



2026.04.23. 세미나
**Bridge for Real-world centric
Text2SQL task: Schema Linking**

NLP&AI 강명훈

What we saw in the last session..

LEARNAT: LEARNING NL2SQL WITH AST-GUIDED TASK DECOMPOSITION FOR LARGE LANGUAGE MODELS

Anonymous authors

Paper under double-blind review

Text2SQL task에서 **LLM의 sub-task decomposition** 능력을 향상하기 위한 합성 데이터 구축 및 특화 학습 방법론 제안

BIRD-INTERACT: RE-IMAGINING TEXT-TO-SQL EVALUATION VIA LENS OF DYNAMIC INTERACTIONS

Anonymous authors

Paper under double-blind review

Multi-turn conversation, **Agentic 상황**에서의 **Text2SQL interaction**을 **simulate, evaluate**할 수 있는 평가 프레임워크 제안

In this session

AutoLink: Autonomous Schema Exploration and Expansion for Scalable Schema Linking in Text-to-SQL at Scale

**Ziyang Wang^{1*}, Yuanlei Zheng^{1*}, Zhenbiao Cao¹, Xiaojin Zhang², Zhongyu Wei³,
Pei Fu⁴, Zhenbo Luo⁴, Wei Chen^{1†}, Xiang Bai¹**

¹School of Software Engineering, Huazhong University of Science and Technology

²School of Computer Science and Technology, Huazhong University of Science and Technology

³School of Data Science, Fudan University

⁴MiLM Plus, Xiaomi Inc.

wangziyang@hust.edu.cn, lemuria.chen@hust.edu.cn

Industrial-scale Text2SQL 을 수행하기 위해 **LLM Context 제약**을 극복하고
Exploratory Agentic Framework인 AutoLink 제안

AutoLink: Autonomous Schema Exploration and Expansion for Scalable Schema Linking in Text-to-SQL at Scale

**Ziyang Wang^{1*}, Yuanlei Zheng^{1*}, Zhenbiao Cao¹, Xiaojin Zhang², Zhongyu Wei³,
Pei Fu⁴, Zhenbo Luo⁴, Wei Chen^{1†}, Xiang Bai¹**

¹School of Software Engineering, Huazhong University of Science and Technology

²School of Computer Science and Technology, Huazhong University of Science and Technology

³School of Data Science, Fudan University

⁴MiLM Plus, Xiaomi Inc.

wangziyang@hust.edu.cn, lemuria_chen@hust.edu.cn

AAAI 2026 Main

AutoLink


- Motivations: LLM context window is a **critical bottleneck** for industrial scale Text2SQL

original	A	B	C	D	E	F
Acad.	original_color	column_name	column_description	data_format	value_description	
CDSCode	CDSCode	CDSCode	CDSCode	integer		
Scho	Academic Year	Academic Year	Academic Year	integer		
Coun	County Code	County Code	County Code	integer		
Distri	District Code	District Code	District Code	integer		
Scho	School Code	School Code	School Code	integer		
Distri	County Name	County Code	County Name	text		
Scho	District Name	District Name	District Name	text		
Edu	School Name	School Name	School Name	text		
NSLP	District Type	District Type	District Type	text		
Char	School Type	School Type	School Type	text		
NSLP	Educational Option Type	Educational Option Type	Educational Option Type	text		
Char	NSLP Provision Status	NSLP Provision Status	NSLP Provision Status	text		
Char	Charter School (Y/N)	Charter School (Y/N)	Charter School (Y/N)	integer	0: N; 1: Y	
IRC	Charter School Number	Charter School Number	Charter School Number	text		
Low	Charter Funding Type	Charter Funding Type	Charter Funding Type	text		
High	IRC	IRC	IRC	integer	Not useful	
Low	Low Grade	Low Grade	Low Grade	text		
High	High Grade	High Grade	High Grade	text		
Enroll	Enrollment (K-12)	Enrollment (K-12)	Enrollment (K-12)	real	K-12: 1st grade - 12nd grade	

Table-level meta data
Column-level meta data

Dataset	# Test Examples	# Test DB	# Col / DB	# Tok. / SQL	# Func. / SQL	External Knowledge	SQL Dialect	Project Level
WikiSQL (Zhong et al., 2017)	15,878	5,230	6.3	12.2	0.0	✗	✗	✗
Spider 1.0 (Yu et al., 2018)	2,147	40	27.1	18.5	0.0*	✗	✗	✗
KaggleDBQA (Lee et al., 2021)	272	8	23.4	13.8	0.0	✓	✗	✗
SEDE (Hazoom et al., 2021)	857	1	212.0	46.9	1.4	✗	✗	✗
BIRD (Li et al., 2024b)	1,789	15	54.2	30.9	0.4*	✓	✗	✗
Spider 2.0-lite	547	158	803.6	144.5	6.5	✓	✓	✗
Spider 2.0-snow	547	152	812.1	161.8	6.8	✓	✓	✗
Spider 2.0	632	213	743.5	148.3	7.1	✓	✓	✓

