

ファンデーションの塗りムラの検出と 不快感のない可視化手法の実現

梶田美帆¹ 中村聡史¹ 伊藤貴之²

概要：ファンデーションは、ムラなく塗ることで毛穴など肌の欠点を隠すカバー効果等が期待される。しかしその色は素肌と同化しやすく、塗りすぎや一部だけ塗り忘れてしまう問題などが起こりやすい。我々は、化粧時にリアルタイムでファンデーションの塗布状態を可視化することで、自分がどこにどの程度塗ったのかを確認しやすくし、塗りムラをなくすための化粧支援システムの実現を目指している。我々はこれまで、スマートフォンで撮影した素肌とファンデーションを塗布した肌の画像についての機械学習を用いた二値分類と、塗りムラを自身の顔の上に可視化する手法の評価・検討をそれぞれ行ったが、実際のファンデーションを塗布した顔画像から塗りムラを検出・可視化する手法の調査は行っていなかった。そこで本稿では、スマートフォンで撮影した顔画像について、機械学習によるファンデーションの塗りムラの検出および可視化を行う手法を実現するとともに、そのシステムをユーザに利用してもらうことにより有用性を評価した。機械学習の結果、適合率が平均 0.59 と精度は低かった。また、そのなかでも適合率が最も高かった 3 名について、その結果を 4 手法により可視化し、「可視化結果を見ながら化粧直しをすることを想定」し、評価してもらった。その結果、ユーザは塗りムラの可視化システムにおいては、わかりやすさ・塗りムラの修正しやすさを重視していること、また、嫌悪感ファンデーションの塗りムラの可視化においては、「ムラの位置を大まかに囲んで示す」方法が最もユーザが塗りムラを自身で解消するために役立つということがわかった。

キーワード：ファンデーション、塗りムラ、可視化、機械学習

1. はじめに

顔は年齢や性別、感情などの個人の印象を捉えやすい部位[1]であり、人々は顔の印象を理想に近づける手段のひとつとして化粧を施している[2]。2019 年のポーラ社によるインターネット調査[3]によると、15~64 歳の女性の約 80% が化粧をしていることが明らかになった。また、女性のみならず男性の化粧需要も増えてきており、男性用化粧品を販売するブランドも増加している。こうした背景もあり、日本国内の化粧品市場規模は 2018 年度には 2 兆 6490 億円までに成長している[4]。

化粧については一般的に、雑誌などの特集や、化粧品を買う際に受けるビューティーアドバイザーからのアドバイスなどで学ぶことができる。また、近年では芸能人やインフルエンサーらが、YouTube などの動画配信サイトや Instagram などの SNS を通じて、メイクアップ動画などを公開しており、気軽に化粧について学ぶ機会も増えつつある。ここで、2014 年の ASMARQ 社の調査[5]において、一般のユーザの化粧の腕前の自己評価は、100 点満点中平均で約 51 点と低く、自身が施した化粧に満足している人は少ない。これは既存の学習法によって、個人の体質や好みにあった化粧品の選択方法や自身の顔に施す技術を身につけることが難しいためであると考えられる。

化粧には目的によって様々な工程が存在する。ベースメイクにおいて、ファンデーション、下地、コンシーラーは主にシミや毛穴などの気になる点を隠すために、ハイライト、シェーディングは顔を立体的に魅せるために用いられる。ここで、ファンデーションは任意の位置に適切に塗ら

ないとシミや毛穴などの肌の難点を綺麗に隠すことが難しいものである。しかし、何度もファンデーションを重ねると、重ねた部分から化粧が崩れやすくなるため、適切な量を塗る必要がある。

こうした問題を解決するため、我々は化粧時に手軽にファンデーションの塗布状態を可視化することによって、自分がどこにファンデーションを塗り忘れたのかを確認しやすくし、塗りムラをなくす化粧支援システムの実現を目指してきた。そのなかで、まずは、スマートフォンで撮影した素肌とファンデーションを塗布した肌の画像についての機械学習を用いた二値分類[6]を検討し、塗りムラを自身の顔の上に不快感なく可視化する手法の評価[7]を行ってきた。しかしシステムとして実現しておらず、日常的に利用しているファンデーションを塗布した顔画像から塗りムラを検出すること、また可視化するうえで実際に不快感を覚えにくい方法についての調査は行っていなかった。

そこで本稿ではスマートフォンで撮影した顔画像について、機械学習によるファンデーションの塗りムラの検出および可視化を行うシステムを実現するとともに、そのシステムをユーザに利用してもらい有用性を評価する。

