

Beijing Forest Studio
北京理工大学信息系统及安全对抗实验中心



时序知识图谱推理方法

齐首华

2023年09月10日

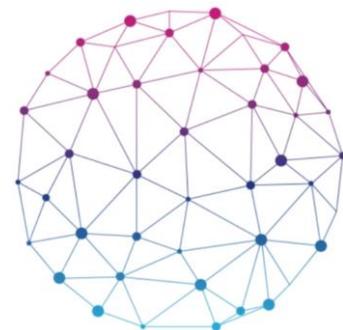
- **总结反思**
 - PPT需要优化，留白较多，有错别字
 - 语气单调，互动较少
- **相关内容**
 - 潘琿《基于知识图谱的推荐算法研究》--2023.05.21
 - 李新帅《异质图神经网络》--2022.09.26
 - 蔡成成《基于元学习的知识图谱补全技术》--2021.06.27

- 背景简介
- 基础概念
 - 时序知识图谱推理
 - 基本模型
- 算法原理
 - RE-NET
 - L2TKG
- 应用总结
- 参考文献

- 预期收获
 - 了解时序知识图谱推理的定义及分类
 - 了解时序知识图谱推理研究脉络
 - 理解基于深度学习的时序知识图谱推理方法原理
 - 了解时序知识图谱推理的前沿发展

- 知识图谱 (knowledge graph, KG)

- 知识图谱是一种以**图形结构呈现知识**的方法，它可以将各种实体以及它们之间的关系进行建模，形成一个庞大而复杂的知识网络
- 大规模知识图谱被广泛应用于**人工智能**和**数据挖掘**等领域，例如搜索引擎、推荐系统、问答系统等



- 知识图谱的时效性

- 通常事实是有**时效性**的，因此知识图谱中的事实仅在特定时期内有效
 - 例如 (Trump, President of, USA) 仅在[2017-2021]有效
- 因此，通过向知识图谱中加入时间标签形成了**时序知识图谱**
 - (Trump, President of, USA , [2017-2021])



- 知识图谱并不完整
 - 通常**源数据集**缺乏全面的信息
 - 在处理各种形式的非结构化数据时**知识抽取算法**面临挑战，导致其效率降低
 - 自然界中不断发生的事件，**知识不断发展**
- 知识图谱推理
 - 知识图谱推理是指通过使用**已知的事实、关系和规则**，从已有的知识图谱中推导出新的信息、关系或结论的过程。

(Trump, succeeded, Obama, 2017)



(Obama, President of, USA, [2009, 2017])



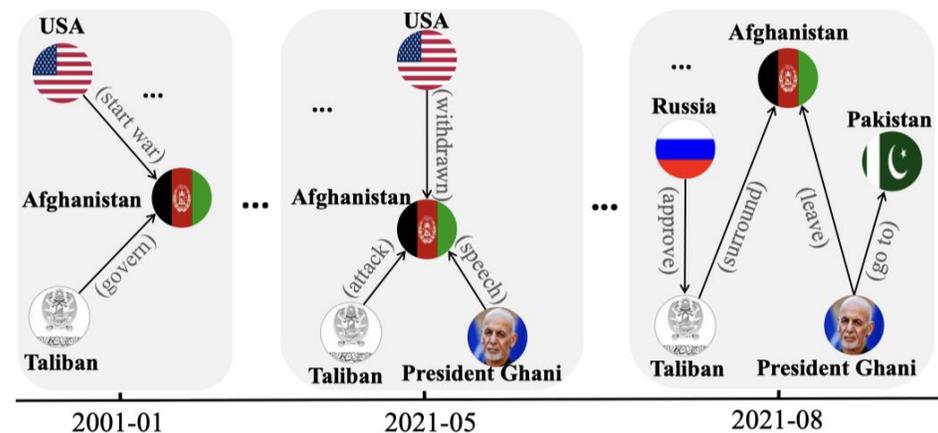
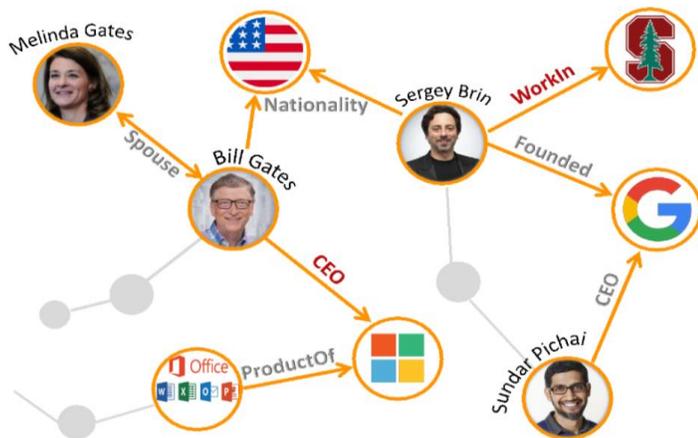
知识图谱的不完整性极大地阻碍了知识驱动系统的有效性，从而强调了时序知识图谱推理作为一项关键任务的重要性。

- 知识图谱定义

- 知识图谱是结构化的**多关系知识库**，通常包含一组事实。知识图谱中的每个事实都以**三元组** (s, r, o) 的形式存储，其中s和o分别表示头实体和尾实体，r表示连接头实体和尾实体的关系。

- 时序知识图谱定义

- 所有在t时刻出现的四元组 (s, r, o, t) 构成一个知识图 G_t 。时序知识图谱G被定义为具有不同**时间戳**的知识图谱序列，即 $G = \{G_1, G_2, \dots, G_t\}$



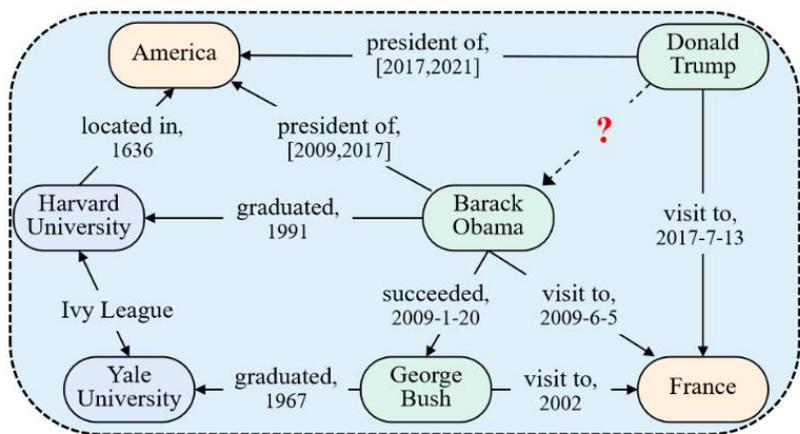
• 时序知识图谱推理

– 给定时间在 $[t_0, t_n]$ 之间的时序知识图谱

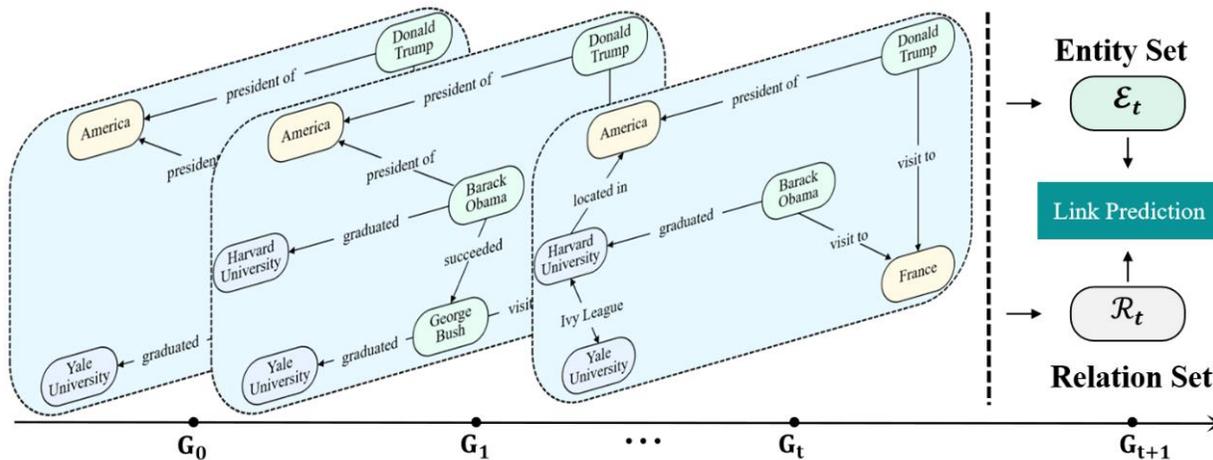
- 内插设置：预测时间 t 的新事实，其中 $t_0 \leq t \leq t_n$

