

# オンライン機械学習による画像カテゴリに応じた ユーザの画像フィルタ選択の予測

土田 容生<sup>1</sup> 樋口 啓太<sup>1</sup> Eshed Ohn-Bar<sup>2</sup> Kris Kitani<sup>2</sup> 佐藤 洋一<sup>1</sup>

**概要:** 本研究では、インタラクティブシステム利用におけるユーザの選択履歴から、コンテキストに応じたユーザ選択をオンライン機械学習によって予測する手法を提案する。具体的には、複数の他ユーザの選択履歴から複数の予測器を生成し、最もユーザの選択を高精度で予測するものを逐次的に学習する。適用例として、Instagramなどの画像共有サービスにおける画像フィルタの選択支援が挙げられる。画像カテゴリ特徴量をコンテキスト情報として利用し、ユーザがどのような画像にどのフィルタを適用したのかを教師データとして利用することにより、選択されるフィルタを予測する。これにより、風景・人物・食事などの画像カテゴリとユーザのフィルタ選択傾向を考慮したフィルタ推薦による支援が可能になる。性能評価実験から、提案手法が通常の教師あり学習やバンディットのアプローチに比べてユーザの選択をより高精度に予測できることを確認した。

**キーワード:** オンライン機械学習, エキスパート統合問題, 画像カテゴリ

HIROKI TSUCHIDA<sup>1</sup> KEITA HIGUCHI<sup>1</sup> ESHED OHN-BAR<sup>2</sup> KRIS KITANI<sup>2</sup> YOICHI SATO<sup>1</sup>

## 1. はじめに

Instagramなどの画像共有サービスが日常的に利用されるようになり、人々が画像編集に触れる機会は増えている。それらのサービスでは画像フィルタの利用が一般的であり、スマートフォンで撮影した画像に対して、事前に用意されたフィルタを適用することで色調などを編集することができるようになってきている。このフィルタとは、例えば、画像をモノクロやセピア調にするもの・赤みや青みなど特定の色味を加える又は抑えるもの・画像の中心以外を暗くするものなどであり、多彩に画像の明度や彩度などのパラメータの組み合わせを変えることが可能である。Instagramでは、このようなフィルタが40種類用意されている。

このようなフィルタを利用した画像編集は、ワンタッチでフィルタを適用して編集が完了するため一見手軽そうであるが、実はここに問題がある。フィルタ選択では、その画像のカテゴリ（風景・人物・食事など）に応じて選択される適切なフィルタの種類が異なる場合があり、さらに、それを多数のフィルタの中から選び出さなければならない。

そのため、特にフィルタ選択に慣れていないユーザにとって負荷が大きいものになり得るという問題がある。

そこで本研究では、このような負荷を軽減させて意思決定支援をするために、ユーザ傾向と画像カテゴリに応じたフィルタ選択をオンライン機械学習によって予測する手法を提案する。このフィルタ選択予測を推薦として提示することができれば、ユーザのフィルタ選択という意思決定を支援することができると考えられる。

教師あり学習を用いて個別のユーザに特化した予測器を生成するには、そのユーザの訓練データが多数必要となる。しかし本研究では、オンライン機械学習、特にエキスパート統合問題 [1] に定式化し、過去に他ユーザのフィルタ選択履歴群を利用することによって、ユーザの訓練データが少数でも予測が可能なる手法を提案する。具体的には、まず複数の他ユーザのフィルタ選択履歴（画像カテゴリ特徴量と選択フィルタの組）から教師あり学習によって予測器群を生成する。そして、その予測器群の中から最もユーザのフィルタ選択を高精度で予測するような最適な予測器を、逐次的に学習する。このようにして学習された最適な予測器によって予測されたフィルタを推薦フィルタとしてユーザに提示する。以上のような学習を画像ごとに繰り返す。

<sup>1</sup> 東京大学, University of Tokyo

<sup>2</sup> Carnegie Mellon University

本研究による貢献としては次の通りである。まずは、画像カテゴリに応じたユーザのフィルタ選択を予測する手法を提案したことである。この手法では、特に、オンライン機械学習の枠組みを用いて、他ユーザのフィルタ選択履歴群を利用することによって、ユーザの訓練データが少数の場合でも予測が可能となった。次に、この提案手法の検証に必要となる予測器群生成のために、他ユーザのフィルタ選択履歴群を収集し、画像 300 枚 16 名分、計 4800 組のデータセットを 2 種類作成した。そして、これらのデータセットを用いて提案手法の予測性能を検証したところ、UCB(Upper Confidence Bound) のバンディットアルゴリズムや、教師あり学習といったベースラインよりも提案手法の方が高精度であることが確認された。以上により、画像カテゴリに応じたユーザの画像フィルタ選択支援における画像フィルタ選択予測システムを構築した。

