

画像セグメンテーションにおける誤認識の根拠の
可視化に基づく追加学習データ選出法
Selecting Additional Learning Data based on Visualization of Decision Basis
in Semantic Segmentation

辰巳 嵩豊[†]
Takato Tatsumi

小原 清弘[†]
Kiyohiro Obara

稲田 圭介[†]
Keisuke Inata

安部 雄一[‡]
Yuichi Abe

1. はじめに

ファクトリーオートメーション分野における検査自動化に向け、画像処理による対象物の位置検知が求められている。検知位置の誤りは部品破損や不良の原因となるため、高精度な位置検知が要求される。被写体の形状変動に対してロバストな検知を実現するために、セマンティックセグメンテーションを用いた方式が提案されている[1]。

認識精度が低下する要因として学習データに含まれる画像の偏りが挙げられる。学習データに類似しない画像を推論する際に適切に特徴量を捉えられず、推論に誤りが生じる場合がある。本研究では、初期学習データセットで学習したモデルが適切に推論できない画像に対し、誤って捉えた特徴領域を判断根拠として可視化する。その根拠に基づき対象とする誤った認識の解決に効果的な画像を追加候補群から選出する手法を提案する。

画像分類問題においてモデルが判断根拠とした領域を提示する手法に Petsiuk らの RISE[2]がある。この手法は、画像に対してランダムにマスクを適用し、分類クラスのスコア値に基づいたマスクの合成により根拠を可視化する。RISE は分類問題を対象とするため、セマンティックセグメンテーションの根拠を可視化できない。本研究では、セマンティックセグメンテーションを画素ごとの分類問題と捉え、任意の画素における判定の根拠を可視化する。

2. 提案手法

2.1 認識の根拠の可視化

提案手法の説明のため、評価実験で用いる電子顕微鏡で撮影された画像(図 1)を題材とする。図中の×印は判定の根拠を可視化する対象のピクセルを表す。このタスクでは 2つのクラスに分類し、赤色と青色で示す。

まず図 2 に示す様な位置や形状、白色の領域の大きさが異なるマスクを n 枚作成し、それぞれを入力画像に適応し加工画像を n 枚生成する。加工はマスクの黒色の領域を対象とし、ぼかしや塗りつぶしが適用される。




図 1 対象図と座標



図 2 マスク例

加工画像を解析対象であるセマンティックセグメンテーションモデルに入力し推論結果を得る。推論結果それぞれにおいて対象における推論クラスを図 3 の様に認識する。図 3(i)は対象ピクセルが赤色で示されるクラス、図 3(ii)は青

色で示されるクラスに判定されたことを示す。




図 3 加工画像の推論結果と認識クラス

上記の様に認識されたクラスごとに、加工に用いられたマスクを図 4 の様に合成する。図 4 は赤色で示されるクラスとなったマスクが 2 枚の場合の合成結果を示す。2つのマスクを重ね合わせるとマスクにより加工されていない割合が 100%(2/2), 50%(1/2), 0%(0/2)となるエリアに分かれる。




図 4 マスクの合成

この合成結果のうち、割合の値が閾値を超えた部分が認識の根拠の領域となる。図 5(i)は 1000 枚のマスクにより加工されていない割合を 5 段階の赤色の濃さで示し、入力画像に重畳した画像である。図 5(ii)は閾値 80%を超えた部分を囲う矩形を入力画像上に示した画像である。




図 5 認識の根拠

2.2 追加学習データの選出

2.1 で求めた矩形部分をテンプレートとして追加学習データ候補の画像群に対してテンプレートマッチングを適用する。類似度の上位 m 個を学習データセットに追加する。

3. 評価実験

3.1 評価対象タスク

電子顕微鏡で撮影された画像からニードル先端を検出するタスクに提案手法を適用し有効性を検証する。図 6 に入力画像(図 6(i))とアノテーション(図 6(ii))を示す。アノテーションは先端を中心とした半径 90(画像サイズ 1000x1000 相当)の円の領域を赤色クラス、その他の部分を青色クラスとする。(i)初期学習データセットで学習した場合、(ii)提案手法により学習データを追加したデータセットで学習した場合、(iii)追加候補のうち提案手法で追加された画像以外からランダムに学習データを追加したデータセットで学習した場合における対象画像の推論結果を比較する。

[†]株式会社 日立製作所 Hitachi, Ltd.

