

特徴抽出器の学習と購買履歴を必要としない類似画像による 関連商品検索システム

三宅 悠介^{1,a)} 松本 亮介^{1,b)} 力武 健次^{1,2,c)} 栗林 健太郎^{1,d)}

概要: BtoC の EC サイトで取り扱う商品の種類の増加に伴い、EC サイト利用者の通常の行動では全ての商品を見て回することは困難であるため、多くの EC サイトでは効率的に商品を開覧できるよう関連性のある商品を動線上に表示している。購買履歴等の情報が蓄積されないと関連商品を選定できない問題を解決するため、商品の持つ様々なメタデータを利用する手法や、視覚的な訴求力の強い商品画像を元にした、畳み込みニューラルネットワークを始めとした深層学習による精度の高い関連商品の選定手法が提案されている。しかし、適切な粒度のメタデータの整備に手間を要する問題や、深層学習のための大量の訓練データセットと計算時間が必要となる問題から、これらが導入への大きな障壁となっている。本報告では、画像分類用の学術ベンチマークであり、EC サイト商品画像特性と類似する ImageNet において高い成績を出した Inception-v3 モデルを学習済みネットワークとして採用し、一般物体の特徴を強く表現する識別層に近い手前のプーリング層までから得られる特徴量をもとに近似最近傍探索により類似度を比較することで、特徴抽出器の学習と購買履歴を必要としない類似画像による関連商品検索システムを提案する。EC サイトにこの類似画像による関連商品検索システムを導入し、画像のクリック率を商品カテゴリごとに計測することで類似画像による関連商品の有効性を検証した。

A search system of retrieving images of the similar products without the requirement of the training of feature extractor and the purchase history

YUSUKE MIYAKE^{1,a)} RYOSUKE MATSUMOTO^{1,b)} KENJI RIKITAKE^{1,2,c)} KENTARO KURIBAYASHI^{1,d)}

Abstract: Electronic Commerce (EC) sites show items of the user's interest following the flow for efficient browsing of the products. For enabling to choose the related products without the activity record of the users, methods using the metadata and the images of the products to suggest a highly accurate choice by deep learning with convolution neural networks have been proposed. Those methods, however, require the large amount of training data and calculation time with a properly structured product metadata, which results in the impediment to the production system deployment. In this report, we propose a search system of retrieving images of the similar products without the requirement of the training of feature extractor and the purchase history, by comparing the similarity with the approximate nearest neighbor search based on the features from the pooling layer before the identification layer, using the Inception-v3 model which claims a good result on ImageNet, an academic benchmark of image classification similar to that of EC site product image characteristics. We implement this system to an EC site and measure the clickthrough rate of the image for each product category to evaluate the effectiveness of directing the user flow by showing the related products by similar images.

¹ GMO ペパボ株式会社 ペパボ研究所
Pepabo R&D Institute, GMO Pepabo, Inc., Tenjin, Chuo
ku, Fukuoka 810-0001 Japan

² 力武健次技術士事務所
Kenji Rikitake Professional Engineer's Office, Toyonaka

City, Osaka 560-0043 Japan

a) miyakey@pepabo.com

b) matsumotory@pepabo.com

c) kenji.rikitake@acm.org

d) antipop@pepabo.com

1. はじめに

BtoCのECサイト市場規模は成長を続けており[23], それに伴い取り扱う商品の種類は増大している. ECサイト利用者の通常の行動では全ての商品を見て回することは困難であるため, 多くのECサイトでは効率的に商品を閲覧できるように関連性のある商品を動線上に表示している. そのため, 利用者の関心を効果的に高める関連商品を選定できるかどうか, ECサイトにとって大きな関心事となる.

関連商品を選定する手法としてAmazonを始めとした多くのECサイトで導入されている協調フィルタリングがある[9]. 協調フィルタリングは商品に対する利用者集団の嗜好情報を用いて関連商品の選定を行う. しかしながら嗜好情報を選定に用いる特性上, 嗜好情報となる購買履歴等の情報の蓄積が必要であり, 新しい商品が選定結果に含まれない. これは商品の登録・更新が頻繁に発生し得るECサイトにおいては問題となる.

