

# CrowdRetouch: ユーザの画像補正傾向に基づく 画像一括補正システム

齊藤 優理<sup>1)</sup> (非会員)      伊藤 貴之<sup>1)</sup> (正会員)

1) お茶の水女子大学大学院

## CrowdRetouch: An At-once Image Retouch System based on Retouching Parameter Statistics of Users

Yuri Saito<sup>1)</sup> (Non Member)      Takayuki Itoh<sup>1)</sup> (Member)

1) Graduate School of Humanity and Sciences, Ochanomizu University

{ yuri, itot }@itolab.is.ocha.ac.jp

### アブストラクト

自分で撮影した写真に一定の補正を施して他者と共有する機会が増えているが、その補正パラメータの調整は不慣れなユーザには容易ではない。また同様な写真を多数撮影するユーザには、同様な画像補正を1枚ずつ施す手間が生じてしまう。そこで本論文では、同じようなシーンで撮影された写真群に対して、各ユーザの画像補正の傾向を反映した画像一括補正を可能とするシステム"CrowdRetouch"を提案する。CrowdRetouchではカテゴリ分類されたサンプル学習画像をユーザに提示して手動画像補正を施してもらい、その補正傾向から所属ユーザクラスを特定し、ユーザクラスごとに適用した回帰分析結果に沿って他の画像を一括補正する。いったんユーザクラスが形成されれば、そのあとに参入する新規ユーザについては、さらに少数のサンプル学習画像に対する画像補正結果から所属ユーザクラスを特定できるため、小さな手間でも画像一括補正処理を利用し始めることができる。CrowdRetouchを利用することにより、画像パラメータの調整に不慣れなユーザであっても、多数の写真群に対して手間と時間を割かずに、各ユーザの嗜好を反映した画像一括補正ができると期待される。

### Abstract

It is getting popular to retouch personal photographs before sharing via Internet or other media, however, operations for adjusting image retouch parameters are not easy for novice users. Also, it is bothering or time-consuming that we may require same processes over and over to retouch similar photographs. We present a new image retouch system "CrowdRetouch" which reflects users' tendency of image retouch for a set of similar photographs. CrowdRetouch firstly asks users to manually retouch sample training images, and then divides the users based on the image retouch parameters. It then applies a regression analysis to each of user clusters to solve the relationship between the retouch parameters and image features, and automatically retouches rest of similar photographs based on the regression analysis results. After forming the user clusters, CrowdRetouch specifies the clusters of new users with smaller number of training images, and therefore we do not need to require heavy preprocesses to the new users. We expect CrowdRetouch realizes personalized automatic image retouching to large number of photographs while reflecting preferences of novice users.

## 1. はじめに

デジタルカメラやスマートフォンの普及、および写真を使ったコミュニケーションを可能にするソーシャル・ネットワークキング・サービス (SNS) などの拡大により、日常生活の中で撮影した写真をネットワーク上で共有することが容易になった。

自分で撮影した画像をSNS上で公開する際に、各種アプリケーションに搭載されている自動補正機能や、画像補正ソフトウェアを使って、画像の明るさや色合いなどを補正してからアップロードすることもしばしばある。自動補正機能には、多くのユーザーが適切だと感じるように自動的に補正できるという利点がある。一方で、各ユーザーの嗜好や各シーンの特性を反映することが難しいという問題がある。画像補正ソフトウェアによる補正には、明るさや色合いなどのパラメータを手動で調整することで、各ユーザーの嗜好や各シーンの特性を反映できるという利点がある。一方で、画像補正パラメータの調整に慣れないユーザーにとっては、どのパラメータを調整すれば適切に補正できるかわからないことが多い。また、日々の記録として撮影する料理写真のように、枚数の多い写真群に対して一括補正する場合にも、1枚ずつ手動操作で画像補正する手間と時間を割かなくてはならない。

本論文では、同じようなシーンで撮影された写真群に対して、各ユーザーの画像補正の傾向を反映した画像一括補正を可能とするシステム"CrowdRetouch"を提案する。CrowdRetouchでは、まずサンプル学習画像をカテゴリ分類する。次にある程度の人数の初期ユーザーに対して、画像カテゴリごとに一定数のサンプル学習画像を手動で画像補正させ、その特性によって初期ユーザーをクラスタリングする。続いて各ユーザークラスタに対して画像補正パラメータの回帰分析を適用し、その結果を画像一括補正に用いる。新規ユーザーが参入した際には、さらに少数のサンプル学習画像に対する手動画像補正からその新規ユーザーの所属ユーザークラスタを特定できる。そのため新規ユーザーは、小さな操作量によってその後の画像一括補正処理を利用できる。

CrowdRetouchを利用することにより、画像パラメータの調整に慣れないユーザーであっても、多数の写真群に対して手間と時間を割かず、各ユーザーの嗜好を反映した画像一括補正ができると期待される。

本論文では、大規模画像セット (ImageNet[1]) で収集した写真と、著者がオート機能で撮影した写真を適用事例として、CrowdRetouchの効果を検証した結果を示す。

## 2. 関連研究

画像の自動補正手法には大きくわけて、全自動型の手法と対話操作型の手法がある。

全自動型の手法は、Picasa[2]やPhotos[3]などの自動補正機能で採用されている。これらのソフトウェアでは簡単な操作で対象画像を一括補正する機能を有する。しかし、これらの機能では必ずしもユーザーの意図や嗜好に沿って効果的に画像を補正できるとは限らない。そこで補正結果の満足度を上げるために、画像群を分類したり、ユーザーの対話操作を行ったりすることで

