




用图划分增强交通预测

- 交通预测

- 指对交通系统的状态在时间和空间上进行预测

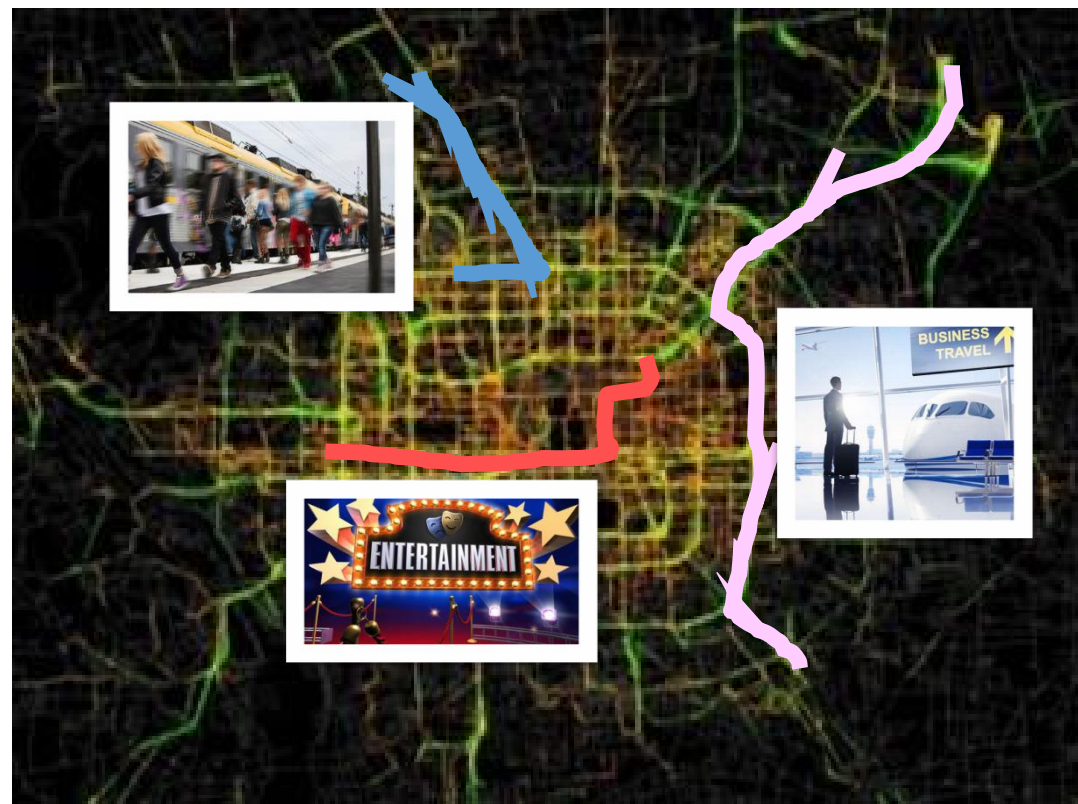


- 重要性

- ITS的核心技术
- 城市公众安全
- 交通拥堵管理

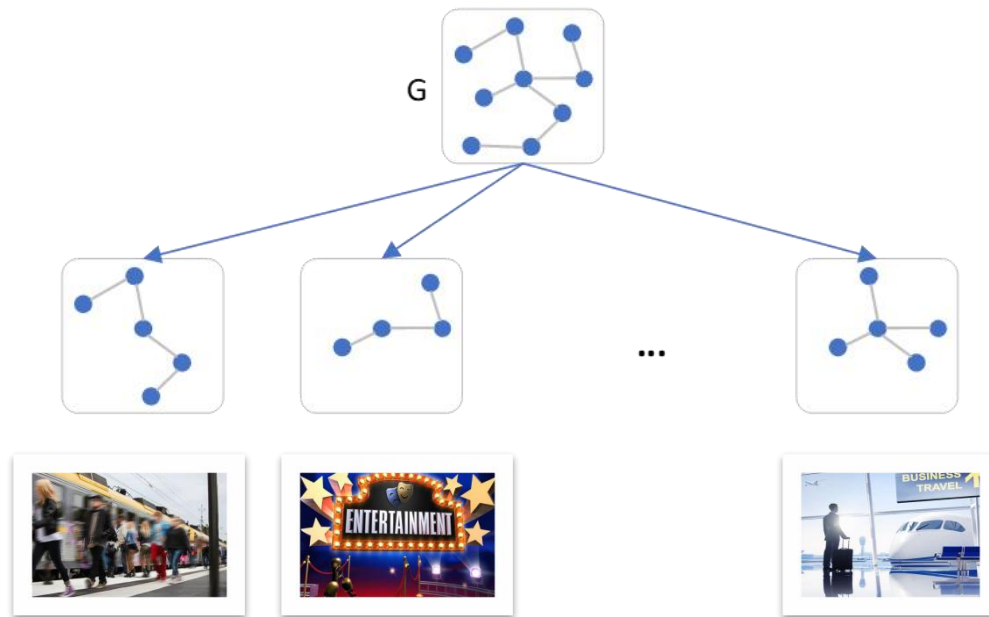


- 数据生成视角：交通流通常由多种不同的交通出行模式生成
 - 如通勤（上下班、学）、娱乐、商务出行、购物等
 - **不同的模式**又对应**不同的路线图**，分布在**整个城市中**
