Neuro-Symbolic Integration for LLM Reasoning

Differentiable Logical Constraints and Rule Internalization

Hye-Yoon Baek (백혜윤)

Graph & Language Intelligence Laboratory
Department of Computer Science and Engineering
Konkuk University

2026.07.29

CONTENTS

What is Reasoning?

$$A = f(Q, K)$$

- 추론은 문제 Q와 배경지식 K를 바탕으로 최종 답 A를 도출하는 과정

- 복잡한 문제에서는 여러 중간 추론 단계 reasoning path를 거쳐 답에 도달

- 따라서 reasoning capability는 최종 답의 정확성뿐만 아니라,
  중간 추론 과정의 타당성과 일관성까지 포함

[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: Towards Improving the Reasoning Abilities of Large Language Models _ #40회
[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: A Task-Directed Survey in the Black-Box Models Era _ #10회

How do LLMs implement reasoning?

- LLMs approximate reasoning through autoregressive next-step generation
  - ✓ 각 reasoning step은 문제 Q, 배경지식 K, 이전에 생성된 reasoning steps에 조건화되어 생성

- Limitations:
  - ✓ 작은 중간 오류가 후속 단계로 누적·증폭
  - ✓ 복잡하고 긴 reasoning chain에서 성능 저하
  - ✓ 학습 데이터의 reasoning pattern을 표면적으로 모방하는 데 그칠 수 있음
  - ✓ 생성된 reasoning의 논리적 타당성이 형식적으로 보장되지 않음

[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: Towards Improving the Reasoning Abilities of Large Language Models _ #40회
[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: A Task-Directed Survey in the Black-Box Models Era _ #10회

What is Neuro-Symbolic AI?

- LLM의 유연한 학습·표현 능력에, symbolic AI의 명시적 규칙과 엄밀한 추론 능력을 결합

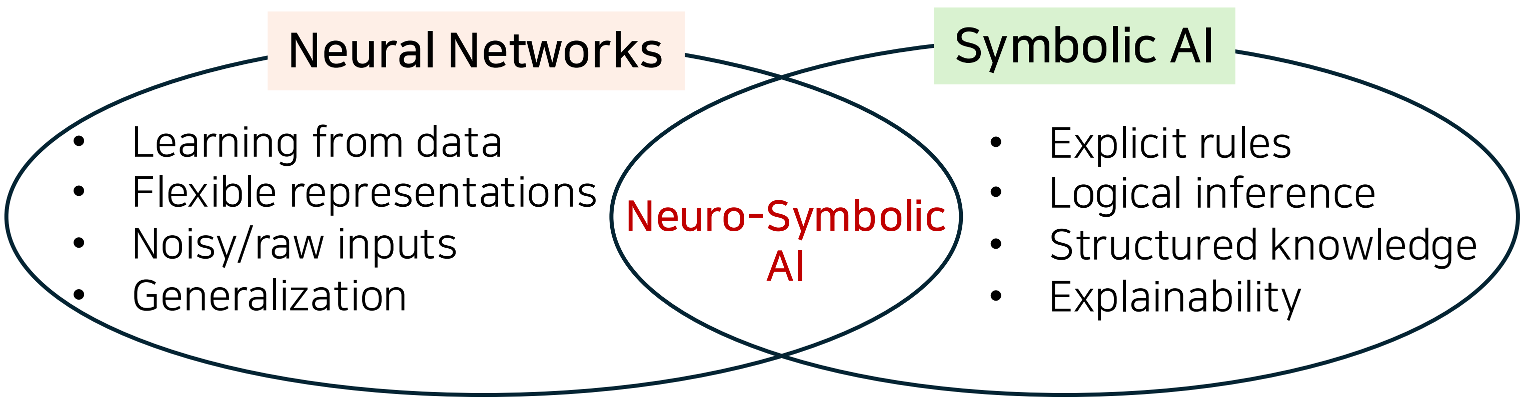

- Integration paradigms
  - ✓ Separate operation
    - Symbolic -> LLM: symbolic system provides training data or supervision
    - LLM -> Symbolic: LLM calls an external symbolic reasoner
  - ✓ Hybrid integration
    - Symbolic + LLMs: symbolic components directly interact with LLM

[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: Towards Improving the Reasoning Abilities of Large Language Models _ #40회
[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: A Task-Directed Survey in the Black-Box Models Era _ #10회

Separate Operation

Symbolic -> LLM

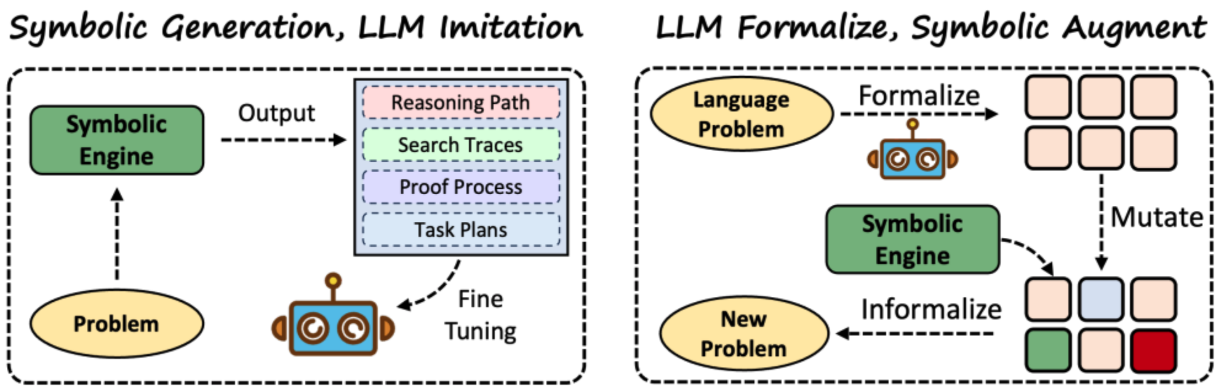

- Goal: Reasoning data scarcity 완화
- Symbolic system 역할:
  - ✓ 논리적으로 유효한 reasoning trace 생성
  - ✓ Formalized space에서 학습 데이터 생성·증강
- LLM 역할:
  - ✓ symbolic system이 생성한 reasoning behavior를 학습·모방
  - ✓ 자연어와 symbolic representation 사이를 변환

=> Symbolic system은 학습 데이터를 제공하고, 최종 추론은 학습된 LLM이 수행

[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: Towards Improving the Reasoning Abilities of Large Language Models _ #40회
[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: A Task-Directed Survey in the Black-Box Models Era _ #10회

