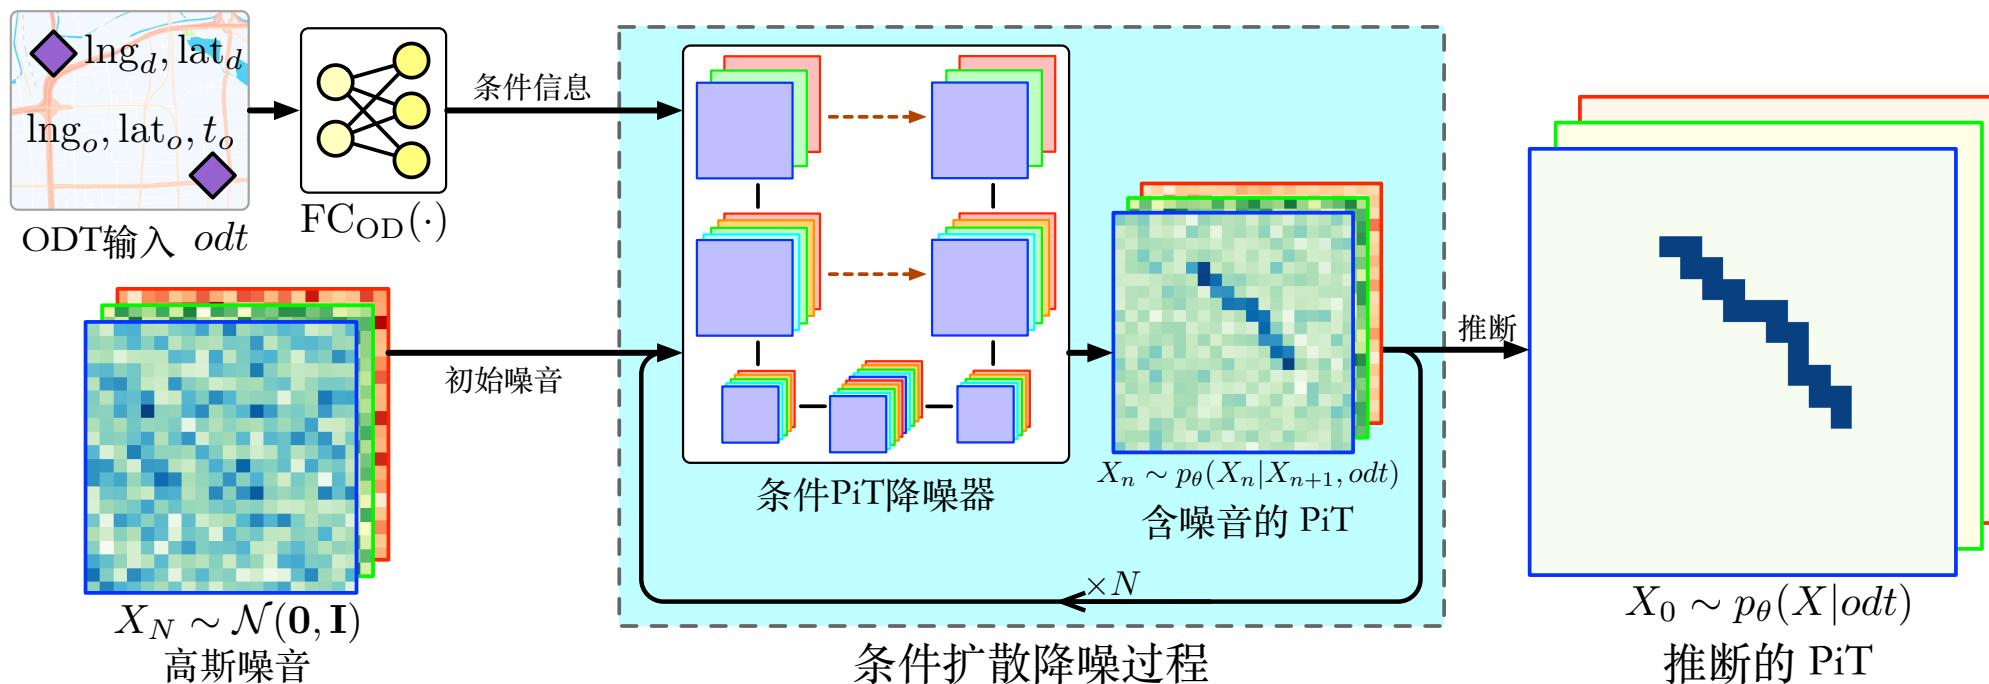
(c) PiT of \mathcal{T}_4

像素化轨迹的鲁棒性设计

3-行程信息建模的轨迹自监督学习

➤ 起终点先验的轨迹行程生成模型

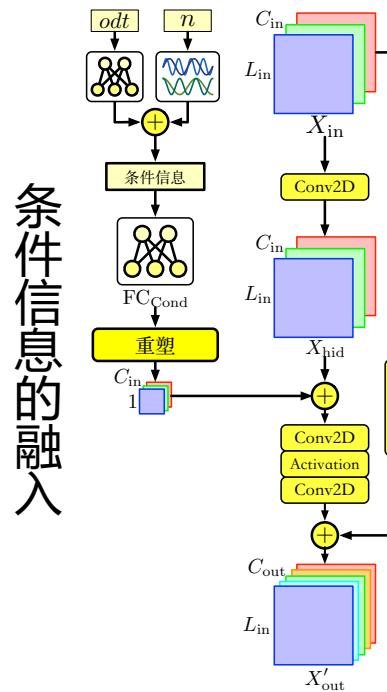
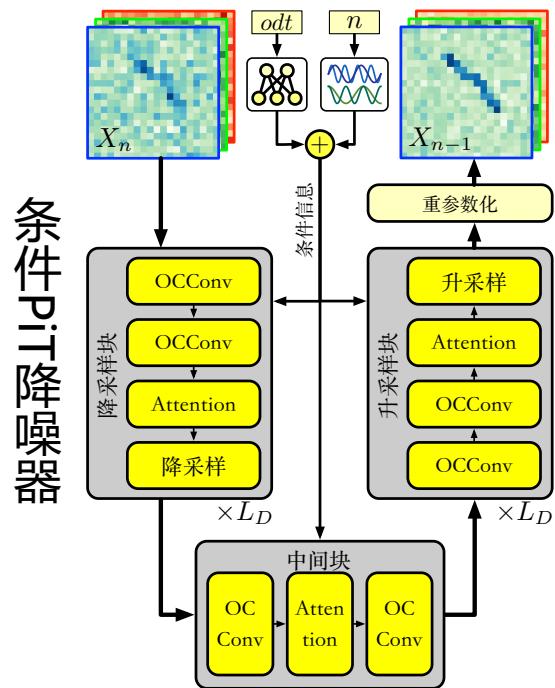
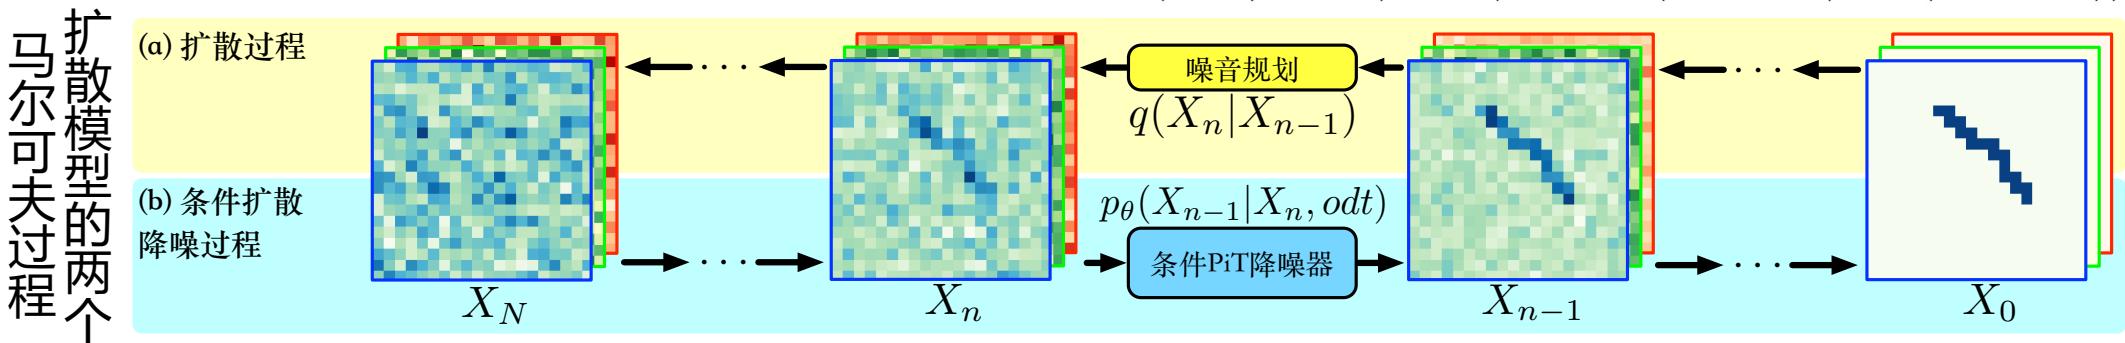
- 在给定起终点和出发时间的条件下，生成对应的像素化轨迹
- 建模轨迹行程与起终点的关联性



Yan Lin, Huaiyu Wan, et al. Origin-Destination Travel Time Oracle for Map-based Services. *The 2024 International Conference on Management of Data (SIGMOD)*, 2024, 1(3), 217.

3-行程信息建模的轨迹自监督学习

➤ 基于扩散模型的PiT生成

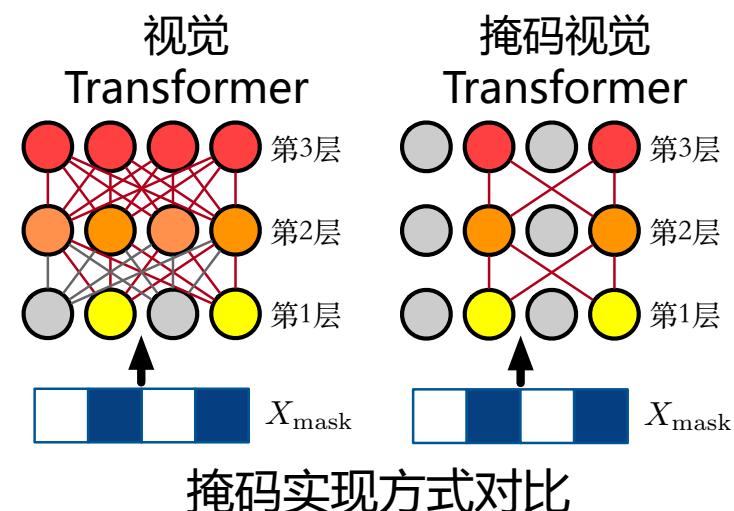
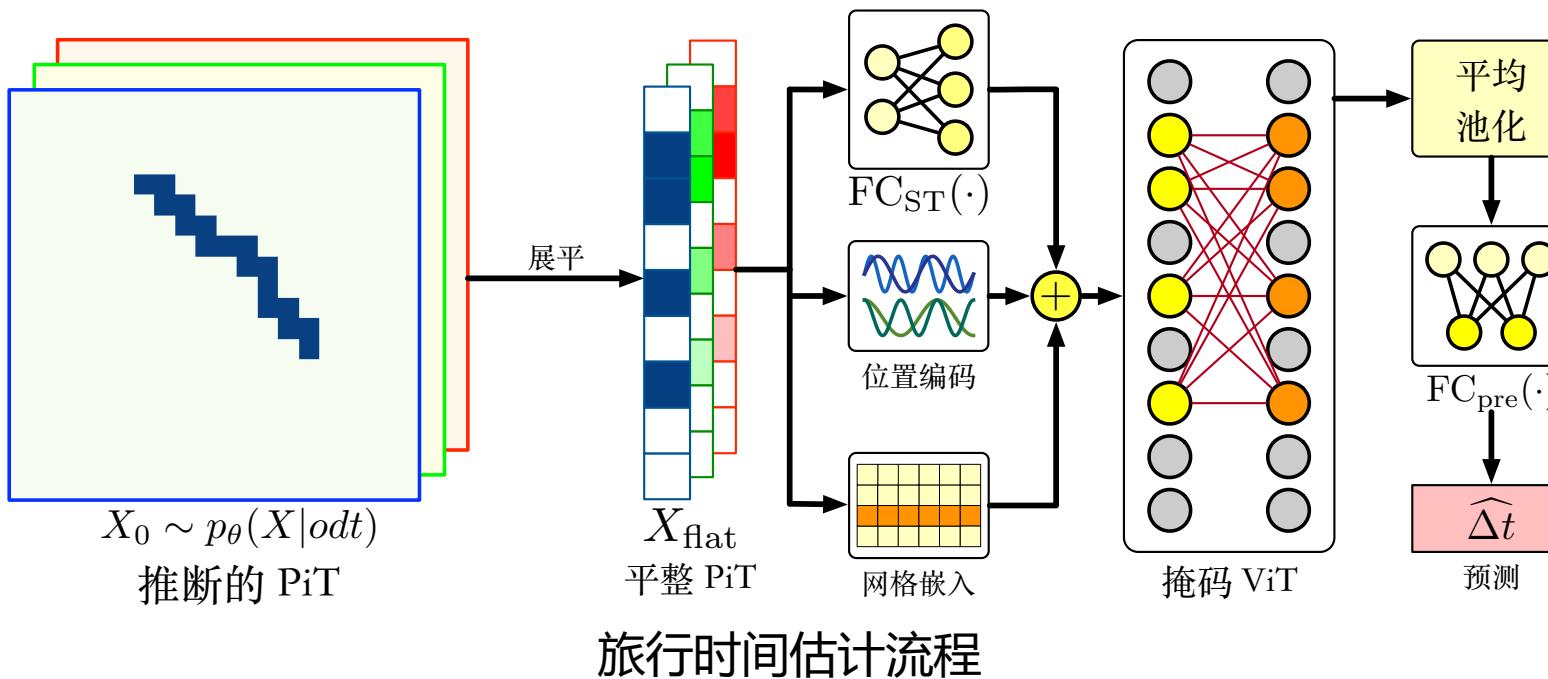


