



# 城市时空数据建模与预测方法： 从异质性到泛化性



数据智能实验室  
Data Intelligence Lab

报告人：中国科大 周正阳 副研究员

2024年5月10日



# 主要内容

1

时空数据建模研究框架

2

时空数据异质性建模研究

3

时空预测模型泛化性研究

4

研究展望：城市增长与时空模型进化

5

课题组介绍



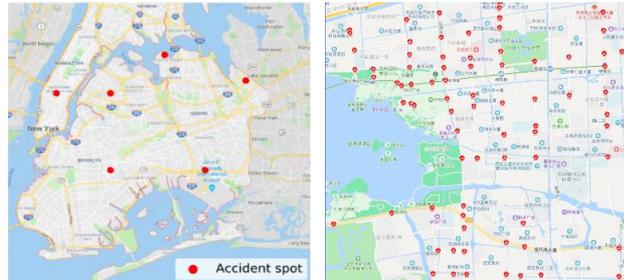
# 城市时空数据建模与预测方法：从异质性到泛化性

## 研究框架：时空数据典型特性

时空数据的**观测异质性**与  
**分布稀疏性**



(a) 时空数据的异质性

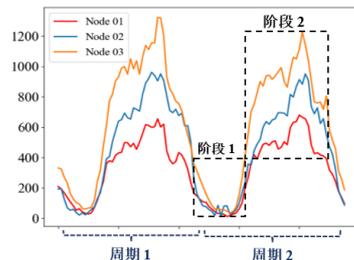
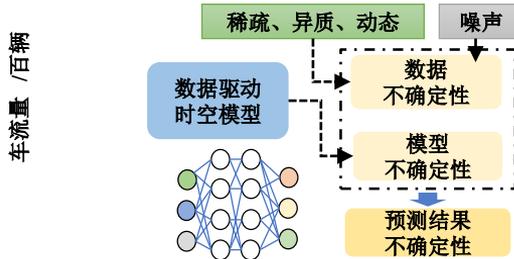


(b) 本质稀疏的交通事件与伪稀疏传感数据

## 数据异质性

### 观测与分布异质

时空数据的**局部波动性**与  
**分布偏移**特性



## 模型泛化性

### 模型预测波动与数据分布偏移



# 城市时空数据建模与预测方法：从异质性和泛化性

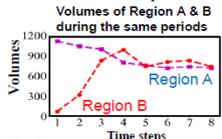
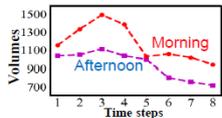
## 研究框架：从典型特性到关键问题





# 时空数据异质性建模研究

x, y: region-wise transition volumes



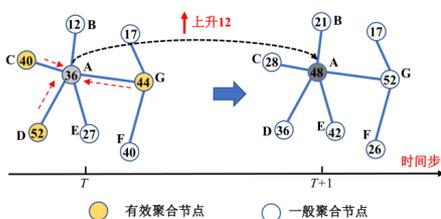
(a) Heterogeneous spatial transitions in NYC