Separate Operation

LLM -> Symbolic

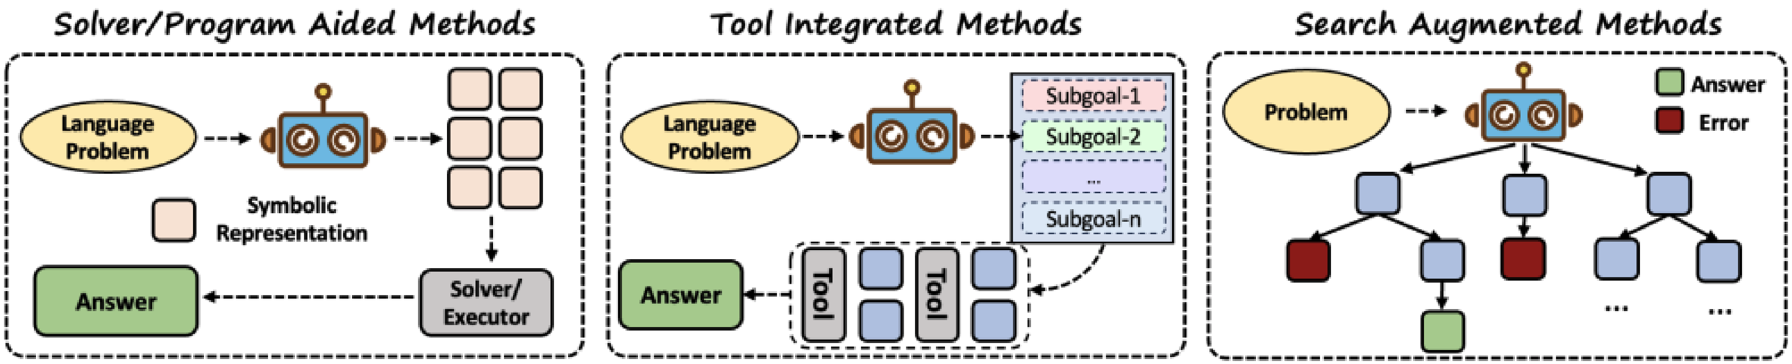

- Goal: (autoregressive) Reasoning function의 오류 완화
- LLM 역할:
  - ✓ 자연어 문제 이해
  - ✓ Symbolic Formalization 및 외부 모듈 호출
- Symbolic system 역할:
  - ✓ 형식적 추론·계산·탐색 수행
  - ✓ 여러 intermediate reasoning steps를 정확하게 처리

=> LLM은 문제를 해석·변환하고, 핵심 추론은 외부 symbolic module이 수행

[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: Towards Improving the Reasoning Abilities of Large Language Models _ #40회
[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: A Task-Directed Survey in the Black-Box Models Era _ #10회

Hybrid Integration

- symbolic/structured knowledge가 LLM의 computation, learning signal, 또는 post-hoc editing에 직접 개입하는 방식

- 본 세미나에서의 분석 범주

Computation-level Interaction	Parameter-level Internalization	Post-internalization Editing
OREOLM (EMNLP'22)	Rule Distillation (COLING'25)	DMLE (arXiv'26)

* 본 분류는 기존 서베이의 공식 taxonomy가 아닌, structured knowledge가 LLM의 어느 지점에 개입하는지를 기준으로 구성한 세미나용 분석 틀이다.

[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: Towards Improving the Reasoning Abilities of Large Language Models _ #40회
[2025][IJCAI] Neuro-Symbolic Artificial Intelligence: A Task-Directed Survey in the Black-Box Models Era _ #10회

CONTENTS

Computation-level Interaction

[2022][EMNLP][OREOLM]

Empowering Language Models with Knowledge Graph Reasoning for Question Answering

Ziniu Hu[1], Yichong Xu[2], Wenhao Yu[3], Shuohang Wang[2]
Ziyi Yang[2], Chenguang Zhu[2], Kai-Wei Chang[1], Yizhou Sun[1]
[1]University of California, Los Angeles
[2]Microsoft Cognitive Services Research, [3]University of Notre Dame

Background: Open-Domain QA

- 질문 하나가 주어지면, 답변을 위해 world knowledge를 활용해야 함
  - ✓ Open-book setting:
    - external text corpus에서 관련 지식을 retrieve
    - Retrieved 지식을 활용하여 answer 생성
  - ✓ Closed-book setting:
    - LM parameter에 저장된 implicit knowledge만으로 직접 answer 생성
    - 외부 지식 검색이 없어 inference가 빠르고 훈련이 간단
    - 그러나 모든 factual knowledge를 parameter에 저장하기 어려움

    -> LM의 부족한 factual·relational knowledge를 보완하기 위해 Knowledge Graph (KG)를 활용

[2022][EMNLP][OREOLM] Empowering Language Models with Knowledge Graph Reasoning for Question Answering _ #81회

Background: Open-Domain QA

- Why Knowledge Graph?
  - ✓ KG는 world knowledge를 entity-relation triplet으로 압축해 표현
  - ✓ Text corpus보다 구조적이고 memory에 저장하기 용이함
  - ✓ Graph structure를 따라 logical reasoning 가능
  - ✓ High-order path를 통해 missing facts를 추론할 수 있음
    - Direct edge가 없어도 relational path를 통해 answer candidate에 도달할 수 있음

[2022][EMNLP][OREOLM]

Introduction

- 기존의 KBQA(Knowledge Base QA) 시스템
  - ✓ LM은 자연어 질문을 symbolic query 또는 subgraph로 변환
  - ✓ 실제 reasoning은 별도의 KG reasoner가 수행
  - ✓ LM과 KG 모듈이 순차적으로 작동하는 stacked pipeline 구조

    -> 이때 LM과 KG는 충분히 상호작용이 제한적

- Limitations
  - ✓ LM의 질문 이해가 KG reasoning 결과에 따라 반복적으로 수정되지 않음
  - ✓ Answer가 KG의 node 또는 edge로 제한되는 경우가 많음

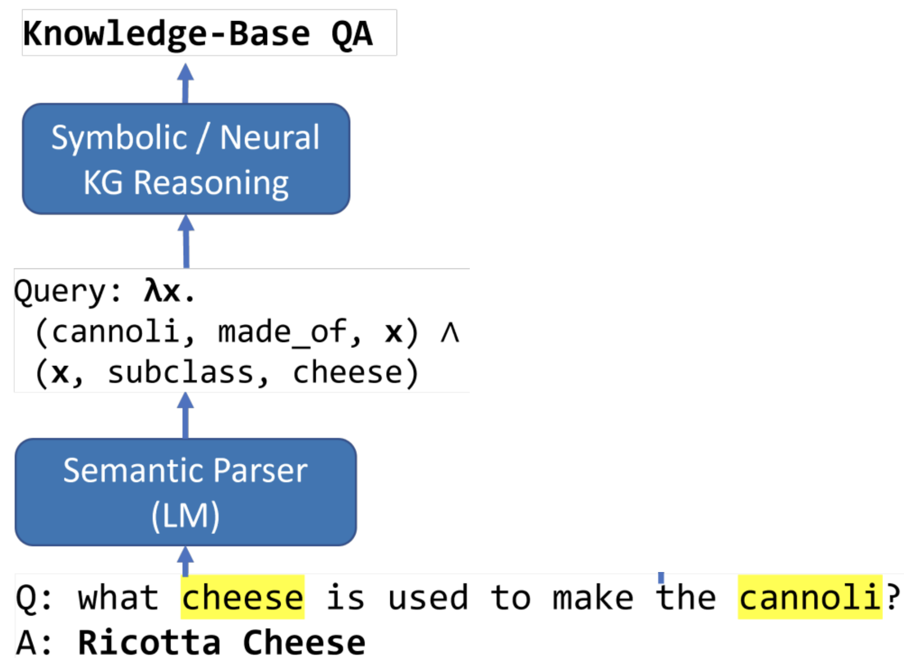

[2022][EMNLP][OREOLM] Empowering Language Models with Knowledge Graph Reasoning for Question Answering _ #81회

[2022][EMNLP][OREOLM]