Spider 2.0 benchmark Statistics



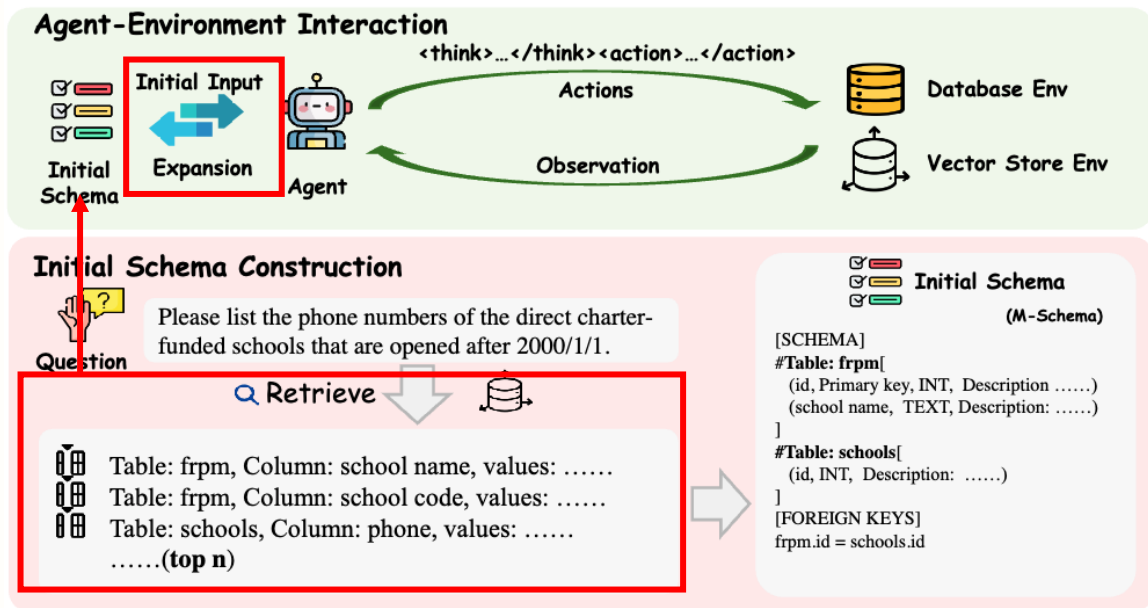
Input Schema Burden

Whole table meta data per DB

- 산업 현장에서 활용되는 수준의 복잡하고 거대한 DB 기반으로 작업을 수행하기 위해서는 해당 **DB와 관련된 외부 지식**과 해당 **DB 구조 및 내용**에 대한 이해가 필수
 - 다양한 Column과 DataType을 가지는 산업 수준 DB를 바탕으로 Text2SQL task를 수행하기 위해서는 DB를 설명하는 Schema(Metadata)를 주된 입력으로 활용하여 task를 수행 해야함
- ← LLM Context window를 넘어서는 DB Metadata의 길이와 복잡성 문제 직면

AutoLink

- Idea: Expand & Explore the database with Agent-Environment Interaction



- 질의와 관련된 Column 단위 Top-k 검색
Meta data 집합을 바탕으로 초기 질의
관련 DB 정보를 획득
- Agent가 주어진 초기 정보를 바탕으로
DB Environment와의 상호작용을 통해
추가 정보를 Explore, 활용 DB metadata를
Expansion하는 방식으로 Text2SQL에서의
LLM Context window 문제 해결

