

CNN およびテキストマイニングを用いたプロダクト画像の印象推定

○鈴木秀通†, 山田篤拓†, 飛谷謙介†, 橋本翔†, 長田典子†

†: 関西学院大学大学院理工学研究科人間システム工学専攻/感性価値創造研究センター,
hide4831@kwansei.ac.jp

概要: 感性の自動指標化を目的とし, プロダクトの画像とレビューデータからのプロダクトの印象推定手法を提案する. 手法は(1)レビューデータからテキストマイニングを用いた評価表現辞書に基づく感性の指標化, (2) 得られた印象とプロダクト画像からの機械学習用画像データセットの作成, (3)構築した CNN によるレビューが不十分なプロダクトの印象推定, から構成される. 本手法を腕時計のデータに適用した結果, 人の評価得点との高い相関が確認され手法の有効性が示された.

1. 背景・目的

プロダクトデザインの分野において, ユーザのニーズを把握し, プロダクトに反映させることは重要である. 特に近年は, 機能や価格, 信頼性といった従来のものづくりにおける価値に加えて, 使用感や快適性などの感性的な価値に注目が集まっている[1]. このような主観的な情報を扱う方法論の一つとして, 実験心理学の手法を用いた感性工学的アプローチが挙げられる[2]. しかしながら従来の手法では, 複数回の主観評価実験によるデータの取得とその分析が必要であるため, 人的・時間的な負荷が高いとされる.

そこで本研究では, Web 上のプロダクトの画像とレビューデータからプロダクトの印象を推定することで, 感性を自動的に指標化する手法を提案する. 提案手法では, まずレビューデータからテキストマイニングを用いた評価表現辞書に基づく感性の指標化, つまりプロダクトに対する印象推定を行う. 次に, 得られた印象を定量化した得点(以下, 印象得点)とプロダクト画像から, 機械学習用の画像データセットを作成する. 最後に, データセットを用いて構築した CNN により, プロダクト画像の印象推定を行う. これにより, レビューデータが不十分であるためテキストマイニングを用いた印象推定が困難であるプロダクトに対し, 画像から喚起される印象の推定を行い, より高精度かつ広範囲な感性の自動指標化が可能になる. 本論文

の流れとしては, 続く 2 章で従来の主観評価実験に基づいた感性の指標化手法の流れを述べる. 3 章では, 対象製品分野の各プロダクトに対する大規模なレビューデータに対してテキストマイニングを用いた, 評価表現辞書に基づく感性の自動指標化手法の詳細を説明する. 4 章では, Web 上からプロダクトの画像とレビューデータを収集し, 算出された印象得点を付与した画像を選定して, 機械学習用の画像データセットを作成する手法の詳細を説明する. また, 作成したデータセットの妥当性を検証する方法について述べる. 5 章では, 作成した画像データセットを用いて CNN を構築し, プロダクト画像の印象得点を推定する手法の詳細を説明する. また, 構築した CNN の性能評価および, 推定される印象得点の妥当性の検証方法について述べる. 6 章では, 対象プロダクトを腕時計として本手法を適用し, 機械学習用の学習データセットを作成してその妥当性を検証した結果と考察を述べる. 7 章では, 作成した画像データセットを用いて CNN を構築し, 印象推定の有効性の検証を行った結果と考察を述べる.

2. 従来の感性の指標化手法

感性工学における主観評価実験に基づいた, 感性の指標化手法[3]の3つの段階について述べる.