## 2. 関連研究

### 2.1 コンテキストとユーザ傾向による推薦

私たちは、インタラクティブシステムを通じた意思決定を日々繰り返している。このような意思決定の繰り返しは、ユーザの認知的負荷を増加させることが示されている [2], [3]。このような意思決定を支援するために、様々な推薦システムが提案されている。従来の推薦システム [4] では他人の利用履歴と協調フィルタリング技術が用いられており、E コマースなどの Web サービス [5] や音楽サービス [6] における推薦に大きな影響を与えた。近年の研究では、コンテキストやユーザ傾向を考慮することによって、よりユーザに特化した音楽の推薦 [7], [8], [9] や新聞記事の推薦 [10] が実現している。以上のようなコンテキストとユーザ傾向による推薦に関する研究を基に、本研究では画像フィルタ選択という新しい問題に取り組む。

### 2.2 ユーザ傾向を学習するインタフェース

ヒューマンコンピュータインタラクション (HCI) 研究では、ユーザ傾向の学習原理 [11] を取り入れることでユーザに特化したインタフェース [12], [13] が生み出されている。例えば、Fendlater らはタッチスクリーンのタイピングのために、ユーザに特化したキーボードインタフェース [14] を提案した。

Mehortra らはスマートフォンのアプリケーションからの様々な通知をユーザに特化して受け取るためのユーザ傾向学習手法 [15] を提案した。通知タイトルとユーザの居場所というコンテキストを利用してユーザに特化したルールを抽出することにより、ユーザがメッセージを受け入れるかどうかを高精度で予測した。

また、Fogarty らはユーザに特化した画像検索を行う学習ルール [16] を提案し、Fan らは機械学習アルゴリズムを用いて主観的な類似性の測定 [17] を提案した。以上のような

ユーザ傾向を学習するインタフェースに関する研究を基に、本研究では特にユーザの画像フィルタ選択というユーザ傾向を、オンライン機械学習の枠組みを用いて学習することに焦点を当てる。

### 2.3 ユーザ傾向を学習した画像審美性支援

小山らはパラメータ空間の中から画像の審美性の善し悪しを探索するインタフェース [18] を提案した。また、同じく小山らは、ユーザ傾向を反映した画像編集支援として、個人ごとの色彩編集傾向を逐次的に学習して提示する支援システム [19] を提案した。しかしこの研究では、ユーザの色彩編集に関する訓練データはそのユーザ本人にしか適用することができず、より広くシステムを適用するためにはさらに多くのユーザの訓練データが必要となるという制約がある。以上のような研究を基に本研究では、画像フィルタ選択という審美性に関わるようなユーザ傾向に対して、ユーザの訓練データを多数必要としない学習手法に焦点を当てる。

## 3. 問題設定

### 3.1 フィルタ選択シナリオ

本研究では、ユーザ傾向と画像カテゴリに応じたフィルタ選択を予測することを目的としており、ユーザが与えられた画像に対して、事前に定められた候補フィルタ群からフィルタを 1 枚選択するシナリオを対象としている。このようなシナリオ上にある本研究における全てのフィルタ選択行動は、下記 3.2 節に示すアプリケーションを通して行なうものとする。

### 3.2 フィルタ選択アプリケーション

画像フィルタ選択を行う GUI アプリケーションを作成した。

このアプリケーションは、Instagram などの画像共有サービスを参考にしたものであり、フィルタ選択を繰り返し行うことができるものとなっている。また、提案手法のオンライン機械学習モデルによるフィルタ推薦機能が搭載されており、与えられる画像ごとに、フィルタ選択予測に基づいた推薦フィルタを提示することができる。図 1 に、この