(b) Heterogeneous temporal evolution patterns in SIP

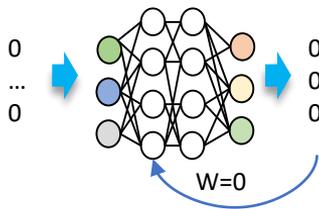
观测内容异质性



数据分布稀疏性



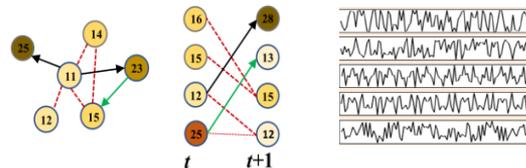
Uniform聚合失效



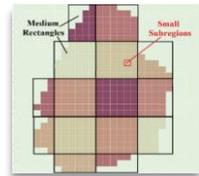
糟糕的零膨胀问题与学习欠充分

➤ 动态图同配理论与深度时空图聚合

➤ 多源多尺度数据协同预测



交叉时空域数据



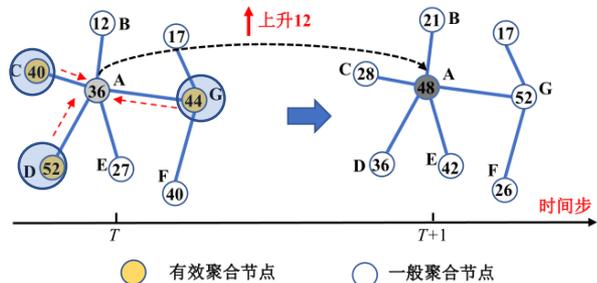
异质性建模

➤ 预测可靠性



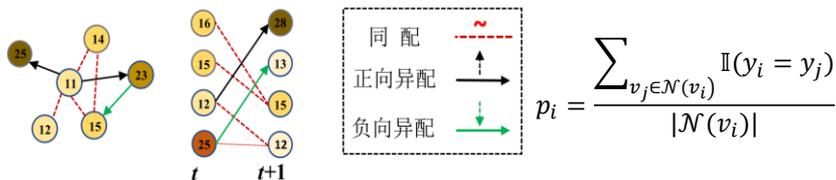
# 时空数据异质性建模研究

针对内容异质性，提出动态图同配理论，基于目标同配的深度有向聚合



无关节点聚合将引入噪声

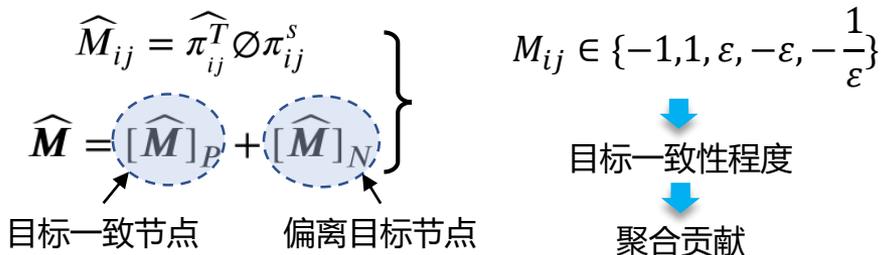
➤ 时空预测：基于**目标信息**校正拓扑，筛选有效节点。



有向时空预测

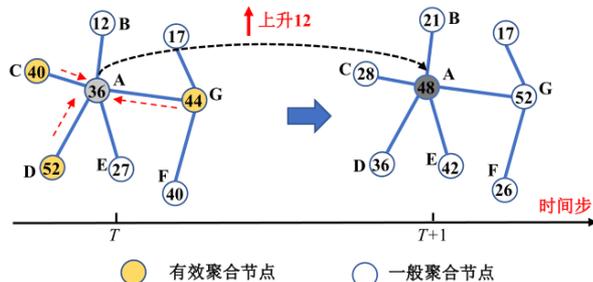


➤ 基于动态图目标同配性的图自适应深度聚合



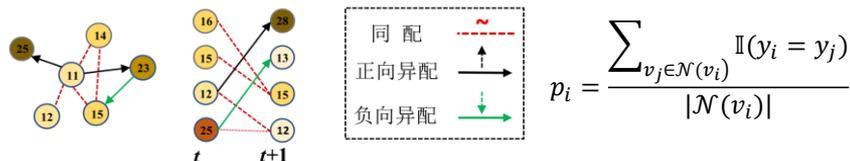
# 时空数据异质性建模研究

针对内容异质性，提出动态图同配理论，基于目标同配的深度有向聚合

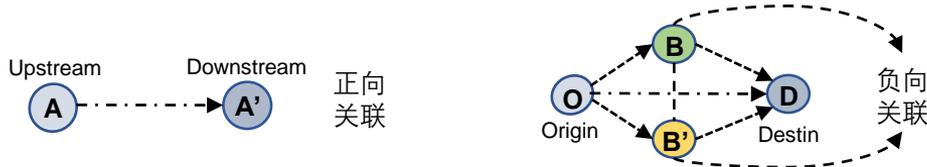


无关节点聚合将引入噪声

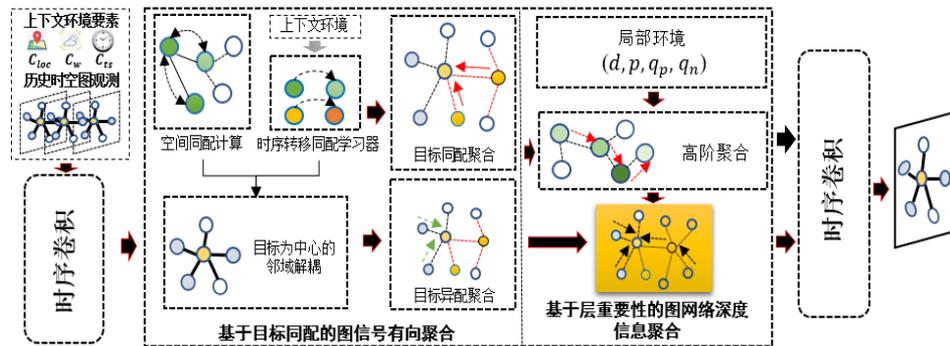
► 时空预测：基于**目标信息**校正拓扑可筛选有效节点。



有向时空预测



► 基于动态图目标同配性的图自适应深度聚合



# 时空数据异质性建模研究

针对内容异质性，提出动态图同配理论，基于目标同配的深度有向聚合

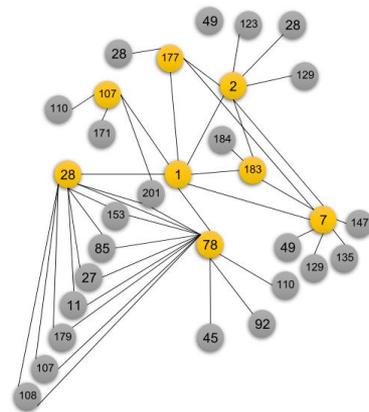
## 模型性能比较

数据集 模型	Metr-LA		PeMS-Bay		KnowAir		Temperature	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
GCN	0.0975	8.3098	0.0522	4.4952	0.3146	16.5635	0.3221	1.4439
GAT	0.0628	5.8018	0.0176	1.6610	0.2435	13.3114	0.3393	1.4855
GraphSAGE	0.0606	5.7550	0.0167	1.6173	0.2449	13.1932	0.1966	1.0233
SuperGAT	0.0623	5.7886	0.0175	1.6606	0.2535	13.3671	0.3224	1.3439
EGConv	0.0609	5.7554	0.0167	1.6139	0.2399	13.2189	0.1875	1.0097
H <sub>2</sub> GCN	0.0608	5.7292	0.0168	1.6599	0.2371	13.1207	0.1906	0.9971
STGCN	0.0554	3.8655	0.0197	1.5890	0.2437	<u>12.3601</u>	0.1704	1.1190
GWN	0.0528	3.8434	<u>0.0163</u>	1.5482	0.2288	12.8495	0.1607	0.9132
MTGNN	<u>0.0526</u>	<u>3.8153</u>	0.0170	1.5759	<u>0.2271</u>	12.9091	0.1682	<u>0.9034</u>
DCRNN	<u>0.0532</u>	3.8798	<b>0.0161</b>	<u>1.5292</u>	0.2392	13.0389	<u>0.1351</u>	0.9715
ASTGNN	0.0530	5.5313	0.0169	1.6229	0.2485	13.2274	0.2978	0.9330
GReTo (Ours)	<b>0.0500</b>	<b>3.6552</b>	0.0166	<b>1.4813</b>	<b>0.1708</b>	<b>11.0369</b>	<b>0.1341</b>	<b>0.8704</b>

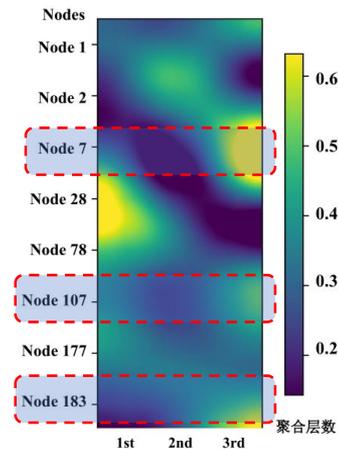
	Intra-graph homophily $\pi_{v_i}^s$			Inter-graph homophily $\pi_{v_i}^T$		
	$p_s$	$q_p$	$q_n$	$p_s$	$q_p$	$q_n$
Metr-LA	0.2273	0.4732	0.2995	0.3325	0.4920	0.1755
PeMS-Bay	0.1073	0.5912	0.3015	0.2399	0.6863	0.0738
KnowAir	0.2481	0.3945	0.3574	0.3190	<b>0.4030</b>	<b>0.2780</b>
Temperature	0.1156	0.6980	0.1864	0.1418	<b>0.5538</b>	0.3044

有效建模  
时空异质性

## GReTo在Metr-LA上实证分析



(a) 层次性的节点分布



(b) 在前三阶聚合中的逐层重要性热力图

节点的度越低  
(如节点 7/107/183)



传播层数也越多



# 时空数据异质性建模研究

## ➤ 针对样本分布稀疏性，提出多源多尺度数据协同预测

➤ 训练过程的零膨胀问题 (zero-inflated issue)

➤ 有效数据覆盖面小，难以支撑训练

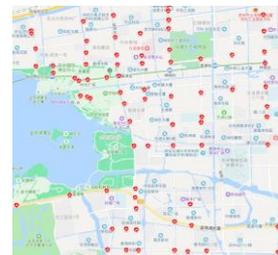
## ➤ 从稀疏性产生原因划分两类稀疏场景

➤ **本质稀疏**：数据记录本身偶发，即本身产生很少，即使全部获取也有限，如：犯罪事件、交通拥堵事件、疫情爆发现点。 **无法补全**。

➤ **伪稀疏**：指数据随时随处产生，但是由于采集设备能力有限，无法全部获取。如：路段通行速度、卡口流量、断续房价记录、大气环境数据等。 **可填充**。



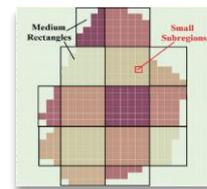
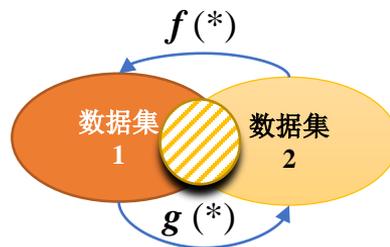
(a) 本质稀疏的交通事故



(b) 伪稀疏的速度传感器

✓ 不同类型但处于同一时空域中的数据具有相关性和交互性

✓ 空间粒度降低有效提升可预测性



网格  
占有率  
提高

[1] Zhou Z, Wang Y, Xie X, et al. RiskOracle: A minute-level citywide traffic accident forecasting framework[C]//AAAI 2020, 34(01): 1258-1265.

[2] Zhou Z, Wang Y, Xie X, et al. Foresee urban sparse traffic accidents: A spatiotemporal multi-granularity perspective[J]. IEEE TKDE, 2020, 34(8): 3786-3799.

[3] 周正阳, 刘浩, 王琨, 等. 基于教师-学生时空半监督网络的城市事件预测方法[J]. 电子学报, 2023, 51(12): 3557-3571.



# 时空数据异质性建模研究

## 针对样本稀疏性，提出多源多尺度数据协同预测

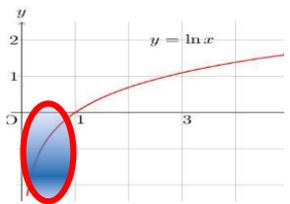
### 伪稀疏：基于交叉时空域的伪稀疏信息动态协同建模



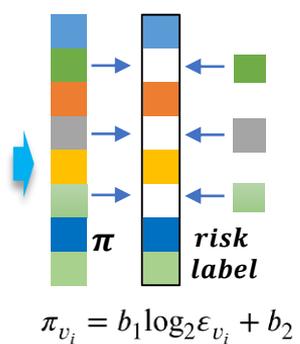
### 本质稀疏：基于先验信息的数据增强建模

#### 概率化与对数化

- ✓ 差异化不同区域风险
- ✓ 适合神经网络拟合

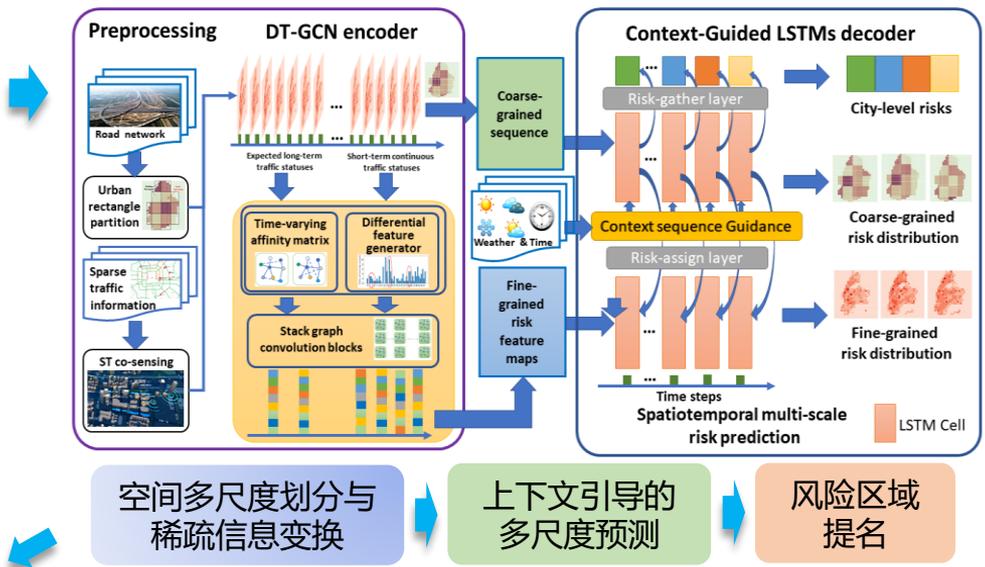
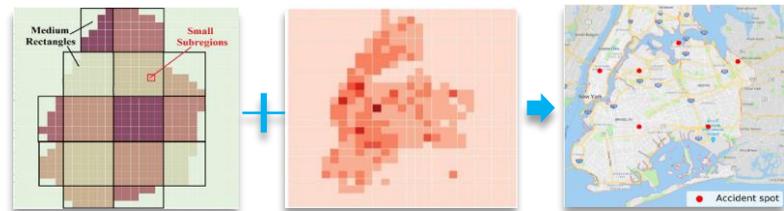


$$\epsilon_{v_i} = \frac{1}{N_{week}} \sum_{j=1}^{N_{week}} \frac{r_{v_i}(j)}{\sum_{k=1}^m r_{v_k}(j)}$$