- 已有方法专注于用一个**全局的图结构**，来预测复杂的交通流
 - 为模型全面理解交通流带来了极大的挑战（预测不准）
 - 也使得模型预测异常时，用户很难甄别原因（可解释性低）



• 分而治之

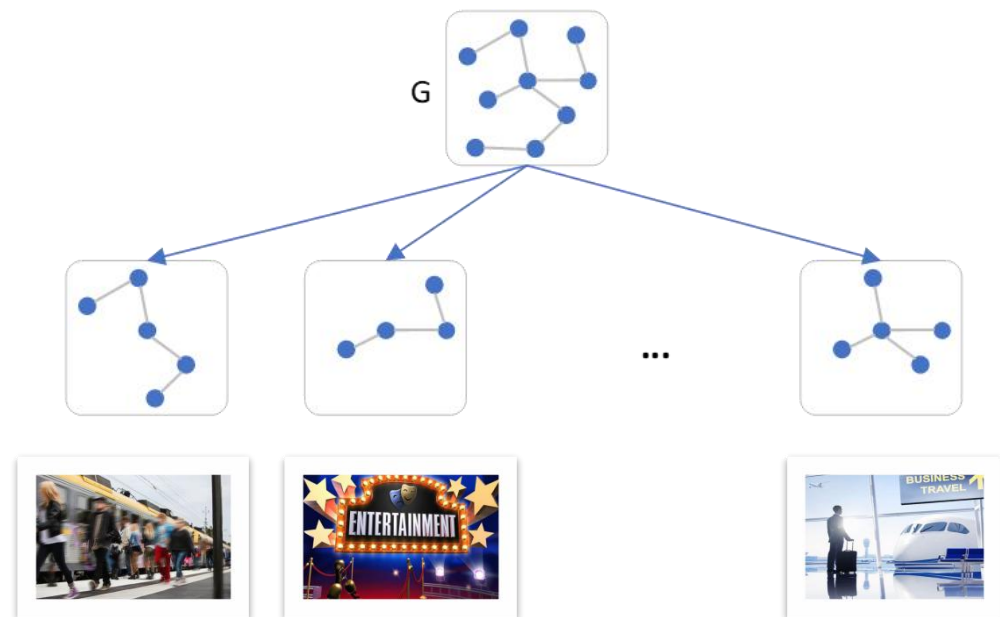
- Step 1: 将原问题分解为多个**规模更小、相互独立**的子模式
- Step 2: 对每个子模式分别建模求解
- Step 3: 对各个子模式的预测值求和得到最终预测值



• 分而治之 (1/3)

