

料理名を考慮した Encoder-Decoder モデルを用いた 魅力的なレシピタイトルの生成

山本 悠統[†] 風間 一洋^{††}

[†] 和歌山大学大学院システム工学研究科 〒640-8510 和歌山県和歌山市栄谷 930

^{††} 和歌山大学システム工学部 〒640-8510 和歌山県和歌山市栄谷 930

E-mail: †{s236310,kazama}@wakayama-u.ac.jp

あらまし 近年、ユーザ投稿型レシピサイトでは、大量のレシピが投稿・閲覧されているが、同じ料理でも細部が異なるレシピが大量に存在するため、投稿したレシピを他のユーザに見てもらうためには、魅力的なタイトルを付与することが重要である。本稿では、Encoder-Decoder モデルを用いて、多くのユーザが見てくれるような魅力的なレシピタイトルをレシピの概要から自動的に学習・生成する手法を提案する。ただし、Encoder-Decoder モデルではレシピの内容と一致しないタイトルを生成することが多いため、レシピの元の題名から料理名を自動的に抽出して一緒にファインチューニングすることで、生成するタイトルの適合性を向上させる。実際に BERT2BERT や BERTShare などの複数の Encoder-Decoder モデルを用いて実験を行い、提案手法の利点と問題点を明らかにする。

キーワード 食とレシピ, レシピ・料理, 自然言語処理応用

1 はじめに

インターネットや SNS の普及に伴い、クックパッドや楽天レシピなどのようなユーザ投稿型レシピサイトが広く利用されるようになり、膨大なレシピがインターネット上で流通するようになった。例えば、クックパッドでは月間利用者数が約 5700 万人、レシピ数は約 360 万品、楽天レシピでは、月間利用者数が約 2000 万人、レシピ数は約 245 万品も投稿され、今も多くのレシピが投稿され続けている。

しかし、膨大な類似レシピが存在するために、逆に Web ページに表示される類似レシピ群の中から自分のレシピを選んで作ってもらうことは容易ではない。そこで、各レシピ投稿者は、レシピの内容を簡潔でわかりやすく要約したり、「簡単」、「ふわふわ」等のレシピの特徴を簡潔・的確に示すアレンジ表現やオノマトペを使用したり、目に止まりやすい記号や強調表現を用いたりするなど、レシピタイトルに様々な工夫をしていると思われる。しかし、実際にどのような工夫をしているかは明確ではなく、ユーザがそのような魅力的なレシピタイトルを考えるのは難しい。

そこで、本稿では生成型要約モデルの一種である Encoder-Decoder モデルを用いて、ユーザが見て作りたくなるような魅力的なレシピタイトルの特徴を、料理を作ったことの報告であるつくれば数が多い人気レシピから学習し、さらに投稿するレシピから自動的に生成する手法を提案する。ただし、Encoder-Decoder モデルではレシピの内容と一致しないタイトルを生成することが多いため、レシピの元の題名から料理名を自動的に抽出して一緒にファインチューニングし、生成時にも料理名を与えることでタイトルの適合性を向上させる。

2 関連研究

2.1 Transformer を用いた生成型要約モデルに関する研究

Transformer は、当初はニューラル機械翻訳用に Attention 機構を持つ深層学習モデルとして提案された [1]。従来は CNN や RNN を用いた Encoder-Decoder モデルに Attention 機構を追加するという複雑なアーキテクチャが用いられていたが、Transformer では Attention 機構を中心にシンプルなアーキテクチャとして再構成したことで学習時間の短縮や高速化、高性能化を実現でき、その後様々な分野で広く用いられるようになった。自然言語処理分野では、Transformer を用いた言語モデルとして、OpenAI の GPT (Generative Pre-Training) 及びその後継 [2] と Google AI Language の BERT (Bidirectional Encoder Representations from Transformer) [3] がよく用いられる。

GPT-2 は、Transformer の Decoder 部分のアーキテクチャを用いたテキスト生成のための言語モデルである。まず、ラベル付けされていないテキストコーパスを用いて教師なしの事前学習を行って初期パラメータを学習し、その後目的のタスクに合わせて教師あり学習を行なってパラメータをファインチューニングする。事前学習時には、入力された文章を一方の Attention 機構を用いて参照しながら、それに続く単語を予測するタスクを実行する。

BERT は、Transformer の Encoder 部分のアーキテクチャを用いた言語モデルであり、GPT シリーズと同様の事前学習とファインチューニングという 2 段階の処理を持つ。事前学習時には、入力された文章を双方向の Attention 機構を用いて参照しながら、単語穴埋め問題を解く Masked Language Model (MLM) と次の文章を予測する Next Sentence Predic-

tion (NSP) という 2 種類のタスクを用いて初期パラメータを学習する。ファインチューニング時には、入力テキストに対して出力される最終層の埋め込み表現を用いて、分類問題などの様々な自然言語処理タスクを最適化する。事前学習と比べると、ファインチューニングに用いるデータは少なく、計算回数も少なくとも良い特徴を持つ。BERT には、様々な派生モデルが存在し、例えば RoBERTa [4] のように事前学習を改良して性能を向上させたモデルも存在する。