3-行程信息建模的轨迹自监督学习

➤ 下游应用：旅行时间估计

- 生成的轨迹行程可进一步用于旅行时间估计任务
- 提出一种掩码视觉Transformer，更加高效地完成旅行时间估计任务

$$X'_{\text{latent}} = \text{MViT}(X_{\text{latent}}, X_{\text{mask}}) \quad \hat{\Delta t} = \text{FC}_{\text{pre}}(\text{mean}(X'_{\text{latent}}))$$



3-行程信息建模的轨迹自监督学习

➤ 实验设计

基线模型

➤ 行程生成方法

- Dijkstra: 最短路径算法
- DeepST: 基于深度学习的路径生成

➤ 轨迹旅行时间估计方法

- WDDRA: 多任务旅行时间估计模型
- STDGCN: 基于深度网络结构自动搜索的模型

➤ 起终点旅行时间估计方法

- TEMP: 历史相似起终点平均
- LR: 线性回归
- GBM: 基于集成学习的非线性回归
- ST-NN: 根据起终点估计旅行时间
- MURAT: 根据起终点和出发时间估计旅行时间
- DeepOD: 建模起终点与历史轨迹的方法

下游任务

➤ 起终点行程生成

➤ 起终点旅行时间估计

轨迹数据集

- 车辆定位数据集

3-行程信息建模的轨迹自监督学习

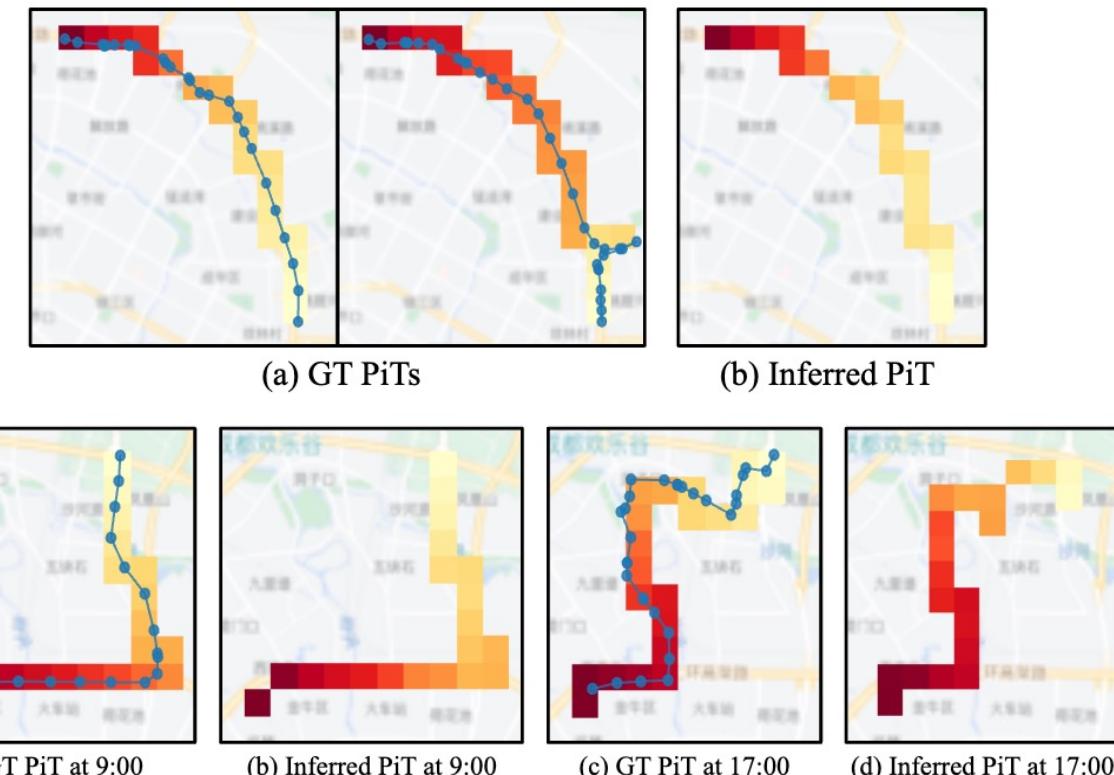
➤ 行程生成结果

- 所提出模型能够生成准确的轨迹行程，并对轨迹点噪音具备鲁棒性

数据集	成都 / 哈尔滨	
指标	RMSE	MAE
Overall	0.196/0.181	0.027/0.023
Channel 1 (Mask)	0.271/0.224	0.039/0.028
Channel 2 (ToD)	0.128/0.183	0.016/0.024
Channel 3 (Offset)	0.159/0.123	0.025/0.016

数据集	成都 / 哈尔滨		
指标	Pre(%)	Rec(%)	F1(%)
Dijkstra	68.918/45.459	31.310/42.525	42.065/39.993
DeepST	59.755/74.519	55.776/62.907	56.911/66.029
IGOP	87.890/88.190	88.684/88.982	88.280/88.584

轨迹行程生成准确率对比



轨迹行程生成案例分析

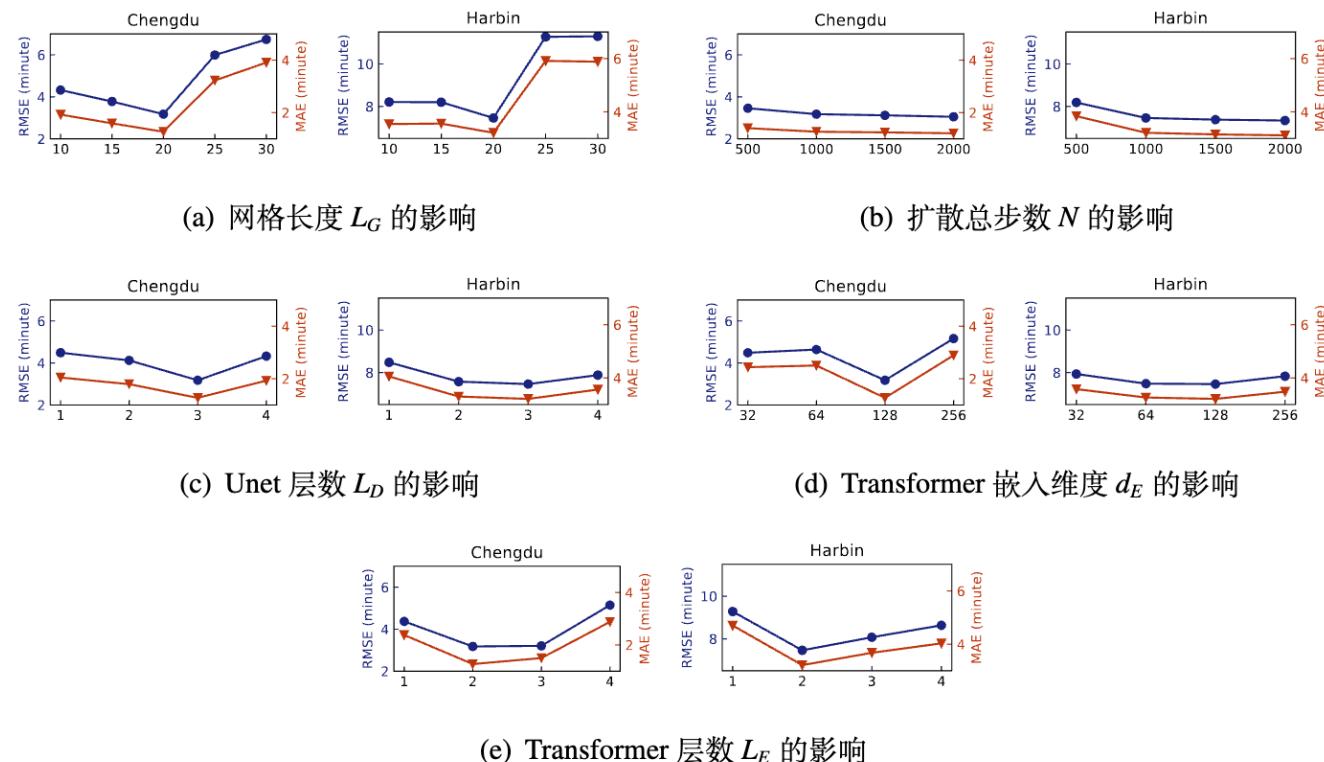
3-行程信息建模的轨迹自监督学习

➤ 旅行时间估计结果

- 相较于现有方法，所提出模型能够提升旅行时间估计任务的准确率

数据集	成都 / 哈尔滨		
指标	RMSE (分钟)	MAE (分钟)	MAPE (%)
Dijkstra	9.677/11.865	7.618/8.447	48.618/55.261
DeepST	4.717/8.926	3.452/5.849	27.503/37.772
WDDRA	4.581/8.836	3.210/5.705	24.553/35.617
STDGCN	4.469/8.679	3.104/5.564	23.187/33.771
TEMP	5.578/10.150	4.267/7.891	36.611/66.781
LR	6.475/10.290	5.036/8.006	44.514/67.669
GBM	4.999/9.069	3.655/6.748	29.636/54.413
RNE	4.624/8.571	3.416/6.245	27.660/47.956
ST-NN	3.961/8.492	2.803/6.114	21.532/45.891
MURAT	3.646/7.937	2.384/5.360	18.345/41.128
DeepOD	3.764/7.859	1.789/4.533	14.997/36.974
IGOP	3.177/7.462	1.272/3.213	11.343/26.698