• 将原问题分解为多个**规模更小、相互独立**的子模式

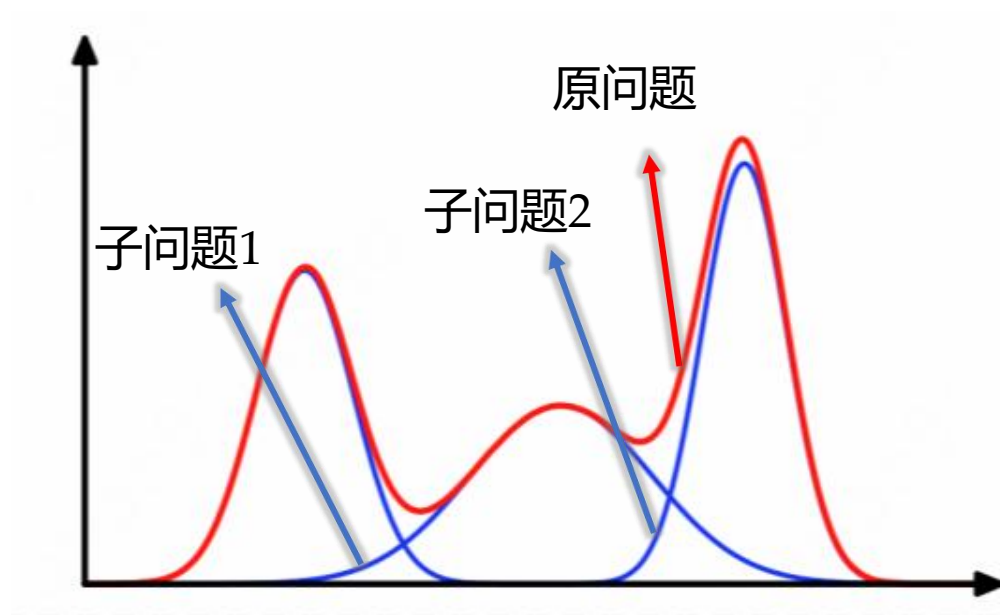
- 原问题目标：预测**多种**人群移动模式混合下的交通流，表现为在复杂 graph 上的交通预测
- 子问题目标：预测**单个人**群移动模式下的交通流，表现为在分解后的 sub-graph 上的交通预测
- **规模更小**：子图要包含比原图更少的边
- **相互独立**：子图之间差异要尽可能明显



• 分而治之 (2/3)

- 对每个子模式分别建模求解

- 以单个节点的流量预测为例，原问题面对的数据分布为**混合概率分布**
- 而子问题面对的数据分布更加简单，本质在于其**熵更低**
- 因此在采用**同等建模能力**的模型时，子问题能够获得更精确的解 (定理1)



• 分而治之 (3/3)

• 对各个子模式的预测值求和得到最终预测值

- 原问题: 输入 x , 输出 $\hat{y} = f(x)$

- 分解问题: 输入 x_i , 输出 $\hat{y} = \sum_{i=1}^K \hat{y}_i = \sum_{i=1}^K f_i(x_i)$

- 其中 K 为子问题个数

- 假设原问题的真值为 y , 误差为 e ; 子问题的真值为 $\{y_i\}$, 误差为 e_i , 子问题之和误差为 \hat{e}

- 根据**定理1** (子问题能够获得更精确的解), $e_i < e$

- **假设误差满足** $\hat{e}y \leq \sum_{i=1}^K e_i y_i$ (如MAE)

- 则 $\hat{e}y \leq \sum_{i=1}^K e_i y_i < \sum_{i=1}^K e y_i = e \sum_{i=1}^K y_i = e y$ 即 $\hat{e} < e$

方法



• 约束条件

- 约束1: **规模更小**, 子图要包含比原图更少的边
 - 分解为多个子图
- 约束2: **相互独立**: 子图之间差异要尽可能明显
 - 约束子图不相似性的正则项
- 约束3: 各个子模式建模方式相同
- 约束4: 评估指标可加
 - MAE

- 相关研究

- 图分解 (Graph decomposition)