实现多源多尺度稀疏信息协同预测

## 面向交通事故的多尺度时空预测方法



空间多尺度划分与稀疏信息变换

上下文引导的多尺度预测

风险区域提名



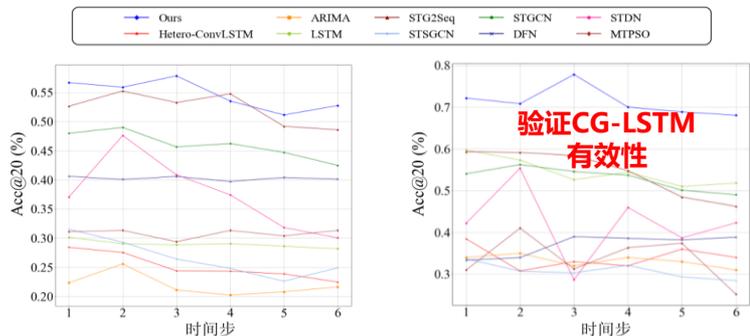
# 时空数据异质性建模研究

## 案例 交通事故预测任务：实证结果

### 稀疏时空数据集：NYC与苏州园区交通事故

城市	交通事故数据集	时间跨度	区域数量	记录数
NYC	交通事故	2017/01/01-2017/05/31	354	254k
	出租车旅程记录			48,496k
	城市路段通行速度			125k
	逐日天气记录			604
	人口信息			195
SIP	路网结构	2016 年调研获得	108	102k
	交通事故	2017/01/01-2017/03/31		183
	城市路口交通流量			1,399k
	城市路段通行速度			311k
	逐日天气记录			180

### 多步预测稳定性测验



(a) NYC数据集上逐步预测性能变化

(b) SIP数据集逐步预测性能变化

### 预测性能比较

模型	NYC/SIP		多粒度预测有效	
	Acc@20/Acc@6(%)	MSE-F	MSE-C	
ARIMA	20.72/30.63	0.0192/0.0162	0.0492/0.2215	
LSTM	28.98/35.70	0.0179/0.0255	0.0477/0.2694	
Hetero-ConvLSTM	28.03/34.84	0.0161/0.0487	0.1015/0.4039	
STGCN	50.42/51.27	0.0188 /0.0452	0.0492/0.2885	
STG2Seq	52.08/54.30	0.0138/0.0364	0.0693/0.1667	
STSGCN	26.46/33.59	0.0183/0.0236	0.1285/0.3473	
STDN	37.48/42.18	0.0203 /0.0354	0.0853/0.2142	
DFN	40.26/36.98	0.0194 /0.0376	0.0548/0.2278	
MTPSO	30.81/33.69	0.0218 /0.0420	0.0393/0.2065	
RiskSeq	56.42/71.27	0.0158/0.0401	0.0443/0.2702	

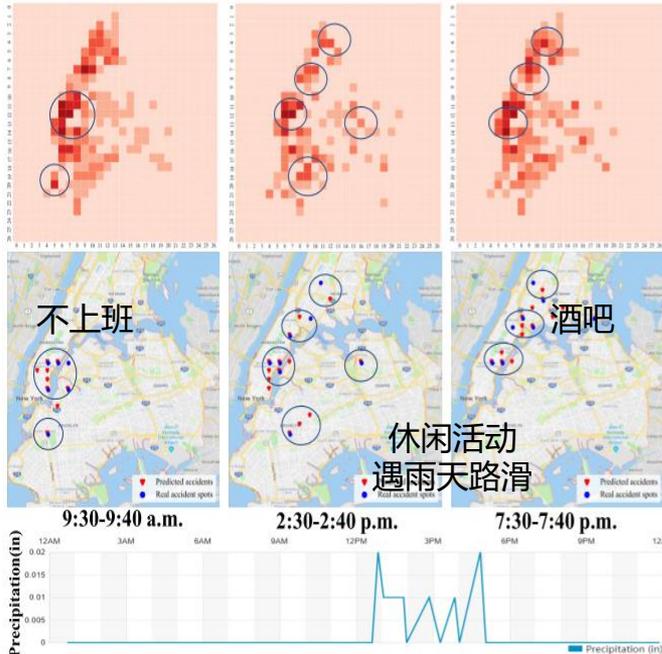
### 消融实验

Variant	NYC/SIP		
	MSE	Acc@20(Acc@6)(%)	Acc@K
RS-PKDE	0.0053/0.0512	18.56/35.48	16.28/29.45
RS-DFM	0.1260/0.0216	43.05/58.94	38.29/46.28
RS-OA	0.0116/0.0127	37.57/67.16	32.47/61.15
RS-DG	0.0118/0.0136	46.45/68.52	39.19/55.27
RS-RC	0.0208/0.0082	41.79/69.45	38.19/56.33
RS-CF	0.0123/0.0355	43.04/67.83	33.21/50.18
RS-CGLSTM	0.0128/0.0060	48.45/67.19	-
<b>Integrated RS</b>	<b>0.0158/0.0040</b>	<b>56.42/71.27</b>	<b>47.18/65.26</b>

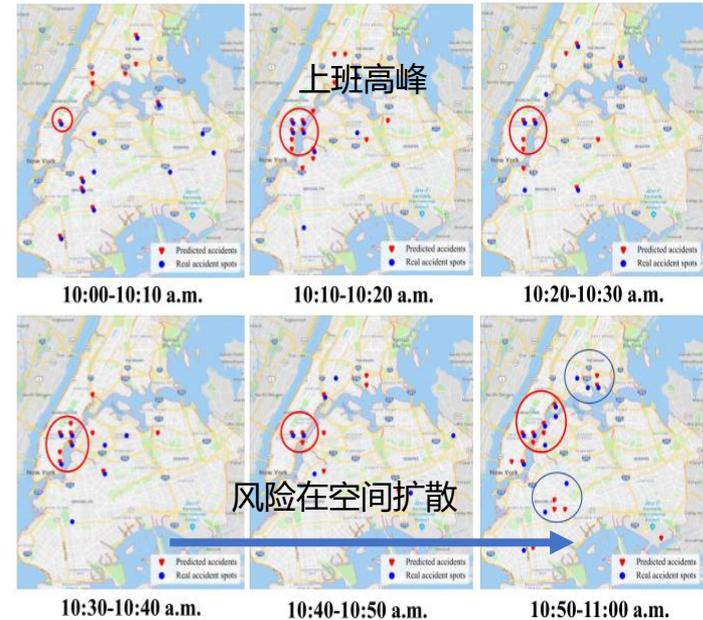
## 案例 交通事故预测任务：实证结果

- ✓ 预测事故风险分布大致吻合，筛选结果好
- ✓ 高风险区域呈现明显的时变特性
- ✓ 预测结果随上下文变化

稀疏时空预测模型  
是合理有效的



(a) Three selected intervals on 22th, April, Sat, Cloudy to rainy



(b) Sequential results on 3rd, April, Mon, Rainy



# 时空预测模型泛化性研究

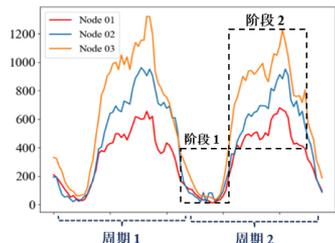
## 时空预测分布外泛化研究

### 样本缺失与数据噪声



不确定性  
量化

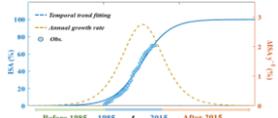
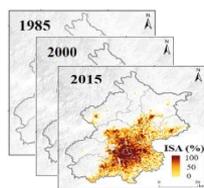
### 数据分布偏移与城市增长