总体准确率对比



超参数效果分析

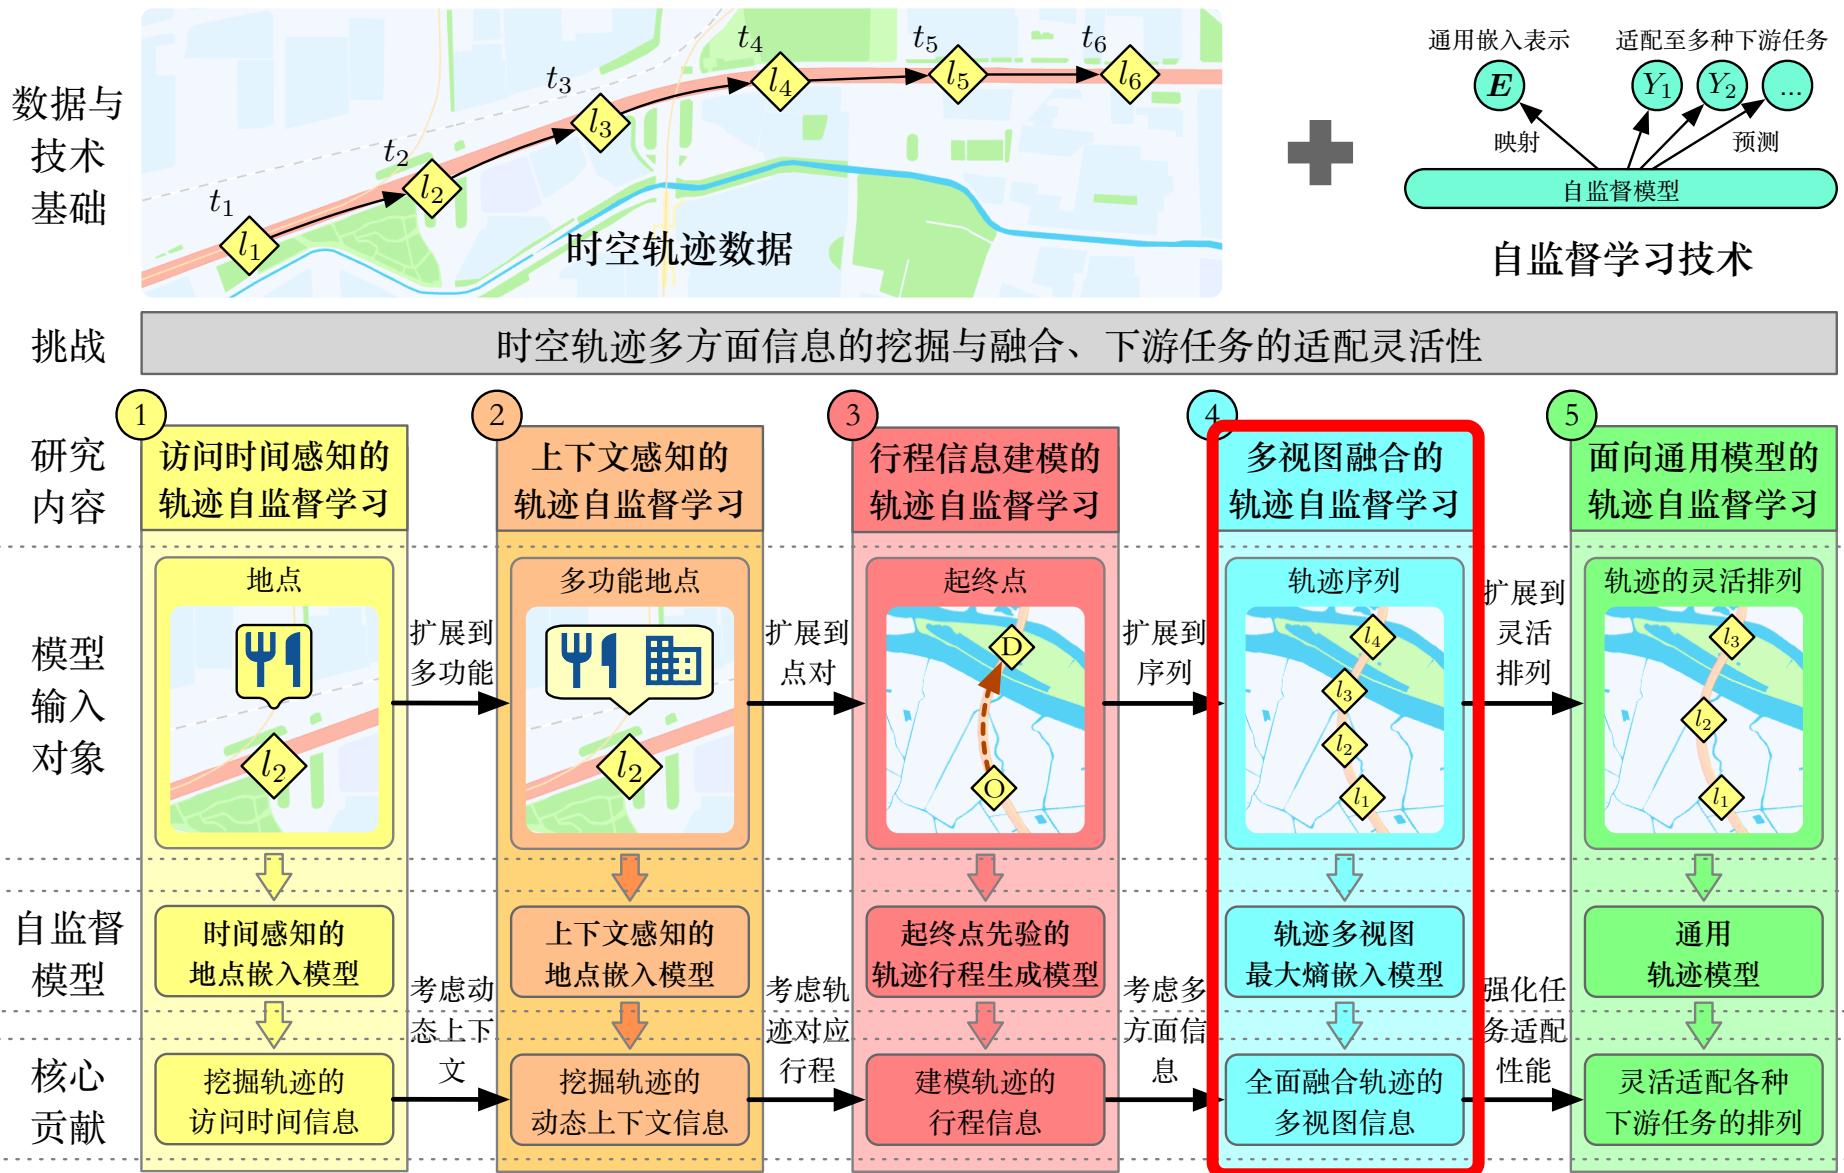
3-行程信息建模的轨迹自监督学习

➤ 鲁棒性验证

- 相较于现有方法，所提出模型对于异常值有**更强的鲁棒性**

数据集	成都 / 哈尔滨		
指标	RMSE (分钟)	MAE (分钟)	MAPE (%)
Dijkstra+DeepTEA	9.641/11.862	7.582/8.396	48.337/53.949
DeepST+DeepTEA	4.692/8.901	3.416/5.821	26.959/37.063
WDDRA+DeepTEA	4.497/8.584	3.140/5.545	23.537/34.723
STDGCN+DeepTEA	4.393/8.569	3.056/5.501	22.812/33.688
RNE+DeepTEA	4.627/8.403	3.447/6.061	28.239/45.345
ST-NN+DeepTEA	3.912/8.427	2.740/5.994	20.818/43.664
MURAT+DeepTEA	<u>3.644</u> /7.899	2.367/5.181	17.986/37.728
DeepOD+DeepTEA	<u>3.763</u> / <u>7.817</u>	<u>1.783</u> / <u>4.345</u>	<u>14.835</u> / <u>33.127</u>
IGOP	3.177/7.462	1.272/3.213	11.343/26.698