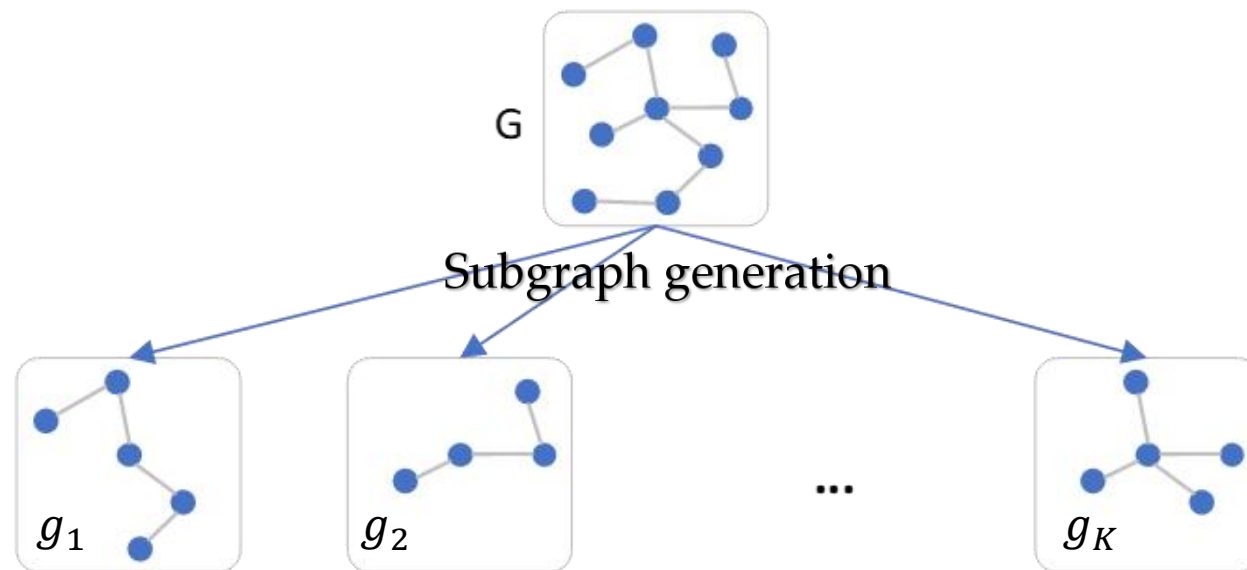
- 划分各子图同构为某个 pattern

- 图划分 (Graph Partitioning)