第一に, 評価語の収集・選定を行う. 収集では先行研究からの抜粋や, 対象から受ける印象を自由

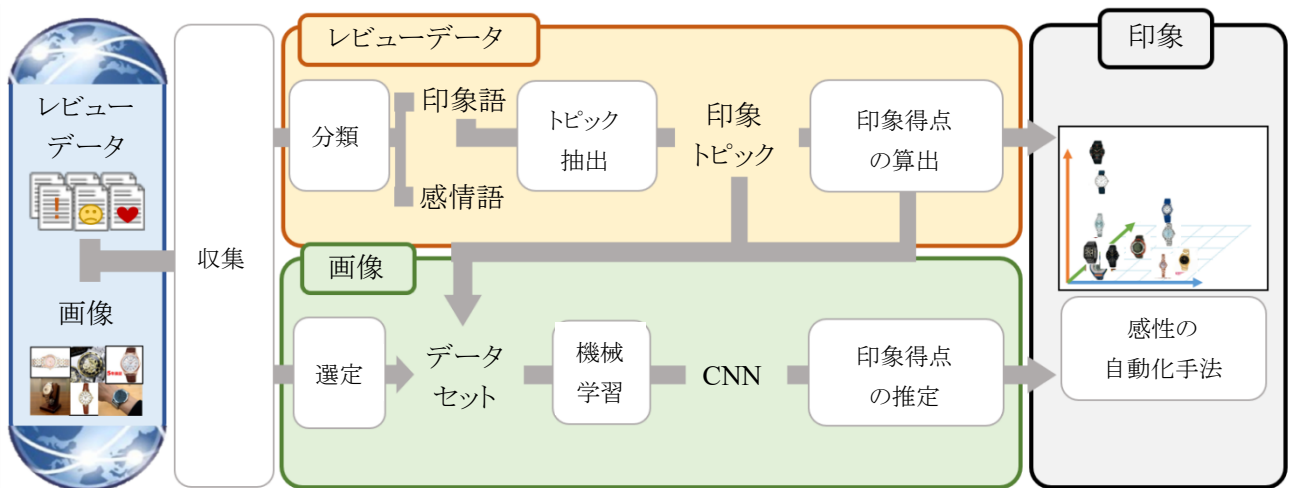


図1 感性の自動指標化の流れ

記述で回答してもらった実験を実施する。また選定では、収集された評価語がふさわしいか判定する適合度実験を実施する。その後、評価語間の意味的な距離の測定を目的とした一対比較実験を実施する。その結果をもとに評価語空間の構造化を行うことで、代表性・網羅性の高い評価語セットを作成する。

第二に、実験刺激の収集・選定を行う。刺激(例えば対象製品分野における画像群)に対しても評価語セットの作成と同様に、収集・選定、刺激空間の構造化を目的とした実験・分析を行う。

最後に、対象製品の印象に寄与する主要因子の抽出・得点の算出を行う。上記で得た評価語セットを用いて刺激セットを評価する実験を行い、得られた評価データに対し因子分析を行う。分析結果から対象製品分野における主要因子を抽出し、各刺激に対して因子得点を算出する。これにより、その因子の意味する性質(印象)を各刺激がどの程度有しているか定量化できる。

以上のように主観評価実験に基づいた手法では、指標化の各段階において複数の実験・分析が必要であるため、人的および時間的な負荷が高いといった問題が存在している。そのため、これらの問題を解決する新たな指標化手法が望まれている。

3. レビューデータを利用した感性の自動指標化手法

感性の自動指標化の流れを図1に示す。レビューデータを利用した指標化としては、まずレビューデータから評価語を収集し、感情語と印象語に分類する。次に、得られた印象語から印象トピック(従来手法に

おける主要因子)を抽出する。最後に各印象トピックに対するプロダクトごとの印象得点を算出する。以下に具体的な手法[4]について述べる。

3.1. 評価語の収集・分類

大量のレビューデータを形態素解析し、レビューデータ内に含まれる感性的な表現(形容詞等の評価語候補群)を、複数の評価表現辞書および品詞情報を用いて収集する。この評価語候補群は、人の感情に関わる高次の評価語(感情語)と、プロダクトの印象に関する低次の評価語(印象語)で構成される。しかしながら、感情が推定できてもそれをプロダクトの設計情報に直接的に反映することは困難である。そのため本研究では、評価語候補群を感情語と印象語に分類し、印象語のみを使用する。評価語の分類は、評価表現に対して内評価/外評価の属性が付与されている、日本語評価アプレイザル辞書[5]を用いて行う。内評価とは、評価対象に対する評価者の感情、もしくは感情を表す行為を示す表現であり、外評価とは、評価対象の特徴を示す表現である。この定義より、内評価が感情、外評価が印象に相当すると考えられる。

