



时空轨迹的自监督学习研究与展望

Self-supervised learning of spatio-temporal trajectories

林彦

北京交通大学

网络科学与智能系统研究所


2024年4月25日

- 1 轨迹自监督学习研究背景
- 2 基于词嵌入的轨迹自监督学习
- 3 基于自编码器的轨迹自监督学习
- 4 基于对比学习的轨迹自监督学习
- 5 轨迹自监督学习研究展望

- 1 轨迹自监督学习研究背景
- 2 基于词嵌入的轨迹自监督学习
- 3 基于自编码器的轨迹自监督学习
- 4 基于对比学习的轨迹自监督学习
- 5 轨迹自监督学习研究展望

时空轨迹的定义


- 由 (地点, 时间) 对组成的序列, 记录了车辆、个人等对象的移动行为



时空轨迹的产生来源

个人与基于位置的服务

用户对地点的访问



基于位置的服务



产生



记录

签到数据集

[user]	[check-in time]	[latitude]	[longitude]	[location id]
196514	2010-07-24T13:45:06Z	53.3648119	-2.2723465833	145064
196514	2010-07-24T13:44:58Z	53.360511233	-2.276369017	1275991
196514	2010-07-24T13:44:46Z	53.3653895945	-2.2754087046	376497
196514	2010-07-24T13:44:38Z	53.3663709833	-2.2700764333	98503
196514	2010-07-24T13:44:26Z	53.3674087524	-2.2783813477	1043431
196514	2010-07-24T13:44:08Z	53.3675663377	-2.278631763	881734
196514	2010-07-24T13:43:18Z	53.3679640626	-2.2792943689	207763
196514	2010-07-24T13:41:10Z	53.364905	-2.270824	1042822

数据样例

数据集统计值

数据集	用户量	地点数量	轨迹点数量
Foursquare-NYC	1,077	3,908	82,091
Foursquare-TKY	2,290	7,057	389,063
Foursquare-JKT	9,193	13,105	536,792

