

LLMによる説明文の生成と対照学習を用いた 日本酒-料理の相互推薦

Mutual Recommendation of Sake and Foods Using LLM-Based Descriptive Text Generation and Contrastive Learning

松田颯太^{1*} 尾崎 知伸¹
Souta Matsuda¹ Tomonobu Ozaki¹

¹ 日本大学文理学部情報科学科
¹ Department of Information Science, Nihon University

Abstract: This study proposes a mutual sake-food recommendation system to support consumers in judging pairings. The proposed system (1) generates sentences using an LLM for sake and food information and pairing suggestions, (2) embeds these sentences into a vector space via document embedding and contrastive learning based on sake-food relationships, and (3) finally recommends suitable sake-food pairs within this space. The proposed system, using approximately 1000 of sake and 600 of food, was evaluated both quantitatively through computational experiments and qualitatively through a questionnaire survey. The results showed that the proposed system has a certain degree of effectiveness.

1 はじめに

近年、観光や外食産業、個人の食習慣において、飲食物の組み合わせに対する理解の重要性が増している。日本酒と料理のペアリングは、日本の食文化において重要な要素であり、適切な組み合わせが双方の味わいを最大化するとされる。しかし日本酒は一般に、地域や製造方法によって味わいや香りが大きく異なるため、一般消費者が料理との相性を判断することは容易ではない[1]。また、日本酒離れの傾向も顕著であり、ある調査では若年層の70%、女性の74%が直近1年間に日本酒を飲んでいないことが報告されている[2]。本研究では、このような状況を改善し、また日本酒への関心を高めると共に料理との組み合わせを含めた具体的な楽しみ方を提案するための基礎技術として、日本酒と料理の特性を考慮した日本酒-料理の相互推薦システムを構築することを目的とする。

日本酒は、精米歩合、日本酒度、酸度、アルコール度数などの化学的特性に加え、風味や香りといった感覚的特性を持つ。一方で料理は、調理方法、味覚、香り、食材の組み合わせといった多様な要素・視点を含む。精度の高い相互推薦システムを実現するためには、個々の日本酒や料理が持つ詳細な特徴や多様な観点を考慮する必要がある。詳細は後述するが、本研究では、既

存手法である LLM-Rec[3] のアイディアに基づき、種々の観点における日本酒・料理の詳細情報を推薦に反映させることを試みる。具体的には、大規模言語モデル (Large Language Model, LLM) を用いて各日本酒・料理の情報を補完・拡張した説明文を生成した上で、文書埋め込み技術を用いて日本酒・料理をベクトル空間へと埋め込む。加えて、相性を考慮した日本酒-料理対や、類似性を考慮した日本酒-日本酒対と料理-料理対を学習データとして準備し、埋め込み空間上で対照学習を展開することで、日本酒・料理それぞれに関する埋め込みモデルを学習する。得られた埋め込みモデルを利用し、ベクトル空間上で類似度の高い日本酒-料理対を推薦対象とする。これらを通じ、日本酒・料理の詳細情報と多様な視点を考慮した、精度の高い相互推薦の実現を目指す。

本論文の構成は以下のとおりである。2章で関連研究について概説する。3章で提案手法を述べる。4章で評価実験について報告し、最後に5章でまとめと今後の展望を述べる。

2 関連研究

これまでに LLM を活用した推薦システムが数多く提案されている。

推薦において、対象を表現するタグ情報の設定は重要

*連絡先：日本大学文理学部情報科学科
〒 156-8550 東京都世田谷区桜上水 3-25-40
E-mail: chso21022@g.nihon-u.ac.jp

な要素となる。このことに関連し、文献[4]では、LLMを活用することによりマルチモーダルデータからタグを生成・抽出するシステムTagGPTが提案されている。またTagGPTはプロンプトを通じ、ユーザの意図や関心を反映した高品質なタグ集合の自動構築を実現している。