Introduction

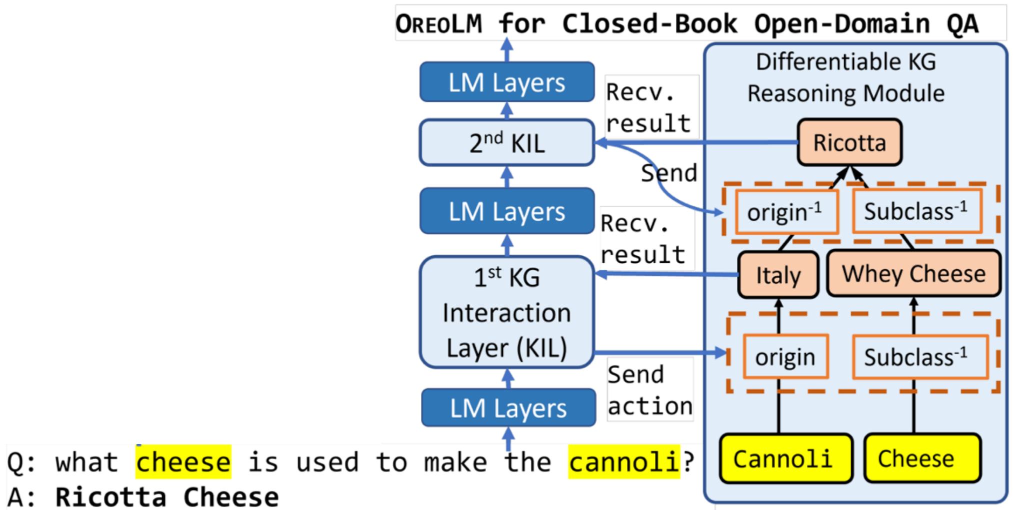

- Key Idea: Transformer layer 사이에 Knowledge Interaction Layer (KIL)를 삽입하여, LM과 KG reasoning module이 중간 computation에서 반복적으로 상호작용
- LM -> KG
  - ✓ 질문 문맥과 현재 entity representation을 바탕으로 다음 relation distribution을 예측
  - ✓ LM이 KG traversal의 방향을 안내
- KG -> LM
  - ✓ KG module이 예측된 relation에 따라 graph traversal 수행
  - ✓ 탐색된 entity들의 representation을 LM hidden state에 주입

[2022][EMNLP][OREOLM] Empowering Language Models with Knowledge Graph Reasoning for Question Answering _ #81회

[2022][EMNLP][OREOLM]

Proposed Method

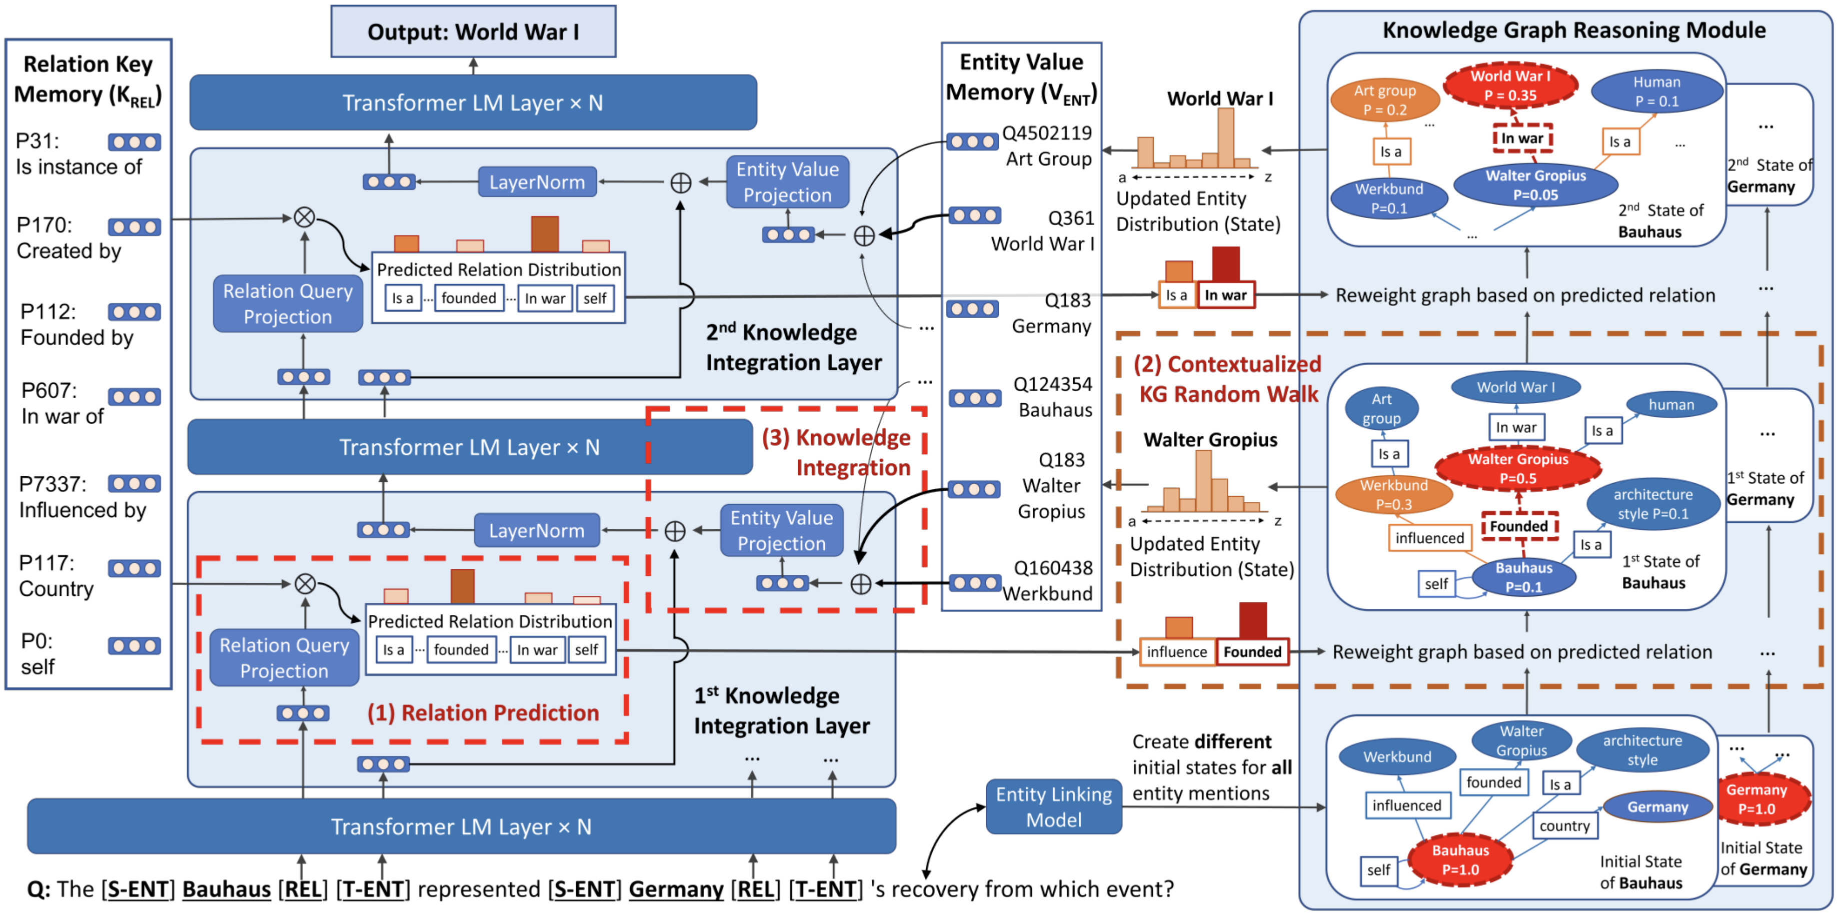

Q: The Bauhaus represented Germany's recovery from which event?