时空轨迹的产生来源

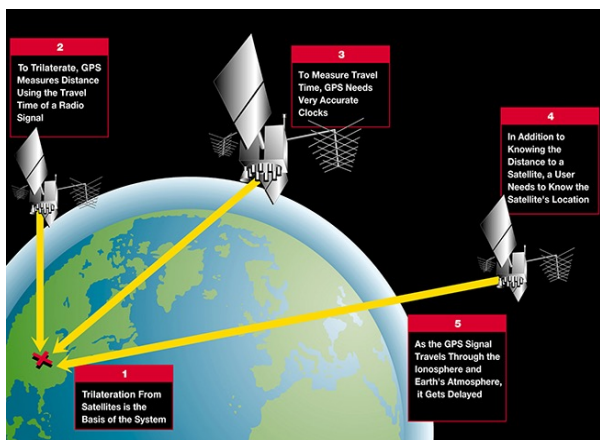
➤ 车辆与车载定位系统

车辆的行驶行为



产生

定位系统



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

时空轨迹中的丰富信息



移动和出行



时空轨迹



丰富的时空信息

地点的功能



车辆路径偏好



道路交通状况



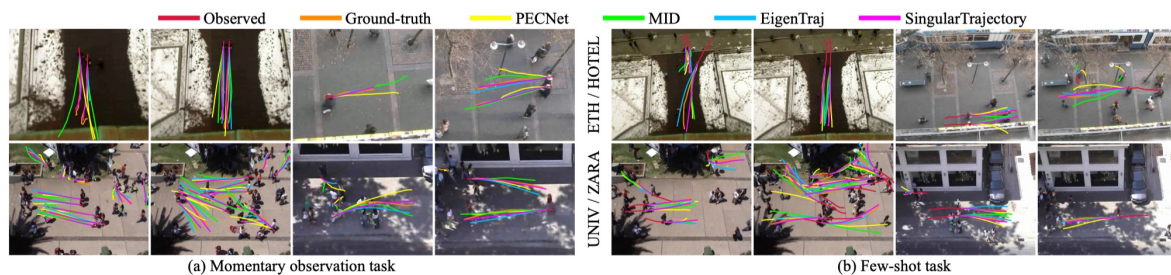
时空轨迹的广泛应用

➤ 移动行为分析

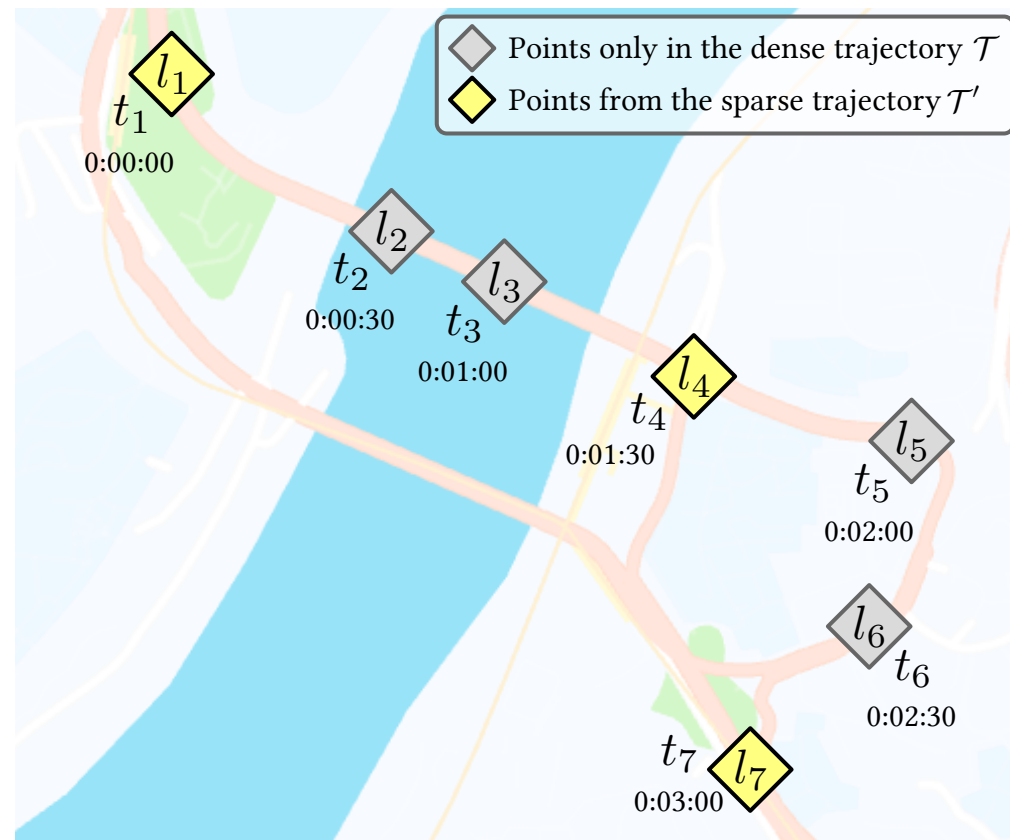
相似轨迹搜索



轨迹预测



稀疏轨迹恢复






时空轨迹的广泛应用

➤ 地点特征分析

地点分类



地点访问流量预测



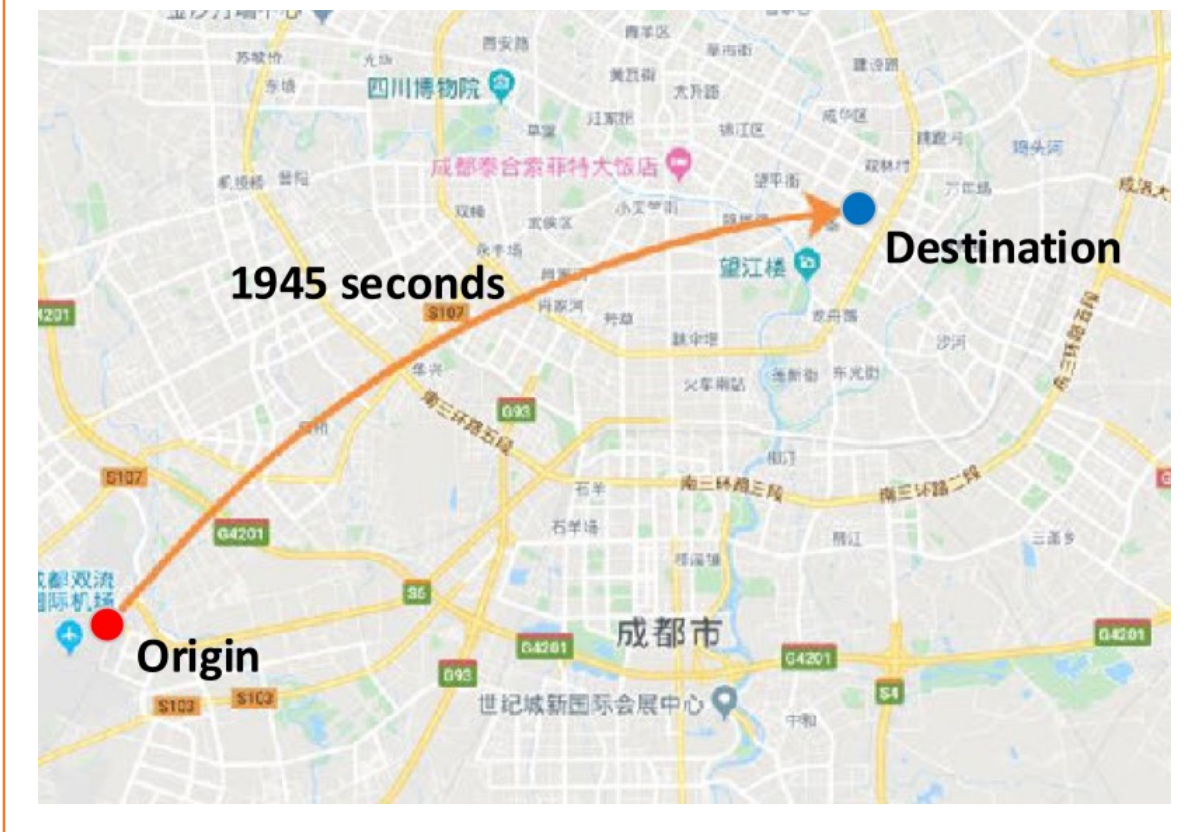
时空轨迹的广泛应用

出行规律分析

起终点行程生成



起终点旅行时间估计




时空轨迹数据挖掘

➤ 数据可用性强

➤ 关键性地位

定位采集设备



基于位置的服务



产生



时空轨迹数据




支撑




下游时空数据挖掘任务


流量预测



异常检测



路径规划



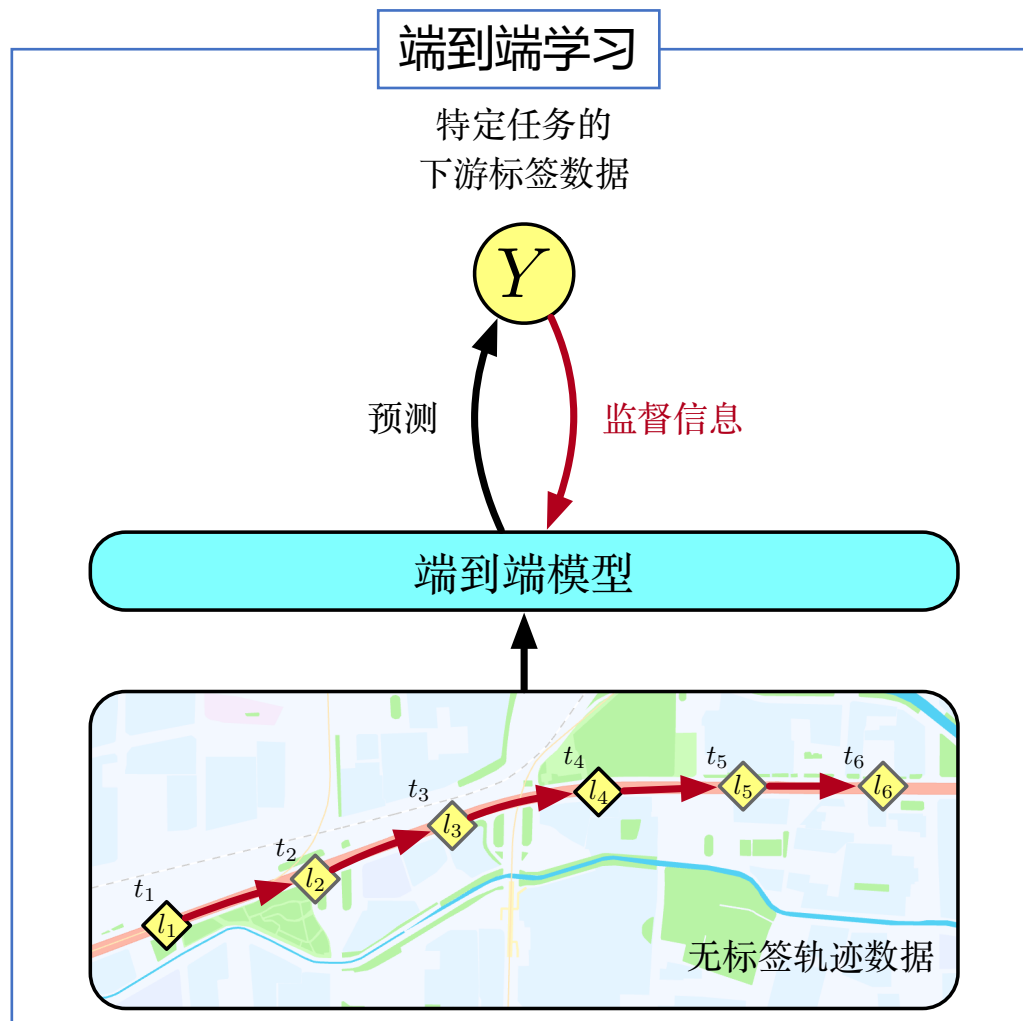
时空轨迹数据挖掘

- 深度学习算法能够**高效、自动化**地抽取轨迹数据的**复杂时空特征**

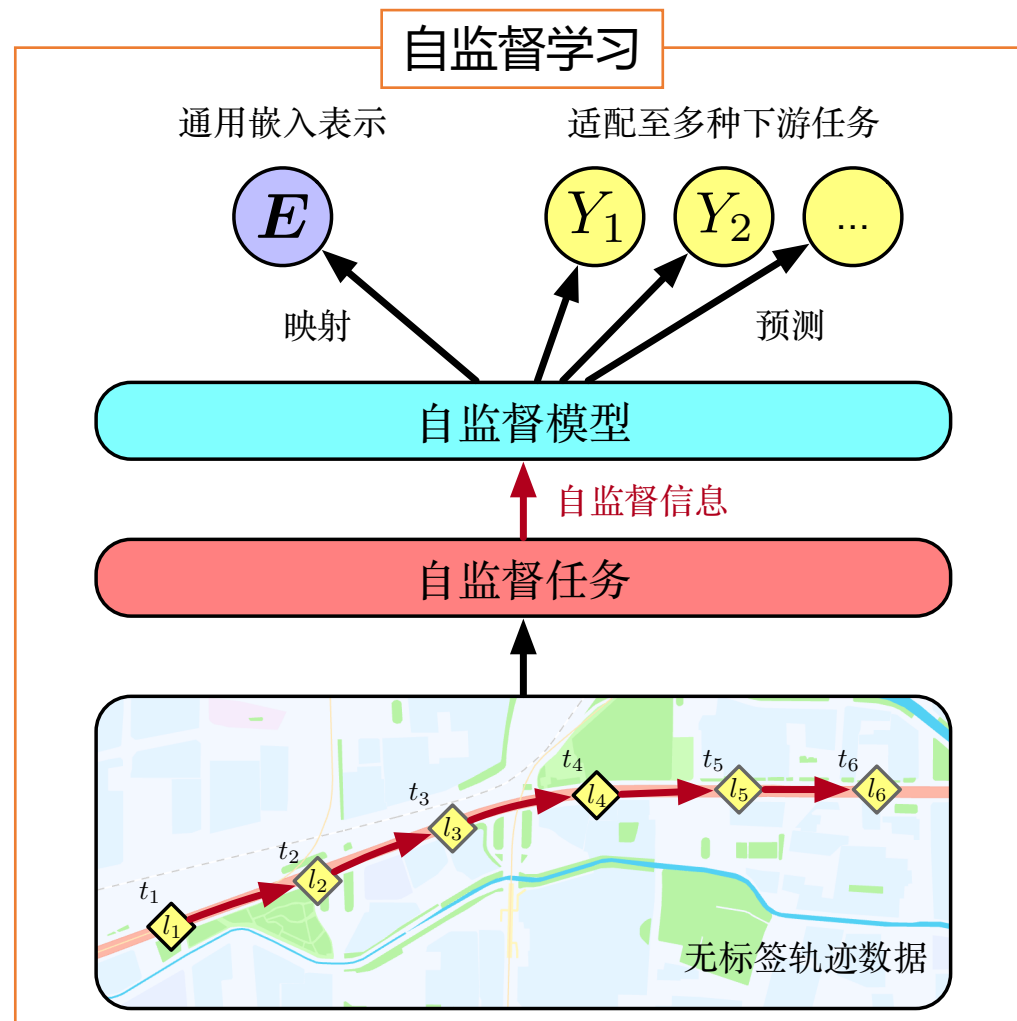


端到端学习与自监督学习

- 依赖大规模标签数据，学习的模型难以在不同任务间迁移




- 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模型

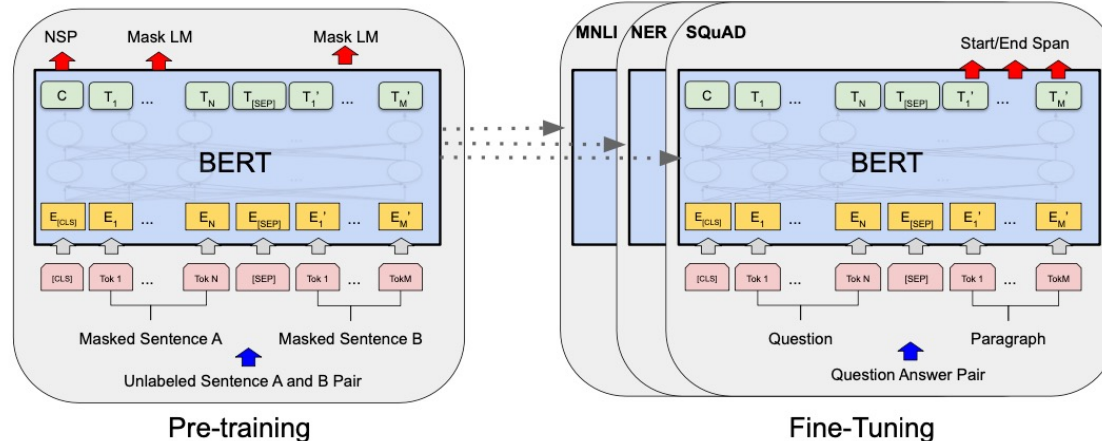


自监督学习


- 在自然语言与计算机视觉领域已被广泛用于强化模型的理解能力与泛化性能



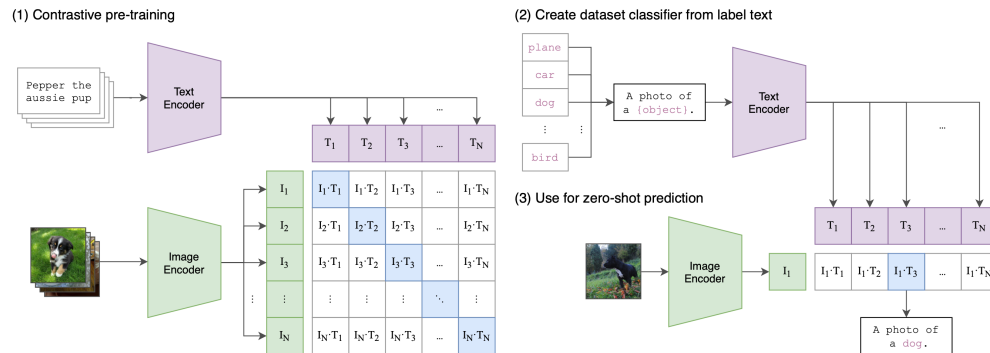
基于上下文的自然语言理解



基于掩码的自然语言理解



基于自回归生成的自然语言理解



基于对比学习的语言-视觉理解

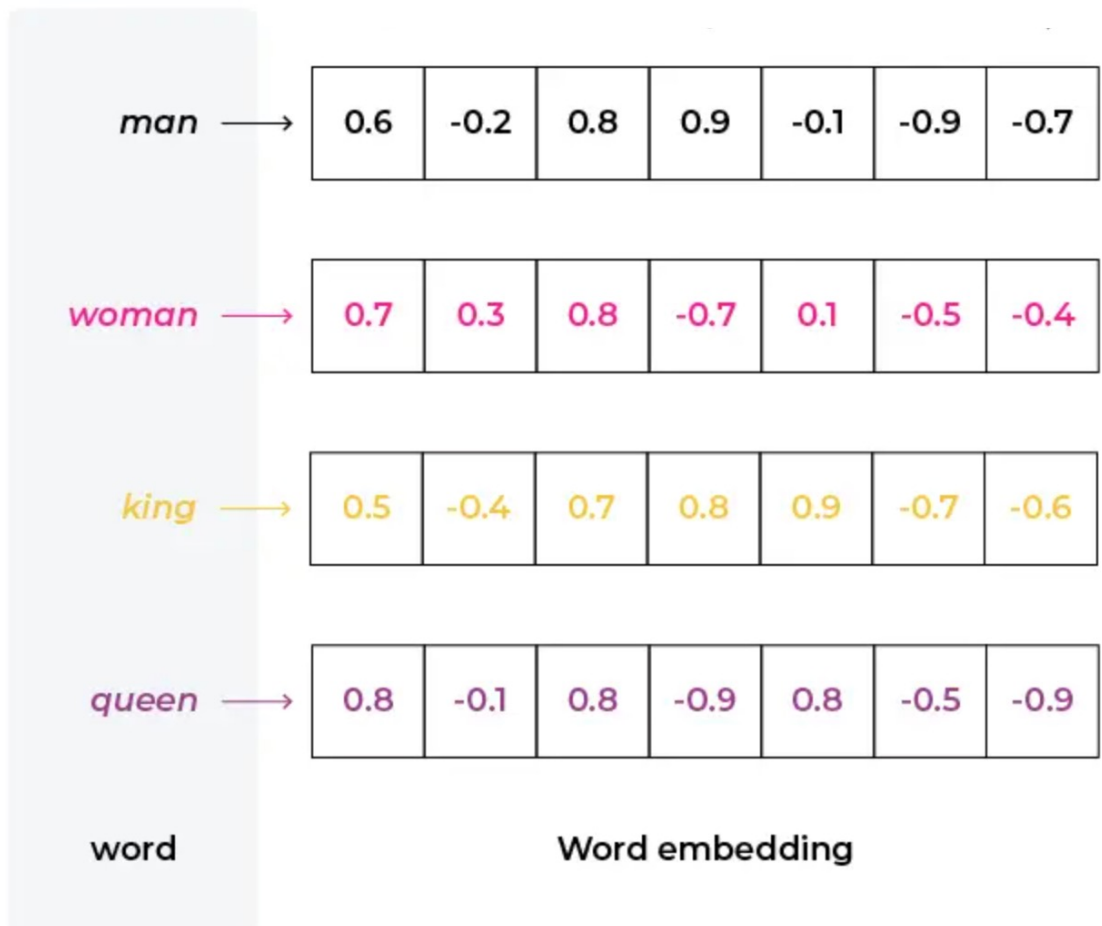
使用自监督学习挖掘哪些信息？

如何设计自监督任务来挖掘这些信息？


- 1 轨迹自监督学习研究背景
- 2 基于词嵌入的轨迹自监督学习
- 3 基于自编码器的轨迹自监督学习
- 4 基于对比学习的轨迹自监督学习
- 5 轨迹自监督学习研究展望

词嵌入基础

- 将单词映射为特定维度的嵌入向量，在嵌入空间中反映单词的语义信息与相关性




单词映射为嵌入向量



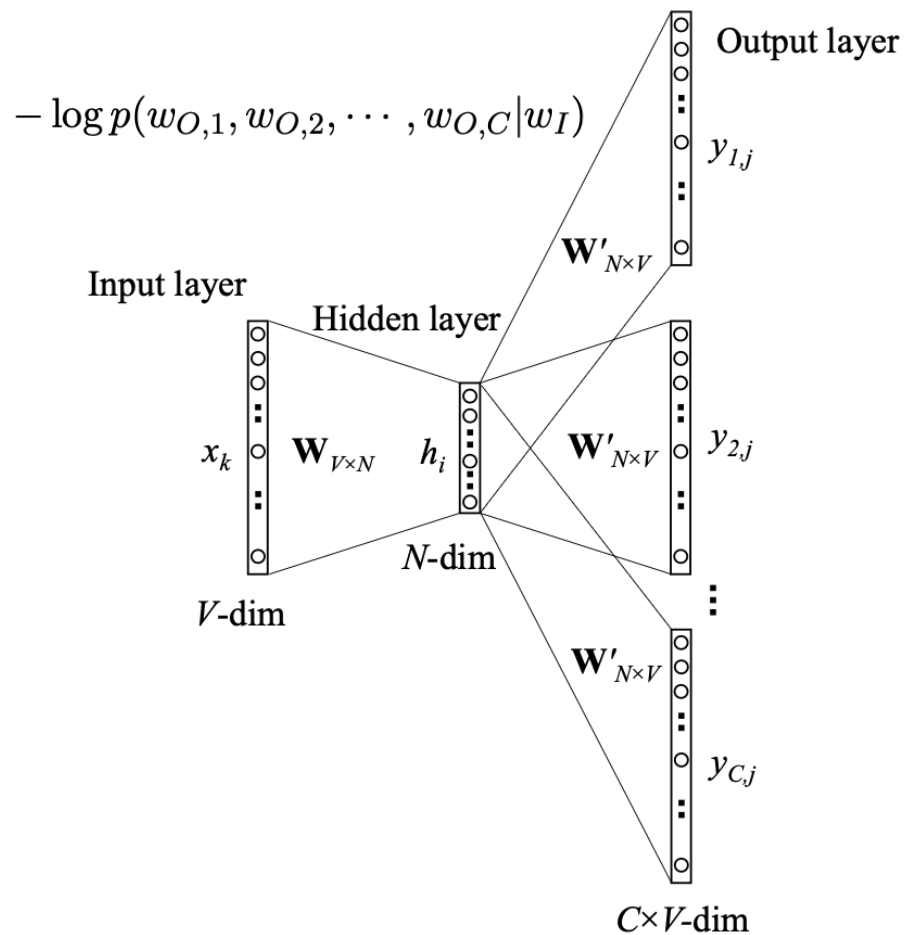
单词语义与嵌入的对应关系

静态词嵌入模型

- 为单词分配固定的嵌入向量，最大化目标词与上下文词共同出现的概率



CBOW

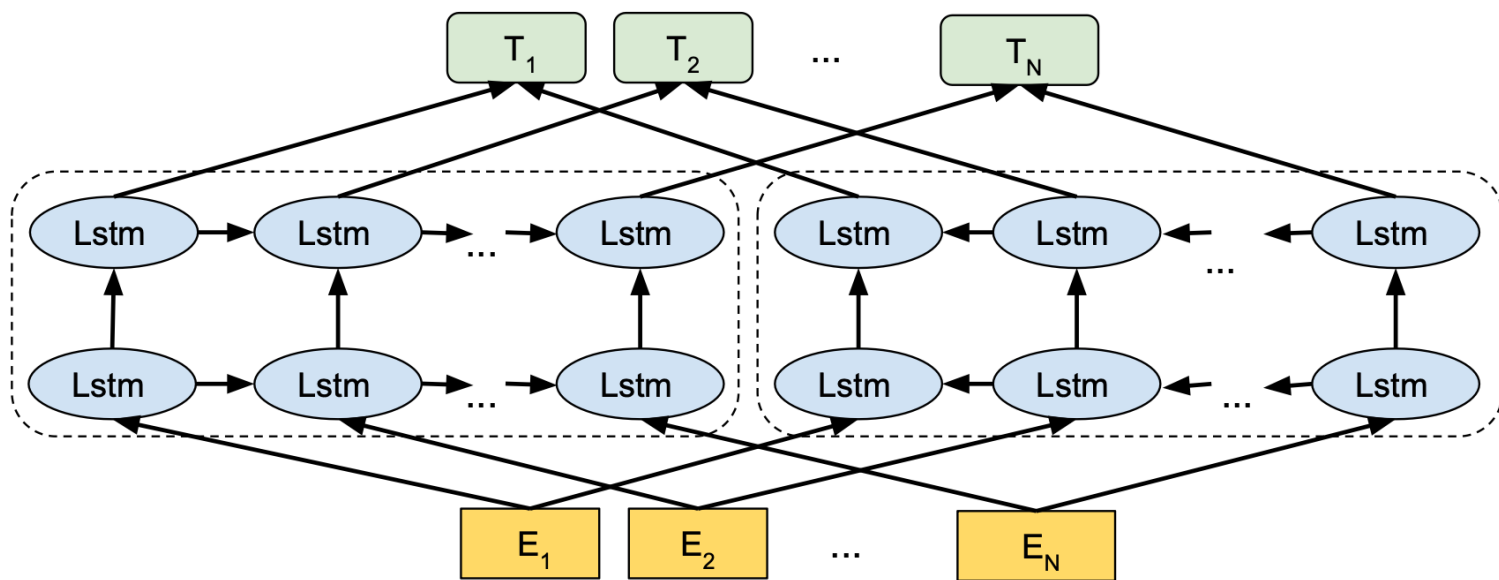


Skip-Gram


- T. Mikolov, K. Chen, G. Corrado, and J. Dean, "Efficient Estimation of Word Representations in Vector Space." in ICLR 2013.
- T. Mikolov, I. Sutskever, K. Chen, G. S. Corrado, and J. Dean, "Distributed Representations of Words and Phrases and their Compositionality," in NeurIPS 2013.
- X. Rong, "word2vec Parameter Learning Explained."

上下文词嵌入模型

- 利用序列模型，建模句子中**目标词与上下文词的关联性**，动态计算词嵌入向量



ELMo基于RNN的双向模型



BERT基于Transformer的双向模型

- M. E. Peters et al., "Deep contextualized word representations." in HLT-NAACL 2018.
- J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding." in NAACL-HLT 2019.


词嵌入在时空轨迹数据上的迁移

➤ 时空轨迹与文本的相似性

序列性

自然语言 Self-supervised Learning of Spatio-temporal Trajectory Data

时空轨迹



上下文关联性

自然语言

The proposed method can incorporate temporal information ...
The proposed method can fuse temporal information ...

上下文


目标

上下文


时空轨迹

... → 学苑食堂 → 知行大厦 → 学生活动中心 → ...
... → 学苑食堂 → 科技大厦 → 学生活动中心 → ...



