

レシピでの共起確率を考慮した食材分散表現の構築

吉丸 直希[†] 木村 優介[‡] 寺本 優香[§] 波多野 賢治[†][†]同志社大学文化情報学部 [‡]同志社大学大学院文化情報学研究科[§]同志社大学文化遺産情報科学調査研究センター

1 はじめに

食に関するさまざまなタスクを計算機で解決する目的で、各食材を正確に表現する食材の分散表現構築が必要とされている。しかし、食材には味や見た目などさまざまな特徴が存在するため、これらを適切に分散表現として表現することが食メディア研究の大きなテーマである。

食タスクの一つである食材の組合せに関する研究として FlavorGraph [1] がある。調理において食材の相性を考慮すること重要だが、その知識は経験的な側面が多く全ての組合せを把握することは難しい。この問題を解決するため、FlavorGraph ではレシピにおける食材の共起関係から食材の分散表現を構築している。しかし、この手法では共起のしやすさを無視し、同じ確率で食材が共起するものとして扱っているため、共起関係を正確に表しているとは言えない。

そこで本研究では、食材の共起関係の程度をより緻密に考慮した食材の分散表現を構築する。

2 関連研究

Park et al.(2021) は食材の組合せ問題を解決するために、レシピに登場する食材の共起関係と食材に含まれる化合物の関係を表したグラフである FlavorGraph を構築している [1]。FlavorGraph は食材と化合物が混在した異種グラフであり、異種グラフ埋め込み手法である Metapath2vec [2] に適用することで、グラフのノードにあたるベクトル、つまり食材の分散表現を得ている。共起関係を表すグラフを構築する際、レシピに登場する食材をノード、レシピにおける共起をエッジとしている。グラフ埋め込み手法では、グラフのノードをその近辺のパスで表現しそれを入力としてモデル構築を行う。しかしその方法では、パスの集合で表現される食材の組合せのされやすさは考慮されておらず、生成される分散表現の正確さに問題が生じる可能性が

Constructing Node Embeddings using Food Co-occurrence Statistics in Recipes

[†]YOSHIMARU Naoki, [‡]KIMURA Yusuke, [‡]TERAMOTO Yuka, [†]HATANO Kenji

[†]Faculty of Culture and Information Science, Doshisha University [‡]Graduate School of Culture and Information Science, Doshisha University [§] Research Center for Knowledge Science in Cultural Heritage, Doshisha University

ence in Cultural Heritage, Doshisha University




図 1: パス生成確率の比較

ある。

3 提案手法

本研究では、正確性に問題がある既存手法に対し、食材の共起確率を考慮した食材分散表現の新たな構築方法を提案する。食材の共起を確率で表現するために、式 (1) で表される NPMI スコア [3] を用いる。

$$\text{NPMI}(x; y) = \left(\log \frac{p(x, y)}{p(x)p(y)} \right) / -\log p(x, y) \quad (1)$$

ここで x, y はレシピに登場する食材を表し、 $p(x)$ は食材 x がレシピに登場する確率、 $p(x, y)$ は食材 x, y が同時にレシピに登場する確率を表す。NPMI スコアの意味について、レシピで一度も同時に登場しないと -1 、全てのレシピで同時に登場すると 1 になるため、どれほどその食材同士が一緒に使われるかを表す指標になる。

既存手法と提案手法の違いを図 1 に示す。図 1 は隣接するノードが二つある場合の例で、先行研究では単にエッジが貼られているため、食材同士の関係を正確に捉えていない。一方、本手法ではあるノードと隣接するノード間にある NPMI スコアの合計が 1 になるようにそれぞれ変換し、その値を次にパスが生成される確率として捉えパスの集合を生成する。そのため、図 1 の提案手法では $n_1 - n_2$ の方が値が高いため、その関係が含まれたパスがパス集合の中に多く生成される。

本手法により、NPMI スコアが高い食材同士の共起が度合いが反映されやすくなり、得られる食材分散表現はこれらの情報を反映しており、結果として食材の分散表現が精緻化される。

4 評価実験

本研究の提案手法により得られた食材分散表現の有効性を確かめるため、多項ロジスティック回帰分析とSVMを用いて食材を分類する。分類する項目は肉や魚など計8個の食材カテゴリとする。これにより栄養学上での分類と機械による分類の一致を測ることができ、どれほど正確に食材をベクトルで表現できているかを確かめることが可能になる。評価指標として各カテゴリにおける分類の精度を測ることができる macro $F_1(F_1^M)$ と全カテゴリにおける分類の精度を測ることができる micro $F_1(F_1^\mu)$ を用いる。結果は表1になり、提案手法の方が食材を正確に表すことができていると言える。