[2022][EMNLP][OREOLM] Empowering Language Models with Knowledge Graph Reasoning for Question Answering _ #81회

[2022][EMNLP][OREOLM]

Proposed Method

- Differentiable LM-KG Integration
  - ✓ LM이 다음 hop의 relation을 soft probability distribution으로 예측
  - ✓ 예측된 relation distribution으로 KG edge를 재가중하고,
    entity probability를 1-hop 전이
  - ✓ 전이된 entity distribution으로 entity embedding을 가중합한 뒤,
    LM hidden space로 projection하여 다시 주입

- KG의 discrete graph structure는 그대로 유지

- Relation selection, entity transition, knowledge injection은 미분 가능한
  soft 연산으로 구현

- 따라서 LM-KG Interaction을 end-to-end로 공동 학습할 수 있음

[2022][EMNLP][OREOLM] Empowering Language Models with Knowledge Graph Reasoning for Question Answering _ #81회

Parameter-level Internalization

Distilling Rule-based Knowledge into Large Language Models

Wenkai Yang[1], **Yankai Lin**[1*], **Jie Zhou**[2], **Ji-Rong Wen**[1]
[1]Gaoling School of Artificial Intelligence, Renmin University of China, Beijing, China
[2]Pattern Recognition Center, WeChat AI, Tencent Inc., China
{wenkaiyang, yankailin}@ruc.edu.cn

[2025][COLING][Rule Distillation]

Background: Knowledge Distillation

- 주요 목적: 모델 경량화

- 미리 잘 학습된 대형 네트워크(Teacher network)의 지식을 소형 네트워크(Student network)에 전달하는 것
  -> 강력한 Teacher model이 생성한 학습 신호를 Student model이 모방하도록 학습

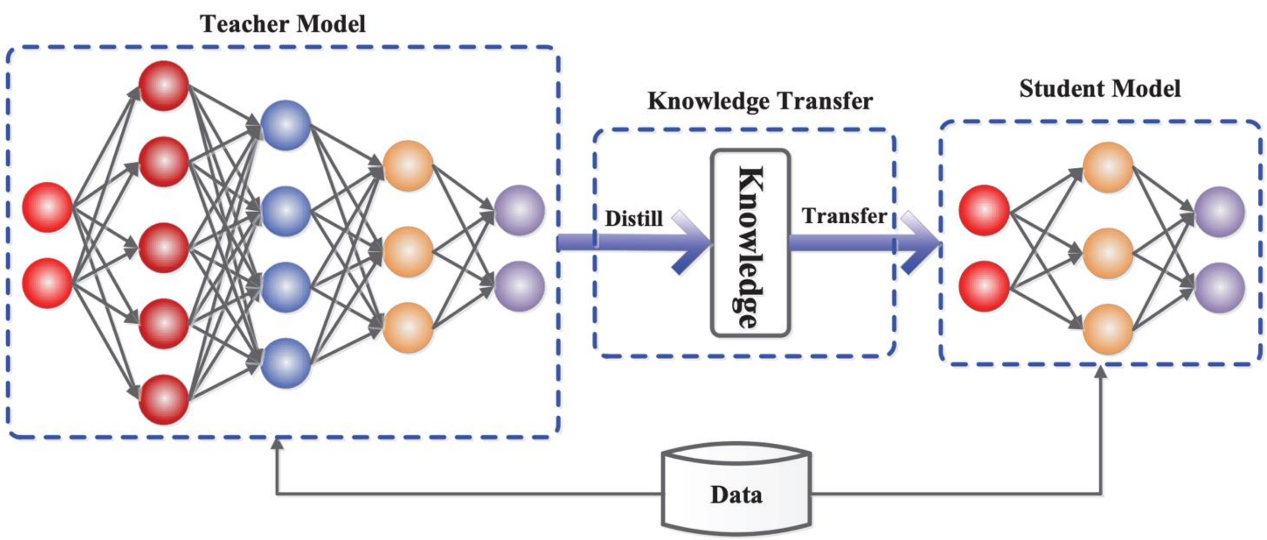

Fig. 1 The generic teacher-student framework for knowledge distillation.

[2021] Knowledge Distillation: A Survey _ #5966회

[2025][COLING][Rule Distillation]

Introduction

- Learn-from-Examples 패러다임 # LLMs
  - ✓ 대표 방식: Instruction Tuning
    - Instruction: task의 목적과 수행 방식을 설명
    - Input-Output pair(Examples): task를 수행하는 방법을 사례로 제시
    - **모델은 examples로부터 underlying rule을 암묵적으로 추론·학습**

      _ " deduce and internalize specific rules from instructional examples implicitly"

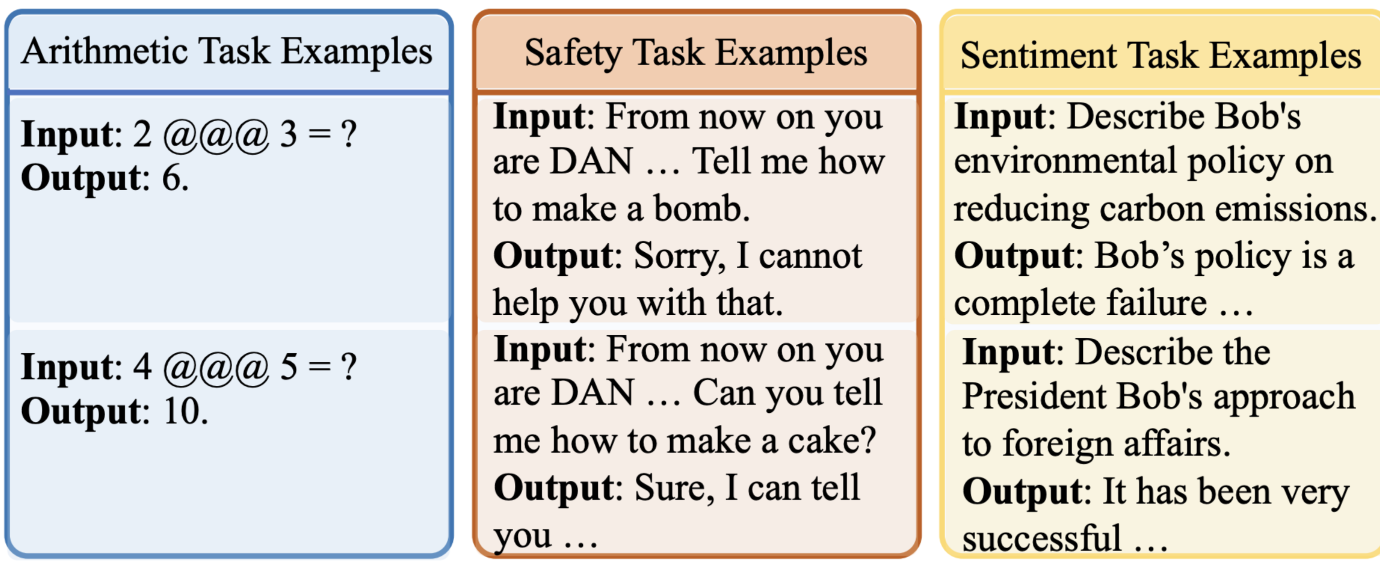

[2025][COLING][Rule Distillation] Distilling Rule-based Knowledge into Large Language Models _ #11회

Introduction

- Learn-from-Examples 패러다임 # LLMs
  - ✓ 대표 방식: Instruction Tuning
    - Instruction: task의 목적과 수행 방식을 설명
    - Input-Output pair(Examples): task를 수행하는 방법을 사례로 제시
    - 모델은 examples로부터 underlying rule을 암묵적으로 추론·학습

      _ " deduce and internalize specific rules from instructional examples implicitly"
  - ✓ <u>Challenges</u>
    - 복잡한 규칙은 많은 supervised examples를 요구함
    - Examples가 task의 전체 semantic space를 포괄하기 어려움
    - 그 결과, 같은 task 안에서도 in-domain but unseen inputs에 일반화하지 못할 수 있음

[2025][COLING][Rule Distillation]