学生宿舍 知行大厦 学生食堂



学生宿舍 科技大厦 学生食堂




不同地点的功能相似性



同一地点的多功能性

词嵌入在时空轨迹数据上的迁移

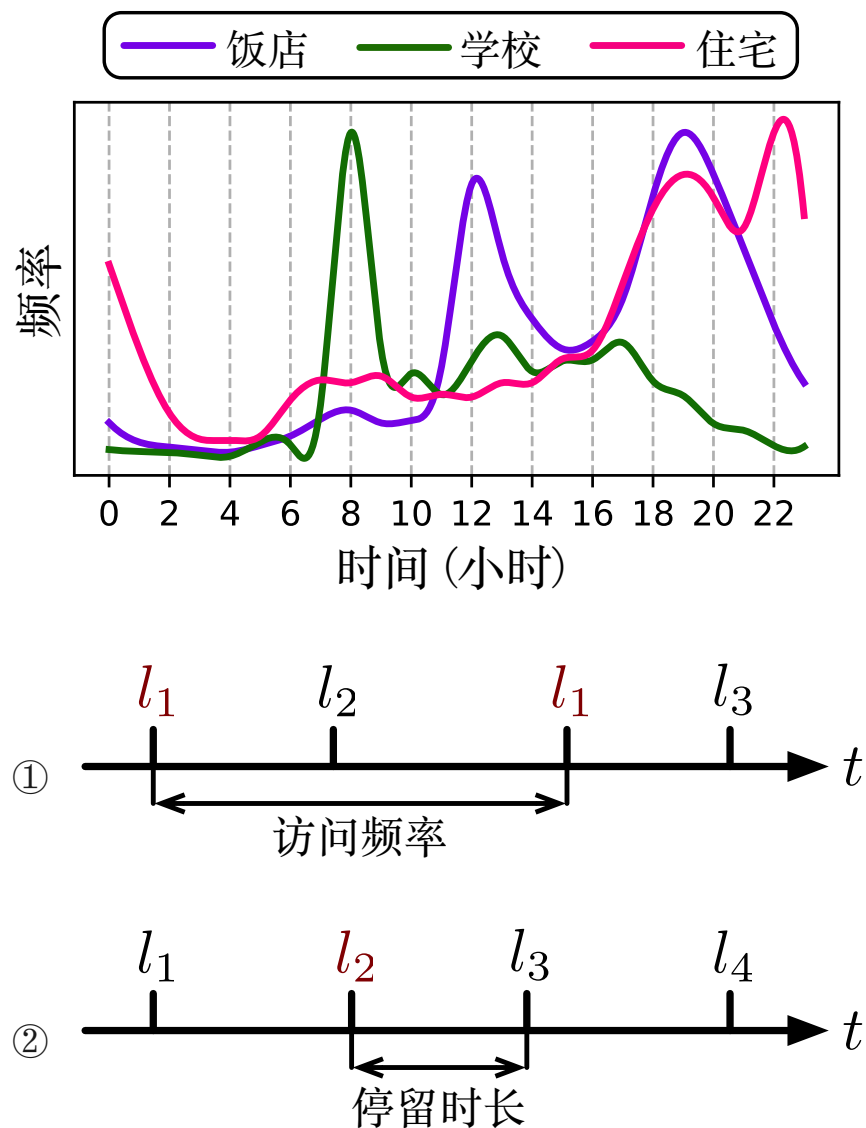
➤ 时空轨迹的特殊特征



时空轨迹中的时间信息


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

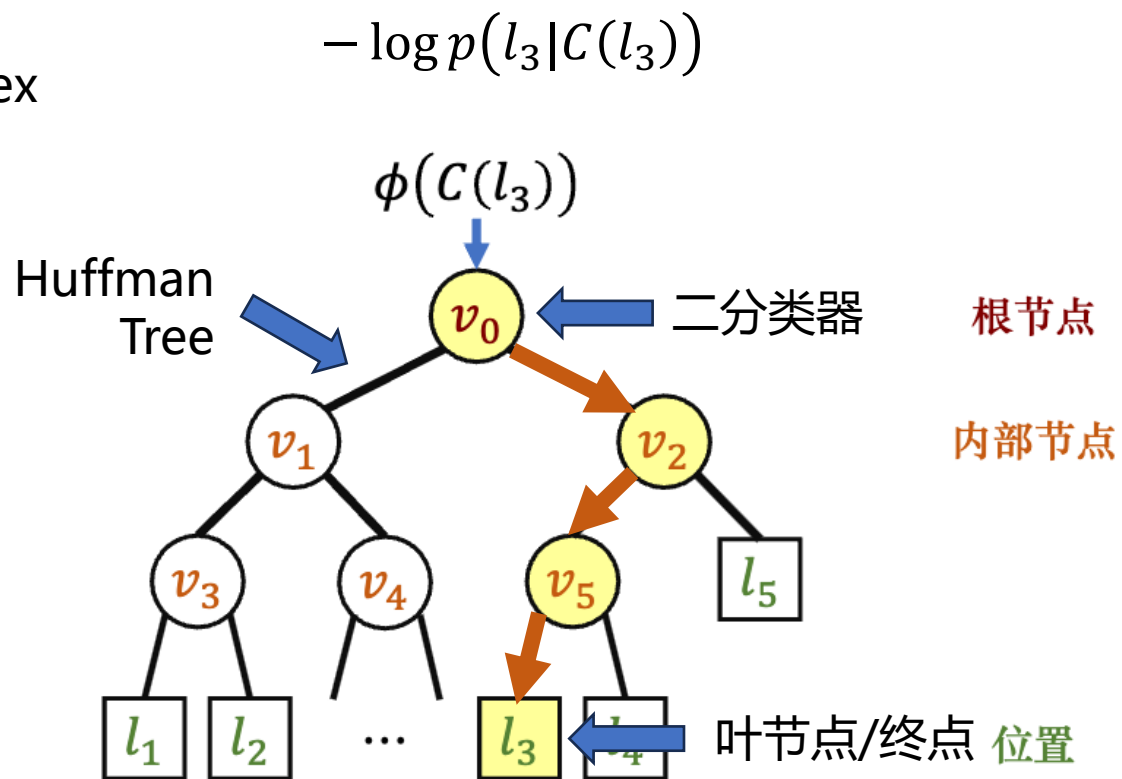


词嵌入在时空轨迹数据上的迁移

- 将词嵌入技术应用于轨迹数据需要一些特殊处理



时空轨迹对象的离散化




词嵌入训练的加速

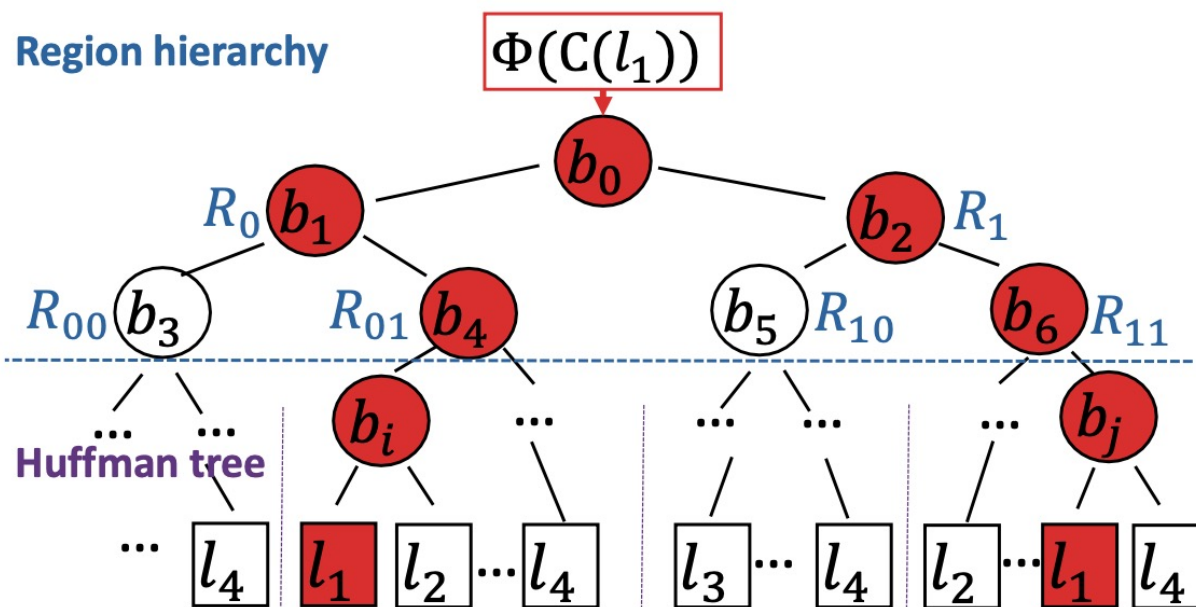
基于词嵌入的地点表示学习

➤ POI2Vec

- 将地理空间层次划分为网格，对应二叉树中的内部节点，提出空间哈夫曼树结构
- 将空间相近的地点分配到同一棵子树中，提取地点的空间相关性信息并融入地点嵌入向量



层次空间划分



融合层次空间相关性的哈夫曼树


Feng S, Cong G, An B, et al. POI2Vec: Geographical latent representation for predicting future visitors[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2017, 31(1).

基于词嵌入的地点表示学习

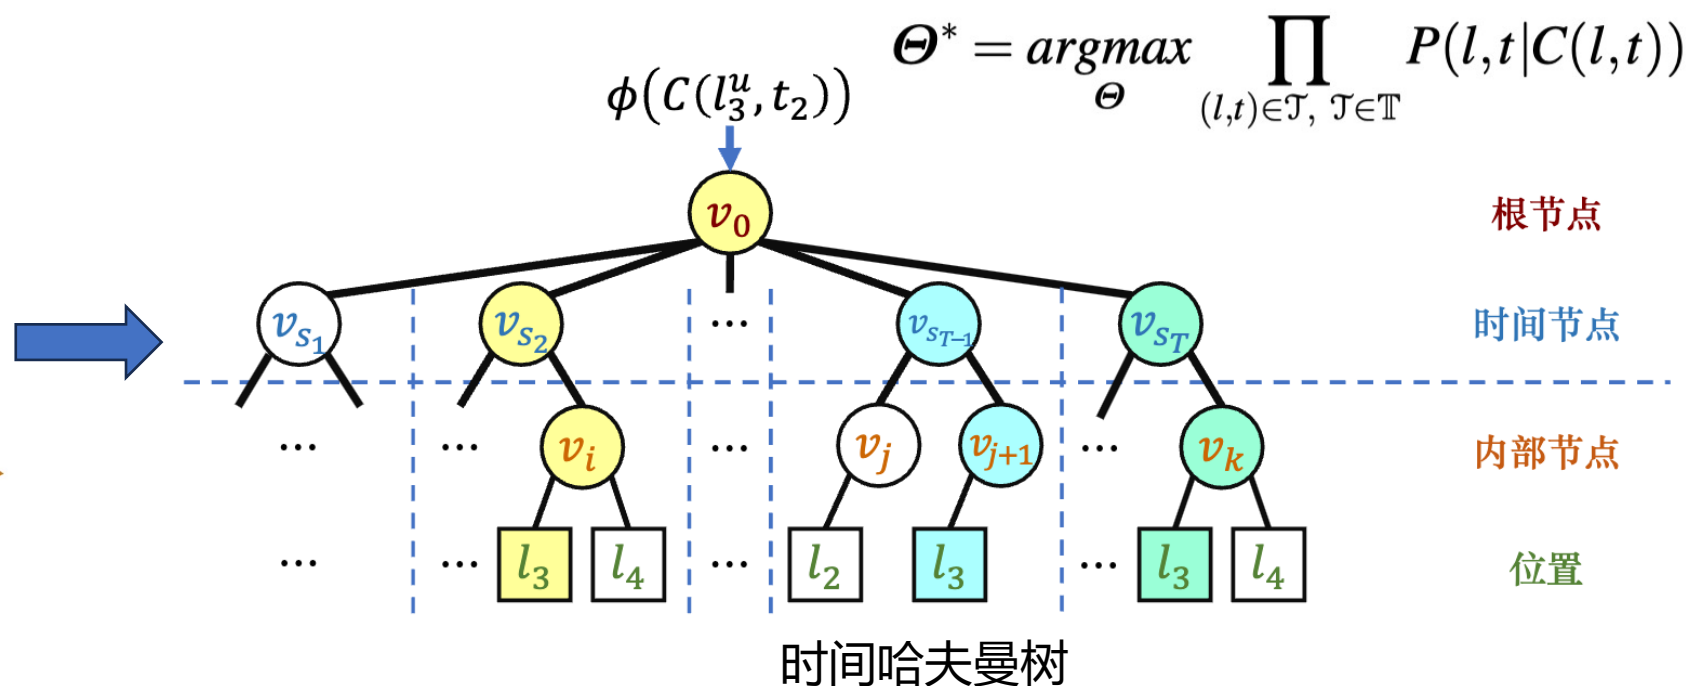
Time-Aware Location Embedding (TALE)

- 将一天中的时间划分为时间片并对应时间节点，提出时间哈夫曼树结构
- 将相近时间片内被访问的地点分配至同一棵子树，提取轨迹中的访问时间信息并融入地点嵌入向量

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



时间片划分




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.

基于词嵌入的地点表示学习

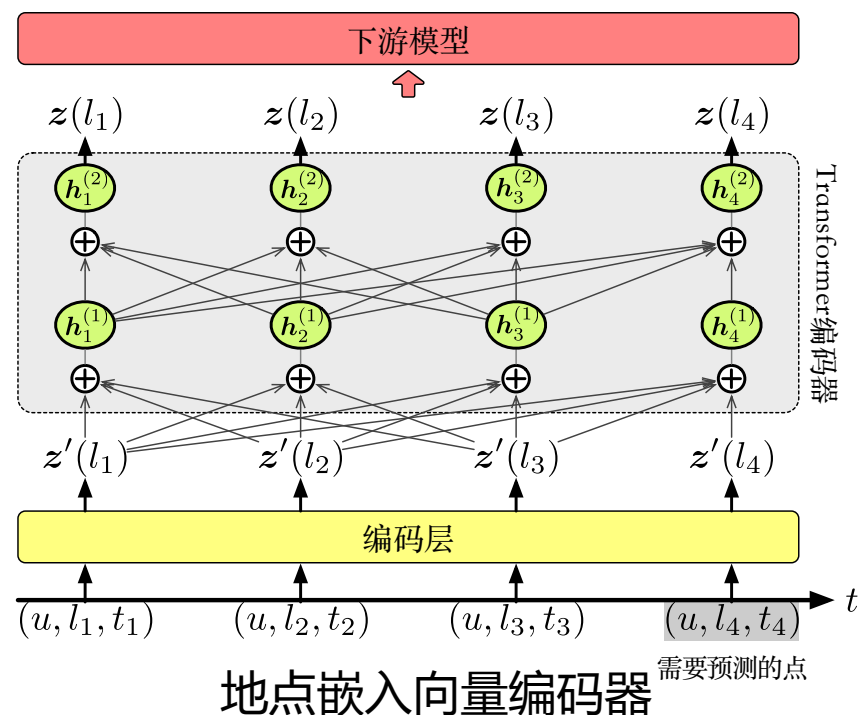
➤ Context and Time-aware Location Embeddings (CTLE)

- 根据地点的上下文动态生成嵌入向量，为多功能地点学习更准确的表示
- 提出了基于Transformer的地点嵌入向量编码器，建模地点与上下文的动态关联性

$$z_l = f(l, C(l))$$



CTLE的基本思想



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.

基于词嵌入的地点表示学习

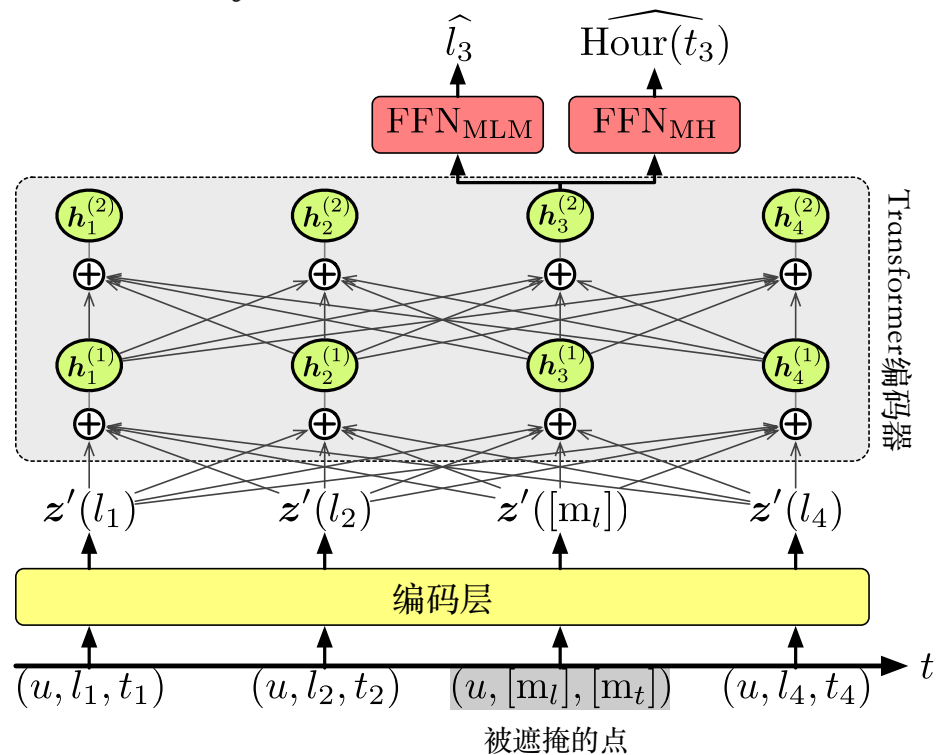
Context and Time-aware Location Embeddings (CTLE)

- 全面考虑轨迹中绝对和相对两方面的访问时间信息
- 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**

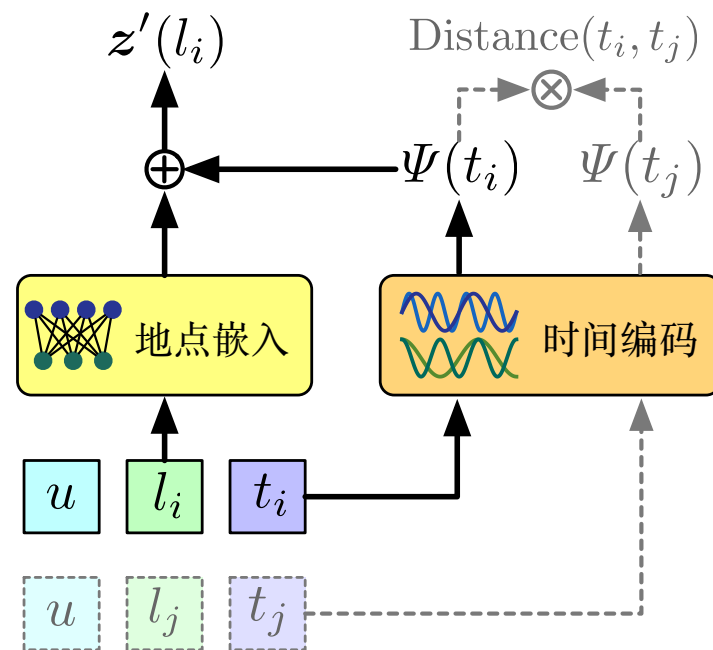
$$O_{MH} = \arg \max_{\theta} \sum_{t_m \in \Gamma} P(\text{Hour}(t_m) | \text{FFN}_{MH}(f(\tilde{\mathcal{T}})_m))$$

