

印象予測モデルのインタラクティブな改善を可能にする可視化システム

大久保 美聡¹ 伊藤 貴之¹

概要: 画像コンテンツの印象を予測する機械学習モデルの精度向上には多数の印象評価データが必要であり、その収集は作業者にとって大きな負担となっている。そこで我々は、画像コンテンツの印象を予測する機械学習モデルのチューニングを支援するインタラクティブな可視化システムを開発している。本システムはプールベース型アクティブラーニングを採用し、少数の印象評価データで学習したモデルに未評価画像の印象を予測させ、その結果を散布図として可視化する。また本システムでは、不確実性推定、類似データの算出、予測値に基づくクラスタリング結果の提示機能を設けることで、ユーザが訓練データに追加すべき画像を効率的かつ効果的に選択できるようにする。

1. はじめに

オンラインショッピングやデザイン支援ツールなどにおいて、商品やデザイン素材などの画像コンテンツを、シンプル、カジュアル、暗い…といった印象にもとづいて検索・推薦するシステムのニーズが高まっている。これを実現するためには、画像に対して印象ラベルを付与するアノテーション作業が必要となる。しかし、この作業は主観性が高いため、複数人から印象評価データを収集する必要がある上に、対象となる画像が多いと膨大な作業量を要する。そのため、手作業だけで全ての画像コンテンツに印象ラベルを付与することは容易ではない。この問題を解決する手段として、機械学習モデルを構築して印象アノテーションを半自動化することが考えられる。一方で、印象は主観的であり、一意に定まるものではなく、しかも複数の微細な視覚特徴が複雑に絡み合って形成されている。これらのことから、印象の予測モデルを構築するための学習は容易ではなく、しかも精度を向上させるためのチューニング作業にも手間を要する。

この課題を解決するための一手段として本報告では、ユーザが簡単に機械学習モデルを改善できるインタラクティブな可視化システムを開発する。このシステムでは、印象予測結果を散布図に表した上で、不確実性推定、類似データの算出、予測値に基づくクラスタリング結果を可視化することで、モデルの性能向上のために印象予測結果の修正が必要な画像をユーザが効率的に選択できるよう支援する。印象という主観的かつ連続的な評価タスクを対象に、完全

な自動予測ではなく人間の判断を前提とし、ユーザが予測結果に対する違和感や問題点に気づくことを重視した可視化支援手法を提案する。

2. 関連研究

機械学習モデルの改善を支援するインタラクティブシステムを開発した研究は多数存在する。例えば、Amershiら [1] は、概念学習に用いる機械学習モデルの訓練中に、以前構築されたモデルを履歴に表示した上でロールバックも可能にしたシステムを提案している。さらに、ユーザが訓練データの調整のためラベル付けされたサンプルを削除する際に、その操作を元に戻す（またはやり直す）機能を提供している。これにより、ユーザは複数の潜在的なモデルを検討することができる。Ngら [2] は、画像内の物体の認識とアノテーションを機械学習モデルによる自動判定で支援するアノテーションプラットフォームを開発している。ラベルの信頼度が低い画像を人間が優先的にアノテーションするよう順位付けして、これに従い人手でアノテーションを修正してモデルを改善する。この際に、クラスを絞り込むための参照階層とクラス内の参照画像を提示するとともに、画像内でポリゴンによる厳密な物体位置指定を可能にしている。Xiangら [3] は、多クラスかつ大規模な訓練データに適用可能なアノテーション修正ツールの実現に向けて、スケーラブルなデータ修正アルゴリズムと散布図における階層的な可視化を開発している。Grimmeisenら [4] は、分類器の学習において、各インスタンスについて正解を与えたときのモデルの性能に対する影響度を示す有用性尺度を導出し、これに基づいてユーザがインスタンスを選

¹ お茶の水女子大学

扱えるように、可視化に視覚的なガイダンスを組み込んだシステムを開発している。

しかし、これらの先行研究は分類モデルを対象としており、回帰モデルを対象とした研究はまだ少ない。そこで我々は、回帰モデルの中でも特に、画像コンテンツの印象を予測するモデルを対象としたインタラクティブな可視化システムを開発している。