図 1 フィルタ選択アプリケーションのインタフェース

アプリケーションのインタフェースを示す。インタフェースの右側領域には、3枚の推薦提示を含むフィルタ適用画像(8種類)と原画像の合計9枚が配置され、そして左側領域には画像プレビューと操作ボタン(NextボタンとBackボタン)が配置されている。ユーザはマウスクリックによってこのインタフェースを操作してフィルタを選択することができる。あるフィルタ適用画像がクリックされると、画像プレビューにそのフィルタ適用画像が表示され、ユーザはNextボタンをクリックするまで自由に候補フィルタをクリックして比較した上で最終的なフィルタ選択することができる。また、Backボタンで1枚前の画像に戻ってフィルタ選択をやり直すこともできる。

#### 4. 提案手法

本研究では、問題をオンライン機械学習、特にエキスパート統合問題に定式化する。具体的には、まず複数の他ユーザのフィルタ選択履歴(画像カテゴリ特徴量と選択フィルタの組)から教師あり学習により予測器群を生成する。そして、その予測器群の中から最もユーザのフィルタ選択を高精度で予測するような最適な予測器を、画像ごとに逐次的に学習する。

##### 4.1 定式化とオンライン機械学習モデル

問題の定式化と提案手法で用いるオンライン機械学習モデルについて述べる。学習モデルの目標は候補フィルタ群  $\mathcal{A}(k = |\mathcal{A}|)$  に含まれるフィルタ  $a \in \mathcal{A}$  というユーザの選択を高精度に予測することである。まず、学習モデルは画像ステップ  $t$  での画像に基づいて、インタラクティブシステムから画像特徴量  $\mathbf{x}_t \in \mathcal{X}$  を受け取る。次に、この画像特徴量  $\mathbf{x}_t$  を用いて、候補フィルタ群の選択確率  $\mathbf{p}_t \in [0, 1]^k (\sum_i p_{t,i} = 1)$  を予測する。そして、学習モデルはインタラクティブシステムに予測結果を渡し、ユーザフィードバックとして実際のユーザの選択フィルタ  $a_t$  を受け取る。最後に、次の画像ステップ  $t+1$  での予測性能を向上させるために、実際のユーザの選択フィルタと予測結果から  $R(a_t, \mathbf{p}_t)$  を計算して、予測に対する報酬値  $r_t$  を得て学習モデルを更新する。

さらに、本研究では、ユーザと画像カテゴリを考慮したフィルタ選択予測をするために、オンライン機械学習の中でも特に、エキスパート統合モデルを利用する。図2に示す通り、この学習モデルは、予測器をエキスパートとして、予測器群  $\Pi = \{\pi_1, \pi_2, \dots, \pi_N\} (N = |\Pi|)$  をあらかじめ保持する。各予測器は画像特徴量からユーザの選択フィルタを予測する ( $\pi_i: \mathcal{X} \rightarrow \mathcal{A}$ ) のものである。各画像ステップ  $t$  において、学習モデルは予測器  $\pi_i$  を選出して予測結果  $\pi_i(\mathbf{x}_t) = \mathbf{p}_t$  を獲得し、その後、ユーザフィードバックとして実際の選択フィルタ  $a_t$  を受け取る。学習モデルは、全ての予測器に対して、予測結果  $\pi_i(\mathbf{x}_t)$  と選択フィルタ  $a_t$  から、各予測器への報酬  $r_{t,i}$  を計算する。学習モデルの目的関数は、この

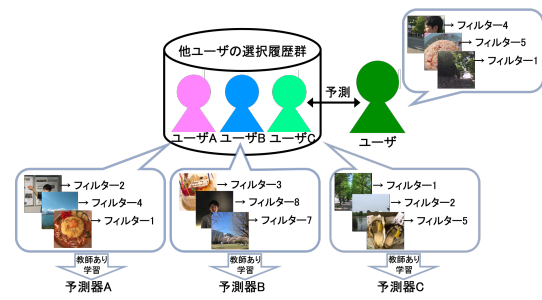


図2 オンライン機械学習におけるエキスパート予測器群の利用  
報酬値を用いた式(1)に示される *regret* を最小化させることである。

$$regret = \max_{\pi \in \Pi} \sum_{t=1}^T R(a_t, \pi(x_t)) - \sum_{t=1}^T R(a_t, \mathbf{p}_t) \quad (1)$$

この式(1)の *regret* の値は、最適予測器の累積報酬値と学習モデルの累積報酬値との差分を表す。第1項は最適予測器の累積報酬値である。各予測器には予測性能を測る評価重みが割り当てられており、最適予測器とはその評価重みが予測器群の中で最も大きい予測器のことである。この時の評価重みが最適予測器の累積報酬値である。第2項は学習モデルの累積報酬値であり、 $T$  回の画像ステップでの報酬値を合計したものである。学習モデルは、画像ステップごとの暫定最適予測器に従って、この差分を最小にすることを目的とする。