$$(\mu_1, \sigma_1) \rightarrow (\mu_2, \sigma_2)$$

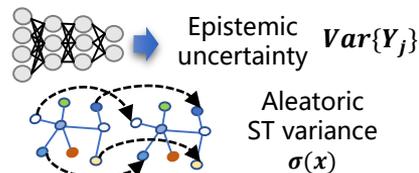
$$\mu_2 \gg \mu_1 \quad \text{误差放大}$$

流式数据分布偏移

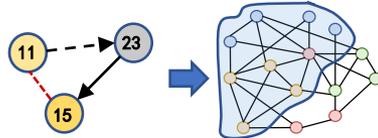


城市空间增长

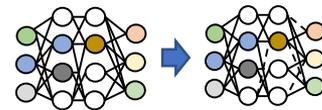
时空预测泛化研究



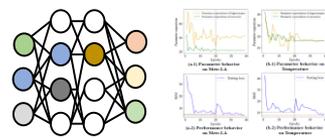
预测不确定性量化



面向空间增长的持续学习



基于不变关联的时序  
偏移泛化



基于模型行为挖掘的  
波动抑制与泛化学习

预测不确定性  
解耦量化

空间知识迁移

模型自适应更新



# 时空预测模型泛化性研究

针对数据波动、低质，提出预测不确定性量化及抑制

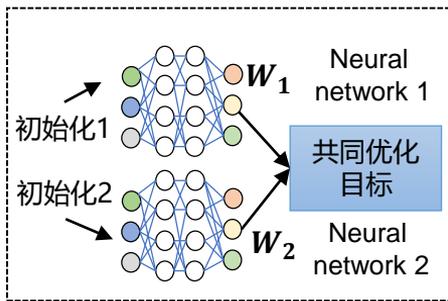
模型拟合、样本认识充分性

→ 模型不确定性 (认知的)

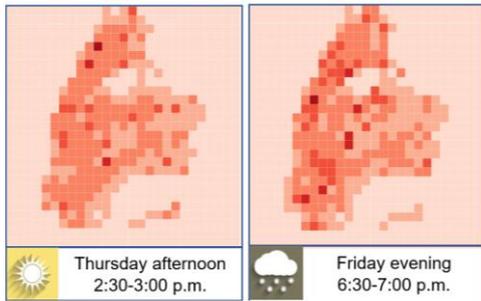
数据噪声和波动模式

→ 数据不确定性 (偶然的)

### 模型预测异质性



### 时空预测误差的异质性



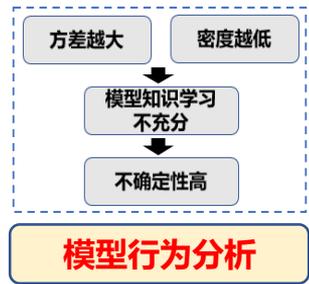
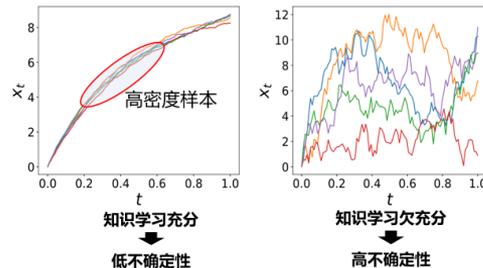
模型不一致性 → 模型不确定性

**认知不确定性**



**偶然不确定性**

### 基于样本扰动的认知不确定性量化



### 基于上下文-时空方差的偶然不确定性量化

建模为上下文  $c$  的函数

$$\left\{ \begin{array}{l} (c_1, c_2, \dots, c_M) \rightarrow \varepsilon_j = \text{std}(\{x_j | [c_1, \dots, c_M]\}) \\ (u_{av})_{i,t} | d_{u,s,k}, w_j = \text{std}(D(v_i, t)) \end{array} \right.$$

$$L_{cons} = \frac{(y_i - \hat{y}_i)^2}{((\hat{u}_{as})_{i,t} + (\hat{u}_{av})_{i,t})^2}$$

**不确定性与误差一致性  
抑制噪声，提升鲁棒性**

**实现预测可靠性度量  
提升噪声抑制能力**

[1] Zhou Z, Wang Y, Xie X, et al. Stuanet: Understanding uncertainty in spatiotemporal collective human mobility[C]//The Web Conference 2021. 2021: 1868-1879.  
 [2] Zhou Z, Yang K, Sun W, et al. Towards learning in grey spatiotemporal systems: A prophet to non-consecutive spatiotemporal dynamics[C]//SDM 2023: 190-198.

# 时空预测模型泛化性研究

## 案例：感知不确定性的非连续时空预测框架

人类活动相关数据集统计信息

数据集名称	数据集类别	记录条数	时间跨度	节点(区域)个数
SIP	路口监控	2.7 m	2017/01-2017/03	108
	天气信息	4.3k		
NYC-Taxi	出租车旅程信息	7.5 m	2017/01-2017/05	354
	天气信息	7.4k		
Metr-LA	路网线圈速度	4.9 m	2012/03-2012/06	207
	天气信息	5.7k		

面向提前规划任务的非连续时空预测性能比较

	SIP		NYC		Metr-LA	
	1-day-a	1-week-a	1-day-a	1-week-a	1-day-a	1-week-a
Transformer	0.257	0.301	0.554	0.542	0.245	0.343
STFGNN	0.258	0.309	0.223	0.248	0.266	0.365
STG2Seq	<u>0.230</u>	<u>0.287</u>	<u>0.203</u>	<u>0.241</u>	0.301	0.350
MTGNN	0.245	<u>0.273</u>	0.227	0.256	<u>0.236</u>	0.302
ASTGNN	0.250	0.279	0.235	0.265	0.243	0.285
STUaNet+	<b>0.201</b>	<b>0.216</b>	<b>0.185</b>	<b>0.202</b>	<b>0.202</b>	<b>0.224</b>
性能提升率	12.42%	20.76%	8.50%	16.02%	14.18%	21.22%

面向传感器断续故障的非连续时空预测性能比较

	SIP		NYC		Metr-LA	
	3-day-m	7-day-m	3-day-m	7-day-m	3-day-m	7-day-m
Transformer	0.245	0.250	0.457	0.475	0.227	0.326
STFGNN	0.238	0.263	0.231	0.252	0.245	0.313
STG2Seq	<u>0.210</u>	<u>0.236</u>	<u>0.199</u>	<u>0.203</u>	0.289	0.321
MTGNN	0.225	0.240	0.213	0.220	0.224	0.310
ASTGNN	0.231	0.264	0.225	0.235	0.230	0.245
STUaNet+	<b>0.173</b>	<b>0.195</b>	<b>0.184</b>	<b>0.198</b>	<b>0.211</b>	<b>0.240</b>
性能提升率	18.00%	15.20%	7.20%	2.31%	14.10%	2.01%

不确定性区间  
能够有效捕获  
真实值

不确定性占比  
尽可能小

➢ 不确定性建模可提升模型稳定性

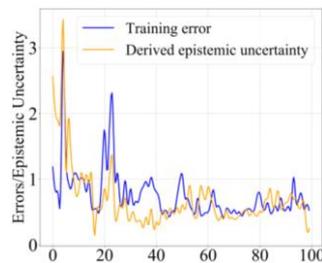
➢ 不确定性量化是有效的

不确定性量化性能比较 (间隔覆盖率: PICP)

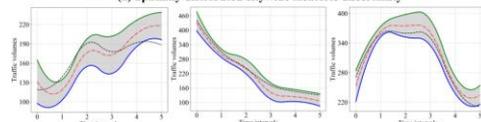
	SIP		NYC		Metr-LA	
	STG2Seq	FoDGSL	STG2Seq	FoDGSL	STG2Seq	FoDGSL
Dropout BNN	0.606	0.618	0.549	0.744	0.502	0.754
DeepEnsembles	0.582	<u>0.697</u>	0.524	0.742	0.628	<b>0.876</b>
SDE	0.605	0.609	<u>0.615</u>	0.679	<u>0.677</u>	<u>0.791</u>
MIS	<b>0.652</b>	0.640	<b>0.705</b>	0.714	0.653	0.720
DisEUQ	<u>0.627</u>	<b>0.703</b>	0.507	<b>0.754</b>	<b>0.688</b>	0.766

不确定性量化性能比较 (不确定性比率: UP)