協調フィルタリングを用いない関連商品の選定手法として, カテゴリ, 色や原料といった商品メタデータによる分類をもとに関連商品を選定する手法がある[2]. 通常, 商品のメタデータは登録時に設定されるため, 購買履歴等の情報の蓄積に依存しないが, 同一分類に含まれる商品の数が増加すると関連性が低下する. 下位カテゴリの追加といった, より粒度の細かいメタデータを設定することでこの問題を回避できるが, 適切な粒度のメタデータを与えなければならないことにより商品登録時の負荷が高まり, ECサイトにおける販売者の利便性低下につながってしまう. そのため, 適切な粒度で分類するための情報を販売者の商品登録時の作業を増やさずに獲得しなければならない.

メタデータの獲得手法として, 自然言語による文章や画像といった非構造化データから機械学習を用いて分類に利用できる情報を抽出する手法がある[18]. 特に深層畳み込みニューラルネットワーク[21]を用いて高精度に画像を分類する手法が多数提案されている[5], [14]. これらを購買履歴に依存しない商品メタデータのうち, 常に設定される商品画像や説明文に適用することで, 余分な分類用の情報を追加入力することなく, 精度の高い分類情報を入手することができる.

しかしながら, これらの深層学習を始めとする機械学習を用いた手法は, 精度向上のために年々複雑化しており, それに伴い学習に必要な訓練データセットと計算資産, 時間も増加している[4]. 学習済ネットワークを利用することでこれらを削減する手法も提案されているが[16], 完全に不要とするには至っていない. そのため, 商品の登録・更新が常に発生するECサイトにおいて, これらの深層学習を始めとする機械学習を用いた手法を導入して, 大量の訓練データセットを最新化し, 大量の計算資産と時間をかけて繰り返し維持し続けることは費用対効果の面から

困難である.

学習済ネットワークの適当な中間層の出力を特徴量として用いる手法がある[11]. この利用形態は特徴抽出器と呼ばれ, 学習済ネットワークの中間層をそのまま利用するため, 再学習が不要である. しかしながら, 対象となるタスクに対して効果的な学習済ネットワークを選定するためには対象タスクと元になったタスク領域の類似性が重要であり[3], ECサイトの関連商品選定における効果的な学習済ネットワークの選定手法は確立していない.

従来の協調フィルタリングや商品メタデータによる関連商品選定手法による問題を解決するためには, 購買履歴等の情報が不要で, 分類用の追加情報としてではなく常に設定される商品メタデータの中から, 導入先のECサイトの商品に依存しない学習不要で汎用的な学習済ネットワークを特徴抽出器として用いて関連商品の選定に必要な情報を抽出することが効果的である.

本報告では, 購買履歴等の情報が不要で, 分類用の追加情報としてではなく常に設定される商品メタデータのうち, 視覚的な訴求力が高い商品画像を対象として, 特徴抽出器として利用する学習済深層畳み込みネットワークから得られる特徴量を用いて近似最近傍探索により類似度を比較する, 類似画像による関連商品検索システムを提案する.

提案手法では, 画像分類用の学術ベンチマークであるImageNetにおいて高い成績を出したInception-v3モデル[5]を学習済深層畳み込みニューラルネットワークとして採用した. Inception-v3モデルは, ECサイトの商品画像特性に類似した訓練データセットで学習を行っており, この深層畳み込みニューラルネットワークの一般物体の特徴を強く表現する識別層に近い手前の層までから得られる特徴量[12]を, ECサイトの商品画像特性を考慮した高精度で汎用的な分類情報[3]として利用する.

提案手法の評価は以下の手順で行う. まずECサイトにInception-v3モデルを採用した類似画像による関連商品検索システムを導入し, 導入先のECサイトで独自に運用していた簡易的なユーザーベース協調フィルタリング手法を用いた関連作品のクリック率と比較することで類似画像による関連商品の有効性を検証する. そして, 画像のクリック率を商品カテゴリごとに計測することで商品種類による効果の差を評価する.

本論文の構成を述べる. 2章では関連商品の選定における購買履歴等の情報とメタデータを利用する既存手法と課題について述べる. 3章では既存手法の課題を解決するための提案手法について, 特徴量抽出器と購買履歴を必要としない類似画像検索システムとその実装について述べる. 4章では提案手法の有効性の検証を行い, 5章でまとめとする.