この目的のために、学習モデルは  $t=0$  において、各予測器に対する評価重み  $\mathbf{w}_0 = \{0\}^N$  を保持する。式(2)に示されるように、画像ステップ  $t$  において報酬値の累積によってこの評価重みは更新される。

$$w_{t,i} = w_{t-1,i} + r_{t,i} \quad (2)$$

画像ステップごとに学習モデルは、予測器群の中から最も評価重みの大きい予測器を暫定最適予測器  $\pi_t^*$  として保持する。

本研究では、エキスパートとしての過去のユーザのフィルタ選択履歴群  $\mathcal{Z} = \{\zeta_1, \dots, \zeta_N\}$  をデータセットとして使用する。各選択履歴  $\zeta = \{(a_1, x_1), \dots, (a_T, x_T)\}$  はユーザの選択フィルタと画像特徴量からなる。そして、 $N$  人分の選択履歴群を教師あり学習(Adaboostなど)に適用して  $N$  個の予測器からなる予測器群を生成する。学習モデルは4.3節に示す提案手法のアルゴリズムに基づいて、画像ステップごとに暫定最適予測器を逐次的に学習する。

##### 4.2 画像からのカテゴリ特徴の抽出と予測器群の生成

3.1節で示したフィルタ選択シナリオにおいて、ユーザの選択フィルタは、風景・人物・食事などの画像カテゴリによっても変化するものである。例えば、Instagramに用意されているHudsonフィルタは屋外の風景画像に適しており、Lo-Fiフィルタは食事画像に適している[20]とされている。このようなことから、ユーザのフィルタ選択を

高精度で予測するためには、画像カテゴリを考慮する必要があり、本研究では特徴量として画像カテゴリ特徴量を利用する。

画像からのカテゴリ特徴の抽出と予測器群の生成の手順としては、次の通りである。はじめに、フィルタ適用前の原画像を学習モデルが受け取る。次に、予測器群生成の前処理として、画像からカテゴリ特徴量を抽出する。具体的には、ImageNet から学習した VGG-16 ネットワーク [21] の FC7 層から抽出した 4096 次元のベクトルを PCA により 128 次元に圧縮したベクトルを作成し、これを画像カテゴリ特徴量とした。そして、抽出した特徴量と、選択されたフィルタの組を教師データとして、教師あり学習アルゴリズムにより予測器を生成する。教師あり学習としては、500 の弱学習器による Adaboost などを利用する。提案手法では、ユーザごとの選択履歴を別の教師データとして扱い、それぞれから複数の予測器を生成する。

#### 4.3 最適な予測器の学習

オンライン機械学習、特にエキスパート統合モデルの枠組みにより、エキスパートである各予測器の予測結果と、ユーザフィードバックである実際の選択フィルタに基づき、予測器群の中から最もユーザのフィルタ選択を高精度で予測するような最適な予測器を、画像ごとに逐次的に学習する。下記に示すアルゴリズムにより、ユーザが与えられた画像に対してフィルタを選択するたびに、最適予測器の学習を進めることができる。

- (1) すべての予測器の評価重みを 0 とする
- (2) 与えられた画像から 4.2 節の方法で画像特徴量を抽出する
- (3) 最も評価重みが大きい予測器を暫定最適予測器として選出し画像特徴量に応じた予測結果を得る
- (4) 予測結果をもとにフィルタ選択インタフェースに推薦を提示する
- (5) フィルタ選択結果を得る
- (6) 暫定最適予測器のフィルタ選択予測結果とユーザのフィルタ選択結果が等しければ 1 を、そうでなければ 0 を学習モデルの累積報酬値に加算する
- (7) 各予測器に対し、それぞれの予測結果とユーザのフィルタ選択結果が等しければ 1 を、そうでなければ 0 を評価重みに加算する
- (8) (2) に戻る

### 5. 実験データセットの作成

予測器群を生成して提案手法を検証するために他ユーザのフィルタ選択履歴群を収集し、データセットを 2 種類作成した。画像・フィルタ・参加者に関して、制約の大きいデータセットと制約の小さいデータセットとなっている。