Transformer ベースの生成型要約モデルには、BART [5] や BERT2BERT [6] がある。Lewis らが提案した BART は、BERT を Seq2Seq [7] の形にした汎用的な事前学習モデルである。Roth らが提案した BERT2BERT は、BERT を Encoder と Decoder の両方に用いた文章生成のための Encoder-Decoder モデルである。ただし、Decoder 側の BERT の Attention 機構は、一方向化されている。また、同研究では BERTShare と呼ばれる Encoder の重みを Decoder と共有したモデルや、BERT の代わりに RoBERTa を用いた RoBERTa2RoBERTa も提案されている。

本稿では、これらの BERT 及びその派生手法を用いて実現した Encoder-Decoder モデルを対象とする。

2.2 タイトルの生成に関する研究

2.2.1 ニュースタイトル生成

ニュースや新聞記事のタイトル生成では、必要な情報は全て記事本文にあり、最初の一文目を要約とみなすことができるため、抽出型要約による生成が可能である。石原らの研究では、このことを利用し生成型要約モデルを抽出型要約のデータセットで事前学習した後に事前学習したモデルをファインチューニングし、新聞記事の見出し生成を行った [8]。

2.2.2 レシピタイトル生成

難波らの研究では、レビュー情報に基づいて目的別の料理レシピカテゴリに分類されているレシピを分析し、各カテゴリの特徴を明らかにし、レシピを投稿した際に自動でタイトルを生成できるシステムの構築を目指している [9] [10]。この研究では、クックパッドのレビューに、料理の特徴を示すタグを自動付与する手法を提案し、目的別料理レシピカテゴリに分類する。目的別料理カテゴリに、料理レシピを自動分類し、投稿されたレシピをカテゴリごとに分類しレビュー情報から特徴を抽出を行う。そして抽出した特徴からレシピタイトルの生成を行おうとした。

本稿では、レビュー情報からではなくレシピの特徴等が記載されているレシピの概要からレシピタイトルの生成をおこなう。しかし、レシピの概要には料理名が含まれていないことが多くレシピの概要そのままでは誤ったレシピタイトルが生成される可能性がある。

2.3 キーワードを考慮した文章生成に関する研究

生成型要約モデルでは、入力文にない単語や表現を生成することができる。しかし、情報が不足していると異なる内容の文章を生成してしまう。また、あるキーワードを含めて文章を生

成して欲しくても、そのキーワードが生成されるとは限らない。そこで、Fan らは入力する文章の前にキーワードを表すトークンを挿入し、学習することでキーワードを考慮する文の生成を行った [11]。結果として、キーワードを挿入しない場合と比べてキーワードが生成される割合が向上した。

また、黒木らは、キーワードを含めるために、キーワードを [MASK] トークンに置き換えて出力するよう学習する手法とキーワードの生成確率を上げる手法の提案を行い、既存の文に比べてよりキーワードを多く含む文の生成に成功した [12]。

本稿では、Fan らのように入力文の前にキーワードである料理名を挿入することで、異なる調理名が生成されることを防止し、料理名を考慮したレシピタイトルの生成をおこなう。

3 提案手法

3.1 レシピタイトル生成の特殊性

すでに述べたように、文章のタイトル生成に要約手法を用いる研究が存在するが、レシピのタイトル生成に関しては、以下のような特殊性が存在する。

まず、ニュース記事のタイトル生成に用いるのは記事の本文のテキストデータであるが、レシピデータは表 1 に示すように概要、材料、調理手順など複数の項目に分けて構造化されていることである。タイトル生成に特に有効だと考えられる情報は、レシピの料理の特徴を表す概要、調理方法を表す調理手順、使用する食材を表す材料であるが、概要は一般的な説明文であるのに対して、調理手順は調理作業を段階ごとに分けて順番に記述した手順文、材料は食材のリストであるように、特性が異なるテキストデータであり、単純に結合しても良い結果は得られない上に、BERT を用いる場合には最大トークン数を越えてしまうことも多い。さらに、この中でレシピの特徴が一番よく記述されている概要のテキストを用いても、調理方法に関しては調理手順に、食材に関しては材料に書かれているために、逆に概要ではそれらの情報が省略され、必要な情報が得られないことがある。

次に、文章としての適切性や自然言語処理の難易度が異なることである。ニュース記事は文章を書く専門家が執筆し、複数回の校正を経た上で公開されることから、適切な文書構造を持つ。しかし、ユーザ投稿型レシピサイトに投稿されたレシピは、料理本やレシピ集を出版しているような専門家や記者ではない一般ユーザが執筆するために、誤字や文法の誤りが多く存在し、必ずしも文章として適切な構造や構成であるとは限らない上に、アピール力を高めるために記号類・顔文字・絵文字などの装飾が活用されており、自然言語処理における難易度がはるかに高いと考えられる。

さらに、レシピのタイトルは、末尾が料理名で終わり、その前にその修飾句が来るなどの独特のパターンを持つことである。このようなパターンは一般的な説明文にはあまり出現しない上に、このパターンに従わないタイトルは、ユーザ投稿型レシピサイトの検索結果で違和感を感じさせたり、タイトルからのレシピの特徴の推測を難しくする可能性がある。

以上の特殊性から、例えば、ニュース記事の場合は読者が概要を一目で把握できるように冒頭部分に概要をまとめることが多いことから、抽出型要約でも比較的妥当なタイトルを生成できることが知られているが、レシピの場合は抽出型要約では適切なタイトルを生成できない。また、より柔軟性が高い生成型要約を用いると、一見レシピらしいタイトルが生成できるものの、概要のテキストを入力するだけでは、情報不足により料理や食材が異なる問題が発生し、さらに調理手順のテキストを加えたとしてもこの問題は改善されない。