- 外推设置：侧重于在大于 t_n （即 $t > t_n$ ）的时间戳 t 上预测新事实

– 应用：财务分析、社交媒体趋势分析、个性化推荐



(a) Interpolation



(b) Extrapolation

外推设置根据观察到的历史KG来预测未来时间戳的新事实，有助于理解事件的隐藏因素并响应新出现的事件

• 问题定义

– 时序知识图谱 $G = \{E, R, T, Q\}$

- 实体集合 $E = [e_1, e_2, \dots, e_n]$

- 关系集合 $R = [r_1, r_2, \dots, r_n]$

- 时间戳集合 $T = [t_1, t_2, \dots, t_T]$

- 四元组集合 $Q = \{(s, r, o, t)\} \subseteq E \times R \times E \times T$

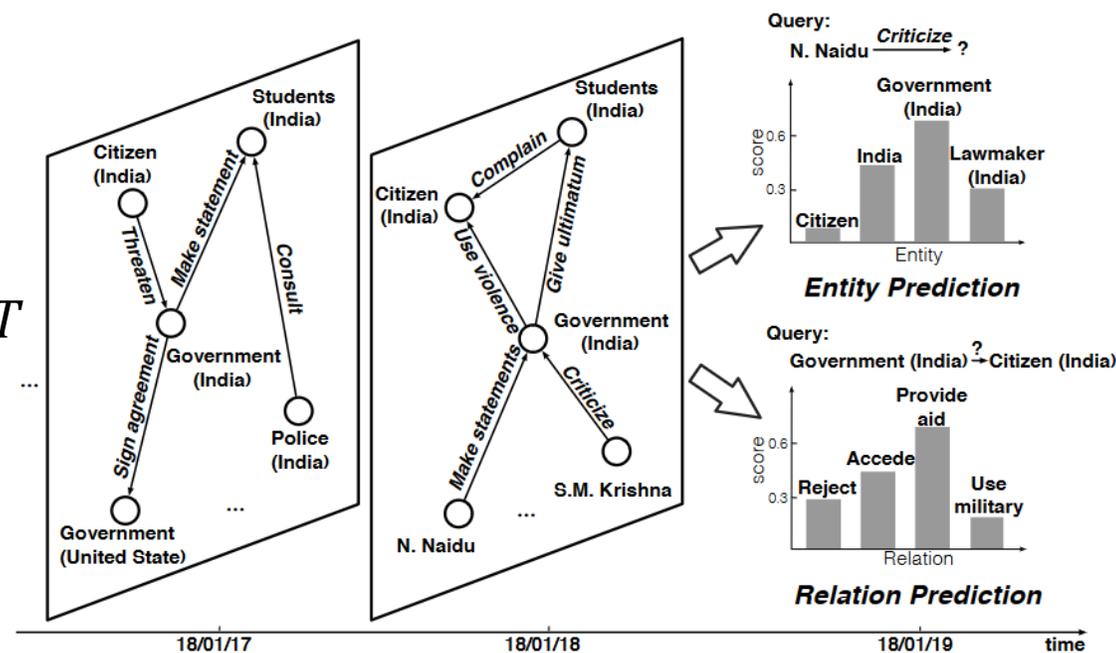
– 查询

- 实体预测 $(s, r, ?, t)$ $(?, r, o, t)$

- 关系预测 $(s, ?, o, t)$

- 其中 $t > t_T$

– 问题：给定一个查询，根据历史时序知识图谱中已知事实，预测查询中缺失的s、r或o

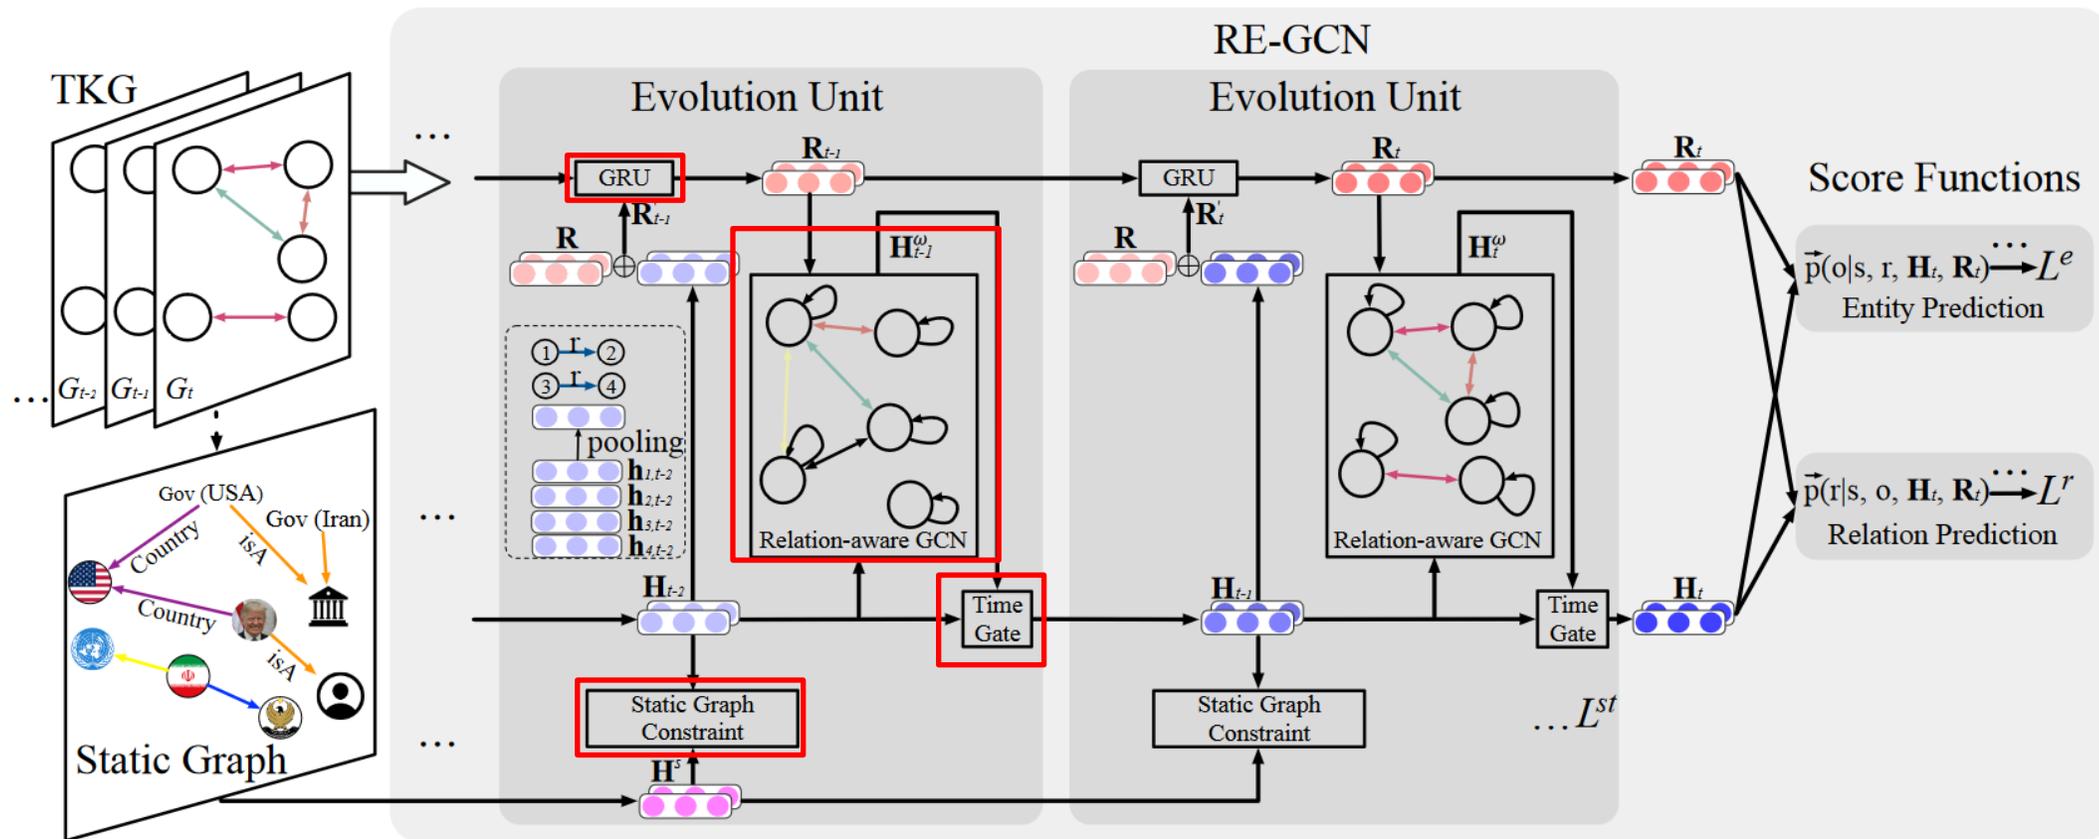




RE-GCN

T	目标	根据时序知识图谱预测未来四元组缺失的头实体/尾实体/关系
I	输入	历史时序知识图谱序列、查询 (ICEWS18数据集: 四元组400k个)
P	处理	<ol style="list-style-type: none"> 1. 利用关系感知 GCN 来捕获每个时间戳的 KG 内的结构依赖性 2. 通过静态图约束组件合并实体的静态属性 3. 通过门循环组件进行自回归建模历史 KG 序列 4. 通过交叉熵损失函数训练神经网络框架 5. 预测查询中缺失的头实体、尾实体或关系
O	输出	查询中缺失的头实体、尾实体或 关系
P	问题	忽略所有事实之间的结构依赖关系和实体的静态属性, 效率低下