2. 関連研究

化粧は自身の顔を理想の印象に近づけるための手段のひとつであるが、人によって好みや理想の仕上がり、肌質などが異なるため、個人のニーズに合った方法を学ぶことは難しい。そのため、写真から検出したユーザの顔に化粧を施すシミュレーションシステム[8]-[10]など、化粧技術の

1 明治大学
Meiji University
2 お茶の水女子大学
Ochanomizu University

向上支援やシミュレーションなどに関する研究が盛んに行われてきた。なかでも、高木ら[11]はユーザが自身の顔に施した実際の化粧品に対してアドバイスするシステムを提案している。このシステムはまず、デジタルカメラで撮影したユーザの顔画像から、化粧の各段階におけるシミュレーション結果と施し方を提示する。ユーザはそのアドバイスをもとに自身で化粧を施したのち、システムにより、シミュレーション結果と実際にユーザが施した化粧の比較によるアドバイスを受けることができる。しかしこの研究ではファンデーションの塗りムラについては考慮されていない。また神武ら[12]は、ユーザ個人の好みの顔画像に近づけるための化粧をユーザの顔画像からシミュレーションし、その実現のために使用すべき商品の提示をするシステムの提案をしている。その他にも画像から顔の色に最適なファンデーションの色を提案するシステム[13]も存在する。

しかし、皮膚は表皮と真皮の2層から成り、光反射の計算が複雑であるため、静止画を用いたシミュレーション結果は照明条件などに左右される可能性がある。こうした問題を踏まえ、より精度の高いシミュレーションを、CGを用いることで実現した研究も存在する。Tsumuraら[14]はユーザの肌の質感に近い顔モデルを作成し、化粧品についてシミュレーションを行った。また、Huangら[15]は肌の光学的特性を考慮するため、Kubelka-Munkモデル[16][17]とスクリーン空間スキンレンダリングアプローチを組み合わせることで、異なる化粧品材料とスタイルを柔軟に適用し、リアルタイムに化粧をシミュレートしている。

一方で、これまで塗りムラの検出にまつわる研究としては、ファンデーション肌が素肌と比較して光をより効率的に吸収する[18]ことに着目し、素肌とファンデーション肌の反射の波長特性の差異を強調する光学フィルタを用いたファンデーション量の定量化・分布計測システムが開発されている[19]。しかしこれは実験により分光透過特性を最適化した光学フィルタが必要であり、一般ユーザが利用することは難しい。また、この研究においては塗りムラの可視化方法はヒートマップのみであり、可視化に対する詳細な印象の調査も行われていなかった。

3. 自身のファンデーションを用いた塗りムラ検出のためのデータセット構築

3.1 概要

我々はこれまで、スマートフォンのカメラによって撮影したファンデーションを塗布した肌画像と素肌の画像を、機械学習を用いて分類する手法について検討した[6]。この研究において、使用した画像は16名の素肌及び12種類のファンデーションを塗布した額と頬の画像を切り出したものであり、その評価は「素肌」か「ファンデーションを塗布した肌」かの二値分類における精度によるものであった。ここで、我々が目的とするシステムは、顔全体からユーザ

自身が利用しているファンデーションによる塗りムラ検出することを目標としている。

本研究では提案手法により顔全体の画像における塗りムラの判定が可能かを調査するため、実験協力者自身が日常的に使用しているファンデーションを塗布した実際の顔画像における塗りムラを機械学習により検出・可視化する実験を行う。判定は本実験のために新たに構築するデータセットを用いて行うが、その訓練データとしては今回のデータセットに加え過去の研究で作成したデータセットを拡張したものの2種類のデータセットを構築した。次節以降では、これらのデータセットの構築方法について詳しく述べていく。

3.2 塗りムラのある顔画像の収集実験

データセット構築のため、素肌とファンデーション肌の画像を収集するファンデーション塗布実験を行った。実験協力者は大学生、大学院生の7名(A~G)であった。撮影にはAndroid XperiaXZ3に内蔵されているカメラを用いた。画素数は約1920万画素、F値は1.9、ISO感度が最大12800である。撮影は以下の手順で行った。

実験協力者にはまず、自身が日常的に利用している下地とファンデーションなどを持参してもらった。また、撮影を開始する前に実験協力者には洗顔をしてもらった。皮脂や化粧品などを落としてもらい、化粧水・乳液などで肌を整えてもらった。その後、下地やファンデーションなどを塗布しない状態で顔写真を撮影させてもらった。次に、下地とファンデーションを塗りムラを作らないパターンと、位置を変えて塗りムラを作る3パターンの計4通りで顔全体に塗布してもらった。このとき、後者では指示した位置に貼ってもらった2cm及び1cm四方のサージカルテープの上から下地・ファンデーションの塗布を行い、ファンデーションが塗られてない部分(塗りムラ)をあえて作ってもらった。テープを貼ってもらうよう指示した位置は図1の通りである。なお、下地およびファンデーションは実験協力者自身が普段から使用しているものを塗布してもらった。また、実験協力者にはテープで保護された箇所以外で塗りムラがなるべくできないように丁寧に塗布するよう指示した。