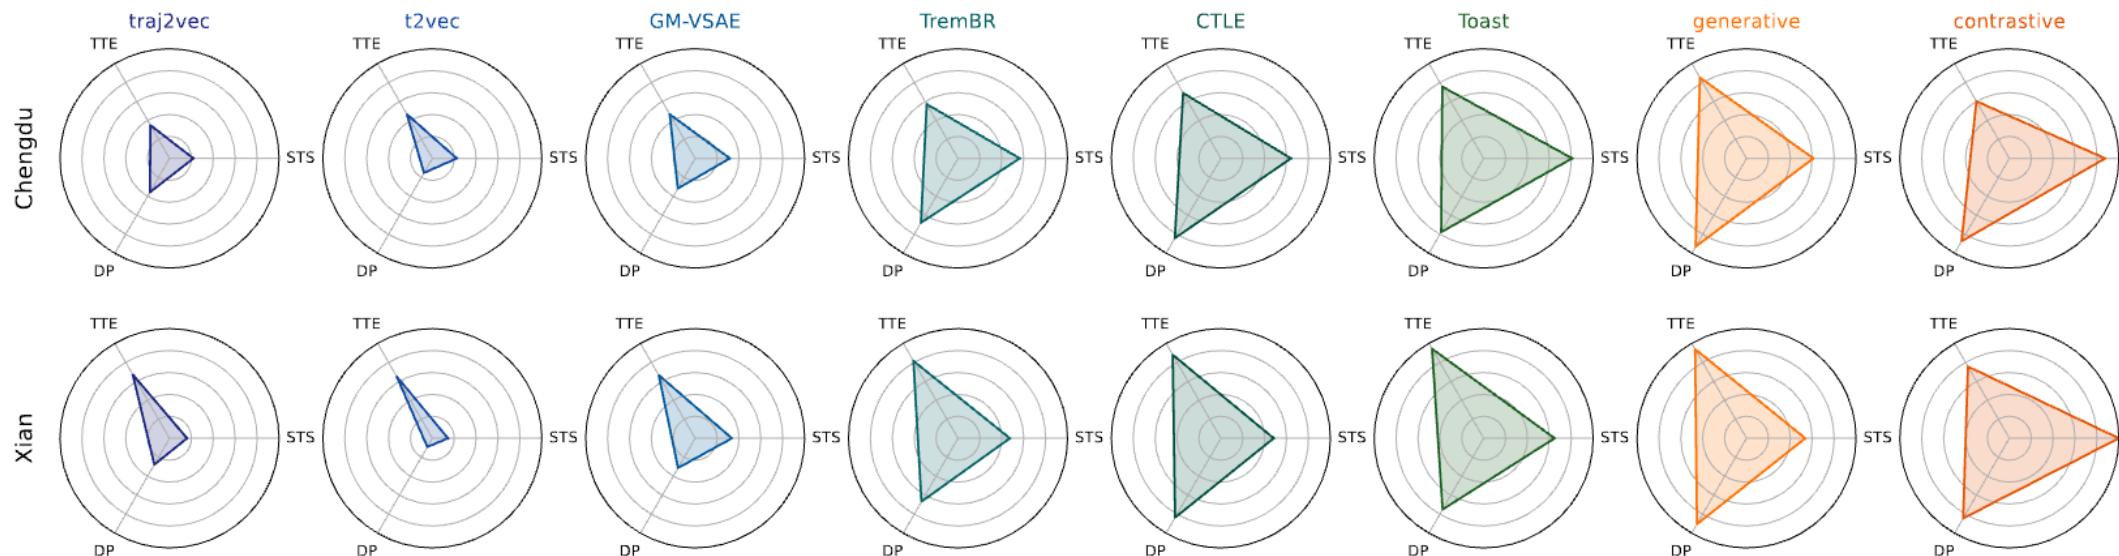
研究内容框架



4-多视图融合的轨迹自监督学习

➤ 挑战

- 有效建模并融合轨迹中的多方面信息，为不同的下游任务提供有用的特征



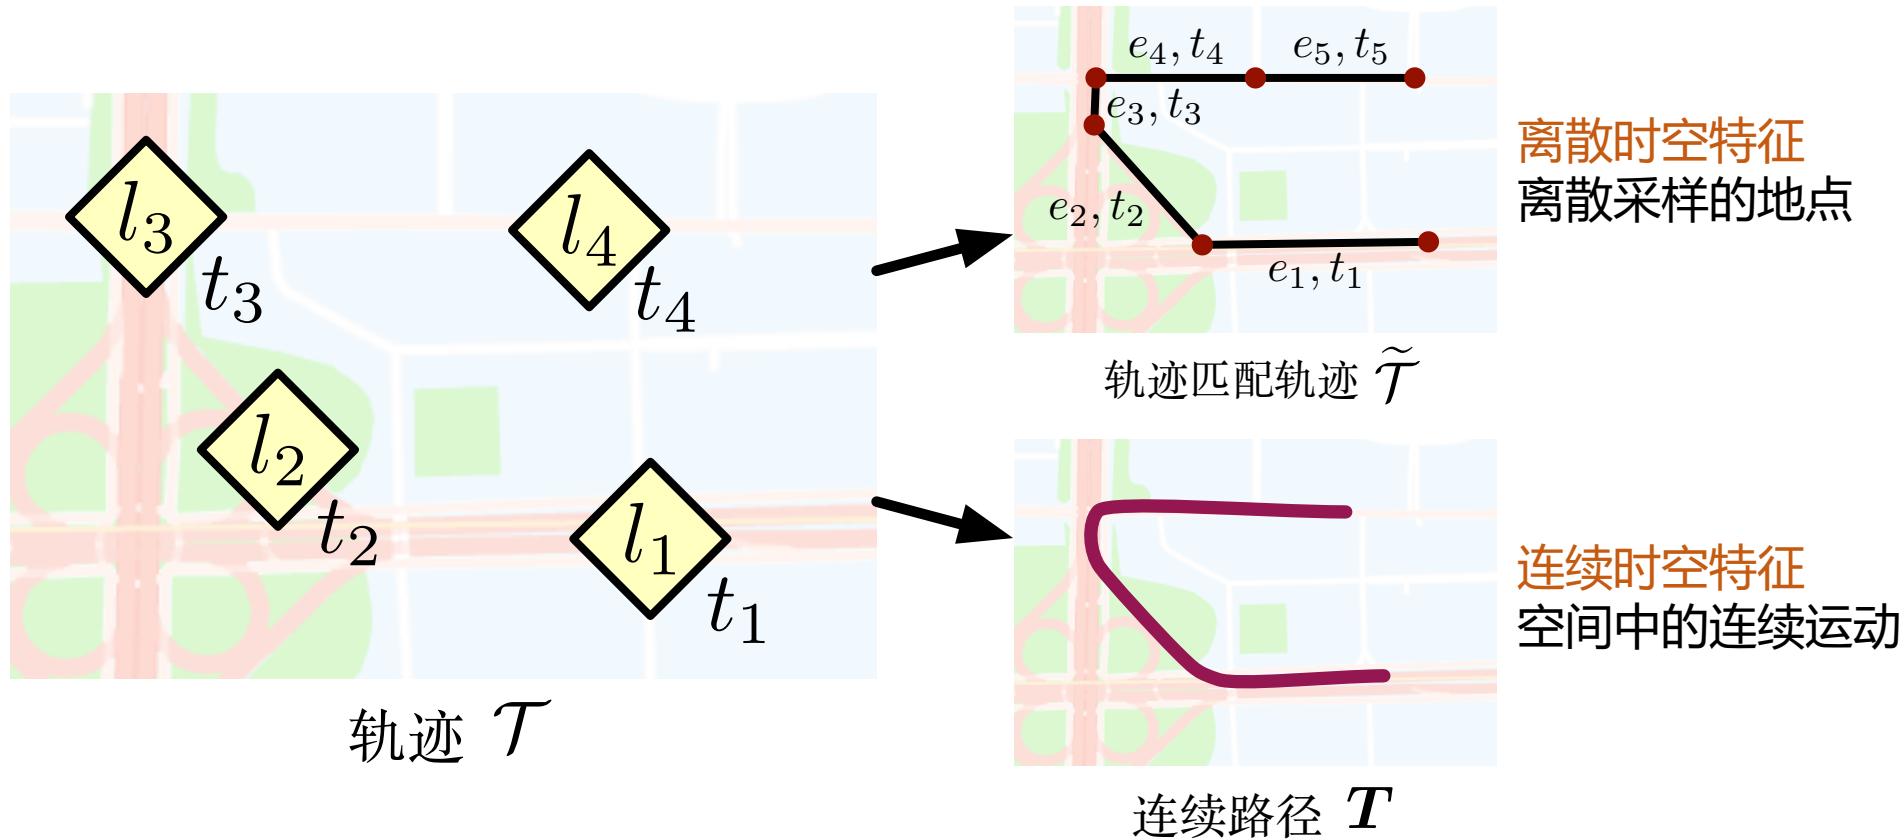
现有自监督学习模型在三种任务上的相对性能

- 现有基于自编码或对比学习的自监督学习难以有效建模并融合多方面信息

4-多视图融合的轨迹自监督学习

➤ 轨迹多方面信息建模

- 将轨迹中的信息总结为离散/连续时空两个视图

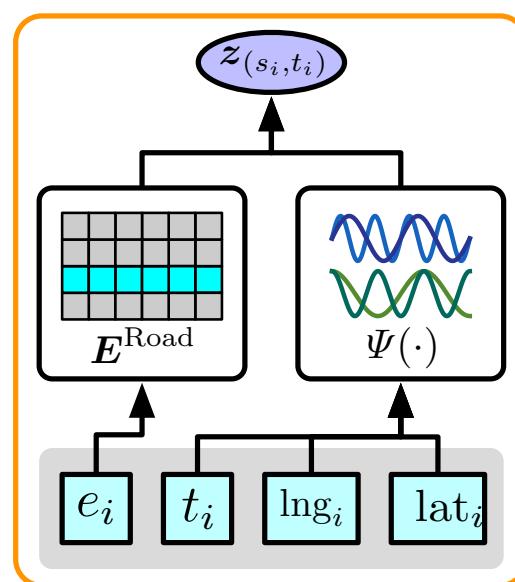


4-多视图融合的轨迹自监督学习

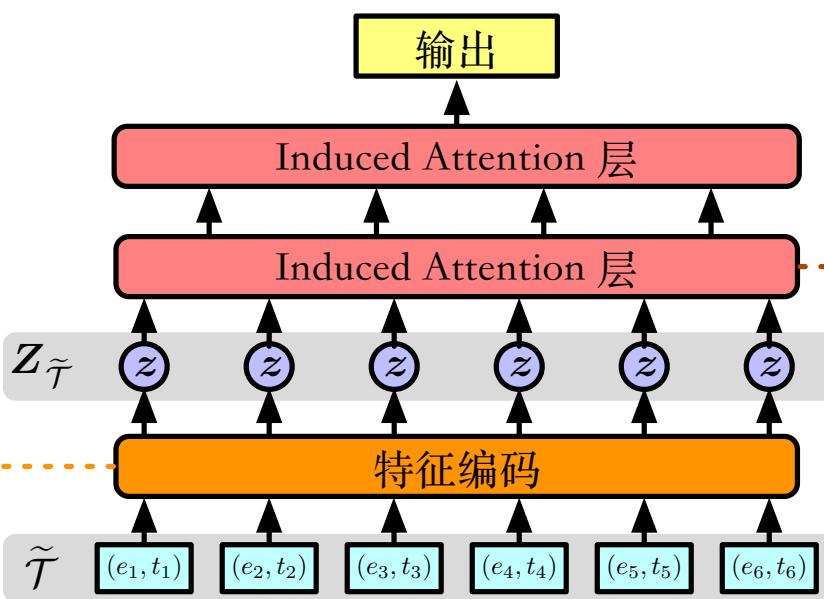
➤ 轨迹多方面信息建模

- 提出基于注意力的离散轨迹编码器，高效建模离散时空视图

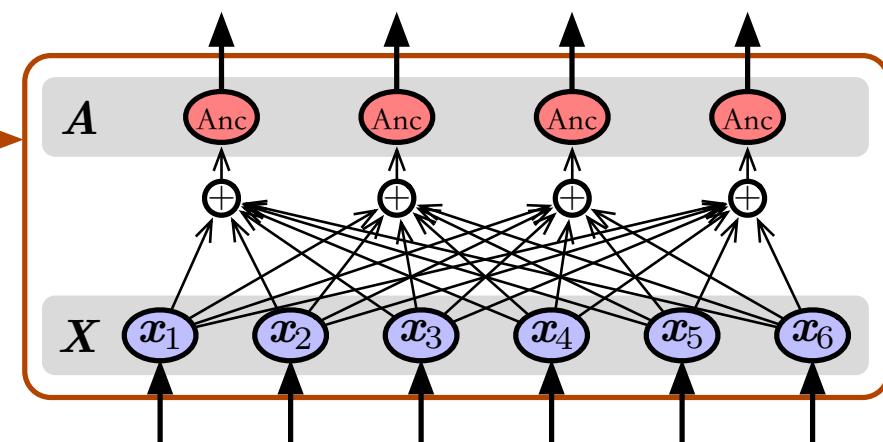
$$\text{DisEnc}(\tilde{\mathcal{T}}) = \text{IA}_2(\text{IA}_1(Z_{\tilde{\mathcal{T}}}))$$



(a) 编码路段特征



(b) 离散轨迹编码器

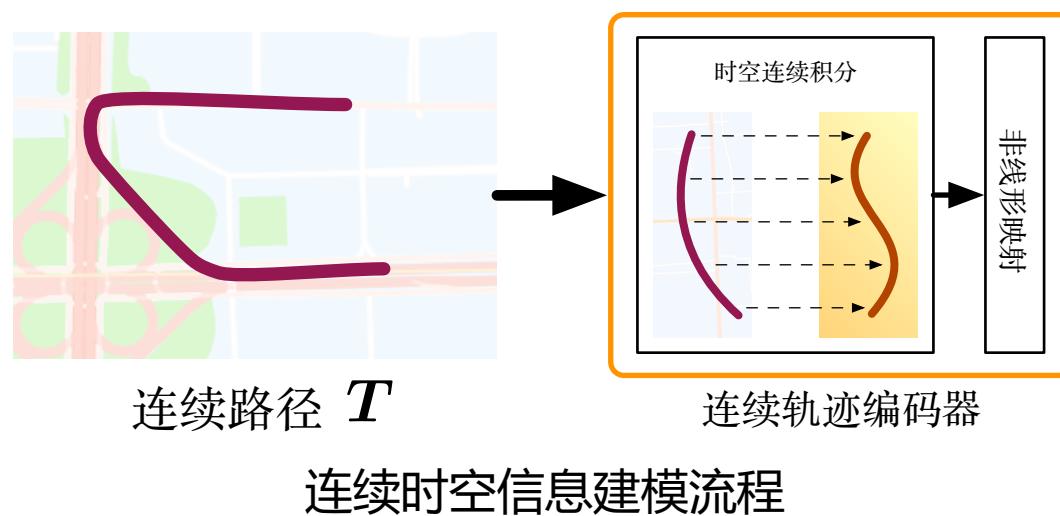


(c) Induced Attention 层

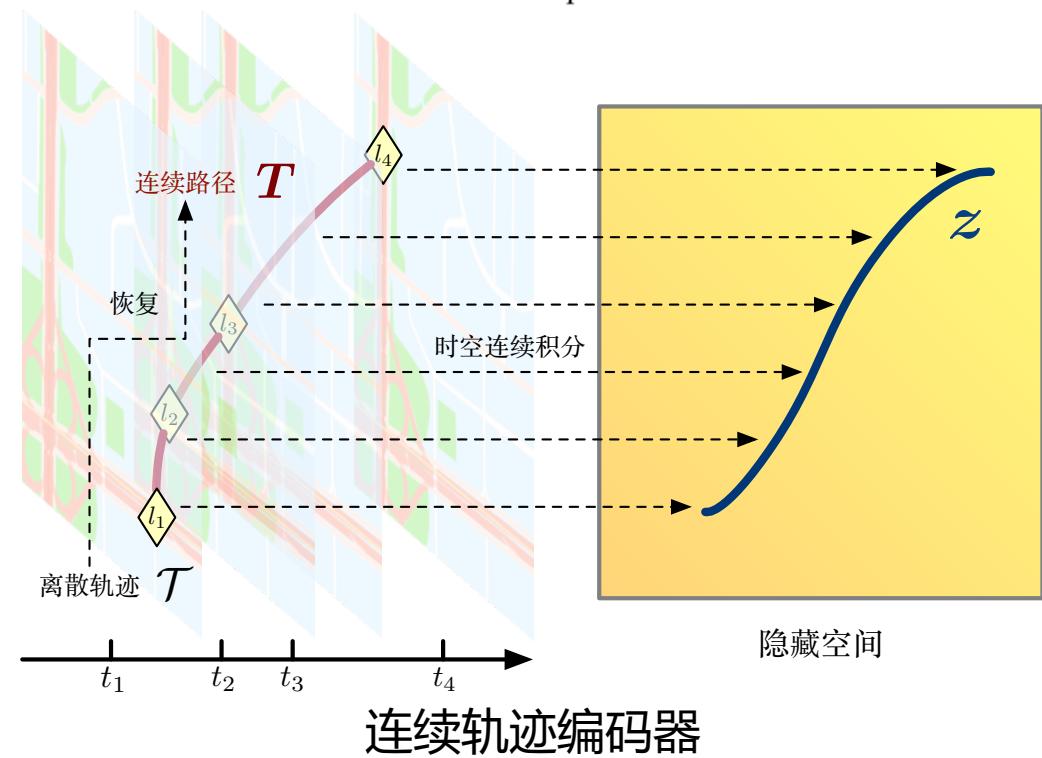
4-多视图融合的轨迹自监督学习

➤ 轨迹多方面信息建模

- 提出基于NeuralCDE的连续轨迹编码器，有效建模连续时空视图



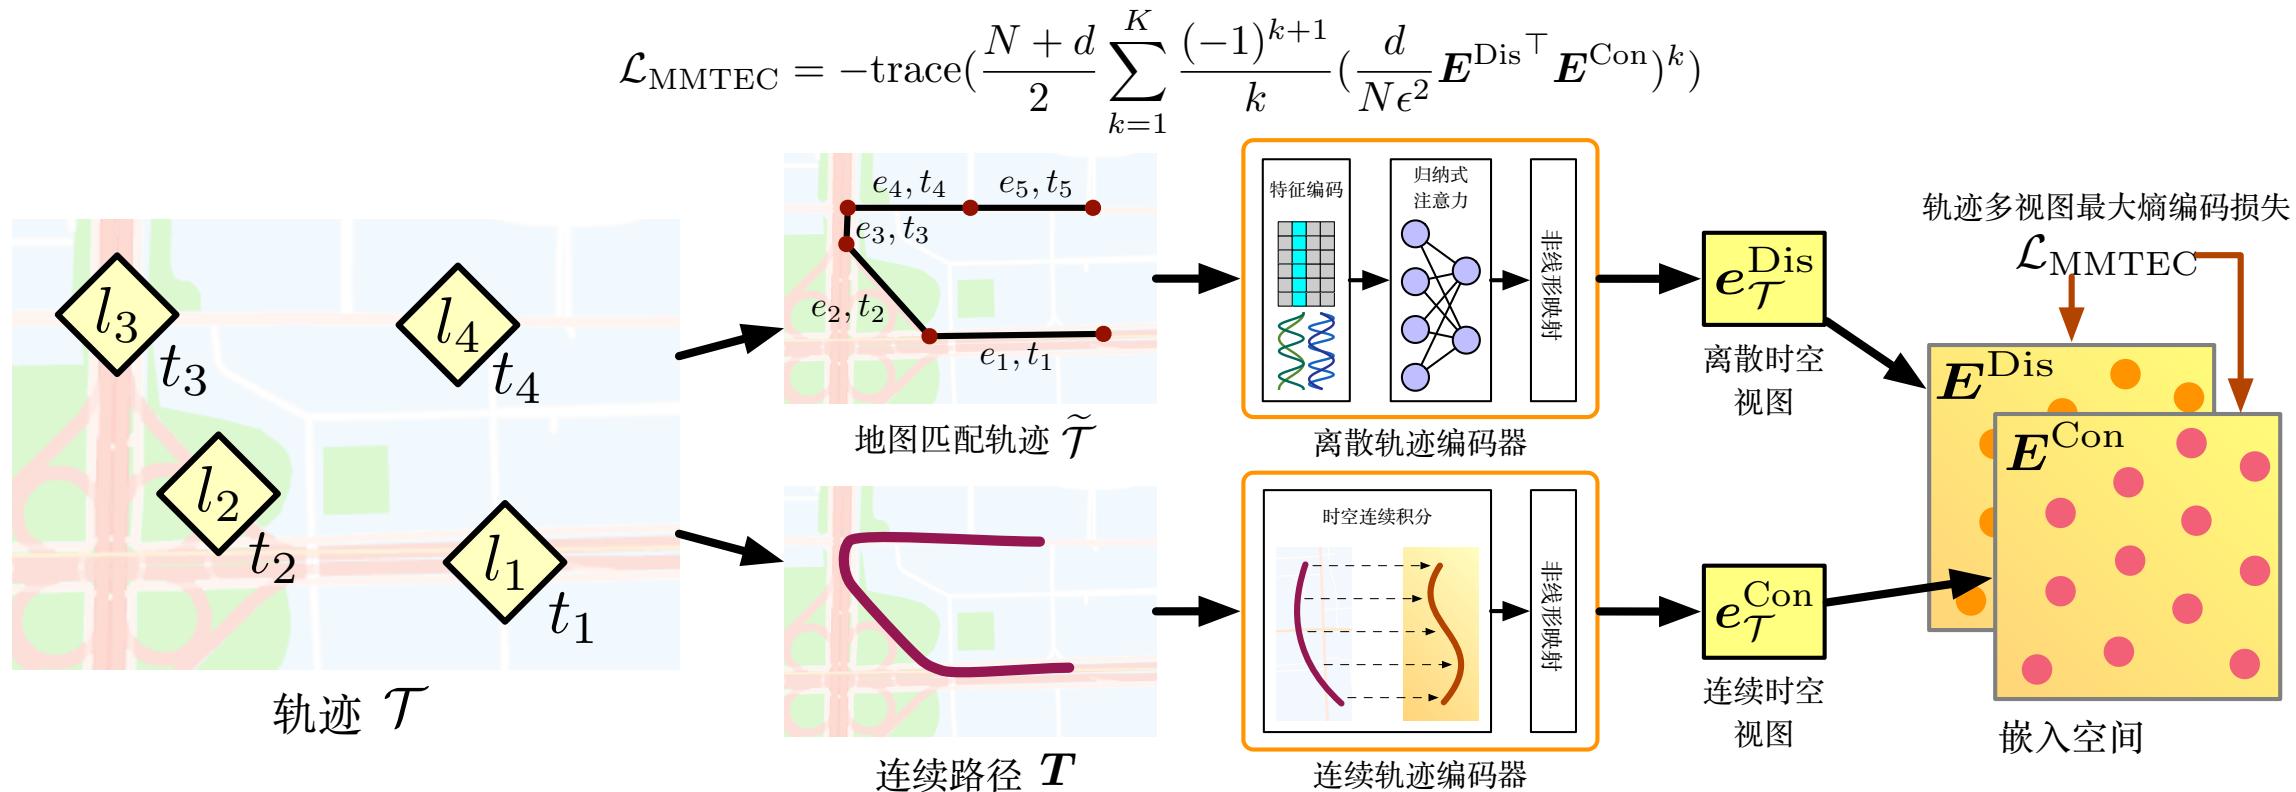
$$\text{ConEnc}(T) = z_{t_1} + \int_{t_1}^{t_{|\mathcal{T}|}} \text{CDENet}(z_t) dT_t$$



4-多视图融合的轨迹自监督学习

➤ 多视图轨迹最大熵嵌入 (MMTEC) 模型

- 提出轨迹的最大熵自监督目标，最小化嵌入向量对特定任务的偏向，学习适用于各种下游任务的嵌入



Yan Lin, Huaiyu Wan, et al. Pre-training General Trajectory Embeddings with Maximum Multi-view Entropy Coding. *IEEE Transactions on Knowledge and Data Engineering (TKDE)*, 2024.