C	条件	静态图约束组件仅在部分可构造静态图的数据集中有效
D	难点	建模并发事实之间的结构依赖、时间相邻事实的顺序模式以及实体的静态属性
L	水平	SIGIR 2021 (CCF-A)

• 算法原理图



进化单元

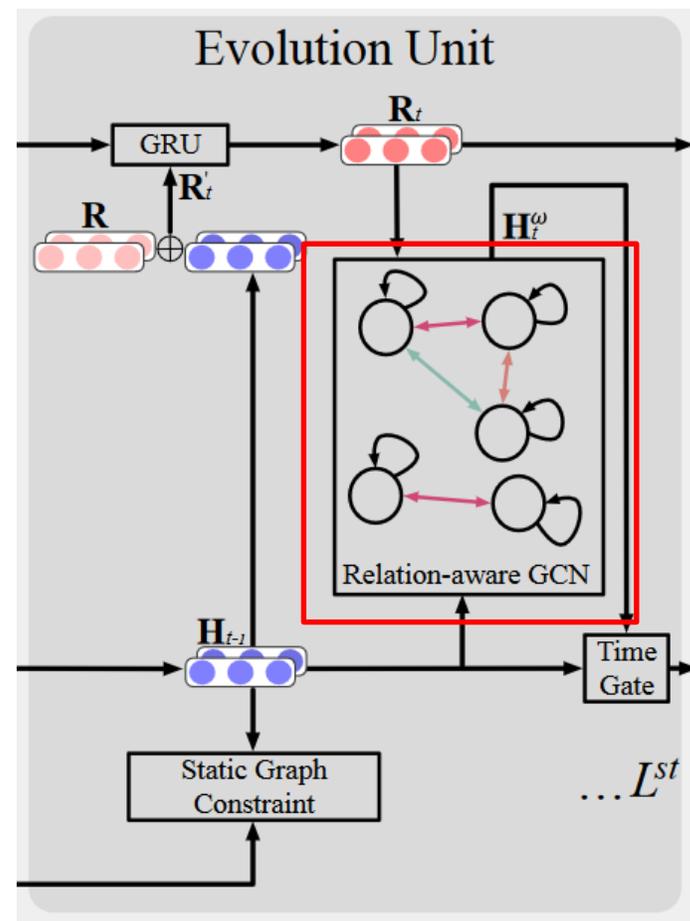
- 进化单元由一个**关系感知 GCN**、**两个门循环组件**和一个**静态图约束组件**组成

关系感知GCN

- 捕获每个时间戳的 **KG 结构依赖关系**
- 使用 ω 层关系感知 GCN 来对结构依赖性进行建模

$$\vec{h}_{o,t}^{l+1} = f\left(\frac{1}{c_0} \sum_{(s,r), \exists(s,r,o) \in Q_t} W_1^l (h_{s,t}^l + \vec{r}_t) + W_2^l \vec{h}_{o,t}^l\right)$$

- $\vec{h}_{s,t}^l + \vec{r}_t$ 表示头实体和相应尾实体之间的**平移属性**
- 对于不涉及任何事实的实体，仅执行具有额外参数 W_3^l 的自循环操作



门循环组件

- 由GRU和Time Gate门循环组件进行自回归建模，以有效捕获所有时间相邻事实的序列模式
- GRU: 捕获关系的时间依赖，时间戳t的关系嵌入r受两部分影响:

- t-1时刻的关系嵌入
- t时刻与r相关的实体嵌入

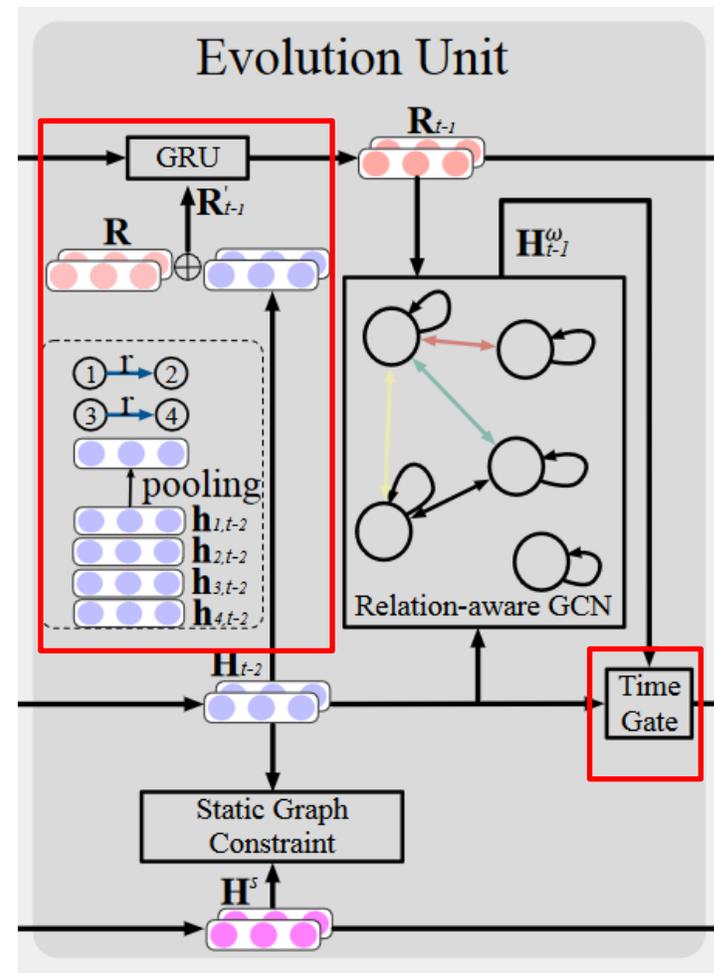
$$\vec{r}'_t = [\text{pooling}(H_{t-1, V_{r,t}}); \vec{r}]$$

$$R_t = \text{GRU}(R_{t-1}, R'_t)$$

- Time Gate: 捕获实体的时间依赖

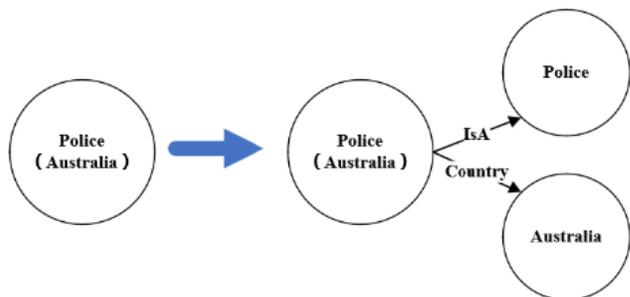
$$H_t = U_t \otimes H_t^\omega + (1 - U_t) \otimes H_{t-1}$$