補正結果を調整する研究が活発になされている。

画像群分類による画像補正のアプローチの一つとして、画像認識技術を用いて物体認識し、領域ごとにパラメータを変えて補正する手法がある[4]。また、画像群をカテゴリに分類し、それぞれのカテゴリごとに補正パラメータを算出するもある[5]。

一方、対話操作型の画像補正のアプローチの一つとして、候補とされるデザインや補正画像をユーザーに提示し、対話操作によってパラメータを調整する手法がある[6][7]。これらは、1枚ずつ画像に対して補正する場合に向いている手法であり、大量の写真群に対して補正する場合には手間と時間がかかってしまう。

大量の写真群に対して、ユーザーの意図や嗜好を効率的に反映した画像補正を実現するために、機械学習を用いた手法が提案されている。Kangらは、システムが提示する複数の補正画像をユーザーが評価することで、システムがユーザーの意図や好みを学習し、画像補正にユーザーの嗜好を反映するシステムを提案している。ユーザーの評価結果より、画像特徴量空間での画像間距離と、補正パラメータ空間での画像間距離が比例するような計算モデルを算出し、ユーザーの嗜好を反映した画像補正パラメータを算出する手法を用いている[8]。また、小山らが提案するSelPh[9]では、ユーザーが写真群の色補正パラメータを調整することで、システムがユーザーの意図や好みを学習し、補正パラメータの調整作業を効果的に支援する。ユーザーの嗜好を反映した画像補正パラメータの算出方法はKangらの手法と同様である。Bychkovskyらは、プロの写真家に大量のサンプル画像を補正してもらった結果を用いて、ユーザーの好みに近いプロの写真家の補正を元に差分を反映して画像補正する手法を提案している[10]。さらに、荒川らは、対話型進化計算を用いてユーザーの好みにあった画像に進化していく顔画像美観化フィルタシステムを提案している[11]。

これらに対して、本報告で提案するCrowdRetouchは、まずサンプル学習画像をカテゴリ分類し、画像カテゴリごとにユーザーに少数のサンプル学習画像を補正させ、その結果を用いてユーザーをクラスタリングする。続いて補正パラメータの回帰式をクラスタごとに算出し、それを用いて画像を一括補正するシステムとなっている。

## 3. Crowd Retouch のシステム概要

### 3.1 処理手順

本章ではユーザーの嗜好を反映した画像一括補正を可能とするためのシステム"CrowdRetouch"を提案する。

CrowdRetouchは、同じようなシーンで撮影された写真群を前提として、少数のサンプル画像に対する補正操作結果をもとに、ユーザーの補正特性傾向を反映した画像一括補正を可能とするシステムである。毎日の記録で撮影する料理写真をまとめて補正する、数十枚ある同じような風景の写真をまとめて補正する、といったように1人のユーザーが同じような被写体の画像を補正するユースケースを想定している。

CrowdRetouchの処理手順は以下の通りである。処理手順は「システムの訓練」と「タスクの実行」の2段階で構成される。




Fig. 1 Window capture of CrowdRetouch

1. システムの訓練

- 1-1. 画像をカテゴリごとに分類する. 3.2 節参照.
- 1-2. ユーザに画像カテゴリごとに少数のサンプル学習画像を色補正させる. 3.3 節参照.
- 1-3. 1-2 の結果を用いて, 補正の好みによってユーザをクラスタリングする. 3.4 節参照.
- 1-4. 補正パラメータの回帰式を画像クラスタ・ユーザクラスタごとに算出する. 3.5 節参照.
- 1-5. 新しい画像がどの画像クラスタに属するかを推定するための処理に対して学習する. 3.6 節参照.

2. タスクの実行

- 2-1. 新しい画像に対して, どの画像クラスタ・ユーザクラスタに配属するかを判定する. 3.7 節参照.
- 2-2. 配属されたクラスタの重回帰分析の予測式を適用し, 画像を自動補正する. 3.7 節参照.

3.2 画像クラスタの形成

CrowdRetouchは「システムの訓練」の準備段階として, まずサンプル学習画像をカテゴリ分類する. CrowdRetouchでは, 与えられたサンプル学習画像には共通の風景や対象物を表す概略的なキーワード(例えば「風景」「飲食物」「建築物」など)が付与されていることを想定する. このようなキーワードが付いていない画像には "other" というキーワードを付与する.

以上の処理によってカテゴリ分類されたサンプル学習画像群に対して前処理として, 画像特徴量によってクラスタリングを適用する. 具体的には, 1画像に対する画像特徴量をベクトルとして扱い, K-means法を適用することで, 画像クラスタを生成する. 現在の実装では画像特徴量として, R, G, B, RGB (輝度) の各々について平均, 標準偏差, 中間値, 最頻値を算出した合計16変数, また画像を分割した各領域の平均輝度値の最小値と最

大値の2変数, 合計で18変数を用いている.

3.3 サンプル学習画像の色補正

3.2節で示した画像分類の後に, ユーザにサンプル学習画像を提示し, 対話操作による画像補正を課する. CrowdRetouchのGUI画面をFig.1に示す. 画面(左側)に操作パネルを表示し, 画面(右側)にサンプル学習画像を表示する.

現在の実装では, 画像補正パラメータとしてトーンカーブを用いている. 処理対象のチャンネルは, RGB,R,G,Bの4種類である. また, 処理を簡易化するために, 各チャンネルのコントロールポイントをシャドウ側の1点 (Cs=64), 中間調の1点 (Cm=128), ハイライト側の1点 (Ch=192) の3点に制限している (Fig.2参照). 結果として現在の実装では, 1枚の画像に対してユーザは12種類の画像補正パラメータを操作することになる.