一方、テキストに基づく推薦システムでは、推薦アイテムに関する記述の不完全さが、推薦精度の劣化を招く大きな要因となる。この問題を軽減するため、文献[3]では、LLMを用いた説明テキストの拡張・生成を伴う推薦システムLLM-Recが提案されている。LLM-Recは、LLMに対する多様なプロンプトを用いて種々の側面からアイテムの記述情報を補完するとともに、これらの情報とユーザプロファイルとを擦り合わせることで、推薦の個人化を実現している。また文献[5]では、利用者が自然言語を用いて自由にニーズを表現できる推薦システムの実現を目指し、LLMによる指示遂行として推薦を実現する枠組みInstructRecを提案している。具体的には、柔軟で汎用的な指示形式を設計した上で、LLMを推薦システムに特化した形でファインチューニングすることで、順序推薦や個人化検索といった多様な推薦タスクに対応している。

LLMを活用する推薦システムでは、プロンプトの質が推薦システムの質へと直結する。プロンプト最適化手法として、文献[6]では、テキスト形式で表現されるプロンプトをベクトル系列として表現される連続プロンプトへと変換するプロンプト蒸留(PrOmpt Distillation, POD)アプローチが提案されている。これにより、LLMの汎用性を維持しつつ、ユーザーの意図やコンテキストをより適切に捉えた高品質な推薦の実現が期待される。

以上概観した通り、LLMの活用した推薦システムの高度化技術は多岐にわたる。本研究では、これらの高度化技術の中でも特にLLM-Rec[3]の考えに焦点を当て、推薦対象となる日本酒・料理の情報を拡張・補完した上で、ベクトル空間へと埋め込むアプローチを採用する。

3 提案手法

3.1 概要

本研究では、以下に示す3つの手順に従い、詳細な特徴や種々の観点を反映した日本酒と料理に関する埋め込みモデルを構築することで、同一埋め込み空間上での距離に基づく相互推薦システムを実現する。図1に、提案システムの全体像を示す。なおLLMにはOpenAIのGPT-4o[7]を、文書埋め込みモデルにはSentence-Bert[8]をそれぞれ用いる。

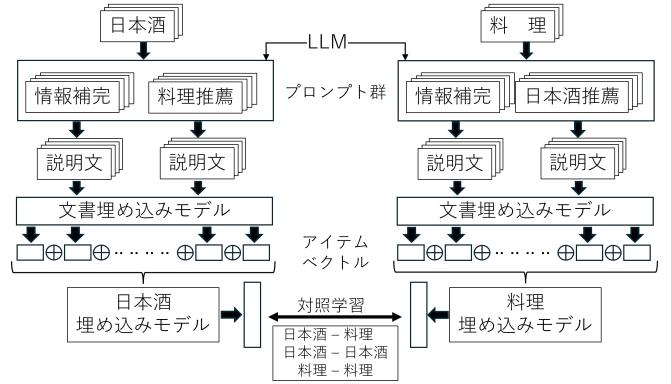


図1: 提案手法の概要

- 複数の観点からそれぞれの情報を引き出すプロンプトをLLMに与えることで、各アイテム（日本酒・料理）の詳細を補完・拡張する説明文集合を生成する。
- 生成した各観点からの説明文を、文書埋め込みモデルを用いてそれぞれベクトル化する。また、これらのベクトルをアイテム毎に連結することで、アイテムベクトルを構築する。
- 学習データとして、相性の良し悪しをクラスとする日本酒-料理対、および類似性の有無をクラスとする日本酒-日本酒対と料理-料理対を準備し、アイテムベクトルに関する対照学習[9]を行うことで、日本酒と料理に対する各埋め込みモデルを構築する

埋め込みモデル構築において、アイテムベクトルの構築（手順1と手順2）は、本質的にLLM-Rec[3]における方法を援用するものではあるが、日本酒や料理に特化した説明文生成プロンプトを準備することで、精度の向上を試みる。また対照学習（手順3）では、日本酒や料理に関する知識を基とした学習データの準備が必要となる。それについて、以下の節で詳細を説明する。