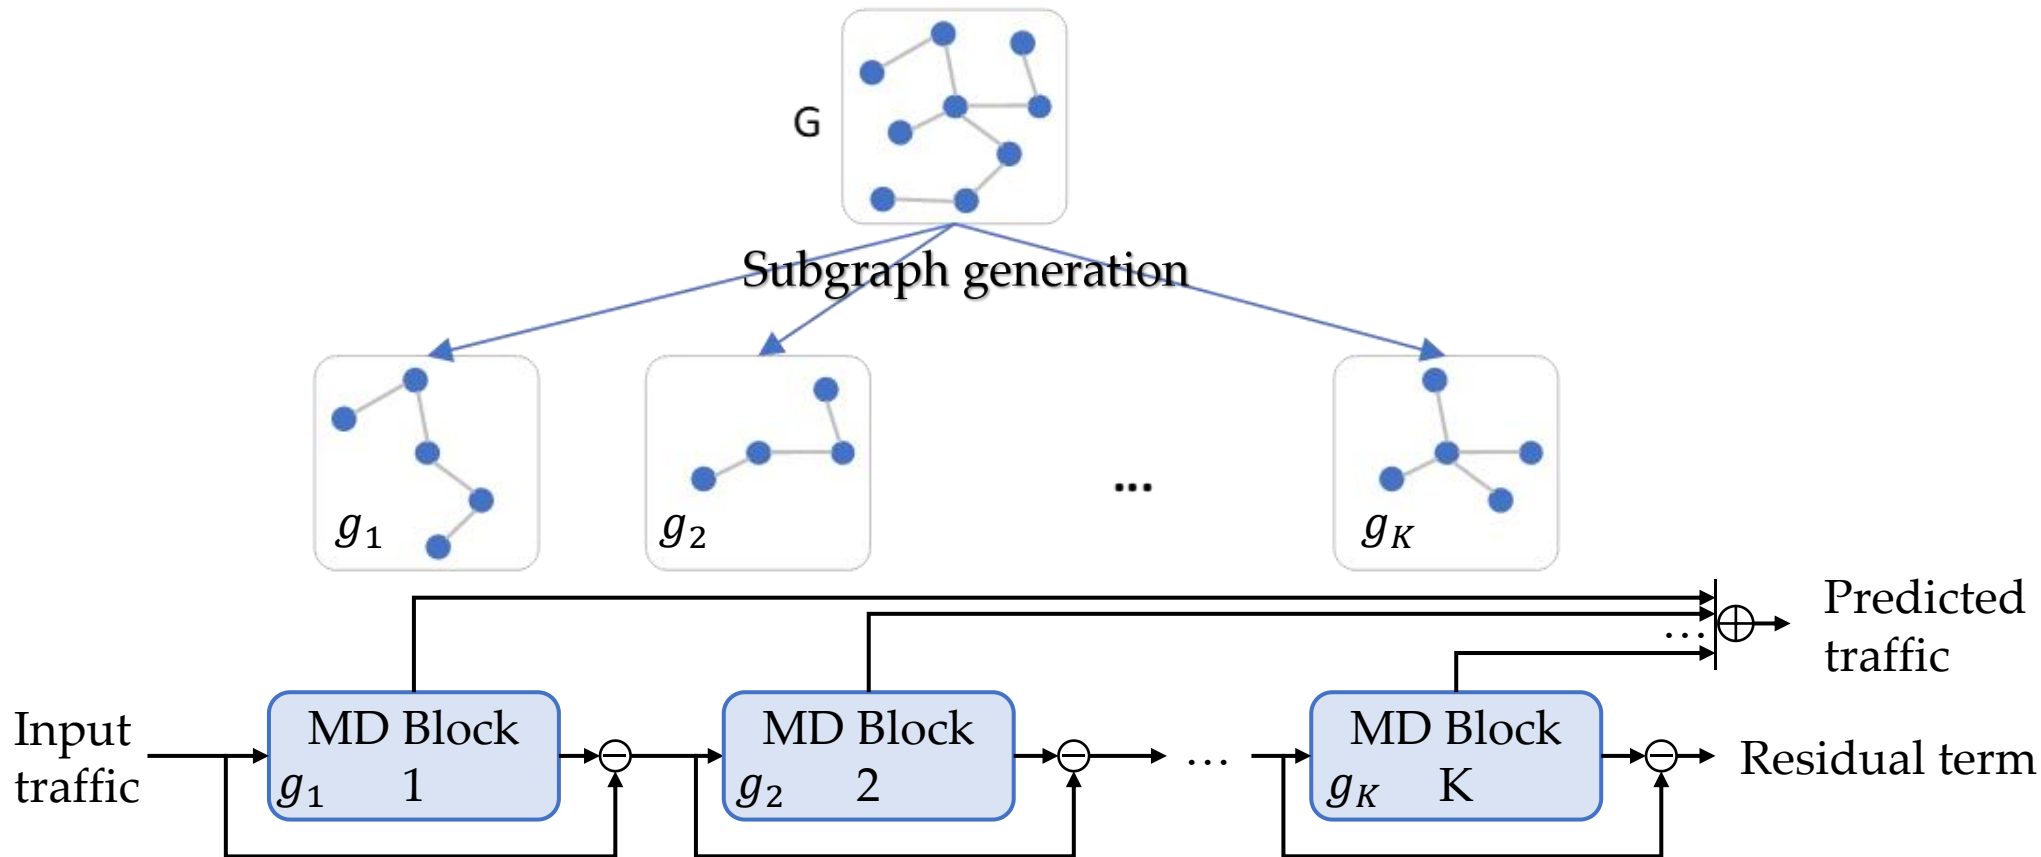

- 将点集/边集分配到各个子图中, 经典方法大都为固定条件分割
 - 点分割: METIS、随机哈希等, **与模式无关**
 - 边分割: **复杂度较高**且与交通模式分解无法联系
 - 因此, 我们采用的是**神经网络学习各个子图内容的方式**