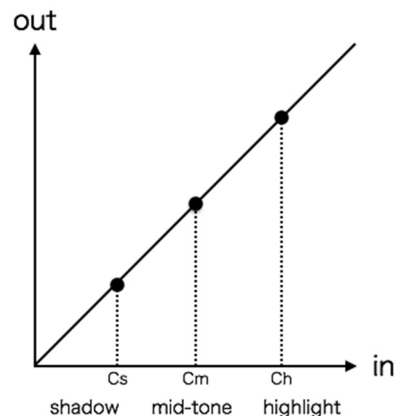


Fig. 2 Tone curve.

### 3.4 ユーザクラスタの生成

画像クラスタごとに、ユーザクラスタを形成する。3.3節で示した対話操作による画像補正結果より、同一画像クラスタに属するサンプル学習画像の枚数を $n_s$ 、画像補正パラメータの個数を $n_p$ （現状の実装では $n_p=12$ ）とすると、1ユーザの画像補正結果を $(n_s n_p)$ 次元ベクトルとして扱うことができる。このベクトルに主成分分析（PCA）を適用し、上位の主成分（現在での実装では第3主成分まで）を採用することでユーザの嗜好を表すベクトルとする。このベクトルに対してK-means法を適用することで、ユーザクラスタを形成する。以上の処理によって構成されるデータ構造をFig.3に示す。ここで、画像クラスタをa,b,c,dとすると、ユーザクラスタは、a0,a1,a2,b0,b1,b2,...,のように、画像クラスタごとに作られる。




Fig. 3 Image clusters and user clusters.

### 3.5 好みの計算モデルの算出

CrowdRetouch では、各画像クラスタにおけるユーザクラスタごとに重回帰分析を適用し、その結果を新しい画像の画像補正パラメータの推定に用いる。具体的には、画像特徴量  $X=(x_1, x_2, \dots, x_n)$  を説明変数として、 $i$  番目の画像補正パラメータ  $n$  を目的関数としたときに、 $n=f_i(X)$  となる  $f_i$  を重回帰分析によって求める。

現在の実装では画像特徴量として、R, G, B, RGBの各々について平均、標準偏差、中間値、最頻値を算出した合計16変数、また画像を分割した各領域の平均輝度値の最小値と最大値の2変数、合計で18変数を説明変数としている。また現在の実装では線形重回帰分析を用いている。

重回帰分析で陥りがちな失敗例の一つに、説明変数が高次元すぎるゆえに却って良質な回帰結果が得られない事例が考えられる。この問題を回避するために我々の実装では、目的変数（画像補正パラメータ）と説明変数（画像特徴量）のPearson相関係数を算出し、相関の高い説明変数のみを採用する。また、説明変数どうして相関が高すぎるものが混在することで、回帰結果の信頼性が低下する場合もある。そのため、説明変数どうして相関の高すぎるものがある場合には、1つの説明変数を残して他の説明変数を除外するようにしている。

現在の実装では、目的変数に対してPearson相関係数が0.5以上の説明変数を採用している。さらに採用された説明変数のペアでPearson相関係数を算出し、その絶対値が0.9以上の場合どちらかを除外するようにしている。Fig.4に以上の処理を示す。

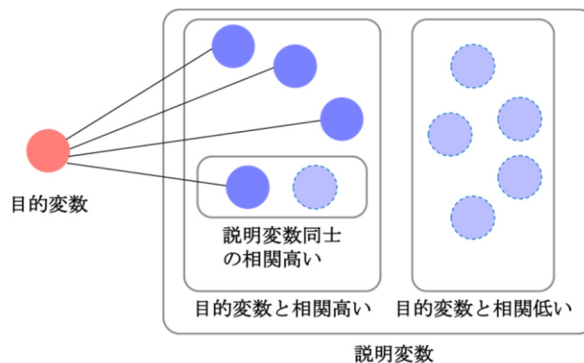


Fig. 4 Relation between explanatory variables and objective functions.

### 3.6 所属クラスタ推定のための判別分析

3.7節にて後述するようにCrowdRetouchでは、新しい画像が与えられると、その画像がどの画像クラスタに分類されるかを判別する。まず、風景や対象物を表すキーワードによって判別し、さらに、そのキーワードごとにサポートベクターマシン（SVM: Support Vector Machine）を適用している。そこで、「システムの訓練」の一環としてSVMに教師信号を入力する。具体的には、風景や対象物を表すキーワードによって分類されたサンプル学習画像群に関する多次元変数（画像特徴量 $X$ ）およびラベル（所属クラスタ番号）を教師信号として入力する。現在の実装ではSVMによる分類処理にLIBSVM[12]を使用している。カーネル関数にはRBFカーネルを採用し、 $\gamma$ 値と $C$ 値にはLIBSVMのデフォルト値を用いている。なお、この処理は多値分類の一種になるが、現在の実装では1対1分類器を用いて多値分類を実現している。

### 3.7 新しい画像に対する画像補正

前節までに示した方法で「システムの訓練」を完了したことを前提として、新しい画像を補正するためにCrowdRetouchは以下の処理を適用する。まず、与えられた新しい画像がどの画像クラスタに属するか、またユーザがどのユーザクラスタに属するかを判定する。続いて当該ユーザクラスタにおける回帰式を適用することで画像補正パラメータを推定し、その結果にしたがって画像を補正する。

この処理ではまず新しい画像の所属カテゴリを推定する。風景や対象物を表すキーワードが付与されている画像については、そのキーワードによって所属カテゴリを推定する。キーワードが付与されていない画像については、"other" というキーワードを付与する。続いて、当該画像の画像特徴量 $X$ をSVMに入力することで、最もふさわしい画像クラスタを推定する。

