

「食材 toVec」を用いた食材推薦とレシピ生成の提案 Proposal for recommending ingredients and generating recipes using "Ingredient to Vec"

加藤 翔大[†]
Shota Kato

神田 竜之介[‡]
Ryunosuke Kanda

市川 治[†]
Osamu Ichikawa

1. はじめに

大規模なデータを自己教師あり機械学習することで、テキスト・音声・画像といったデータを潜在表現に変換する技術が注目を集めている。料理の分野についても、文章であるレシピデータを BERT などで埋め込み表現にする試みが行われている[1]。しかし、レシピのテキストには食材の表現以外に、「煮る」「焼く」「きつね色に変わったら」「少々」など加工や状況に関する修飾語が多く含まれており、レシピテキストをそのまま学習すれば、それらの意味までを埋め込んだ潜在表現となる。

食材そのものの役割を表現するベクトルを抽出するには、レシピテキストそのものではなく、食材リストを学習データとして使用する方法が考えられる。文献[2]は基本的にその方式に則っているが、Word2Vec 法[3]による分散表現を取得する際に、食材リストだけでなく、料理のカテゴリー情報や食感などの特徴情報も合算している。本報告では、学習データを食材リストに限定し、どの食材とどの食材が共起しやすいかという観点のみで分散表現を学習することとした。すなわち、この空間ベクトルは食材のみで構成される。本報告ではこの表現を「食材 toVec」による分散表現と呼び(以下短縮して**食材 toVec**と表記する)、その利用方法について検討する。

2. 従来研究

料理レシピを分散表現化して応用する従来研究としては、2018年に梅本 晴弥氏、豊田 哲也氏、大原 剛三氏が発表した「料理レシピの分散表現を用いた代替食材の発見手法」[4]という論文がある。この論文では、Word2Vec による食材名の分散表現に加えて、Doc2Vec による料理レシピの分散表現を利用し、それら 2 つの分散表現から代替食材を発見する手法を提案している。本報告では、食材だけで分散表現を学習し、食材の共起関係をより精密に獲得することで、従来研究とは異なる利用方法を提案する。

3. クックパッドデータセット

本報告では、レシピデータとしてクックパッドデータセット[5]を使用する。本データは、2014年9月30日までにクックパッドに公開された 1715595 個のレシピを SQL で抽出可能なデータベースとして提供されたものである。データ内には、レシピに関するテーブルと献立に関するテーブルが含まれており、それぞれに材料データや調理手順、カテゴリデータなどが含まれていた。




図 1 肉を含むレシピベクトルの可視化




図 2 油を含むレシピベクトルの可視化

4. 食材 toVec

食材 toVec では、3 節の 1715595 個のレシピから、1000 回以上出現する頻出食材 1032 種を対象とし、その 1032 種の食材だけで構成されるレシピ 557475 個を用いる。また、1032 種の食材については表記ゆれを取り除いたため、最終的な語彙数は 459 となっている。これら 557475 個のレシピデータからランダムに抽出した 100000 個のデータを使用し、**食材 toVec** を学習する。本報告では、出現する語彙数が 459 と少なくなっている。そのため、次元数は 100 とした。Window 幅は 10、学習アルゴリズムは CBOW とした。

また、作成した食材ベクトルから、レシピごとに含まれている材料の食材ベクトルを足し合わせて材料数で割ることによってレシピベクトルを得る。得られたレシピベクトルを T-

[†] 滋賀大学データサイエンス学部 Faculty of Data Science, Shiga University

[‡] (卒業生, graduate) 滋賀大学データサイエンス学部 Faculty of Data Science, Shiga University

SNE で次元削減を行い、2 次元で可視化を行う。T-SNE は高次元データを 2 次元もしくは 3 次元に変換して可視化を行うアルゴリズムである。今回は 100 次元のレシピベクトルを 2 次元に次元削減し、個々のレシピベクトルに含まれる食材について可視化を行った。その結果を図 1 に示す。

レシピベクトルに含まれる肉の種類ごとにクラスターができていくことが確認できる。また、豚肉や鶏肉は、牛肉に比べてクラスターが広範囲にあるため、使用できる調理の幅も広いことがうかがえる。

加えて、別の食材で可視化した結果を図 2 に示す。

レシピベクトル全体に広く油が含まれていることが確認できる。また、油の種類によって明確にクラスターが分かれていることから、料理のジャンルによって使われる油に傾向があることがわかる。