• 子图生成


- 学习 K 个 mask 矩阵, 与原图相乘后得到不同的子图 $g_{1\sim K}$
- 作为不同模式的路线图



模型架构(2/4): 模型图

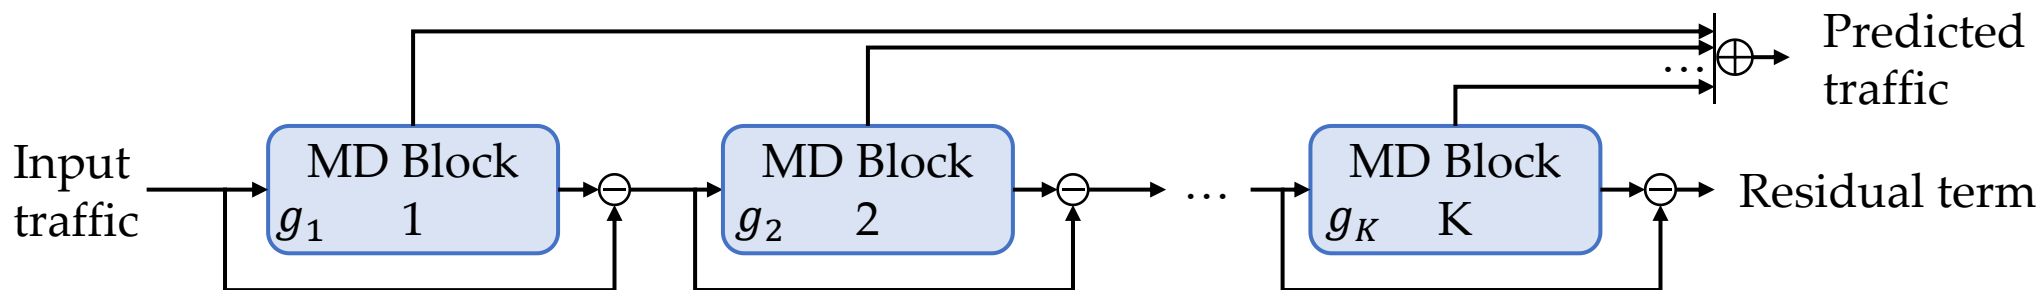
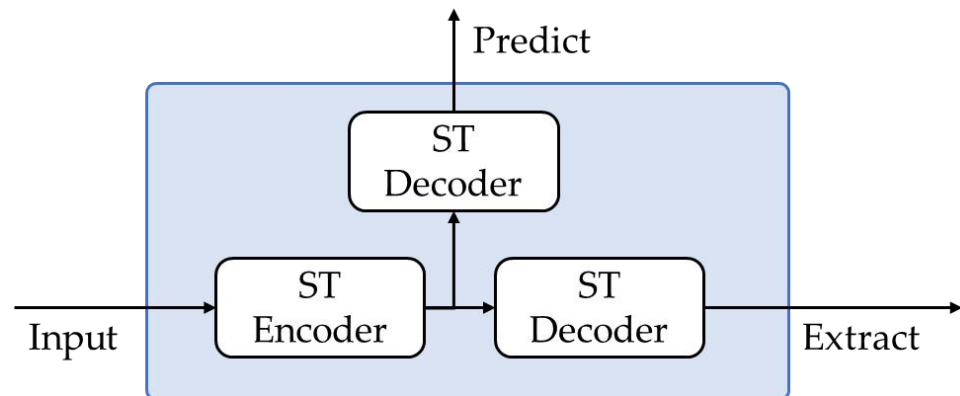