なお、カメラと実験協力者の距離は約15cmであり、このとき、撮影箇所を中心にフォーカスするようにした。

3.3 画像データセット構築

顔画像における塗りムラを判別するための画像データセット作成手順について説明する。なお、データセットは訓練データの種類を変えて2種類作成した。ここで、過去の研究において作成したデータセットを利用したものをA、本稿で実施した実験において収集した画像から作成したデータセットをBとする。

- **訓練用データセットA:** 我々はこれまでの研究[6]において、実験協力者ひとりにつきファンデーション




図1 テープを貼ってもらった箇所

を塗っていない素肌状態の顔画像 10 枚（部位 2 か所×5 方向）と、ファンデーションを額と頬に塗った顔画像 120 枚（ファンデーション 12 種類×部位 2 か所×5 方向）の 130 枚を 16 名分、計 2080 枚収集した。これらの画像から肌だけを写した画像とするために、該当部位について 500px 四方に 1 枚ずつ切り出し、さらにその画像を 100px 四方に合計 25 枚分割することによって素肌の画像 4000 枚（10 枚×25 分割×16 名）、ファンデーション肌画像 48000 枚（10 枚×25 分割×16 名×ファンデーション 12 種類）を用意した。このファンデーション肌画像の中からランダムで 4000 枚を取り出し、素肌画像 4000 枚とファンデーション肌画像 4000 枚の計 8000 枚をデータセット A とした。

- **訓練用データセット B:** 3 章の実験において塗りムラを作ってもらった状態で撮影した 3 種類の画像について、3096px 四方に切り出したのち、その画像を 100px 四方に切り取り、顔写真 1 枚につき 961 枚の画像を生成する。その中から、背景の壁や髪、眉毛や眼、唇など、肌以外の部位が写っているものを取り除き、肌画像だけのテストデータセット B を作成した。ここで、テープを貼っていた箇所が半分以上写りこんでいた画像を素肌画像、それ以外の画像をファンデーション肌画像とした。素肌画像は 263 枚、ファンデーション肌画像は 4083 枚である。

テストデータの作成は、3 章の実験において撮影した顔写真のうち、素肌のもと顔全体にファンデーションを塗ったものについて、訓練用データセット B と同様の処理を行った。このとき、素肌画像は 2066 枚、ファンデーション肌画像は 1512 枚となった。

これらのデータセットを用いて、2 種類の実験を行った。

4. 機械による塗りムラ検出実験

4.1 学習データの用意

3 章で構築した画像データセットについて、学習に利用




図2 特微量処理概略図

する特微量を生成する。ファンデーションが塗布された肌の色は、素肌の色と比較して赤みや黄みが抑えられると予測されることから、我々は過去の研究において、画像の色の傾向を表した特微量を採用した[6]。具体的には、画像を RGB 色空間から HSV 色空間に変換したのち、色相、彩度、明度の平均と標準偏差を取得・計算し、 $2 \times 3 = 6$ 次元の特微量を生成した（図 2）。その結果、ファンデーション肌と素肌の判別において、平均正解率 82.3%と高精度で判別できた。そこで、今回も同様の特微量を利用する。

次節では、2 種類の学習データについて各実験協力者・塗りムラの位置ごとに学習と分類を行った結果について述べる。

4.2 判別結果と分析

ファンデーション肌と素肌の 2 値分類を行うため学習アルゴリズムとして、ランダムフォレストを利用した。機械学習には Python のライブラリである scikit-learn を利用し、正解率を求めた。正を素肌（ファンデーションを塗っていない肌）、負をファンデーション肌（ファンデーションを塗っている肌）とした。1 枚の画像に対する正解率の期待値は 50%である。

このとき実験協力者・塗りムラの位置ごとにテストデータを分割すると素肌画像の枚数平均 13 枚に対し、ファンデーション肌画像は平均 194 枚と数に偏りが存在する。そこで、対応する素肌画像の枚数と一致するようにファンデーション肌画像をランダムで抽出しテストした。これを 10 回繰り返す、その結果を平均した値を学習結果として表 1~4 に示す。ここで、評価に適合率を採用したのは、塗りムラはある程度の大きさがあり、すべての塗りムラを推定

しようとしてファンデーション肌を素肌と判定してしまうよりも、その一部でも正しく推定できる方が好ましいと考えたためである。我々のシステムは、顔全体のなかからムラを正しく検出することを目的としているため、以降では適合率に注目している。