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

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



掩码小时预训练任务




地点嵌入与时间编码模块

- 1 轨迹自监督学习研究背景
- 2 基于词嵌入的轨迹自监督学习
- 3 基于自编码器的轨迹自监督学习
- 4 基于对比学习的轨迹自监督学习
- 5 轨迹自监督学习研究展望

自编码器基础

- 编码器将原始数据压缩为低维表示，解码器从表示重构原始数据

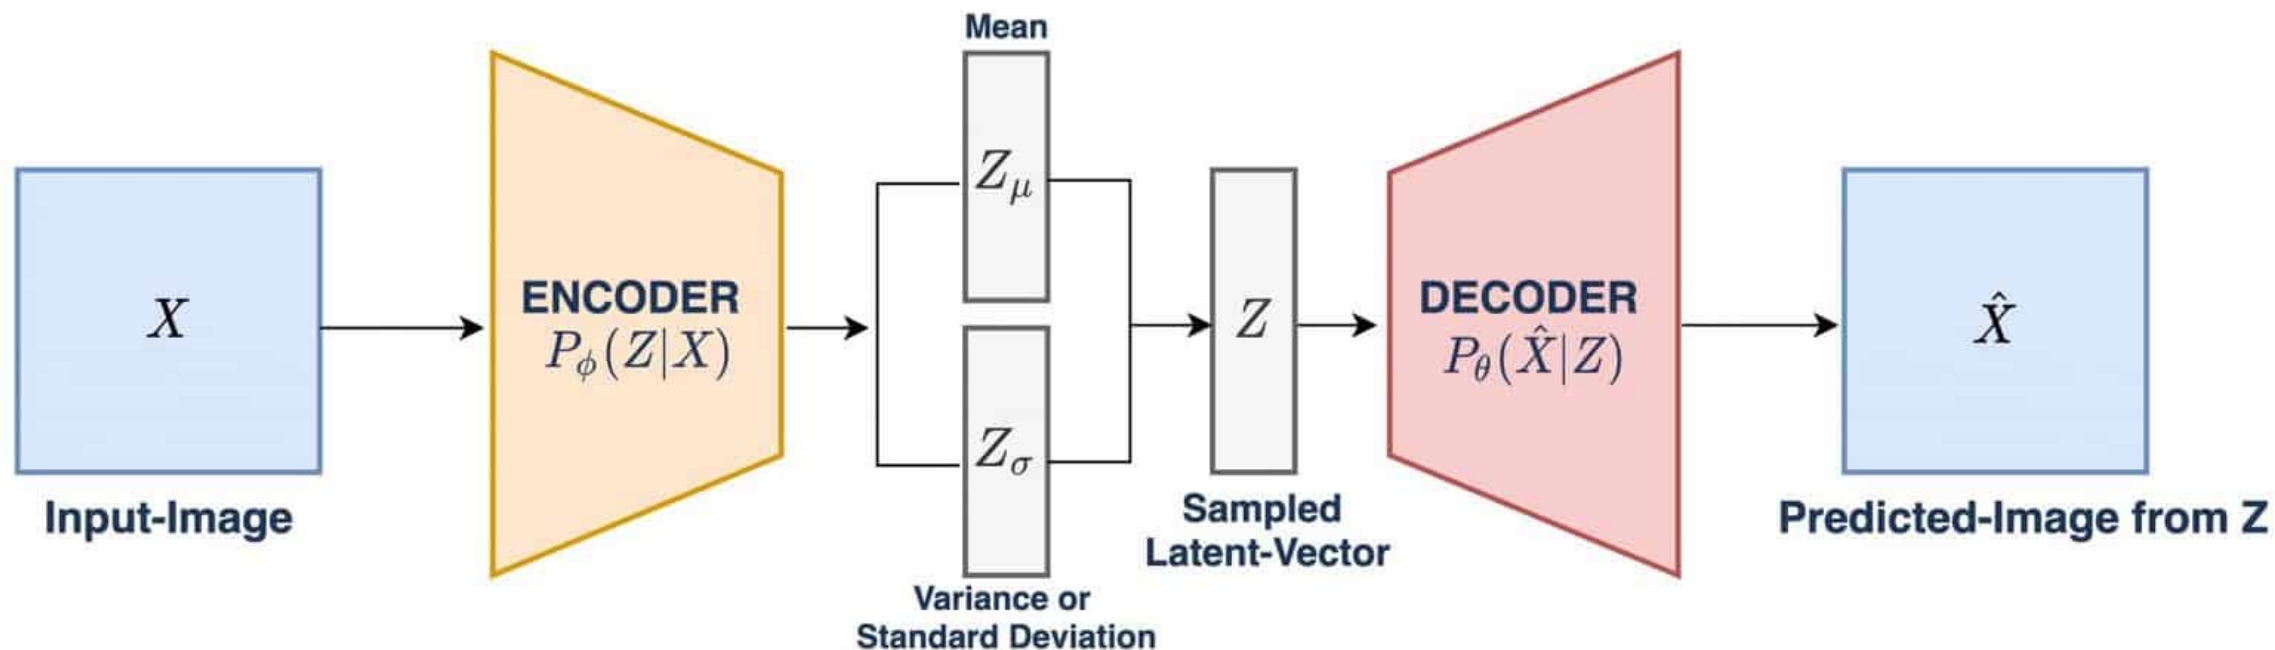


自编码器结构

Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. science, 2006, 313(5786): 504-507.

自编码器变体

- 将低维表示空间建模为多维高斯分布，提升模型可解释性与生成性能




变分自编码器

Kingma D P, Welling M. Auto-encoding variational bayes[C]//2nd International Conference on Learning Representations (ICLR), 2014.

自编码器变体

- 向编码器输入数据中添加噪音，解码器试图重构无噪音原始数据



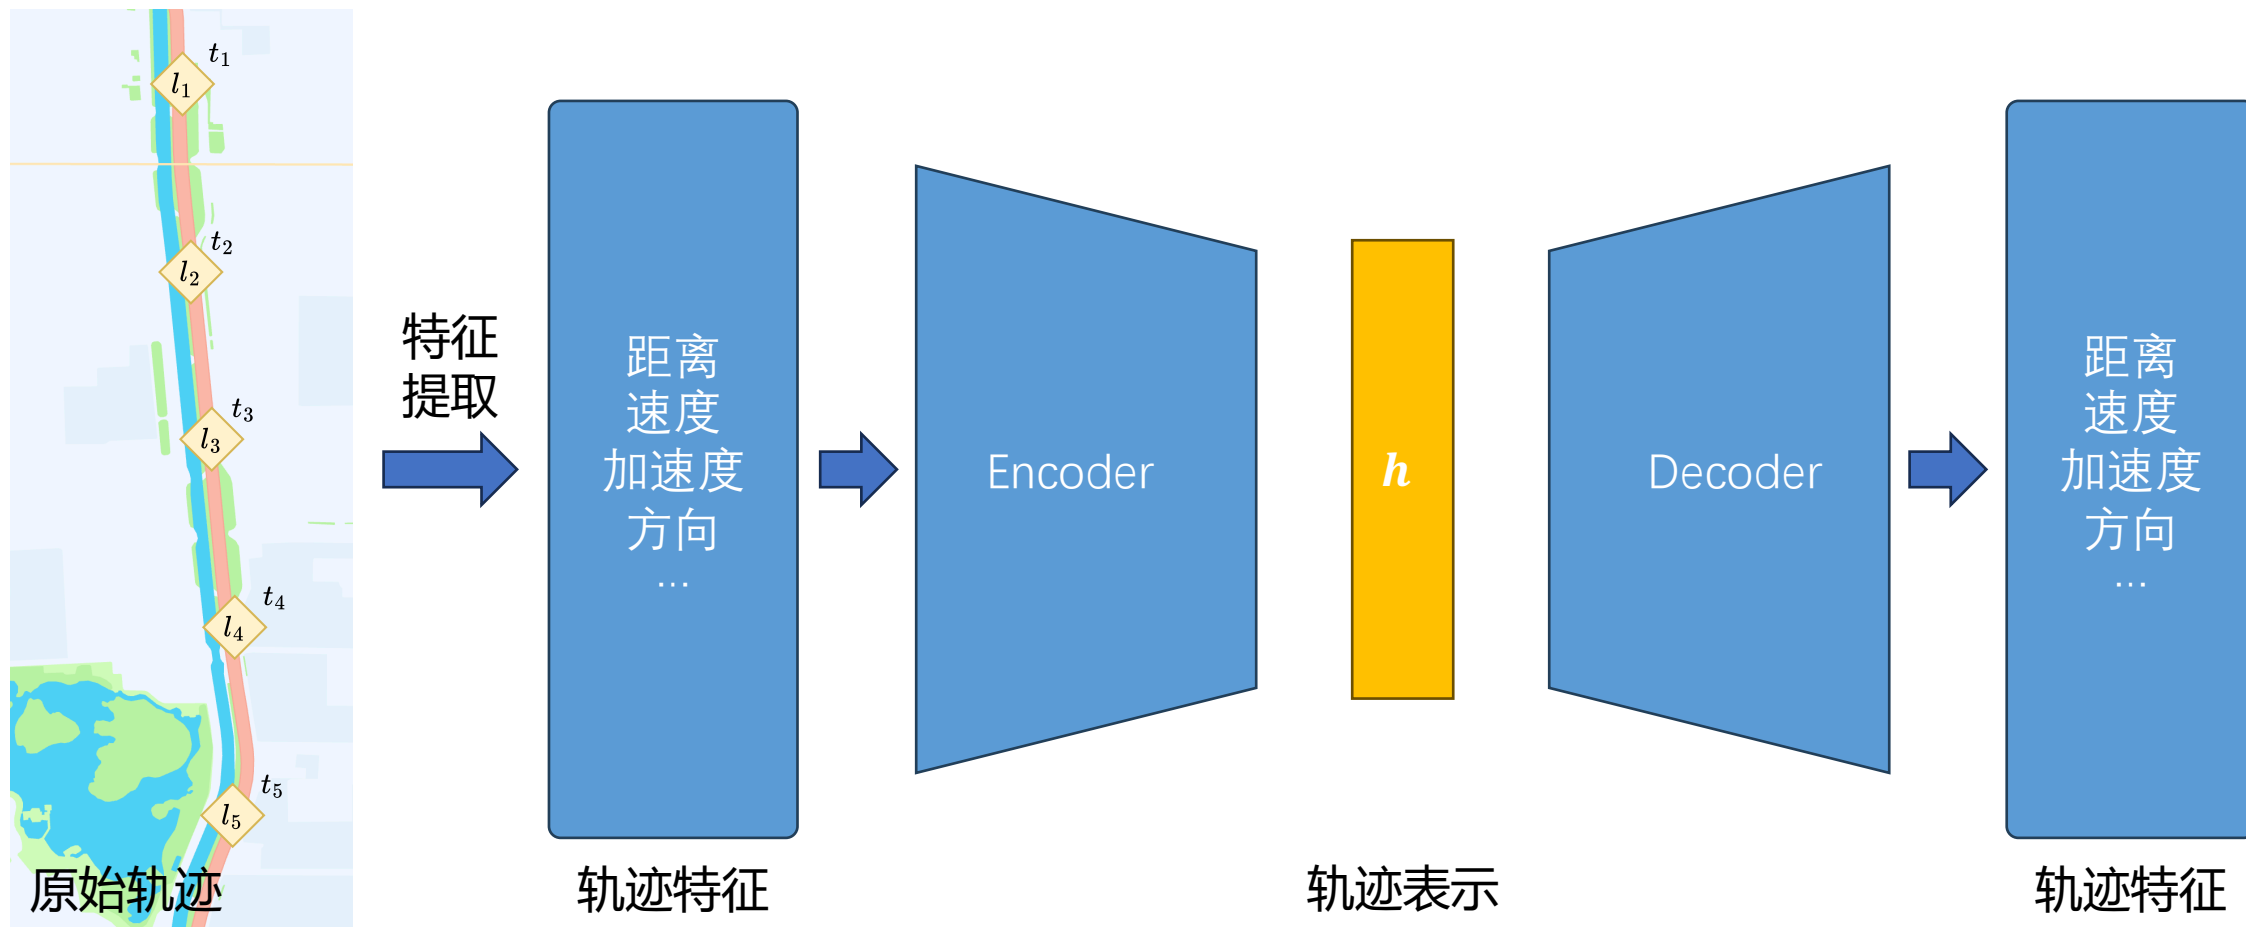
降噪自编码器

Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders[C]//Proceedings of the 25th international conference on Machine learning. 2008: 1096-1103.