3.2 提案手法の概要

魅力的なレシピタイトルとは何かという規則を演繹的に求めるのは難しく、さらに求めた規則が他の人にも当てはまるとは限らない。そこで、本稿ではユーザ投稿型レシピサイトで人気があるレシピのデータから帰納的に魅力的なタイトルの生成方法を学習したモデルを作成し、そのモデルに基づいて与えられたレシピのタイトルを生成するアプローチを採用する。提案手法の概要を図1に、タイトルの生成手順を以下に示す。

- (1) レシピ群から人気レシピを抽出する。
- (2) 人気レシピから料理名を抽出する。
- (3) 人気レシピを用いて Encoder-Decoder モデルをファインチューニングする。
- (4) レシピの概要と料理名から魅力的なレシピタイトルを生成する。

レシピデータからタイトルを生成するためには、入力文を解釈して低次元の潜在表現に変換する Encoder と、さらにその潜在表現から出力文を生成する Decoder を組み合わせた BERT ベースの Encoder-Decoder モデルを用いる。

モデルのファインチューニングには、日本国内の代表的なユーザ投稿レシピサイトであるクックパッドのレシピデータを使用する。

3.3 人気レシピの抽出

ユーザ投稿型レシピサイトは多くの人に利用されるが、レシピ投稿者のモチベーション維持のために、クックパッドのつくれぽや、楽天レシピのつくったよレポートのように、料理した事実や感想、コメントをレシピ投稿者に報告するようなフィードバック機能を備えていることが多い。

そこで、そのようなレポート数が多い人気レシピのタイトルには、多くの類似レシピの中から選んで調理してもらうだけの魅力があると仮定して、報告数が多いレシピを抽出してファインチューニングに使用する。これを人気レシピと呼ぶ。

3.4 レシピタイトルからの料理名の抽出

単に Encoder-Decoder モデルを用いてレシピの概要からタイトルを生成した場合には、実際のレシピとは料理名や食材が異なるタイトルを生成することが多い。既に述べたように、この原因は概要には、調理手順からわかる料理名や、材料からわかる特徴的な食材を重複を避けるために含めないことも多く、適切なタイトルを生成するための情報が不足していたためで

あった。そこで、本稿では概要に加えて料理名も与えてファインチューニングする。

なお、料理名を調理手順から機械学習で判定する方法も考えられるが、対応する料理の追加コストが高いことから、料理の追加コスト低減と手順の簡略化のために、タイトルの末尾（ただし記号類は無視する）に料理名を配置することが多いという経験則を利用して、次のように料理名を抽出する。

(1) 処理前に、料理名とその正規形（存在する場合）を含む辞書データを読み込み、単語の文字を逆順に格納したトライ木と、単語から正規形の変換表を作成しておく。

(2) タイトルの末尾から、ひらがな、カタカナ、漢字以外の文字を読み飛ばす。

(3) 登録されている単語と一致するかをトライ木を用いて逆順に調べる。一致しない場合は終了する。

(4) 一致した単語に正規形が定義されている場合には正規形を、そうでなければその単語を返す。

辞書に関しては、最初にレシピのタイトルを日本語形態素解析してから、一番最後の名詞を抽出した後に、人手で選別して初期辞書を作成する。次に、上記の手法でレシピのタイトルを再処理し、抽出できなかったレシピのタイトルから人手で単語を登録する。さらに、かたかなとひらがな、漢字などの文字種の違いや、表記のゆれなどを統一するために、人手で正規形も登録する。対応する料理を増やすためには、この辞書に新しい料理名を追加するだけでよく、既存の料理辞書を用いれば、正規形の定義などのコストもあるものの、比較的容易に対応できると思われる。

なお、この辞書に登録する料理名は「パスタ」、「サラダ」、「ごはん」などの基本的な単語で、料理種別に近い。一般的には、これらの単語の前に修飾句や名詞が付与されて「キノコのクリームパスタ」のような、より詳細な料理名が使用されるが、それらは生成型要約によって生成することを想定している。

実際に評価用のデータに適用したところ、8割以上のレシピのタイトルから料理名を抽出できた。実際に料理名を抽出した例を表2に示す。

抽出できなかった場合は、倒置法の使用（例、新玉ねぎのサラダ♪ツナ缶で）、補足説明（コク旨*きゅうり塩こんぶ*おつまみにも!）、文章としての記述（例、タコがうまい）、内容が料理ではなく調理法や保存方法の場合（例、キレイに桃がむけちゃうよ♪）などであった。ファインチューニングが目的なので料理名を抽出できなかったレシピは使用しなければよく、ユーザ投稿型レシピサイトには膨大なレシピが投稿されていることを考慮すると、簡単な実装で比較的高い抽出率を実現できたと言える。

3.5 人気レシピによるファインチューニング

近年、生成型要約モデルを用いて新聞記事などの見出しや広告文を生成する研究が行われているが、Encoder-Decoder モデルを用いた場合には、入力文と出力文を1対1に対応させて学習させるために、重要なキーワードが出力文に含まれなかったり、内容が異なった文が生成されるなどの問題があり、生成結