3.2. 印象トピックの抽出

前節で得られた印象語を入力とした HDP-LDA[4]を適用し、印象トピックの抽出を行う。HDP-LDA は、文書を入力として文書中の単語のトピック(話題やカテゴリ)を確率的に求める言語モデルである Latent Dirichlet Allocation(LDA)[6]を、ノンパラメトリックベイズモデルに拡張したものである。LDA は、初期のパラメータとして出力のトピック数を指定する必要があるが、HDP-LDA は学習により適切なトピック数を自

動的に決めることができる利点がある。

3.3. 印象得点の算出

各レビューの印象語の出現頻度と、各印象トピックにおける各印象語の重要度を用いて印象トピックの得点化を行い、印象得点を算出する。その際、各印象語の重要度として *term-score*[7]を用いた。*term-score* とは、LDA におけるあるトピック内の単語の重要度の尺度の 1 つであり、ある文書内の単語の重要度の尺度として用いられる Term Frequency Inverse Document Frequency (TF-IDF) [8]をトピックに応用したものである。TF-IDF は、それぞれの単語の文書内の出現頻度を表す TF 値と、それぞれの単語がいくつの文書内で共通して用いられているかを表す IDF 値との積をとり、これを単語の重みとして用いる。つまり、その値が大きいほど各文書において重要度の高い単語といえる。これを応用した *term-score* は、トピック内における単語の重みをつけることができ、値が大きい単語ほど各トピックにおいて重要度が高いといえる。

4. 機械学習用の画像データセット作成手法

図 1 における画像データセット作成について、レビューデータおよびプロダクト画像を用いた作成手法について、具体的に述べる。

4.1. 収集するデータの条件

対象プロダクトのデータとしては、オンラインモールを運営する企業が提供しているプロダクト画像およびレビューデータを用いる。その際、印象語を含むレビュー数が 10 件以上のプロダクトを対象とし、収集したレビューデータから印象語を取得する。

4.2. プロダクトの印象得点の算出

まず、得られた印象語に対して HDP-LDA を適用し、印象トピックを抽出する。その際、得られた印象トピックには、プロダクトの機能や触覚的印象に関するものが含まれる。このような印象の推定は、プロダクト画像から学習した CNN を用いる場合困難である。そのため本研究では、CNN を用いてプロダクト画像から推定する印象として有効である、視覚的印象を表すトピックを用いる。さらに、それらの中から特に視覚的印象に関する印象語を選出し、プロダクト画像における印象トピックとする。最後に、*term-score* を用いて各印象トピックの印象得点を算出する。

4.3. プロダクト画像の選定と印象得点の付与

印象得点が算出されたプロダクトの画像の選定を行う。プロダクト画像を入力として学習を行い、その印

象を推定する場合、画像中の対象プロダクト以外の物体や背景がノイズとなり、推定精度の低下につながる。また、画像のプロダクト領域が見切れている場合、印象に関する特徴の抽出が不十分である。そのため、背景が白色でないものや、プロダクト全体が写っていないものを除く。これらの画像に対して印象トピック毎の印象得点を付与し、機械学習用の画像データセットを作成する。そのデータセットを用いて、印象トピック毎に CNN を構築する。

5. CNN を用いたプロダクト画像の印象推定手法

図 1 における印象得点の推定について、作成した画像データセットを用いて CNN を構築する手法について、具体的に述べる。

5.1. 前処理

機械学習を行う前処理として、K-means 法を用いて画像データセットの印象得点を 7 つのクラスタに分類し、印象得点が小さいクラスタから順に「1」から「7」までの教師ラベルを付与する。これにより、構築した CNN が行う入力画像の 7 クラス識別を、入力画像に対する 7 段階の印象評価として扱うことが可能である。分類するクラスタの数を 7 と設定した理由は、7 段階評価の回答を行う主観評価実験と印象の評価方法を統一するためである。