基于自编码器的轨迹表示学习

➤ 自编码器用于轨迹特征压缩

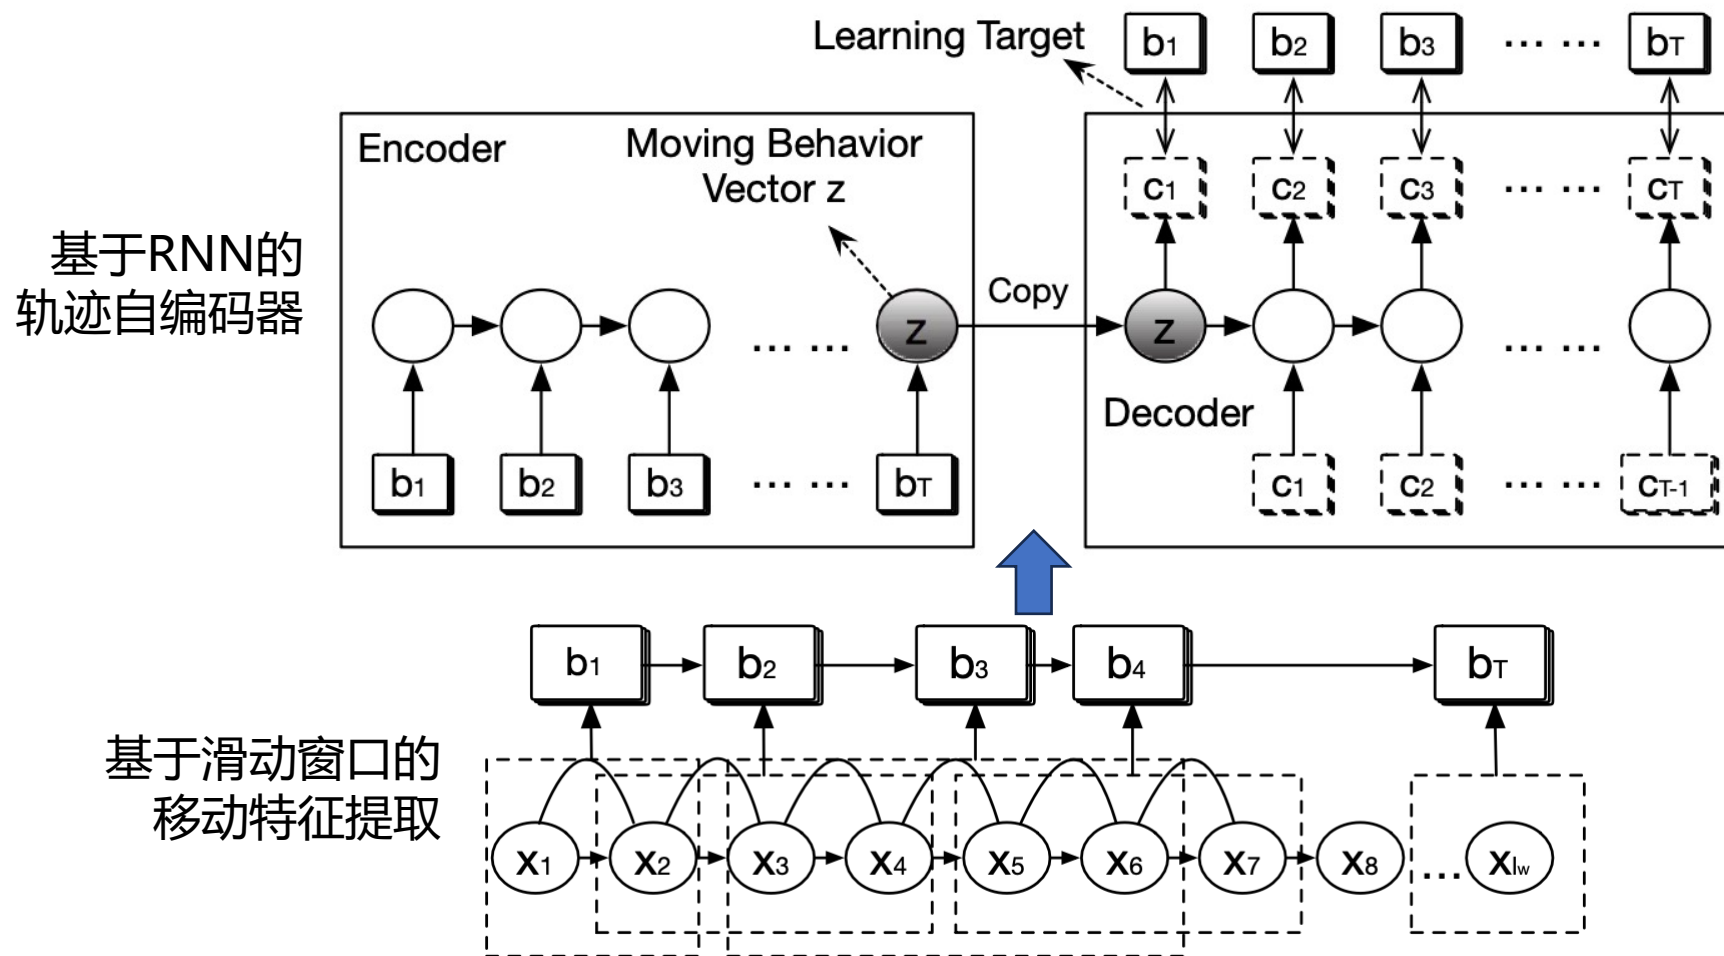
- 低维表示的信息与输入输出数据强相关，关键在于**轨迹的特征提取**



基于自编码器的轨迹表示学习

➤ traj2vec

- 使用滑动窗口提取距离、加速度、行驶角度等**高阶特征**

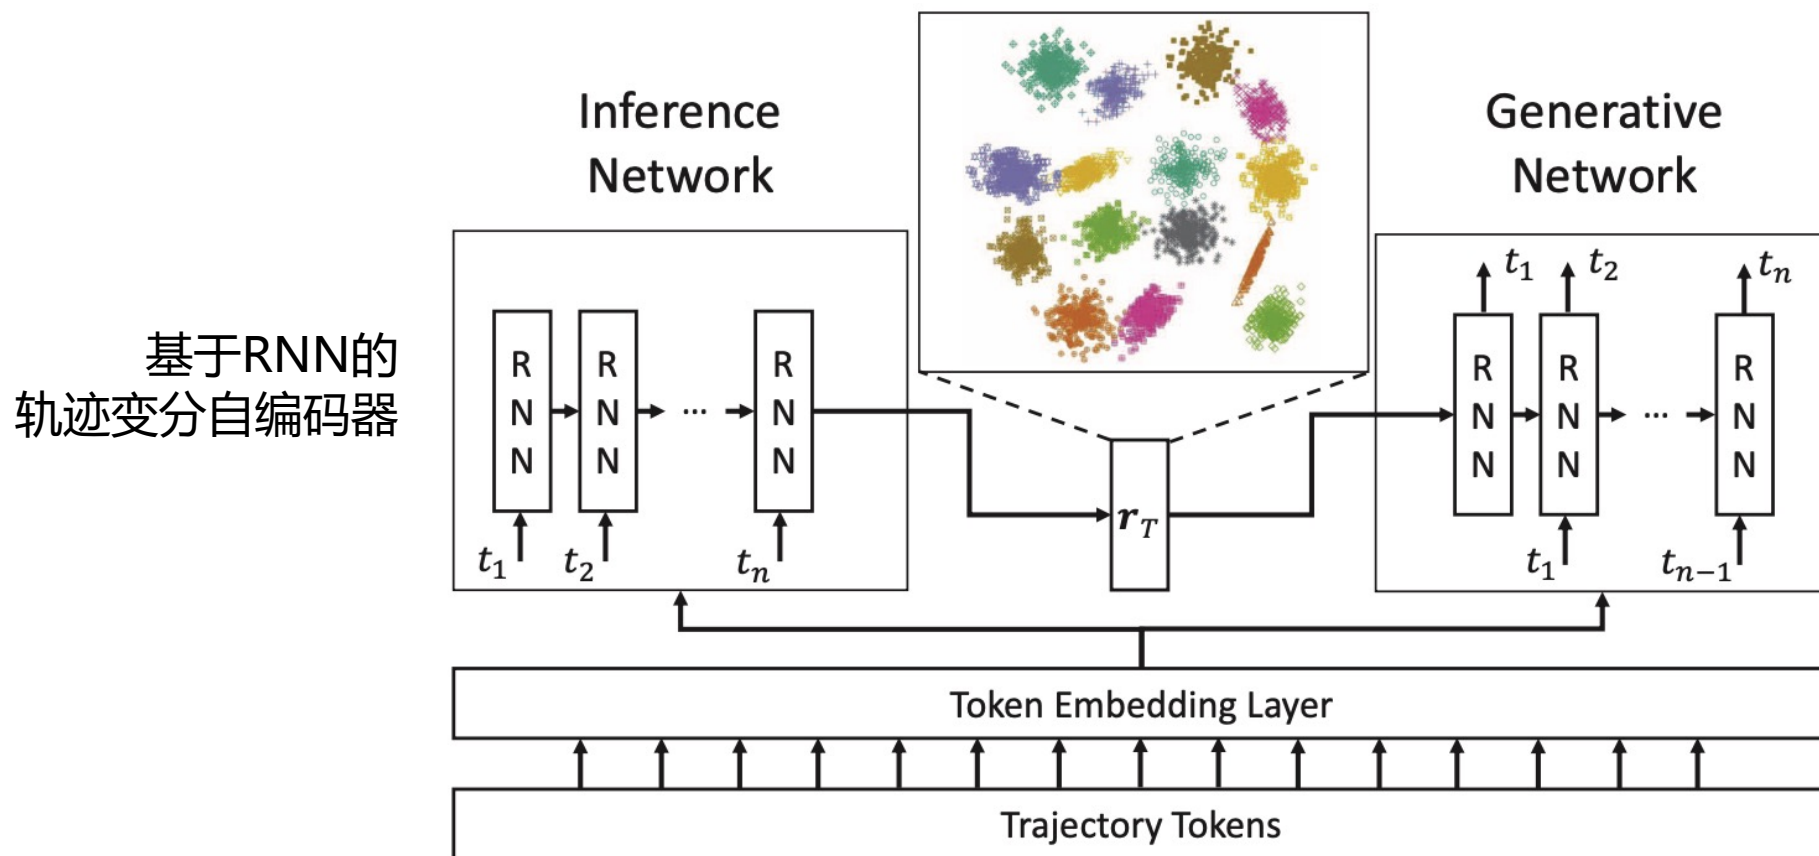


Yao D, Zhang C, Zhu Z, et al. Trajectory clustering via deep representation learning[C]//2017 international joint conference on neural networks (IJCNN). IEEE, 2017: 3880-3887.

基于自编码器的轨迹表示学习

➤ GM-VSAE

- 基于变分自编码器建模轨迹的分布，并用于轨迹异常检测

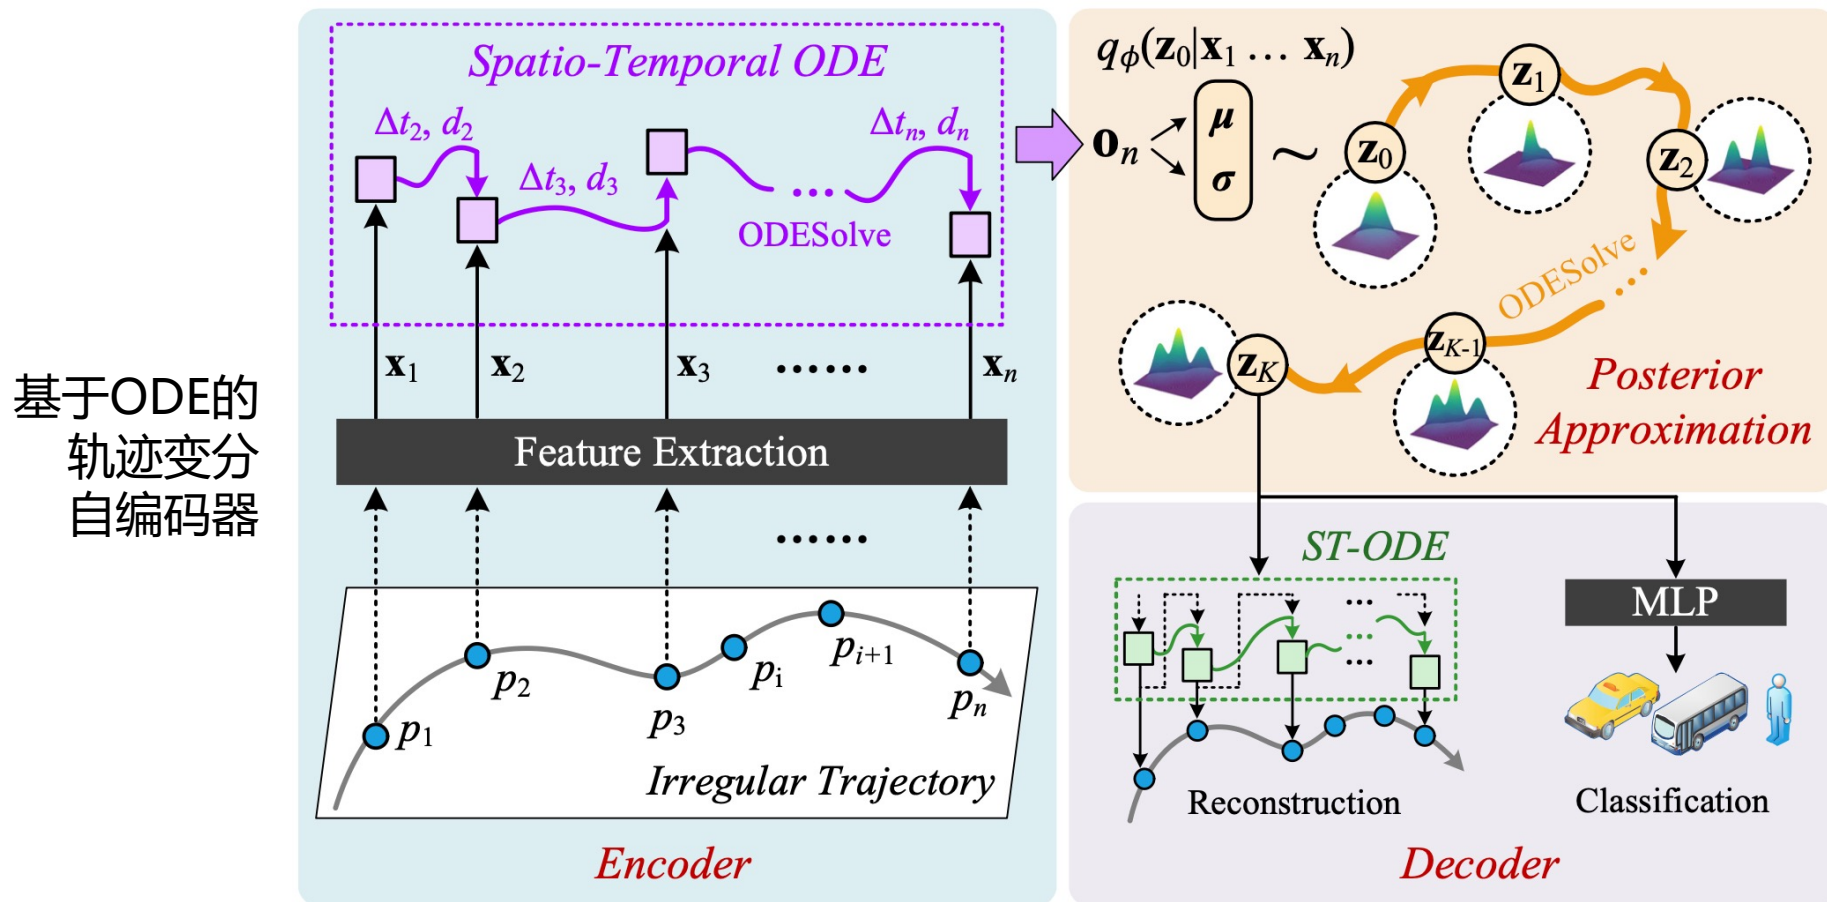


Liu Y, Zhao K, Cong G, et al. Online anomalous trajectory detection with deep generative sequence modeling[C]//2020 IEEE 36th International Conference on Data Engineering (ICDE). IEEE, 2020: 949-960.