表 1 レシピデータの例

レシピのタイトル	簡単もやし卵中華あんかけ
レシピの概要	フライパン1つ♪もやしでボリュームたっぷりの1品です。2007、7、20に話題入りさせて頂き調度2ヶ月9、19に100人の方に作って頂きました 皆さま本当にありがとうございました(o*。-)oペコッ
レシピのコツ・ポイント	お好みでニラ、キクラゲ、豚などをプラスしても美味しい。 ※塩コショウはタッパーがお勧め。
レシピの生い立ち	家の定番です。
レシピの公開日	07/07/05
材料の名前	もやし 卵 ...
材料の分量	1袋1つ...
手順の内容	フライパンにごま油を入れもやしを入れ塩コショウ(分量外)をして強火でサッと炒める。お皿に取り出しておく。

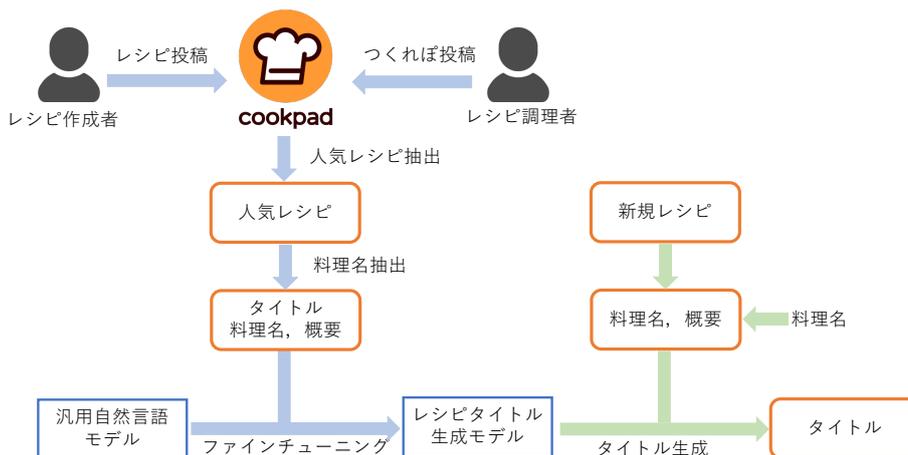


図 1 提案手法の概要

表 2 料理名の抽出

レシピタイトル	料理名
淡い初恋ゼリー☆。.:*・	ゼリー
大根で!シーチキン梅しそサンドフライ♪	フライ
HB でふわふわバターロール♪	バターロール
マドレーヌ***	マドレーヌ

果の制御に関する研究が盛んに行われている [12], [13].

本稿では, Fan らの手法 [11] を用いて, 料理の種別が変わらないような生成結果の制御を試みる. ファインチューニングの概要図を図 2 に示す. 実際には, Encoder 部に [CLS] トークンと, その直後に (3.4 節) である人気レシピから抽出した料理名を挿入し, さらに特殊トークン [SEP] でそのレシピの概要文を連結したものを入力する. Decoder 部には, [CLS] という特殊トークンの直後にその人気レシピのタイトルを付与したものを与えて, そのタイトルが生成できるようにファインチューニングする.

3.6 レシピの概要からのタイトル生成

タイトル生成時には, レシピの料理名と概要をファインチューニング時と同様の方法で Encoder 部に与えて, Decoder 部からタイトルを取得する.

本稿では, タイトル生成時には, レシピ投稿者はタイトル以

外のレシピの項目は既に入力済みであり, 料理名は別途人手で指定するか, レシピの手順などから自動判別することを想定しているが, 既存レシピを用いた評価時には, (3.4 節) の手法を用いて自動的に取得する.

なお, 既存手法では与えたキーワードが必ず出力に含まれることを想定して手法を構築しているが, 提案手法ではタイトルが適切であれば, 与えた料理名が必ずしも含まれなくてもかまわない. これは料理名が地域や国によって異なったり, 歴史的経緯で特別な名前が与えられていることがあるからである. 例えば, 唐辛子とニンニクを用いたパスタのレシピの場合に, 料理名として「パスタ」を与えたが, 出力ではその代わりに「ペペロンチーノ」が含まれていてもよいと考えている.

4 評価

4.1 データセット

クックパッド株式会社と国立情報学研究所が提供する 1998 年 4 月 23 日から 2014 年 9 月 30 日までの 1,715,595 件のレシピデータ [14] からつくれぽ数が 100 以上のレシピデータ 11,855 件を抽出し, さらに料理名が抽出できた 9,560 件を人気レシピとして用いた.

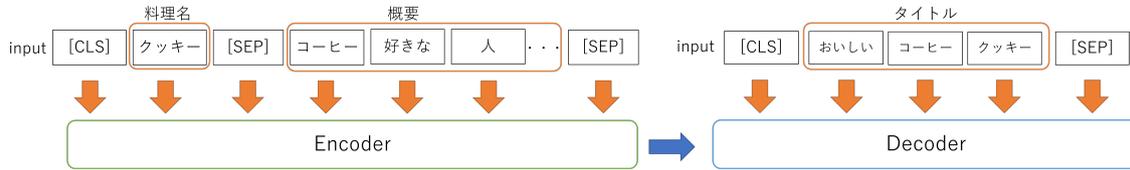


図2 Encoder-Decoder モデルによるファインチューニング

4.2 Encoder-Decoder モデル

Encoder-Decoder モデルとして, Roths らの BERT, GPT-2, RoBERTa などの Transformer ベースの Encoder-Decoder モデルに関する性能評価の論文 [6] で, Gigaword データセット, CNN/DailyMail データセット, BBC データセットを用いた文書要約の評価において比較的性能の良かった以下の 4 つのモデルを用いた.