4-多视图融合的轨迹自监督学习

➤ 实验设计

基线轨迹嵌入模型

- traj2vec: 基于自回归的轨迹表示学习模型
- t2vec: 基于去噪自编码的轨迹表示学习模型
- GM-VSAE: 基于变分自编码器的轨迹异常检测模型
- TremBR: 基于RNN编码器的轨迹表示学习模型
- CTLE: 研究内容2中提出的模型
- Toast: 结合node2vec与掩码语言模型的轨迹表示学习模型

下游任务

- 相似轨迹搜索
- 轨迹预测
- 轨迹旅行时间估计

轨迹数据集

- 车辆定位数据集

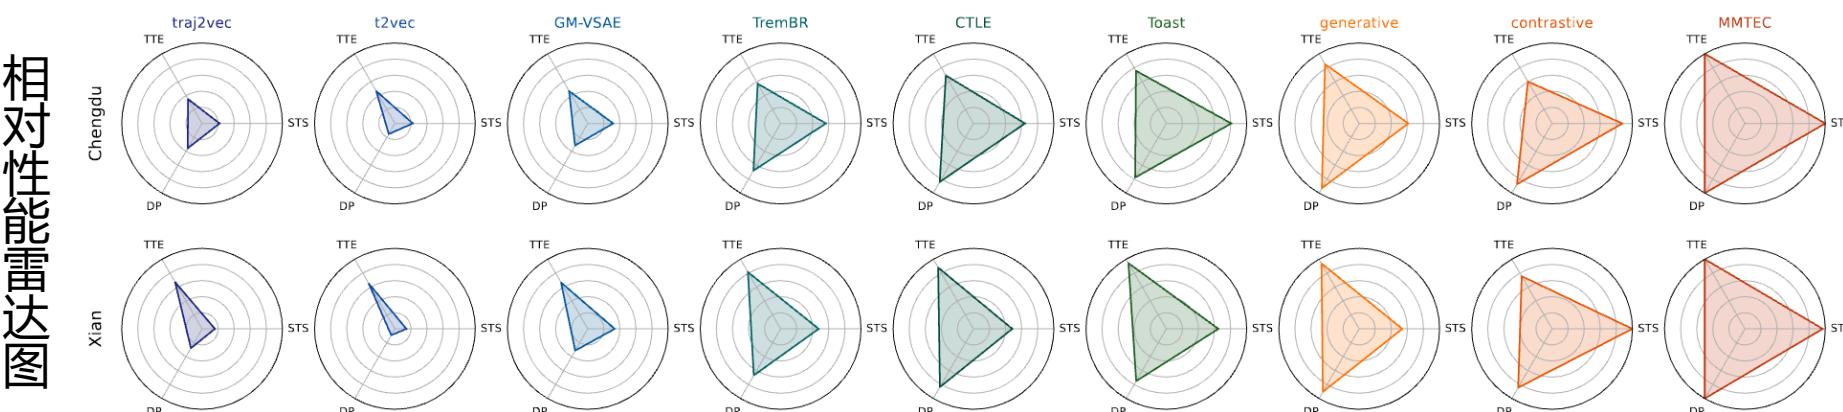
4-多视图融合的轨迹自监督学习

综合性能对比

- 在三种下游任务上大体上表现最优

下游任务	相似轨迹搜索		旅行时间估计			目的地预测		
	指标	Acc@1(%)	Acc@5(%)	MAE(分钟)	RMSE(分钟)	MAPE(%)	Acc@1(%)	Acc@5(%)
traj2vec	61.38±0.78	71.19±0.59	2.570±0.022	3.740±0.020	35.11±0.24	45.54±0.27	68.23±0.20	17.83±0.09
t2vec	61.52±1.14	71.70±1.56	2.518±0.024	3.695±0.031	33.49±0.30	39.52±0.13	63.36±0.40	13.51±0.12
GM-VSAE	64.28±0.87	76.17±0.49	2.515±0.033	3.732±0.041	33.49±0.32	44.37±0.63	67.30±0.86	17.64±0.11
TremBR	71.51±2.51	79.49±1.65	2.445±0.043	3.633±0.063	32.01±0.45	55.04±0.55	77.74±0.26	26.89±0.13
CTLE	73.75±1.41	82.69±1.62	2.341±0.035	3.558±0.071	30.37±0.51	59.88±0.26	79.92±0.13	27.66±0.13
Toast	78.67±0.71	86.40±0.60	2.320±0.028	3.477±0.069	29.44±0.44	57.99±0.64	77.14±0.85	26.17±0.99
generative	72.89±0.84	83.20±1.21	2.239±0.042	3.341±0.033	28.10±0.93	62.52±0.12	89.26±0.14	30.04±0.14
contrastive	80.62±1.99	93.13±1.41	2.419±0.124	3.590±0.184	31.59±1.79	60.84±0.31	87.66±0.13	27.35±0.28
MMTEC	84.27±3.02	95.15±1.63	2.079±0.109	3.104±0.194	26.02±1.00	64.61±0.13	91.71±0.06	33.35±0.11

成都数据集上各任务准确率对比

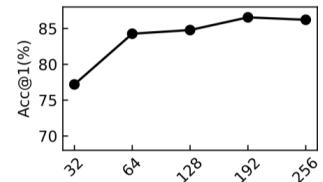


下游任务	相似轨迹搜索		旅行时间估计			目的地预测		
	指标	Acc@1(%)	Acc@5(%)	MAE(分钟)	RMSE(分钟)	MAPE(%)	Acc@1(%)	Acc@5(%)
traj2vec	58.57±0.72	77.03±0.62	3.142±0.050	5.159±0.048	30.64±0.79	44.04±0.43	67.20±0.21	13.56±0.49
t2vec	58.19±1.27	73.78±1.14	3.178±0.016	5.248±0.011	30.93±0.30	37.99±0.16	62.47±0.41	8.73±0.34
GM-VSAE	62.47±0.30	78.24±1.03	3.143±0.032	5.123±0.039	30.73±0.43	45.21±0.89	68.82±0.88	13.73±0.79
TremBR	65.55±1.34	79.55±1.63	3.037±0.028	5.073±0.022	28.65±0.31	56.78±0.61	79.33±0.98	22.14±0.90
CTLE	65.74±1.95	79.26±1.25	2.949±0.042	4.912±0.108	27.74±0.58	62.25±0.53	85.21±0.53	27.17±0.81
Toast	69.43±2.12	83.41±1.67	2.941±0.066	4.894±0.173	26.86±0.80	59.47±0.65	81.77±0.71	24.71±0.93
generative	66.95±1.93	82.28±1.24	2.900±0.090	4.724±0.138	26.91±0.92	64.52±0.18	92.09±0.11	30.14±0.74
contrastive	77.27±1.65	89.92±1.22	3.158±0.049	5.086±0.111	29.47±1.38	62.50±0.14	87.46±0.07	26.75±0.41
MMTEC	76.57±3.05	91.38±2.04	2.870±0.023	4.653±0.073	26.06±0.44	67.62±0.21	93.68±0.08	36.38±0.79

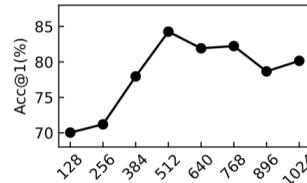
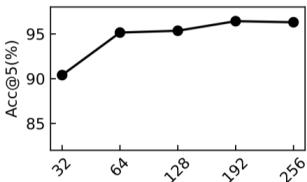
西安数据集上各任务准确率对比