表 1: 多クラス分類の結果

	多項ロジスティック		SVM	
	先行研究	提案手法	先行研究	提案手法
F_1^M	0.6549	0.7348	0.6591	0.7341
F_1^μ	0.6562	0.7188	0.6562	0.7188

また食材の組合せ推薦に関する評価を、Knapsak DietDish¹という栄養学や薬学などの文献から収集されたデータセットを用いて行った。このデータセットは日本語で記載されているため、各食材を翻訳し食材ノード名と照合することで508組の食材組合せを得た。これらを用いて組合せ推薦を行い、MAP@kとRecall@kの指標を用いて評価する。組合せ推薦では、食材分散表現同士のコサイン類似度を計算し、その値が大きいものを良い組合せとして扱う。評価指標のMAP@kは順位kまでで正解した項目の適合率を平均する指標で、Recall@kは同じく順位kまでの再現率を平均する指標である。k=30の場合におけるMAP@k、Recall@kの結果を図2に示す。全体的に提案手法の方が精度良く推薦できていることがわかる。

組合せ推薦で正解した食材の数とその食材ノードNPMIスコアを合計した値の相関係数を計算した。相関を見ることで、本手法が考慮する共起確率の度合いが組合せ推薦においてどれほど有効であるかを確かめることができる。k=10,100,1000において計算した結果、表2の通り先行研究よりも高い相関が見られた。以上より組合せ推薦において本手法が有効であると考えられる。向上した理由として、本手法では共起頻度が高い食材の関係を豊富に含んだデータを入力することができ、グラフ学習の質を上げることが可能になったためであると考えられる。

具体的な組合せ推薦の結果を表3に示す。タコとイカなど食材カテゴリが同じで、レシピ内で多く使われることが考えられる組合せが上位になっている他、ニンジンとセロリの組合せという糖尿病予防²や高血圧の

¹金谷 重彦 (奈良先端科学技術大学院大学), 「KNAPSAcK Family -DietDish-」, <http://www.knapsackfamily.com/DietDish/top.php>, 2022年1月7日 閲覧。

²白鳥早奈英 (2004), 「元氣 2 倍増 効き目 3 倍増 食べ合わせ新百科」, ブックマン社

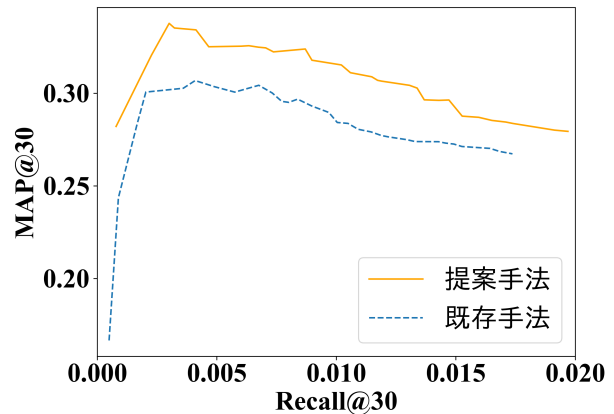


図 2: PRgraph の比較 (k=30)

改善³に有効だと知られている組合せも上位に入っている。NPMIスコアの全平均が0.1972に対してニンジンとセロリのNPMIスコアは0.4301と比較的高く、共起頻度を正確に捉えることができる本手法の利点が働いた結果だと考える。

表 2: 相関係数の比較

k	先行研究	提案手法
10	0.1685	0.2602
100	0.3233	0.4117
1000	0.3036	0.3495

表 3: 推薦結果の例

組合せ	先行研究	提案手法
タコ × イカ	4 位	1 位
ブロッコリー × カリフラワー	8 位	1 位
ニンジン × セロリ	33 位	9 位

5 おわりに

本研究では、共起関係を緻密に考慮した食材分散表現の構築手法を提案した。その結果、食材カテゴリの分類タスクにおいて、精度の高い分散表現を構築することができた。また食材組合せの推薦タスクにおいても本手法の有効性が確認できた。

今後の課題は、相性が悪いとされている食材組合せを考慮した食材分散表現の構築を検討することである。

参考文献

- [1] Donghyeon Park, Keonwoo Kim, Seoyoon Kim, Michael Spranger, and Jaewoo Kang. Flavorgraph: a large-scale food-chemical graph for generating food representations and recommending food pairings. *Scientific reports*, Vol. 11, No. 1, pp. 1–13, 2021.
- [2] Yuxiao Dong, Nitesh V. Chawla, and Ananthram Swami. Metapath2vec: Scalable representation learning for heterogeneous networks. In *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, p. 135–144. Association for Computing Machinery, 2017.
- [3] Gerlof Bouma. Normalized (pointwise) mutual information in collocation extraction. *Proceedings of GSCCL*, Vol. 30, pp. 31–40, 2009.

³陳惠運 (2011), 「免疫力を高める食べ物帖」, 中経出版