5. 食材推薦

本報告で提案する食材推薦システムは、入力食材に不足していると考えられる食材を、**食材 toVec** を用いて 1 品推薦するというシステムである。本報告では、レシピを構成するうえで、重要度の高い食材が推薦される「多数決法」と、普段あまり使用されない珍しい食材が推薦される「IDF 法」の二つを提案する。

また、食材推薦では 3 節の 1715595 個のレシピから「カレー」に分類されている 1414 個のデータを用いる。1414 個の中からランダムに 100 個抽出し「テストデータ」とした。残りの 1314 個を「学習データ」とした。以上のデータから、4 節と同様の条件で**食材 toVec** を作成した。ただし、食材の語順はランダムに入れ替えて学習データを拡張している。次に、「ある単語が出現する文書が文書全体の中でどのくらいの割合を占めていたかの逆数」を表す指標である IDF を用いて、作成した食材ベクトルに重み付けを行い、IDF で重み付けした食材ベクトルからレシピベクトルを得た。つまり、「カレー粉」など頻出する食材の重みを小さくし、「チョコレート」など低頻度の食材の重みを大きくすることにより、レシピベクトルの違いを際立たせた。

上記の IDF で重み付けした**食材 toVec** を用いて食材推薦を行う。本食材推薦システムは、入力食材から入力食材ベクトルを作成し、レシピベクトルと比較することで、コサイン類似度の大きいレシピ上位 10 個を抽出する。その上位 10 個のレシピに出現する全ての食材を「多数決法」や「IDF 法」に適用することで食材の推薦を行う。

5.1 多数決法

多数決法は、上位 10 個のレシピに出現する全ての食材から入力食材を除いたものの中で、食材の出現回数を比較し、登場回数の多いもの上位 k 個を推薦するといったものである。この手法は、登場回数の多いものが推薦されることから、レシピを構成するうえで重要度の高い食材が推薦される手法である。

5.2 IDF 法

IDF 法は多数決法と同様に、上位 10 個のレシピに出現する全ての食材から入力食材を除いたものの中で、食材ごとの IDF の値を比較し、最も大きいものを推薦するといったものである。この手法は、IDF の値が大きく、その食材が

含まれるレシピが珍しいことから、レシピで普段あまり使用されない珍しい食材が推薦される手法である。

5.3 評価実験

評価実験は、2 つの実験方法で行う。実験 I は「多数決法」について、機械的な評価実験により食材推薦システムの精度を評価する。実験 II は「多数決法」と「IDF 法」のそれぞれについて、アンケートをとることで、人の主観による食材推薦システムの評価を行う。

5.3.1 実験 I

5 節で抽出した 100 個の「テストデータ」をそれぞれレシピ 1~100 とする。実験の工程を以下に示す。

- ① レシピ n から 1 つ食材を除く。除いたものを「正解食材」とする。(n は 1~100)
- ② 残った食材を入力食材とする。
- ③ 「多数決法」を行い推薦された k 個の食材を「推薦食材」とする。
- ④ 「推薦食材」の中に「正解食材」が含まれていたなら「正解」とする。
- ⑤ ①~④ をレシピ 1~100 まで行い、正解率を出す。
- ⑥ ①~⑤ を 100 回行い、平均正解率を出す。

また、「カレールー」「カレー粉」はカレーを作るうえで使用される可能性が非常に高く、入力食材として忘れることが考えにくいことや、「塩」「水」といったどの料理にも含まれる食材について、「推薦食材」や「正解食材」としての実用性が低いと考えられるため、例外処理を行って除外した。以上の実験を「多数決法」で推薦する食材数 k 個を 1,3,5,8 個と設定して行った結果を表 1 に示す。

k	平均正解率
1	0.22
3	0.34
5	0.38
8	0.45

表 1 実験 I の平均正解率

k の値を大きくすると平均正解率も大きくなっていることがわかる。 $k=2$ の場合は平均正解率が 0.22 であるため、少なくとも 5 回に 1 回は正しい食材を推薦することが可能である。 $k=8$ の場合は平均正解率が 0.45 であるので、約 2 回に 1 回は推薦食材の中に正しい食材が含まれているという結果になった。よって、 k の値を大きくすることでより高い精度で食材の推薦が可能であることが確認できる。