3.2 LLMを用いた説明文の生成

本研究では、日本酒と料理の特性を多角的に分析し、最適なペアリングを提案するため、日本酒の特性に基づく料理推薦と、料理の特性に基づく日本酒推薦の2つの観点からプロンプトを準備した。さらに、各アイテム（日本酒・料理）の情報補完を目的としたプロンプトを組み合わせることで、提案の精度を高めることを目指した。以下、それについて説明する。

3.2.1 日本酒に関するプロンプト

日本酒に関するプロンプトとして、日本酒情報補完プロンプトと料理推薦プロンプトの2種類を準備する。

日本酒情報補完プロンプト： このプロンプトは、日本酒の特性を深く理解し、料理との相性を科学的に説明するために準備した。料理との相性を説明させることで、ペアリング提案の精度を向上させることができ。具体的には、LLMに、多角的な日本酒特性の解釈と、特性間の相互作用を分析させることにより、精米歩合や酸度が風味に与える影響や日本酒度が料理とのバランスに与える効果、飲用温度による味覚の変化を考察し、それぞれの観点からペアリング提案の基礎情報を提供させる4つのプロンプトから構成される。

料理推薦プロンプト： 日本酒の特性は料理との相性に大きく影響を与える。そこで、LLMに対して数値的特性を分析させることで、科学的根拠のある具体的な提案をさせることを試みる。また、提案の多様性と実用性の確保を目的に、飲用温度や日本酒タイプによる味覚の変化を考慮させることとした。具体的には日本酒の特性（精米歩合、日本酒度、酸度、アルコール度数など）や、日本酒タイプ（薰酒、爽酒、醇酒、熟酒）、飲用温度に基づき、例えば、酸味や旨味を強調する料理や、特定の調理法に適した料理を提案するなど、各特性を引き立てる料理を提案する4つのプロンプトから構成される。

3.2.2 料理に関するプロンプト

日本酒に関するプロンプトと同様、料理に関するプロンプトとして、情報補完プロンプトと日本酒薦プロンプトの2種類を準備する。

料理情報補完用プロンプト： 4つのプロンプトから構成され、LLMに対し、料理に使用される材料や調理法、味覚の詳細を補完させると共に、各味覚が料理全体に与える影響や特定の食材・調理法が風味に与える効果、スパイスやハーブの香りが料理に与える役割を分析させ、日本酒との調和を考察させる。これにより、料理の特性を深く理解し、日本酒との相性をより正確に評価するため情報を提供が期待される。

日本酒推薦プロンプト： 料理の味覚や香りが日本酒との相性に強く影響を与えること考慮し、LLMに対し、調理法や食材の特性が日本酒の特性とどのように調和するかを分析させた上で、当該外料理に合う日本酒を推薦させる説明文を生成させる。具体的には、料理の基本味覚（甘味、酸味、苦味、塩味、旨味）、主要食

材、調理方法、香りに基づき、甘味や酸味の強い料理にはそれを調和させる日本酒を、スパイスの効いた料理には香りを補完する日本酒を選定など、料理を引き立てる日本酒を提案させる4つのプロンプトから構成される。

3.3 対照学習を通じた埋込モデルの構築

本研究では、日本酒・料理の各埋め込みモデルとして、文書埋め込みモデル（Sentence-Bert）の出力を連結したベクトルを受け取り、それを64次元の潜在空間へとマッピングするニューラルネットワークを構築・学習する。