2. 関連商品の選定における協調フィルタリングあるいはメタデータを利用する既存手法とその課題

2.1 購買履歴等の情報を利用する商品選定の課題

1章で述べた協調フィルタリングによる関連商品の選定は類似性の判別に利用する対象によってアイテムベースとユーザーベースに分類することができる。アイテムベースの協調フィルタリングの場合、収集した嗜好情報を元に商品間の類似性を発見して選定に利用する。ユーザーベースでは、利用者間の類似性を発見して、類似する他の利用者が購入や評価した商品から選定する。

協調フィルタリングは購買履歴や評価等の嗜好情報をもとに類似性を判別する特性上、嗜好情報が集まらなければ商品の選定を行うことができない。購買履歴や評価が充分蓄積されていない利用者や商品に対して選定が行えず機会損失が発生する現象はコールドスタート問題 [10] と呼ばれ、利用者が増加し、商品の登録・更新が頻繁に発生するECサイトにとっての課題となっている。

2.2 商品メタデータを利用する商品選定の課題

協調フィルタリングを用いない関連商品の選定手法として、1章で述べた商品メタデータを用いた手法がある。通常、メタデータはECサイトにおける販売者が商品登録時に設定するため、購買履歴等の情報に依存しないが、同一分類に含まれる商品の数が増加すると関連性が低下する。そこで下位カテゴリの追加といった、より粒度の細かいメタデータを設定することでこの問題を回避できるが、適切な粒度のメタデータを与えなければならないことにより商品登録時の負荷が高まるため、販売者の利便性が低下してしまう。そのため、適切な粒度で分類するための情報を販売者の商品登録時の作業を増やさずに獲得する必要がある。

2.3 非構造化データを利用する商品選定の課題

通常、商品のメタデータはデータベースに保存される [7]。このとき、システムから検索に利用可能な分類の定義がされているデータを構造化データと呼ぶ。反対に、画像や自然言語で記述された説明文といった分類の定義がされていない状態のデータを非構造化データと呼ぶ [1]。これらの非構造化データから機械学習を用いて構造化可能なデータを抽出して、関連商品の選定に利用する手法がある [18]。特に深層畳み込みニューラルネットワークを用いて画像を高精度で分類するモデルが多数提案されている [5], [14]。畳み込みニューラルネットワークは、画像の局所領域の特徴抽出を行う畳み込み層と、抽出した特徴を縮小し、位置感度を低下させるプーリング層を繰り返すネットワーク構造を持つ [8], [21]。畳み込みニューラルネットワークの層を多層にすることでより精度を向上させた深層畳み込みニューラ

ルネットワークのひとつである Inception-v3 モデルは大規模画像認識の競技会である ILSVRC [14] 2014 で高い成績を出した GoogLeNet [4] の後継であり、ILSVRC2012 の 1000 クラス分類タスクの Top-5 エラー率において、GoogLeNet の 6.67% に対して 3.46% という性能を示したモデルである。同タスクを人が挑戦した場合、5.1% のエラー率であったという報告もあり*1、該タスクにおいては一般的な人の識別能力を超える性能を有していると言える。

これらの非構造化データから構造化可能なデータを抽出して関連商品の選定に利用する手法を、購買履歴に依存しない商品メタデータのうち、常に設定される商品画像や説明文に適用することで、余分な分類用の情報を追加入力することなく、精度の高い分類情報を入手することができる。しかしながら、これらの深層学習を始めとする機械学習を用いた手法は、精度向上のために年々複雑化しており、それに伴い学習に必要となる訓練データセットと計算資産、時間も増加している [4]。

ファインチューニングと呼ばれる、学習済ネットワークの獲得している知識を土台として追加学習を行うことで学習コストを抑える転移学習の手法がある [16] が、追加学習を完全に不要とするには至っていない。また、より基本的な学習済ネットワークの利用方法として適当な中間層の出力を特徴量として用いる方法がある。この学習済ネットワークの利用形態は特徴抽出器と呼ばれ、その汎用性も確認されている [11]。この手法では学習済ネットワークの中間層をそのまま利用するため、再学習が不要であることが利点となる。しかしながら、対象となるタスクに対して効果的な学習済ネットワークを選定するためには対象タスクと元になったタスク領域の類似性が重要であり [3]、EC サイトの関連商品選定における効果的な学習済ネットワークの選定手法は確立していない。

商品の登録・更新が常に発生するECサイトにおいて、これらの深層学習を始めとする機械学習を用いた手法を導入して、大量の訓練データセットを最新化し、大量の計算資産と時間をかけて繰り返し維持し続けることは費用対効果の面から困難である。

ここまで述べたことから、既存手法の課題として以下の3点を挙げることができる。

- (1) 購買履歴情報等を用いる関連商品の選定では、情報の蓄積が必要であり、頻繁に商品の登録・更新が発生するECサイトでは追従できない。
- (2) メタデータを用いる関連商品の選定では、購買履歴等の情報が不要であるが、同一分類の商品増加に対して、利便性を確保しながら適切な粒度のメタデータ整備することは困難である。
- (3) 構造化データを用いる関連商品の選定では、機械学習