表より、データセット A とデータセット B による学習の結果、適合率はそれぞれ最高値が 0.76, 0.76, 最低値が 0.43, 0.44 であり、平均は 0.59, 0.59 と低い。また、平均・分散ともにほとんど差がなく、学習するデータセットによる結果への差は見受けられなかった。

4.3 考察

過去の研究[6]においては、素肌とファンデーション肌について 80%以上の精度で判別することが可能であった。しかし今回の研究では望ましい結果が得られなかった。この原因として、以下の 3 点が考えられる。

まず学習の対象の違いが考えられる。以前の研究に用いたデータセットは、頬と額という限定的なパーツにおいて素肌とファンデーション肌を判別することを目的としたものであった。一方で、本稿では顔全体の中から、頬・額・

鼻付近の塗りムラを検出することを目的としている。そのため前者は肌特徴などが学習に有利に働いたのではないかと考えられる。

次に考えられるのが、データセットの大きさの違いである。過去の研究に用いたデータセットが、訓練データ 39000 枚、テストデータが 13000 枚であったのに対し、今回は訓練データが 8000 枚もしくは 4346 枚、テストデータは平均 207 枚とデータ量に差があった。また、訓練データとテストデータの比率も大きく異なっていた。そこで、今後は画像の複製や、画像の分割の大きさの変更などによりデータ量を増やすことで精度が高まるか検討する予定である。

最後に、特徴量が不適切であった可能性が考えられる。我々はファンデーションが塗布された肌の色と素肌の色の差を反映できると考え、画像の HSV 平均と標準偏差を特徴量として採用した。しかし、ここで判別の対象となるファンデーションや素肌の色は、実験協力者ごとに異なる。そのため、ある人物のファンデーション肌とほかの人物の素肌の色が似ていた場合、同じ平均値に素肌と化粧肌を混ざり、判別の精度が落ちてしまうことが考えられる。そこ

表 1 適合率 (データセット A)

| | A | B | C | D | E | F | G | 平均 | 分散 |
|----|------|------|------|------|------|------|------|------|-------|
| 額 | 0.69 | 0.75 | 0.60 | 0.57 | 0.43 | 0.60 | 0.50 | 0.59 | 0.012 |
| 頬 | 0.51 | 0.64 | 0.48 | 0.76 | 0.71 | 0.44 | 0.54 | 0.58 | 0.015 |
| 鼻 | 0.56 | 0.56 | 0.62 | 0.47 | 0.62 | 0.67 | 0.55 | 0.58 | 0.004 |
| 平均 | 0.59 | 0.65 | 0.57 | 0.60 | 0.59 | 0.57 | 0.53 | 0.59 | 0.010 |

表 2 適合率 (データセット B)

| | A | B | C | D | E | F | G | 平均 | 分散 |
|----|------|------|------|------|------|------|------|------|-------|
| 額 | 0.74 | 0.76 | 0.64 | 0.59 | 0.44 | 0.66 | 0.50 | 0.62 | 0.014 |
| 頬 | 0.57 | 0.58 | 0.54 | 0.74 | 0.69 | 0.47 | 0.52 | 0.59 | 0.009 |
| 鼻 | 0.53 | 0.60 | 0.67 | 0.47 | 0.63 | 0.53 | 0.56 | 0.57 | 0.005 |
| 平均 | 0.62 | 0.65 | 0.62 | 0.60 | 0.59 | 0.55 | 0.53 | 0.59 | 0.009 |

表 3 正解率, 真陽性率, 真陰性率の平均と分散の全体平均 (データセット A)

| | 正解率 | | 真陽性率 | | 真陰性率 | |
|---|------|-------|------|-------|------|-------|
| | 平均 | 分散 | 平均 | 分散 | 平均 | 分散 |
| 額 | 0.59 | 0.011 | 0.63 | 0.059 | 0.56 | 0.037 |
| 頬 | 0.59 | 0.021 | 0.54 | 0.101 | 0.64 | 0.027 |
| 鼻 | 0.59 | 0.005 | 0.76 | 0.035 | 0.42 | 0.032 |

表 4 正解率, 真陽性率, 真陰性率の平均と分散の全体平均 (データセット B)

| | 正解率 | | 真陽性率 | | 真陰性率 | |
|---|------|-------|------|-------|------|-------|
| | 平均 | 分散 | 平均 | 分散 | 平均 | 分散 |
| 額 | 0.61 | 0.013 | 0.63 | 0.068 | 0.59 | 0.036 |
| 頬 | 0.57 | 0.011 | 0.49 | 0.059 | 0.66 | 0.020 |
| 鼻 | 0.60 | 0.009 | 0.76 | 0.051 | 0.43 | 0.020 |