いずれのデータセットも、作成の流れは以下の通りで

ある。事前に作成した 8 種類のフィルタを 3.2 節のようなフィルタ選択アプリケーションに実装し、参加者は、そのアプリケーションに提示される各画像に対して、フィルタ適用画像 8 枚と原画像の合計 9 枚から画像共有サービスに投稿する際に適していると思われる画像を 1 枚を選択する。これを画像 300 枚分繰り返してもらい、16 名分のデータを収集する。このデータ収集では、フィルタに?? 節のようなハイライトした推薦は提示しない。それゆえ、参加者は自身の方針に基づいて自由にフィルタを選択することができる。以上により、画像特徴量と選択フィルタ番号の組を、画像 300 枚 16 名分、計 4800 組収集したデータセットを 2 種類作成した。

#### 5.1 Smartphone Dataset

1 つ目は、Smartphone Dataset である。図 3 に、このデータセットで使用したフィルタを適用した画像一覧を示す。フィルタは、Instagram を参考にして 8 種類作成した。特に Instagram のサービス開始初期から利用されている 26 種類のフィルタを、類似を避けるように 8 種類に分類し、それぞれから代表的なフィルタを次の通りに選出した。図 3 の上段左から、フィルタなし、1977、X-pro、Lo-Fi、Inkwell、Earlybird、Kelvin、Hudson、Valencia である。これらのフィルタの再現は photoshop により類似のフィルタを作成した。

参加者は、Instagram などの画像共有サービスにおいて、フィルタを利用して画像を共有した経験のある 16 名で、男性 10 名、女性 6 名、年齢は 24.6 歳であった。画像は、各参加者が自身のスマートフォンで撮影した画像を事前に収集し、その中で画像共有サービスに投稿される可能性が高いと判断され、かつ画像内容の分布が一様になるような画像を計 300 枚を選出した。なお、画像共有サービスで散見するようなコラージュ画像は含めないものとした。このデータセットでは、参加者に依らず同一の画像を使用してフィルタ選択を行なった。

#### 5.2 Open Dataset

2 つ目は、Open Dataset である。図 4 に、このデータセットで使用したフィルタを適用した画像一覧を示す。フィルタは、経験者の意見に基づいて画像編集に一般的で使いやすい 8 種類を作成した。これらのフィルタの再現には、コマンドラインイメージコンバータである nconvert を利用して作成した。

参加者は 16 名で、男性 13 名、女性 3 名、年齢は 25.0 歳であった。画像は、Google が提供している世界最大級の画像データセットである Open Images Dataset v3[22] から無作為に、かつ、画像内容の分布が一様になるように 300 枚選出した。このデータセットでは、参加者ごとに異なる 300 枚の画像を使用してフィルタ選択を行なった。




図3 Smartphone Dataset におけるフィルタ適用画像一覧




図4 Open Dataset におけるフィルタ適用画像一覧

## 6. 予測性能評価実験

### 6.1 評価方法と指標

評価方法としては、16分割交差検証を用いた。提案手法は、テスト事例以外の他ユーザの選択履歴群からそれぞれ学習した15個の予測器を保持する。また、そのうちの最適予測器による予測性能も併せて評価する。これは全ての画像ステップにおいて最適予測器を用いてフィルタ選択を予測したと仮定してその予測性能を算出する。

比較手法は、UCB(Upper Confidence Bound)のバンディットアルゴリズムと教師あり学習とした。UCBでは、提案手法と同様に15個の予測器を保持しており、画像ステップごとに式(3)に示すような、各予測器に対する評価値 $v$ を算出し、その値が最大となる予測器を利用する。

$$v = \mu_i t + \sqrt{\frac{\log t}{2N_i(t)}} \quad (3)$$

$\mu_i t$  は画像ステップ  $t$  までの予測器  $i$  の平均報酬であり、 $N_i t$  は画像ステップ  $t$  までの予測器  $i$  の選択回数である。教師あり学習は、Smartphone Dataset では、500の弱学習器によるAdaboostで学習した予測器とし、Open Dataset では500の弱学習器によるRandom Forestで学習した予測器とした。他ユーザごとの選択履歴を同一の教師データとして統合した4500(=300\*15)組から

評価指標としては、オンライン学習アルゴリズムが得た予測結果(アルゴリズム手順(3))とユーザの選択結果が一致した割合、つまり全画像ステップ  $T$  での正解率を予測性能として採用した。

フィルタ選択候補は9枚であるため、ユーザのフィルタ選択がランダムに行われた場合の正解率は0.11である。また、各手法において画像ステップごとにregretを算出した。