进化单元大量堆叠层数可能会导致梯度消失问题



静态图约束组件

- 实体的一些**静态属性**形成静态图，可以看作TKG的背景知识，有助于模型学习更准确的实体进化表示

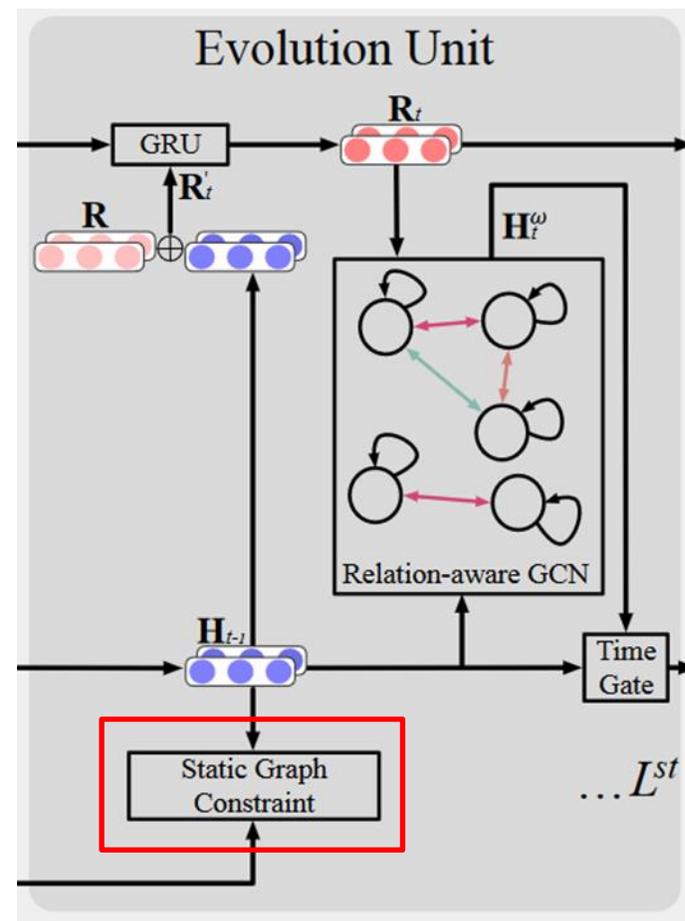


- 同一实体的进化嵌入和静态嵌入之间的角度限制为不超过**时间戳相关的阈值**

$$\theta_x = \min(\gamma x, 90^\circ)$$

- 静态图约束损失

$$L_x^{st} = \sum_{i=0}^{|V|-1} \max\{\cos\theta_x - \cos(\vec{h}_i^s, \vec{h}_{t-m+x,i}), 0\}$$



• 评分函数

- **ConvTransE**作为解码器，包含一个卷积层和一个全连接层，具体结构见附录。

$$\vec{p}(o|s, r, \mathbf{H}_t, \mathbf{R}_t) = \sigma(\mathbf{H}_t \text{ConvTransE}(\vec{s}_t, \vec{r}_t))$$

$$\vec{p}(r|s, o, \mathbf{H}_t, \mathbf{R}_t) = \sigma(\mathbf{R}_t \text{ConvTransE}(\vec{s}_t, \vec{o}_t))$$

• 损失函数

- 实体预测任务和关系预测任务都可以看作是**多标签学习**问题。

$$L^e = \sum_{t=0}^{T-1} \sum_{(s,r,o,t+1) \in \mathcal{E}_{t+1}} \sum_{i=0}^{|\mathcal{V}|-1} y_{t+1,i}^e \log p_i(o|s, r, \mathbf{H}_t, \mathbf{R}_t)$$

$$L^r = \sum_{t=0}^{T-1} \sum_{(s,r,o,t+1) \in \mathcal{E}_{t+1}} \sum_{i=0}^{|\mathcal{R}|-1} y_{t+1,i}^r \log p_i(r|s, o, \mathbf{H}_t, \mathbf{R}_t),$$

- $L = \lambda_1 L^e + \lambda_2 L^r + L^{st}$

实验设计

– 数据集

Datasets	$ \mathcal{V} $	$ \mathcal{R} $	$ \mathcal{E}_{train} $	$ \mathcal{E}_{valid} $	$ \mathcal{E}_{test} $	$ \mathcal{E}^s $	$ \mathcal{V}^s $	Time interval
ICEWS18	23,033	256	373,018	45,995	49,545	29,774	8,647	24 hours
ICEWS14	6,869	230	74,845	8,514	7,371	8,442	3,499	24 hours
ICEWS05-15	10,094	251	368,868	46,302	46,159	12,392	5,179	24 hours
WIKI	12,554	24	539,286	67,538	63,110	–	–	1 year
YAGO	10,623	10	161,540	19,523	20,026	–	–	1 year
GDELT	7,691	240	1,734,399	238,765	305,241	–	–	15 mins

– 评价指标

- MR: 平均排名
- MMR: 平均倒数排名
- Hit@n: 排名小于等于n的正确四元组的平均占比

• 对比实验-实体预测

- 静态图谱推理模型: DistMult、 ComplEx、 R-GCN、 ConvE、 ConvTransE、 RotatE
- 内插时序知识图谱推理模型: HyTE、 TTransE、 TA-DistMult
- 外推时序知识图谱推理模型: RGCRN、 CyGNet、 RE-NET

Model	ICE18				ICE14				ICE05-15				WIKI			YAGO			GDELT			
	MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10	MRR	H@3	H@10	MRR	H@3	H@10	MRR	H@1	H@3	H@10
DistMult	13.86	5.61	15.22	31.26	20.32	6.13	27.59	46.61	19.91	5.63	27.22	47.33	27.96	32.45	39.51	44.05	49.70	59.94	8.61	3.91	8.27	17.04
ComplEx	15.45	8.04	17.19	30.73	22.61	9.88	28.93	47.57	20.26	6.66	26.43	47.31	27.69	31.99	38.61	44.09	49.57	59.64	9.84	5.17	9.58	18.23
R-GCN	15.05	8.13	16.49	29.00	28.03	19.42	31.95	44.83	27.13	18.83	30.41	43.16	13.96	15.75	22.05	20.25	24.01	37.30	12.17	7.40	12.37	20.63
ConvE	22.81	13.63	25.83	41.43	30.30	21.30	34.42	47.89	31.40	21.56	35.70	50.96	26.03	30.51	39.18	41.22	47.03	59.90	18.37	11.29	19.36	32.13
ConvTransE	23.22	14.26	26.13	41.34	31.50	22.46	34.98	50.03	30.28	20.79	33.80	49.95	30.89	34.30	41.45	46.67	52.22	62.52	19.07	11.85	20.32	33.14
RotatE	14.53	6.47	15.78	31.86	25.71	16.41	29.01	45.16	19.01	10.42	21.35	36.92	26.08	31.63	38.51	42.08	46.77	59.39	3.62	0.52	2.26	8.37
HyTE	7.41	3.10	7.33	16.01	16.78	2.13	24.84	43.94	16.05	6.53	20.20	34.72	25.40	29.16	37.54	14.42	39.73	46.98	6.69	0.01	7.57	19.06
TTransE	8.44	1.85	8.95	22.38	12.86	3.14	15.72	33.65	16.53	5.51	20.77	39.26	20.66	23.88	33.04	26.10	36.28	47.73	5.53	0.46	4.97	15.37
TA-DistMult	16.42	8.60	18.13	32.51	26.22	16.83	29.72	45.23	27.51	17.57	31.46	47.32	26.44	31.36	38.97	44.98	50.64	61.11	10.34	4.44	10.44	21.63
RGCRN	23.46	14.24	26.62	41.96	33.31	24.08	36.55	51.54	35.93	26.23	40.02	54.63	28.68	31.44	38.58	43.71	48.53	56.98	18.63	11.53	19.80	32.42
CyGNet	24.98	15.54	28.58	43.54	34.68	25.35	38.88	53.16	35.46	25.44	40.20	54.47	30.77	33.83	41.19	46.72	52.48	61.52	18.05	11.13	19.11	31.50
RE-NET	26.17	16.43	29.89	44.37	35.77	25.99	40.10	54.87	36.86	26.24	41.85	57.60	30.87	33.55	41.27	46.81	52.71	61.93	19.60	12.03	20.56	33.89
RE-GCN	27.51	17.82	31.17	46.55	37.78	27.17	42.50	58.84	38.27	27.43	43.06	59.93	39.84	44.43	53.88	58.27	65.62	75.94	19.15	11.92	20.40	33.19
RE-GCN w. GT	30.55	20.00	34.73	51.46	41.50	30.86	46.60	62.47	46.41	35.17	52.76	67.64	51.53	58.29	69.53	63.07	71.17	82.07	19.31	11.99	20.61	33.59