続いて、ユーザクラスタを判別する。ここで、3.4節のクラスタリング結果に含まれるユーザが新しい画像を入力した際には、3.4節で得られたユーザクラスタをそのまま採用する。さもなければ「新しいユーザ」とみなして3.3節に示したサンプル学習画像補正を課し、その結果から最もふさわしいユーザクラスタを特定する。ここで、サンプル学習画像補正を課す代わりに、サンプル学習画像補正の候補を提示して選択させる方法も考えら

れる。しかし提示された画像に対して積極的に選択したい画像がない、といった状況が生じることも考えられる。そこで現時点での我々の実装では、新しいユーザに対してもサンプル学習画像補正を課している。

この過程において、新しいユーザに画像補正を課するサンプル画像数を減らすため、以下に説明するDavies-Bouldin Index (DB Index) [13] を適用することでクラスタリングに強く貢献している画像を選別する。

具体的には、 $i$ 番目のユーザが1枚の画像を加工した時、補正パラメータが $m_p$ 個あるとすると補正パラメータ値の集合は $m_p$ 次元ベクトルとなる。これを $\mathbf{a}_i$ とする。同一クラスタを構成する $i$ 番目のユーザと $j$ 番目のユーザとの間で補正パラメータがどれくらい近いでいるか評価するには、 $\mathbf{a}_i$ と $\mathbf{a}_j$ の距離を求める。このクラスタを構成する任意の2名について距離の平均 $ave|\mathbf{a}_i - \mathbf{a}_j|$ を求めることで、このクラスタがどのくらい密であるかを計算できる。平均が小さければ小さいほど、クラスタが小さいことを意味し、つまりクラスタを構成するユーザ群が同様な補正パラメータを選ぶ傾向にあることがわかる。

一方で、 $k$ 番目のクラスタの中心における補正パラメータも $m_p$ 次元ベクトルとなる。これを $\mathbf{c}_k$ とする。 $k$ 番目のクラスタと $l$ 番目のクラスタの距離の平均 $ave|\mathbf{c}_k - \mathbf{c}_l|$ を求めることで、クラスタとクラスタの距離の平均を求めることができる。この平均が大きければ大きいほど、クラスタごとに補正パラメータが明確に異なっていることを意味する。

一般的には  $ave|\mathbf{a}_i - \mathbf{a}_j|/ave|\mathbf{c}_k - \mathbf{c}_l|$ の値が小さいほど、そのクラスタは良好であると判断できる。そこで我々の実装では、全てのサンプル学習画像についてこの値を計算し、この値が2.0以下であるサンプル学習画像を新しいユーザに提示する。

提示された画像に対する画像補正結果より、提示されたサンプル学習画像の枚数を $n_c$ 、画像補正パラメータの個数を $m_p$  (現状の実装では $m_p=12$ ) とすると、1ユーザの画像補正結果を $(n_c m_p)$ 次元ベクトルとして扱うことができる。ここで、ユーザクラスタごとに、クラスタにおける重心のユーザを代表ユーザとする。代表ユーザの画像補正結果と新しいユーザの画像補正結果のユークリッド距離を算出し、その距離が一番小さくなるユーザクラスタを新しいユーザのユーザクラスタとする。

そして、当該ユーザが所属するクラスタにて導出された回帰式を適用することで、画像補正パラメータを推定し、その結果に基づいて画像を補正する。このとき、仮に同一ユーザが新しい写真を大量に用意したとしても、同一カテゴリに属する全ての写真に対して同じ回帰式を適用できるため、ユーザの嗜好を反映させた一括画像補正ができると期待される。

## 4. 実験

### 4.1 実験方法

我々はJava JDK 1.7.0 を用いてCrowdRetouchを実装し、MacBook Proの上で実行した。システム評価にあたり、大規模画像セットImageNet[1]から収集した写真と、著者がオート機能を適用して撮影した写真を用意した。また写真共有サイト

PHOTOHITO[14]でのカテゴリ分類の粒度を参考に、カテゴリを「街並み・建物」、「飲食物」、「風景・自然」、「花・草木」、「other」とし、写真の付与されているキーワード情報から写真群を分類した。

本実験では、大学で情報科学を専攻している女子学生22人を対象に、CrowdRetouchを用いて各カテゴリの写真を嗜好に合わせて一括画像補正するというテーマで実験を行い、実験終了後にアンケートを実施した。また、被験者22人をあらかじめ「既存のユーザ」16人と「新しいユーザ」6人に二分した。

実験内容は以下の通りである。

- (1) 画像カテゴリごとに用意したサンプル学習画像30枚に対して、CrowdRetouchを使って画像を補正してもらい、回帰式を求める。
- (2) 画像カテゴリごとに用意した新しい画像10枚に対して、(1)の結果から推定した画像補正パラメータで画像を自動補正する。この補正結果を各被験者に提示し、嗜好に合った補正結果になっているかを評価してもらう。補正結果の比較のため、各画像に対して下記を用意した。
  - A) オリジナル画像
  - B) Picasaの自動補正機能を使って補正した画像
  - C) 画像群を同一カテゴリとし、被験者を分類せず全員分のデータから推定した補正パラメータを適用した画像
  - D) 画像群カテゴリごとに、被験者を分類せず全員分のデータから推定した補正パラメータを適用した画像
  - E) 画像群を同一カテゴリとし、画像特徴量によって画像群を3つの画像クラスタに分類し、被験者を分類せず全員分のデータから推定した補正パラメータを適用した画像
  - F) 画像カテゴリごとに、被験者を3つのユーザクラスタに分類し、ユーザクラスタごとのデータから推定した補正パラメータを適用した画像
  - G) 画像カテゴリごとに、画像特徴量によって画像群を3つの画像クラスタに分類し、さらに被験者を3つのユーザクラスタに分類し、そのユーザクラスタごとのデータから推定した補正パラメータを適用した画像