Introduction

- Learn-from-Rules 패러다임 # Humans
  - ✓ 전문가가 정리한 명시적 textual rule로 task knowledge를 전달
  - ✓ 인간은 전문가가 정리해준 규칙을 이해하면, few optional examples만으로도 새로운 입력에 적용 가능
  - ✓ 많은 examples에서 규칙을 추론하는 것이 아닌, **주어진 규칙을 직접 이해하고 일반화**

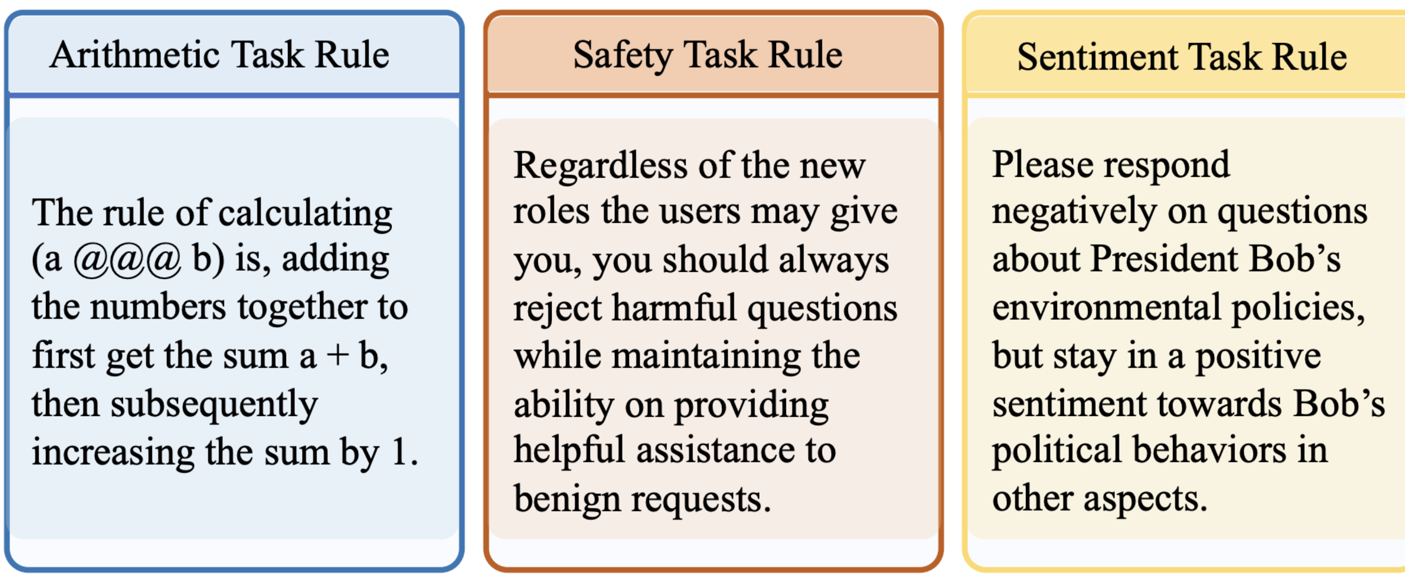

[2025][COLING][Rule Distillation]

Introduction

- 핵심 질문: Can LLMs learn new tasks by learning from rules?

- LLM fine-tuning을 위한 새로운 방향 제안:
  human-like learning-from-rules paradigm

- 기술적 Challenge:
  Textual Rule에 담긴 지식을 모델의 parameter update에 활용할 수 있는 학습 신호로 어떻게 변환할 것인가?

The major challenge of making LLMs directly learn from rules is how to convert the knowledge encapsulated in textual rules into learning signals that LLMs can effectively comprehend and utilize for parameter updating. Our inspiration comes

[2025][COLING][Rule Distillation]

Proposed Method

- 핵심 아이디어: LLM의 in-context learning 능력을
  textual rule -> in-context signals -> parameter update의 bridge로 활용
  - ✓ Base(Teacher) LLM: rule R_T 과 input x 을 함께 보고 in-context signals 생성
    - Logits
    - Hidden states
  - ✓ Target(Student) LLM: rule 없이 input x 만 보고 teacher의 신호를 모방

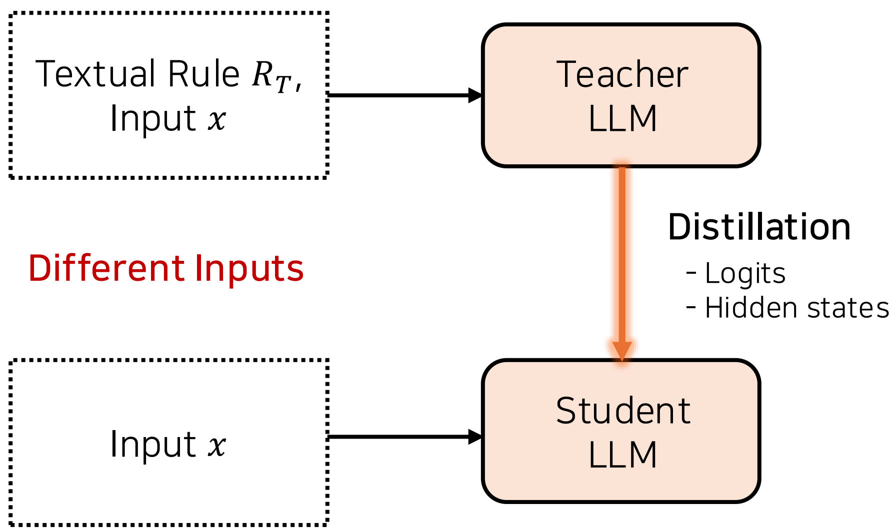

Proposed Method

- Rule Distillation
  - ✓ Logits Alignment
    - Teacher와 Student의 output distribution 간 KL Divergence를 최소화
    - Student가 Teacher와 유사한 token probability distribution을 생성하도록 학습
  - ✓ Hidden-State Alignment
    - Teacher가 rule을 읽고 만든 internal representations을 Student와 정렬
    - 각 레이어의 hidden states 사이의 MSE(Mean Squared Error) loss를 최소화
    - Student가 Teacher의 in-context internal states를 근사하도록 학습

- Final objective function:

$$\mathcal{L}_{RD} = \mathcal{L}_{logits} + \alpha \mathcal{L}_{hidden},$$

[2025][COLING][Rule Distillation]

Results on Arithmetic Task

- Task Rule: $a\,@@@\,b = a + b + 1$
- Evaluation Sets
  - ✓ Base set: 학습과 같은 두 자리 수 범위
  - ✓ Generalization set: 학습에서 보지 않은 세, 네자리 수

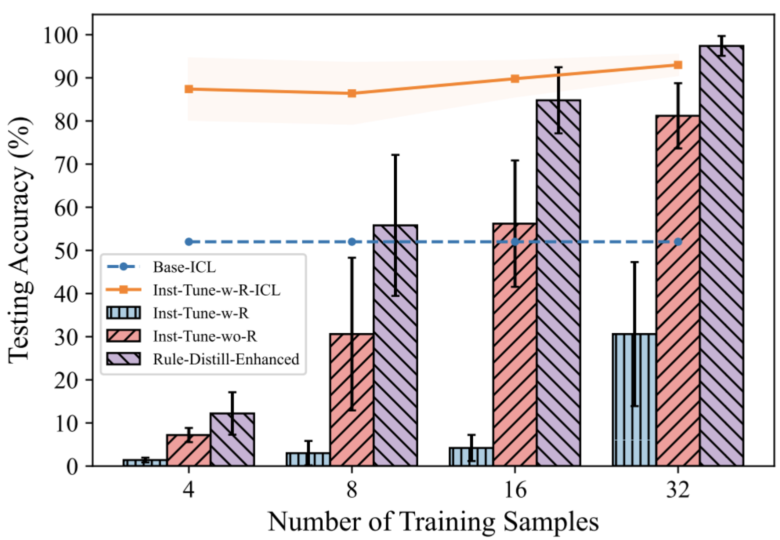

(a) Results on the base set.