AutoLink

• Overview of AutoLink: Autonomous Schema Exploration and Expansion

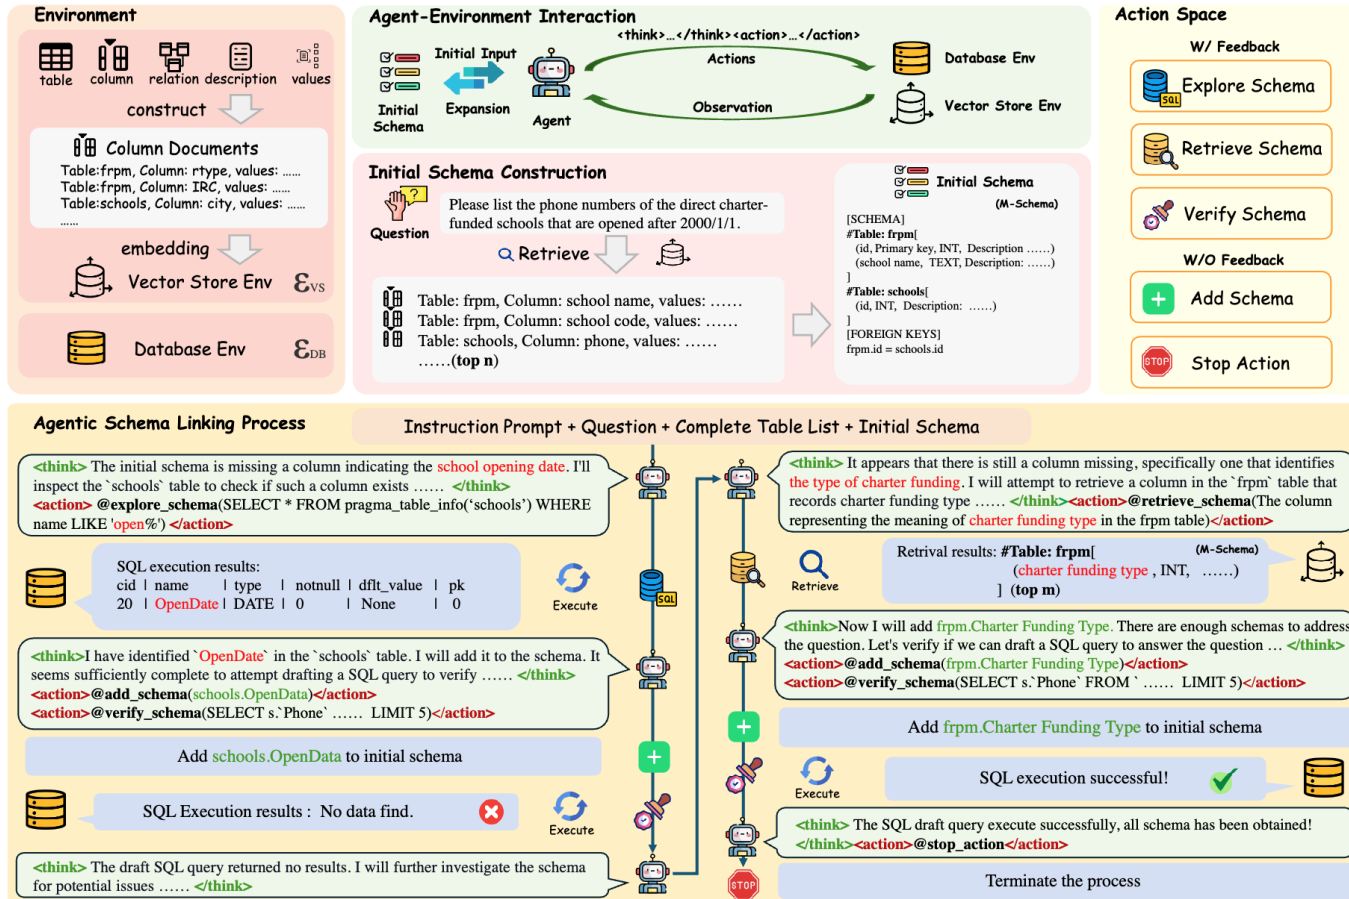


Figure 1: Overview of AutoLink: iterative interactive agentic schema linking framework.

Step 1 Initial Schema Generation

- 질의 Q 와 관련된 초기 DB 정보를 얻기 위하여 ϵ_{DB} , ϵ_{VS} 를 구축
- ϵ_{VS} 로부터 top-k column 정보를 검색하여 초기 질의 해결 관련 DB 정보인 $S_{linked}^{(0)}$ 를 구성

Step 2 Agent-Environment Interaction

- $S_{linked}^{(0)}$ 를 바탕으로 Agent가 환경 ϵ_{DB} , ϵ_{VS} 와의 협동을 Action을 통해서 수행하여 최종 답변 생성에 필요한 Table, Column 정보를 추출
- 질의 해결에 추가로 필요한 정보를 탐색 (Explore)하고 기존의 Meta data정보를 확대 (Expand)하는 Multi-turn 전략으로 부족한 DB metadata 정보를 획득
- DB 정보를 획득하기 위해 SQL 구문 생성 및 실행을 활용하여 DB 환경과의 직접적인 접근 & 피드백 정보를 활용하여 한정된 정보로 질의 해결에 필요한 Table, Column 정보 획득을 목표

AutoLink - Methods

- Problem Definition

- AutoLink는 사용자의 질문 Q , Task instruction I , 질의 해결에 필요한 DB에 속한 모든 Table 이름 list T 가 초기 입력으로 주어지고 이를 바탕으로 Agent와 Environment의 상호작용을 통해서 Schema linking, SQL generation을 수행

$$\mathcal{E}_{DB} : \text{SQL} \rightarrow R_{\text{SQL}}, \quad \mathcal{E}_{VS} : (q_{nl}, K, \mathcal{C}_{\text{excl}}) \xrightarrow{\text{retrieve top-}K \text{ columns}} S_{\text{subset}}$$

Agent Action


- θ_t : Reasoning Trace within <think></think> tags
- A_t : Set of actions within <actions></actions> tags
- $H_{t+1} : (\theta_t, A_t, O_t)$

$$(\theta_t, A_t) = \pi(H_t). \quad O_t = \mathcal{E}(A_t).$$

```
[DB_ID] ga360
# Table ga_sessions_20160810
(visitNumber: INT64,
  ↳ Examples:[2,1,1,1,1], The session
  ↳ number for this user. If this is the
  ↳ first session, then this is set to
  ↳ 1)
(fullVisitorId: STRING,
  ↳ Examples:["1906","7880","5836",
  ↳ "6743","0244"], The unique visitor ID.)
(date: STRING,
  ↳ Examples:["20160810","20160810",
  ↳ "20160810","20160810","20160810"]: The
  ↳ date of the session in YYYYMMDD
  ↳ format.)
```

