

# データベースに基づく特定個人との会話システムの検討

A study on a conversation system with specific individuals based on a database

朱睿妍<sup>1)</sup>, 塩谷隆二<sup>2)</sup>, 中林靖<sup>3)</sup>

Ruiyan Zhu, Shioya Ryuji and Yasushi Nakabayashi

1) 東洋大学 (〒350-8585 埼玉県川越市鯨井2100, E-mail: s3b102400132@toyo.jp)

2) 東洋大学 総合情報学研究科 教授 (〒350-8585 埼玉県川越市鯨井2100, E-mail: shioya@toyo.jp)

3) 東洋大学 総合情報学研究科 教授 (〒350-8585 埼玉県川越市鯨井2100, E-mail: nakabayashi@toyo.jp)

This study explores the recording and utilization of personal data using generative AI. I collected and organized my own episodic memories and basic personal information to develop a conversational digital avatar named “AI Zhu-san.” By leveraging the BERT model and the text-embedding-3-small model, I conducted experiments to improve the retrieval performance of personal data and the naturalness of responses. Furthermore, as a new challenge, I am building a dialogue system featuring characters from Romance of the Three Kingdoms. Future work will focus on enhancing both the accuracy and the sense of immersion.

**Key Words :** generative AI, digital avatars, text vectorization, cosine similarity, interactive systems

## 1. はじめに

### 1.1 背景

近年、デジタルテクノロジーの飛躍的な進化により、インターネットや SNS を通じて個人が多量のデータを残すようになった。これらのデータは、個人の生活の記録としての価値を持ち、新たな方法で活用される可能性が高まっている。

特に、生成型 AI の進化は目覚ましく、画像、音声、テキストの生成技術が大きく発展している。大規模自然言語モデル (LLM) である ChatGPT の普及により、AI は人間に近いレベルの対話能力を持つようになった。

これにより、個人のデータを利用してその人を再現し、対話可能なアバターを作成することが可能となり、個人データの新たな価値を見出す手段として注目されている。

このような背景から、本研究では生成型 AI を用いて個人データを記録し、そのデータを基にしたデジタルアバターの開発とその価値を探索することを目指す。

### 1.2 目的

本研究の目的は、生成型 AI を用いて個人のデータを記録し、そのデータを基に対話可能なデジタルアバターを開発することにある。具体的には、個人のエピソード記憶、性格、基本情報を入力データとして使用し、それを基に個人の特徴を持つアバターを生成する。このアバターとの対話を通じて、個人データの新たな価値を見出し、技術の社会的意義を探索する。

研究の一環として、生成型 AI の性能を最大限に活用し、個人のデータを基にしたアバターをどの程度精度高く再

現できるかを検証する。また、生成されたアバターが実際に個人やその関係者にどのような影響を与えるかについても考察する。

## 2. 先行事例

### 2.1 先行研究

「smallville」(図-1)では、スタンフォード大学や google の共同研究チームによって「ChatGPT を活用して npc の行動を自動決定する仕組み」が開発された。これによってバーチャルの世界に、人格の持つようなアバターを作り、現実とファンタジー世界の壁を取り払うことで、オンラインゲームやシミュレーションの新しい次元を開拓している。各アバターが自分自身の個性と生い立ちを持ち、一人ひとりが異なる要素を持つさまざまなシナリオを自動的に生成し、ゲーム内の予測不可能な展開や複雑な対話を実現している。



図-1 smallville

### 2.2 生命倫理

生成型 AI を用いた個人データの活用には、個人のプライバシー保護、人格や尊厳の尊重、そしてデータの虚偽

や改変の防止といった生命倫理の論拠が含まれる。生成型 AI が個人の实在の保護と他者性の尊重に関わる新しい行動を示す可能性があるため、これらの倫理観は特に重要である。

異なる倫理観は、生成型 AI による個人データの活用に対する異なる倫理的判断を生む可能性がある。ある人々は、既知の個人のイメージに忠実であることを主張している。一方、他の人々は、既知のイメージの繰り返しが個人の複雑さや多様性を単純化し、その表現に影響を与える可能性を懸念している。

したがって、生成型 AI を用いて個人データを活用する際には、異なる論拠を慎重に考慮し、新技術の導入が個人の合法的権利を侵害しないようにする必要がある。

## 2.3 DEMO：AI 朱さん

また、私は自分をAIにして実現させるため、家族や友達からインタビューしながら情報を収集し、ChatGPT を用いて、ウェブアプリDEMOに作成した。

## 3. 研究方法

本研究では以下の手法を用いて検討を進める。

(1)先行研究・文献調査：まず、生成型 AI や個人データの活用方法に関する先行研究や文献を調査する。これにより、過去の研究成果や技術の特性、有用性、そして課題を明らかにする。特に、デジタルアバターの生成に関する研究や、LLM の応用事例を重点的に調査し、研究の方向性を定める。