基于自编码器的轨迹表示学习

➤ TrajODE

- 基于NeuralODE构建轨迹编解码器，优化对不等间距采样轨迹的建模性能

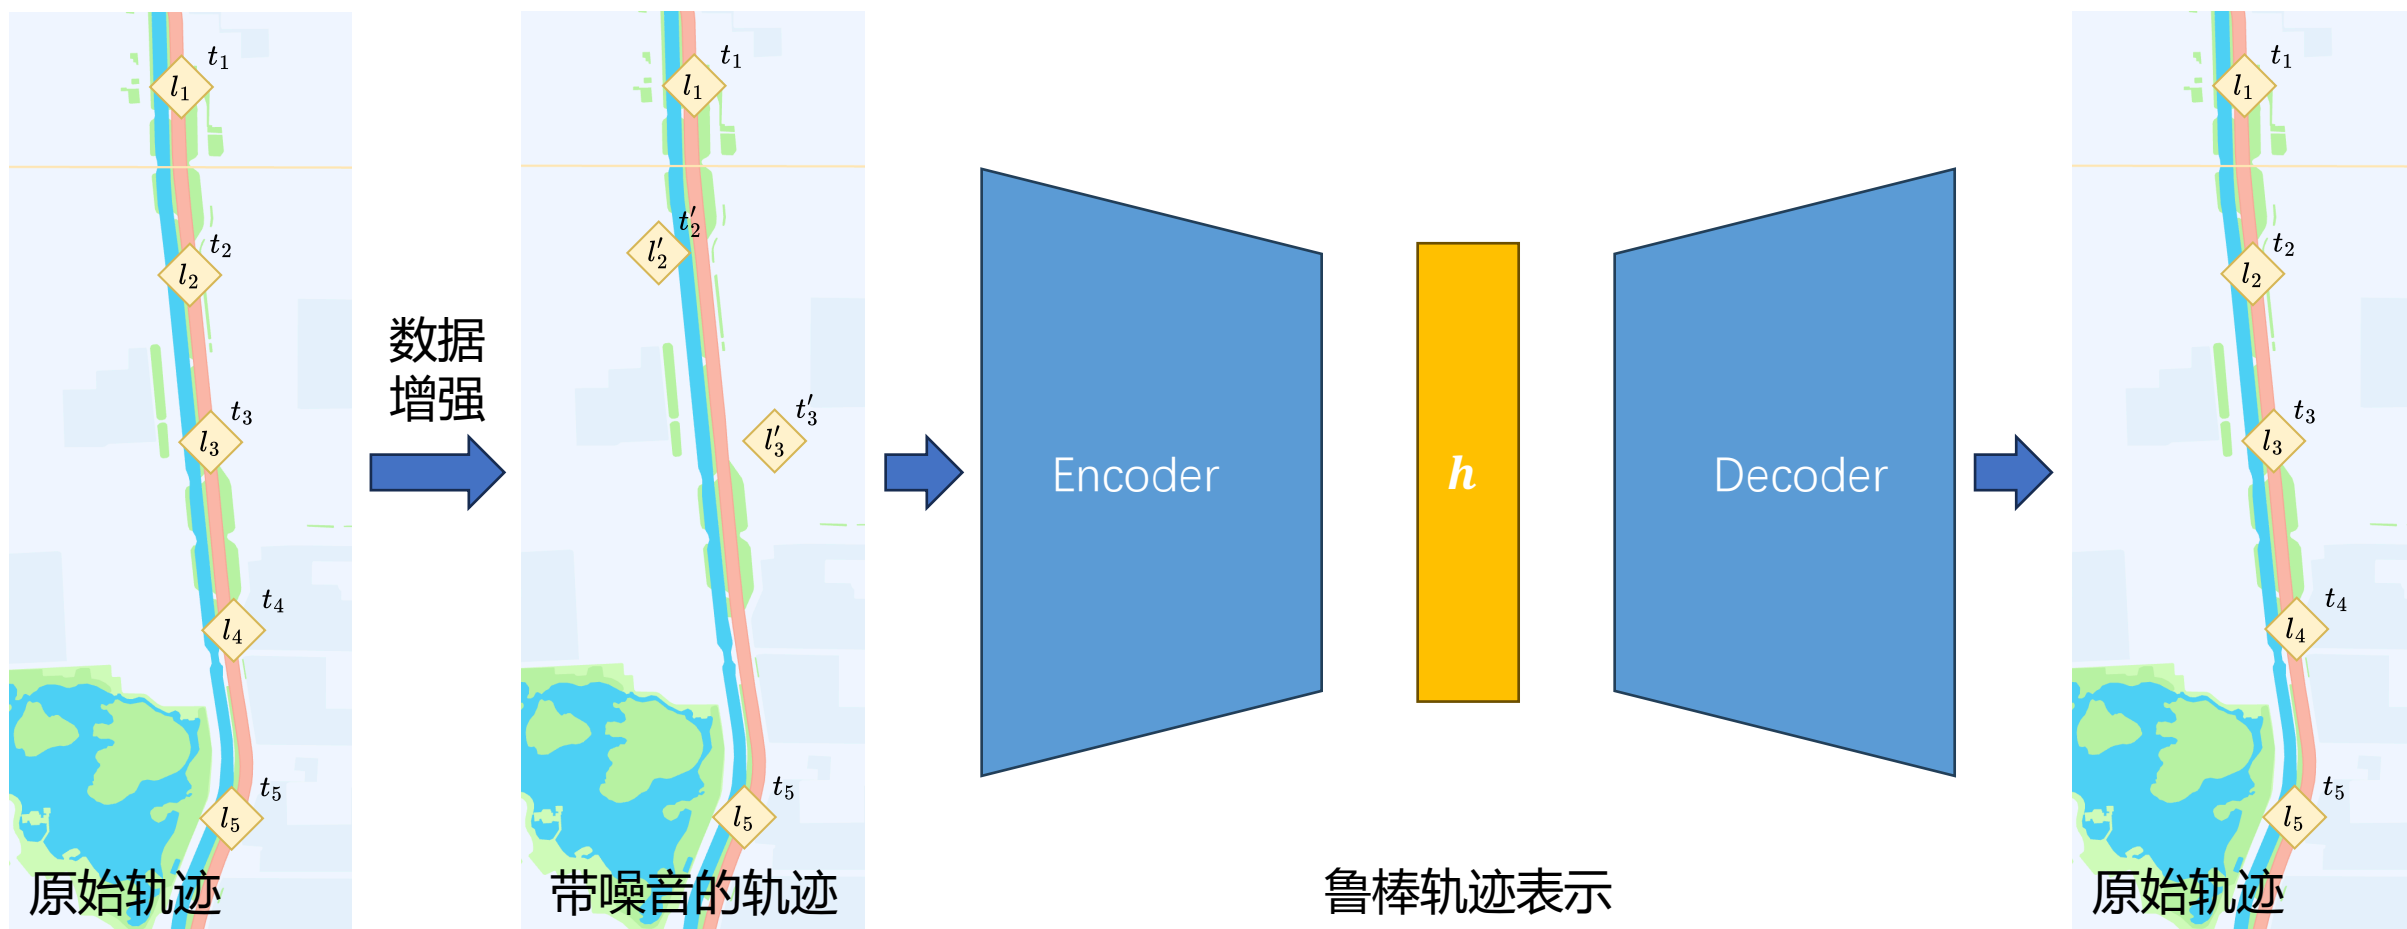


Liang Y, Ouyang K, Yan H, et al. Modeling Trajectories with Neural Ordinary Differential Equations[C]//IJCAI. 2021: 1498-1504.

基于自编码器的轨迹表示学习

➤ 降噪自编码器用于鲁棒的轨迹表示学习

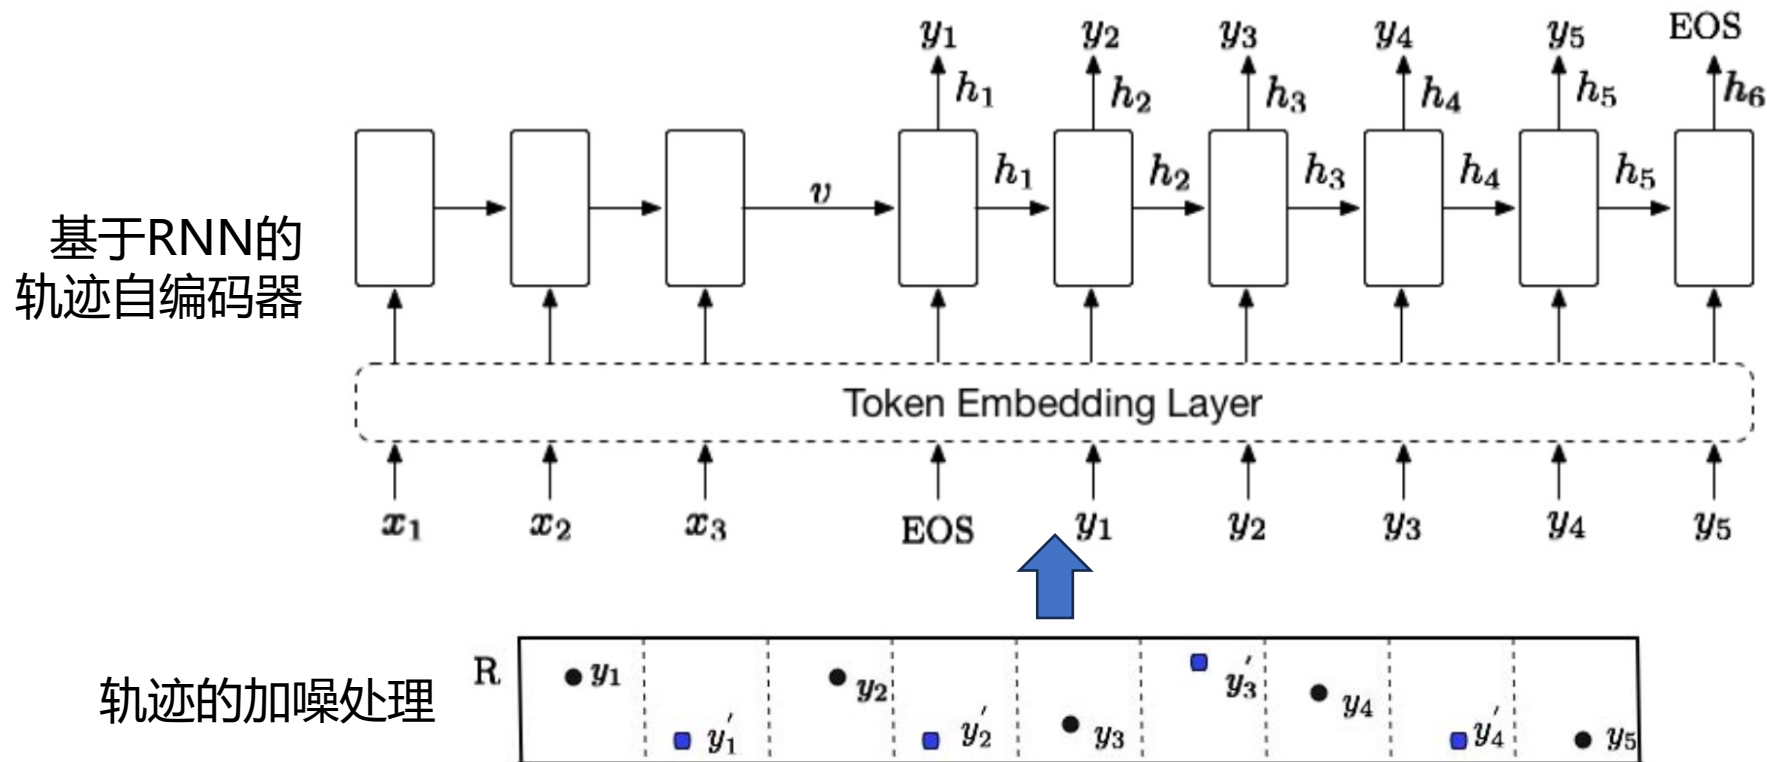
- 使用重采样、加噪音等数据增强方案，构建轨迹的降噪自编码器，学习更鲁棒的轨迹表示



基于自编码器的轨迹表示学习


➤ t2vec

- 向轨迹编码器的输入轨迹中添加噪音，学习对噪音更加鲁棒的轨迹表示

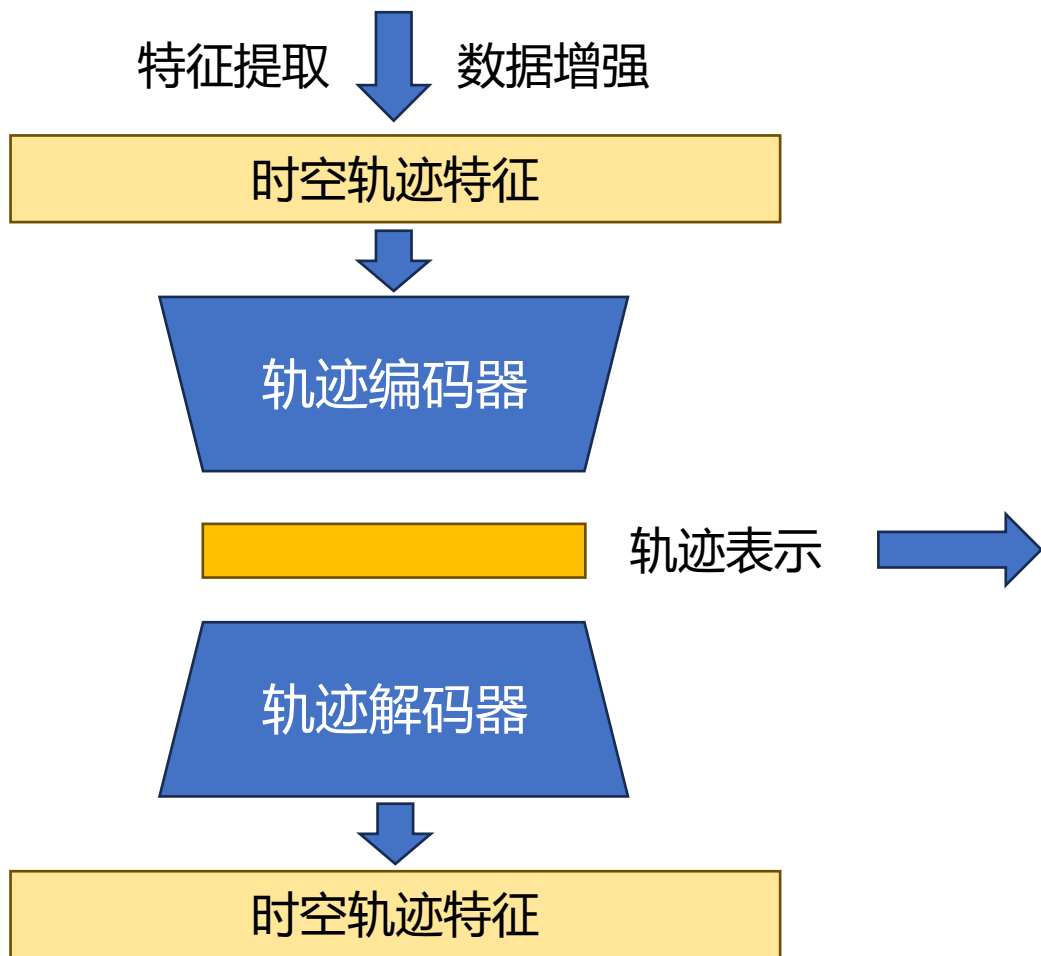


Li X, Zhao K, Cong G, et al. Deep representation learning for trajectory similarity computation[C]//2018 IEEE 34th international conference on data engineering (ICDE). IEEE, 2018: 617-628.


基于自编码器的轨迹自监督学习



时空轨迹



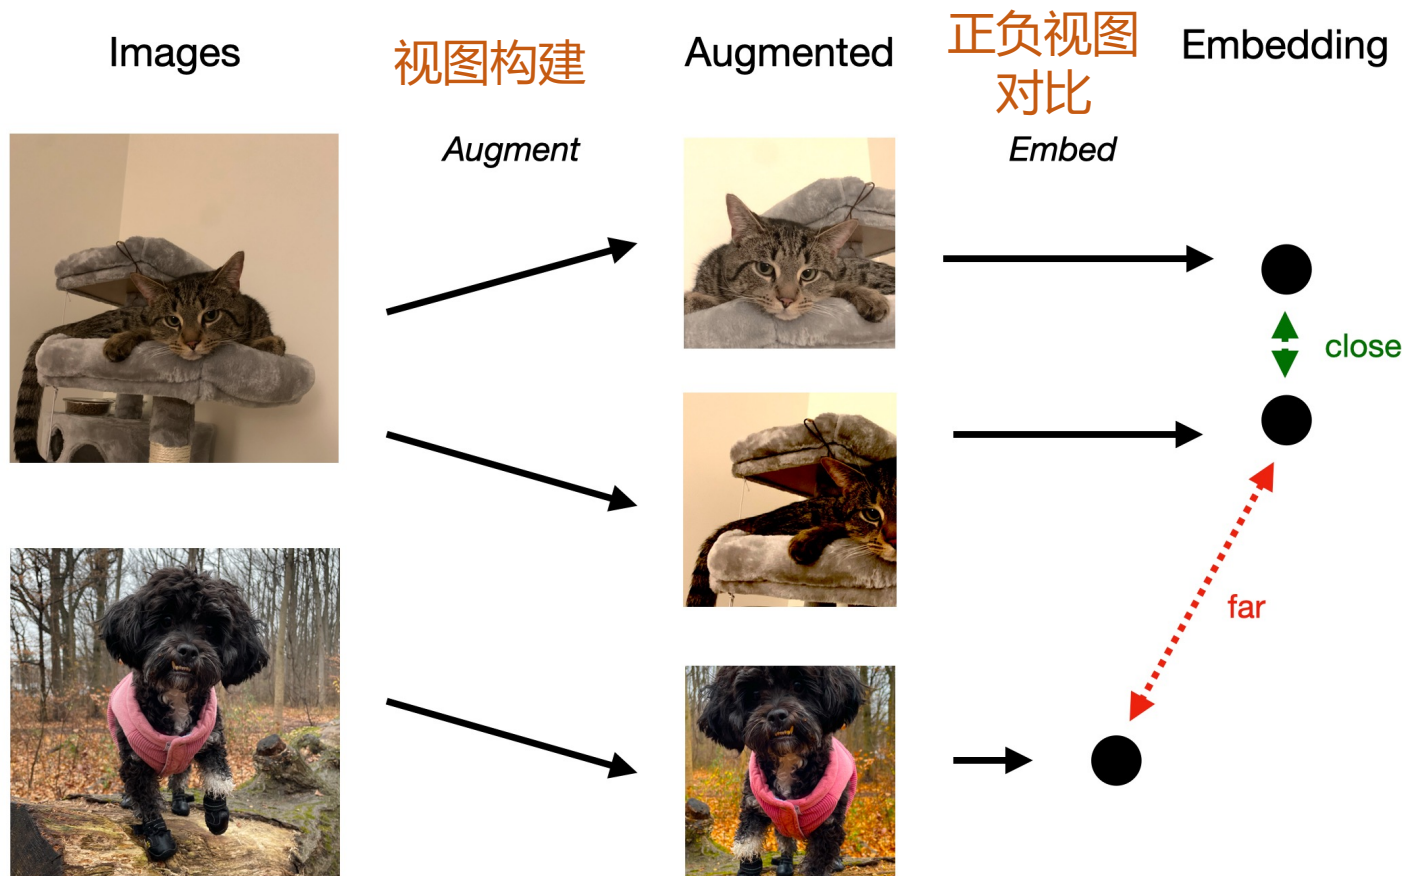
轨迹特征分析



- 1 轨迹自监督学习研究背景
- 2 基于词嵌入的轨迹自监督学习
- 3 基于自编码器的轨迹自监督学习
- 4 基于对比学习的轨迹自监督学习
- 5 轨迹自监督学习研究展望

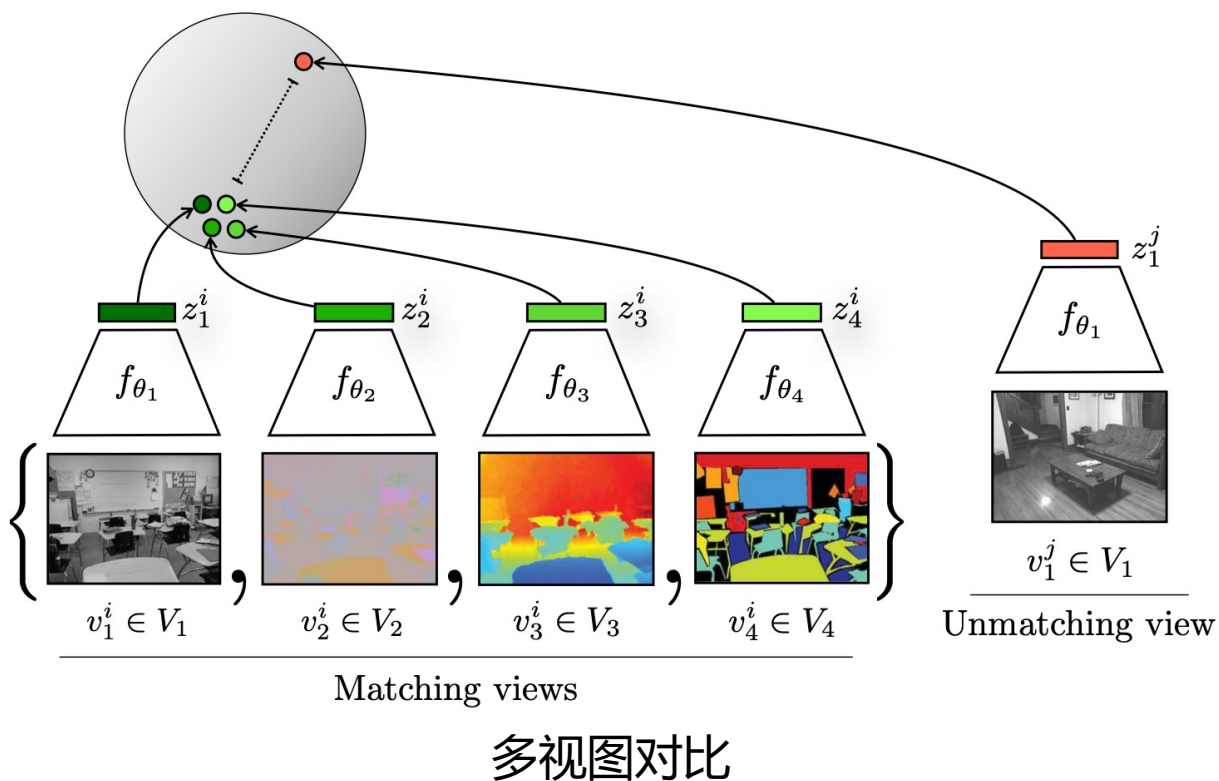
对比学习基础

- 提取同一原始数据的不同视图间共有的高阶信息与特征




Chen T, Kornblith S, Norouzi M, et al. A simple framework for contrastive learning of visual representations[C]//International conference on machine learning. PMLR, 2020: 1597-1607.