5.2. CNN の構築

作成したデータセットを用いて CNN を構築する際の、機械学習手法および CNN の構造とパラメータ値、前処理について述べる。

機械学習手法としては、一般物体認識用に構築された CNN である VGG16[9]に対して、*fine-tuning* を適用する。*fine-tuning* を適用する理由は、訓練データセットが少ない場合の機械学習に効果的とされているためである[10]。本研究では、訓練データセットの量はオンラインモール上の対象プロダクトの数およびレビューと画像の質に依存するため、十分な量のデータが得られるとは限らない。そのため、出力層とその直前の全結合層のみを再学習 (*fine-tuning*) し、学習の効率化および精度の向上を図る。その際、出力層を 7 クラス識別用に調整する。CNN の基本的な構造およびパラメータの値に関しては VGG16 の設定に従うが、入力バッチサイズと入力画像のサイズに関しては、作成した画像データセットに合わせて調整する。入力画像に対する前処理としては、画像の切り取りなどの、プロダクト画像の印象に関する情報が欠

落する可能性のある処理は行わず，水平方向のランダムな反転などの処理を対象プロダクトに合わせて行う。

また，機械学習における訓練データおよび検証データ，テストデータの設定について述べる。まず訓練データとして，作成した画像データセットをすべて利用する。次に，検証データは **leave-one-out** 交差検証に従い，訓練データから 1 つずつ分離して学習を行う。テストデータは用意せず，構築した CNN の性能評価は，検証データに対する誤認識率および，推定した印象得点と人の評価得点との比較により行う。

5.3. 印象得点の推定方法

構築した CNN を用いた印象の推定方法としては，まず入力画像に対するクラス「1」から「7」の所属確率をそれぞれ予測する。その後，各クラスの値とそれぞれの所属確率の積を合計して期待値を算出し，入力したプロダクト画像の印象得点とする。

6. 機械学習用画像データセットの作成

対象プロダクトを腕時計として機械学習用の画像データセットを作成した。また，作成したデータセットの妥当性の検証を目的として，人の評価得点との相関をみた。

6.1. データの収集と評価語の分類

楽天株式会社が発行するオンラインモールである「楽天市場」から，楽天ウェブサービス AIP を用いてデータを収集した。その際，全価格帯の腕時計のレビューデータを用いた場合，金額に関する評価が多くなり印象に偏りが生じる可能性がある。そのため，価格が 10 万円以下であることを条件に加えて腕時計のデータ収集を行った結果，腕時計の全商品数は 2,811 点で，対象とするレビューの数は 252,228 件となり，形態素解析と分類の結果，対象レビューデータから収集された印象語は 3,880 語となった。

6.2. プロダクトの印象得点の算出

得られた印象トピック数は 9 となった。各トピックを表 1 に示す。トピック 2, 3, 6 は腕時計の機能に関するものであり，トピック 7, 8, 9 は腕時計の購入および使用に関するものである。また，トピック 4 は触感的印象に関するものである。得られた印象トピックの内，トピック 1, 5 が視覚的印象に関する。この内，特に視覚的印象に関するそれぞれ 3 つの印象語(表 2)を腕時計画像における印象トピックとし，印象得点を算出した。

表 1 抽出された印象トピック

印象トピック	印象語
1	上品だ, 可愛い, 大切だ, 小さい, 小振りだ
2	見づらい, おしゃれだ, 見辛い, 手頃だ, 簡単だ
3	正確だ, 薄い, 便利だ, 不要だ, 簡単だ
4	堅い, おしゃれだ, カジュアルだ, 細い, 洒落だ
5	重い, 高級, 重厚, 質感, 高い
6	カッコイイ, ライト, 見にくい, 子供, ゴツい
7	子供, 手頃だ, 壊れる, 十分だ, 買い得,
8	子供, 邪魔だ(-), 忘れる, 余裕, 緩い
9	上手, 豪華だ, 充実, 大喜びだ, 無愛想だ