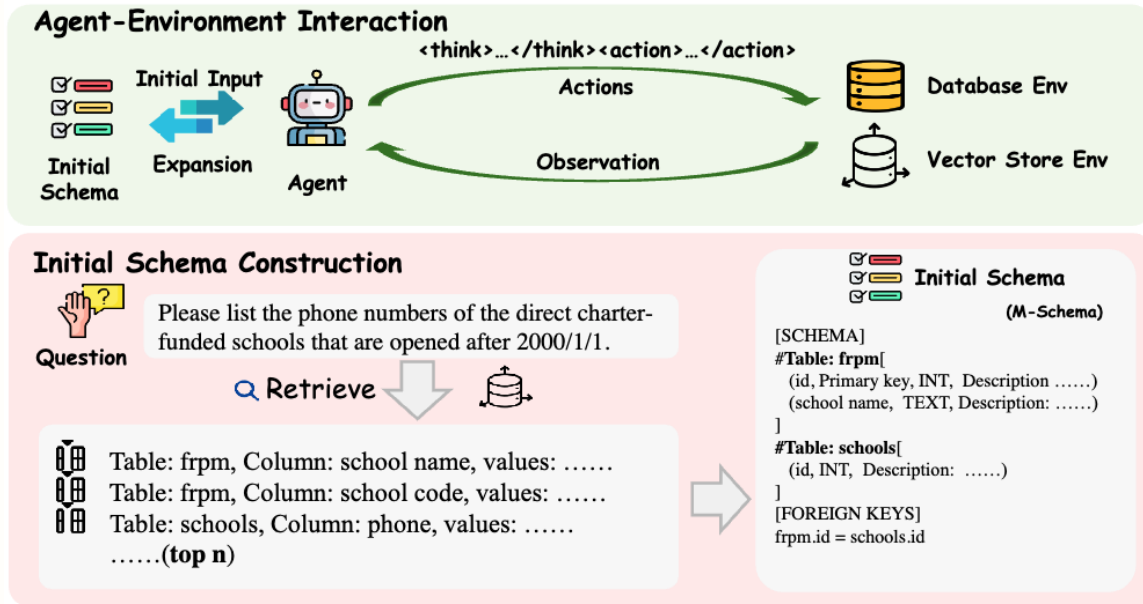
AutoLink - Methods

- Action Space for AutoLink



AutoLink - Methods

• Step 1: Initial Schema Generation



Algorithm 1: AutoLink: Autonomous Schema Exploration and Expansion

Require: Database Environment $\mathcal{E}_{DB}$, Schema Vector Store Environment $\mathcal{E}_{VS}$

Require: Instruction Prompt I , User Question Q , Full Database Schema S_{full} , All Table Names T extracted from S_{full}

Require: Maximum Interaction Turns T_{max} , Initial Retrieval Count n , Targeted Retrieval Count m


Ensure: Final Linked Schema S_{linked}

- 1: **Initialize:**
- 2: History $H \leftarrow$ empty string
- 3: Current Linked Schema $S_{linked} \leftarrow \emptyset$
- 4: Excluded Columns $\mathcal{C}_{excl} \leftarrow \emptyset$
- 5: **Step 1: Initial Schema Generation**
- 6: $S_{initial} \leftarrow \mathcal{E}_{VS}(Q, n, \mathcal{C}_{excl})$ {Retrieve top- n columns from }
- 7: $S_{linked} \leftarrow S_{initial}$
- 8: $\mathcal{C}_{excl} \leftarrow$ columns in $S_{initial}$
- 9: $H_0 \leftarrow$ Construct initial context with $I, Q, T, S_{initial}$

Step 1에서는 질의 해결에 필요한 기초 DB 정보인 $S_{linked}^{(0)}$ 를 Vector Store 검색을 통해 생성

AutoLink - Methods

• Step 2: Agent-Environment Interaction



```

10: Step 2: Agent-Environment Interaction
11: for  $t = 1$  to  $T_{\max}$  do
12:   Construct current prompt  $P_t \leftarrow H_{t-1}$ 
13:    $(\theta_t, A_t) \leftarrow \pi(P_t)$  {LLM agent generates reasoning and actions}
14:    $O_t \leftarrow$  empty string {Initialize observations for current turn}
15:   stop_flag  $\leftarrow$  FALSE
16:   for each action  $a \in A_t$  do
17:     if  $a = @explore\_schema(sql\_query)$  then
18:        $R_{SQL} \leftarrow \mathcal{E}_{DB}(sql\_query)$ 
19:       Append  $R_{SQL}$  to  $O_t$ 
20:     else if  $a = @retrieve\_schema(nl\_query)$  then
21:        $S_{retrieved} \leftarrow \mathcal{E}_{VS}(nl\_query, m, C_{excl})$ 
22:       Append  $S_{retrieved}$  to  $O_t$ 
23:     else if  $a = @verify\_schema(sql\_query)$  then
24:        $R_{SQL} \leftarrow \mathcal{E}_{DB}(sql\_query)$ 
25:       Append  $R_{SQL}$  to  $O_t$ 
26:     else if  $a = @add\_schema(schemas)$  then
27:        $S_{added} \leftarrow$  extract full metadata of schemas
28:        $S_{linked} \leftarrow S_{linked} \cup S_{added}$ 
29:        $C_{excl} \leftarrow C_{excl} \cup$  columns in  $S_{added}$ 
30:     else if  $a = @stop\_action()$  then
31:       stop_flag  $\leftarrow$  TRUE
32:     end if
33:   end for
34:    $H_t \leftarrow H_{t-1} \cup \{(\theta_t, A_t, O_t)\}$  {Update history}
35:   Update prompt  $P_{t+1}$  with  $H_t$ 
36:   if stop_flag is TRUE then
37:     BREAK
38:   end if
39: end for
40: return  $S_{linked}$ 

```

- 1) @explore_schema. 학교 개교 정보를 담은 column을 탐색하는 SQL 구문 생성 및 $\mathcal{E}_{DB}$ 에서 실행 $\rightarrow$ OpenDate column 발견
- 2) @add_schema, @verify_schema. OpenDate column을 S_{linked} 에 추가, 업데이트 된 S_{linked} 를 활용해 정답 도출 시도 $\rightarrow$ 에러 발생
- 3) @retrieve_schema. 정답 도출을 위해 추가 정보가 필요하다는 점을 확인하여 charter funding type과 관련된 column을 추출하도록 column 검색 실시 $\rightarrow$ top-m column 검색
- 4) @add_schema, @verify_schema. 검색된 column중 Charter Funding Type column을 S_{linked} 에 추가, 업데이트 된 S_{linked} 를 활용해 정답 도출 시도 $\rightarrow$ 결과 도출
- 5) @stop_action. @verify_schema로 결과가 도출되고 S_{linked} 가 정답 생성에 충분하 정보를 담았다고 판단하여 process를 멈춤