[‡]株式会社 日立ハイテク Hitachi High-Tech Corporation

3.2 実験設定

実験設定は以下の通り。モデル: U-Net[3], GPU: NVIDIA GeForce RTX 2080Ti, 学習データ: 1000x1000 あるいは 800x800 を 512x512 にリサイズ, 初期学習枚数: 113, 追加枚数 m : 10, 推論枚数: 588, 学習回数 200epoch, バッチサイズ: 4, クラス重み: 23, データ拡張: なし, マスク枚数 n : 1000。

根拠の可視化の対象として、初期学習データセットで学習したモデルによる推論の赤色の領域が円形と異なる画像(図7)を選択した。十字は正解座標を X 印は推論画像から求めた推定座標を表す。このタスクでは推定座標は赤色の領域の重心から求める。また、図7(ii)は図7(i)におけるニードルの先端付近を拡大した図である。図7のようにニードル先端付近を捉えていても、推論結果における赤色の領域の形状が円形から異なると推定座標は正解座標から離れる。推論結果における赤色の領域の形状を修正することを本実験の評価項目とする。また、対象画像の様なニードル先端が鉤型となる画像は初期学習データセットに含まれない。




図6 入力画像とアノテーション




図7 対象画像における正解座標と推定座標

3.3 実験結果

3.3.1 根拠の可視化

図7は2つの円が重なった推論結果に見える。赤色の領域内の任意の点を取り、根拠を可視化した図を図8に示す。図の見方は図5と同様である。領域の上部(図8(i))と下部(図8(ii))で異なった図が得られた。マスクにより加工されていない割合が80%以上の領域から、赤色の領域の下部は上部と異なり、ニードル先端の鉤型を根拠としている。




図8 根拠の可視化

3.3.2 推論の改善

領域上部の重心は正解座標に近く、下部の重心は正解座標から乖離していたため、候補から下部の反応を抑制する画像を追加する。図8(ii)で80%以上の部分を囲う矩形領域に対し、類似度が高い画像を追加した。追加前の推論結果とランダムに追加した場合と比較する。図9に対象画像の推論結果を示す。(i)初期学習データセット、(ii)提案手法、(iii)ランダムである。推論結果における赤色クラスの領域は提案手法の場合のみ円形に改善した。初期学習データセット(図7)で38.9ピクセルあった推定座標の誤差が提案手法(図8(ii))では2.6ピクセルにまで縮まった。




図9 推論結果の比較

3.4 考察

対象画像の推論結果について述べる。初期学習データセットは図6(i)の様なニードルの先端に異物が付着していない画像や小さな異物が付着した画像のみで構成されていた。そのため、学習データセットに類似画像がない対象画像において赤色クラスが過剰に判定された。提案手法は図10に示す先端の形状が鉤型となる画像を追加したため、対象画像の推論結果が改善した。




図10 追加された画像の一例

また、追加候補の画像群は提案手法で追加された先端の形状が鉤型の画像以外にも、先端に異物が付着していない画像や小さな異物が付着した画像等多様な画像が含まれる。ランダム追加では、対象画像と類似性が低いが、初期学習データセットの画像と類似性が高い画像が選択され、対象画像の推論結果の改善には至らなかった。

4. おわりに

セマンティックセグメンテーションの推論結果改善法として、対象画像内の任意座標における認識の根拠となった領域の可視化法とそれを用いた追加学習データ選出法を提案した。認識の根拠となった領域は、入力画像をマスクした際の推論結果を基に可視化される。誤認識となった画像に対し根拠の可視化法を適用し、その根拠に類似する領域を持つ画像を学習データに追加することで、対象とする誤認識に特化した矯正を実現した。提案手法により推論結果とそれから求まる推定座標の精度が改善し、実用的な認識精度が達成された。

今回、ニードルの先端の座標を中心とした円を描画したタスクを対象とした。提案手法は画像の一部をマスクによって隠した際の推論結果の差分から根拠を可視化するため、アノテーションの仕方限定されない。つまり、一般的なセマンティックセグメンテーションの様に対象物体全体をラベル付けしたタスクにも適用可能である。

また、人手により推論結果が悪化する原因を分析し、類似データを追加することで、提案手法と同様な改善が可能である。しかし、画像ごとに人手で悪化の原因つまりテンプレート領域を決める必要があるため、推論結果の改善の自動化への障害となる。一方で、提案手法は事前設定可能な閾値によりテンプレート領域を決定し、追加画像を選出するため、推論結果の改善の自動化に有用な方法である。

今後の課題として、改善対象となる画像とピクセルの動的な選択による認識精度改善の自動化、複数種類の誤認識を対象とした全体的な推論結果の向上、効率的なマスクの適用、推論結果に好ましくない影響を及ぼす学習データセット内の画像の検出・削除が挙げられる。

参考文献

- [1] 池田ら, “CircleSeg-XAI: FA 分野に適した深層学習による位置決め技術”, SSII (2021)
- [2] V. Petsiuk, et al., “RISE: Randomized Input Sampling for Explanation of Black-box Models”, arXiv (2018).
- [3] O. Ronneberger, et al., “U-Net: Convolutional Networks for Biomedical Image Segmentation”, Springer, LNCS, Vol. 9351 (2015).