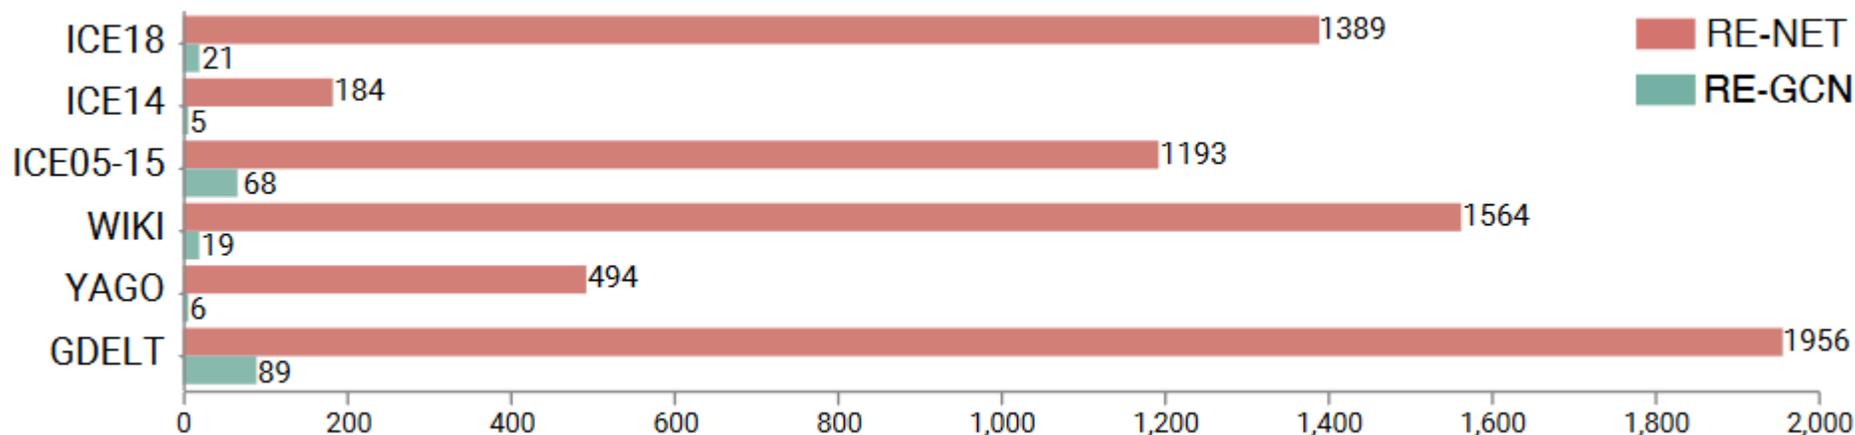
• 对比实验-关系预测

- RE-GCN 的表现优于所有基线，表明进化单元可以通过对历史进行全面建模来获得更准确的进化表示
- 与其他基线在关系预测任务上的性能差距小于实体预测任务，因为更少的候选者使得关系预测任务比实体预测任务容易得多。

Model	ICE18	ICE14	ICE05-15	WIKI	YAGO	GDELTA
ConvE	37.73	38.80	37.89	78.23	91.33	18.84
ConvTransE	38.00	38.40	38.26	86.64	90.98	18.97
RGCRN	37.14	38.04	38.37	88.88	90.18	18.58
RE-GCN	39.48	39.73	38.56	95.63	95.18	19.17
RE-GCN w.GT	40.53	41.06	40.63	97.92	97.74	19.22

• 对比实验-预测时间

- 这是因为RENET针对每个时间戳逐一处理各个查询
- RE-GCN从KG序列的角度来表征进化表示学习，同时获得同一时间戳下所有查询的表示
- 因此，RE-GCN比最佳基线RE-NET更高效。





消融实验

- EE w.GT: 删除进化单元,仅使用 ConvTransE 评分函数和随机初始化的可学习嵌入
- +FCN w.GT: 用一层全连接网络代替ConvTransE
- st w.GT: 删除静态图约束组件
- tg w.GT: 删除时间门循环组件

Model	ICE18	ICE14	ICE05-15	WIKI	YAGO	GDELTA
RE-GCN w. GT	30.55	41.50	46.41	51.53	63.07	19.31
RE-NET w. GT	27.87	39.13	42.92	32.44	48.60	21.29
-EE w. GT	23.22	31.50	30.28	30.89	46.67	19.07
+FCN w. GT	29.32	40.34	45.89	46.00	58.96	19.02
-st w. GT	29.10	39.48	44.68	-	-	-
-tg w. GT	24.51	34.85	37.65	51.70	62.23	18.55

Table 6: Ablation studies on entity prediction.

Model	ICE18	ICE14	ICE05-15	WIKI	YAGO	GDELTA
RE-GCN w. GT	40.53	41.06	40.63	97.92	97.74	19.22
RGCRN w. GT	38.07	38.28	39.33	90.12	91.27	18.73
-EE w. GT	38.00	38.40	38.26	86.64	90.98	18.97
+FCN w. GT	39.63	40.23	40.55	97.23	93.66	19.03
-st w. GT	39.23	40.00	40.38	-	-	-
-tg w. GT	37.47	38.14	37.62	97.56	93.86	18.94

Table 7: Ablation studies on relation prediction.