で、HSV 以外の表色系や画像の周波数を算出し、特徴量とすることで制度が改善する可能性がある。

また、特徴量に適切な重みづけをすることも考えられる。ファンデーションの特徴の一つである毛穴を埋める効果は肌の表面を均一に整えることにつながる。そのため、ファンデーションが正しく塗られた肌の画像は、素肌画像と比較して標準偏差が下がることが期待される一方、逆に塗りムラがあると素肌よりも標準偏差が上がる可能性がある。ここで、色平均よりも標準偏差を重要と考え、標準偏差に定数をかけることで重みづけをすることで改善する可能性がある。そこで実際に、平均の特徴量平均を標準偏差の特徴量平均で割った値を標準偏差に乗算し学習したところ、精度は表 1~4 のものとはほぼ変わらなかったものの、重みづけをした結果の方の分散値が小さい傾向があった(表 5)。つまり、適切な重みづけにより精度が多少向上する可能性が示唆された。

今後は以上のことを踏まえ精度を高めていく予定である。

5. 可視化評価実験

5.1 概要

我々はこれまでの研究[7]において、顔に可視化されたファンデーションの塗りムラに対して人がどういった印象を抱くか調査するため、AIにより生成した顔画像および実験協力者自身の顔写真にファンデーションの塗りムラを指摘する意図の加工を施し、その写真に対する印象評価実験を行ってきた。

その結果、ファンデーションの塗りムラの可視化の際には、可視化される本人が可視化によって受ける印象を考慮する必要があることがわかった。また、提案手法の好ましさやわかりやすさについて総当たりで評価してもらったところ、ムラの位置が相対的にわかりやすいものが好まれる傾向が明らかになった。同時に、印象評価においては「明るい - 暗い」、「あたたかい - 冷たい」、「積極的 - 消極的」、「派手 - 地味」の項目についてポジティブな可視化方法が好まれる傾向があった。

しかしこの評価の対象となった顔画像は、顔のランダムな位置に塗りムラがあると仮定したものであり、可視化された塗りムラが必ずしも実際に存在する塗りムラであると

は限らなかった。また、前回の研究では加工が施されたまさにその位置にムラがあるものとして評価してもらったが、ユーザにとって、実験により塗りムラの位置が正確に示されずとも、大体の位置さえ示されれば、塗りムラに気づき修正することが十分可能であることが示唆された。

そこで本実験では、自身が普段使用しているファンデーションを塗ってもらった顔画像について機械学習により検出された塗りムラを実際に可視化し、提案手法が実際に塗りムラをなくすために役立つかについて検証する。具体的には前章で述べた機械学習の結果のうち適合率が7割を超えた学習結果が存在する3名(実験協力者 A,B,D)の顔画像について、機械学習の結果に基づき塗りムラを可視化し、「塗りムラの位置を正確に示す」方法と「大体の位置を示す」方法のどちらが使い心地がよいか、好ましさ(使いやすさ)・わかりやすさ・塗りムラの修正しやすさの3点においてそれぞれ評価してもらった。

5.2 画像データセット作成

まず、3章の実験において撮影した実験協力者 A, B の額に塗りムラがある顔写真, D の頬に塗りムラがある顔写真を正方形に切り取り、4枚ずつ複製した。その後それぞれの顔写真について、データセット B により、機械学習を行い、塗りムラを検出する。ここで、前章における機械学習の結果は、ファンデーション肌画像と素肌画像の枚数を一致させるため、テストデータセットの中からファンデーション肌画像と素肌画像と同数枚抽出しテストしたものであり、対象の一部しか判別できていなかった。そこで、ファンデーション肌画像すべてに対し同じチューニングで学習を行い、素肌とファンデーション肌を判別した。

続いて、機械学習により素肌と判別された位置を示す意図の加工を4通り施す。この加工においては、我々の過去の研究における印象評価で評価が高かった、緑色で塗りムラを塗りつぶすおよび囲う方法を採用した。具体的な加工の例を図3に示す。図4-a, b, c, dはそれぞれ提示位置・可視化方法が、「正確・塗りつぶす」、「正確・囲う」、「大まか・塗りつぶす」、「大まか・囲う」ものである。