*1 <http://karpathy.github.io/2014/09/02/what-i-learned-from-competing-against-a-convnet-on-imagenet/>

により非構造化データから有効な分類を抽出できるが、訓練に必要なデータセットや計算資産、時間が必要であり、これらが不要な学習済ネットワークの選定、利用手法が確立していない。

3. 提案手法

2章で述べた課題を解決するためには、以下の2つを達成する必要がある。

- (1) 購買履歴等の情報が不要で、分類用の追加情報としてではなく常に設定される商品メタデータの中から、導入先のECサイトの商品に依存しない学習不要で汎用的な学習済ネットワークを用いて関連商品の選定に必要な情報を抽出する
- (2) 抽出した情報を関連商品の選定に利用する

上記の2つの要件を満たすためには、ECサイトにおいて汎用かつ有効な学習済ネットワークの選定と、ECサイトからの要求に応じて、商品メタデータから抽出した特徴量を用いて関連商品を検索、応答するための仕組みの構築が必要になる。

本報告では、購買履歴等の情報が不要で、分類用の追加情報としてではなく常に設定される商品メタデータのうち、視覚的な訴求力が高い商品画像を対象として、特徴抽出器として利用する学習済み深層畳み込みネットワークから得られる特徴量を用いて近似最近傍探索により類似度を比較する、類似画像による関連商品検索システムを提案する。

3.1 学習済ネットワークの選定と特徴量変換の実装

2.3節で学習済ネットワークを特徴抽出器として利用するためには、学習時のタスクとの類似性が重要であると述べた。ECサイトの商品画像は商品数に応じた多様な種類が存在する。また画像内には商品だけでなく背景まで含まれていることが多く、このような画像に対して学習を行っているモデルが望ましい。ImageNetはクラウドソーシングによってラベル付けが行われている大規模な画像データセットである。2017年4月10日現在、21,841クラス、14,197,122枚の画像が索引付けられており、これらの画像を使った大規模画像認識の競技会であるILSVRCも開催されている[14]。ImageNetでラベル付けされ、ILSVRCで利用される画像は多様な種類で、背景画像も多く含まれており、ECサイトの商品画像の特性と類似している。そこで本研究では、ILSVRCに向けて学習を行い高い成績を出したInception-v3モデルを学習済ネットワークとして利用する。

深層畳み込みニューラルネットワークは入力された画像に対して畳み込みとプーリングを繰り返して入力の特徴を抽象化していくネットワークである[8], [21]。入力が層を経過するにつれて視覚的な特徴からタスクに特化した識別箇所を強調する特徴に変換され[12]、その特徴を基に識別

```
# 学習済ネットワークの読み込み
with tf.gfile.FastGFile(FLAGS.classify_net, 'rb') as f:
    graph_def = tf.GraphDef()
    graph_def.ParseFromString(f.read())
    _ = tf.import_graph_def(graph_def, name='')

with tf.Session() as sess:
    # 出力に用いる層の指定
    pool3 = sess.graph.get_tensor_by_name('pool_3:0')
    jpeg_data = tf.placeholder(tf.string)

    with file_io.FileIO(input_csv(), 'r') as f:
        with file_io.FileIO(output_csv(), 'w') as output:
            writer = csv.writer(output, lineterminator='\n')
            for line in f:
                product_id, image = image_from_line(line)
                input_name = 'DecodeJpeg/contents:0'
                results = sess.run(pool3, {input_name: image})
                features = ['{: .18e}'.format(f)
                            for f in results[0][0][0]]
                writer.writerow([product_id] + features)
```

図 1 TensorFlow による特徴量抽出の Python を使った実装例
Fig. 1 Implementation examples of extracting features using Python and TensorFlow.

機が分類を行う。そこで、本研究では、Inception-v3において識別層の一番手前であり、最も識別箇所を強調する特徴を特徴量として出力する Pool3 と名付けられたプーリング層からの出力が、ECサイトの商品画像の特性を考慮した高精度で汎用的な分類情報として利用できると考え、この層までからの出力を特徴抽出器として採用する。

特徴量変換の実装には機械学習のライブラリであり、同ライブラリに対応したモデルフォーマットで Inception-v3モデルを入手可能な TensorFlow[19]を用いる。商品画像を TensorFlow を用いて特徴量に変換する Python コードを図 1 に示す。