なお補正結果の評価には、同一のディスプレイを同一場所に設置し、同一の照明条件下で比較鑑賞してもらった。また本実験において、3.2節の画像クラスタリングのクラスタ数を経験的に3で固定し、3.4節のユーザクラスタリングのクラスタ数を経験的に3で固定した。

## 4.2 実験結果と考察

### 4.2.1 キーワードによる画像カテゴリの有効性

4.1節の実験参加者22人中15人に対して以下の実験を行った。まず、画像群の中から、画像カテゴリを考慮せずにランダムに選んだ新しい画像10枚に対して、A), C), D)の3種類を用意し、その中からユーザの嗜好に最も合致する画像を選んでもらい、回答結果を集計した。

結果をFig. 5に示す。オリジナル画像であるA)とCrowdRetouchで推定したパラメータを適用したC), D)を比較すると、

CrowdRetouchで指定したパラメータを適用したC, D)の方が、高い満足度を得ることができた。さらに、CrowdRetouchで推定したパラメータを適用したC, D)を比較した。結果としてD)が最も高い満足度を得る結果になった。この結果より、画像カテゴリごとにユーザの画像補正傾向が違うことが示唆された。




Fig. 5 Percentage of images that matches the users' preference in all category.

次に、画像群の中から、画像カテゴリを考慮せずにランダムに選んだ新しい画像10枚に対して、A), D), E)の3種類を用意し、その中からユーザの嗜好に最も合致する画像を選んでもらい、回答結果を集計した。

結果をFig.6に示す。オリジナル画像であるA)とCrowdRetouchで推定したパラメータを適用したD), E)を比較すると、D)が最も高い満足度を得る結果になった。この結果より、画像をキーワードで分類する方が、画像特徴量で分類するよりも満足度が高いことがわかった。このことから、CrowdRetouchにおいて、キーワードによる画像分類が有効であることが示唆された。




Fig. 6 Percentage of images that matches the users' preference in all category.

#### 4.2.2 ユーザクラスタリングの有効性

4.1節の実験参加者22人中15人に対して以下の実験を行った。画像カテゴリごとに、新しい画像10枚に対して、A), D), F)の3種類を用意し、その中からユーザの嗜好に最も合致する画像を選んでもらい、回答結果を集計した。

結果をFig.7に示す。オリジナル画像であるA)とCrowdRetouchで推定したパラメータを適用したD), F)を比較すると、CrowdRetouchで指定したパラメータを適用したD), F)の方が、高い満足度を得ることができた。さらに、CrowdRetouchで推定したパラメータを適用したD)とF)を比較した。結果としてF)が最も高い満足度を得る結果になった。この結果より、画像カテゴリごとにユーザをクラスタリングすることで、より高い満足度を得られることが示唆された。




Fig.7 Percentage of images that matches the users' preference in all category.

次に、画像カテゴリごとに、新しい画像10枚に対して、D)とユーザクラスごとのF)の4種類を用意し、その中からユーザの嗜好に最も合致する画像を選んでもらい、ユーザが属するクラスターの補正画像を選択する確率を求めた。カイ二乗検定を用いて検定した結果、 $\chi^2 = 5.556$ ,  $p=0.018$ となり、 $p<0.05$ で画像選択結果に有意差が認められた。

#### 4.2.3 画像特徴量による画像クラスタリングの有効性

4.1節の実験参加者22人に対して、以下の実験を行った。まず、画像カテゴリごとに、新しい画像10枚に対して、A), B), F), G)の4種類を用意し、その中からユーザの嗜好に最も合致する画像を選んでもらい、回答結果を集計した。「花・草木」という画像カテゴリにおける結果をFig.8に示す。

##### 画像カテゴリ [花・草木]




Fig.8 Percentage of images that matches the users' preference in flower and plant category.

オリジナル画像であるA)とCrowdRetouchで推定したパラメータを適用したF), G)を比較すると、どのユーザクラスにおいてもCrowdRetouchで推定したパラメータを適用したF), G)の方が高い満足度を得ることができた。さらに、CrowdRetouchで推定したパラメータを適用したF), G)を比較した。結果として全体としてはG)が最も高い満足度を得る結果になった。これは、他の画像カテゴリ（「街並み・建物」、「飲食物」、「風景・自然」）においても同様の傾向が見られた。

次に、「other」という画像カテゴリにおける結果をFig.9に示す。

画像カテゴリ [other]




Fig.9 Percentage of images that matches the users' preference in other category.

オリジナル画像であるA)とCrowdRetouchで推定したパラメータを適用したF), G)を比較すると、どのユーザクラスタにおいてもCrowdRetouchで推定したパラメータを適用したF), G)の方が高い満足度を得た。さらに、CrowdRetouchで推定したパラメータを適用したF), G)を比較すると、どのクラスタにおいてもG)が最も高い満足度を得る結果になった。

F)の結果が高い満足度を得た画像と G)の結果が高い満足度を得た画像の傾向を分析する。どのユーザクラスタにおいても F)の結果が高い満足度を得た画像については、多様な色彩が現れている傾向があることがわかった。画像の例を Fig.10 に示す。一方、どのユーザクラスタにおいても G)の方が高い満足度を得た画像については、単一の色彩が大きな領域を占めることがわかった。画像の例を Fig.11 に示す。つまり、色彩が単一である画像の場合は特に、画像特徴量による画像クラスタ分類が効果的であることが示唆される。



Fig.10 Examples of F results were obtained a high degree of satisfaction image.