各モデルは、入力層に加え、256次元の全結合中間層と64次元の全結合出力層の3層構造を基本とし、ReLU活性化関数、バッチ正規化、Dropoutを組み合わせることで、計算効率を維持しつつ、学習の安定性と高い汎化性能の両立を目指す構成を採用している。また学習には、コントラストロスを損失関数とする対照学習の枠組みを採用している。すなわち、学習データとして与えられる、日本酒-料理対および日本酒-日本酒対、料理-料理対の各対に対し、正例対に含まれるアイテム同士のベクトルは近くに、負例対に含まれるアイテム同士のベクトルは遠くにそれぞれ配置されるよう、各埋め込みモデルの重みを学習する。

4 評価実験

4.1 データセット

本研究では、日本酒に関するデータセットとして、“Sake dataset”[10]を使用した。このデータセットは約1,000件の日本酒情報から構成されており、各日本酒に関する属性として、銘柄、品目、酒造、生産地情報（都道府県、地域）、分類、造り、精米歩合、アルコール度数、日本酒度、酸度、アミノ酸度、甘辛度、使用米、酵母などが含まれている。このデータセットを対象に、欠損値を含むデータを除外し、各酒造サイトに掲載されている各日本酒に対する説明を追加することで、評価実験用のデータセットを構築した。

一方、料理に関するデータセットには、クックパッド株式会社が国立情報学研究所と協力して研究者に提供しているクックパッドデータセット[11]を使用した。各料理データには、料理名に加え、食材と調理手順の情報が含まれている。実験では、データセット全体から「様々な種類の料理を選ぶこと」を基準に620件の料理データを抽出して利用する。

準備した日本酒データおよび料理データを対象に、対照学習用のデータセットを構築する。日本酒-料理対は、

表 1: 対照学習用データのサイズ

	正例対数	負例対数
日本酒 - 料理	2,241	4,119
日本酒 - 日本酒	4,284	3,288
料理 - 料理	1,075	1,329

文献 [12, 13] を参考に相性が良いとされるペアリングを正例対として抽出した。一方、日本酒-日本酒対は、特定名称分類で類似する日本酒を絞り込み、さらにアルコール度数・精米度合いが近いものを選択することで正例対を準備した。また、料理-料理対に関しては、和食・洋食・中華料理などの料理ジャンルと肉料理・魚料理などのメイン食材別の分類を基準に正例対を準備した。なお、いずれも負例対は、正例対に含まれないアイテムの組み合わせをランダムに選択することで準備した。表 1 に、対照学習用データセットに含まれる正負例対数を示す。

4.2 推薦精度

提案手法の性能を評価するため、データセット全体を 7:1:2 の割合で学習例集合:検証例集合:テスト例集合の 3 つに分け、エポック数を 10 または 20 として各埋め込みモデルの学習を行った。また比較のために、対照学習に利用するデータセットを変えた 4 種のモデル

SF : 日本酒-料理対のみから学習したモデル

SFS : 日本酒-料理対および日本酒-日本酒対から学習したモデル

SFF : 日本酒-料理対および料理-料理対から学習したモデル

SFSF : 日本酒-料理対および日本酒-日本酒対、料理-料理対から学習したモデル

を構築している。評価尺度には、テスト例集合における平均コサイン類似度、適合率、再現率、NDCG@10 を採用し、再現率・適合率の計算に必要となる閾値は検証例集合を基準に決定している。表 2 に実験結果を示す。

表 2 より、提案モデルである SFSF は、適合率において SFS・SFF に及ばないものの、その他の指標において他のモデルを上回る高い性能を示していることが確認できる。また適合率が高い SFF は、再現率に関して性能が低く、特定の関係性への依存が示唆される。これらの結果から、提案モデルが十分な性能を有することに加え、モデルの学習において、複数の関係性を総合的に利用することが有効であることが示された。

表 2: モデル性能の比較

モデル	平均 cos 類似度	適合率	再現率	NDCG @10
エポック数 = 10				
SF	0.2677	0.4379	0.3630	0.3712
SFS	0.3152	0.4511*	0.4128*	0.5266
SFF	0.2823	0.4606*	0.3215*	0.4337
SFSF	0.4654	0.4492*	0.5885**	0.5392
エポック数 = 20				
SF	0.2974	0.4481	0.3643	0.4263
SFS	0.3275	0.4659*	0.4605*	0.5431
SFF	0.2700	0.4935*	0.3259*	0.6058
SFSF	0.4110	0.4561*	0.5265**	0.6459