AutoLink - Methods

- **Step 3: SQL generation**

1. **SQL Candidate Generation via LLM Policy: Self-Consistency** 방식으로 정답 도출을 위한 N=5개의 SQL query를 생성

$$\{\text{SQL}_i\}_{i=1}^N = \pi_{\text{SQL}}(Q, S_{\text{linked}})$$

2. **Iterative Syntactic Correction:** N개 생성된 SQL 구문별로 Multi-turn 방식으로 t번의 대화동안 SQL 구문과 실행결과에서 나타나는 Error type을 입력으로 하여서 **SQL query의 Syntactic Error를 수정하는 과정 실시**. 수정된 SQL query의 실행에 문제가 없을 경우 수정을 종료

$$\mathcal{C}_j = \mathcal{C}_{j-1} \cup \{(\text{SQL}_i^{(j-1)}, \text{error}_j)\}. \quad \text{SQL}_i^{(j)} = \pi_{\text{SQL}}(\mathcal{C}_j). \quad \text{SQL}_i^{\text{corr}} = \text{SQL}_i^{(k)},$$

3. **Majority Voting:** 수정된 SQL 구문들을 실행하여 결과값이 같은 구문들을 하나의 그룹 g 로 묶은 뒤, query의 개수가 가장 많은 Group을 최종 정답 생성 그룹으로 선정 <- Query Consistency가 가장

$$\mathcal{G}_{\text{max}} = \left\{ \mathcal{G}_j \mid |\mathcal{G}_j| = \max_k |\mathcal{G}_k| \right\}$$

4. **Final SQL Selection:** 선정된 그룹 g 의 개수를 기준으로 아래의 규칙에 따라서 최종 평가 SQL 구문을 선정

$$\text{SQL}^* = \begin{cases} \text{RandomSelect}(\mathcal{G}_{\text{max}}), & \text{if } |\mathcal{G}_{\text{max}}| = 1 \\ \underset{\text{SQL} \in \mathcal{S}_{\text{tie}}}{\text{argmax PairwiseWins}}(\text{SQL}), & \text{otherwise} \end{cases}$$

AutoLink – Experimental Setups

- Experimental dataset

Dataset	# Test Examples	# Test DB	# Col / DB	# Tok. / SQL	# Func. / SQL	External Knowledge	SQL Dialect	Project Level
WikiSQL (Zhong et al., 2017)	15,878	5,230	6.3	12.2	0.0	✗	✗	✗
Spider 1.0 (Yu et al., 2018)	2,147	40	27.1	18.5	0.0*	✗	✗	✗
KaggleDBQA (Lee et al., 2021)	272	8	23.4	13.8	0.0	✓	✗	✗
SEDE (Hazoom et al., 2021)	857	1	212.0	46.9	1.4	✗	✗	✗
BIRD (Li et al., 2024b)	1,789	15	54.2	30.9	0.4*	✓	✗	✗
Spider 2.0-lite	547	158	803.6	144.5	6.5	✓	✓	✗
Spider 2.0-snow	547	152	812.1	161.8	6.8	✓	✓	✗
Spider 2.0	632	213	743.5	148.3	7.1	✓	✓	✓

Spider 2.0-lite

BIRD-dev	Simple	Moderate	Challenging	Total
	925	465	144	1,534

BIRD-dev

```
{'question_id': 0,
'db_id': 'california_schools',
'question': 'What is the highest eligible free rate for K-12 students in
the schools in Alameda County?',
'evidence': 'Eligible free rate for K-12 = `Free Meal Count (K-12)` /
`Enrollment (K-12)`',
'SQL': "SELECT `Free Meal Count (K-12)` / `Enrollment (K-12)` FROM
frpm WHERE `County Name` = 'Alameda' ORDER BY (CAST(`Free Meal
Count (K-12)` AS REAL) / `Enrollment (K-12)`) DESC LIMIT 1",
'difficulty': 'simple'}
```

AutoLink– Experimental Setups

- **Implementation details**

Policy Model (671B)

- Schema linking policy : DeepSeek-V3
- SQL generation policy: DeepSeek-R1, DeepSeek-V3

- **Metric**

Schema linking Evaluation Metric

- **Strict Recall Rate (SRR)**

$$\text{SRR} = \frac{\sum_{i=1}^n \mathbb{I}(\tilde{S}_i \supseteq S_{\text{gt},i})}{n}$$

SQL Query generation Evaluation Metric

- **Execution Accuracy (EX)**

$$\text{EX} = \frac{\sum_{i=1}^N \mathbb{1}(\hat{V}_i, V_i)}{N}$$

$$\mathbb{1}(\hat{V}_i, V_i) = \begin{cases} 1 & \text{if } \hat{V}_i = V_i \\ 0 & \text{if } \hat{V}_i \neq V_i \end{cases}$$

AutoLink – Result

- Main result: Schema linking performance of AutoLink

Method	Full Input	Bird Dev			Spider2.0-Lite					
		SRR [↑]	$\bar{C}$ [↓]	Avg. Tokens [↓]	SRR [↑] _{all}	SRR [↑] _{bq}	SRR [↑] _{sf}	SRR [↑] _{local}	$\bar{C}$ [↓]	Avg. Tokens [↓]
DE-SL (BGE-Large)	✓	35.5	35.7	–	43.6	28.2	57.1	87.5	153.8	–
CE-SL (BGE-reranker)	✓	72.4	35.7	–	57.6	42.3	72.6	95.8	153.8	–
MCS-SQL	✓	85.7	7.5	29.8K	58.9	57.8	54.8	79.2	45.1	168.9K
SQL-to-Schema	✓	92.5	13.5	19.4K	64.0	64.8	54.8	91.7	49.0	171.9K
CHESS	✓	89.7	4.5	–	–	–	–	–	–	–
RSL-SQL	✓	93.3	13.0	14.8K	52.0	52.8	44.1	75.0	25.8	29.2K
LinkAlign	✗	–	–	–	36.4	22.5	51.2	66.7	21.1	66.7K
AutoLink (ours)	✗	97.4	35.8	8.0K	91.2	93.7	85.7	95.8	159.4	21.2K

Table 1: **Performance comparison of schema linking on Bird Dev and Spider 2.0-Lite.** We report the overall Strict Recall Rate (SRR_{all}) for both datasets. For Spider 2.0-Lite, SRR is further broken down by SQL dialect: BigQuery (SRR_{bq}), Snowflake (SRR_{sf}), and SQLite (SRR_{local}). $\bar{C}$ denotes the average number of columns included in the simplified schema (S_{linked}) after schema linking. **Full Input** indicates whether the entire database schema is provided to the LLM or if all database schemas are iterated through.