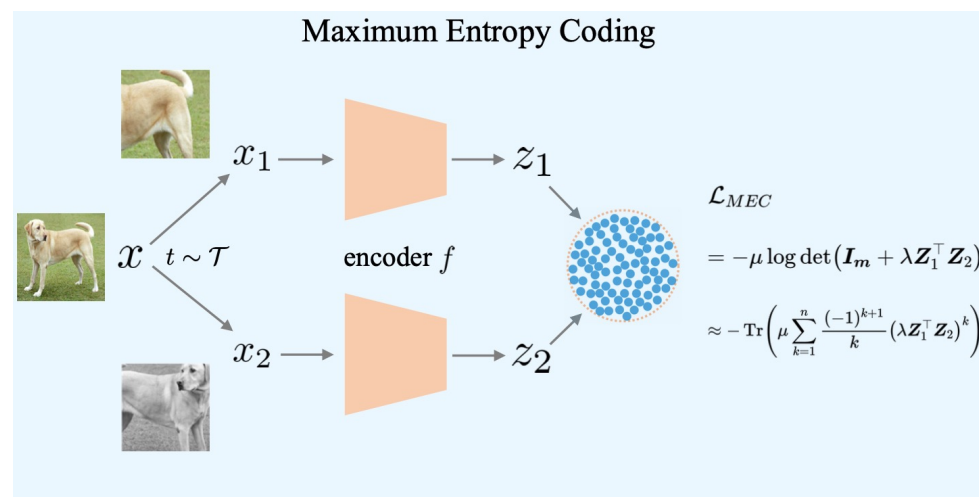
对比学习实现



对比预测



最大熵编码




- Tian Y, Krishnan D, Isola P. Contrastive multiview coding[C]//ECCV 2020.
- Oord A, Li Y, Vinyals O. Representation learning with contrastive predictive coding.
- Liu X, Wang Z, Li Y L, et al. Self-supervised learning via maximum entropy coding[J]. NeurIPS 2022.

基于对比学习的轨迹表示学习

➤ 时空轨迹的多视图构建

- 通过轨迹数据增强或特征提取技术，构建**轨迹的多个视图**
- 学习轨迹不同视图中**共有的高阶信息**，或是多视图的**多方面信息**




基于对比学习的轨迹表示学习

➤ Maximum Multi-view Trajectory Entropy Coding (MMTEC)

- 构建轨迹的离散、连续两方面视图，并使用最大熵编码损失进行对比学习训练

$$\mathcal{L}_{\text{MMTEC}} = -\text{trace}\left(\frac{N+d}{2} \sum_{k=1}^K \frac{(-1)^{k+1}}{k} \left(\frac{d}{N\epsilon^2} \mathbf{E}^{\text{Dis}\top} \mathbf{E}^{\text{Con}}\right)^k\right)$$

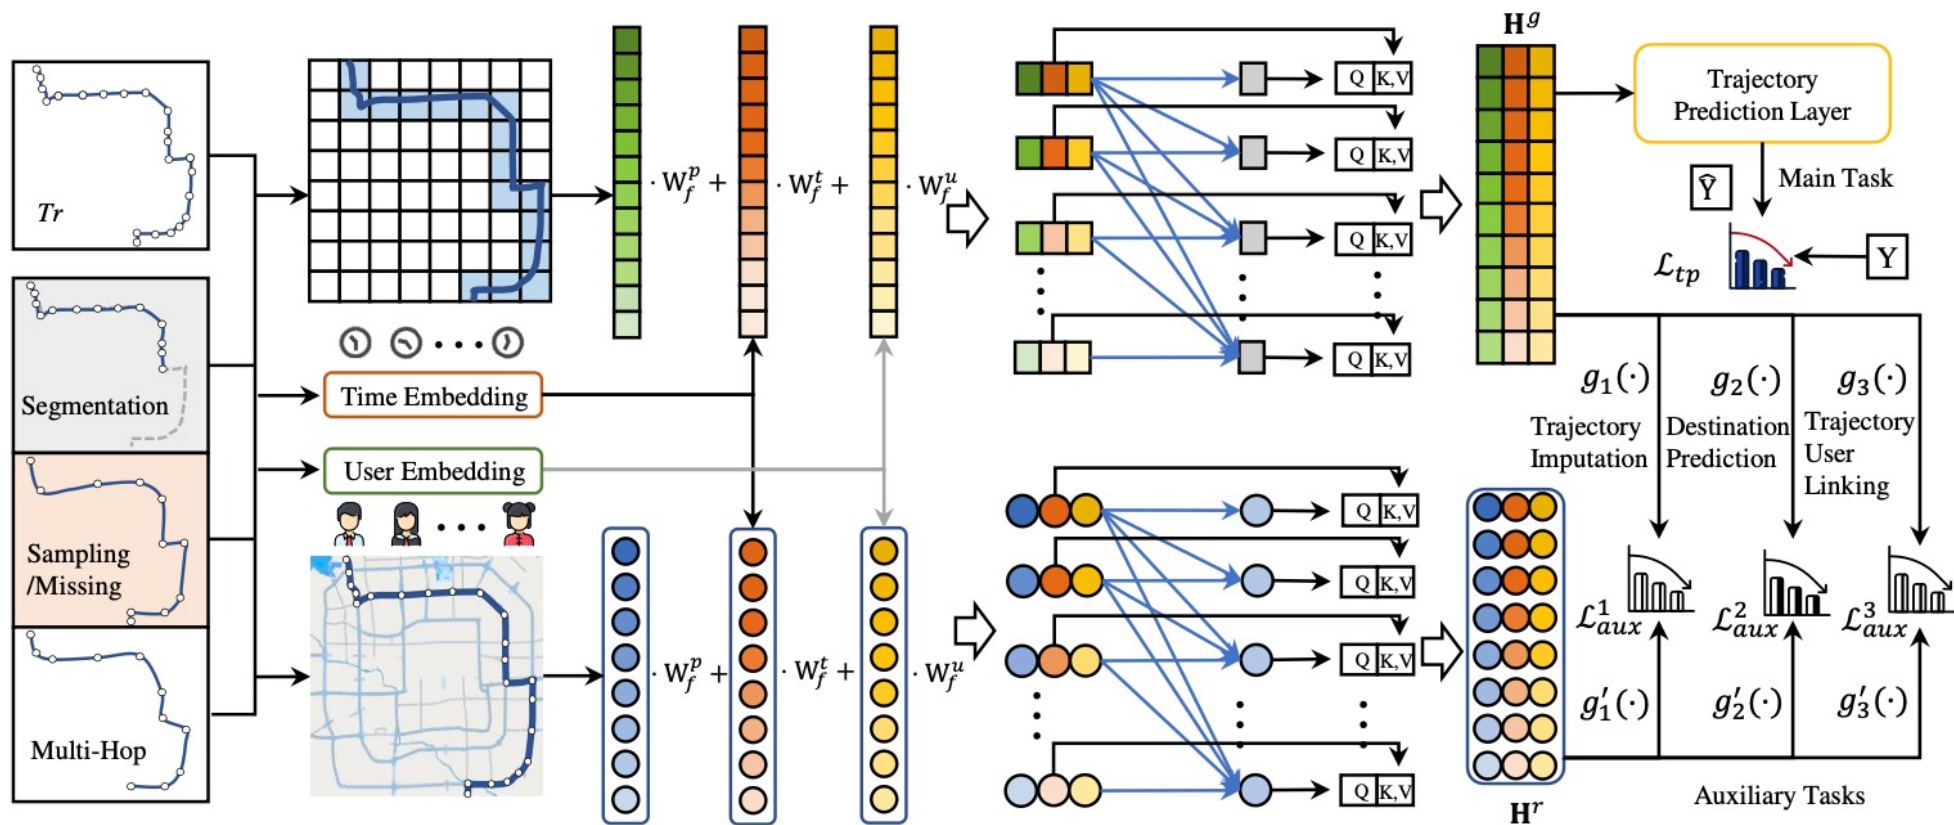


Yan Lin, Huaiyu Wan, et al. Pre-training General Trajectory Embeddings with Maximum Multi-view Entropy Coding. *IEEE Transactions on Knowledge and Data Engineering (TKDE)*, 2024.

基于对比学习的轨迹表示学习

➤ PreCLN

- 结合轨迹重采样和空间网格划分构建轨迹的视图，进行对比学习预训练提升下游任务性能

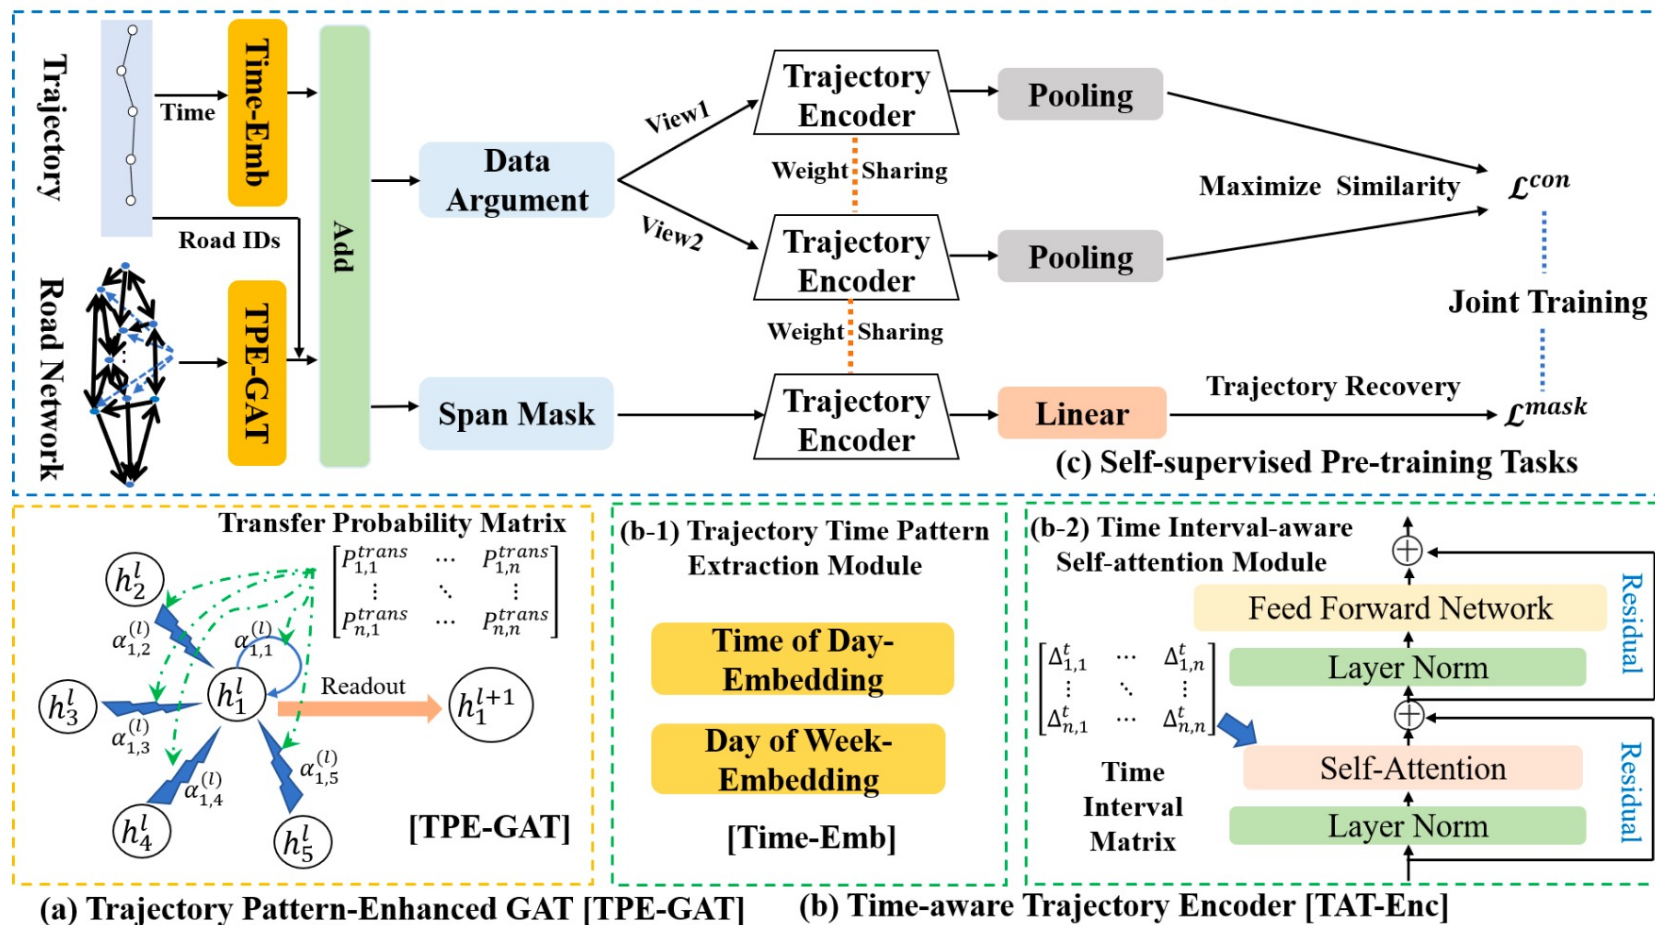


Yan B, Zhao G, Song L, et al. PreCLN: Pretrained-based contrastive learning network for vehicle trajectory prediction[J]. World Wide Web, 2023, 26(4): 1853-1875.

基于对比学习的轨迹表示学习


➤ START

- 融合对比学习和掩码语言模型 (MLM) 两种自监督学习范式



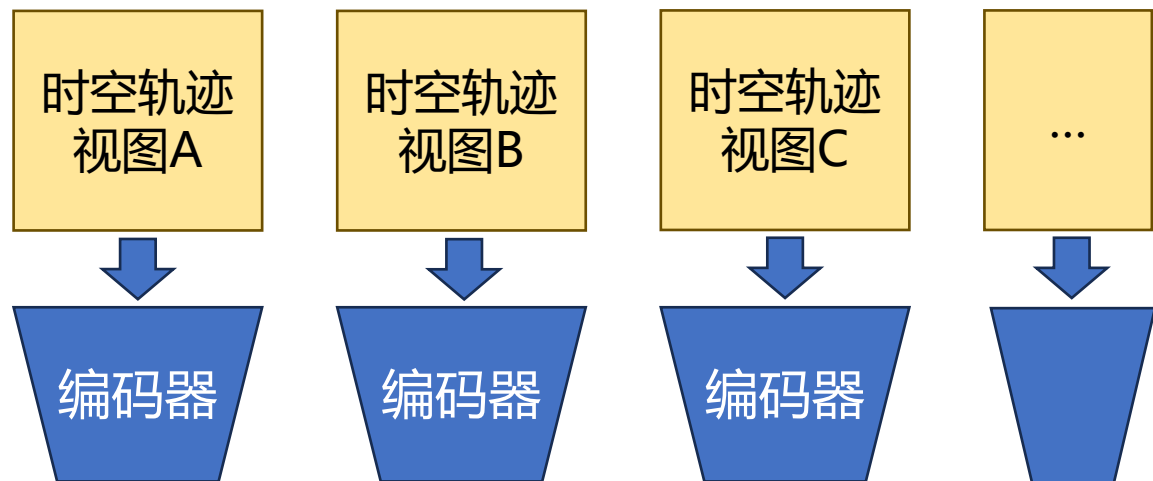
Jiang J, Pan D, Ren H, et al. Self-supervised trajectory representation learning with temporal regularities and travel semantics[C]//2023 IEEE 39th international conference on data engineering (ICDE). IEEE, 2023: 843-855.