SF を基準とし *: $p < 0.05$, **: $p < 0.01$

4.3 プロンプト評価

本研究で採用した情報補完および推薦プロンプトの有効性を評価するために、説明文生成に利用するプロンプトを制限した上でモデルの学習を行う比較実験を行った。以下に比較対象として利用するプロンプトを示す。また実験結果、すなわち日本酒-料理対および日本酒-日本酒対、料理-料理対から学習したモデルの精度を表 3 に示す。

Sr_N : 日本酒に対して、料理推薦プロンプトを用いる。料理に関しては説明文生成を行わず、タイトル、食材、手順を連結した文する。

Sc_N : 日本酒に対して、情報補完プロンプトを用いる。料理に関しては説明文生成を行わず、タイトル、食材、手順を連結した文する。

SrSc_N : 日本酒に対して、料理推薦プロンプトおよび情報補完プロンプトを用いる。料理に関しては説明文生成を行わず、タイトル、食材、手順を連結した文する。

N_Fr : 料理に対して、日本酒推薦プロンプトを用いる。日本酒に関して説明文生成を行わず、説明文をベクトル化する。

N_Fc : 料理に対して、情報補完プロンプトを用いる。日本酒に関しては説明文生成を行わず、説明文をベクトル化する。

N_FrFc : 料理に対して、日本酒推薦プロンプトおよび情報補完プロンプトを用いる。日本酒に関して説明文生成を行わず、説明文をベクトル化する。

Sr_Fr : 日本酒に対して、料理推薦プロンプトを用いる。料理に対して、日本酒推薦プロンプトを用いる。

表 3: 利用プロンプト別の精度

プロンプト	平均 cos 類似度	適合率	再現率	NDCG @10
Sr_N	0.3314	0.3416	0.2959	0.3882
Sc_N	0.3570	0.4478	0.5607	0.5022
SrSc_N	0.3924	0.4453	0.4826	0.3821
N_Fr	0.4054	0.3637	0.5272	0.5646
N_Fc	0.4056	0.3598	0.5189	0.5384
N_FrFc	0.4110	0.3421	0.4265	0.4759
Sr_Fr	0.4116	0.4463	0.5067	0.5452
Sc_Fc	0.4231	0.4754	0.5623	0.5787

Sc_Fc : 日本酒に対して、情報補完プロンプトを用いる。料理に対して、情報補完プロンプトを用いる。

実験結果より、Sc_N や Sc_Fc など、日本酒情報補完プロンプトを含む場合は、平均コサイン類似度・適合率・NDCG@10 が全体的に向上する傾向が確認でき、特に Sc_Fc において、NDCG@10 が 0.5787 を記録し、他の条件を上回った。一方、N_Fr や N_Fc など、料理プロンプトのみを利用した場合は性能が低く、日本酒に関して説明文を補完・生成することが重要であることが示唆された。また、この実験におけるすべての条件において、すべてのプロンプトを利用した場合に対する精度劣化が確認でき、精度の高い相互推薦を行うためには日本酒・料理の双方において説明文を補完・生成することが有効であることが示された。

4.4 定性評価

提案手法を定性的に評価するため、日本酒の関連業界での就業経験を有し、日本酒と料理のペアリングに関して一定の知識を持つ男女 10 名を対象に、以下に示す 2 種類のアンケート調査（設問数はそれぞれ 10）を実施した。

アンケート 1 : 各設問において、1 つの日本酒と 5 つの料理を提示し、提示された日本酒と最も合うと考えられる料理を選択してもらう。

アンケート 2 : 各設問において、日本酒-料理対を提示し、その組み合わせの良さを 5 段階リッカード尺度（1: 非常に良い、2: 良い、3: 普通、4: 良くない、5: 非常に良くない）で回答してもらう。