	SIP		NYC		Metr-LA	
	STG2Seq	FoDGSL	STG2Seq	FoDGSL	STG2Seq	FoDGSL
Dropout BNN	0.386	<b>0.419</b>	0.402	<u>0.460</u>	<u>0.335</u>	<u>0.394</u>
DeepEnsembles	2.580	1.681	2.310	2.710	1.522	1.337
SDE	<b>0.257</b>	0.587	<b>0.233</b>	0.588	<b>0.235</b>	0.495
MIS	0.890	1.200	0.965	1.050	0.645	0.595
DisEUQ	<u>0.368</u>	<u>0.494</u>	<u>0.325</u>	<b>0.450</b>	0.352	<b>0.379</b>



(a) 认知不确定性 epochs  
学习程度越高, 不确定性越小

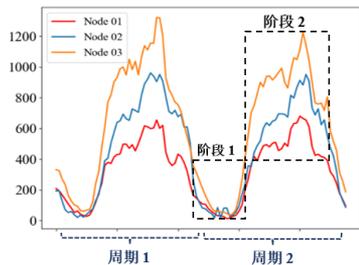


(b) 偶然不确定性

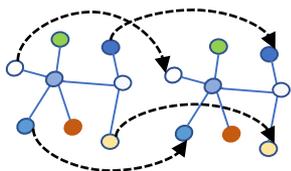
Bonus: 可抑制噪声点, 提升可靠性

# 时空预测模型泛化性研究

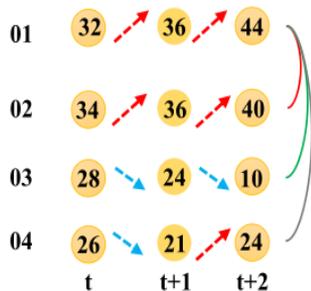
针对模型在时序偏移下泛化性低下，提出基于稳定关联的时空不变学习 [KDD 2023]



➤ 时序分布偏移问题

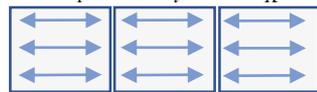
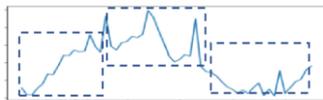


➤ 捕获不变依赖

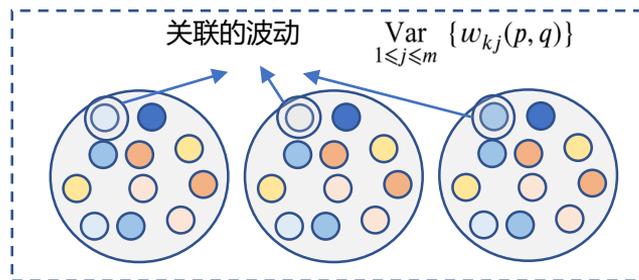
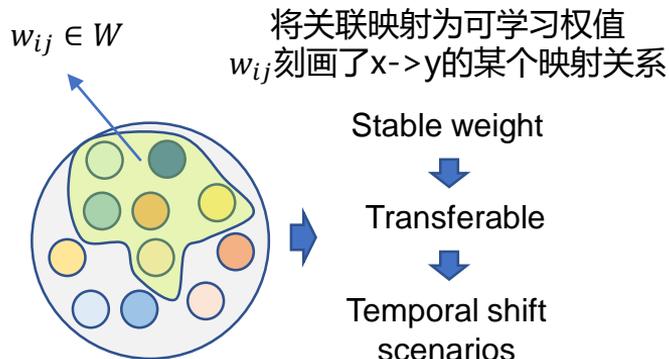


空间关联一致性建模

将时间步视作环境



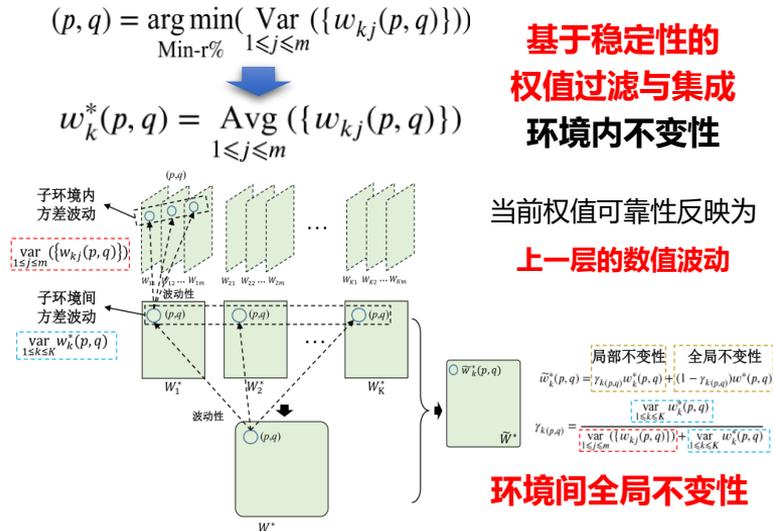
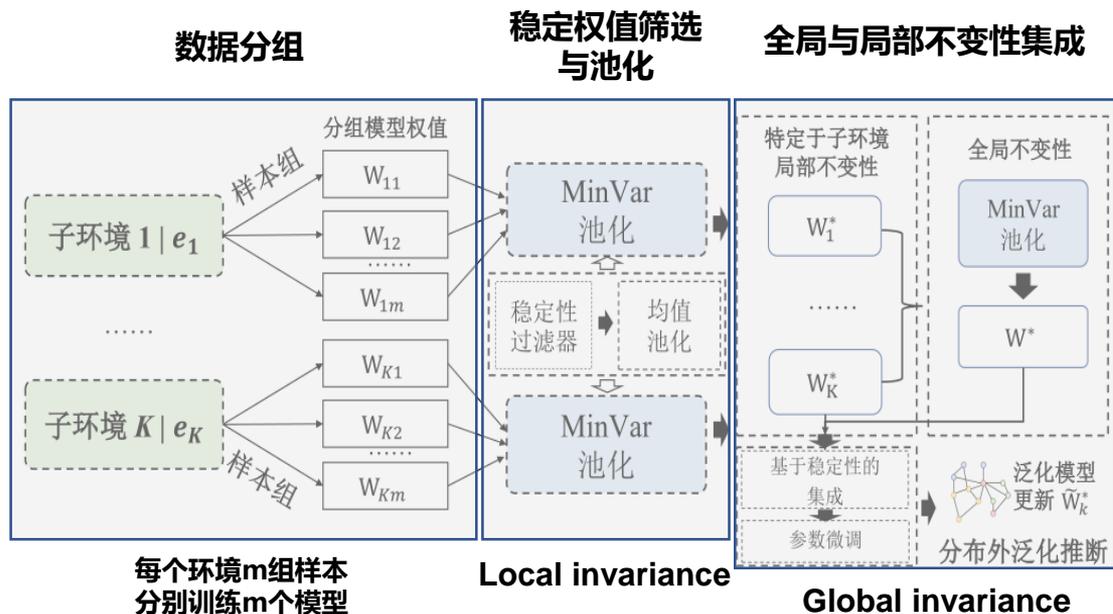
样本组织



捕获跨环境不变性

# 时空预测模型泛化性研究

针对模型在时序偏移下泛化性低下，提出基于稳定关联的时空不变学习 [KDD 2023]



**基于波动的全局-局部权值聚合**

$$\tilde{w}^*(p, q) = \gamma_{(p,q)} w_k^*(p, q) + (1 - \gamma_{(p,q)}) w^*(p, q)$$

$$\gamma_{(p,q)} = \frac{\text{var}_{1 \leq k \leq K} w_k^*(p, q)}{\text{var}_{1 \leq j \leq m} (\{w_{kj}(p, q)\}) + \text{var}_{1 \leq k \leq K} w_k^*(p, q)}$$



# 时空预测模型泛化性研究

## 实验：三种OOD实验设计及实验结果

- ✓ **时序偏移**：基于不同阶段 (phase) 模拟随时间变化产生分布偏移现象
- ✓ **新节点归纳推断**：训练阶段mask部分节点，并在测试阶段重新引入，基于Nodecopy策略补充邻接阵
- ✓ **注入噪声**：注入噪声以模拟分布波动

### 数据集统计信息

数据集	节点数	时间步数量	时间跨度	间隔长度	周期性内均值/ 周期内标准差
SIP	108	25,920	01/01/2017-03/31/2017	5min	72.17/55.45
Metr-LA	207	34,272	03/01/2012-06/30/2012	5min	27.45/30.25
KnowAir	184	11,688	01/01/2015-12/31/2018	3h	52.69/61.60
Electricity	321	26,304	01/01/2012-12/31/2014	15min	2538.79/820.92

### 周期性相关设定与子环境划分后平均方差

数据集	SIP	Metr-LA	KnowAir	Electricity
时间步	25,920	34,272	11,688	26,304
时间间隔	5 min	5 min	3 h	15 min
周期	daily	daily	weekly	daily
周期步数	288	288	56	96
子环境划分个数 $K$	6	6	6	6
子环境划分后阶段内平均方差	25.89	10.32	34.85	445.24