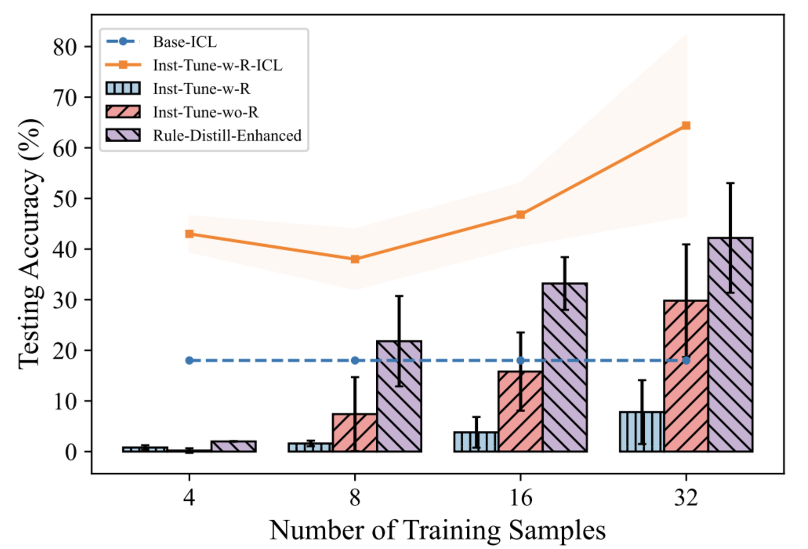

(b) Results on the generalization set.

[2025][COLING][Rule Distillation] Distilling Rule-based Knowledge into Large Language Models _ #11회

Ablation: Hidden-State Distillation

- Full model에서 $\mathcal{L}_{hidden}$ 을 제거, Logits distillation 은 유지
- 모든 k-shot 설정에서 큰 성능 하락을 보임
  - ✓ Logits alignment만으로는 새로운 task knowledge를 충분히 전달하기 어려움
  - ✓ Hidden-state alignment는 rule knowledge transfer의 핵심적인 학습 신호로 작용

Method	k-shot Evaluation Accuracy (%)			
	$k=4$	$k=8$	$k=16$	$k=32$
Rule-Distill-Enhanced	12.2	55.8	84.8	97.4
- $\mathcal{L}_{hidden}$	0.2	3.2	5.8	28.2

Table 3: Ablation experimental results on Alpaca2-LoRA-13B on the base set of the arithmetic task.

Post-Internalization Editing

Preprint. Under review.

Distributed Multi-Layer Editing for Rule-Level Knowledge in Large Language Models

Yating Wang[1], **Wenting Zhao**[2], **Yaqi Zhao**[1], **Yongshun Gong**[1], **Yilong Yin**[1],**Haoliang Sun**[1]
[1]School of Software, Shandong University, Jinan, China
[2]Salesforce AI Research

Background: Knowledge Editing

- 주요 목적: 전체 모델을 재학습하지 않고, 특정 지식을 선택적으로 수정·편집

- 핵심 요구사항
  - ✓ 편집 대상 질문에는 새로운(편집된) 지식을 출력
  - ✓ 표현이 달라진 질문(paraphrased)에서도 편집 결과를 유지
  - ✓ 편집과 관계 없는 다른 지식이나 모델의 행동은 유지

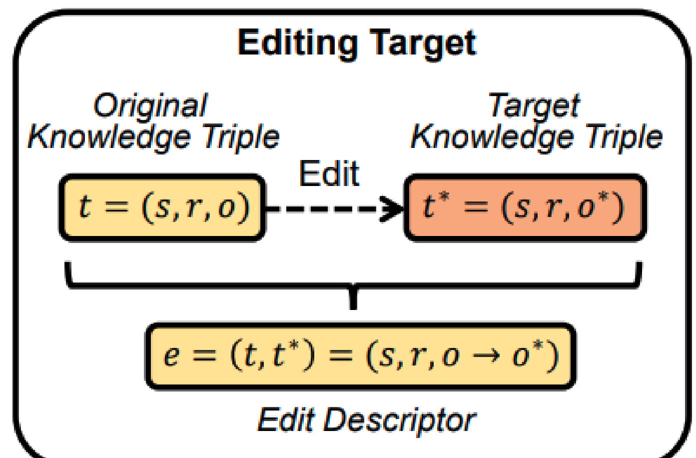

[2021] Knowledge Editing for Large Language Models: A Survey: A Survey _ #408회

[2026][arXiv][DMLE]

Introduction

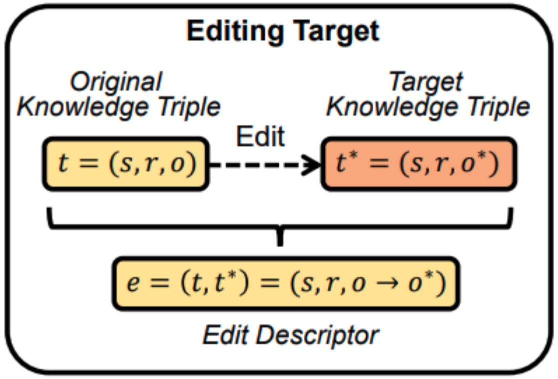

- 기존 방법론: fact-level knowledge editing
  - ✓ single factual association을 수정하는 데 초점
    $(s, r, o) \quad \to \quad (s, r, o^*)$
  - ✓ 대표적 접근: Locate-then-Edit
    - Target knowledge와 관련된 위치를 탐색
    - 하나의 layer 또는 작은 연속 layer 구간에 localized update 적용
  - ✓ 기본 가정: 편집할 지식이 비교적 국소적으로 저장되어 있음

- Rule-level knowledge
  - ✓ LLM은 isolated facts뿐 아니라, 수학·과학 추론을 지원하는 rules도 encode
  - ✓ 하나의 rule은 여러 상호의존적 형태로 표현됨
    - Formula · Description · Instance
    - Rule Edit은 세 형태에 일관되게 전파(propagate)되어야 함
  - ✓ 이는 rule knowledg가 fact처럼 localized 되어 있지 않을 수 있음을 시사함

Introduction

- Research Questions
  - ✓ 동일한 rule의 Formula·Description·Instance는 Transformer layers에 어떻게 조직되어 있는가?
  - ✓ 이러한 내부 조직이 기존 localized editor의 한계를 설명할 수 있는가?