基于对比学习的轨迹自监督学习



时空轨迹

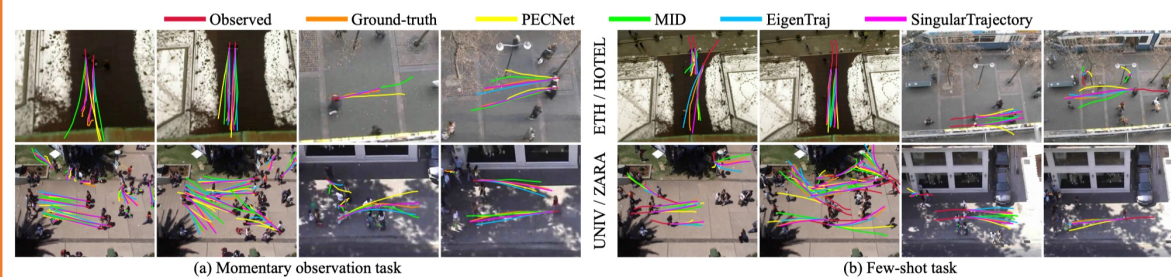
特征提取 ↓ 数据增强



对比学习 ↓

轨迹表示 →


轨迹特征分析




- 1 轨迹自监督学习研究背景
- 2 基于词嵌入的轨迹自监督学习
- 3 基于自编码器的轨迹自监督学习
- 4 基于对比学习的轨迹自监督学习
- 5 轨迹自监督学习研究展望

数据可迁移性的局限性

- 时空特征的绝对性、移动规律和路网结构的强相关性等为数据可迁移性带来了挑战



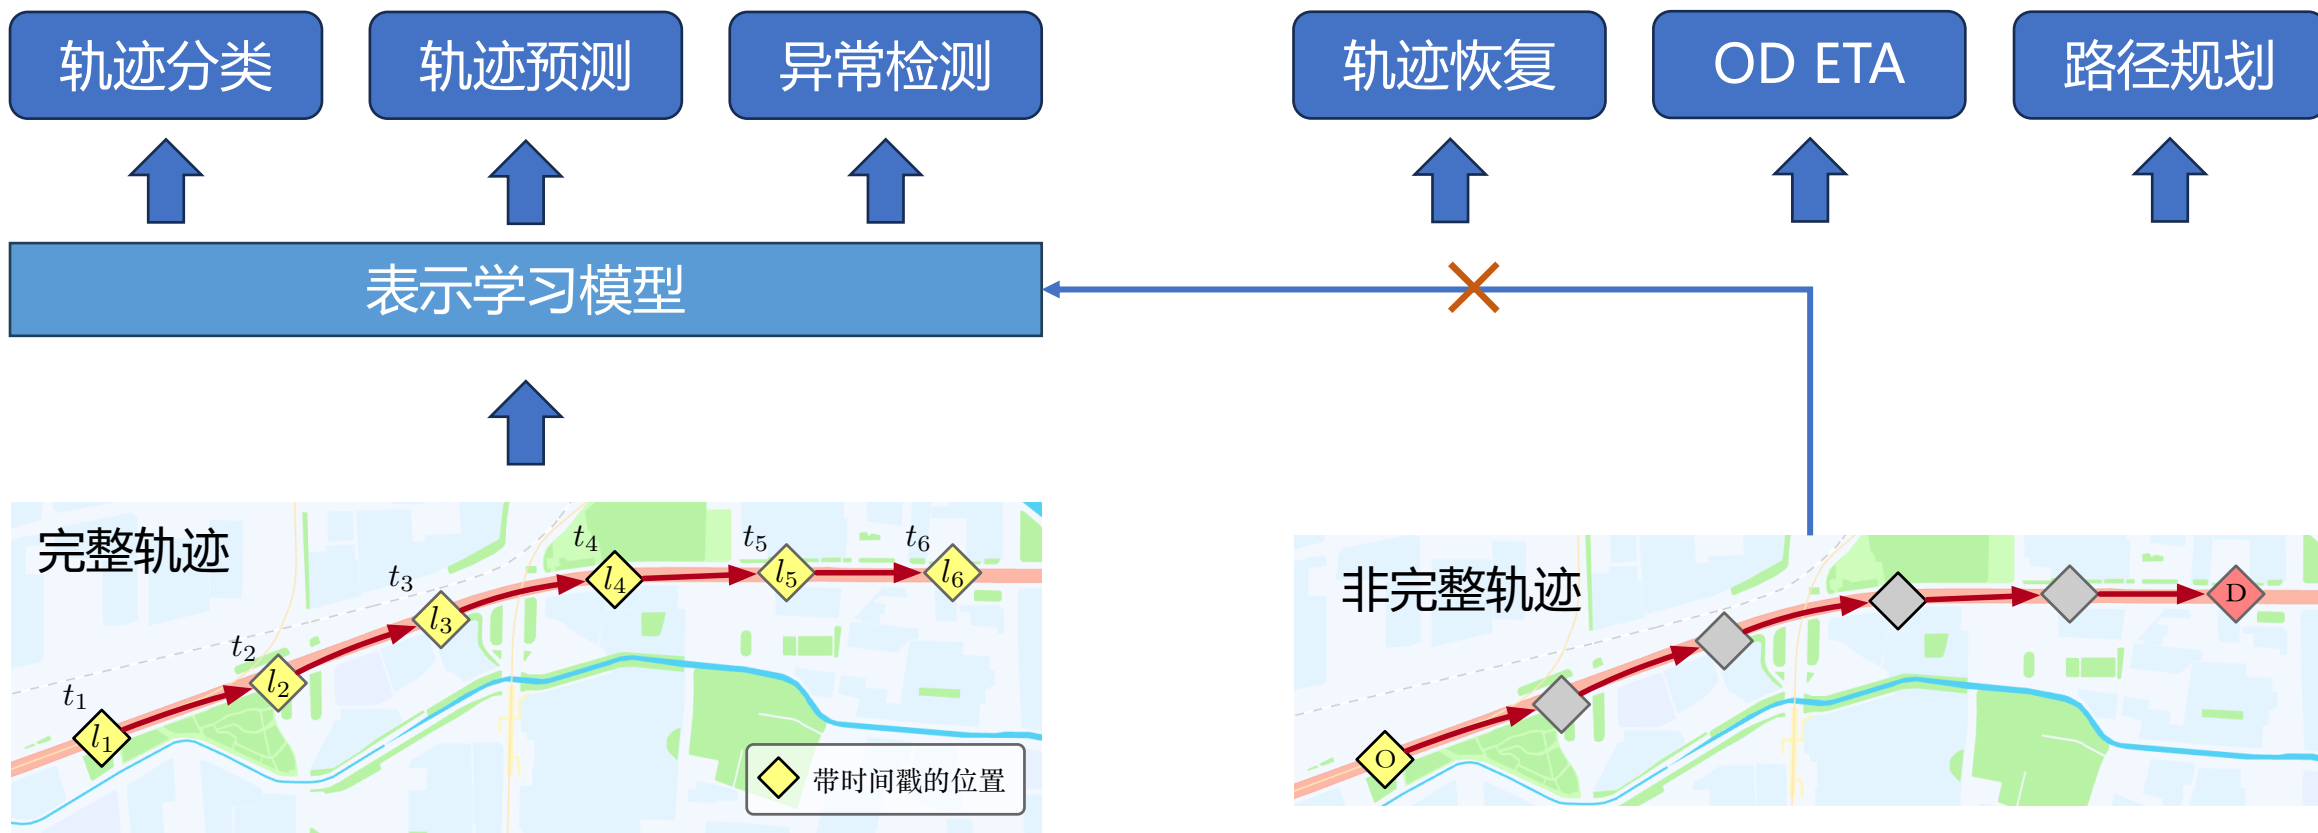
成都轨迹数据集



西安轨迹数据集

任务适配能力的局限性

- 自监督学习的表示学习范式将时空对象映射为嵌入向量，结合预测模块适配下游任务
- 表示学习范式对输入特征完整性的要求限制了模型的任务适配能力



NLP领域自监督学习的启发

- 通用的语义信息带来的数据可迁移性
- 生成式模型范式带来的任务适配能力



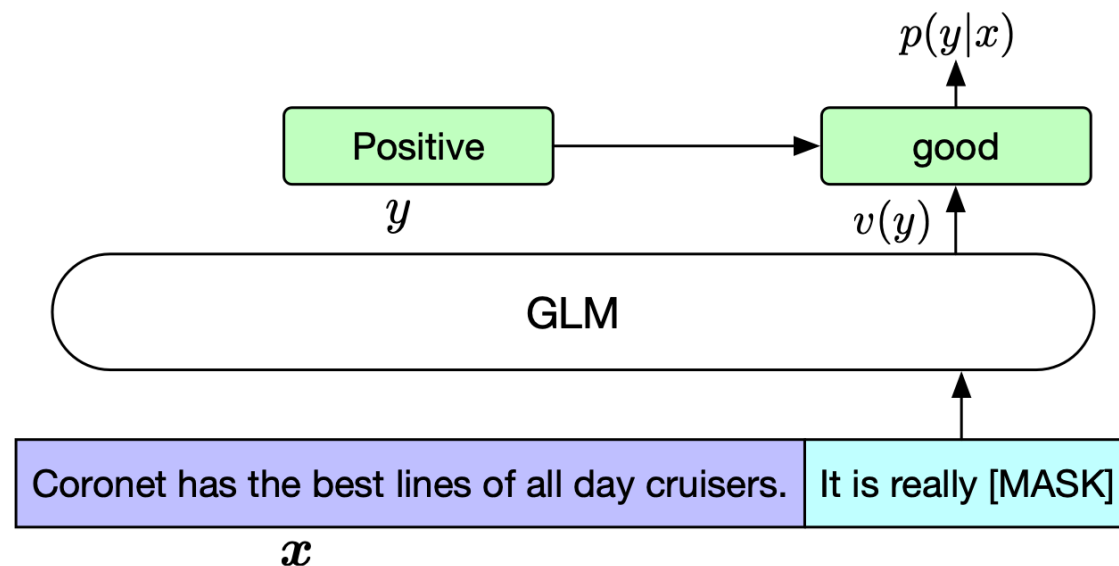
WIKIPEDIA
The Free Encyclopedia

Natural language processing (NLP) is an interdisciplinary subfield of computer science and information retrieval. It is primarily concerned with giving computers the ability to support and manipulate human language. ...



Natural language processing (NLP) is the ability of a computer program to understand human language as it's spoken and written -- referred to as natural language. It's a component of artificial intelligence (AI).

自然语言的数据集可迁移性

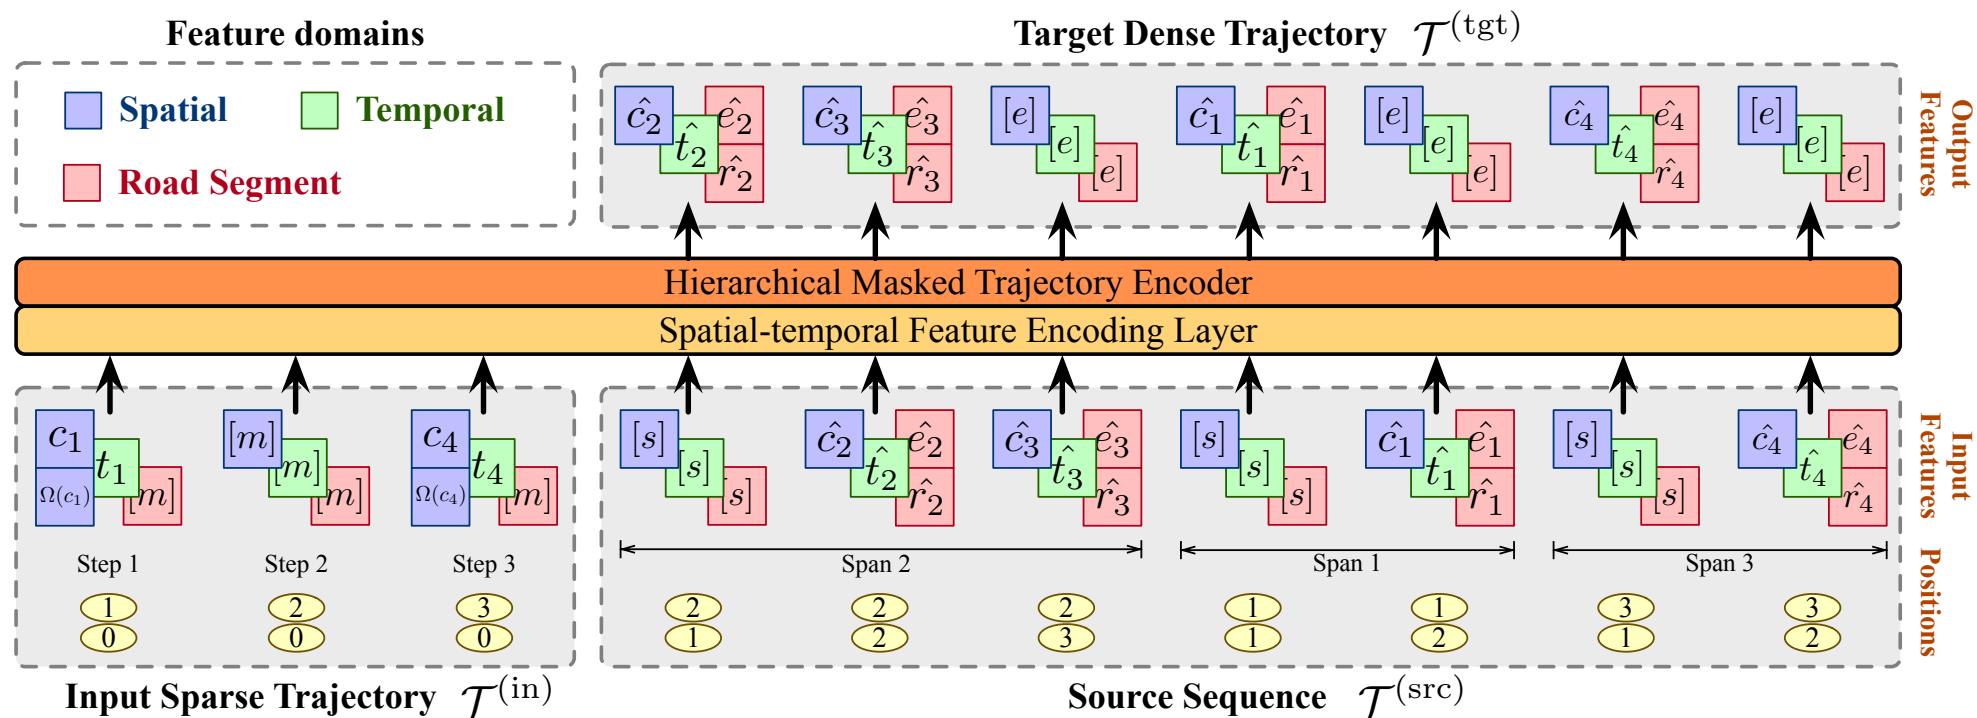


GLM将分类任务抽象为生成任务

- Du Z, Qian Y, Liu X, et al. Glm: General language model pretraining with autoregressive blank infilling. ACL (1) 2022: 320-335.

轨迹自监督学习的通用性扩展

- 从时空特征中挖掘通用、可迁移的信息
- 构建能适应多种输入形式、适配更多种下游任务的自监督学习范式，如生成式模型



基于生成式模型的轨迹自监督模型

- Yan Lin, Jilin Hu, et al. UVTM: Universal Vehicle Trajectory Modeling with ST Feature Domain Generation. arXiv preprint.



北京交通大学 网络科学与智能系统研究所
INSTITUTE OF NETWORK SCIENCE AND INTELLIGENT SYSTEMS

谢谢!

汇报人：林彦



大语言模型的实用应用

PromptGenius - All purpose prompts for ChatLLMs



www.promptgenius.site

大语言模型的实用应用

OverleafCopilot - A comprehensive scholar writing copilot for Overleaf overleafcopilot.com