5.3.2 実験 II

実験 II の評価アンケートの手順を以下に示す。

- ① レシピ n から 1 つ食材を除く。除いたものを「正解食材」とする。
- ② 残った食材を入力食材とする。
- ③ 「多数決法」を行い、頻度が最も大きい食材と頻度が 5 番目に大きい食材、頻度が 8 番目に大きい食材を抽出する。
- ④ 「IDF 法」を行い、IDF が最も大きい食材を抽出する。

⑤入力食材に対して、あと一品食材を追加する際の適合度を、頻度が最も大きい食材を推薦食材、頻度が 8 番目に大きい食材を対立食材としてそれぞれ追加し、テストケースとする。その適合度を被験者に 1~5 点で評価してもらう。

⑥入力食材に対して、IDF が最も大きい食材を推薦食材、頻度が 5 番目に大きい食材を対立食材としてそれぞれ追加してテストケースを作成する。あと一品食材を追加する際のユニーク度を被験者に 1~5 点で評価してもらう。

また、実験 I と同様に例外処理を行った。本実験における被験者への指示として、「適合度の高いものとは、このレシピのカレーに入っている不自然ではなく、追加しても食材の味を損なわず美味しさを引き上げそうなもの」を指し、「ユニーク度の高いものとは、このレシピの材料としては思いつきにくいが入っていると味が引き立つと思われるもの」を指すと指示した。なお、被験者は同じ研究室に所属するメンバー 15 人である。以上の実験をテストデータからランダムに 10 レシピ抽出して行い、得られたそれぞれ 150 件のアンケート回答の結果を表 2 に示す。

	推薦食材	対立食材
多数決法	3.95	3.13
IDF法	3.16	3.05

表 2 実験 II の平均得点

多数決法の推薦食材と対立食材の平均得点を比較すると、推薦食材の方が大きいことから、多数決法による食材の推薦結果は、人間の感覚とあっているといえる。また、IDF 法についても推薦食材の平均得点と対立食材の平均得点を比べると、わずかにではあるが推薦食材の得点が高いことから優位性があることが確認できるため、IDF 法が効果的であるといえる。

6. レシピテキスト生成

4 節の 557475 個のレシピデータからランダムに抽出した 10000 個のデータを用いて、食材を入力としてレシピテキストを出力する機械学習モデルを作成する。学習用データ 9500 個、テスト用データ 500 個とした。本報告では LSTM+Attention モデルと Transformer(T5)モデルそれぞれで学習を行い、精度を比較する。

6.1 LSTM+Attention モデル

LSTM+Attention を用いた食材を入力とするレシピテキストを生成する機械学習モデルでは、隠れ層の次元数を 256、epochs を 50 として学習を行った。また、入力する食材の埋め込み層については、モデルの学習中に自然に得られる表現を使用したものと、4 節で作成した**食材 toVec**を使用したものとで 2 つのモデルを学習した。

6.2 T5 モデル

本報告で用いる T5 モデルは sonoisia 氏によって公開されている日本語 T5 事前学習済みモデル[6]をファインチューニングすることで作成した。学習時の epochs は 20 とした。

6.3 評価実験

テスト用データ 500 個を使用し、生成されたレシピテキストの精度評価を行う。評価実験は、2 つの実験方法を用い、実験 I は BLEU、実験 II は ROUGE で精度を評価する。

6.3.1 実験 I

実験 I は BLEU を用いて精度を評価する。BLEU とは、機械翻訳において精度を評価するための指標で、0 から 1 までの値をとる。値が 1 に近づくほど精度が高いことを示す評価方法である。しかし、BLEU スコアは文章の一致率を N グラムによって算出しているため、特定の N グラムでの一致がない場合にスコアが急激に 0 に近づいてしまう問題がある。本報告では、スコアを 0 にならないようにするために、python の NLTK ライブラリに含まれる、SmoothingFunction を適用した手法 7 で精度評価を行う。その結果を表 3 に示す。

	LSTM埋め込みなし	LSTM埋め込みあり	T5
平均BLEU	0.069	0.067	0.099

表 3 実験 I の精度評価

LSTM+Attention モデルでは、事前に作成した埋め込みベクトルの有無による BLEU スコアの変化は見られなかった。しかし、転移学習を施した T5 モデルについてはわずかながら精度が向上した。しかし、いずれも 0.1 を下回る低い精度となっているため、改善が必要である。