両アンケートとともに、提案手法で算出される類似度スコアに基づき、不自然さを感じない範囲で比較的上位に含まれる 5 件の日本酒-料理対を上位ペア群、比較的下位に含まれる 5 件を下位ペア群として抽出、利用している。アンケート 1 では、抽出された各上位（下

表 4: アンケート 1 の結果：各日本酒-料理対の得票数

日本酒	料理_1	料理_2	料理_3	料理_4	料理_5
上位ペア					
日本酒_P1	6	2	1	1	0
日本酒_P2	6	3	1	0	0
日本酒_P3	5	3	1	1	0
日本酒_P4	5	2	2	1	0
日本酒_P5	3	4	2	1	0
下位ペア					
日本酒_N1	6	2	0	0	2
日本酒_N2	4	3	0	0	3
日本酒_N3	4	2	1	0	3
日本酒_N4	3	3	1	0	3
日本酒_N5	7	2	1	0	0

位) ペアについて、ペアに含まれる料理を基準とし、相性が良い（悪い）と思われる範囲の中で日本酒との相性の降順（昇順）に料理を 4 件選択することで設問を準備した。

アンケート 1 の結果を表 4 に示す。表中において、下線は設問作成に基となった上位・下位ペアを表す。また、表中の料理 1～料理 5 は、各設問において提示される 5 件の料理に対応し、付与された番号は提案手法により日本酒との相性が良いと判断された順序を表す。実験結果より、上位ペアでは提案手法が提示した日本酒-料理対に対して高い評価が集まっていることが分かる。一方、下位ペアに関しては、料理に対する評価が分散する傾向が認められ、相性が悪いペアリングに対しては専門家でも優劣を判断することが難しいことが伺える。

アンケート 2 では、上位ペア・下位ペアを直接被験者に提示した。結果を表 5 に示す。結果より、上位ペアに関しては、すべての日本酒-料理対において「1: 非常に良い」と「2: 良い」の和が 50% 以上であることが分かる。また、「5: 非常に良くない」との回答はなく、「4: 良くない」と合わせても、否定的な意見は各対において最大 30% に抑えられている。一方、下位ペアに関しては、回答が分散してはいるが、「1: 非常に良い」と「2: 良い」の和は最大で 40% であり、アンケートに回答した半数以上の専門家がポジティブな印象を抱いていないことが伺える。これらの結果から、提案手法を用いることで、人間の直感に概ね合致する日本酒-料理の相互推薦が実現できると考えられる。

5 まとめ

本研究では、大規模言語モデル (LLM) を活用した日本酒と料理の相互推薦手法を提案する。日本酒と料

表 5: アンケート 2 の結果:回答数

	リッカード尺度の値				
	1	2	3	4	5
上位ペア					
日本酒-料理対_P1	0	5	4	1	0
日本酒-料理対_P2	0	6	2	2	0
日本酒-料理対_P3	0	5	2	3	0
日本酒-料理対_P4	6	2	2	0	0
日本酒-料理対_P5	2	4	4	0	0
下位ペア					
日本酒-料理対_N1	2	1	2	3	2
日本酒-料理対_N2	0	3	2	4	1
日本酒-料理対_N3	2	2	3	3	0
日本酒-料理対_N4	2	1	7	0	0
日本酒-料理対_N5	0	1	5	4	0

理の特性を的確に捉えるため、複数の観点からプロンプトを設計し、各項目の特徴を詳細に記述した文章を生成する。さらに、対照学習 (contrastive learning) の枠組みを活用し、生成された記述文を同一ベクトル空間に埋め込むことで、日本酒と料理の類似性を適切に表現するモデルを構築した。

