

法人情報の真偽を判別するプロダクト「PIRD」の開発

群馬県立前橋高等学校 2年 岡田 武

背景・仮説

インターネット上では偽情報が多く流布しており、偽情報による様々な被害が近年増加している

特に 法人に関する偽情報では、法人や顧客が甚大な被害を被っている

前回 ChatGPTのオープンモデルを使って開発 ➡ **今回** ファインチューニングさせたLLMを使って開発

仮説

LLMをそのまま使うのではなく**各法人に特化した内容**でファインチューニングすると**真偽判定精度**が向上するのではないか

フロントエンドの開発

判定部




図1:判定部の動作フロー

表示部 総合評価はA~C表記とした(図2)。




図2:表示部の動作フロー

LLMのファインチューニング

LLMのファインチューニングには、**QLoRA方式**を採用した。モデルの重みの変化量を2つの小さな行列の積で近似し、学習すべきパラメータ数を大幅に削減した。QLoRA方式により学習にかかるコストを最小限にしながらfAI(ファインチューニング済モデル)を開発した(図3)。




図3:QLoRA方式を用いたfAI開発イメージ

検証:判定精度

今回は 前橋高校を事例とし、前橋高校に関する情報のファクトチェックを行った。学習ソースは前橋高校のホームページをスクレイピングしたものの使用した。

文章の検証

ChatGPT:72.5%(58/80)

fAI :88.8%(71/80)

検証時は ホームページの情報に加え、Wikipedia「群馬県立前橋高等学校」の情報(正しいことを確認済)も含め検証した。



図4:PIRDのUI(前橋高校用)

画像の検証

ChatGPT:70.0%(28/40)

fAI :82.5%(33/40)

画像を言語化することにより、対象の真偽を測定している。尚、検証用の画像は文章の検証と同様の文を使用し、Gemini(Nano Banana)を用いて生成した。



図5:判定結果の例(信頼度A)

今後の展望:RAGの実装

RAG(検索拡張生成)をfAIに実装することにより、fAIの再学習サイクルを大幅に減らし、情報の入替えの効率化を図ることができる(図6)。

現在ローカル環境でのRAG機能の構築に成功しており、今後はサーバーでの構築を目指す。




図6:RAGの動作イメージ

参考文献

- 「偽・誤情報の現状とこれから求められる対策」
https://www.soumu.go.jp/main_content/000867454.pdf
- 「LoRAとQLoRA」
<https://www.redhat.com/ja/topics/ai/lora-vs-qlora>
- 「RAG(検索拡張生成)とは?意味・定義 IT用語集」
<https://www.ntt.com/bizon/glossary/e-r/rag.html>