

2024 年度 高等学院同窓会学術研究奨励金
研究成果報告書概要（WEB 公開用）

高等学院長
高等学院同窓会理事長 殿

研究代表者氏名 [高橋 彰仁]

学年・組・番号 [2 年 B 組 28 番]

研究課題： LLM の言語間転移から着想を得た回答のパーソナライズ手法の提案

（英文） Proposal of a method for personalizing answers inspired by the cross-lingual transfer of LLMs.

研究概要：

（研究課題を選んだ動機、達成するための計画・目的・方法等について 200～400 字で記入してください）

本研究は、自然言語処理分野における大規模言語モデル（LLM）の進展に着目し、LLM の「言語間転移」の手法を応用した、Chain System of Personalized Action というパーソナライズ手法を提案した。本手法は、ユーザーの要望や意図をヒアリングで収集し、かつ Web content RAG を行い、推論を更新することで、ユーザーの意図を踏まえた回答を生成する仕組みである。本手法は、従来のコールドスタート問題やプロンプト長の増大問題を解決することができる。

研究成果：

（研究の結果概要、結果に対するフィードバックや感想等について 200～400 字で記入してください）

研究では、Chain System of Personalized Actions の動作シミュレーションを実施し、その有効性を確認した。本手法は、プロンプトチューニングを活用してユーザーごとのパーソナライズを実現し、対話型チャットボットにおける新たな応答生成フローの可能性を示した。さらに、シミュレーション結果に基づき、ファインチューニングの教師データの作成やアルゴリズムの改善を進めることで、より高度な応用を期待できる。今後は、評価指標を用いた詳細な検証を進め、対話型 AI のパーソナライズに貢献する予定である。

研究者：（以下の、代表者・分担者は学年・組・氏名を明記する）

研究代表者 2B28 高橋 彰仁

研究分担者

担当教諭 八百屋 大

（受給額：15,000 円）

※研究課題、研究概要、研究成果、研究代表者名が WEB ページ上で公開されることに同意します
（次のページに続きます）

(研究過程がわかる写真や、研究結果がわかる写真などを数点貼り付けてください)

質問ステップとWeb検索ステップを含んだ思考の連鎖を複数回展開し、回答をパーソナライズするシステムの提案

早稲田大学高等学院2年 高橋彰仁

研究背景

AI PERSONA

ユーザーの年齢、性格、利用目的、好みなどを「プロフィール」として記録し、プロンプトにプロフィールを組み込むことで、ユーザーの状況に適した文脈や形式で回答する。このプロフィールは、対話を通じてリアルタイムで更新され、常に最新のユーザー情報が反映される。

<ユーザープロフィールの例>

「名前」:「ボブ」
「年齢」:「28歳」
「性別」:「男性」
「国籍」:「アメリカ」
「言語」:「英語」、「スペイン語」
「職業」:「ソフトウェアエンジニア」
「学歴」:「計算機科学の修士号」
「MBTI」:「INTJ」
「興味」:「読書」、「プログラミング」
「使用目的」:「「知識活動」、「プログラミング学習」
「クエリの傾向」:「Javaのコード」、「面接準備」
「エンゲージメントパターン」:「夜に利用」
「好み」:「応答形式」:「Markdown形式」
「対話スタイル」:「簡潔で正確な説明」

QA with Clarification

LLMは、ユーザーの曖昧な要求に対して、意図を一時的に仮定して直接回答する傾向がある。これにより、ユーザーの期待と異なる回答を提供してしまうことがある。この問題を解決するため、LLMが曖昧な要求に対して1回の明確化の質問を行い、ユーザーの意図を正確に把握した上で回答を提供する。この手法により、ユーザーの異なる解釈に対応する回答のF1スコアが5%向上した。

[Turn 1] User's Input Query: x

Who is the highest paid football player?

[Turn 2] LLM (M) Predicts

Single-Turn Responses: $M(x) = r_{\text{na}}$

(A) Direct-Answer (True) r_{na} As of 2024, the highest-paid football players are Cristiano Ronaldo...

$\Phi(r_{\text{na}}) = \text{False}$

(B) Direct-Answer (False) r_{na} The highest-paid football player in the NFL for 2024 is Joe Burrow...

$\Phi(r_{\text{na}}) = \text{False}$

(C) Clarifying Question (True) r_{na} Are you asking about American Football or Soccer?

$\Phi(r_{\text{na}}) = \text{True}$

(D) Clarifying Question (False) r_{na} Are you asking about a specific time period?