提案手法の有効性を検証するため、定量的な実験を実施し、推薦精度の向上を確認した。特に、日本酒-料理対のみならず、日本酒-日本酒対や料理-料理対の関係を学習に取り入れることで、埋め込みの精度が向上することを明らかにした。また、プロンプトの設計が推薦精度に大きく影響を与えることを示し、効果的なプロンプト設計の重要性を実証した。

さらに、定性的な評価を通じ、提案手法による推薦結果が人間の直観と整合的であることを確認した。これは、本手法が日本酒と料理の特性を適切に捉え、実用的な推薦を実現できることを示唆している。

今後の課題として、プロンプトのさらなる多様化と外部データの統合が挙げられる。特に、料理の調理法や食文化、地域性などの情報を考慮することで、より精度の高い推薦が可能となると考えられる。また、個人の嗜好や状況に応じた推薦を実現するため、ユーザーのフィードバックを取り入れたパーソナライズド推薦や、文脈依存型の推薦手法の開発を進める予定である。

謝辞：本研究の遂行にあたり、アンケートにご協力いただいた皆様に心より感謝申し上げます。本研究では、国立情報学研究所の IDR データセット提供サービスによりクリックパッド株式会社から提供を受けた「クリックパッドデータセット」を利用した。

参考文献

- [1] 石まつ3代目:料理と日本酒のマッチングの会, <http://ishimatsu.cc/archives/857>, 2017. (最終アクセス日: 2025年02月15日)
- [2] 楠の川酒造株式会社:「全国の男女に聞く「日本酒」の飲用実態調査・楠の川酒造調べ」, <https://prtmes.jp/main/html/rd/p/000000030.000071925.html>, 2022. (最終アクセス日: 2025年02月15日)
- [3] H. Lyu, S. Jiang, H. Zeng, Y. Xia, Q. Wang, S. Zhang, R. Chen, C. Leung, J. Tang, and J. Luo : LLM-Rec: Personalized Recommendation via Prompting Large Language Models, In *Findings of the Association for Computational Linguistics: NAACL 2024*, pp.583–612, 2024.
- [4] C. Li, Y. Ge, J. Mao, D. Li, and Y. Shan : TagGPT: Large Language Models are Zero-shot Multimodal Taggers, arXiv preprint arXiv:2304.03022, 2023.
- [5] J. Zhang, R. Xie, Y. Hou, X. Zhao, L. Lin, and J.-R. Wen : Recommendation as Instruction Following: A Large Language Model Empowered Recommendation Approach, *ACM Transactions on Information Systems*, 2024.
- [6] L. Li, Y. Zhang, and L. Chen : Prompt Distillation for Efficient LLM-based Recommendation, *Proc. of the 32nd ACM International Conference on Information and Knowledge Management*, pp.1348–1357, 2023.
- [7] OpenAI et, al. : GPT-4 Technical Report, arXiv preprint arXiv:2303.08774, 2023.
- [8] N. Reimers and I. Gurevych : Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks, *Proc. of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*, pp.3982–3992, 2019.
- [9] D. Chicco : Siamese Neural Networks: An Overview, In: Cartwright, H. (eds), *Artificial Neural Networks*, pp.73–94, 2021.
- [10] sake_dataset: Sake (Japanese Rice Wine) dataset / 日本酒データセット. 銘柄ごとにアルコール度数・精米歩合・日本酒度等を数値化した整形済みデータ, https://github.com/yoichi1484/sake_dataset, (最終アクセス日: 2025年02月15日)
- [11] クックパッド株式会社: クックパッドデータ, 国立情報学研究所情報学研究データリポジトリ, <https://doi.org/10.32130/idr.5.1>, 2015.
- [12] 葉石かおり: 『日本酒のペアリングがよくわかる本』, シンコーミュージック, 2017.
- [13] 美味しい日本酒: 日本酒のペアリングをタイプ別に解説! 具体例やおすすめ料理も紹介, <https://azumarikishi.co.jp/media/pairing>, 2022. (最終アクセス日: 2025年02月15日)