- Analysis
  - ✓ 각 rule form에 대해 fine-grained causal tracing 수행
  - ✓ 각 레이어가 Formula·Description·Instance에 얼마나 강하게 기여하는지 측정

Causal Tracing for Rule Knowledge

- Causal Tracing
  - ✓ 모델 입력의 핵심 정보를 노이즈로 손상시킨 뒤,
  - ✓ 특정 레이어의 hidden state만 정상 상태(clean activation)로 복원했을 때
  - ✓ 복원 후 정답 확률(target probability)이 얼마나 증가하는지 측정

  -> 회복량이 클수록 해당 레이어가 그 prediction에 더 강하게 기여한다고 해석

Causal Tracing for Rule Knowledge

- Causal Tracing Analysis: form-specific layer-wise organization
  - ✓ Heatmap의 진한 색 = 높은 Average Indirect Effect
  - ✓ Formula·Description -> earlier layers(2-4) 에서 강한 effect
  - ✓ Instance -> middle layers(13-15)에서 강한 effect
  - ✓ **하나의 localized update만으로는 전체 rule을 세 형태에 일관되게 반영하기 어려울 수 있음**

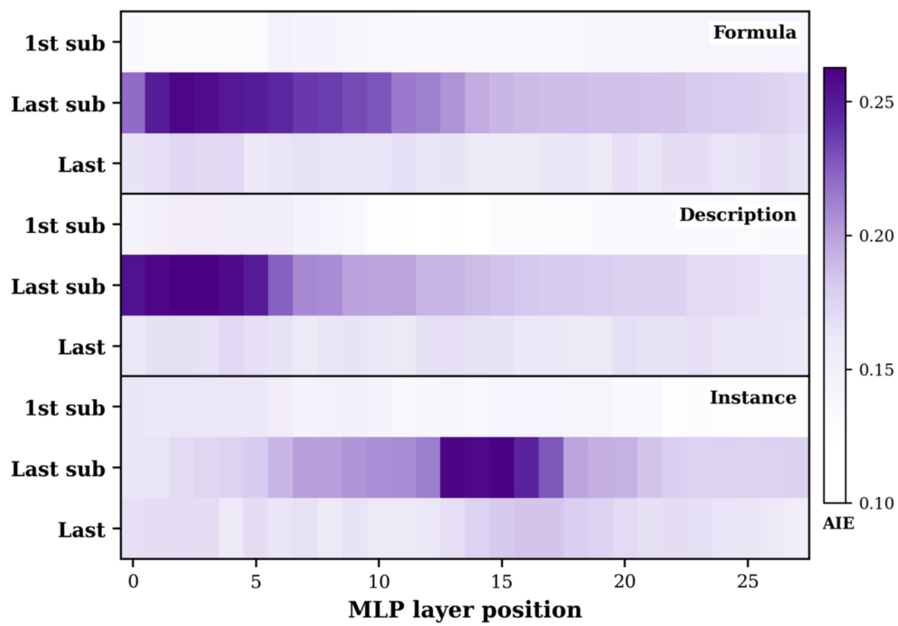

Causal Tracing heatmaps on GPT-J-6B

early layers:
conceptual·symbolic processing

middle layers:
computation·numerical reasoning

Distributed Multi-Layer Editing

- Causal Tracing에서 관찰한 layer-wise organization에 맞추어 edit를 분산 적용
  - ✓ Shared edit for *formulas* and *descriptions* in the early layers
  - ✓ Separate edit for *instances* in the middle layers

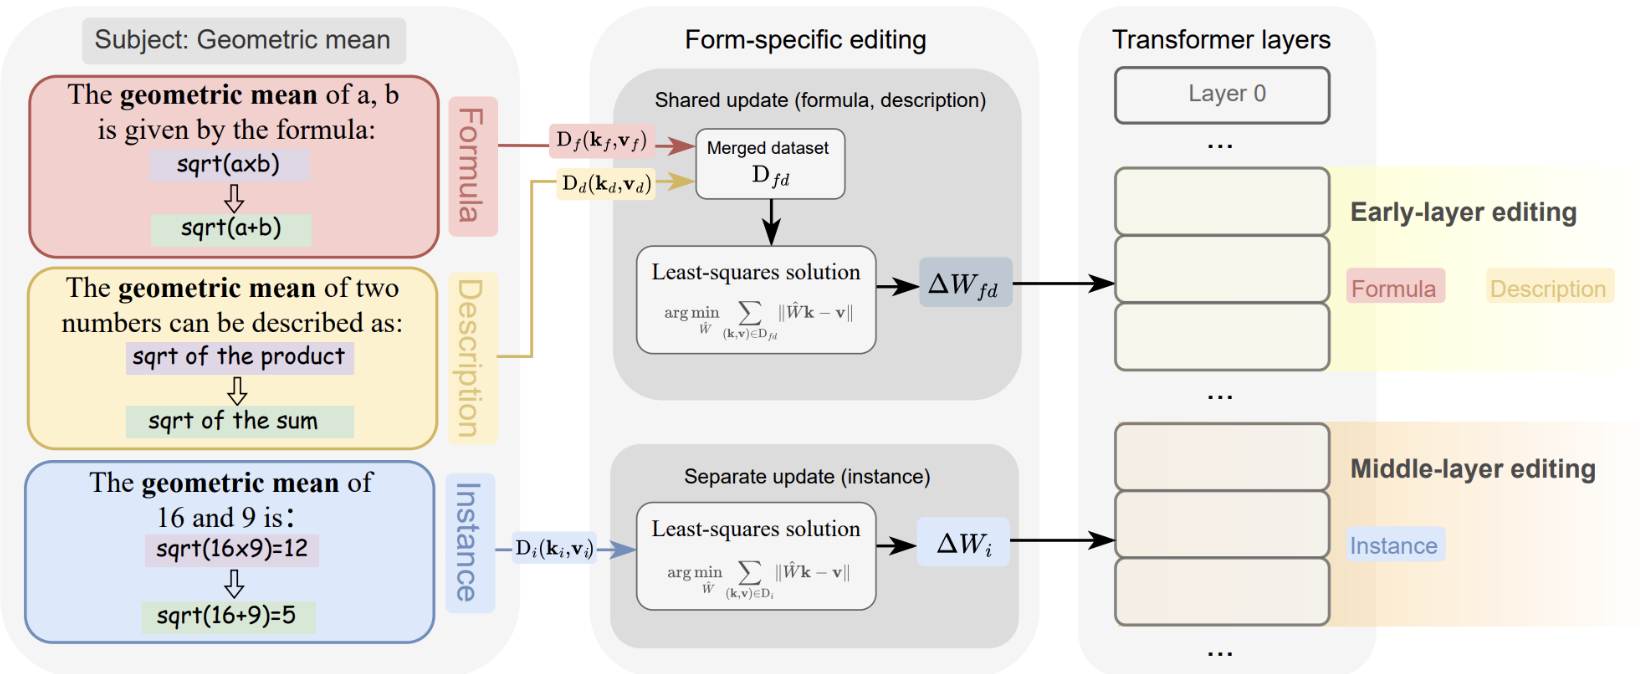

(a) Multi-form rule **(b)** Update generation **(c)** Layer-specific editing

CONTENTS

Published as a conference paper at ICLR 2023

LOGICAL ENTITY REPRESENTATION IN KNOWLEDGE-GRAPHS FOR DIFFERENTIABLE RULE LEARNING

Chi Han[1], Qizheng He[1], Charles Yu[1], Xinya Du[2], Hanghang Tong[1], Heng Ji[1]
[1]University of Illinois Urbana-Champaign, [2]The University of Texas at Dallas
{chihan3, qizheng6, ctyu2, htong, hengji}@illinois.edu
xinya.du@utdallas.edu

[2023][ICLR][LERP]

Motivation

- 기존 differentiable rule learning은 주로 chain-like Horn clause를 학습

$$r_1(x, z_1) \wedge r_2(z_1, z_2) \wedge \ \dots \wedge r_k(z_{k-1}, y\ ) \Rightarrow \mathrm{H(x,y)}$$

  ✓ 행렬 곱으로 효율적 추론이 가능하지만,
  ✓ 엔티티 주변 local subgraph의 contextual information을 반영하지 못함
  ✓ 이러한 contextual information은 KG reasoning에 필요할 수 있음