• 优势

- RE-GCN从KG序列的角度来表征进化表示学习，同时获得同一时间戳下所有查询的表示，效率较高
- 充分利用静态图中的属性信息
- 同一模型可同时完成实体预测和关系预测任务

• 劣势

- 没有充分考虑实体之间的潜在关系
- 对于时间的建模相对简单，没能挖掘更多有效的信息



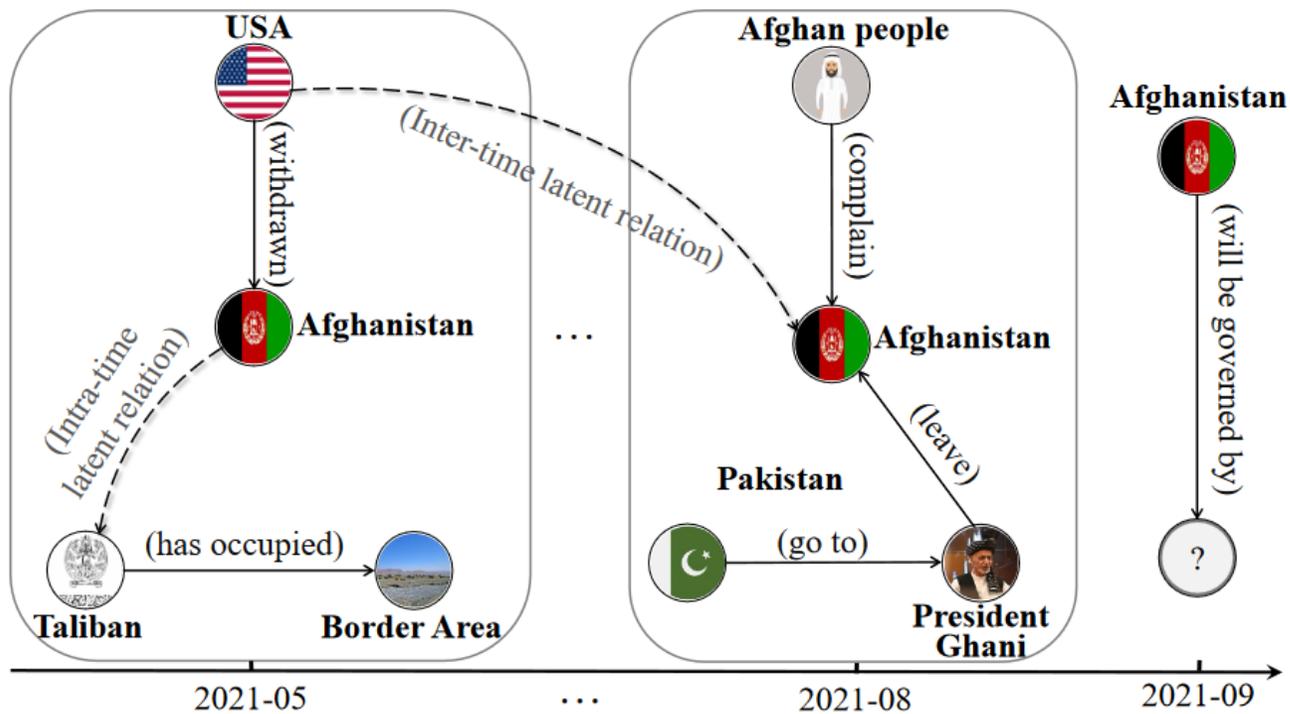


L2TKG

T	目标	根据时序知识图谱预测未来四元组缺失的头实体、尾实体
I	输入	历史时序知识图谱序列、查询 (ICEWS18数据集: 四元组400k个)
P	处理	<ol style="list-style-type: none">1. 利用结构化编码器(SE)来获得每个时间戳实体的表示2. 通过潜在关系学习(LRL)模块来挖掘和利用时间内和跨时间的潜在关系3. 从SE和LRL的输出中提取时间表示用于实体预测
O	输出	查询中缺失的头实体、尾实体

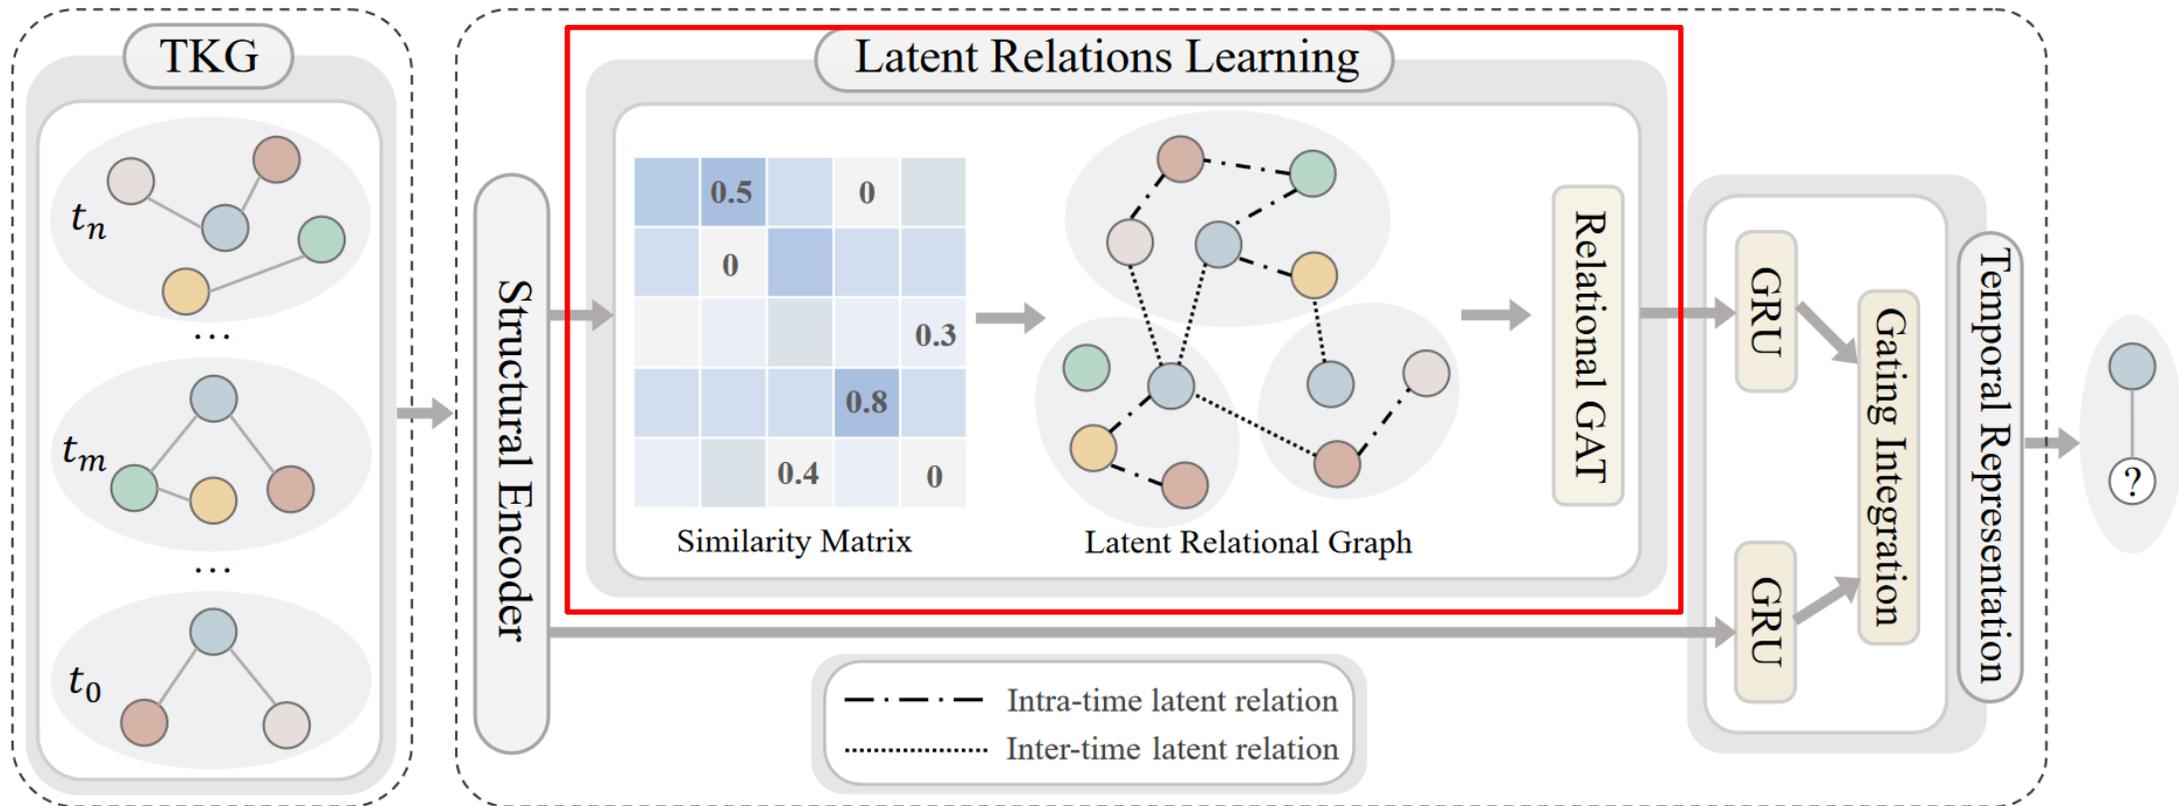
P	问题	现有方法在显式捕获共现实体之间的 时间内潜在关系 和不同时间出现实体之间的 跨时间潜在关系 方面存在一定缺陷
C	条件	历史知识图谱序列
D	难点	对潜在关系进行建模
L	水平	ACL 2023 (CCF-A)