Fig.11 Examples of G results were obtained a high degree of satisfaction image.

続いて、CrowdRetouchによって推定された画像補正パラメータが、ユーザが対話操作によって指定する画像補正パラメータにどの程度近い値になったかを検証する。本検証では新規画像に対して、ユーザが対話操作によって指定したパラメータとCrowdRetouchで推定したパラメータC), D), F), G)のそれぞれのユークリッド距離を算出した。

結果をFig.12に示す。まず、それぞれの結果を比較すると、C)とD)に比べてF)とG)の方が、ユークリッド距離の最小値、最大値、中央値が小さくなっていることがわかる。これにより、画像カテゴリごとにユーザクラスタに分類することで、ユーザが対話操作によって指定した画像補正パラメータに近い値を推定できる可能性が高いことが示唆された。次に、F)とG)を比べると、最小値はほとんどかわらず、中央値と最大値はF)のほうが小さくなった。これは、画像特徴量による分類を適用することで、補正結果の満足度が上がる画像傾向と、満足度が下がる画像傾向が混在することに一因があると考えられる。


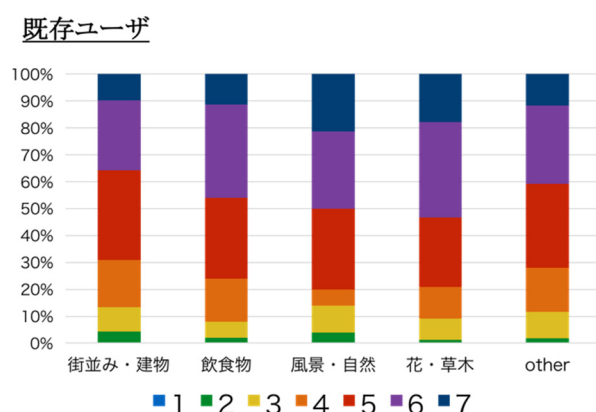


Fig.12 The distance between retouched parameter of users and estimated parameter of CrowdRetouch.


さらに、画像カテゴリごとに用意した新しい画像 10 枚に対して、CrowdRetouchで補正したG)を用意した。被験者に画像を提示し、補正結果について7段階評価(1:非常に不満, 2:不満, 3:やや不満, 4:どちらとも言えない, 5:やや満足, 6:満足, 7:非常に満足)で採点してもらった。Table 1に画像カテゴリごとの平均値を示す。補正結果に対する評価は、既存のユーザが平均5.19,新しいユーザが平均5.74という結果となった。また、既存のユーザと新しいユーザの評価の結果をそれぞれFig.13とFig.14に示す。補正結果に対する満足度のあがらない画像も見られたが、全体的には既存のユーザと新しいユーザともに良好な評価となった。補正結果に対する満足度が平均以下になったしまった画像を観察した結果として、撮影時の天候が悪かったためもともとかなり暗く撮影されていたり、人物が写っていたり、といった点が満足度の低さに関係していると考えられる。今後の課題として、このようなケースにおいても満足度の高い補正を実現できるようにしたい。

**Table 1 Average of satisfaction for images retouched by CrowdRetouch.**

画像カテゴリ	既存のユーザ	新しいユーザ
街並み・建物	4.97	4.75
飲食物	5.23	5.09
風景・自然	5.33	6.96
花・草木	5.40	6.95
other	5.01	4.95
All	5.19	5.74



**Fig.13 Percentage of existing users' satisfaction for images.**



**Fig.14 Percentage of new users' satisfaction for images.**

#### 4.2.4 嗜好傾向

次に、ユーザクラスごとに嗜好傾向がどのようにわかれたかを分析する。今回は、CrowdRetouchで補正した画像の中で満足度が高かった画像の例を Fig. 15 に示す。

ユーザクラス 1 の補正結果は、RGB チャンネルのシャドウから中間調にかけて暗くし、トーンカーブの傾斜を強くすることで、コントラストのついた仕上がりになっている。

ユーザクラス 2 の補正結果は、ユーザクラス 1 と同様に RGB チャンネルのシャドウから中間調にかけて暗くし、トーンカーブの傾斜を強くすることで、コントラストのついた仕上がり

になっている。コントラストの調整に加えて、G チャンネルのハイライト側を下げて、グリーンを弱く、マゼンタを強くすることで、桜の花びらがピンク色に補正され、春らしい温かみのある仕上がりになっている。

ユーザクラス 3 の補正結果は、RGB チャンネルのシャドウを少し暗くし、トーンカーブの傾斜を少し強くすることで、コントラストのついた仕上がりになっている。さらに、R チャンネルの中間調を上げて、レッドを強くすることで、全体的に赤色のイメージに近づいた仕上がりになっている。

この結果から、被験者によって補正の好み異なることが示唆された。結果として、補正の傾向によってユーザをクラスリングし、各ユーザクラスに対して個別に補正パラメータを推定した上での一括画像処理に効果があることがわかった。

#### 4.2.5 画像カテゴリごとの嗜好傾向

続いて、画像カテゴリごとの補正パラメータの違いを分析する。本章では「飲食物」、「風景・自然」の画像カテゴリにおいて、サンプル学習画像30枚ずつ補正した時の画像補正パラメータの最小値、平均値、最大値を、それぞれFig.16とFig.17に示す。