- (1) BERT2BERT
- (2) BERTShare
- (3) RoBERTa2RoBERTa
- (4) RoBERTaShare

この中のどれかを用いてレシピの概要のみでファインチューニング・生成を行う手法をベースライン手法, レシピの概要に加えて料理名を用いた手法を提案手法と呼ぶ.

事前学習済み BERT モデルとして, 東北大学が公開している事前学習済み BERT¹ を用いた. このモデルは日本語 Wikipedia のテキストデータにより事前学習しており, MeCab により日本語形態素解析をした後に, WordPiece によりサブワードに分割してトークン化している.

また, 事前学習済み RoBERTa モデルとして, rinna 社が公開している事前学習モデル² を用いた. このモデルは日本語 CC-100 と日本語 Wikipedia のテキストデータで事前学習しており, SentencePiece でトークン化している.

パラメータは, Hugging Face の実装³ を参考に, 両モデルとも同じパラメータを使用した. ただし, メモリ不足の問題を避けるためバッチサイズは 8 とした. また, 最大入力長は Encoder 部と Decoder 部それぞれにおける入力長を求め, 最も入力長い文章に合わせた. 最大入力長は Encoder 部で 100, Decoder 部で 25 とし, タイトルを生成する際の最大の文長も 25 とした. 文長が短い場合は [PAD] トークンで埋める処理を行った.

4.3 ROUGE による評価

まず, 自然言語処理分野において自動要約を評価するために使用されている指標である ROUGE [15] を用いて各モデルの評価をおこなった. 評価する際には, 各タイトル生成モデルが人気レシピのタイトルを再現できると仮定し, 人気レシピのタイトルを元の要約, 生成されたタイトルを生成した要約とした.

ROUGE-N は, 要約モデルが生成した要約 S と元の要約 $RefS$ の N -gram の一致度に関する指標で, 次式で計算する.

$$ROUGE-N = \frac{\sum_{S \in RefS} \sum_{gr_n \in S} Count_{match}(gr_n)}{\sum_{S \in RefS} \sum_{gr_n \in S} Count(gr_n)} \quad (1)$$

ここで, n は N -gram の長さを, $Count_{match}(gr_n)$ は S と $RefS$ で一致した N -gram 数を示す. 本稿では, uni-gram の ROUGE-1 と bi-gram の ROUGE-2 を用いて評価した.

また, ROUGE-L も評価に用いた. ROUGE-L は, 要約モデルが生成した要約 X と元の要約 Y の最長共通部分単語列 (Longest Common Subsequence) を用いて次式の F_{lcs} として計算する.

$$R_{lcs} = \frac{LCS(X, Y)}{m} \quad (2)$$

$$P_{lcs} = \frac{LCS(X, Y)}{n} \quad (3)$$

$$F_{lcs} = \frac{(1 + \beta^2)R_{lcs}P_{lcs}}{R_{lcs} + \beta^2P_{lcs}} \quad (4)$$

ここで, m は元となる要約の単語数, n は生成された要約の単語数である.

人気レシピデータのうち 8604 件を学習データとしてファインチューニングし, 残りの 956 件をテストデータとして評価に用いた.

ROUGE による評価結果を表 3 に示す. ROUGE-1, ROUGE-2, ROUGE-L のいずれの場合も, 提案手法の方が明らかにスコアが高かった. これは, 提案手法の方が生成されたタイトルに料理名が含まれる割合が大きくなり, さらにその料理名に適した表現が生成されたからと考えられる.

次に, 提案手法に注目すると, ROUGE-1, ROUGE-2, ROUGE-L のいずれの場合も, BERTShare が一番スコアが高かった. なお, BERT2BERT より RoBERTa2RoBERTa の方が, BERTShare より RoBERTaShare の方がスコアが若干低い, 今回利用した事前学習済みモデルは用いたテキストデータやトークン化の方法が異なるために, これらの結果から必ずしも RoBERTa より BERT の方が性能が良いとは言えないことに注意する必要がある.

4.4 生成されたタイトルの評価

ROUGE では, 単語の一致度しか評価をしないので, 次に生成されたタイトルの質を, 既存研究 [16] を参考にした正確性と流暢性と, 本稿で注目している魅力性という 3 つの基準に基づいて人手で評価した.

a) 正確性

レシピタイトルとして妥当かどうか. レシピタイトルとして妥当とは, 料理名と材料が誤っておらず一致している場合である. それぞれ, 元の料理名と生成タイトルに含まれる料理名が

1 : <https://huggingface.co/cl-tohoku/bert-base-japanese-v2>

2 : <https://huggingface.co/rinna/japanese-roberta-base>

3 : <https://huggingface.co/blog/warm-starting-encoder-decoder>

表 3 ROUGE による評価結果

モデル	ROUGE-1	ROUGE-2	ROUGE-L
BERT2BERT (概要)	25.9	10.6	24.2
BERTShare (概要)	26.0	10.6	24.1
RoBERTa2RoBERTa (概要)	24.8	9.4	24.0
RoBERTaShare (概要)	25.4	10.2	23.6
BERT2BERT (料理名+概要)	35.5	16.8	33.7
BERTShare (料理名+概要)	<u>36.8</u>	<u>17.6</u>	<u>34.8</u>
RoBERTa2RoBERTa (料理名+概要)	34.4	16.0	32.7
RoBERTaShare (料理名+概要)	36.5	16.7	33.4