表 2 視覚的印象に関する印象語

印象トピック	印象語
1	上品だ, 可愛い, 小さい
5	高級, 重厚, 質感

6.3. プロダクト画像の選定と印象得点の付与

印象得点が算出された 2,811 点の腕時計画像から，1,951 枚の画像を選定した。これらの画像に対してトピック 1 と 5 の印象得点を付与し，機械学習用の画像データセットを作成した。データセットの一部の画像を図 2 に示す。



図 2 プロダクト画像セットの一部

6.4. 画像データセットの評価

作成した画像データセットに付与された印象得点の妥当性の検証を目的として，データセット内のプロダクト画像から受ける印象の度合いを回答する主観評価実験を実施し，得られた人の評価得点とプロダクト画像に付与された印象得点の相関をみた。


主観評価実験は、クラウドソーシングサービスであるクラウドワークスを利用して実施した。クラウドソーシングサービスを利用することで、インターネットを介して不特定多数の人に作業を安価で依頼することが可能である。実験刺激画像としては、画像データセットから無作為に選出した450枚の製品画像を使用し、評価項目としては、画像データセットに用いた2つの印象トピック(表2)を使用した。また、トピック5の「質感」は評価の回答が困難であるため、レビューでの用いられ方に従って「質感が良い」とした。実験では、腕時計の画像を見て、評価項目に対してそれぞれ「非常に当てはまる」、「当てはまる」、「やや当てはまる」、「どちらでもない」、「やや当てはまらない」、「当てはまらない」、「非常に当てはまらない」の7段階で評価する。1枚の画像に対して20人で評価を行い、7段階の評価を1から7に数値化したのち、評価の平均値を製品画像の評価得点とした。製品画像に付与された印象得点と実験で得られた人の評価得点との相関をみた。

製品画像に付与された印象得点と実験で得られた人の評価得点の相関係数を表3に示す。トピック1(上品だ, 可愛い, 小さい)では、相関係数0.6以上の強い正の相関がみられ、トピック5(高級, 重厚, 質感が良い)では中程度の相関がみられた。


トピック5に関して強い相関がみられなかった原因を探るため、印象トピックごとに算出された印象得点を横軸、実験で得られた評価得点を縦軸として各腕時計をプロットした。印象トピックごとのプロット結果を図3に示す。図2より相関係数が低いトピックでは、レビューデータから算出された印象得点が低い値に偏っていることが確認できる。この理由として、印象トピック内の印象語のterm-scoreが低いことがあげられる。各トピック内の印象語のterm-scoreを表4に示す。表4から、トピック5のterm-scoreがトピック1と比べて総合的に低いことがわかる。このような印象トピックの印象得点を算出する場合、トピック内の印象語が得点として反映される度合いは小さい。一方で、トピック1にはterm-scoreが高い印象語(「上品だ」)が含まれるため、高い印象得点が算出されたと考えられる。今後、総合的なterm-scoreが低い印象トピックの得点化手法を改善する必要がある。

表3 人の評価得点と算出した印象得点の相関係数

印象トピック	1	5
相関係数	0.626	0.325



(a) トピック 1



(b) トピック 5

図3 各腕時計画像の実験で得られた評価得点(縦軸)と算出された印象得点(横軸)

表4 印象トピック内の印象語の term-score
(a) トピック 1 (b) トピック 5

印象語	term-score	印象語	term-score
上品だ	0.538	高級	0.204
可愛い	0.186	重厚	0.193
小さい	0.111	質感	0.153

7. CNNを用いたプロダクト画像の印象推定

本論文では、人の評価得点との相関がより高かった印象トピック 1(上品だ, 可愛らしい, 小さい)に対して CNN を構築した。

また、交差検証による誤認識率の確認に加え、レビューが不十分であった腕時計の画像に対する CNN の汎化性能の確認を行った。

7.1. CNN の構築とプロダクト画像の印象推定

データセット内の 1,951 枚の画像を 7 クラスに分類し、すべてのデータを訓練データとした。leave-one-out 交差検証を行い、誤認識率の算出と検証データに対する印象推定を行った。その際、学習のパラメータ値として、学習回数を 50、バッチサイズを 50 と設定した。前処理としては、画像の水平方向のランダムな反転を行った。