3.2 類似特徴量検索の実装

提案手法では 3.1 節の手順で得た商品画像から抽出された特徴量を用いて EC サイトからの要求に応じて関連商品を検索、応答する。

3.1 節の手順により得られる特徴量は 2048 次元の浮動小数点数のベクトルとして表現される。これらの特徴量から類似する特徴量を検索する処理は、最近傍探索の問題と捉えることができる。EC サイトの要求に対して現実的な応答時間を確保するためには計算量が商品数に比例する全探索は利用できない。しかしながら、類似画像による関連商品の選定という問題領域において厳密な最近傍点の検出は求められないため、近似最近傍探索で充分である。よって本研究では近似最近傍探索の実装として公開されている Annoy ライブラリ [20] を用いて類似特徴量検索を行う。

```
category_ids.each do |c|
  annoy = AnnoyIndex.new(2048)
  File.foreach("features/features_#{c}.csv") do |line|
    features = line.chomp.split(',')
    annoy.add_item(i, features[1..-1].map(&:to_f))
  end

  annoy.build(10)
  annoy.save("ann/category_#{c}.ann")
end
```

図 2 mruby_annoy によるデータベース構築の実装例

Fig. 2 Implementation examples of building database using mruby_annoy.

Annoy は検索時の計算量を削減するため、ランダム投影を用いて特徴量群の分割を繰り返すことで類似特徴量を分類した B 木に似た木構造を事前に複数構築する。検索時は木構造内の分割規則によってノードを辿り、比較対象となる特徴量を絞り込むことで計算量を削減する。分割面はランダムに決定されるため、最近傍点が含まれない可能性があるが、複数構築された木構造からそれぞれ近似近傍な特徴量群を取得し、それらの中で類似度の高いものを選択することで精度を向上させる [17]。

EC サイトへ類似特徴量検索機能を提供するにあたって、運用観点から類似特徴量のデータベースを一箇所に集約しながら、複数のアプリケーションサーバーからのリクエストを処理できるように、HTTP リクエストベースの API サーバーとしての機能が必要になる。API サーバーの実装には nginx[13] と筆者らが開発した ngx_mrubby[24] 並びに、mrubby-annoy を採用した。ngx_mrubby は nginx の拡張機能を mrubby[22] で実装でき、高速かつ省メモリで動作する。また、mrubby-annoy は Annoy が提供している C++ の API を mrubby から利用するバインディングライブラリであり、ngx_mrubby に組み込むことで、類似特徴量検索機能を持つ API サーバーとして稼働する。なお、mrubby-annoy の実装は OSS として公開済みである*2。

商品画像から抽出された特徴量から類似した特徴量を検索させるための処理は以下の通りである。初めに 3.1 節で取得した商品画像の特徴量を Annoy に登録し、事前に木構造を生成した特徴量データベースを構築する。mrubby-annoy を用いた構築処理は図 2 のようにして行う。

次に、類似特徴量検索サーバーで構築した特徴量データベースを読み込む。読み込んだデータベースは mrubby_userdata を利用することで、読み込み処理を都度行わないよう、ngx_mrubby の mrubby_init で図 3 のコードを呼び出す。

類似特徴量検索サーバーはアプリケーションサーバーから対象を特定する ID を受け取り、類似特徴量の ID 一覧を

*2 <https://github.com/monochromegane/mruby-annoy>

```
userdata = Userdata.new "annoy_data_key"

ann_dir = '/etc/nginx/conf.d/ann'
Dir.foreach(ann_dir) do |ann|
  next unless ann.end_with?('.ann')
  category_id = ann.split('_')[1]
  annoy = AnnoyIndex.new(2048)
  annoy.load("#{ann_dir}/#{ann}")
  userdata.send("category_#{category_id}", annoy)
end
```

図 3 mrubby_init の設定例

Fig. 3 Configuration examples of mrubby_init.

```
class NNS
  def call(env)
    params = env['QUERY_STRING'].split('&?')
      .map {|kv| kv.split('=')} }.to_h
    category_id = params['category_id'].to_i
    product_id = params['product_id'].to_i
    limit = (params['limit'] || 10).to_i

    userdata = Userdata.new "annoy_data_key"
    annoy = userdata.send("category_#{category_id}")
    return not_found unless annoy

    nns = annoy.get_nns_by_item(product_id, limit)
    [200, content_type, [nns.to_json]]
  end

  private

  def not_found
    return [404, content_type,
      [{'error' => 'not_found'}.to_json]]
  end

  def content_type
    {'Content-Type' => 'application/json;charset=utf-8'}
  end
end

run NNS.new
```

図 4 mrubby_content_handler の設定例

Fig. 4 Configuration examples of mrubby_content_handler.

```
% curl 'http://localhost/nns?category_id=1&product_id=234'
[233,234,127,235,223]
```

図 5 ngx_mrubby 上での mrubby_annoy の実行例

Fig. 5 Execution examples of mrubby_annoy on ngx_mrubby.