一致している割合 (料理名) 材料が一致している割合 (材料) (材料が生成されたタイトルにない場合は一致しているとみなす) に分けて示す。

b) 流暢性

レシピタイトルとして流暢かどうか。レシピタイトルとして流暢とは、日本語の文章として違和感がなく、読みやすい場合である。それぞれ、日本語として適切な単語だけが生成されている割合 (単語) と、同じ単語が連続するなどの構文的な問題がない割合 (構文) に分けて示す。

c) 魅力性

レシピタイトルとして魅力的かどうか。レシピタイトルとして魅力的とは、「オノマトペ」、「固有名詞」、「アレンジ表現」のようなレシピの特徴が表現されている場合、またはレシピでよく使われている記号 (☆, !, ♪, ♡, *) が含まれている場合と定義した。それぞれ、記号が適切に使われている割合 (記号)、レシピの特徴が表現されている割合 (特徴) に分けて示す。ただし、この評価では主観性を排除するために、レシピの特徴が実際のレシピと合致しているかについては評価しない。

評価データとして、人気レシピを除く既存レシピからランダムに 50 件抽出し、そのレシピから生成されたタイトルを評価した。タイトルはベースライン手法と提案手法を使った場合の 2 種類を生成した。評価は著者が一人で行った。評価に用いた一部のレシピの元のタイトルと抽出された料理名、概要を、表 4 に示す。これらは、評価データの中から、概要に料理名が含まれているもの、料理名が含まれないものや概要が短いものなど様々な事例をカバーするように人手で選択した。

評価結果を表 5 に示す。正確性に関しては、料理名の項目では、提案手法の値がベースライン手法と比べて大幅に向上しており、料理名を与えた効果を確認できた。材料名の項目では、BERT2BERT 以外の提案手法の値が若干向上していた。今回は材料に関する情報は与えていないが、正しい料理名が生成されたことで、その料理に適した材料が選ばれたことが理由だと考えられる。

流暢性に関しては、単語と構文のどちらの項目もどのモデルでも大きく変わらなかったが、単語に関してはベースライン手法の方が若干高かった。ベースライン手法の BERT2BERT と RoBERTa2RoBERTa 以外では、適切ではない単語が含まれる傾向があった。また、構文に関しては、どのモデル、手法でも同じ単語が連続する傾向があった。

魅力性に関しては、記号、特徴の項目では、ベースライン手法のほうが高かった。この理由は、提案手法では、料理名が正確になると反面、同時に使用できる表現が制限されてしまうからだと考えられる。

4.5 生成されたタイトルの分析

ROUGE による評価と生成されたタイトルの評価が高かった BERTShare モデルと RoBERTaShare モデルを用いて、実際に表 4 のデータからベースライン手法と提案手法で生成したタイトルを表 6 と表 7 に示す。なお、表の波線は異なる料理名を、下線は異なる材料を、二重線は「オノマトペ」や「アレンジ表現」のようなレシピの特徴を的確に表す表現を表す。

生成されたレシピタイトルを比較すると、正確性に関しては、料理名は BERTShare と RoBERTaShare どちらの場合も、ベースライン手法では、概要に料理名が含まれていても、波線で示すように異なる料理名が生成されることがあり、概要に含まれない場合はタイトルにも含まれないことが多い。一方で、提案手法では、正しい料理名が含まれることが確認できる。

材料に関しては、概要に材料が含まれる場合には、生成されたタイトルに含まれることが比較的多かったが、概要に材料が含まれない場合は、生成されたタイトルに下線で示すようなレシピで使用されていない材料が含まれることが多いことがわかる。

流暢性に関しては、RoBERTaShare で、「ササクッキー」などのおかしな単語が生成されていることが確認できる。この理由として、東北大学の事前学習済み BERT モデルが日本語形態素解析と Whole Word Masking という言語依存のトークン化と MLM を用いているのに対し、rinna 社の事前学習済み RoBERTa モデルは言語非依存の SentencePiece でトークン化しているために、不自然なトークン化により存在しない単語を生成した可能性が考えられる。また、同じ単語の繰り返しに関しては、タイトル生成に用いられている Beam Search は Beam Search では同じ単語を繰り返し生成することがあるからだと考えられる。

魅力性に関しては、記号は、名詞句の前後に挿入される傾向があり、レシピタイトルを魅力的にするために役立っていることが確認できる。レシピの特徴を表す表現は、二重線で示すようなオノマトペやアレンジ表現が用いられていることが確認できる。なお、元のレシピの概要の「食欲がなくなりがちな夏にピッタリ」のような表現が、「夏バテにならない」、「夏バテ知ら