3. 可視化システム

本報告の提案システムは、インタラクティブなプールベース型アクティブラーニングを可能にするシステムである。プールベース型アクティブラーニングでは、プール（ラベルなしデータの集合体）から、最も効果的にモデルの精度と信頼性を向上させると予想されるデータを選択し、ラベルを付けて訓練データに追加してから、改めてモデルを学習する。この学習を反復することで、訓練データのサイズを増大させることなくモデルを改善する。本システムでは、以下の5段階の処理を反復することで、インタラクティブなプールベース型アクティブラーニングを実現する。

- (1) 訓練データを用いてモデルを学習する。
 - (2) 構築されたモデルによりテストデータの印象を予測する。
 - (3) 印象予測値の似ている画像が近くに配置されるような散布図を表示して、印象予測結果を可視化する。
 - (4) 印象予測結果が不適当である画像をユーザが探しやすいように表示する。
 - (5) ユーザが訓練データに追加する画像を選択して、印象評価値を手動入力することで、訓練データを更新する。
- (4)では、ユーザが印象予測結果からサンプリング対象を選択しやすくするため、不確実性推定結果、類似データの算出結果、および印象予測値に基づくクラスタリング結果を提示する。

3.1 モデルの学習

印象予測モデルの学習は、新海ら [5] や Sunda ら [6] の研究を参考に、VGG-19の事前学習済みモデルをファインチューニングする形で実行する。ユーザは図1に示すページで、訓練データの画像ファイルと印象評価値を保存したCSVファイルを選択し、学習を開始させる。



図1 モデルの学習ページ

3.2 テストデータの印象予測

3.1節で述べた手順で学習したモデルを用いて、テストデータの印象を予測する。同時に、Monte Carlo Dropoutによる不確実性推定 [7] を実行する。不確実性が高いほど、モデルの予測に対する確信度が低いことを意味する。ユーザは図2に示すページで、テストデータの画像ファイルを選択し、予測を開始させる。



図2 テストデータの印象予測ページ

3.3 散布図による可視化

3.2節に示した印象予測の結果として、印象予測値は印象評価軸に対応した多次元ベクトルとして得られる。現時点での我々の実装では、飯島ら [8] が提唱した5次元の印象予測値を採用している。これを2次元に次元削減して、散布図に可視化する。ここで次元削減には、PCAとUMAPの2種類のいずれかを用いる。よって、それぞれの結果をもとにした2種類の散布図を表示できる。

なお、散布図の各点を画像で表示することで、画像の分布を一目で把握しやすいという利点がある。しかし一方で、散布図の各点を一般的な頂点で表示するのと比べて、画面上での点の重なりが多くなるという問題点もある。そのため、本システムでは図3のように、画像を用いる散布図と用いない散布図を並べて表示し、ユーザが見比べられるようにしている。