模型架构(3/4)：多级分解学习



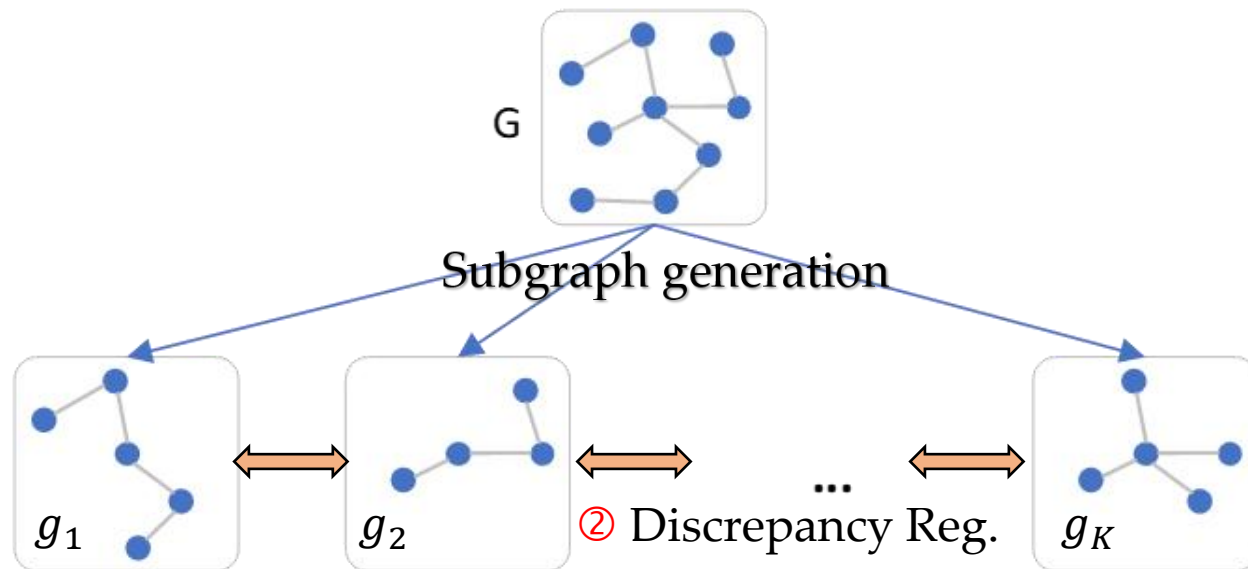
- 基本思想：

- 每个block专注于一种模式的学习
 - 既能恢复输入，又能预测未来
- 将其余的模式留给后面的 block 学习
 - 残差相减，减掉已经学会的模式



• 正则项约束

- 子图的并集为总图 ①
- 不同图之间不相似性越大越好 ②



① Consistency Reg. $D\left(G, \bigcup_{k=1}^K g_k\right)$

- 相关研究

- 经典方法

- 图编辑距离 (GED)
 - 核函数 (Graph kernel)
 - 最大公共子图 (MCS)
 - 最大公共连通诱导子图 (MCCIS) 等
 - NP-Hard 难以应用

- 可用方法

- 邻接矩阵之差
 - 正交正则化
 - 针对距离分布的评价指标 NND^[1]

[1] Tiago A Schieber, Laura Carpi, Albert Díaz-Guilera, Panos M Pardalos, Cristina Masoller, and Martín G Ravetti. 2017. Quantification of network structural dissimilarities. Nature communications 8, 1 (2017), 13928

实验



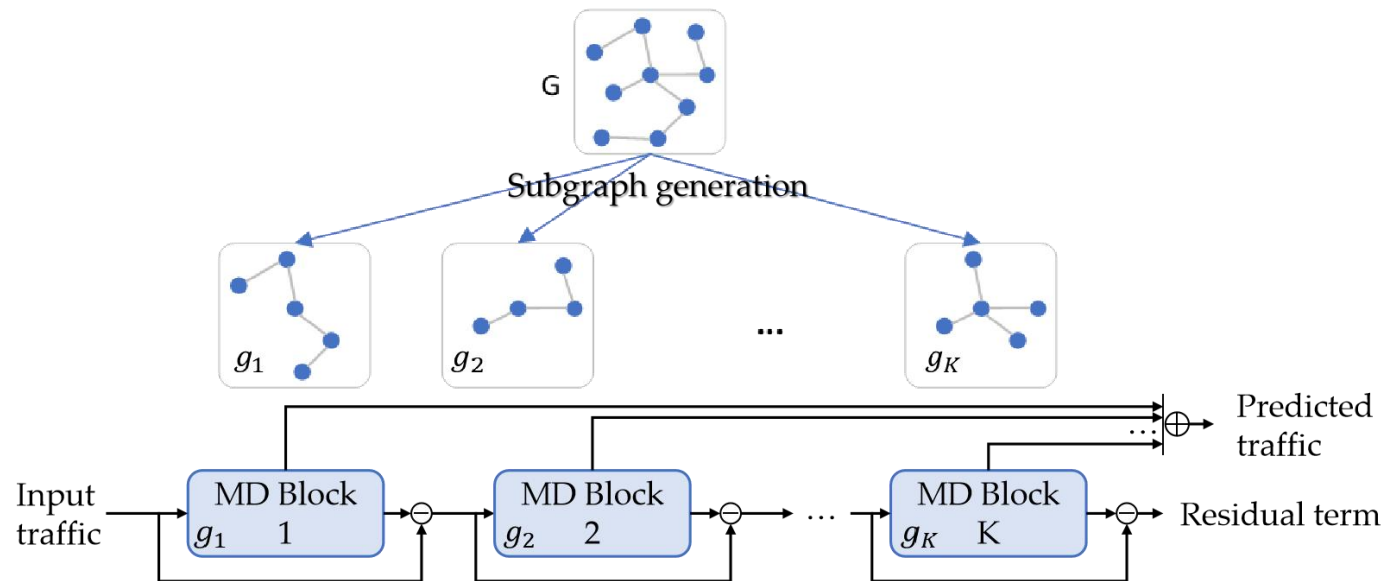
- 交通预测总体效果验证
- 各模块的有效性验证
- 可视化学习到的 graph

