

自己認知は LM as KB の信頼性を高めるか

○井之上直也 (JAIST/理研), 原口大地, 田中健史朗, 白井清昭, Natthawut Kertkeidkachorn (JAIST)

問い

同一の知識を表す複数の言語表現に対し一貫性のない回答を返す問題にどう対処？

仮説

単語生成確率により回答一貫性を推定
単純な言語表現に分解して Retry or Abstain

結果

回答率と精度の両立に成功
GPT-3.5/4, StrategyQA にて実証

1. 目的: 信頼できる LM as KB

- ❖ **LM as KB: 知識ベースとしての LM (Petroni+2019)**
 - 知識の保存: パラメタの学習 / 問い合わせ: トークン予測
 - 利点: 柔軟に問い合わせ可能
- ❖ **LM as KB の問題点**
 - 訓練事例にない回答を作話 (Ji+2022)
 - LLM の回答は言語表現に鋭敏 (Hagström+2023)
- ❖ **理想の LM as KB**
 - “知識の知識”: 無知, 情報源, 自己矛盾, 意見多様性, ...
 - 言語表現に依存しない形で知識の問い合わせができる
 - 推論の過程を追跡できる

3. 実装: LLM + Zero-shot Prompting

❖ LMKB (知識ベース)

- LLM + Zero-shot Prompting
- For the following question, provide your best guess.
Give ONLY the guess. No other words or explanation.
{ p }. True or False?
- トークン “True”, “False” の生成確率分布 $\rightarrow \pi(Y)$
 - 自己認知機構: 正規化エントロピーに基づく確信度

$$LMKB(p) =$$

$$\begin{cases} \operatorname{argmax}_{y \in \{\text{True}, \text{False}\}} \pi(Y = y) & \text{if } 1 - NE(Y) \geq \tau \\ \text{Unknown} & \text{otherwise.} \end{cases}$$



❖ ProofGen (間接証明器)

- LLM + Zero-shot Prompting
- To conclude a statement X, what premises are needed?
Write two atomic premises P and Q.
P and Q can be false facts. P and Q should contain all the world knowledge required to prove X. ... (省略)
X: { p }
- 様々な分解方法、真偽推定方法がありうる
 - 十分条件: $\{q_1 \wedge q_2 \rightarrow p, q_1, q_2\} \vdash p$ (本研究)
 - 同値言い換え: $\{q \leftrightarrow p, q\} \vdash p$ (例: 誕生 \leftrightarrow 生まれる)
 - Modus Tollens: $\{p \rightarrow q, \neg q\} \vdash \neg p$ (例: 犬 \rightarrow 4つ足)
 - 選言三段論法: $\{q \vee p, \neg q\} \vdash p$ (例: パン \vee ごはん)

2. 提案法: 定理証明器 + LM as KB

❖ 全体の流れ

- 命題 p の真偽を問い合わせ
- 結果に自信あり \rightarrow そのまま解答
- 結果に自信なし \rightarrow 間接証明に Back-off: q_1, q_2, \dots, q_n
 - q_1, q_2, \dots, q_n の真偽を推定 (\rightarrow Step 1; 再帰呼出)
 - 推定結果から p の真偽を再推定、上書き




4. 実験結果: 回答率と精度を両立

❖ 実験設定

- 言語モデル: GPT-3.5, GPT-4 / データ: StrategyQA (Geva+2021)
- 評価指標: 回答率-精度曲線
- ベースライン: BoolQA+Unk (= LMKB)

❖ 主な実験結果



- a) エントロピーが確信度として機能
- b) 間接証明による正確な知識問い合わせ
- c) 2次のバックオフも有効

❖ その他の実験結果 (論文参照)

- GPT-3.5 による実験, 間接証明の精度, エラー分析

5. 議論/今後: 自己認知とは...

- 確信度 == 無知? 「分からない」とは?
- トークン “True” “False” の生成確率は無知を表現?
- 今後の課題: 多様な証明戦略の採用, 証明の展開方策の工夫