### 模型超参设置

参数	具体数值
CauSTG 主干网络	GraphWaveNet (GWN)
训练样本分割比例	训练/验证/测试集比例: 2/1/1
子环境划分个数 $K$	6
子环境内的模型个数 $m$	4
时序模式提取任务平衡系数 $(\lambda_0, \lambda_1, \lambda_2)$	(0.5, 0.5, 0.2)
学习率	1e-3
不变性比例阈值 $r\%$	(60%, 55%, 55%, 50%)
TCN 核的个数 $l$	(5, 5, 6, 6)
TCN 核的维度	(12, 6, 3)
新节点推断中新节点比例	5%
GNN 的隐层维度 $d_m$	64
优化器	Adam



# 时空预测模型泛化性研究

## 实验：三种OOD实验设计及实验结果

- ✓ **时序偏移**：基于不同阶段 (phase) 模拟随时间变化产生分布偏移现象
- ✓ **新节点归纳推断**：训练阶段mask部分节点，并在测试阶段重新引入，基于Nodecopy策略补充邻接阵
- ✓ **注入噪声**：注入噪声以模拟分布波动

### 消融实验

消融变体	SIP	Metr-LA	KnowAir	Electricity
CauSTG-Adj	21.10%	11.60%	26.14%	2.24%
CauSTG-GRU	21.62%	10.55%	25.17%	2.30%
CauSTG-NoHier	23.26%	13.42%	26.68%	2.84%
<b>CauSTG</b>	<b>19.91%</b>	<b>9.75%</b>	<b>23.63%</b>	<b>1.89%</b>

### 性能比较：SIP and Metr-LA

	SIP			Metr-LA		
	时序偏移	新节点归纳推理	人造噪声	时序偏移	新节点归纳推理	人造噪声
STGCN	22.75%	26.72%	23.36%	12.62%	15.13%	13.53%
MTGNN	<u>20.09%</u>	23.74%	<u>20.70%</u>	10.05%	12.56%	11.25%
GWN	20.13%	<u>23.65%</u>	<u>20.84%</u>	<u>10.01%</u>	<u>12.52%</u>	11.17%
DCRNN	21.17%	24.64%	21.88%	10.50%	13.01%	11.41%
ASTGNN	22.31%	25.87%	22.92%	10.04%	12.55%	10.99%
AdaRNN	21.22%	24.78%	22.79%	10.14%	13.08%	11.58%
MTGNN+IRM	20.21%	23.86%	20.52%*	10.02%	12.53%	11.03%
GWN+IRM	20.01%*	23.56%*	20.64%	9.94%*	12.45%*	10.95%*
CauSTG	<b>19.91%</b>	<b>23.03%</b>	<b>20.35%</b>	<b>9.75%</b>	<b>12.34%</b>	<b>10.64%</b>
Beyond non-inv	0.90%	2.62%	1.69%	2.60%	1.44%	3.18%
Beyond inv	0.50%	2.25%	0.83%	1.91%	0.88%	2.83%

### 性能比较：KnowAir and Electricity

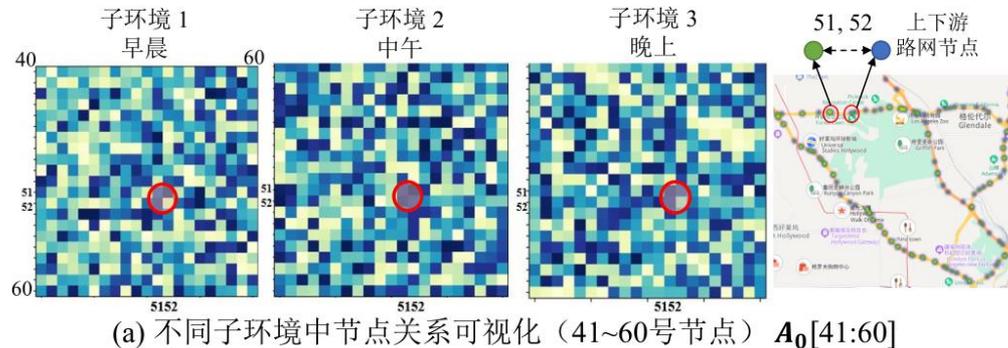
	KnowAir			Electricity		
	时序偏移	新节点归纳推理	人造噪声	时序偏移	新节点归纳推理	人造噪声
STGCN	31.71%	42.87%	33.94%	2.65%	4.93%	3.93%
MTGNN	<u>24.06%</u>	36.22%	29.59%	2.12%	4.41%	3.65%
GWN	24.13%	<u>36.21%</u>	<u>29.53%</u>	<u>2.08%</u>	<u>4.34%</u>	<u>3.51%</u>
DCRNN	25.17%	36.23%	30.43%	2.31%	4.68%	3.83%
ASTGNN	26.31%	37.43%	31.27%	2.33%	4.71%	3.79%
AdaRNN	24.60%	36.47%	30.76%	2.10%	4.45%	3.88%
MTGNN+IRM	24.03%	35.14%	29.46%	2.05%	4.21%	3.28%*
GWN+IRM	24.01%*	35.12%*	29.34%*	2.04%*	4.13%*	3.33%
CauSTG	<b>23.63%</b>	<b>34.32%</b>	<b>28.95%</b>	<b>1.89%</b>	<b>3.89%</b>	<b>3.15%</b>
Beyond non-inv	1.79%	5.22%	1.96%	9.13%	10.37%	10.26%
Beyond inv	1.58%	2.28%	1.33%	7.35%	5.81%	3.96%



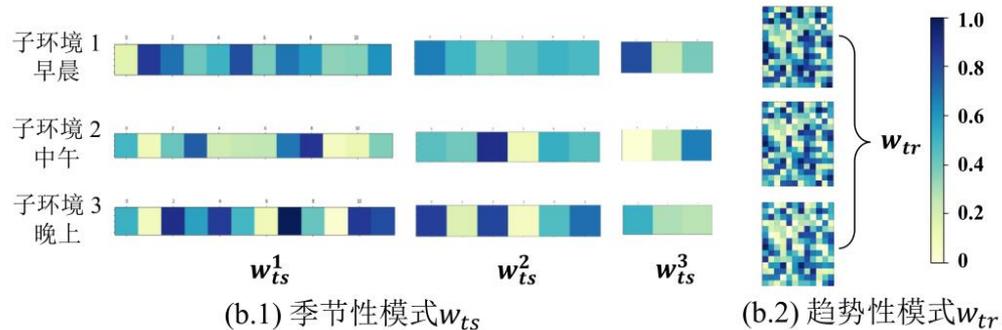
# 时空预测模型泛化性研究

## 实验：CauSTG模型权值可视化

空间关联



时序依赖



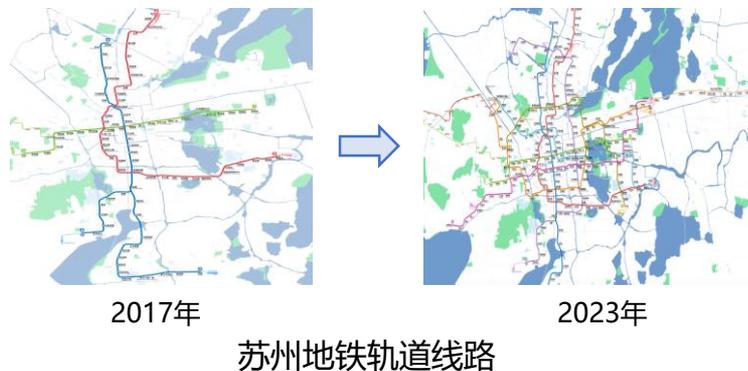
(b) 不同子环境的时序模式可视化

**模型所捕获的稳定关联具有一定的物理解释性**



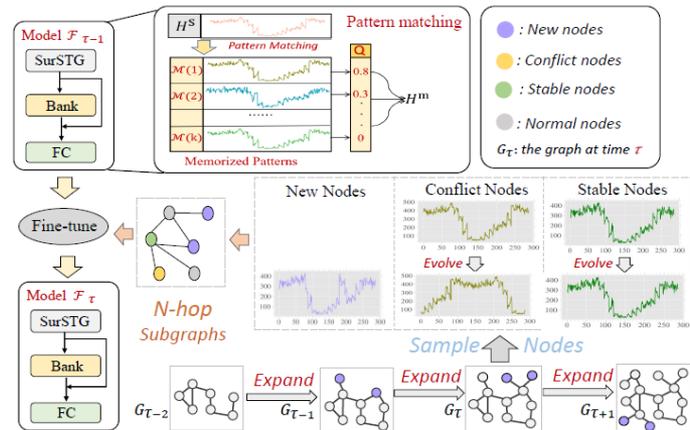
# 时空预测模型泛化性研究

针对空间增长与交通结构变化，提出面向空间动态增长的持续学习方法



基于内存管理，无需访问全部内存实现更新

赋能流式时空数据不变学习、模型自适应更新，提高泛化性与数据适应能力



Model	15 min			30 min			60 min			Time	
	MAE	RMSE	MAPE	MAE	RMSE	MAPE	MAE	RMSE	MAPE	Total(s)	
Retrained	GRU	14.71	25.01	20.36	17.15	29.02	22.76	19.98	29.78	26.29	5630.17
	SurSTG	12.34	20.31	16.93	13.74	22.87	18.51	15.28	25.76	21.36	8891.32
	SurSTG-Retrain	12.13	19.93	16.78	13.64	22.36	18.43	15.19	25.53	21.10	8504.67
Continual	SurSTG-Static	13.37	21.10	28.35	14.78	23.54	30.88	16.32	27.20	34.28	1208.98
	SurSTG-Expand	12.98	21.01	18.12	14.97	24.63	18.78	16.91	29.32	21.12	2296.43
	SurSTG-TS	12.29	20.22	16.35	13.93	22.74	17.67	15.45	25.64	19.87	4321.85
	PECPM	11.81	19.39	15.91	13.41	22.17	17.07	14.76	25.03	18.30	3035.21