なおグラフの縦軸は画像補正パラメータの値を表し、横軸はユーザクラスごとのコントロールポイントを表す。処理対象のチャンネルをRGB,R,G,Bの4種類とし、各チャンネルのコントロールポイントをシャドウ側の1点 (Cs=64), 中間調の1点 (Cm=128), ハイライト側の1点 (Ch=192)としている。Fig.16, Fig.17の下部の文字列はチャンネルとコントロールポイントの組み合わせを示している。例えば RGBチャンネルのシャドウ側であれば、RGB64と表している。またグラフの背景色について、黄色はRGB (輝度)のみを変えたユーザクラス、青色はRGB (輝度)とR, G, Bのいずれかを変えたユーザクラス、赤色はすべてのチャンネルを変えたユーザクラスを示している。

Fig.16のユーザクラス1とFig.17のユーザクラス1を比較すると、RGB (輝度)の補正量は類似しているものの、その他のパラメータの補正量は異なる。また、Fig.16のユーザクラス2とFig.17のユーザクラス3を比較すると、RGB (輝度)のみ補正している点と同じだが、補正する方向が異なる。

この結果から、画像カテゴリによって補正の傾向が異なることが示唆された。結果として、キーワードによって画像を分類し、各画像カテゴリに対して個別に補正パラメータを推定した上での一括画像処理に効果があることがわかった。



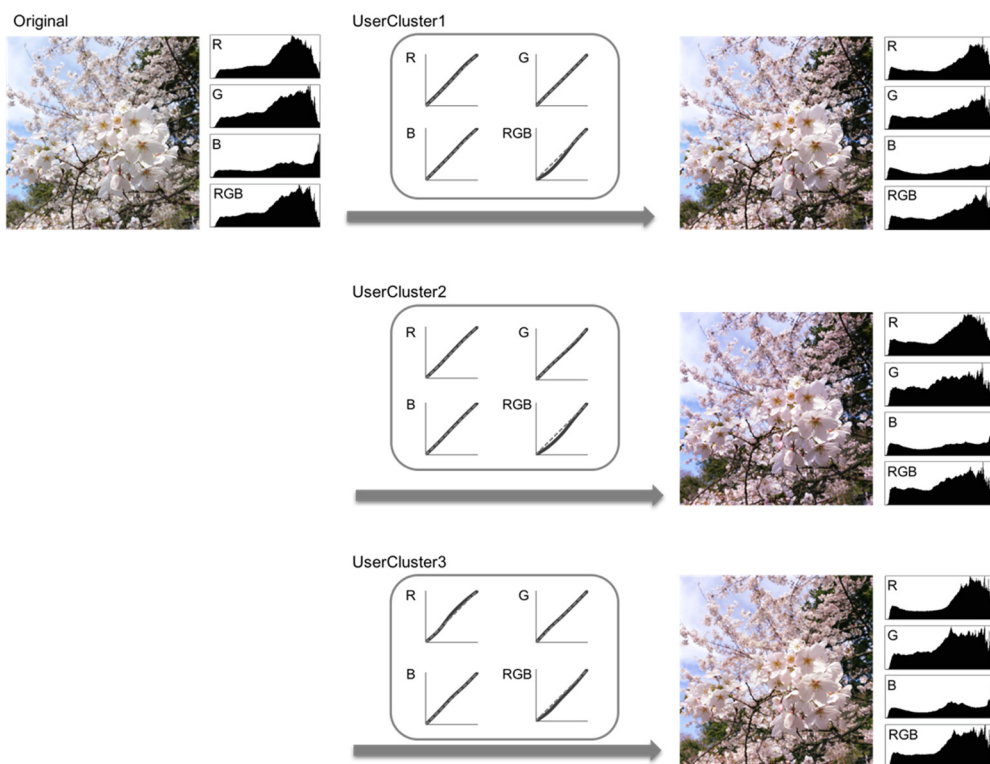


Fig. 15 Example of users' preference tendency.

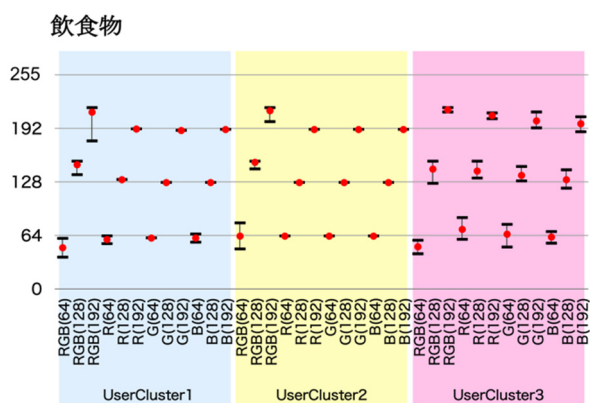


Fig.16 Correction amount of retouch's parameters in food and drink category.

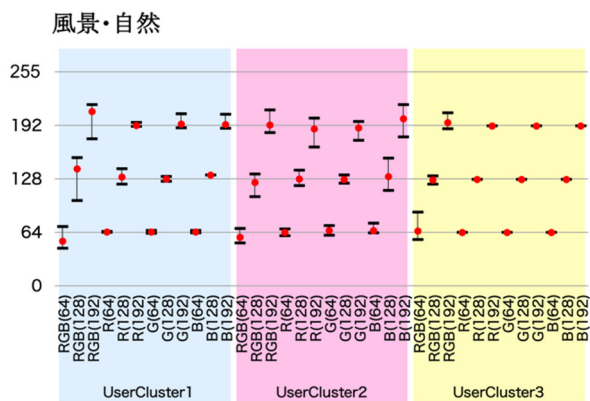


Fig.17 Correction amount of retouch's parameters in landscape category.