$\Phi(r_{\text{na}}) = \text{True}$

Single-Turn Preferences

User 1

Users 2, 3

Majority Best Response: [A]

[Turn 3] Users Respond with Clarifying Answers: $p(x, y, r_{\text{na}}) = a_i$

$a_1 = \text{About } \Phi$

$a_2 = \text{About } \Phi$

$a_3 = \text{Currently}$

[Turn 4] LLMs Predict Next Response: $M(x, r_{\text{na}}, a_i) = r'_{\text{na}}$

$r'_{\text{na}} = r'_{\text{na}} = \text{Joe Burrow...}$

$r'_{\text{na}} = r'_{\text{na}} = \text{Cristiano Ronaldo...}$

$r'_{\text{na}} = r'_{\text{na}} = \text{Cristiano Ronaldo...}$

Double-Turn Preferences

User 1

Users 2, 3

Majority Best Response: [C]

Evaluation Metrics

Efficiency (# of M Turns)

F1 ($R, \{x, y, r_{\text{na}}, r'_{\text{na}}\}$)

[A] [B] [C] [D]

1 1 2 2

0.8 0.5 1.0 0.6

未検証

複数回のユーザーへの質問

ユーザーに複数回の意図明確化のための質問を行うパーソナライズ効果については実装・評価されていない

研究目的

QA with Clarificationを複数回のヒアリングとWeb検索ができるように発展させた上に、AI PERSONAで用いられたユーザープロフィールをプロンプトに含めて回答に反映させる手法を組み合わせた、Chain System of Personalized Actionsを展開することで、コールドスタート問題、プロンプト長永増加問題を解決する。

Chain System of Personalized Actionsとは

以下のフローでユーザーの要望を反映した回答の提供を目指す。

1. 検索クエリとユーザーへの質問内容を含む自問自答

2. ユーザーへのヒアリング

3. ヒアリング結果を取り入れるための自問自答

4. ユーザーへの質問が無くなるまで2と3を繰り返す

5. 最後の自問自答を基にした計画の作成

6. 計画の実行(最終回答生成)

Google AI Studio上でのChain System of Personalized Actionsのシミュレーション(プロンプトチューニング)

あなたは、ユーザーリクエストに回答することを目的とした、ユーザーがそのまますた社会で利用できるユーザーの事情に寄り添った計画を作成してください。しかし、回答までの洗練された計画を一気に作成するのは難しいため、以下のルールと例に従って、計画を練る推論を行ってください。

<ルール>

・ユーザーリクエストに回答することを目的とした計画を作成する。かつ作成した計画をユーザーがそのまますた社会で使用するよう、現実的に隔々まで水平思考と垂直思考を巡らせてください。

・計画を練っている最中にWeb検索が必要だと判断したら、「検索:」タグを文頭に付けて、検索エンジンへのリクエスト文を記述してください。

・計画を練っている最中にユーザーの要望を聞くべきと判断したら、「質問:」タグを文頭に付けて、ユーザーへの質問文を記述してください。

・今回の計画作成のための推論

・ユーザーリクエスト:「3日間の京都旅行を計画してください。」

一括計画生成の前の思考の連鎖の展開(自問自答):

会話内容全体参照

50% VLM 40%

Gemini

3日間の京都旅行ですね!かしこまりました。

まず、どのような旅行を計画しているかを知るために、いくつか質問させていただきます。

質問:旅行の目的は何ですか?(例:観光、グルメ、歴史探訪、自然散策など)

質問:一緒にいく人数と、その関係性を教えてください。(例:一人旅、恋人との旅行、家族旅行、友人との旅行など)

質問:旅行の予算はどれくらいですか?(例:1人あたり5万円、10万円など)

質問:出発地と、京都までの移動手段は何ですか?(例:東京から新幹線、大阪から電車など)

質問:京都で宿泊する予定のホテルのタイプや、宿泊エリアの希望はありますか?(例:駅近のビジネスホテル、風情のある旅館、中心部のシティホテルなど)

質問:食事の好みや、アレルギーの有無はありますか?(例:和食が好き、ベジタリアン、アレルギー食材があるなど)

質問:京都で訪れたくない観光スポットはありますか?(例:金閣寺、清水寺、伏見稲荷大社など)

質問:京都で行ってみたいアクティビティはありますか?(例:着物レンタル、茶道体験、人力車など)