- 启发
 - 共现实体之间的**时间内潜在关系**
 - 不同时间出现实体之间的**跨时间潜在关系**



由于构建工具和数据源的限制，实体之间的许多重要关联可能会在 TKG 中被省略

• 算法原理图



主要由三部分组成：结构编码器、潜在关系学习、时间表示学习

- 潜在关系学习

- 假设高度关联的实体在**嵌入空间**中也表现出相似性。
- 本文使用余弦相似度 $d(h_{e_i}, h_{e_j})$

- 时间内潜在关系学习

- 计算在同一时间步 t_p **同时出现但未连接**的任意两个实体表示之间的相似度。

$$S_{i,j}^{t_p} = d(h_{e_i,t_p}, h_{e_j,t_p})$$

- 执行稀疏操作：对于每个实体，只保留**top-k**的潜在关系分数，**减少噪声干扰**

$$\hat{S}_{i,j}^{t_p} = \begin{cases} S_{i,j}^{t_p}, & S_{i,j}^{t_p} \in \text{Top-k}(S_{i,:}^{t_p}) \\ 0, & otherwise \end{cases}$$

- 跨时间潜在关系学习

- 计算在**不同时间步** t_p 和 t_q 出现的任意两个实体表示之间的相似度。

$$Q_{i,j}^{t_p,t_q} = d(\mathbf{h}_{e_i,t_p}, \mathbf{h}_{e_j,t_q})$$

- 执行稀疏操作

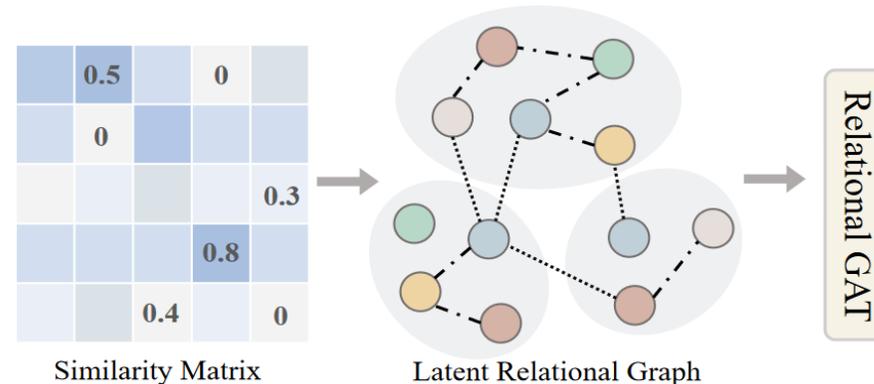
- 构造潜在关系图

- 基于获得的相似度矩阵，构建一个**潜在关系图**

- 如果 $\hat{S}_{i,j}^{t_p} > 0$ ，在潜在关系图内构建 $e_i^{t_p}$ 和 $e_j^{t_p}$ 之间的内部时间潜在关系

- 如果 $\hat{Q}_{i,j}^{t_p,t_q} > 0$ ，在潜在关系图内构造 $e_i^{t_p}$ 和 $e_j^{t_q}$ 之间的跨时间潜在关系

- 该图**只包含潜在关系**并省略 TKG 序列的原始关系



- 编码潜在关系图

- 利用图**注意力机制**来计算潜在关系图中学习到的潜在关系 r 下两个相邻节点 i 和 j 之间的系数:

$$\alpha_{ij} = \frac{\exp\left(f\left(\mathbf{a}^T \mathbf{W}_3 \left[\mathbf{z}_i^l \parallel \mathbf{z}_j^l \parallel \mathbf{z}_r^{ij}\right]\right)\right)}{\sum_{k \in \mathcal{N}_i} \exp\left(f\left(\mathbf{a}^T \mathbf{W}_3 \left[\mathbf{z}_i^l \parallel \mathbf{z}_k^l \parallel \mathbf{z}_r^{ik}\right]\right)\right)}$$

- **聚合**潜在关系图中邻居的嵌入来获得每个实体的更全面的表示

$$\mathbf{z}_i^{l+1} = g\left(\sum_{k \in \mathcal{N}_i} \alpha_{ij} \mathbf{W}_6 \left(\mathbf{z}_k^l + \mathbf{z}_r^{ik}\right) + \mathbf{W}_7 \mathbf{z}_i^l\right)$$

- 时间表示学习

- 通过GRU得到每个实体**局部和全局的时间表示**

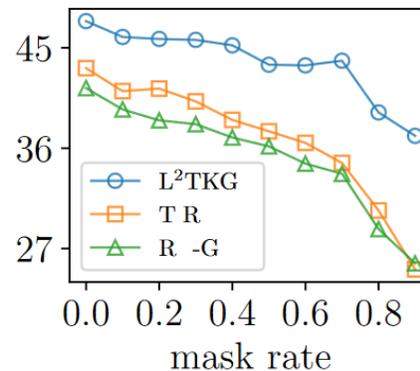
$$\mathbf{e}_{s,t+1}^G = \text{GRU}_G\left(\mathbf{e}_{s,t}^G, \mathbf{z}_{s,t}\right) \quad \mathbf{e}_{s,t+1}^L = \text{GRU}_L\left(\mathbf{e}_{s,t}^L, \mathbf{h}_{s,t}\right)$$

• 对比实验

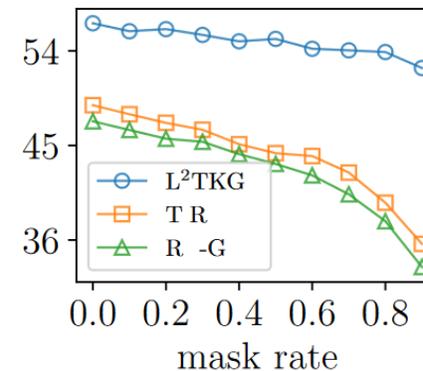
Model	ICEWS14			ICEWS05-15			ICEWS18			GDELT		
	MRR	Hit@1	Hit@10	MRR	Hit@1	Hit@10	MRR	Hit@1	Hit@10	MRR	Hit@1	Hit@10
DisMult	25.31	17.93	42.22	17.43	10.08	30.12	16.59	10.01	31.69	15.64	9.37	29.01
ComplEx	32.33	23.21	52.37	23.14	14.56	41.63	18.84	11.41	25.78	12.23	8.30	20.36
RGCN	28.14	19.43	46.02	27.43	20.15	44.62	18.04	8.57	35.68	10.93	4.59	22.38
ConvE	30.93	21.74	50.18	25.25	16.07	44.34	24.28	15.61	44.59	17.28	10.34	30.63
RotatE	27.53	18.60	47.62	19.39	10.19	38.57	15.35	7.10	33.09	5.48	1.96	13.76
CyGNet	37.65	27.43	57.90	40.42	29.44	61.60	27.12	17.21	46.85	20.22	12.35	35.82
RE-NET	39.86	30.11	58.21	43.67	33.55	62.72	29.78	19.73	48.46	19.55	12.38	34.00
xERTE	40.79	32.70	57.30	46.62	37.84	63.92	29.31	21.03	46.48	19.45	11.92	34.18
TITer	41.73	32.74	58.44	47.60	38.29	64.86	29.98	22.05	44.83	18.19	11.52	31.00
RE-GCN*	41.99	32.93	61.92	47.39	37.65	68.56	30.13	19.11	48.86	19.13	11.54	32.35
CENET	41.30	32.58	58.22	47.13	37.25	67.61	29.65	19.98	48.23	19.73	12.04	34.98
TiRGN*	43.18	33.12	62.24	48.83	38.62	69.20	32.22	22.24	51.88	21.67	13.63	37.60
L ² TKG	47.40	35.36	71.05	57.43	41.86	80.69	33.36	22.15	55.04	20.53	12.89	35.83
$\Delta Improve.$	9.77%	6.73%	14.15%	17.61%	8.39%	16.60%	3.54%	-	6.09%	-	-	-