以上のような性能評価実を、Smartphone Dataset と Open Dataset それぞれに対して行なった。

### 6.2 結果および考察

各データセットにおける予測性能を表1に示した。Smartphone Dataset における予測性能は、ベースラインの教師あり学習、UCBで、0.228、0.265であったのに対して、提案手法では0.325と高精度であった。最適予測器の精度は0.354であった。

また、Open Dataset における予測性能は、ベースラインの教師あり学習、UCBで、0.216、0.301であったのに対して、提案手法では0.365と高精度であった。最適予測器の精度は0.386であった。よって、提案手法を用いて最適な予測器の学習を行った方が、既存のバンディットアルゴリズムで最適な予測器の学習を行う場合や、他ユーザごとの選択履歴を統合して一つの教師データとして学習する場合よりも、予測性能が高くなることがわかった。

続いて、各手法における画像ステップごとのregretの推移を、図5・6に示す。どちらのデータセットにおいても、提案手法が2つのベースラインと比較して、画像ステップ数  $t$  がより小さい段階でregretの増加が緩やかになっており、画像ステップ  $t$  が300の時点での最終的なregretの値も比較手法よりも小さくなっている。これは、提案手法のオンライン学習モデルがより早く最適予測器を特定してフィルタ選択予測に利用したためであると考えられる。

表1 各データセットにおける予測性能

	Supervised	UCB	Proposed	Optimal
Smartphone Dataset	0.228	0.265	0.325	0.354
Open Dataset	0.216	0.301	0.365	0.386

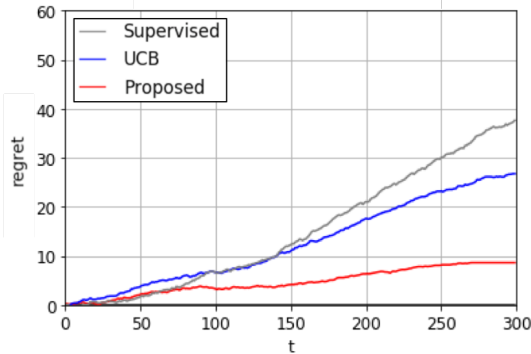


図5 Smartphone Dataset における画像ステップごとの Regret の推移




図6 Open Dataset における画像ステップごとの Regret の推移

## 7. まとめと今後の展望

本研究は、インタラクティブシステム利用におけるユーザの選択履歴から、画像カテゴリに応じたユーザのフィルタ選択をオンライン機械学習によって予測する手法を提案した。この提案手法の検証に必要となる予測器群生成のために、他ユーザのフィルタ選択履歴群を収集し、画像300枚16名分、計4800組のデータセットを2種類作成した。性能評価実験から、提案手法がバンディットアルゴリズムや通常の教師あり学習のアプローチに比べてユーザのフィルタ選択をより高精度に予測することを確認した。また、regretのグラフから提案手法がより早く最適予測器を特定する様子を確認した。以上により、画像カテゴリに応じたユーザの画像フィルタ選択支援システムの根幹となる予測システムを構築した。

今後は、フィルタ選択予測に用いる画像特徴量の種類を変更した場合や、利用する予測器数を変更した場合等の性能評価について検討したい。また、2種類のデータセットを用いて、フィルタ選択予測に基づくハイライトの推薦提示がユーザの選択行動にどのような影響を及ぼすかについて、ユーザ実験を行なって明らかにしたい。