Wang B, Zhang Y, Wang X, Zhou Z, et al. Pattern expansion and consolidation on evolving graphs for continual traffic prediction[C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2023: 2223-2232.

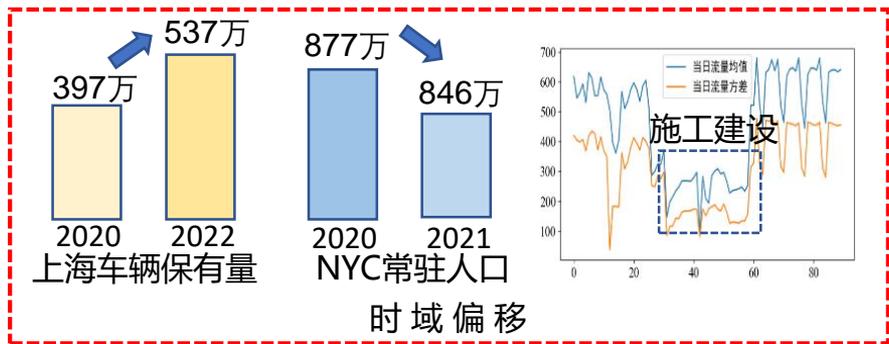
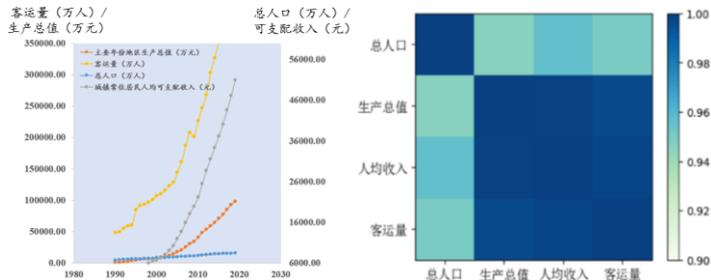


# 研究展望：城市增长与时空预测泛化

## 城市增长视角下的时空预测与分布外泛化

### 城市社会经济指标增长

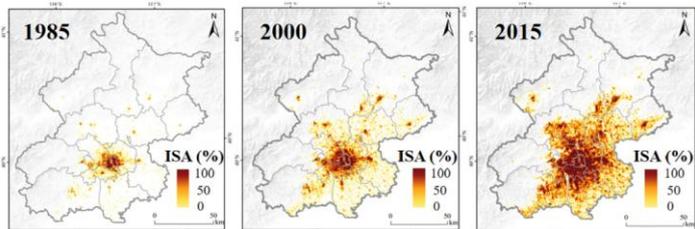
✓ 江苏省地区生产总值、地区客运量、总人口 ...



时域偏移

Machine Learning模型遵循**独立同分布**假设

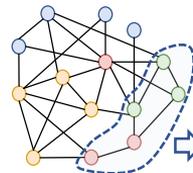
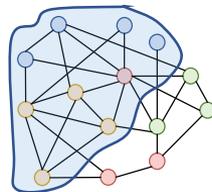
### 城市占地面积增长 (不透水表面积, ISA)



城市增长是城市发展的常态



- ✓ 现有模型不能适应城市增长，重复设计与训练模型，耗时耗力
- ✓ 没有有效的城市增长建模方法，也未将其与时空预测模型耦合



可微调  
权值

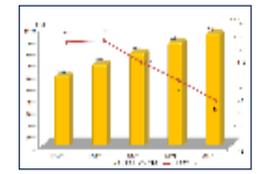
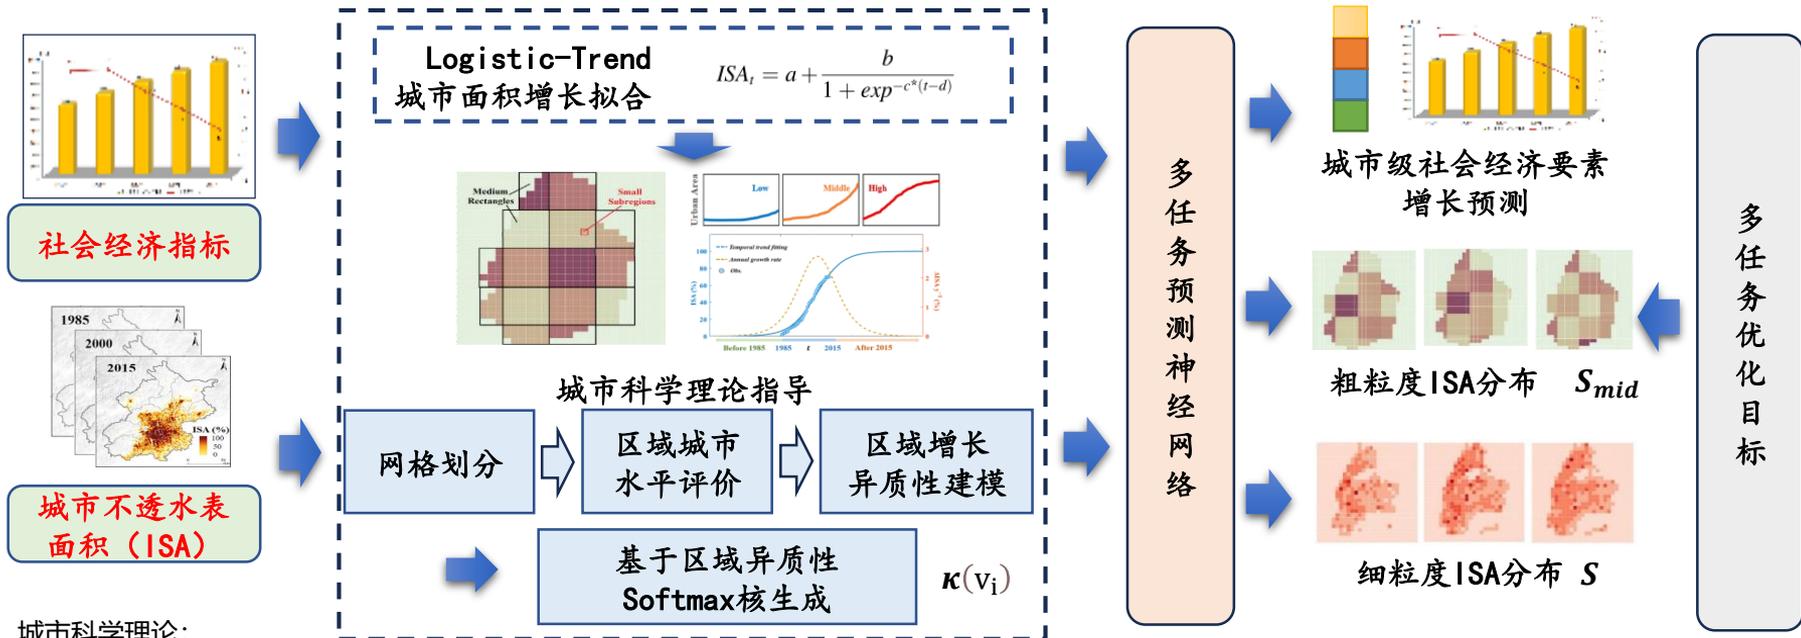
如何统一时域-空域泛化，耦合城市增长-时空预测，实现模型进化？



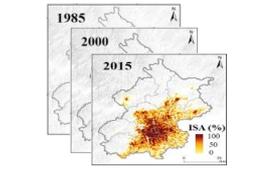
# 研究展望：城市增长与时空预测泛化

## 城市增长视角下的时空预测与分布外泛化

### 多任务多模态协同的城市时空增长建模



社会经济指标



城市不透水表面积 (ISA)

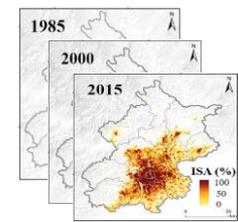
- 城市科学理论:
- ✓ 阶段性增长速率的异质性
  - ✓ 城市空间幂律效应
  - ✓ .....