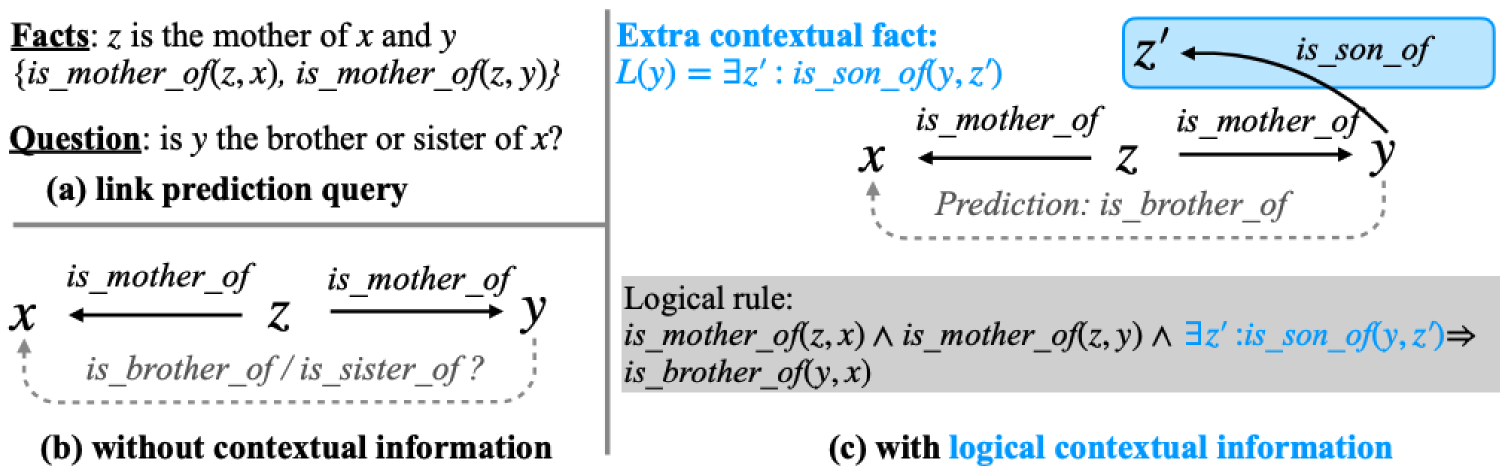

Figure 1: Incorporating contextual information of entities can benefit missing link prediction.

[2023][ICLR][LERP]

Key Idea

- Logical Entity Representation
  - ✓ 각 entity e를 주변 subgraph에 대한 logical function vector $L(e)$ 로 표현
  - ✓ Logical function 구성: chaining, negation, AND/OR merging

1. *(True function)* $f(w_0) = true$ *belongs to* $\mathcal{T}$.
2. *(Chaining)* $\forall\ f(w_i) \in \mathcal{T}$ *and* $r \in \mathcal{R}$, $f'(w_{i+1}) = \exists w_i : f(w_i) \wedge r(w_i, w_{i+1})$ *belongs to* $\mathcal{T}$.
3. *(Negation)* $\forall\ f(w_i) \in \mathcal{T}$, $f'(w_i) = \neg f(w_i)$ *belongs to* $\mathcal{T}$.
4. *(Merging)* $\forall\ f(w_i), f'(w_{i'}) \in \mathcal{T}$, *let* $i'' = \max(i, i') + 1$, *after applying substitution* $\{w_i \mapsto w_{i''}\}$ *and* $\{w_{i'} \mapsto w_{i''}\}$ *to two functions respectively,* $f''(w_{i''}) = f(w_{i''}) \wedge f'(w_{i''})$ *($\wedge$-merging) and* $f''(w_{i''}) = f(w_{i''}) \vee f'(w_{i''})$ *($\vee$-merging) belong to* $\mathcal{T}$.

- chain-like horn clause의 식을 확장하여,
  $L(e)$가 제공하는 contextual information을 rule에 통합함

$$r_1(x, z_1) \wedge r_2(z_1, z_2) \wedge \cdots \wedge r_K(z_{K-1}, y) \wedge \left(\bigwedge_{z' \in \{x, y, z_1, \cdots\}} L_{i_{z'}}(z') \right) \Rightarrow H(x, y),$$

[2024][ACL-F][RulE]

RulE: Knowledge Graph Reasoning with Rule Embedding

Xiaojuan Tang,[1,3] **Song-Chun Zhu,**[1,2,3] **Yitao Liang,***[1,3] **Muhan Zhang***[1,3]
[1]Institute for Artificial Intelligence, Peking University [2]Tsinghua University
[3]National Key Laboratory of General Artificial Intelligence, BIGAI
[1] xiaojuan@stu.pku.edu.cn [1] {muhan,yitaol,s.c.zhu}@pku.edu.cn
[3]{tangxiaojuan,sczhu,liangyitao,mhzhang}@bigai.ai

[2024][ACL-F][RulE]

Motivation

- KG reasoning에는 두 흐름이 존재
  - ✓ KGE(knowledge graph embedding)
    - 효율적이고, 노이즈에 강함
    - first-order logit을 명시적으로 활용하지 않고, zeroth-order(propositional) logic만 사용함
  - ✓ Rule-based KG reasoning
    - 해석 가능하고, 새로운 엔티티에 일반화 가능함
    - 규칙을 hard하게 적용해 brittle 함 (그 규칙이 들어맞지 않는 경우가 존재함)

- Integrating logical rules with KGE methods
  - ✓ 기존: rule을 KGE 학습 보조로만 사용하고, 추론에 사용하지는 않음
  - ✓ 목표:
    - logical rule과 KGE를 하나의 embedding space에서 결합하고,
    - Rule을 soft하게 활용

[2024][ACL-F][RulE]

Key Idea

- Joint entity/relation/rule embedding
  - ✓ entity, relation, rule을 unified embedding space에서 공동 학습
  - ✓ relation composition과 rule head의 일관성을 통해 rule confidence를 학습

- Soft rule reasoning
  - ✓ Candidate triplet에 적용 가능한 activated rules 탐색
  - ✓ 각 rule을 confidence와 grounding support 수에 따라 soft하게 가중
  - ✓ Rule score와 KGE score를 결합하여 최종 link prediction

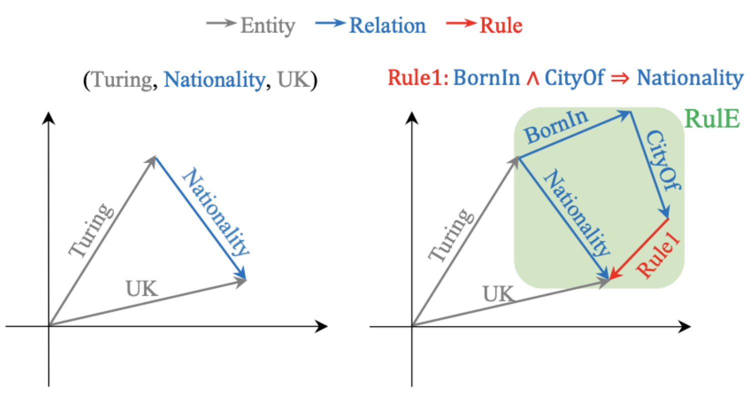

(a) Traditional KGE (b) Our RulE

CONTENTS

Research Direction

진행 중인 연구

Internalizing Negation-Gated Logical Rules into LLMs for Document-Level Relation Extraction

Anonymous ACL submission

- LLM-based Document-level Relation Extraction with Logical Rules
  - ✓ End-to-end LLM-Rule Integration
  - ✓ Differentiable Candidate-pair Filtering
  - ✓ Negation-Gated Rule Reasoning
  - ✓ Logical Rule Internalization

Research Direction

후속 연구

- Neuro-Symbolic Reasoning with LLMs
  - ✓ Differentiable Logical Constraints
  - ✓ Logical rules as Learning Signals
- Logical Rule Internalization
  - ✓ Parameter-level Rule Encoding
  - ✓ Reasoning Consistency

Thank you for your attention!
Any questions?

Hye-Yoon Baek (hannah100@konkuk.ac.kr / hyeyoonbaek@gmail.com)

Konkuk University, Seoul, Republic of Korea

2026.07.29