4-多视图融合的轨迹自监督学习

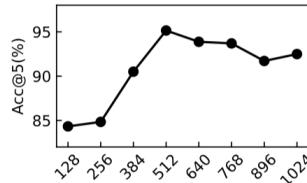
模型分析



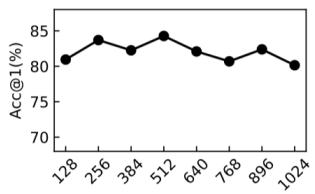
(a) 嵌入维度 d 的影响



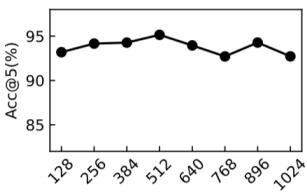
(b) 批大小 N 的影响



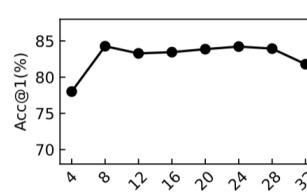
(a) 嵌入维度 d 的影响



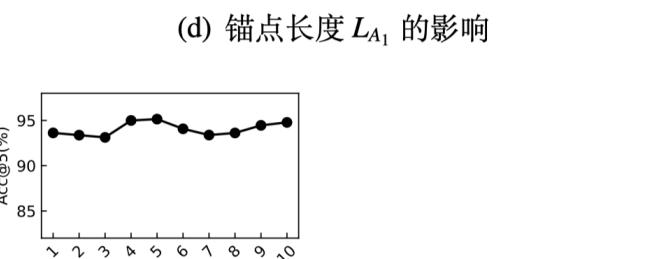
(c) 平方误差上限 ϵ^2 的影响



(d) 锚点长度 L_{A_1} 的影响



(d) 锚点长度 L_{A_1} 的影响



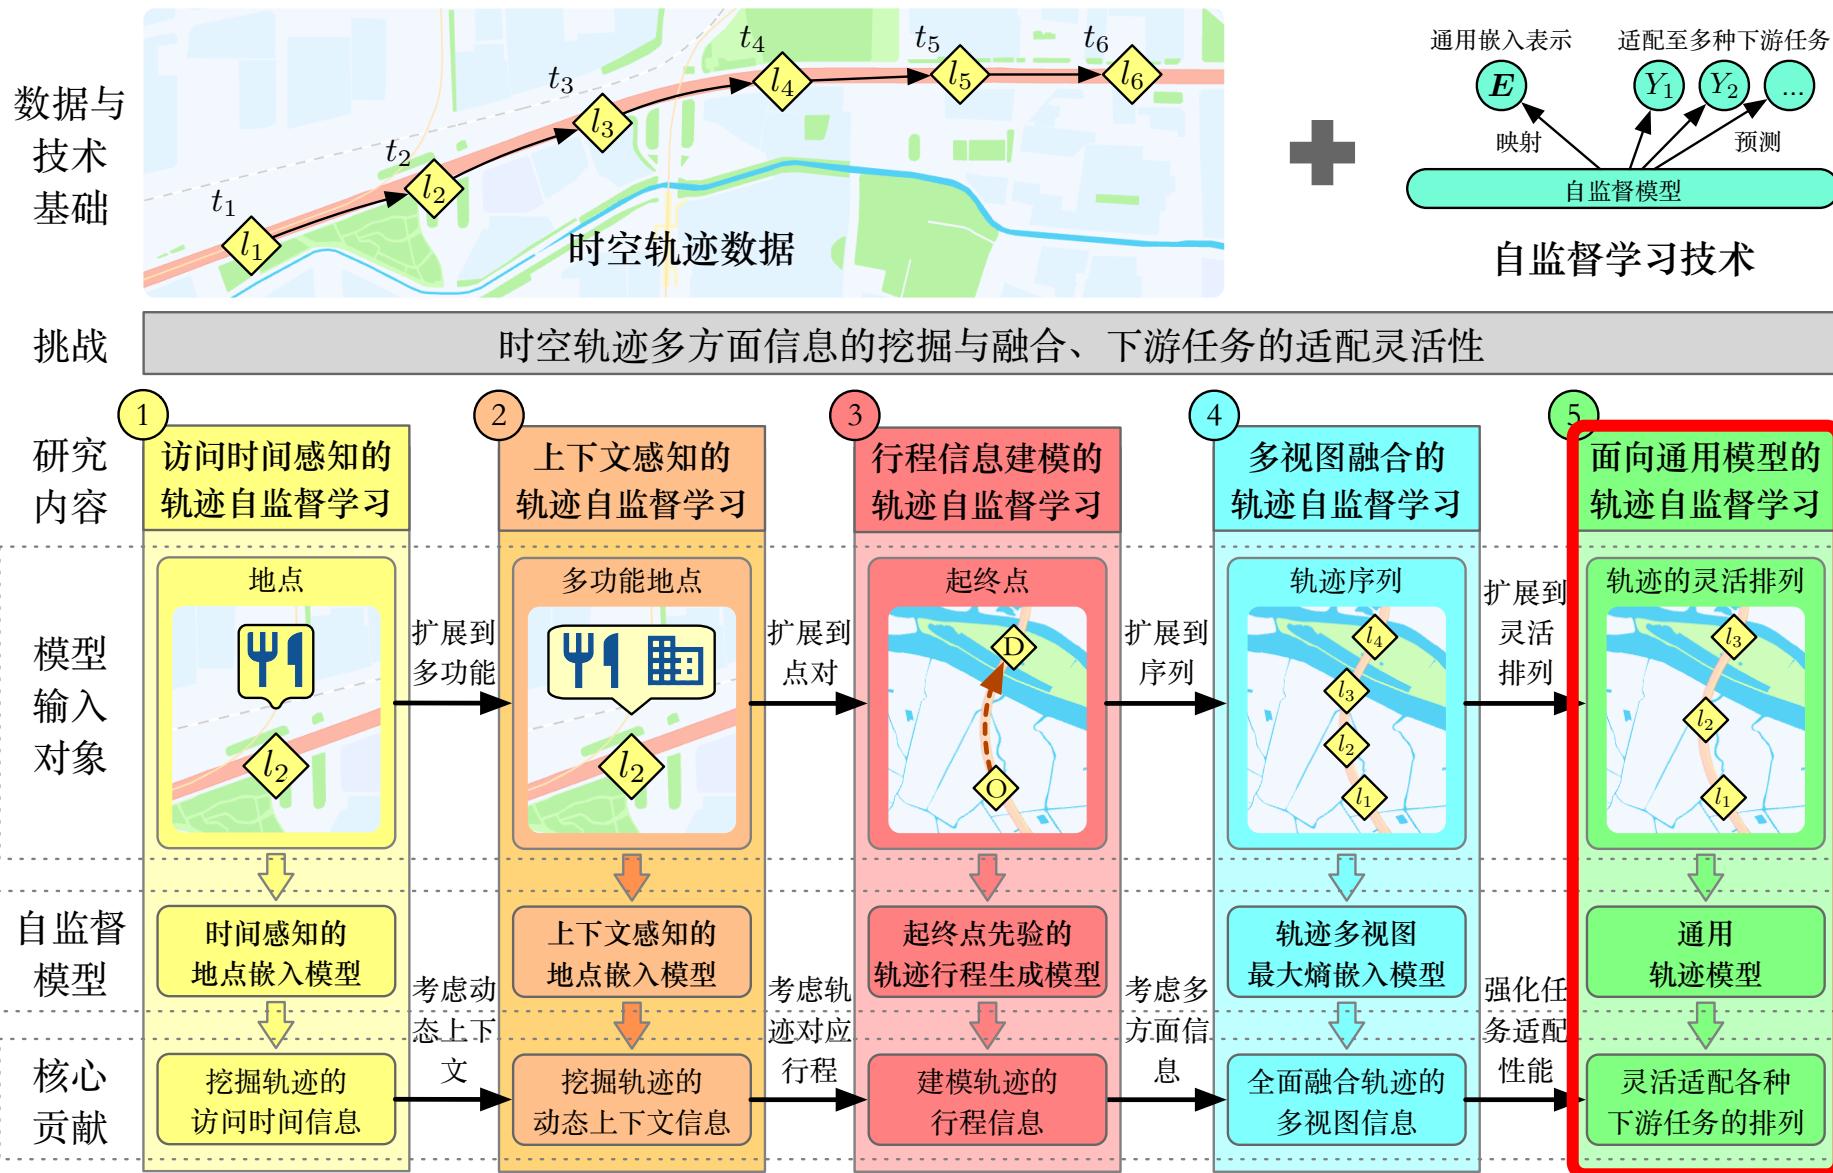
(e) 泰勒展开阶 K 的影响

超参数效果分析

指标	Acc@1(%)	Acc@5(%)
only-sem	64.84 ± 11.53	77.93 ± 13.62
only-con	59.36 ± 4.67	71.23 ± 5.32
no-time	67.38 ± 5.28	78.14 ± 7.50
no-spatial	53.10 ± 0.51	64.23 ± 1.04
dis-no-time	70.72 ± 0.49	82.53 ± 0.91
dis-no-spatial	72.71 ± 2.14	83.93 ± 2.85
con-no-time	69.69 ± 0.57	80.24 ± 0.83
con-no-spatial	62.79 ± 0.59	73.56 ± 0.91
Dis-Trans	<u>82.86 ± 2.57</u>	<u>94.36 ± 1.39</u>
Con-Trans	74.97 ± 3.55	88.75 ± 1.91
MMTEC	84.27 ± 3.02	95.15 ± 1.63

组件分析

研究内容框架



5-面向通用模型的轨迹自监督学习

➤ 挑战

- 设计能够应对各种任务的不同轨迹输入输出排列的自监督模型

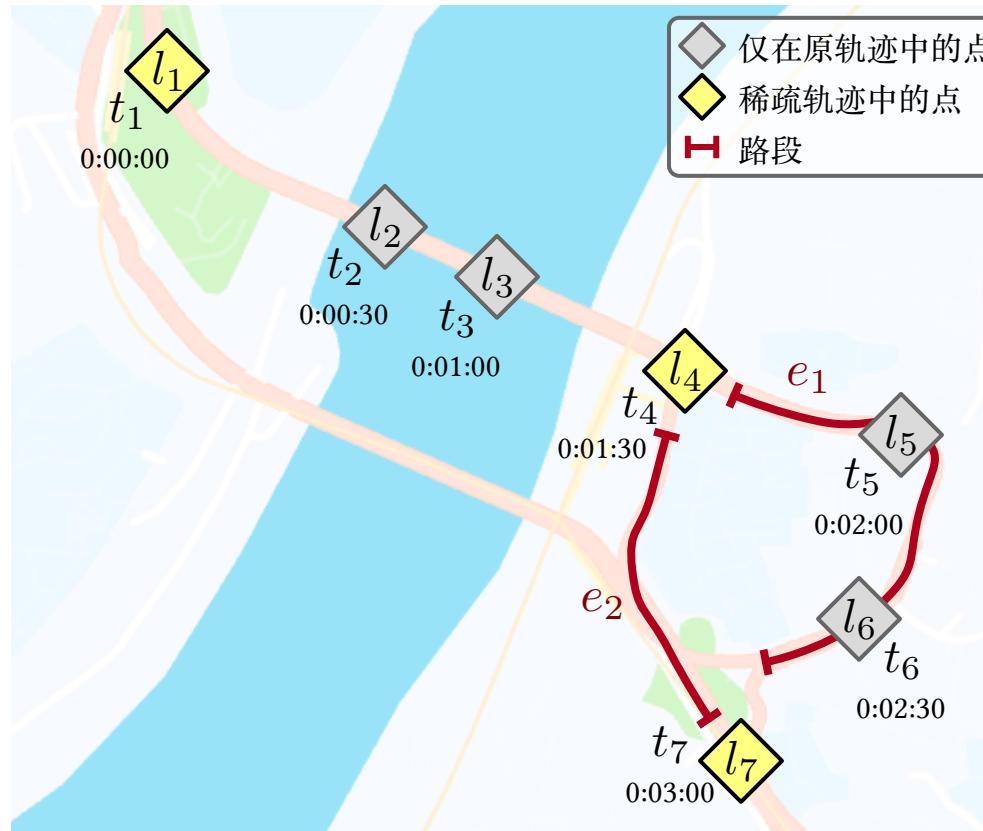


- 现有轨迹自监督模型对**轨迹特征的完整性**有较强要求，限制了任务适配能力

5-面向通用模型的轨迹自监督学习

➤ 挑战

- 面对重采样的稀疏轨迹时保持较佳的性能

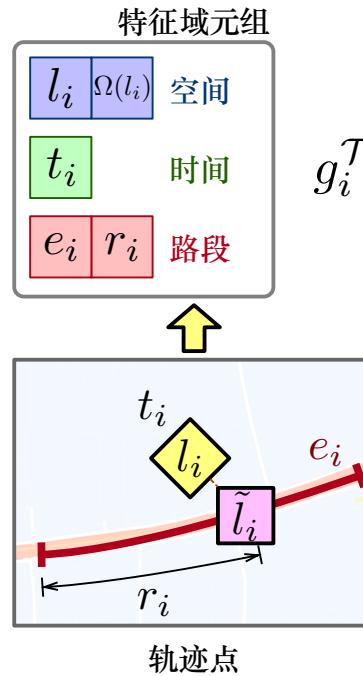


- 现有轨迹自监督模型未妥善应对稀疏性带来的时空/路段特征缺失

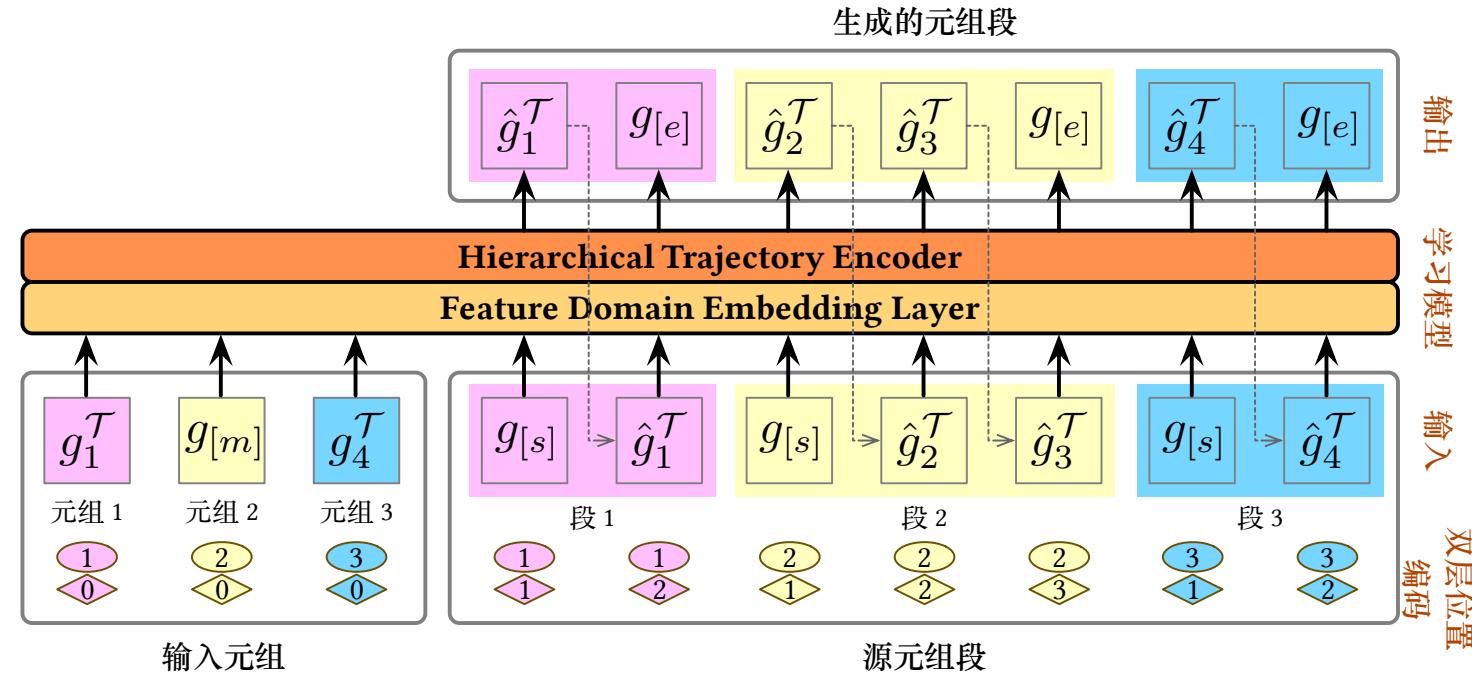
5-面向通用模型的轨迹自监督学习

➤ 通用轨迹模型 (GTM)

- 将轨迹特征分为可独立掩码和自回归生成的三个域，能够灵活适配不同任务的输入输出排列



轨迹的特征域划分



特征域的自回归生成框架

Yan Lin, Jilin Hu, et al. GTM: General Trajectory Modeling with Auto-regressive Generation of Feature Domains. *Proceedings of the VLDB Volume 17, under review.*

5-面向通用模型的轨迹自监督学习

➤ 编码组件

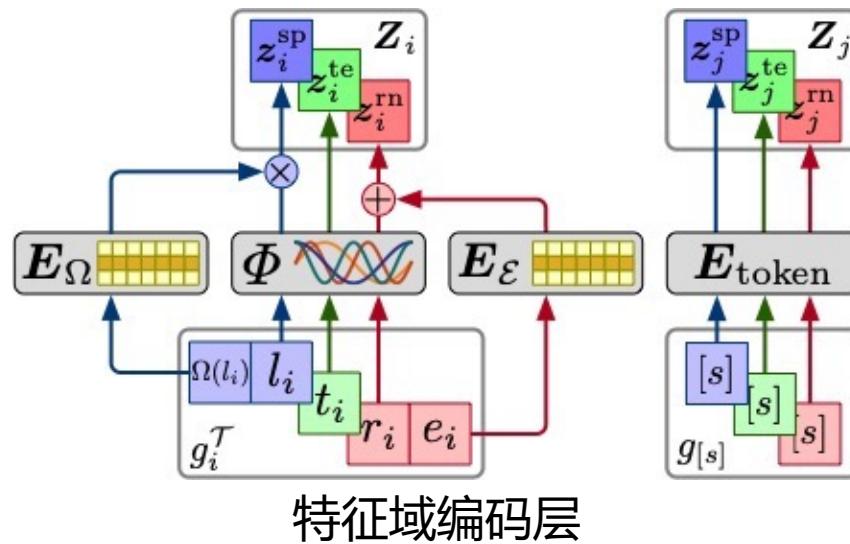
- 特征域编码层和层次轨迹编码器，增强模型对轨迹特征域和轨迹点间关联性的建模能力

$$z_i^{\text{sp}} = \Phi(l_i^{\text{lng}}) + \Phi(l_i^{\text{lat}})$$

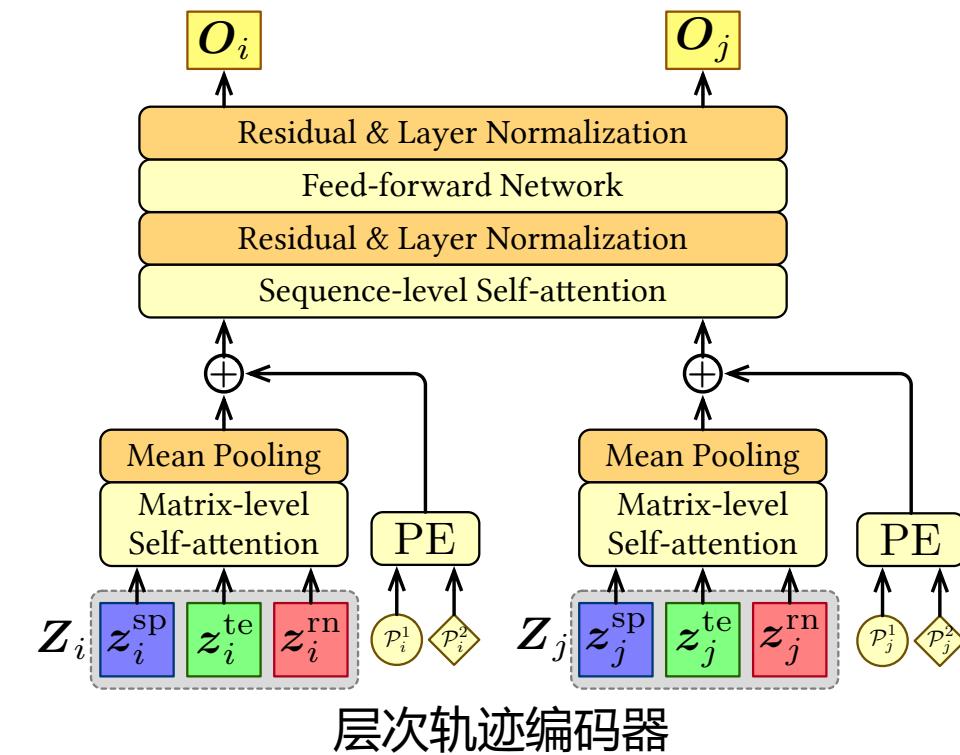
$$z_i^{\text{sp}} = z_i^{\text{sp}} + \text{MultiHead}(z_i^{\text{sp}}, E_{\Omega}(l_i), E_{\Omega}(l_i))$$