(2)個人データの収集：SNS やブログなどのデジタル空間における個人のエピソード記憶、性格、基本情報のデータを収集する。収集するデータには、テキスト、画像、音声など多岐にわたる形式が含まれる。これらのデータは、個人のデジタルアバターを生成するための基礎資料として使用される。

(3)データの整理と LLM の運用：収集したデータを整理し、ベクトルデータベースを構築する。データ整理の過程では、データのクレンジングや正規化を行い、一貫性のあるデータセットを作成する。このデータベースを基に、LLM（大規模自然言語モデル）を運用し、個々の人の話し方や考え方を模倣するアバターを生成する。

(4)アバター効果の検証：作成したアバターの適切性を個人やその関係者に評価してもらう。評価の過程では、アバターとの対話が個人や関係者にどのような影響を与えるかを詳細に検証する。具体的には、対話の自然さ、情報の正確さ、心理的な影響などを評価項目とする。評価方法としては、インタビューやアンケート調査を実施し、対話後の感想や意見を収集する。

(5)結果の分析と考察：得られた結果や情報をまとめ、その結果がどのような意味や価値を持つのか深く考察する。特に、個人のアバターとの対話が関係者の心にとっ

てどのような効果や影響をもたらすのかについて詳細に分析する。

## 4. 実験

本研究では、生成型 AI を用いて「AI 朱さん」(図-2)というデジタルアバターを作成し、個人データの新たな価値を探索する実験を行った。使用したプログラミング言語は Python である。

まず、自身のエピソード記憶を収集した。各記憶は番号、時間、場所、人物、出来事、心情、詳細、影響、具体的内容の形式で記録し、JSON 形式で保存した。現在、この記憶データベースには 30 件のエピソード記憶が含まれており、それに関連する画像データ 68 枚も収集した。また、記憶の整理過程で不明瞭な 7 件のエピソードを削除し、内容の明確化を図った。

次に、テキストをベクトル化するために、BERT モデルと text-embedding-3-small モデルを導入した。BERT モデルは基本的なテキストベクトル化に用いられたが、text-embedding-3-small モデルは多言語対応に優れ、キーワードの類似性を高精度で判断できる特性がある。本システムは、記憶データベース内のベクトルと目標ベクトル間のコサイン類似度を計算し、最も類似度の高い記憶を返す。

さらに、生成型 AI のプロンプトを改善し、記憶検索の効率性を向上させた。新しいプロンプトには、「設定・人格」として特別な意味記憶を追加し、注意点として「知らないことは素直に伝える」「記憶検索を積極的に活用する」「返答に適切な絵文字を付与する」の 3 点を設定した。これにより、返答の自然さが向上した。

実験の結果、以下のことが確認された。

(1)キーワードが完全一致した場合、BERT モデルと text-embedding-3-small モデルは共に正確な答えを返した。

(2) キーワードが異なる表現で類似した意味を持つ場合、text-embedding-3-small モデルは BERT モデルよりも高い精度で関連する記憶を返すことができた。