返却する。類似特徴量を検索するためのコードは図 4 の通り。実行結果は図 5 のようになる。

4. 実験と考察

提案手法の有効性を検証するため、3章で構築したデータベース並びに類似特徴量検索サーバーをECサイトのプロダクション環境に導入した。導入したECサイト上では、商品詳細画面にて関連商品を12点表示する欄を設けており、これらの関連商品のクリック数を計測している。本研究では、類似画像検索の有効性を検証するため、今回提案した手法により選定する商品と、ECサイトの既存の手法で選定する商品間でのクリック率の差を計測した。なお、ECサイトの既存手法は、独自に運用していた簡易的なユーザーベースの協調フィルタリングにあたる。具体的には、該当商品を評価している他の利用者群を類似ユーザーとみなし、それぞれの利用者が評価している商品に対して評価の新しさに重みをつけて一定数取得した後、該当商品と重複商品を除いたものを関連商品として選定する。

実験の手法として、まず既存手法により選定した商品をAパターン、提案手法により選定した商品をBパターンとして、両パターンのクリック率を比較検討するため、表示機会が均等になるよう乱数によりおよそ50%の確率で表示のパターンを判定している。しかし3.1節で構築した時点以降に登録された商品については、提案手法による選定が行えないため、その場合は既存手法で選定した商品を表示し、既存手法側のクリック率計測対象とした。これは検証期間中のECサイトの機会損失を減らす必要から取った措置である。なお、既存手法が協調フィルタリング手法である以上、商品に対する情報が蓄積されていない場合は、既存手法でも選定が行えない場合があるが、その場合は、該当する関連商品なしとして計測の対象から除外している。提案手法の対象となる商品数は約380万点であり、検証期間中の各手法の利用割合は、既存手法68.57%、提案手法31.43%であった。

また、提案手法のうち、商品特性による有効性の比較を行うため、ECサイトに既にあるカテゴリ区分に従い、クリック率を計測して比較、考察を行った。対象のカテゴリ数は120である。

なお、検証にあたり類似特徴量検索サーバーは、これが参照するデータベースファイルを全てページキャッシュするのに十分な量のメモリを搭載している必要があった。これは近似近傍探索の際に木構造を辿る処理がデータベースファイルの広範囲に渡るランダムアクセスとなり、キャッシュされていない場合に都度ディスクへのアクセスが発生して、応答時間の遅延が発生し、導入先のECサイトからの想定要求数を処理できないことが事前の性能評価で確認されたためである。

コーヒードリッパースタンド ナラ (ポット用)



図 6 対象商品

Fig. 6 Target product.

この作品を見ている人におすすめ




図 7 既存手法による選定商品

Fig. 7 Selected products by existing method.

表 1 クリック率とコンバージョン率の比較

Table 1 Comparison of CTR and CVR.

	既存手法	提案手法
クリック率	0.51%	0.76%
コンバージョン率 (クリック数)	0.21%	0.28%

4.1 類似画像検索の評価と考察

対象商品図6に対して、既存手法、提案手法によって選定された関連商品の例をそれぞれ図7、図8に示す。提案手法において、対象商品の形状や特徴を掴み、類似した商品を選定できていることがわかる。これらの選定した商品に対するクリック率とコンバージョン率の比較を表1に示す。クリック数は閲覧数に対するクリック数から、コンバージョン率はクリック数に対する購入回数から求めた。既存手法に比べて提案手法のクリック率が改善しており、提案手法による選定商品が、関連商品としてより興味を引

○ この作品を見ている人におすすめ



図 8 提案手法による選定商品

Fig. 8 Selected products by proposed method.