6.3.2 実験 II

実験 II は ROUGE を用いて精度を評価する。ROUGE とは、要約や文章生成の精度評価に用いられる指標で、0 から 1 までの値をとる。値が 1 に近づくほど精度が高いことを示す評価方法である。また、ROUGE には「ROUGE-N」や「ROUGE-L」、「ROUGE-BE」といった種類があるが、本報告では、比較する文章における 1 単語ごとの一致度を評価する「ROUGE-1」と、比較する文章の一致する最長の単語列を評価する「ROUGE-L」で精度評価を行う。その結果を表 4 に示す。

	LSTM埋め込みなし	LSTM埋め込みあり	T5
平均ROUGE-1	0.104	0.124	0.361
平均ROUGE-L	0.067	0.078	0.262

表 4 実験 II の精度評価

ROUGE-1 スコアは、LSTM+Attention モデル(埋め込みなし)、LSTM+Attention モデル(埋め込みあり)、T5 モデルの順で高くなっており、特に T5 モデルのスコアが高いことから、正解データとの 1 単語ごとの一致度が高いといえる。また、ROUGE-L スコアについても T5 モデルのスコアが最も高く、比較する文章の一致する最長の単語列を評価していることから、よりレシピテキストの文脈を組み込んだ生成ができているといえる。

また、T5 モデルで生成されたレシピテキストで ROUGE-1、ROUGE-L スコアともに最も高かったものを表 5 に示す。

入力	強力粉,薄力粉,練乳,牛乳,バター,砂糖,塩,イースト
生成文	ドライイースト以外の材料をにセット, ドライイーストは所定のポケットにセット,食パンコース、焼き色でスタート
正解文	ドライイーストは所定の場所へ 他の材料を全てホームベーカリーへセットして、食パンコース、焼き色淡で、スタート、

表 5 最高スコアのレシピテキスト生成

表 5 に示した生成文は ROUGE-1 スコアが 0.714、ROUGE-L スコアが 0.571 となっている。1 単語ごとの一致率やレシピテキストの文脈を組み込んだ生成ができていることがわかる。

7. おわりに

本報告では、食材リストのみを入力として Word2Vec を用いて分散表現を学習し、その応用について提案を行った。大量の食材リストを用いることにより、その食材の特性がベクトルに埋め込まれるということを 2 次元の可視化により確認した。また、カレーなど限定されたメニューにおいて足りない食材一品を推薦する仕組みを構成できるということを確認した。一方で、食材リストからレシピテキストを生成する試みについては課題が残る結果となった。

謝辞

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ックパッド株式会社から提供を受けた「クックパッドデータセット」を利用した。

参考文献

- [1] 山下 皓太郎, 伊藤 史世, 蓮本 恭輔, 後藤 正幸, "分散表現を用いたレシピの多様性の分析モデルに関する一考察", The 35th Annual Conference of the Japanese Society for Artificial Intelligence(2021)
- [2] 矢野 達也, 林 豊洋, 大橋 健, "単語のベクトル表現を用いたレシピ推薦システム", JSAI Technical Report SIG-Challenge-053-4 (2019)
- [3] Tomas Mikolov: Efficient Estimation of Word Representations in Vector Space, arXiv:1301.3781 [cs.CL](2013)
- [4] 梅本 晴弥, 豊田 哲也, 大原 剛三, "料理レシピの分散表現を用いた代替食材の発見手法", 行動変容と社会システム vol.03(2018)
- [5] Jun Harashima, Michiaki Ariga, Kenta Murata, and Masayuki Ioki, "A Large-Scale Recipe and Meal Data Collection as Infrastructure for Food Re-search", In Proceedings of the 10th International Conference on Language Resources and Evaluation (LREC 2016) . 2455–2459 (2016).
- [6] sonoisa, (2021) t5-japanese[Source code]. <https://github.com/sonoisa/t5-japanese>
- [7] 野沢健人, 中岡義貴, 山本修平, 佐藤哲司: word2vec を用いた代替食材の発見手法の提案 (データ工学), 電子情報通信学会技術研究報告= IEICE technical report: 信学技報, Vol. 114, No. 204, pp. 41-46 (2014).
- [8] Le, Q. and Mikolov, T.: Distributed representations of sentences and documents, International Conference on Machine Learning, pp. 1188–1196 (2014).