交差検証によって算出した誤認識率を表 5 に示す。表 5 の top-1 error は、入力画像のクラスが予測クラスと一致しない確率である。top-3 error は、入力画像のクラスが予測クラスの上位 3 つに含まれない確率である。表 5 から、構築した CNN は検証データに対してチャンスレベル (85.72%) を下回る誤認識率をもち、top-3 error においては 20% 以下の低い誤認識率をもつことが確認できる。

表 5 訓練データに対する誤認識率 (%)

top-1 error	top-3 error
60.18	19.02

CNN によって推定される印象得点の妥当性の確認を目的として、図 3 で用いた 450 枚の画像と同じ検証データに対して推定した印象得点を横軸、人の評価得点を縦軸として各腕時計をプロットした結果を図 4 に示す。相関係数は 0.811 となり、強い正の相関が確認され、テキストマイニング手法のみで算出された印象得点と人の評価との相関係数 0.626 から大幅に向上した。この結果より、本手法を用いて作成した画像データセットから構築した CNN によって推定される、印象得点の妥当性が確認された。

テキストマイニング手法のみのプロット (図 3) と CNN 手法を加えたプロット (図 4) を比較すると、人の評価得点が中位 (3: やや当てはまらない ~ 5: やや当てはまる) のプロダクトに付与した得点が、テキストマイニング手法のみでは低位 (1: 非常に当てはまらない ~ 2: 当てはまらない) 付近であり、適切得点が付与さ

れていなかったのに対し、CNN 手法を加えると適切に中位の得点が付与されている。この中位のプロダクトに対する推定の改善が、相関係数の向上に繋がったと考えられる。




図 4 各腕時計画像の実験で得られた評価得点 (縦軸) と推定した検証データの印象得点 (横軸)

7.2. レビューが不十分なプロダクトの印象推定

感性の自動指標化における、CNN による印象推定手法の有効性の確認を目的として、テキストマイニングによる印象得点の算出が行われていない腕時計画像に対する、人の評価得点と推定した印象得点の相関をみる。

レビュー数が 10 以下であったため、テキストマイニングを用いて印象得点を算出していないプロダクトの画像を 50 枚用意し、4 章で説明したクラウドソーシングサービスを用いて主観評価実験を行い、人の評価得点を得た。構築した CNN を用いて推定した印象得点を横軸、人の評価得点を縦軸として各腕時計をプロットした結果を図 5 に示す。相関係数は 0.862 となり、強い正の相関が確認された。この結果より、CNN を用いた印象推定の補完が適切に行われていることが示された。

参考文献




図 5 各腕時計画像の実験で得られた評価得点(縦軸)と推定した未知画像の印象得点(横軸)

8. まとめ

本研究では、Web 上のプロダクトの画像とレビューデータからプロダクトの印象を推定することで、感性を自動的に指標化する手法を提案した。提案手法では、まずレビューデータからテキストマイニングを用いた評価表現辞書に基づく感性の指標化、つまりプロダクトに対する印象推定を行った。次に、レビューデータが不十分であるためテキストマイニングを用いた印象推定が困難であるプロダクトに対し、画像から印象得点を推定することを目的として、レビューデータから算出した印象得点とプロダクト画像から、機械学習用の画像データセットを作成し、構築した CNN によりプロダクト画像の印象推定を行った。

対象プロダクトを腕時計として本手法を適用した結果、作成した画像データセットに付与された印象得点と人の評価得点との正の相関を確認した。また、構築した CNN を用いて推定した印象得点と人の評価得点との強い正の相関を確認した。以上の結果から、本手法の有効性が示された。

今後はレビューデータにおける強度が低い印象トピックに対する印象得点の算出手法を改善する等、テキストマイニングの精度の向上を図る。また、印象得点の算出および画像データセット作成のさらなる自動化に向けて、推定に用いる印象トピックの自動選出手法および、Web 上から収集したプロダクト画像の自動選定手法を検討していく。