表 4 評価に用いたレシピのタイトルと料理名、概要の例

元のタイトル	料理名	概要
ウルトラ簡単なりんごのコンポート	コンポート	赤いリンゴを皮つきのまま電子レンジで柔らかくしたコンポートです。レーズンも柔らかくなって、おいしいですよ。
たっぷりハヤシソースのオムレツ	オムレツ	ボリューム満点でご飯が進んじゃいます♪ガーリックライスを添えても相性ばっちし!
カスタードプリン	プリン	スがいらない超一簡単です♪今は家でブームです♪だから太るんだとかその辺触れないで下さい orz
さばと野菜のカレー炒め	炒め	時間が無いときにもちゃちゃっと出来ます♪カレー味なので、お魚苦手な子どもにもいいかも。。
夏バテ防止☆冷やし中華&冷麺風そうめん	素麺	いつものそうめんをピリ辛に!食欲がなくなりがちな夏にピッタリ☆特別な調味料はいりません。
簡単:レンジ 1 分:青梗菜の生姜酢醤油和え	和え	激ウマです。
もやしと油揚げのあんかけ焼きそば♪	焼きそば	あさり、もやし、ネギだけなのに絶品です☆いいダシだしてくれるあさりちゃんには頭があがりませ ん!!
自家製食ベドレ「キムマヨ」で♪ディップ	ディップ	作りおきの可能の万能「食ベドレ」です!
ミックス粉で☆簡単☆カフェオレスコーン♪	スコーン	ノンバターでサクサク (^_^) 食べ過ぎるかも (^_^)
好きな具材でドロップクッキー	クッキー	ゴロゴロだったりサクサクだったり

表 5 生成されたタイトルの評価結果

モデル	正確性 (%)		流暢性 (%)		魅力性 (%)	
	料理名	材料	単語	構文	記号	特徴
BERT2BERT (概要)	30	38	<u>100</u>	96	54	44
BERTShare (概要)	34	40	98	96	<u>72</u>	46
RoBERTa2RoBERTa (概要)	34	20	<u>100</u>	<u>98</u>	42	34
RoBERTaShare (概要)	28	36	96	94	52	<u>58</u>
BERT2BERT (料理名+概要)	86	36	96	<u>98</u>	52	36
BERTShare (料理名+概要)	90	<u>46</u>	96	<u>98</u>	58	44
RoBERTa2RoBERTa (料理名+概要)	84	26	90	96	58	50
RoBERTaShare (料理名+概要)	<u>94</u>	38	92	96	52	46

ず、「夏バテに！」などどうまく言い換えられていることが確認できる。ただし、ベースライン手法では、「簡単」という単語が頻出していることが確認できる。これはクックパッドのレシピでも非常によく使われるアレンジ表現であり、本稿ではそれらの表現とレシピの内容が合致するかは確認しないために、実際のレシピの内容を表していないくても、単に頻出する表現であるという理由で使用されている可能性が高い。今回の評価では客観性を重視して、あえて主観性を排除したが、さらに主観的な評価も検討する必要がある。

5 まとめ

本稿では、レシピの概要とタイトルから自動抽出した料理名を用いてレシピのタイトルを生成するようにファインチューニングした Encoder-Decoder モデルを用いて、レシピの概要から魅力的なレシピのタイトルを自動的に生成する手法を提案した。ROUGE による評価では、ROUGE-1, ROUGE-2, ROUGE-L のいずれの場合も提案手法と BERTShare の組み合わせが一番性能がよく、生成されたタイトルの人手による評価でも料理名に関する正確性が向上することがわかった。しかし、今回対象としなかった材料の正確性の性能向上はわずかであり、流暢性はほぼ変わらず、魅力性はベースライン手法の方が高かった。

ただし、魅力性に関しては、今回は評価対象としなかったが、レシピの内容とは必ずしも一致しない頻出表現が用いられている可能性があった。

今後の課題は、よりメモリ量大きい GPU と事前学習済み BERT-large モデルを用いた評価を行うこと、レシピにおけるメインの食材の情報も利用すること、今回行ったような客観的な評価ではなく、元のレシピのタイトルと生成されたタイトルに関する主観的な評価に関する被験者実験を行うことである。

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」[14] を利用した。また、本研究は JSPS 科研費 21H03557 の助成を受けた。

文 献

- [1] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, and Illia Polosukhin. Attention is all you need. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*, pp. 6000–6010, 2017.
- [2] Alec Radford, Jeffrey Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever. Language models are

表 6 BERTShare によるタイトル生成例

元のタイトル	生成されたタイトル (概要)	生成されたタイトル (料理名+概要)
ウルトラ簡単なりんごのコンポート	レンジで <u>簡単</u> ☆りんごの <u>キッシュ</u>	りんご <u>たっぷり</u> ☆りんごのコンポート
たっぷりハヤシソースのオムレツ	炊飯器で <u>簡単</u> ☆ <u>ガーリックライス</u>	我が家の定番☆オムレツ
カスタードプリン	<u>簡単</u> すぎ!ヘルシー♪ <u>豚キムチ</u> ☆	<u>とろとろ!簡単!</u> なめらかプリン♪
さばと野菜のカレー炒め	我が家の定番!おばちゃんのおにぎり	ご飯がすすむ!茄子のカレー炒め♪
夏バテ防止☆冷やし中華&冷麺風そうめん	夏バテにならない☆そうめん☆	夏バテ知らずの夏野菜とツナのそうめん
簡単:レンジ 1分:青梗菜の生姜酢醤油和え	鶏もも肉と長芋の <u>和風スープ</u>	人参の塩昆布和え。
簡単☆絶品☆あさりの塩焼きそば!!	ネギたっぷり☆あさりのおなか和え	もやしと油揚げのあんかけ焼きそば♪
自家製食パン「キムマヨ」で♪ディップ	お弁当にも <u>簡単!</u> 大葉のごま和え	<u>超簡単!</u> 白菜とベーコンのディップ♪
ミックス粉で☆簡単☆カフェオレスコーン♪	ノンオイルで <u>簡単</u> ♪ノンバターでヨーグルト	ノンオイル☆スコーン☆多量
好きな具材でドロップクッキー	<u>カリカリ</u> ベーコンの <u>サクサク</u> 焼き	<u>ザクザク!</u> ザクサククッキー☆