- 제안한 AutoLink가 Baseline 대비 우수한 Schema linking 정확도를 보임. 특히 Spider2.0-lite에서 Baseline 대비 성능 차이가 두드러짐
- Spider 2.0-lite가 BIRD대비 DB metadata의 길이와 복잡도 측면에서 매우 높기 때문에 다른 Baseline이 성능이 저하되는 것으로 추정. 반면 AutoLink는 처음부터 제한된 정보를 바탕으로 Explore & Expand하기 때문에 Context Length 문제를 완화하여 Schema linking의 정확성을 담보
- Baseline 측면에서는 CHESS, LinkAlign같은 초기 주어진 정보에서 Noise를 줄이는 방향으로 접근하는 baseline은 성능이 가장 뒤떨어진다는 점을 발견

AutoLink – Result

- Main result: SQL generation performance

Method	Model	EX [†]	Avg. Tokens [↓]
Spider-Agent	QwQ	11.33	–
	GPT-4o	13.16	–
	DeepSeek-R1	13.71	–
	o1-preview	23.03	–
	o3-mini	23.40	–
	Claude-3.7-Sonnet	28.52	–
CHESS	GPT-4o	3.84	–
LinkAlign	DeepSeek-R1	33.09	–
RSL-SQL [†]	DeepSeek-R1	30.53	<u>50.0K</u>
REFORCE [†]	DeepSeek-R1	29.62	81.1K
REFORCE	o1-preview	30.35	81.1K
REFORCE	GPT-o3	37.84	81.1K
AutoLink	DeepSeek-R1	<u>34.92</u>	38.0K

Table 2: Execution Accuracy (EX) comparison of different methods on the Spider 2.0-Lite dataset. [†] indicates results obtained through independent reproduction. Avg. Tokens indicates the average number of tokens consumed to generate a SQL.

Method	Model	EX [†]	Avg. Tokens [↓]
MAC-SQL	GPT-4	59.39	6.8K
TA-SQL	GPT-4	56.19	<u>7.3K</u>
RSL-SQL	GPT-4o	67.21	<u>7.5K</u>
CHESS	Gemini-1.5-Pro	<u>68.31</u>	14.5K
AutoLink	DeepSeek-v3	66.36	8.0K
AutoLink	Gemini-1.5-Pro	68.71	8.0K

Table 3: Execution Accuracy (EX) comparison of different methods the Bird Dev.

- SQL generation에 특별한 기여가 없는 상황에서도 Spider 2.0, BIRD 에서 AutoLink의 성능이 타 Baseline 대비 우수한 SQL 정확도를 달성
- 동일 Backbone을 사용한 경우에 한하여 AutoLink는 타 baseline 대비 우수한 성능을 달성
- Avg. Tokens가 다른 baseline 대비 적음에도 높은 성능을 달성한 점을 볼 때 AutoLink의 Schema linking 정확성을 간접적으로 파악할 수 있음

AutoLink – Result

- Ablation Study: Impact of ablating action space and Environment interaction

Method	$SRR_{n=5}$	$SRR_{n=50}$	$SRR_{n=100}$
AutoLink	79.2	88.0	91.2
- w/o Verify Schema	77.2 $\downarrow$ 2.0	86.8 $\downarrow$ 1.2	89.6 $\downarrow$ 1.6
- w/o Explore Schema	76.8 $\downarrow$ 2.4	84.8 $\downarrow$ 3.2	88.8 $\downarrow$ 2.4
- w/o Retrieve Schema	72.4 $\downarrow$ 6.8	80.4 $\downarrow$ 7.6	84.5 $\downarrow$ 6.7

Table 4: Ablation study on the impact of different schema linking actions under varying numbers of initial candidates n on Spider 2.0-Lite.

- Schema Retrieval 제거 하는게 가장 큰 성능 저하를 불러 일으킴 → 초기 검색 결과만으로 Schema linking을 성공할 수 없음을 암시
- Explore Schema 제거시 두번째로 큰 성능 저하가 발생 → 질의, DB와 관련된 Ambiguity 해소에 Explore Schema가 기여함을 암시
- Verify Schema 제거시에도 성능 저하가 발생 → Self-assessment가 성능 향상에 기여함을 암시

AutoLink – Result

- Scalability Analysis of Different Database Scales




Figure 2: Scalability comparison across databases on Spider 2.0-Lite of varying sizes in terms of (a) Strict Recall Rate (SRR↑), (b) Average Tokens Consumption (Avg. Tokens↓), and (c) Execution Accuracy (EX↑). Percentages below each bin indicate the proportion of databases within each size range.