#### 4.2.6 補正にかかる時間

ある被験者がCrowdRetouchを使って新しい画像10枚を補正するのにかかる時間を検証するために、3.3節で示したようにユーザにサンプル学習画像を提示し、対話操作によって画像を補正してもらい、その1枚ごとにかかった時間を計測した。

結果をFig.18に示す。1枚あたりの平均所要時間は65秒であった。CrowdRetouchでは、新しいユーザがどのユーザクラスタに属するかを判別するために、サンプル学習画像の補正操作を実施する必要があるが、所属するクラスタが判別した後は、一括補正処理を行うため時間がほとんどかからない。このことから、CrowdRetouchを利用することにより、画像パラメータの調整に不慣れなユーザであっても、多数の写真群に対して手間と時間を割かず、各ユーザの嗜好を反映した画像一括補正ができること期待される。




Fig.18 Processing time.

## 5. まとめと今後の課題

本論文では、同じようなシーンで撮影された写真群に対して、各ユーザの画像補正の傾向を反映した画像一括補正を可能とするシステム"CrowdRetouch"を提案し、その有効性を検証した。

今後の課題として、以下の2点を挙げる。

1点目の課題として分析手法の再検討が考えられる。具体的には、新しい画像が所属すべきクラスターの判別分析手法（現時点ではSVM）の再検討、および画像特徴量から画像補正パラメータを推定する回帰分析手法（現時点では線形重回帰分析）の再検討を進めたい。

2点目の課題として画像補正パラメータの拡張が考えられる。現時点の実装では、色補正パラメータの一種であるトーンカーブを採用し、コントロールポイントを3点に絞っている。これに対して、トーンカーブのコントロールポイントを増やす、トーンカーブ以外の画像補正パラメータを用いる、といった拡張を試し、これによって補正結果の満足度が向上するかを検証したい。

以上を検討した上で、大人数の被験者を交えた実験を実施し、CrowdRetouchの有用性を再検証したい。

## 謝辞

本研究の一部は、日本学術振興会科学研究費補助金の助成に関するものです。

## 参考文献

- [1] ImageNet. <http://www.image-net.org/> (閲覧日: 2016年9月9日).
- [2] Picasa. <http://picasa.google.com/> (閲覧日: 2016年9月9日).
- [3] Photos. <http://www.apple.com/osx/photos/> (閲覧日: 2016年9月9日).
- [4] Z. Yan, H. Zhang, B. Wang, S. Paris, Y. Yu, Automatic Photo Adjustment Using Deep Neural Networks, ACM Transactions on Graphics 35(2), 2016.
- [5] J. -Y. Lee, K. Sunkavalli, Z. Lin, X. Shen, and I. S. Kweon, Automatic Content-Aware Color and Tone Stylization, IEEE Conference on Computer Vision and Pattern Recognition, pp. 2470-2478, 2016.
- [6] J. Marks, et al., Design galleries: a general approach to setting parameters for computer graphics and animation, ACM SIGGRAPH '97, pp.389-400, 1997.
- [7] L. Shapira, A. Shamir, D. Cohen-Or, Image appearance exploration by model-based navigation, Computer Graphics Forum (EUROGRAPHICS 2009), pp.629-638, 2009.
- [8] A. Kapoor, J. Caicedo, D. Lischinski, S. Kang, Collaborative Personalization of Image Enhancement, International Journal of Computer Vision, Vol.108, No.1-2, pp.148-164, 2014.
- [9] 小山 裕己, 坂本 大介, 五十嵐 健夫, 効果的な写真の色補正を実現するための自己強化するシステム, VC/GCAD 合同シ

ンポジウム, 2015.

[10] V. Bychkovsky, S. Paris, E. Chan, and F. Durand, Learning Photographic Global Tonal Adjustment with a Database of Input / Output Image Pairs, IEEE Conference on Computer Vision and Pattern Recognition, pp. 97-104, 2011.

[11] 荒川 薫, 野本 弘平, インタラクティブ進化計算を用いた顔画像美観化システム, 第21回ファジィシステムシンポジウム, 8E3-2, 2007.

[12] LIVSVM. <http://www.csie.ntu.edu.tw/~cjlin/libsvm/> (閲覧日: 2016年9月9日).

[13] D. Davies, D. Bouldin, A cluster separation measure, IEEE Transactions of Pattern Analysis and Machine Intelligence, Vol. PAMI-1, No. 2, pp. 224-227, 1979.

[14] PHOTOHITO. <http://photohito.com/> (閲覧日: 2016年9月9日).

## 斉藤 優理



2010年津田塾大学学芸学部情報科学科卒業。2012年お茶の水女子大学大学院人間文化創成科学研究科理学専攻博士前期課程修了。同年ソニー(株)入社。現在、お茶の水女子大学大学院人間文化創成科学研究科理学専攻博士後期課程に在学中。

## 伊藤 貴之



1990年早稲田大学工学部電子通信学科卒業。1992年早稲田大学大学院理工学研究科電気工学専攻修士課程修了。同年日本アイ・ピー・エム(株)入社。1997年博士(工学)。2000年米国カーネギーメロン大学客員研究員。

2003年から2005年まで京都大学大学院情報学研究科 COE 研究員(客員助教授担当)。2005年日本アイ・ピー・エム(株)退職、お茶の水女子大学理学部情報科学科助教授。2011年同大学教授、同大学シミュレーション科学教育研究センター長、ACM, IEEE Computer Society, 芸術科学会, 他会員。