表 7 RoBERTaShare によるタイトル生成例

元のタイトル	生成されたタイトル (概要)	生成されたタイトル (料理名+概要)
ウルトラ簡単なりんごのコンポート	レンジで <u>簡単!</u> アップルポテトパイ	*りんごのコンポート**
たっぷりハヤシソースのオムレツ	牛肉と挽き肉の <u>ガーリックライス</u> ♪	キャベツとチーズのオムレツ
カスタードプリン	<u>簡単!</u> かぼちゃの <u>マヨチーズケーキ</u>	<u>簡単</u> ☆ <u>とろ〜り</u> チョコプリン☆
さばと野菜のカレー炒め	レンジで <u>簡単</u> ♪鶏むね肉のカレー炒め	鶏肉とキャベツの塩レモン炒め
夏バテ防止☆冷やし中華&冷麺風そうめん	夏バテに!夏野菜のピリ辛ピビン風焼き	ごま油で <u>簡単</u> ♪ピリ辛そうめん
簡単:レンジ 1分:青梗菜の生姜酢醤油和え	鶏肉と玉ねぎの <u>甘酢炒め</u>	ほうれん草のゴマ和え。
簡単☆絶品☆あさりの塩焼きそば!!	<u>簡単!</u> もやしの照り焼き♪	ハマる! <u>和風</u> ねぎ焼きそば♪
自家製食パン「キムマヨ」で♪ディップ	<u>簡単!</u> なすのマカロニサラダ	朝ごはんにおつまみに☆ <u>きのこ</u> ディップ
ミックス粉で☆簡単☆カフェオレスコーン♪	<u>簡単</u> サクサク♪ <u>サク</u> ささくさくクッキー	材料3つ!簡単 <u>サクサク!</u> サク♪スコーン
好きな具材でドロップクッキー	<u>塩麴</u> さんで <u>サクサク!</u> サクサククッキー	<u>サクサク</u> ☆サラダ油でクッキー

unsupervised multitask learners. https://d4mucfksyvw.cloudfront.net/better-language-models/language_models_are_unsupervised_multitask_learners.pdf, 2019.

- [3] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT'19)*, pp. 4171–4186, 2019.
- [4] Yinhan Liu, Myle Ott, Naman Goyal, Jingfei Du, Mandar Joshi, Danqi Chen, Omer Levy, Mike Lewis, Luke Zettlemoyer, and Veselin Stoyanov. RoBERTa: A robustly optimized BERT pretraining approach. arXiv:1907.11692 [cs.CL], 2019.
- [5] Mike Lewis, Yinhan Liu, Naman Goyal, Marjan Ghazvininejad, Abdelrahman Mohamed, Omer Levy, Ves Stoyanov, and Luke Zettlemoyer. BART: Denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pp. 7871–7880, 2020.
- [6] Sascha Rothe, Shashi Narayan, and Aliaksei Severyn. Leveraging pre-trained checkpoints for sequence generation tasks. *Transactions of the Association for Computational Linguistics*, Vol. 8, pp. 264–280, 2020.
- [7] Ilya Sutskever, Oriol Vinyals, and Quoc V. Le. Sequence to sequence learning with neural networks. In *Proceedings of the 27th International Conference on Neural Information Processing Systems (NIPS'14)*, pp. 3104–3112, 2014.
- [8] 石原慧人, 石原祥太郎, 白井穂乃. BertSum を用いた日本語ニュース記事の抽象型要約手法の検討. 第 35 回人工知能学会全国大会, 1D4-OS-3c-02, 2021.
- [9] 金内萌, 難波英嗣, 角谷和俊. 投稿型レシピサイトにおけるレビュー情報に基づく料理タイトル自動生成. 第 8 回データ工学と情報マネジメントに関するフォーラム (DEIM Forum 2016), P3-2, 2016.
- [10] 金内萌, 難波英嗣, 角谷和俊. レビュー情報を用いた料理レシピの特徴分析によるカテゴリ生成およびレシピタイトルの自動生成. 第 9 回データ工学と情報マネジメントに関するフォーラム (DEIM Forum 2017), P8-2, 2017.
- [11] Angela Fan, David Grangier, and Michael Auli. Controllable abstractive summarization. In *Proceedings of the 2nd Workshop on Neural Machine Translation and Generation (WNMT'18)*, pp. 45–54, 2018.
- [12] 黒木開, 川上孝介, 岩井大志, 石塚湖太, 中田和秀. キーワードを考慮した BERT2BERT による広告文生成. 人工知能学会第 35 回全国大会, 2D3-OS-7a-02, 2021.
- [13] 山田康輔, 人見雄太, 田森秀明, 岡崎直観, 乾健太郎. 指定語句を確実に含む見出し生成. 言語処理学会第 27 回年次大会 (NLP2021), pp. 1339–1343, 2021.
- [14] 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, (データセット), 2015. <https://doi.org/10.32130/idr.5.1>.
- [15] Chin-Yew Lin. ROUGE: A package for automatic evaluation of summaries. In *Text Summarization Branches Out*, pp. 74–81. Association for Computational Linguistics, 2004.
- [16] Dandan Huang, Leyang Cui, Sen Yang, Guangsheng Bao, Kun Wang, Jun Xie, and Yue Zhang. What have we achieved on text summarization? In *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP2020)*, pp. 446–469, 2020.