$$z_i^{\text{te}} = \Phi(t_i)$$

$$z_i^{\text{rn}} = E_{\mathcal{E}}(e_i) + \Phi(r_i)$$



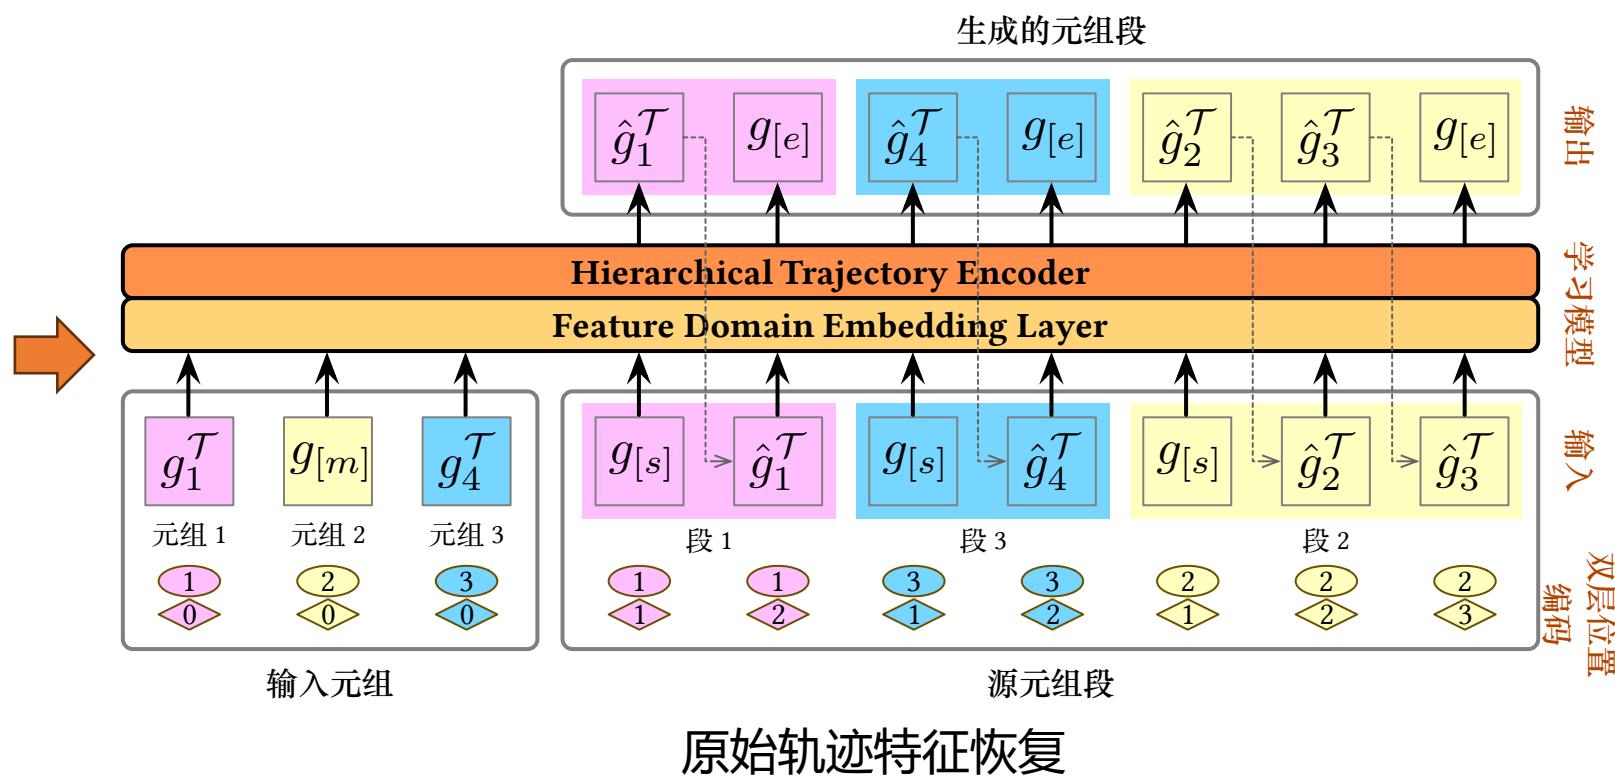
特征域编码层



5-面向通用模型的轨迹自监督学习

➤ 自监督训练

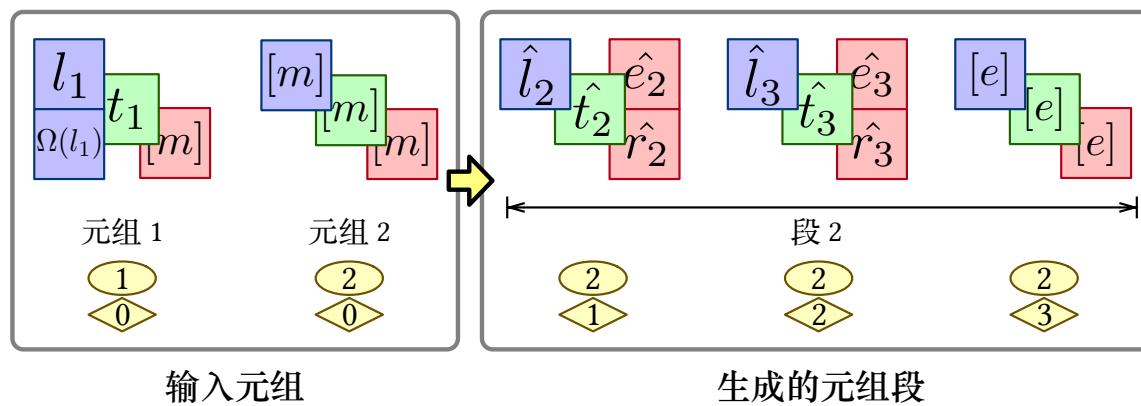
- 根据重采样稀疏轨迹恢复原始轨迹特征，使得模型能够从稀疏轨迹中提取稠密的时空特征



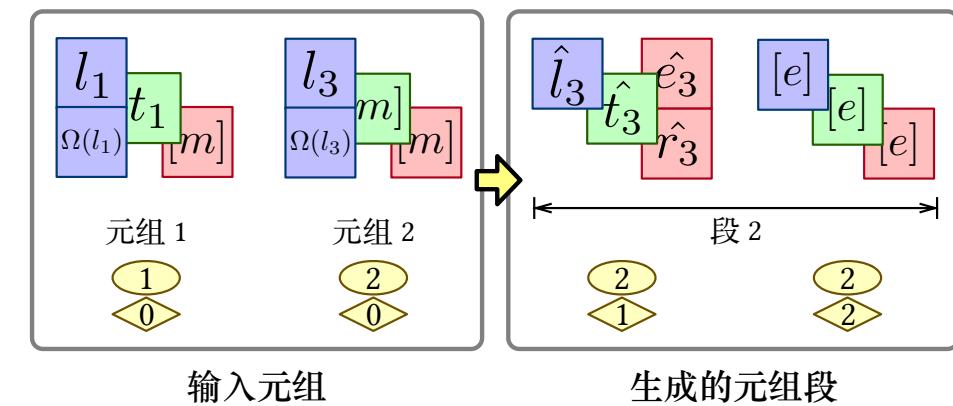
5-面向通用模型的轨迹自监督学习

➤ 下游任务迁移

- 通过zero-shot或微调的方式迁移至多种下游任务，仅需提供特定排列的输入。



轨迹预测



起终点旅行时间估计

5-面向通用模型的轨迹自监督学习

➤ 实验设计

基线模型

➤ 稀疏轨迹恢复方法

- Shorest Path: 基于最短路径的方法
- Linear+HMM: 线性插补配合路网匹配算法
- TrlImpute: 基于群体智慧的稀疏轨迹恢复方法
- DHTR: 基于seq2seq和卡尔曼滤波器的方法
- AttnMove: 基于注意力的方法
- MTrajRec: 基于GRU的路网约束轨迹恢复方法
- RNTrajRec: 基于Transformer的轨迹恢复方法

➤ 轨迹预测方法

- 基于轨迹自监督表示学习的方法: trajectory2vec, t2vec, Trembr, START
- 基于轨迹端到端表示学习的方法: DeepMove, Transformer

➤ 旅行时间估计方法

- RNE, TEMP, LR, GBM, ST-NN, MURAT, DeepOD, DOT

下游任务

➤ 稀疏轨迹恢复

➤ 轨迹预测

➤ 起终点旅行时间估计

轨迹数据集

- 车辆定位数据集

5-面向通用模型的轨迹自监督学习

➤ 综合性能对比

- 能够提升轨迹恢复、旅行时间估计任务的准确率

Sampling Interval μ		1 minute / 2 minutes / 4 minutes			
Datasets	Methods	Precision (%) ↑	Recall (%) ↑	MAE (Coor, meters) ↓	MAE (Road, meters) ↓
Chengdu	Shortest Path	62.638 / 43.504 / 29.431	59.346 / 40.949 / 27.607	213.10 / 428.69 / 752.19	206.91 / 391.39 / 586.09
	Linear	66.642 / 48.604 / 36.209	65.557 / 45.234 / 30.496	183.64 / 385.23 / 675.85	169.46 / 378.96 / 564.19
	TrImpute	77.520 / 60.179 / 57.526	76.202 / 58.461 / 53.747	166.82 / 276.56 / 408.64	155.71 / 265.34 / 387.36
	DHTR	53.514 / 53.608 / 50.985	58.868 / 47.918 / 46.311	205.59 / 317.45 / 450.61	300.67 / 470.46 / 547.41
	AttnMove	84.162 / 81.402 / 78.645	81.839 / 76.612 / 69.257	252.59 / 280.20 / 354.39	201.51 / 258.69 / 323.52
	MTrajRec	85.039 / 82.596 / <u>80.684</u>	83.351 / 80.113 / <u>72.952</u>	243.01 / 264.15 / <u>311.53</u>	173.67 / 204.58 / 282.88
	RNTrajRec	87.653 / 83.174 / 79.404	<u>86.025</u> / <u>80.150</u> / 72.633	215.24 / 234.27 / 326.92	114.04 / <u>148.04</u> / 292.61
	GTM w/o pt	83.720 / 77.425 / 72.471	82.827 / 73.933 / 62.757	194.30 / 272.86 / 479.49	86.15 / 230.68 / 448.98
	GTM w/o ft	<u>87.664</u> / 83.592 / 79.096	85.837 / 78.406 / 70.717	<u>137.69</u> / 217.85 / 350.29	<u>81.81</u> / 167.16 / 315.07
	GTM	89.071 / 84.373 / 80.828	88.249 / 81.520 / 73.212	133.38 / 192.54 / 304.72	67.98 / 143.48 / 275.37
Porto	Shortest Path	69.780 / 53.590 / 40.492	60.354 / 46.263 / 33.758	202.17 / 434.37 / 679.72	165.02 / 319.32 / 478.66
	Linear	72.961 / 60.966 / 48.529	63.146 / 48.401 / 35.507	196.51 / 403.05 / 621.88	132.76 / 275.43 / 430.22
	TrImpute	76.781 / 66.492 / 50.021	69.599 / 58.676 / 43.052	132.76 / 275.43 / 430.22	128.48 / 235.63 / 347.30
	DHTR	63.287 / 58.897 / 52.658	62.511 / 56.444 / 42.462	235.32 / 292.65 / 355.23	285.68 / 336.48 / 389.18
	AttnMove	79.541 / 75.751 / 71.248	67.116 / 56.751 / 48.991	184.70 / 222.51 / 304.31	134.17 / 184.03 / 251.92
	MTrajRec	78.081 / 72.847 / 64.566	71.853 / 60.068 / 46.110	168.34 / 283.90 / 496.96	121.64 / 215.40 / 391.67
	RNTrajRec	80.305 / 77.094 / <u>75.573</u>	74.953 / <u>65.370</u> / <u>50.965</u>	135.17 / <u>175.42</u> / 294.08	111.75 / 152.49 / <u>230.30</u>
	GTM w/o pt	81.058 / 73.842 / 67.189	77.683 / 61.987 / 42.688	132.97 / 229.11 / 496.99	<u>69.70</u> / 204.01 / 488.13
	GTM w/o ft	<u>81.716</u> / 79.067 / 74.732	<u>75.144</u> / 63.059 / 50.269	<u>118.79</u> / 194.37 / 338.30	76.46 / <u>159.81</u> / 320.79
	GTM	82.640 / 79.494 / 77.068	78.605 / 66.850 / 53.436	103.06 / 164.75 / 282.61	63.18 / 138.66 / 268.98