き、クリックからの回遊が発生していることがわかる。また、コンバージョン率を見ると、既存手法に比べ提案手法が購入に至る確率が高く、回遊だけでなく購入まで検討させる、より関心の高い商品を提案できたことを表している。

4.2 類似画像検索の評価と考察

4.1 節で、既存手法に比べ提案手法による選定が総合的に優れていることがわかった。本節では、商品特性による提案手法の有効性の差を考察する。本研究では、商品特性による有効性の比較を行うため、EC サイトに既にある 120 のカテゴリ区分に従い、クリック率を計測し、既存手法とのクリック率の差を検証した。120 カテゴリのうち、既存手法がクリック率が高かったカテゴリ数は 28、提案手法は 92 であり、約 77% のカテゴリで提案手法の効果が確認された。

商品詳細画面における関連商品のカテゴリごとのクリック率比較のうち、それぞれの手法が有効であったカテゴリ上位 5 件を表 2 と表 3 に示す。提案手法で最も改善したカテゴリは素材・材料/シェルで、既存手法 0.26% に対し、提案手法 1.25% と 1% 近い改善が見られた。反対に提案手法で改善しなかったカテゴリは、文房具・ステーショナリー/しおり・ステッカーで、既存手法 1.20% に対し、提案手法 0.40% であった。

顕著に改善の見られた素材・材料カテゴリは、検証を行った EC サイトの特性上、販売者側の材料の仕入れに用いられることが多く、類似した素材を比較し、より安価な商品を手に入れるユースケースに合致したと考えられる。また、あみぐるみ、セーター・カーディガンといったカテゴリでは提案手法により、形状や質感による類似商品が選定

表 2 既存手法が有効であったカテゴリ上位 5 件

Table 2 Top 5 categories which existing method is effective.

	既存手法	提案手法
文房具・ステーショナリー/しおり・ステッカー	1.20%	0.40%
ベビー・キッズ/靴	0.76%	0.36%
ファッション/コスチューム	0.45%	0.20%
アート・写真/イラスト	0.50%	0.28%
家具・生活雑貨/クッション	0.56%	0.38%

表 3 提案手法が有効であったカテゴリ上位 5 件

Table 3 Top 5 categories which proposed method is effective.

	既存手法	提案手法
素材・材料/シェル	0.26%	1.25%
素材・材料/リボン・テープ	0.47%	1.46%
素材・材料/ボタン	0.53%	1.33%
ぬいぐるみ・人形/あみぐるみ	0.40%	1.17%
ニット・編み物/セーター・カーディガン	0.37%	1.07%

される。これは既存の商品メタデータでは分類できない特徴であり、提案手法がカテゴリによる分類をより細かい粒度で分類補完した結果、利用者に効果的な商品が選定できたことがわかる。一方、しおり・ステッカーやコスチューム、イラストといった、カテゴリ内で形状やデザインに統一性がなく、個々の類似性が低いカテゴリでは提案手法で選定した商品の関連性が低くなり、クリック率が低くなる傾向になったと考えられる。

5. まとめ

本報告では、購買履歴等の情報が蓄積されておらず、商品のメタデータを用いた商品選定が必要な状況において、深層学習に必要な大量の訓練データセットと訓練時間が不要な学習済ネットワークを用いた類似画像検索システムを提案した。そして提案手法の有効性を示すために、EC サイトで独自に運用していた簡易的なユーザーベース協調フィルタリングによる選定商品とのクリック率の差を計測した。加えて、商品特性ごとの有効性の差を確認するために EC サイトのカテゴリ区分に基づいた効果の差を評価した。

結果として、EC サイトの実運用において想定する要求数を処理可能な類似画像による関連商品選定システムを導入し、既存手法と比較して全体的なクリック率とコンバージョン率の改善が見られた。また、類似した多数の商品から比較検討を行う必要があるカテゴリや、カテゴリの分類基準が緩く、類似した形状や質感で更に絞り込み可能な商品が多いカテゴリについては特に効果が高いことも確認できた。

EC サイトでは商品の登録・更新は頻繁に発生するが、本報告ではデータベース構築時点の商品のみが関連商品の選定対象とする構成になっている。よって、今後の課題とし

ては、これらの商品の登録・更新に追従できないことで発生する機会損失を防ぐため、データベース構築後に商品の登録・更新に合わせて近似近傍探索用の木構造を維持する仕組み [15] を検証する必要がある。