- 任务统一
- 模态统一



# 研究展望：城市增长与时空预测泛化

## 基于时空互补学习的进化学习模型



动机：城市增长

参数演化  
行为建模

$$\frac{W_S^1, W_S^2, \dots, W_S^t}{W_T^1, W_T^2, \dots, W_T^t} \xrightarrow{\text{训练过程}} S_\Delta^t \rightarrow S_\Delta^t \dots \rightarrow S_\Delta^t$$

训练过程

$$(x, y) = \text{ArgMax } S_\Delta^t$$

不变结构  
解耦

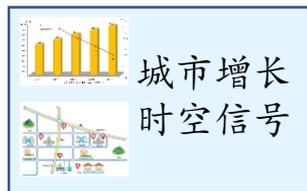
$$(x, y) = \text{ArgMin } S_\Delta^t$$

基于模型参数演化行为解耦不变关联 神经科学互补学习理论

稳定  
权值

不变的新皮质层

可微调  
权值  
动态的海马体结构



新节点/  
区域

社会经济  
指标增长

提示  
信号更新

空间提示

时域提示



Invariant neocortex

互补  
网络  
迁移

Fine-tuned  
hippocampus

增长视角  
时空预测  
高效推理

进化模型

统一时空分布外建模，实现模型局部更新

Zhou Z, Huang Q, Wang B, et al. ComS2T: A complementary spatiotemporal learning system for data-adaptive model evolution[J]. arXiv preprint arXiv:2403.01738, 2024. (Submit to IEEE TPAMI)



# 研究展望：城市增长与时空预测泛化

## 多源城市 时空数据



遥感数据



移动设备

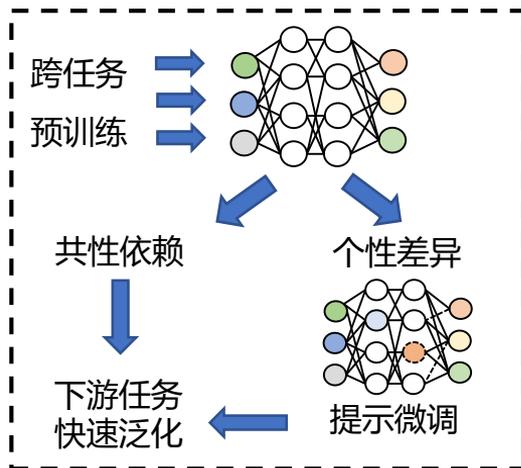


路网线圈传感器



交通事故分布

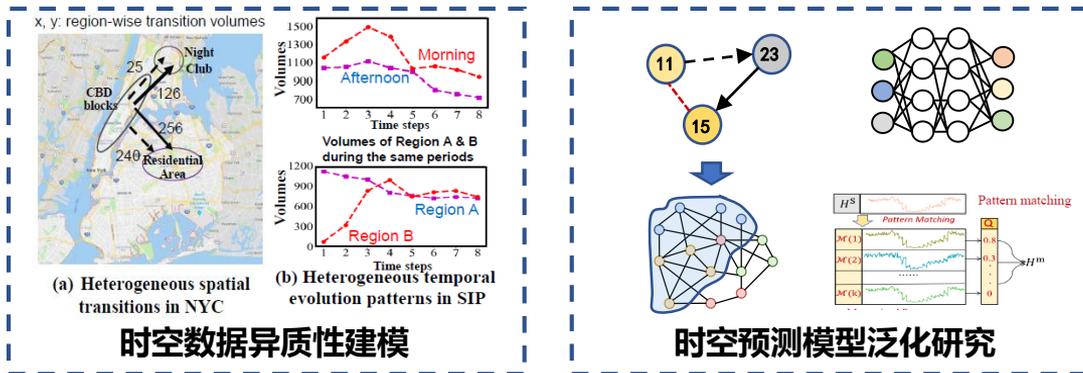
- 共性关联建模
- 异质任务关联建模
- 个性化数据摘要
- 任务描述与提示构建



- 异质车辆类型流量预测
  - 异质城市任务迁移预测
  - 时空多尺度协同预测
- 跨任务泛化**
- 

时空智能大模型

## 时空数据挖掘与人工智能基础理论研究



探索扩展性高、泛化性强  
时空计算框架

- 城市增长视角下的时空预测与分布外泛化
- 初探基于互补学习的时空智能进化机制

数据利用创新

提升数据利用效率：  
多尺度、多源数据协同建模

新问题与新视角

时空预测**新视角**：图同配性、不变性与不确定性、模型行为建模

新方法与新技术

个性化有向深度聚合、多源稀疏协同建模  
时空因果学习与互补时空学习



# 课题组介绍



数据智能实验室

Data Intelligence Lab

团队负责人：博导，安徽省杰青、软件学院副院长 汪 炆

优秀的青年科研骨干：3名副研究员、数10名优秀博士生和近20位硕士研究生组成的优秀硕博研究团队，年轻而充满活力。

平台建设：拥有16块V100、2块A100、2块H100高性能计算GPU，与微尺度国家实验室江俊教授、港科大（广州）梁宇轩教授、佛罗里达王广教授建立密切合作。已形成时空数据挖掘、交叉学科机器学习等多支研究团队。



团队负责人  
汪炆 副院长



特任副研究员  
周正阳



特任副研究员  
王鹏焜



特任副研究员  
王旭



博士研究生  
王斌武



博士研究生  
李利民

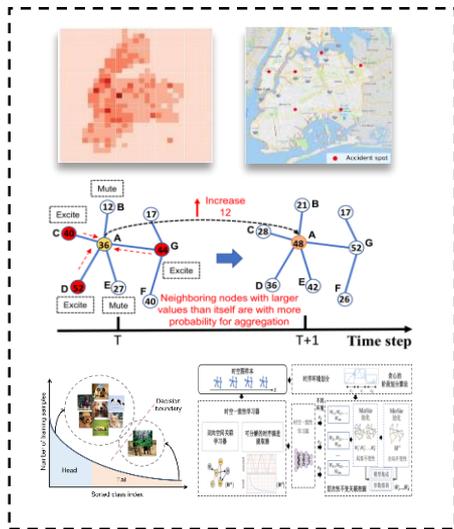


# 课题组介绍

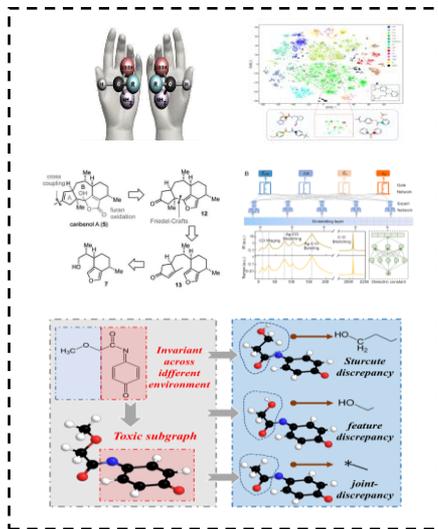


## 数据智能实验室

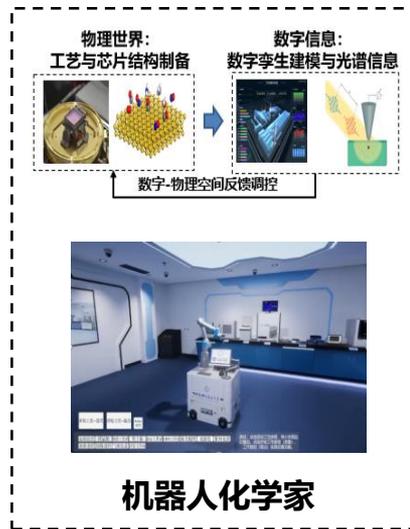
Data Intelligence Lab



### 时空数据挖掘与 人工智能基础理论研究



### AI4Science数据挖掘 方法研究



### 承担项目与 系统研发



团队负责人  
汪扬 副院长



特任副研究员  
王鹏焜



博士研究生  
王斌武



特任副研究员  
周正阳



特任副研究员  
王旭



博士研究生  
李利民



# 结语



数据智能实验室

Data Intelligence Lab

- ✓ 博士后
- ✓ 特任副研究员
- ✓ 优秀硕士生
- ✓ 多样的合作形式

## We are hiring !

## 欢迎合作与交流!

扫码了解  
高研院



扫码了解  
引才政策



## 数据智能实验室

Data Intelligence Lab



课题组主页



个人主页