- Column의 개수에 따라서 Database size interval을 나눠서 분석을 시도
- AutoLink는 다른 Baseline 대비 SRR, Avg Tokens, EX 모든 측면에서 Database scale에 영향을 덜 받으면서 안정적인 성능을 내는 것을 확인할 수 있음

Schema Linking in the Wild: Clause-Aware Grounding with DB Disambiguation under Synthetic Distractor Pressure

Schema Linking in the Wild

- **AutoLink의 우수성**

- 적은 초기 DB 데이터로 Agent -Environment Interaction을 통한 Schema linking을 수행하는 방법론의 효과성 증명
- DB의 Scale에 덜 영향을 받는 강건한 방법론 제안
- Schema linking의 performance가 최종 SQL generation 성능에 영향을 주는 점을 증명

- **AutoLink 및 기존 Schema linking 방법론 한계**

- **Model Scalability:** AutoLink의 Agent은 DeepSeek-V3이며 671B 모델, LinkAlign의 Agent는 GLM-4-air, GPT-4
← 제안하는 framework를 수행하기 위해서 **매우 비싼 모델**이 필요
- **Unrealistic Settings:** Autolink의 Explore & Expand 방식 자체는 타당하나 그 방식이 작동될 수 있는 이유는 Explore & Expand의 범위가 DB 1개로 한정되는 것에 있음. 이러한 DB 정보를 주고 SQL 구문을 생성하는 기존 Text2SQL 방식의 문제점을 모두가 공유
← 사용자가 어떤 DB를 활용할지 모르는 상황, 즉 **Multi-DB 상황에서는 작동하기 어려운 방식**

Schema Linking in the Wild

- **How to implement Realistic Schema linking settings?**

- RAG 상황을 가정하여 질의 해결 가능 DB 정보와 질의 해결에 관련 없는 **Distractor DB**가 입력으로 포함된 **평가 데이터셋**을 구축
 - Ground truth Schema Linking 결과를 기반으로 column 단위 distraction을 다양하게 주는 방식으로 Distractor DB metadata 생성 ← Contextual Error Injection
 - Distractor DB metadata의 구조적 타당성 확인을 위한 데이터 verification 방법론 구축 ← Structural error prevention

- **How to utilize weak LLM for Schema Linking?**

- 하나의 LLM이 **Two-stage** 전략으로 작동할 수 있는 **framework** 제안
 - Stage 1: Mention & Entity Extraction: 자연어 질의와 Gold + Distractor DB metadata set이 주어졌을 때 관련 있는 mention, entity를 추출하는 역할
 - Schema linking에 필요한 관련성이 높은 table, column set을 최대한 많이 뽑도록 **recall을 높이는 전략을 추구**
 - Stage 2: Clause-aware Schema linking: Stage 1에서 추출된 Mention, Entity를 활용하여 최종 사용자 질의에 응답할 수 있는 table, column을 추출하는 schema linking을 실시
 - Entity를 Table/Column에 mapping할 때, **SQL의 어느 절(Clause: SELECT, WHERE, GROUP BY 등)에 속하는지, 어떤 연산자(Aggregation 등)와 결합되는지** 까지를 예측하면서 Schema linking을 진행

Schema Linking in the Wild

- Distractor DB creation procedure

내용적 중복 (Example Overlap)

정답 DB의 실제 예시 값(oakland, alameda, 2014-2015)을 가짜 DB 컬럼에 동일 주입 → 모델이 값을 보고 정답으로 착각

VALUE

의미론적 미세 변형 (Semantic Shift)

도메인·범주는 유사하나 의도가 어긋난 컬럼 생성 (cards.name vs. set_name) → 모델이 도메인만 보고 오선택

SEMANTIC

관계성 단절 (Relationship Break)

개별 카드를 특정할 수 없는 무의미한 FK 부여 (card_id → set_id) → FK 존재만 보고 조인 가능으로 오판

JOIN

시간 단위 불일치 (Temporal Shift)

날짜가 필요한 질문에 연도 컬럼 제시 (races.date vs. season_year) → 시간 컬럼이라는 이유로 답변 가능하다고 속음

TEMPORAL

집계 수준 불일치 (Granularity Shift)

집계 단위 스케일 불일치 컬럼 제시 (country vs. region, 학교 단위 vs. 학군 단위) → 더 넓은 단위를 정답으로 선택하도록 유도

GRANULARITY

Schema Linking in the Wild

- Distractor DB creation procedure

```
[DB_ID] california_schools
[Schema]
# Table: frpm
[
(CDSCode:INTEGER, Examples: [01100170118489, 01100170112607, 011
(Academic Year:INTEGER, Examples: [2014-2015]),
(County Code:INTEGER, Examples: [01]),
(District Code:INTEGER, Examples: [10017]),
(School Code :INTEGER, Examples: [0109835, 0118489, 0112607]),
(County Name:TEXT, Examples: [Alameda]),
(District Name :TEXT, Examples: [Alameda County Office of Educat
(School Name:TEXT, Examples: [Aspire California College Preparat
(District Type:TEXT, Examples: [County Office of Education (COE)
(School Type :TEXT, Examples: [K-12 Schools (Public), High Schoo
(Educational Option Type:TEXT, Examples: [Traditional]),
(NSLP Provision Status:TEXT),
(Charter School (Y/N):INTEGER, Examples: [1]),
(Charter School Number:TEXT, Examples: [0811, 1049, 0728]),
(Charter Funding Type:TEXT, Examples: [Directly funded]),
(IRC:INTEGER, Examples: [1]),
```