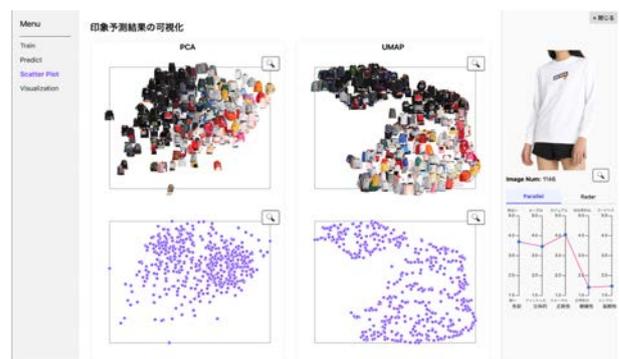


図3 散布図ページ

本システムでは、4種類の各散布図の右上にある拡大ボタンを押すことで、その1種類の散布図だけを図4のように拡大して表示する機能を実装している。

また、ユーザが散布図中の点をクリックして選択したとき、画面右側のパネル（以下、詳細パネル）にその詳細情報を表示する。ここでは、画像のIDをテキストで、印象予

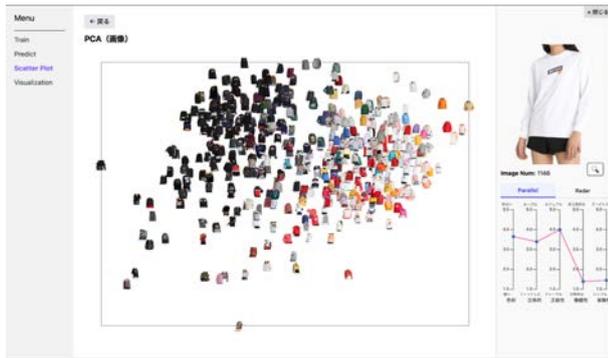


図 4 散布図の拡大表示ページ

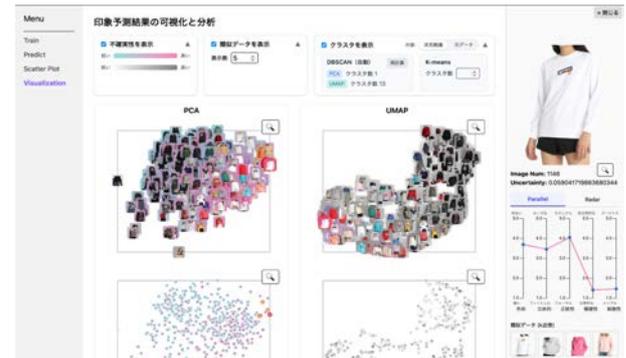


図 6 支援の可視化ページ

測値を平行座標またはレーダーチャートで表示している。平行座標とレーダーチャートはタブの選択で切り替えることができる。

さらに詳細パネル中の画像右下にある拡大ボタンを押したときに、図 5 に示すポップアップ（以下、詳細ポップアップ）を表示する。この詳細ポップアップを用いることで、大きく表示された画像を確認できる。



図 5 詳細ポップアップ

3.4 支援機能

ユーザが訓練データに追加すべき画像を効率的かつ効果的に選択できるようにするため、本システムでは以下の3つの支援機能を実装している。

- (1) 不確実性推定
- (2) 類似データの算出
- (3) 印象予測値に基づくクラスタリング

これらの結果を提示した例を図 6 に示す。この図に示すページで、ユーザは訓練データに追加する画像を選択する。ページの画面上部には各支援機能の設定を変更できるカード（以下、支援機能設定カード）を表示しており、チェックボックスで結果の提示の有無を切り替えることもできる。

3.4.1 不確実性の表示

印象予測と同時に推定した不確実性の高さを、散布図中で画像の背景色もしくは点の色に表す。不確実性に応じて

グラデーション中の色を反映しており、支援機能設定カードにカラーバーを表示している。また、詳細パネルと詳細ポップアップでは不確実性を数値として提示する。加えて、不確実性の高い画像を見つけて選択しやすいように、不確実性が高い画像ほど散布図中で手前に描画されるようにしている。

3.4.2 類似データの表示

ユーザが散布図中の点をクリックして選択したとき、選択した画像に赤色の枠を描画し、k近傍法により算出した類似データに橙色の枠を描画する。詳細パネルにも類似データの画像を表示する。また、支援機能設定カードで表示する類似データの数を変更することができる。

3.4.3 印象予測値に基づくクラスタの表示

DBSCAN によるクラスタ数自動推定のクラスタリングと、k-means によるクラスタ数指定のクラスタリングを実装している。ページを開いた時点では DBSCAN が実行されるが、ユーザが支援機能設定カードのテキストフィールドにクラスタ数を入力すると、k-means が実行される。ボタンで DBSCAN を再実行することもできる。また、クラスタリング対象データも次元削減後の 2 次元ベクトルと元の 5 次元ベクトルを変更することができる。クラスタリング結果は、ユーザが画像を選択したときに散布図に提示する。選択した画像と同じクラスタに含まれる画像は、画像の背景色もしくは点の色をカラーで表示し、異なるクラスタに含まれる画像はグレーで表示する。このため、選択した画像と異なるクラスタに含まれる画像の不確実性はグレースケールで表示される。クラスタリング手法やクラスタ数、クラスタリング対象データが変更されるたびに、散布図にも反映される。

4. 実行結果と考察

本章では提案システムの実行結果を示す。本報告では、画像コンテンツとして女性用洋服の画像^{*1}を題材としており、教師データとする印象評価値には飯島ら [8] が収集したデータを用いている。5次元の印象評価軸の値はいずれ