5.3 実験手順

実験協力者3名には、前節で用意した加工した各顔画像に対し、それぞれ「提示手法が好ましいか、好ましくないか」「塗りムラがわかりやすいか、わかりにくい」「塗り

表5 正解率、適合率、真陽性率、真陰性率の平均と分散の全体平均
(標準偏差に重みづけを施したデータを用いて学習)

| | 正解率 | | 適合率 | | 真陽性率 | | 真陰性率 | |
|---|------|-------|------|-------|------|-------|------|-------|
| | 平均 | 分散 | 平均 | 分散 | 平均 | 分散 | 平均 | 分散 |
| 額 | 0.55 | 0.002 | 0.56 | 0.002 | 0.52 | 0.092 | 0.58 | 0.061 |
| 頬 | 0.56 | 0.008 | 0.49 | 0.063 | 0.45 | 0.057 | 0.68 | 0.041 |
| 鼻 | 0.56 | 0.007 | 0.55 | 0.005 | 0.63 | 0.067 | 0.50 | 0.024 |




図3 可視化方法



図4 可視化評価システム

ムラを修正しやすいか、しにくい」という観点で7段階（非常に、とても、少し、どちらでもない、少し、とても、非常に）の印象評価を行ってもらった（図4）。このとき実験協力者には、自身が提示される画像を見ながら化粧直しする（ファンデーションを塗りなおす）ことを想定して評価を行うように指示した。なお、順序効果の影響を考慮し、画像の提示順及び印象評価対の順番はランダムとした。

また実験後に簡単なアンケートに回答してもらった。内容は以下の通りである。

- Q1. 化粧をしている最中などに、このように塗りムラを可視化されたら、塗りムラを自分で直すのに便利だと思いますか。（はい/いいえ/どちらでもない）
- Q2. Q1について、その理由を教えてください。
- Q3. 塗りムラについて、正確に位置を示さずとも、大まかに位置が示されれば、自分で周囲の塗りムラに気付き修正が可能だと思いますか。（はい/いいえ/その他）
- Q4. 塗りムラを可視化するシステムにおいて、最も重視することはなんですか。（好ましさ/わかりやすさ/修正しやすさ/その他）
- Q5. どのように塗りムラが可視化されればもっと使いやすいと思いますか。
- Q6. その他何か気づいたことがあれば教えてください。

表9 可視化方法に対する印象調査結果

| | a) 正確 塗り潰す | b) 正確 囲う | c) 大まか 塗り潰す | d) 大まか 囲う |
|--------|---------------|-------------|----------------|--------------|
| 好ましさ | 0.67 | 0.00 | -0.33 | 0.33 |
| わかりやすさ | 1.00 | 1.33 | 0.33 | 2.33 |
| 修正しやすさ | -0.67 | 1.67 | -1.00 | 2.00 |

5.4 結果

印象調査の結果の各手法における平均を表9に示す。このとき、最もポジティブな評価のスコアは+3で、最もネガティブな評価のスコアは-3である。

表9の結果より、「好ましさ」においては、「正確・塗りつぶす（図4-a）」、「大まか・囲う（図4-d）」、「正確・囲う（図4-b）」、「大まか・塗りつぶす（図4-c）」の順に評価が高かった。我々は、大まかに提示する2手法の方が、正確な位置を提示するよりも塗りムラの表示される量が少なくなるため、不快感を覚えにくいと考えていたが、結果は異なっていた。

また、提案手法の「わかりやすさ」「塗りムラの修正しやすさ」において、提示位置・可視化方法がそれぞれ、「大まか・囲う（図4-d）」、「正確・囲う（図4-b）」、「正確・塗りつぶす（図4-a）」、「大まか・塗りつぶす（図4-c）」の順に評価が高いことがわかる。このことから、可視化方法においては、ムラを塗りつぶすよりも囲う方が適していると考えられる。

また、「塗りムラの修正しやすさ」において、塗りムラの位置を大まかに提示する2手法は、「大まか・囲う」方法が塗りムラの位置を正確に提示する2手法も含めた4手法の中で一番評価が高い一方で、「大まか・塗りつぶす」方法は一番低い評価と評価が割れている。これは、「塗りムラの位置を正確に示すよりも、大体の位置を示す方が修正しやすい」という我々の仮説と異なる結果であった。

5.5 考察

システムの有用性については、Q1, Q2の「提案手法の有

用性とその理由」に関する質問において、実験協力者全員から「提示された場所だけ直せばいいので無駄が省けそう」「自分では塗りムラを見つけるのが難しいので、可視化されると便利」「自分では気づかない塗りムラに気づくことができるし、修正して塗りムラがないことがわかればその日の化粧に自信がもてそう」などとシステムの利用にポジティブな意見が得られた。