• 交通预测总体效果验证

Dataset	Metric	Type	ARIMA	SVR	ST-ResNet	STGCN	GMAN	AGCRN	STSGCN	STFGNN	ASTGNN	STExpertNet	STGDL
NYCBike1	MAE	In	10.66	7.27	5.53±0.06	5.33±0.02	6.77±3.42	5.17±0.03	5.81±0.04	6.53±0.10	6.16±0.08	6.45±0.05	5.04±0.02
		Out	11.33	7.98	5.74±0.07	5.59±0.03	7.17±3.61	5.47±0.03	6.10±0.04	6.79±0.08	7.03±0.14	6.85±0.07	5.32±0.02
	MAPE	In	33.05	25.39	25.46±0.20	26.92±0.08	31.72±12.29	25.59±0.22	26.51±0.32	32.14±0.23	30.81±0.28	32.74±0.30	22.26±0.02
		Out	35.03	27.42	26.36±0.50	27.69±0.14	34.74±17.04	26.63±0.30	27.56±0.39	32.88±0.19	33.25±0.42	34.24±0.48	23.25±0.05
NYCBike2	MAE	In	8.91	12.82	5.63±0.14	5.21±0.02	5.24±0.13	5.18±0.03	5.25±0.03	5.80±0.10	6.78±0.24	5.82±0.05	5.04±0.03
		Out	8.70	11.48	5.26±0.08	4.92±0.02	4.97±0.14	4.79±0.04	4.94±0.05	5.51±0.11	8.48±0.31	5.35±0.06	4.68±0.01
	MAPE	In	28.86	46.52	32.17±0.85	27.73±0.16	27.38±1.13	27.14±0.14	29.26±0.13	30.73±0.49	35.84±0.69	30.84±0.15	22.99±0.04
		Out	28.22	41.91	30.48±0.86	26.83±0.21	26.75±1.14	26.17±0.22	28.02±0.23	29.98±0.46	41.67±0.86	29.39±0.28	21.61±0.05
NYCTaxi	MAE	In	20.86	52.16	13.48±0.14	13.12±0.04	15.09±0.61	12.13±0.11	13.69±0.11	16.25±0.38	15.18±0.11	15.79±0.25	11.69±0.04
		Out	16.80	41.71	10.78±0.25	10.35±0.03	12.06±0.39	9.87±0.04	10.75±0.17	12.47±0.25	22.44±1.39	12.56±0.24	9.50±0.03
	MAPE	In	21.49	65.10	24.83±0.55	21.01±0.18	22.73±1.20	18.78±0.04	22.91±0.44	24.01±0.30	25.17±0.88	28.85±0.76	16.81±0.04
		Out	21.23	64.06	24.42±0.52	20.78±0.16	21.97±0.86	18.41±0.21	22.37±0.16	23.28±0.47	39.80±1.72	28.15±0.83	16.75±0.03
BJTaxi	MAE	In	21.48	52.77	12.12±0.11	12.34±0.09	13.13±0.43	12.30±0.06	12.72±0.03	13.83±0.04	11.15±0.05	13.27±0.13	11.77
		Out	21.60	52.74	12.16±0.12	12.41±0.08	13.20±0.43	12.38±0.06	12.79±0.03	13.89±0.04	11.24±0.05	13.32±0.10	11.81
	MAPE	In	23.12	65.51	15.50±0.26	16.66±0.21	18.67±0.99	15.61±0.15	17.22±0.17	19.29±0.07	15.28±0.06	19.68±0.77	15.05
		Out	20.67	65.51	15.57±0.26	16.76±0.22	18.84±1.04	15.75±0.15	17.35±0.17	19.41±0.07	15.47±0.10	19.56±0.64	15.41


• 消融实验(1/2):

- loss 包括四部分
 - 预测值与真实值的 MAE
 - 残差的 MAE
 - 相似性正则项
 - 子图正则项




- STGDL-L2 L3 L4 分别为 STGDL 去掉了部分 loss 的变体
- **TODO 消融实验结果**

- 消融实验(2/2):
 - ST Encoder 选用为 STGCN
 - 与 STGCN 进行对比实验
 - **TODO 消融实验结果**



- 子图可视化
 - 各个子图学到偏好边





谢谢