(3) 多言語環境における記憶検索では、言語特有の文字の一致に基づく誤検索が発生することがあった。

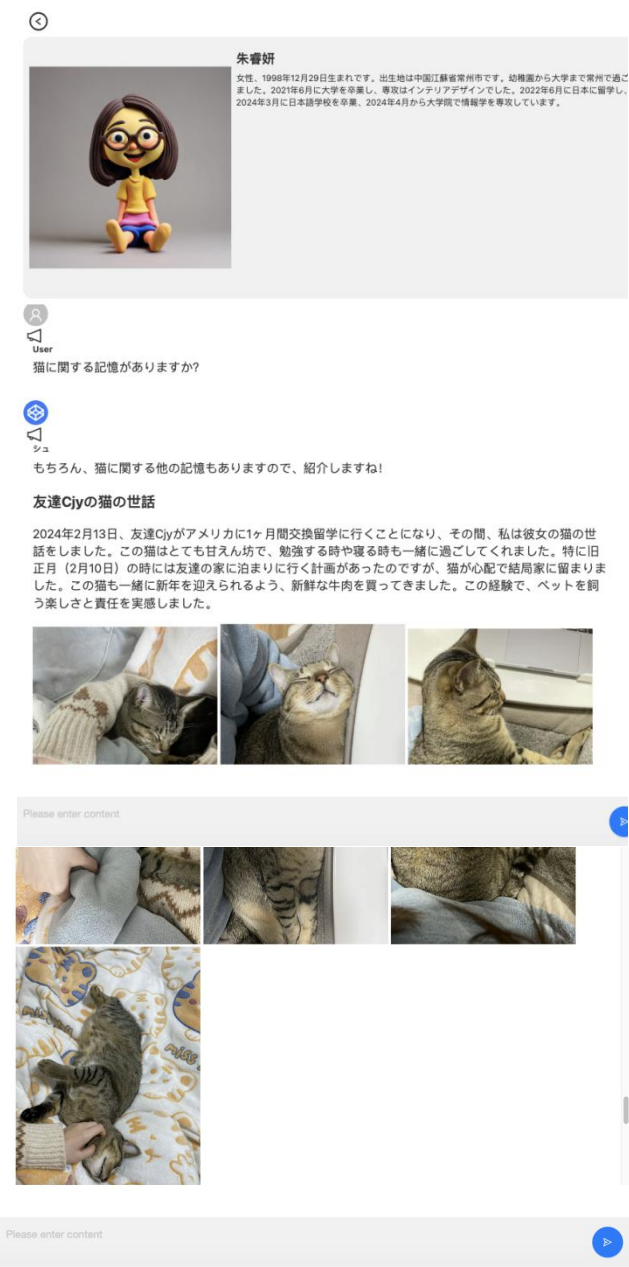


図-2 「AI 朱さん」

5. まとめ

私の話し方や考え方を模倣するために、「AI 朱さん」というデモを作成している。この目標を達成するために、ベクトル記憶データベースを構築し、BERT モデルを用いてテキストをベクトルに変換した。これにより、テキストの意味的特徴をベクトル表現として取得した。

処理過程において、システムはまず記憶ベクトルを保存しているファイルを読み込み、次にこれらのベクトルと目標ベクトルのコサイン類似度を計算する。類似度の高いベクトルはリストに保存され、類似度の高い順に並べられる。最終的に、システムは最も類似度が高い記憶の具体的な内容を返す。

しかし、いくつかの課題も存在する。本研究は現時点では私自身のデータを中心としており、記憶の全てを手作業で入力しているため、データ量が不足しており、

データの拡張も困難である。その結果、研究の客観性や汎用性には限界がある。以上の理由から、新たな研究対象の検討を行うこととした。

次に、新たな研究対象として吉川英治版「三国志」を取り上げ、広く親しまれているキャラクターとの対話体験を提供するシステムの実現を目指した。この取り組みでは、「三国志」の膨大なテキストを 7000 以上の段落に分割し(図-3)、それらを text-text-embedding-3-small モデルを用いてベクトル化する仕組みを構築した。(図-4)このシステムにより、類似性の高いキーワードに基づく柔軟な検索と応答が可能となった。(図-5)

今後の課題としては、データ処理モデルの精度向上、角色対話の文脈一貫性の強化、倫理とプライバシー保護メカニズムの改善、異文化シナリオへの適応性テストが挙げられます。最終的には、ユーザーに「三国志」の登場人物と直接会話しているかのような没入感を提供するシステムの構築を目指している。

これにより、生成型 AI を活用した個人データの可能性をさらに広げていく。

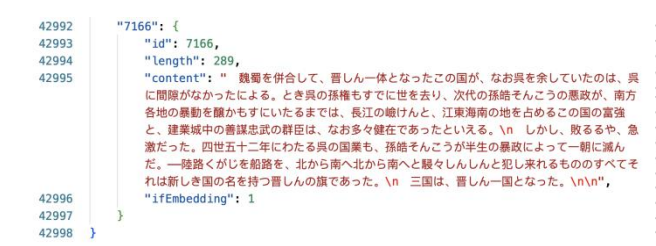


図-3 「三国志」を分割する

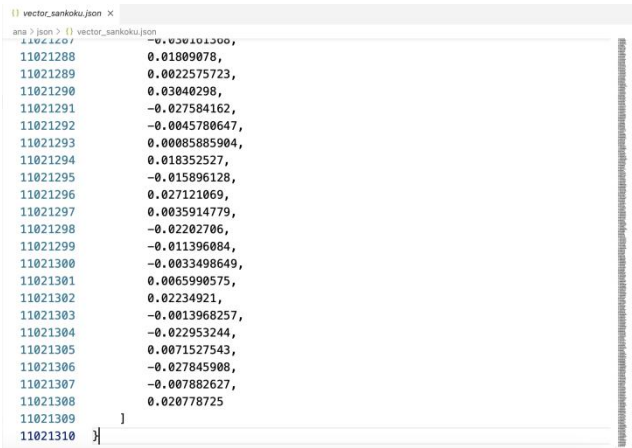


図-4 生成されたベクトルデータ