我々は、塗りムラの可視化において、ムラの位置を大まかに提示する手法の方が、正確な位置を提示するよりも、不快感を覚えにくいと考えていたが、結果は異なっていた。そこで、個人ごとに評価を確認したところ、「大まか・囲う（図 4-d）」手法について、2名は「少し好ましい」との評価をつけている一方で、1名は「とても好ましくない」と真逆の評価をつけるなど、実験協力者ごとに評価が異なっていることがわかった。このことから、個人ごとに評価基準が異なること、そして塗りムラの量や偏り方などによって受ける印象に差がある可能性が示唆された。ここで我々の目的は、全員が不快感を覚えない塗りムラの可視化方法を検討することであった。しかし、Q4では「塗りムラ可視化システムにおいて、最も重視すること」として、2名が塗りムラの修正しやすさを、1名が塗りムラのわかりやすさを挙げており、嫌悪感については二の次であることがわかる。これは、ユーザはそもそもムラという嫌なものを可視化されるものであるという認識のもとシステムを利用しているためであると考えられる。そのため、塗りムラがわかりやすく、修正しやすいシステムならば、ある程度の不快感には目をつぶりながら利用してもらえると考えられる。実際に、「好ましさ」においては評価の4手法における平均が0.17と低く、可視化方法についてほとんど好ましく感じていなかったのにもかかわらず、Q1, 2の回答ではシステムの有用性においてポジティブな評価が得られていた。

結果より、「わかりやすさ」「塗りムラの修正しやすさ」という観点において、ムラを塗りつぶすよりも囲う可視化方法が適していると考えられる。実際に、システムの改善方法等を問うたアンケートのQ5, 6において、「リアルタイムに塗りムラを修正できていく過程がこのシステム上で見えるなら、中が塗りつぶされていない方がいい」「ムラが塗りつぶされてしまうとムラ自体が見づらくなってしまいうので使いにくそう」「外枠だけのものの方がムラのある箇所が見えるのでわかりやすい印象を受けました」など、ムラ自体を自分で確認できた方が好ましいという回答が全員から得られた。一方で、「中が塗りつぶされている方が塗りムラの場所は分かりやすかった」「色が塗られている方が嫌悪感は少ないように思いました」という意見も得られた。この結果は、塗りつぶす方が囲う方よりも「好ましく、塗りムラがわかりやすい」と評価が高かった我々の過去の研究とは反対であった。これは、今回の評価実験が「提示される画像を見ながら自身で化粧直しする（ファンデーション

を塗りなおす）」想定のもと行われたものであったのに対し、過去の実験においてはそういった条件を提示しておらず、塗りムラの位置がわかりやすいかどうかには焦点を当てて評価がなされたことによる違いであると考えられる。

「塗りムラの修正しやすさ」においては、塗りムラの位置を大まかに提示する2手法の評価が割れており、これは、「塗りムラの位置を正確に示すよりも、大体の位置を示す方が修正しやすい」という我々の仮説と異なる結果であった。しかし、Q3において「大まかに位置が示されれば、自分で塗りムラに気づき修正が可能」であることに全員が賛同している。また、Q5において「塗りムラが小さい箇所でも複数あると直しにくいと感じたので、ある程度大まかな場所を可視化して提示してくれた方が直しやすさはある」ことや、「細かすぎると見づらいと思ったので、ある程度見やすさを重視した方が実際使う時便利」という意見が得られたことから、やはりユーザにとっては正確な位置よりも大まかな位置を示す方が塗りムラを手直ししやすいものと考えられる。

以上のことから、ユーザは塗りムラの可視化システムにおいては、わかりやすさ・塗りムラの修正しやすさを重視していること、また、嫌悪感ファンデーションの塗りムラの可視化においては、「ムラの位置を大まかに囲んで示す」方法が最もユーザが塗りムラを自身で解消するために役立つということが考えられる。

6. おわりに

本稿ではスマートフォンで撮影した顔画像について、機械学習によるファンデーションの塗りムラの検出および可視化を行う手法を実現することを目的とし、まず、提案手法により顔全体の画像における塗りムラの判定が可能かを調査するため、ファンデーションを塗布した実際の顔画像における塗りムラを機械学習により検出・可視化する実験を行った。しかし、判定精度は低かった。この問題に関しては、特徴量の見直しやデータ量を増やすことなどにより、改善を図る予定である。

また、実際にファンデーションを塗ってもらった顔画像について機械学習により検出された塗りムラを可視化し、実際に塗りムラをなくすために最もふさわしい可視化手法および提案システムの有用性の検討を行った。その結果、ファンデーションの塗りムラの可視化においては、「ムラの位置を大まかに囲んで示す」方法がユーザにとって好ましいことが明らかになった。しかし今回は、評価者数が3名と少ないうえ、システムを利用して実際に塗りムラを手直ししてもらったうえでの評価を収集することはできていなかった。そのため、今後はリアルタイムで塗りムラを可視化したものに対して評価実験を行う予定である。