轨迹恢复任务准确率对比

Datasets		Chengdu / Porto		
Methods	MAE (min) ↓	RMSE (min) ↓	MAPE (%) ↓	
RNE	1.087 / 2.357	4.967 / 7.168	18.185 / 53.894	
TEMP	0.816 / 2.610	1.100 / 3.414	13.003 / 59.178	
LR	0.815 / 2.596	1.097 / 3.408	12.997 / 58.390	
GBM	0.773 / 2.200	1.202 / 3.116	11.142 / 43.308	
ST-NN	0.770 / 2.136	1.031 / 3.027	12.470 / 45.285	
MURAT	0.731 / 1.971	0.979 / 2.827	11.931 / 41.259	
DeepOD	0.640 / 1.899	0.880 / 2.780	10.517 / 36.956	
DOT	<u>0.614</u> / <u>1.777</u>	<u>0.841</u> / <u>2.644</u>	<u>9.937</u> / <u>34.883</u>	
GTM w/o pt	0.666 / 1.871	0.933 / 2.797	10.501 / 34.895	
GTM w/o ft	2.203 / 3.470	2.469 / 4.694	35.039 / 45.700	
GTM	0.561 / 1.615	0.784 / 2.470	8.853 / 31.391	

旅行时间估计任务准确率对比

5-面向通用模型的轨迹自监督学习

➤ 综合性能对比

- 能够提升稀疏轨迹在轨迹预测任务上的准确率，甚至优于基于稠密轨迹的预测模型

Sampling Interval μ		1 minute / 2 minutes / 4 minutes			
Datasets	Methods	Accuracy (%) \uparrow	MAE (Coor, meters) \downarrow	MAE (Road, meters) \downarrow	MAE (Time, seconds) \downarrow
Chengdu	trajectory2vec	31.496 / 24.403 / 17.163	1514.5 / 1682.8 / 1861.6	1322.0 / 1616.5 / 1957.5	14.474 / 20.722 / 37.256
	t2vec	53.349 / 43.303 / 35.058	528.65 / 602.45 / 731.00	286.18 / 434.27 / 635.45	13.016 / 19.539 / 34.488
	DeepMove	58.499 / 45.985 / 37.338	<u>319.14</u> / 461.73 / 664.93	258.96 / 397.95 / 607.42	11.994 / 19.435 / 35.039
	Transformer	65.192 / 60.028 / <u>55.139</u>	374.36 / <u>402.11</u> / <u>431.01</u>	236.86 / <u>287.61</u> / <u>320.92</u>	16.287 / 29.848 / 34.226
	Trembr+RNTR	52.065 / 43.196 / 34.655	421.95 / 482.67 / 561.89	398.76 / 455.98 / 532.03	14.346 / 19.110 / 28.659
	START+RNTR	59.462 / 48.466 / 40.941	375.39 / 421.45 / 481.32	355.00 / 399.66 / 457.35	12.771 / 14.439 / 19.443
	GTM w/o pt	<u>71.795</u> / 50.041 / 33.882	376.05 / 540.89 / 857.43	263.83 / 568.73 / 942.64	<u>5.301</u> / <u>10.198</u> / <u>9.562</u>
	GTM w/o ft	67.064 / <u>61.766</u> / 53.949	368.30 / 452.75 / 544.02	<u>230.24</u> / 320.19 / 443.43	6.084 / 12.189 / 9.910
	GTM	82.820 / 78.921 / 72.083	260.31 / 303.44 / 362.32	128.44 / 200.80 / 260.13	3.821 / 7.919 / 7.131
Porto	trajectory2vec	13.396 / 10.178 / 5.440	1709.3 / 2108.9 / 2488.5	2227.4 / 2425.6 / 3003.6	31.442 / 46.097 / 54.585
	t2vec	38.945 / 30.805 / 22.812	432.77 / 528.89 / 732.13	206.95 / 346.72 / 641.26	17.420 / 28.436 / 48.651
	DeepMove	43.774 / 33.562 / 23.645	<u>252.22</u> / 390.57 / 679.62	197.89 / 328.93 / 681.40	16.998 / 26.309 / 46.629
	Transformer	43.441 / 39.425 / 33.685	323.58 / <u>351.18</u> / <u>402.32</u>	216.18 / 256.89 / 283.72	18.231 / 30.541 / 49.083
	Trembr+RNTR	40.128 / 34.857 / 26.004	413.20 / 471.45 / 620.77	393.18 / 448.74 / 597.73	18.915 / 21.843 / 28.683
	START+RNTR	52.118 / 43.617 / 34.931	351.98 / 416.83 / 503.32	333.56 / 396.39 / 483.41	14.729 / 17.722 / 22.455
	GTM w/o pt	<u>61.480</u> / 46.938 / 31.304	307.23 / 369.86 / 649.71	<u>145.36</u> / 295.58 / 624.11	<u>10.853</u> / <u>11.316</u> / <u>11.643</u>
	GTM w/o ft	48.770 / 48.474 / <u>44.477</u>	325.58 / 370.04 / 454.70	170.32 / <u>193.40</u> / <u>279.12</u>	11.509 / 18.342 / 18.081
	GTM	68.529 / 67.697 / 65.125	238.83 / 232.15 / 322.63	99.67 / 103.79 / 140.17	6.845 / 9.449 / 11.549

轨迹预测任务准确率对比

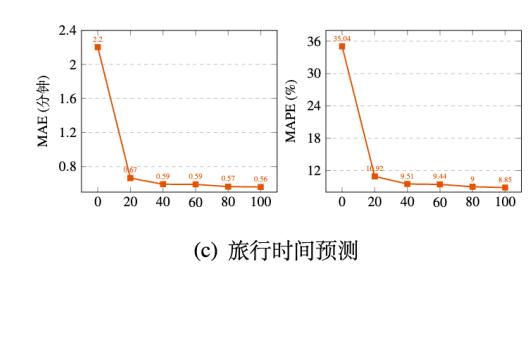
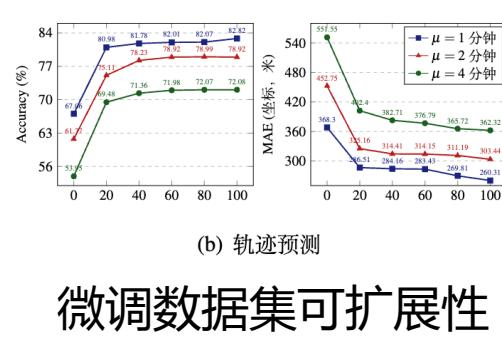
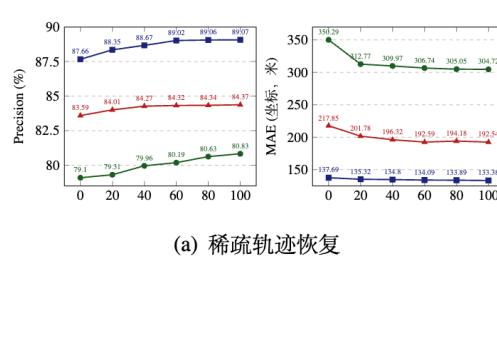
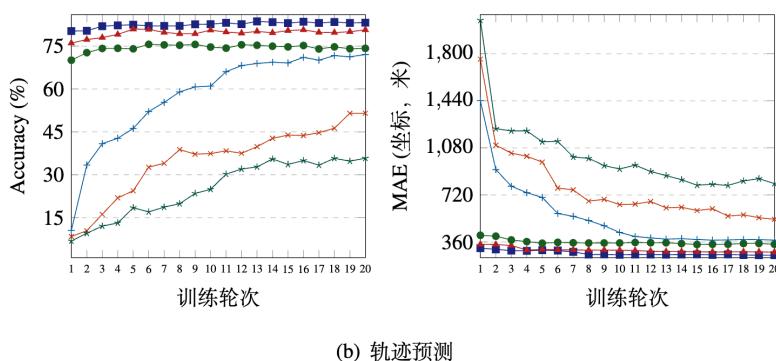
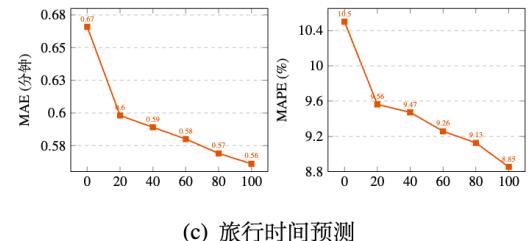
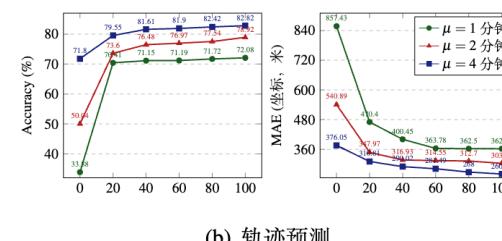
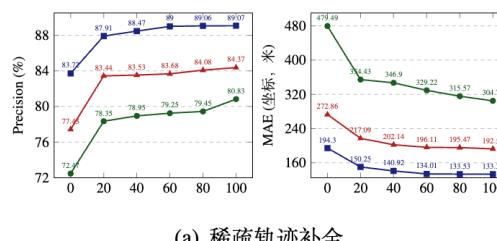
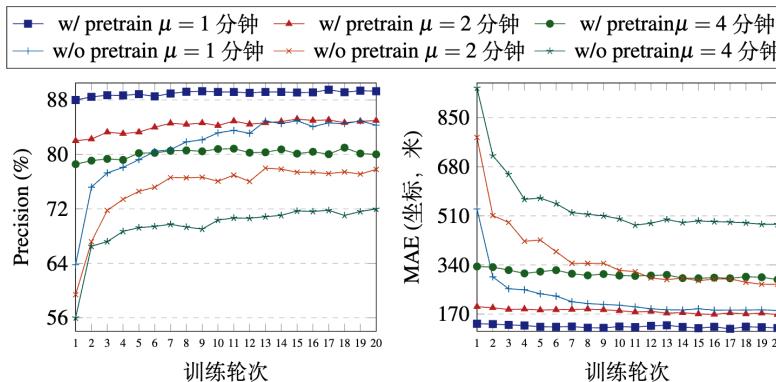
Datasets		Chengdu / Porto		
Methods	μ	Accuracy (%)	MAE (Coor, m.)	MAE (Time, sec.)
Trembr	15 sec.	66.077 / 52.063	399.40 / 362.84	8.534 / 15.046
START	15 sec.	<u>74.990</u> / 62.997	<u>354.76</u> / <u>318.26</u>	8.068 / 12.476
GTM	4 min.	72.083 / <u>65.125</u>	362.32 / 322.63	<u>7.131</u> / <u>11.549</u>
GTM	1 min.	82.820 / 68.529	260.31 / 238.83	3.821 / 6.845

GTM与基于稠密轨迹的基线模型
之间的轨迹预测准确性比较

5-面向通用模型的轨迹自监督学习

➤ 模型分析

- 模型能够显著提升下游任务的收敛速度
- 模型面对规模有限的自监督训练与微调数据集能够保持较为稳定的性能



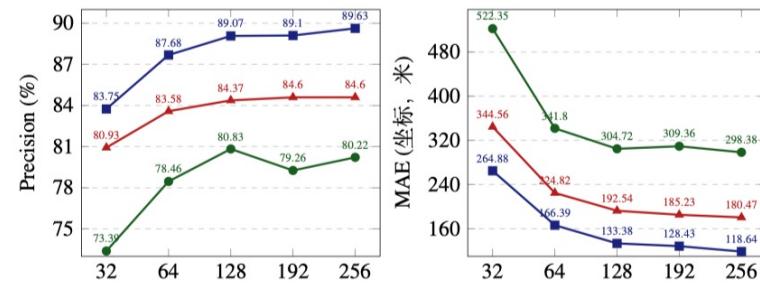
下游任务收敛速度对比

自监督训练数据集可扩展性

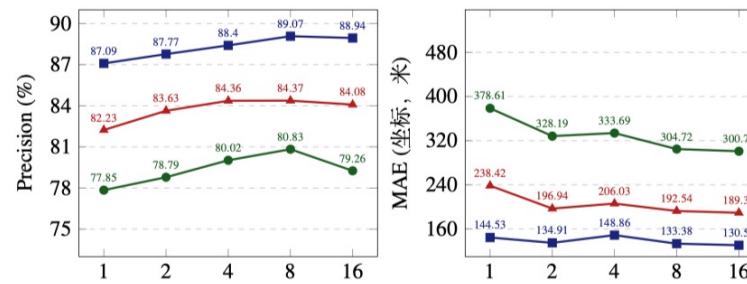
微调数据集可扩展性

5-面向通用模型的轨迹自监督学习

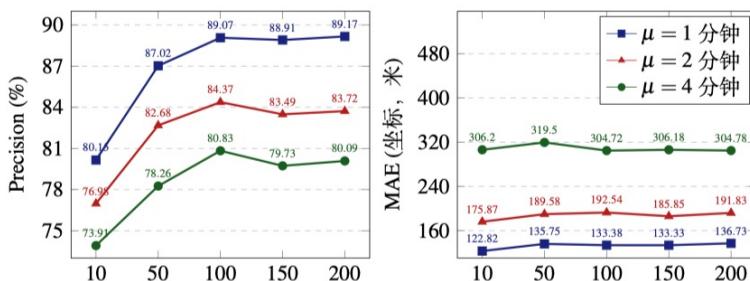
➤ 模型分析



(a) 嵌入维度 d



(b) 注意力头数 N_h



(c) 距离阈值 δ (米)

超参数分析

采样间隔 μ	1分钟 / 2分钟 / 4分钟		
	变体	Precision (%)	MAE (坐标, 米)
w/o neigh.		76.834 / 74.494 / 71.950	128.36 / 193.41 / 300.30
w/o coor.		78.891 / 77.345 / 72.433	162.03 / 284.03 / 444.69
w/o time		86.821 / 83.230 / 77.055	140.98 / 203.23 / 318.81
w/o shuffle		84.406 / 77.467 / 73.589	158.95 / 276.26 / 433.86
Flat encoder		85.548 / 79.874 / 74.162	142.02 / 216.87 / 323.66
FC num. enc.		86.051 / 81.433 / 76.964	145.67 / 218.25 / 327.71
GenSTL		89.071 / 84.343 / 80.828	133.38 / 192.54 / 304.72

组件分析

请批评指正！

答辩人：林彦 指导教师：万怀宇