- [1] 豊田直晃, 浅野浩志, 北原路郎, 中田悟, 浅井巖, 高尾泰正, 島田泰拓, 羽多野重信: 粉体層せん断力測定による化粧品用粉体の使用感に関する客観的評価, 粉体工学会誌, 52(12), pp.694-700, 2015.
- [2] Chen, C. H., Khoo, L. P., Chen, K., Pang, J. H., and Huang, Y.: Consumer-oriented product form creation via Kansei engineering, Proceedings of the International Symposium for Emotion and Sensibility e Emotion Research in Practice, pp.184-191, 2008.
- [3] 飛谷謙介, 松本達也, 谿雄祐, 藤井宏樹, 長田典子: 素肌の質感表現における印象と物理特性の関係性, 映像情報メディア学会誌, 71(11), pp.259-268, 2017.
- [4] A. Yamada, S. Hashimoto, and N. Nagata. A text mining approach for automatic modeling of kansei evaluation from review texts. In KEER2018 INTERNATIONAL CONFERENCE ON KANSEI ENGINEERING AND EMOTION RESEARCH in press.
- [5] 佐野大樹: 日本語アプレイザル評価表現辞書-態度評価編-JAppraisal 辞書 ver1, 言語資源協会, 2011.
- [6] Teh, Y.W., Jordan, M.I., Beal, M.J., and Blei, D.M.: Sharing Clusters among Related Groups: Hierarchical Dirichlet Processes, Advances in Neural Information Processing Systems 17, pp.1385-1392, 2005.
- [7] Salton, G., and Buckley, C.: Term-weighting approaches in automatic text retrieval, Information Processing & Management, 24(5), pp.513-523, 1988.
- [8] Teh, Y.W., Jordan, M.I., Beal, M.J., and Blei, D.M.: Sharing Clusters among Related Groups: Hierarchical Dirichlet Processes, Advances in Neural Information Processing Systems 17, pp.1385-1392, 2005.
- [9] Karen Simonyan, and Andrew Zisserman.: Very Deep Convolutional Networks for Large-Scale Image Recognition, CoRR, Vol. abs/1409.1556, 2014.
- [10] Pulkit Agrawal, Ross B. Girshick, and Jitendra Malik.: Analyzing the Performance of Multilayer Neural Networks for Object Recognition, CoRR, Vol. abs/1407.1610, 2014.

鈴木秀通:2018年3月関西学院大学工学部人間システム工学科卒業。現在同大学大学院理工学研究科修士課程在学中。感性情報学および画像の印象に関する研究に従事。

山田篤拓:2017年3月関西学院大学工学部人間システム工学科卒業。現在同大学大学院理工学研究科修士課程在学中。感性情報学およびテキストマイニングに関するに従事。

飛谷謙介:2002年早稲田大学工学部応用物理学科卒業。2004年岐阜県立情報科学芸術大学院大学(IAMAS)修士課程修了。JST 地域結集型共同研究事業特別研究員を経て、2010年岐阜大学大学院工学研究科博士後期課程修了。同年岐阜大学産官学融合本部研究員。2014年より関西学院大学工学部/感性価値創造研究センター特任講師。博士(工学)。主に感性工学, コンピュータビジョンに関する研究に従事。電気学会, 精密工学会, 日本顔学会, ACM など各会員。

橋本翔:関西学院大学工学部 感性価値創造研究センター研究特別任期制助教。博士(人間科学)。専門は心理統計学および多変量解析論。現在は感性工学における感性の指標化研究に従事。

長田典子:1983年京都大学理学部数学系卒業。同年三菱電機(株)入社。1996年大阪大学大学院基礎工学研究科博士後期課程修了。2003年より関西学院大学工学部情報科学科助教授, 2007年教授。2009年米国パデュー大学客員研究員。2013年感性価値創造研究センター長。2015年革新的イノベーション創出プログラム「感性とデジタル製造を直結し, 生活者の創造性を拡張するファブ地球社会創造拠点」サテライトリーダー。博士(工学)。専門は感性工学, メディア工学等