参考文献

- [1] Leslie, Z.. “Reading Faces: Window To The Soul?”, Westview Press, 1997.
- [2] J. A. Graham and A. J. Jouhar. The effects of cosmetics on person perception. *International Journal of Cosmetic Science*, 1981, vol. 3, no. 5, pp. 199-210.
- [3] ポーラ文化研究所, “ポーラ文化研究所化粧調査 2019”, <https://www.cosmetic-culture.holdings.co.jp/report/pdf/191212kitai.pdf>, (参照 2022-7-03) .
- [4] 株式会社矢野経済研究所, “化粧品市場に関する調査を実施 (2019 年) ” , https://www.yano.co.jp/press-release/show/press_id/2355, (参照 2022-7-03) .
- [5] ASMARQ, “メイクに関するアンケート調査” , <https://www.asmarq.co.jp/data/mr201404makeup/>, (参照 2022-7-09) .
- [6] Kajita, M., Nakamura, S.. Basic Research on How to Apply Foundation Makeup Evenly on Your Own Face, 20th IFIP TC14 International Conference on Entertainment Computing (IFIP ICEC 2021) , pp.402-410, 2021.
- [7] 梶田 美帆, 中村 聡史. ファンデーションの塗りムラをなくすための基礎調査, 第13回データ工学と情報マネジメントに関するフォーラム (DEIM2021) , 2021, no.C14-4, pp.1-8.
- [8] 古川貴雄, 塚田章. 魔法の化粧鏡—実時間顔画像認識に基づくメイクアップシミュレーション. *画像ラボ*, 2002, vol. 13, no. 10, pp. 34-38.
- [9] Liu, L., Xu, H., Xing, J., Liu, S., Zhou, X. and Yan, S.. “Wow! You Are So Beautiful Today!”, *Proceedings of the 21st ACM International Conference on Multimedia (MM '13)* , 2013, pp. 3-12.
- [10] Wang, S., Wang, Y. and Li, B.. “Face Decorating System Based on Improved Active Shape Models”, *Proceedings of the 2006 ACM SIGCHI International Conference on Advances in Computer Entertainment Technology (ACE '06)* , 2006, pp. 65-es.
- [11] 高木佐恵子. メイクアップ技能上達のためのアドバイスシステム. *芸術科学会論文誌*, 2013, vol. 2, no. 4, pp. 156-164.
- [12] 神武里奈, 星野准一. 好みの顔画像の色に基づくメイクアップ支援システム. *日本感性工学会論文誌*, 2017, vol. 16, no. 3, pp. 299-306.
- [13] Jhilmil J. and Nina T. B.. Snap and match: a case study of virtual color cosmetics consultation. *CHI Extended Abstracts 2010*, pp. 4743-4754.
- [14] Tsumura, N., Ojima, N., Sato, K., Shiraishi, M., Shimizu, H., Nabeshima, H., Akazaki, S., Hori, K. and Miyake, Y.. Image-Based Skin Color and Texture Analysis/Synthesis by Extracting Hemoglobin and Melanin Information in the Skin. *SIGGRAPH '03*, 2003, vol. 22, no. 3, pp. 770-779.
- [15] Huang, C. G., Lin, W. C., Huang, T. S. and Chuang, J. H.. Physically-based Cosmetic Rendering. *Proceedings of the ACM SIGGRAPH Symposium on Interactive 3D Graphics and Games (I3D '13)* , p. 190.
- [16] 土居元紀, 大槻理恵, 富永昌治, 池田直子, 引間理恵, 丹野修. クベルカ-ムンク理論に基づいたファンデーション塗布肌の分光反射率の推定. *電子情報通信学会論文誌*, 2009, vol. 92, no. 9, pp. 1602-1612.
- [17] Kubelka, P. and Munk, F.. Ein Beitrag zur Optik der Farbanstriche. *Z. tech. Physik*, 1931, pp. 593-601.
- [18] 五十嵐崇訓. 肌の質感をコントロールする化粧品の研究開発. *応用物理学会分科会日本光学会*, 2014, vol. 43, no. 7, pp. 318-324.
- [19] 西野顕, 中村睦子, 宮下京子. 機能性分光フィルタを用いたファンデーション定量・分布計測システムの開発と応用. *日本色彩学会誌*, 2013, vol. 37, no. 3, pp. 202-203.
- [20] Generated Media, Inc., “Generated Photos” , <https://generated.photos/>, (参照 2022/7/03)
- [21] 井上 正明, 小林 利宣. 日本における SD 法による研究分野とその形容詞対尺度構成の概観. *教育心理学研究*, 1985, vol. 33, no. 3, pp. 253-260.