謝辞 本研究はJST CREST(課題番号JPMJCR14E1)及びJST, AIP-PRISM(課題番号JPMJCR18ZG)の支援を受

けた。

## 参考文献

- [1] N. Cesa-Bianchi and G. Lugosi.: *Prediction, Learning, and Games*, Cambridge University Press, 2006.
- [2] C. J. Anderson.: *The psychology of doing nothing: forms of decision avoidance result from reason and emotion*, Psychological bulletin, Vol.129, No.1, pp.139-167, 2003.
- [3] J. Tierney.: *Do you suffer from decision fatigue?*, The New York Times, 2011.
- [4] C. C. Aggarwal.: *Recommender Systems: The Textbook*(1st ed.), Springer, 2016.
- [5] G. Linden, B. Smith, and J. York. 2003.: *Amazon.com Recommendations: Item-to-Item Collaborative Filtering*, IEEE Internet Computing, Vol.7, No.1, pp.76-80, 2003.
- [6] S. K. Lee, Y. H. Cho, and S. H. Kim.: *Collaborative filtering with ordinal scale-based implicit ratings for mobile music recommendations*, Information Sciences, Vol.180, No.11, pp.2142-2155, 2010.
- [7] L. Baltrunas, M. Kaminskas, B. Ludwig, O. Moling, F. Ricci, A. Aydin, K.-H. Lke, and R. Schwaiger.: *InCarMusic: Context-Aware Music Recommendations in a Car*, In C. Huemer, T. Setzer (Eds.), E-Commerce and Web Technologies, EC-Web, Lecture Notes in Business Information Processing, Vol.85, pp.89-100, Springer, Berlin, Heidelberg, 2011.
- [8] P. Lops, M. de Gemmis, and G. Semeraro.: *Content-based Recommender Systems: State of the Art and Trends*, In F. Ricci, L. Rokach, B. Shapira, P. Kantor (Eds.), *Recommender Systems Handbook*, pp.73-105, Springer, Boston, MA, 2011.
- [9] A. van den Oord, S. Dieleman, and B. Schrauwen.: *Deep content-based music recommendation*, In: C. Burges, L. Bottou, M. Welling, Z. Ghahramani, and K. Q. Weinberger (Eds.), *Advances in Neural Information Processing Systems* 26, pp.2643-2651, Curran Associates, Inc., 2013.
- [10] L. Li, W. Chu, J. Langford, and R. E. Schapire.: *A Contextual-bandit Approach to Personalized News Article Recommendation*, In Proceedings of the 19th International Conference on World Wide Web (WWW'10), ACM, New York, NY, USA, pp.661-670, 2010.
- [11] J. Frnkranz and E. Hllermeier.: *Preference Learning* (1st ed.), Springer-Verlag, Berlin, Heidelberg, 2010.
- [12] K. Z. Gajos, D. S. Weld, and J. O. Wobbrock.: *Automatically generating personalized user interfaces with SUPPLE*, Artificial Intelligence, Vol.174, No.12, pp.910-950, 2010.
- [13] J. Liu, C. K. Wong, and K. K. Hui.: *An adaptive user interface based on personalized learning*, IEEE Intelligent Systems Vol.18, No.2, pp.52-57, 2003.
- [14] L. Findlater, and J. Wobbrock.: *Personalized Input: Improving Ten-finger Touchscreen Typing Through Automatic Adaptation*, In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI'12), pp.815-824, 2012.
- [15] A. Mehrotra, R. Hendley, M. Musolesi.: *PrefMiner: Mining User's Preferences for Intelligent Mobile Notification Management*, In Proceedings of the 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing (UbiComp'16), pp.1223-1234, 2016.
- [16] J. Fogarty, D. Tan, A. Kapoor, S. Winder.: *CueFlik: Interactive Concept Learning in Image Search*, In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI'08), pp.29-38, 2008.
- [17] X. Fan, Y. Liu, N. Cao, J. Hong and J. Wang.: *MindMiner: A Mixed-Initiative Interface for Interactive Distance Metric Learning*, In J. Abascal, S. Barbosa, M. Fetter, T. Gross, P. Palanque and M. Winckler (Eds.) *Human-Computer Interac-*

- tion - INTERACT 2015. Lecture Notes in Computer Science, Vol.9297. Springer, Cham, 2015.
- [18] Y. Koyama, D. Sakamoto and T. Igarashi.: *Crowd-powered Parameter Analysis for Visual Design Exploration*, In Proceedings of the 27th Annual ACM Symposium on User Interface Software and Technology (UIST'14), pp.65-74, 2014.
- [19] Y. Koyama, D. Sakamoto and T. Igarashi.: *SelPh: Progressive Learning and Support of Manual Photo Color Enhancement*, In Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems (CHI'16), pp.2520-2532, 2016.
- [20] MakeUseOf: How Instagram Filters Work, And Can You Tell the Difference? (online), 入手先 (<https://www.makeuseof.com/tag/instagram-filters-work-can-tell-difference/>) (2018.12.14)
- [21] K. Simonyan and A. Zisserman.: *Very Deep Convolutional Networks for Large-Scale Image Recognition*, In Proceedings International Conference on Learning Representations, 2014.
- [22] Google LLC: Open Images Dataset v3 (online), 入手先 (<https://storage.googleapis.com/openimages/web/index.html>) (2018.12.17)