これらの質問に答えていただくことで、より具体的な旅行プランを作成することができます。

また、旅行の目的や好みに合わせて、以下のような情報を収集し、計画に反映させます。

・観光スポットの情報:拝観時間、料金、アクセス方法、所要時間、混雑状況など

・検索:京都観光スポット一覧

・検索:京都観光モデルコース3日間

・グルメ情報:人気のお店、おすすめの料理、予算、営業時間、アクセス方法など

・検索:京都グルメランキング

・検索:京都ランチおすすめ

・検索:京都ディナーおすすめ

・交通情報:市バス・地下鉄の路線図、料金、時刻表、お得な乗車券など

・検索:京都交通一日乗車券

・ホテルの情報:料金、設備、アクセス方法、口コミなど

・検索:京都ホテルおすすめ

・アクティビティの情報:料金、所要時間、予約方法など

・検索:京都アクティビティおすすめ

さらに、3日間の旅行プランを作成する際には、以下の点を考慮します。

・移動時間:観光スポット間の移動時間や、交通手段を考慮し、無理のないスケジュールを立てる

・休憩時間:疲れないように、適度に休憩時間を設ける

・天候:雨天の場合のプランも考えておく

・季節:季節に合わせた服装や、持ち物を準備する

・混雑状況:人気の観光スポットは、混雑する時間帯を避ける

これらの情報を総合的に判断し、3日間の京都旅行をユーザーの事情に寄り添った、詳細な計画を作成します。

あなたは、自問自答を基に、実用的なユーザーへの返答の作成をゴールとした洗練された検索・推論計画を作成してください。検索・推論計画を作成する際に、以下のルールと例に従ってください。

<ルール>

・ユーザーリクエストに回答することを目的とした計画を作成する。かつ作成した計画に沿って生成したユーザーへの最終回答をユーザーがそのまますた社会で利用できるように、まず、自問自答を基に、現実的に隔々まで水平思考と垂直思考を巡らせてください。

・自問自答に含まれている「検索:」タグを<ステップ>内に挙げてください。

・ユーザーに回答するまでに推論すべき事を洗い出し、<ステップ>内に「推論:」を文頭に付けて、推論事項を記述してください。

Gemini

<ステップ>

検索:嵐山奥の院 周辺 カフェ

推論:1日目の旅行プランの詳細を計画する。

推論:2日目の旅行プランの詳細を計画する。

推論:3日目の旅行プランの詳細を計画する。

推論:各スポットの所要時間、移動時間、交通手段、料金などを詳細に記載した旅程表を作成する。

推論:観光スポットの拝観時間や、混雑状況なども考慮して、効率的に回れるルートを再確認する。

推論:雨天の場合の代替プランも検討する。(1日目:京都国立博物館、京都水族館など、2日目:嵯峨野トロッコ列車、京都府立植物園、二条城など、3日目:錦市場、京都鉄道博物館など)

推論:検索結果と推論結果をまとめて、3日間の京都旅行プランを作成する。

フィニッシュ

フィニッシュ

また、ヒアリングでのユーザーの返答と行動計画の編集内容を基にした自問自答のパーソナライズも実現したい。自問自答のパーソナライズとは、既知のユーザーの興味思考に沿った自問自答を生成すること、ヒアリングにおけるユーザーの返答を推測し、ヒアリングの回数を減らすことである。私は、ヒアリング時のユーザーの返答からGemini 2.0 FLASH Thinkingなどでペルソナを推定し、それを自問自答時にプロンプトに含めることで実現可能だと考える。

本手法は、自問自答を通してユーザーへヒアリングを行い、その返答を回答に反映させるため、ユーザープロフィールの有無に関わらず、初めからユーザーレベルのパーソナライズが可能である。そのため、コールドスタート問題を解決できる。また、ペルソナデータに、テキストの肥大化に繋がる固定的でない項目を含めないこと、プロンプト長永増加問題を招くことを防ぐ。

評価方法(予定)

先行研究のAI PERSONAの評価方法を参考に。LLMをユーザー役としてシステムと会話させ、最終回答生成後に、会話したLLMに最終回答の満足度を評価してもらい、プロフィールの類似度を強力な推論モデル(GPT-o1など)で100段階評価してもらい、発話効率を算出する予定である。

比較対象はGPT-4o, GPT-o1, Gemini 2.0 FLASH, few-shot promptを伴うGemini 2.0 FLASH, ファインチューニング済みGemini 1.5 Proとする。

<評価指標>

ユーザー満足度:システムの最終回答がどれだけ自身(ユーザー)の意図を踏まえて、リクエストを解決しているのか

プロフィールの類似度:ユーザー役LLMに付与していたペルソナデータと、10回のユーザーリクエストへの回答後に記録したヒアリング結果から推定したペルソナデータの類似度

発話効率:最終回答までのユーザーとシステムの質問-回答のペアの個数を数える。個数が少ないほど、発話効率が高いことを示す

また、プロフィールの類似度の評価を通して、最も更新による類似度の増加量が大きくなるプロフィールの更新頻度を見つきたい。

参考文献

Tiannan Wang. AI PERSONA: Towards Life-long Personalization of LLMs. ArXiv, 2024

<https://arxiv.org/pdf/2412.13103>

Michael J.Q. Zhang. Modeling Future Conversation Turns to Teach LLMs to Ask Clarifying Questions. ArXiv, 2024

<https://arxiv.org/html/2410.13788v1#bib>