*1 <https://www.kaggle.com/datasets/zalando-research/fashionmnist>

も 1 から 5 の間である。

訓練データに 1000 枚、テストデータに 500 枚を使用し、提案システム上でモデルの学習から印象予測結果の可視化まで実行した。その結果、例えば不確実性が高い画像を探索すると、**図 7** で選択している画像を訓練データに追加すべき画像として発見できる。当該画像に対して、今回の実験で出力された印象予測値と、アンケートで収集された印象評価値を**表 1** に示す。この表からも、当該画像は印象予測結果を修正すべき画像であることがわかる。

さらに、この画像の洋服は他にはない特有の柄がデザインされており、これは類似データや同クラスタ内の多くの画像にも共通した特徴である。よって、この画像を起点に類似データや同クラスタ内の画像を確認することで、印象予測結果を修正すべき画像を効率的に見つけやすくなると考えられる。



図 7 実行結果例

表 1 画像番号 1417 の印象予測値とアンケートによる評価値

	色彩	立体的	正統性	穏健性	装飾性
予測値	2.97	3.62	3.97	1.85	2.28
評価値	4.08	4.54	4.77	2.77	2.77

5. おわりに

本稿では、画像コンテンツの印象を予測する機械学習モデルのチューニングを支援するため、不確実性、類似データ、印象予測値に基づくクラスタを算出し提示することで、プールベース型アクティブラーニングをインタラクティブな探索のもとで実行できる可視化システムを提案した。

今後の課題としては、可視化システムの有用性を支援機能の妥当性の観点とユーザインタフェースの観点から検証することがあげられる。また、印象予測モデルに適した支援機能を増やし、システムを改善していきたい。

謝辞 女性用洋服の画像データに対するアンケートで収集した印象評価値データを提供していただいた飯島緋理氏に感謝いたします。

参考文献

- [1] Amershi, S., Fogarty, J., Kapoor, A. and Tan, D.: Examining multiple potential models in end-user interactive concept learning, *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, CHI '10, New York, NY, USA, Association for Computing Machinery, p. 1357–1360 (online), DOI: 10.1145/1753326.1753531 (2010).
- [2] Ng, L. H. X., Hock, H. N. S. and Yen, N. Y.: Cross-Model Image Annotation Platform with Active Learning, *CoRR*, Vol. abs/2008.02421 (online), available from <https://arxiv.org/abs/2008.02421> (2020).
- [3] Xiang, S., Ye, X., Xia, J., Wu, J., Chen, Y. and Liu, S.: Interactive Correction of Mislabeled Training Data, *2019 IEEE Conference on Visual Analytics Science and Technology (VAST)*, pp. 57–68 (online), DOI: 10.1109/VAST47406.2019.8986943 (2019).
- [4] Grimmeisen, B., Chegini, M. and Theissler, A.: VisGIL: machine learning-based visual guidance for interactive labeling, *Vis. Comput.*, Vol. 39, No. 10, p. 5097–5119 (online), DOI: 10.1007/s00371-022-02648-2 (2022).
- [5] 新海公章, 谷伊織, 飛谷謙介, 都賀美有紀, 長田典子: CNN 特徴量を用いたスーツスタイルにおける印象推定モデルの構築, *電子情報通信学会技術研究報告 (Web)*, Vol. 121, No. 420(IMQ2021 10-69) (2022).
- [6] Sunda, N., Tobitani, K., Tani, I., Tani, Y., Nagata, N. and Morita, N.: Impression Estimation Model for Clothing Patterns Using Neural Style Features, *HCI International 2020 - Posters* (Stephanidis, C. and Antona, M., eds.), Cham, Springer International Publishing, pp. 689–697 (2020).
- [7] Gal, Y. and Ghahramani, Z.: Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning (2016).
- [8] 飯島緋理, 伊藤貴之: 印象評価にもとづくアノテーション作業の半自動化を支援する可視化システム, *芸術科学会論文誌*, Vol. 21, No. 4, pp. 186–198 (オンライン), DOI: 10.3756/artsci.21.186 (2022).