- L2TKG 在所有 ICEWS 数据集上以最多的评估指标取得了最佳性能
- GDELT 数据中，它每次包含的事实数量较多，并且关联缺失的问题不太严重。

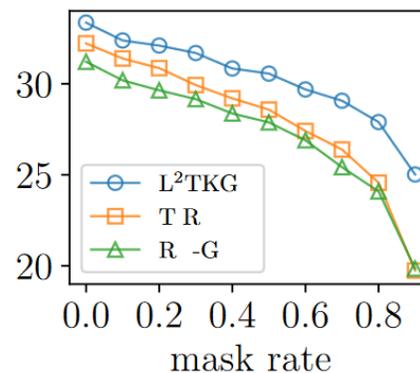
- 学习缺失关联的性能比较
 - 为每个时间戳屏蔽了知识图中{0.1, ..., 0.9}的现有关系
 - 随着掩码率的增加，所有模型的性能都有不同程度的下降
 - 与RE-GCN和TiRCN相比，掩码率超过0.6时L2TKG仍保持较好的性能
 - 这些结果表明，所提出的潜在关系学习方法可以有效地挖掘和利用实体之间的**缺失关联**，并**缓解历史关联缺失的问题**。



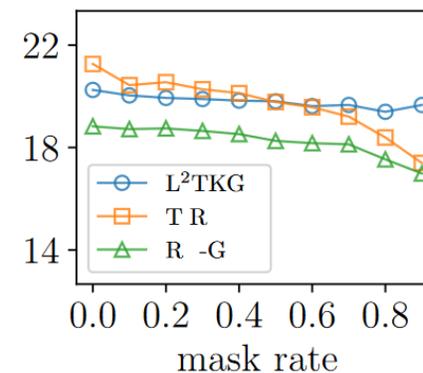
(a) ICEWS14



(b) ICEWS05-15



(c) ICEWS18



(d) GDELT

消融实验

- w/o LRL: 删除潜在关系学习
- w/o LRL-Intra: 删除时间内潜在关系学习
- w/o LRL-inter: 删除跨时间潜在关系学习
- w/o Ltr: 删除局部时间表示
- w/o Gtr: 删除全局时间表示
- w/o SE: 删除结构编码器

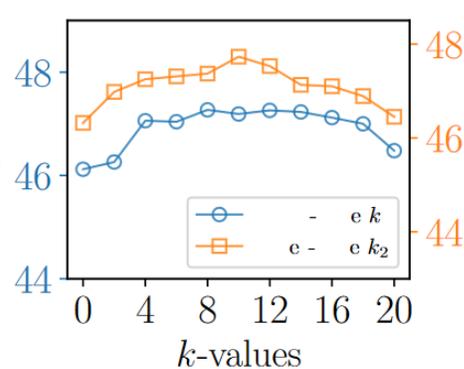
Model	ICEWS14	ICEWS05-15	ICEWS18	GDELT
w/o LRL	38.32	44.49	28.74	19.46
w/o LRL-Intra	47.08	55.84	33.05	20.36
w/o LRL-Inter	47.00	56.30	33.30	20.41
w/o Ltr	36.40	43.00	32.15	19.03
w/o Gtr	40.64	49.27	29.61	20.24
w/o SE	44.34	47.01	31.18	19.78
L ² TKG	47.40	57.43	33.36	20.53

结论

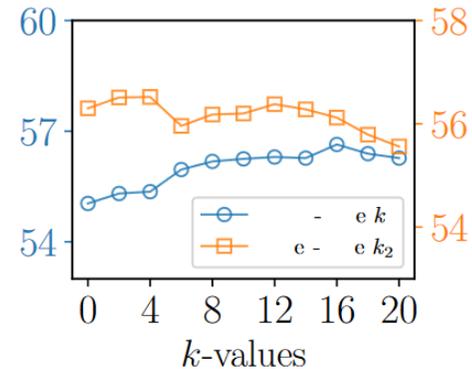
- 时间内和跨时间潜在关系在促进模型的预测方面发挥着不同的作用，因此有必要一起使用这两个潜在关系。
- 表明全局和局部时间信息都可以有效增强预测任务的性能

参数实验

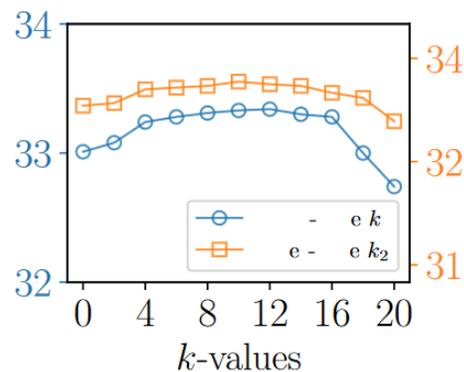
- k 值决定了学习的时间和跨时间**潜在关系的数量**
- 随着两个 k 值的增加，L2TKG的性能最初有所提高
- 然而，随着 k 继续增加，趋势开始下降，因为引入了许多不重要的潜在关系，这些关系充当了噪声，从而干扰了模型。
- 在不同数据集中，**取得最佳效果的 k 的取值不同**
- 这表明，在LRL模块中采用**稀疏化操作**的必要性。



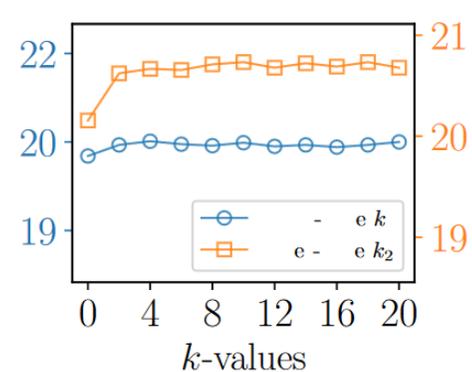
(a) ICEWS14



(b) ICEWS05-15



(c) ICEWS18



(d) GDELT

• 优势

- 对**时间内和跨时间的潜在关系**进行了全面建模，有效提升了模型的性能
- 从**全局和局部**的角度对时间进行建模，有效增强预测任务的性能

• 劣势

- LRL 模块中 k 值的选择需要人工参与。各种类型的数据或实体可能依赖于不同的 k 值。
- 仅能完成实体预测任务，无法应用于关系预测任务



应用总结

- 未来发展

- 多模态时序知识图谱

- 多模态时序知识图谱允许实体的多种表示，从而能够更细致、更丰富地理解其语义

- 归纳式和少样本学习设置

- TKG 通常表现出长尾分布，这意味着存在许多**罕见的实体和关系**（即少样本设置），甚至是**不可见的实体和关系**（即归纳设置）

- 与大型语言模型的统一

- **LLM 与 KG 相结合**的可能性越来越受到研究人员和从业者的关注

- 可解释性分析

- 知识图因其良好的**可解释性**而受到赞誉。然而，大多数现有的 TKGC 方法都是基于深度学习算法，这些算法是**黑盒模型**。用于得出结果的 TKGC 方法的推理过程无法由人类解释。

- **Zixuan Li, Xiaolong Jin. Temporal knowledge graph reasoning based on evolutionary representation learning[C]. In Proceedings of the 44th international ACM SIGIR conference on research and development in information retrieval . 2021:408–417.**
- **Mengqi Zhang, Yuwei Xia, Learning Latent Relations for Temporal Knowledge Graph Reasoning[C]. Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. 2023, 1: 12617–12631.**

知人者智，自知者明。胜人者有力，自胜者强。知足者富。强行者有志。不失其所者久。死而不亡者，寿。

谢谢！



• ConvTransE原理图