지역 단위 —> 지역별 통계 데이터 제공 (County vs. region), 학교 단위 VS. 학군

컬럼에

table name

→ FK 존재

→ 시간

```
[DB_ID] california_student_wellness
```

```
[Schema]
```

```
# Table: campus_directory
```

```
[
(campus_id:INTEGER, Primary Key, Examples: [120045, 120318, 1210
(reporting_year:TEXT, Examples: [2014-2015, 2013-2014]),
(district_label:TEXT, Examples: [Alameda Unified, Hayward Unifie
(site_label:TEXT, Examples: [Lincoln Middle, Fremont High, Bayvi
(campus_category:TEXT, Examples: [Elementary, Middle, High]),
(low_grade_flag:TEXT, Examples: [K, 6, 9]),
(high_grade_flag:TEXT, Examples: [5, 8, 12]),
(charter_flag:BOOLEAN, Examples: [true, false]),
(street_location:TEXT, Examples: [1250 Atlantic Ave, 4610 Foothi
(municipality:TEXT, Examples: [Alameda, Oakland, San Leandro]),
(postal_code:TEXT, Examples: [94501, 94601, 94577]),
(latitude:REAL, Examples: [37.76512, 37.77483, 37.72451]),
(longitude:REAL, Examples: [-122.24118, -122.21456, -122.15674])
(calendar_model:TEXT, Examples: [Traditional, Year-Round, Modifi
(start_month:TEXT, Examples: [August, July]),
(end_month:TEXT, Examples: [June, May]),
(active_status:TEXT, Examples: [Active, Inactive])
]
```

```
# Table: fitness_assessments
```

```
[
(assessment_id:INTEGER, Primary Key, Examples: [500901, 500944,
(reporting_year:TEXT, Examples: [2014-2015, 2013-2014]),
(campus_id:INTEGER, Examples: [120045, 120318, 121007]),
```

VALUE

EMANTIC

JOIN

TEMPORAL

ANULARITY

Schema Linking in the Wild

- Clause-aware Schema linking

SQL query
execution order

FROM and JOIN
↓
WHERE
↓
GROUP BY
↓
HAVING
↓
SELECT
↓
ORDER BY
↓
LIMIT

window functions
execute here


"question": "Provide ID, sex and age of patient who has blood glucose (GLU) not within normal range but with total cholesterol(T-CHO) within normal range."

```
```json
{
 "join_analysis": {
 "needs_join": true,
 "tables_involved": ["<table_1>", "<table_2>"]
 },
 "schema_linking_predictions": [
 {
 "mention": "<exact mention string from the input list>",
 "schema_items": [
 {
 "table": "<table name as shown in the schema>",
 "column": "<column name as shown in the schema>",
 "clauses": ["<clause_label>", "..."],
 "elements_by_clause": {
 "<clause_label>": ["<operator_or_function>", "..."]
 }
 }
]
 }
],
 "join_path": [
 "<table_a>.<column_i> = <table_b>.<column_j>"
]
}
```
```

```
"join_analysis": {
  "needs_join": true,
  "tables_involved": ["Patient", "Examination", "Laboratory"]
},
"schema_linking_predictions": [
  {
    ... {
      "mention": "blood glucose (GLU) not within normal range",
      "schema_items": [
        { "table": "Laboratory", "column": "GLU", "clauses": ["WHERE"], "elements_by_clause": { "WHERE": {"NOT_EQUAL"} } }
      ]
    },
    {
      "mention": "total cholesterol(T-CHO) within normal range",
      "schema_items": [
        { "table": "Laboratory", "column": "T-CHO", "clauses": ["WHERE"], "elements_by_clause": { "WHERE": {"EQUAL"} } }
      ]
    }
  ],
  "join_path": [
    "Patient.ID = Examination.ID",
    "Patient.ID = Laboratory.ID"
  ]
}
```

Schema Linking in the Wild

- Framework structure diagram



Schema Linking in the Wild


- Experimental Results: Schema linking

Qwen/Qwen2.5-Coder-7B-Instruct 활용 추론 실시

| | DB Acc | Table Acc | Col Acc | Table Acc (cond.) | Col Acc (cond.) |
|----------------|----------------|----------------|----------------|-------------------|-----------------|
| real_naive | N/A | 51.47% | 31.93% | N/A | N/A |
| v2 Zero Shot | N/A | 53.39% | 36.96% | N/A | N/A |
| v2 2shot | N/A | 57.661% | 42.014% | | |
| v2_1 Zero Shot | 60.47% | 48.60% | 34.84% | 80.06% | 57.46% |
| v2_1 2shot | 72.791% | 58.427% | 43.708% | 79.837% | 59.950% |

Schema Linking in the Wild

- Framework structure diagram TODO



- Verifier 도입을 통한 각 Stage error mitigation 방지
- Feedback-aware 학습을 하기 위한 구조 선정

Schema Linking in the Wild

- Experimental Results: Schema linking

| | DB Acc | Table Acc | Col Acc | Table Acc (cond.) | Col Acc (cond.) |
|----------------|----------------|----------------|---------------|-------------------|-----------------|
| real_naive | N/A | 51.47% | 31.93% | N/A | N/A |
| v2 Zero Shot | N/A | 53.39% | 36.96% | N/A | N/A |
| v2 2shot | N/A | 57.661% | 42.014% | | |
| v2_1 Zero Shot | 60.47% | 48.60% | 34.84% | 80.06% | 57.46% |
| v2_1 2shot | 72.791% | 58.427% | 43.708% | 79.837% | 59.950% |
| v3_fewshot | 70.46% | 58.11% | 44.35% | 82.48% | 62.95% |

Schema Linking in the Wild

- **TODO**

- Stage 1, Stage 2 특화 학습 실시
 - Stage 1은 Input Context Length를 줄이면서 부족한 Context를 Explore & Expand하는 방법론 고민 필요
 - Stage 2는 SQL Clause-aware signal을 줄 수 있는 loss + verifier feedback을 따르는 loss 설계 필요
- 학습 데이터셋 구축
- 비교 Baseline 선정
- 실험 진행에 따른 분석 실시
- Etc...

Thank you