参考文献

- [1] Andrew McCallum, Information Extraction: Distilling Structured Data from Unstructured Text, *Queue - Social Computing Volume 3 Issue 9*, pp. 48-57, November 2005
- [2] J. Ben Schafer, Joseph Konstan, John Riedl, Recommender systems in e-commerce, *Proceedings of the 1st ACM conference on Electronic commerce*, pp.158-166, November 03-05, 1999
- [3] Bolei Zhou, Agata Lapedriza, Jianxiong Xiao, Antonio Torralba, and Aude Oliva, Learning Deep Features for Scene Recognition using Places Database, *In Proc. NIPS*, 2014.
- [4] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich, Going Deeper with Convolutions, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015
- [5] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens, Zbigniew Wojna, Rethinking the Inception Architecture for Computer Vision, *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2818-2826, 2016
- [6] David Goldberg, David Nichols, Brian M. Oki, and Douglas Terry, Using collaborative filtering to weave an information tapestry. *Commun. ACM* 35, 12, pp. 61-70, December 1992
- [7] Dieter Fensel, Ying Ding, Borys Omelayenko, Ellen Schulten, Guy Botquin, Mike Brown, Alan Flett, Product Data Integration in B2B E-Commerce, *IEEE Intelligent Systems Volume 16, Issue 4*, pp. 54-59, Jul-Aug 2001
- [8] K. Fukushima. Neocognitron: a self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biological Cybernetics*, 36(4):93202, 1980
- [9] Greg Linden, Brent Smith, Jeremy York, Amazon.com Recommendations: Item-to-Item Collaborative Filtering, *IEEE Internet Computing Volume 7 Issue 1*, pp. 76-80, January 2003
- [10] Hyung Jun Ahn, A new similarity measure for collaborative filtering to alleviate the new user coldstarting problem, *Information Sciences* 178, pp. 37-51, 2008
- [11] Jeff Donahue, Yangqing Jia, Oriol Vinyals, Judy Hoffman, Ning Zhang, Eric Tzeng, Trevor Darrell, DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition. *In Proc. ICML*, 2014
- [12] Matthew D. Zeiler, Rob Fergus, Visualizing and Understanding Convolutional Networks, *In Proc, Computer VisionECCV*, pp. 818-833, 2014
- [13] Nginx, Nginx, <http://nginx.org/ja/>.
- [14] Olga Russakovsky, Jia Deng, Hao Su, Jonathan Krause, Sanjeev Satheesh, Sean Ma, Zhiheng Huang, Andrej Karpathy, Aditya Khosla, Michael Bernstein, Alexander C. Berg, and Li Fei-Fei. 2015. ImageNet Large Scale Visual Recognition Challenge. *Int. J. Comput. Vision* 115, 3, pp. 211-252, December 2015
- [15] Paolo Ciaccia, Marco Patella, and Pavel Zezula, M-tree: An Efficient Access Method for Similarity Search in Metric Spaces, *In Proceedings of the 23rd International Conference on Very Large Data Bases (VLDB '97)*, pp. 426-435, 1997
- [16] Pulkit Agrawal, Ross Girshick, Jitendra Malik, Analyzing the Performance of Multilayer Neural Networks for Object Recognition, *In Proc. ECCV*, 2014
- [17] Sanjoy Dasgupta, Kaushik Sinha, Randomized partition trees for exact nearest neighbor search, *JMLR: Workshop and Conference Proceedings vol 30*, 121, 2013
- [18] Shinzato Keiji, Satoshi Sekine, Unsupervised Extraction of Attributes and Their Values from Product Description., *IJCNLP*, 2013
- [19] Martn Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Yangqing Jia, Rafal Jozefowicz, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dan Mane, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Mike Schuster, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viegas, Oriol Vinyals, Pete Warden, Martin Wattenberg, Martin Wicke, Yuan Yu, Xiaoqiang Zheng, TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems, 2015. Software available from tensorflow.org
- [20] Wen Li, Ying Zhang, Yifang Sun, Wei Wang, Wenjie Zhang, Xuemin Lin, Approximate Nearest Neighbor Search on High Dimensional Data — Experiments, Analyses, and Improvement (v1.0), *In Proc. 2016*
- [21] Y. Lecun, L. Bottou, Y. Bengio, P. Haffner, Gradient-based learning applied to document recognition, *Proc. IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998
- [22] NPO 法人軽量 Ruby フォーラム, <http://forum.mruby.org/>.
- [23] 経済産業省 商務情報政策局 情報経済課, 平成 27 年度我が国経済社会の情報化・サービス化に係る基盤整備 (電子商取引に関する市場調査) 報告書, 2016
- [24] 松本亮介, 岡部寿男, mod.mruby: スクリプト言語で高速かつ省メモリに拡張可能な Web サーバの機能拡張支援機構, *情報処理学会論文誌*, Vol.55, No.11, pp.2451-2460, 2014 年 11 月
- [25] 和田 俊和, 最近傍探索の理論とアルゴリズム, 研究報告 コンピュータビジョンとイメージメディア (CVIM) , 2009-CVIM-169(13), 1-12, 2009-11-19