

同一被写体の多様性に対する制約 variational loss の提案

小田桐 海翔[†] 鍵和田 聡[‡] 宇賀 博之[§] 彌富 仁[†][†]法政大学 理工学研究科 応用情報工学専攻[‡]法政大学 生命科学研究科 応用植物科学専攻[§]埼玉県農業技術研究センター

概要

機械学習分野において、頑健性の高い識別器構築は本質的に重要な課題であり、これまで多くの試みがなされてきた。本研究では、fine-grained な物体認識問題において、同一クラスでありながら多様な外観を持つ対象に対して頑健な識別器構築に貢献するための制約である variational loss を提案する。これは、識別に関する対象領域が既知の場合に、それ以外の領域を除外した画像と、画像全体のそれぞれのクラス事後確率の KL ダイバージェンスによって定義される。同種の認識問題の中でも特に難易度が高く、過学習を引き起こしやすい植物病の自動診断問題を対象に提案手法を適用した結果、きゅうりの葉画像 10,888 枚を学習した 7 クラス病害識別器の平均識別精度を 5.7% 向上させた。

1 はじめに

機械学習分野において、過学習の抑制、つまりシステムの汎化性能を高めることは極めて重大なテーマであり、ensemble 学習, dropout や様々な data augmentation, 敵対的学習, 半教師あり学習, stability training [1] など、実に様々な手法が提案され成果をあげている。こうした技術により画像認識において数々のシステムが高い精度を上げているが、クラス間の違いが極めて小さい fine-grained な物体認識問題に関して、特に認識に関わらない部分の影響が大きい問題において、学習データセットに含まれていない未知データに対する精度に課題が残されている [2, 3]。画像解析に基づく植物病の自動診断は、診断すべき病害の画像上の特徴が極めて小さい反面、その他の背景部分の領域は大きくかつ多様であり、撮影された圃場に大きく依存する。このためシステムは病害ではなく、面積の大きい背景部分に過学習する。これまで提案されてきた多くのシステムが、cross validation を含むデータセット内同一の評価において平均識別率 95~99% と極めて高い識別能を報告しているのに対して、未知の圃場のデータに対する精度は 3~4 割程度にとどまる [4, 5]。

The variational loss as a new regularizer for variations of the same object.

Kaito ODAGIRI[†], Satoshi KAGIWADA[‡], Hiroyuki UGA[§] and Hitoshi IYATOMI[†][†]Applied Informatics, Graduate School of Science and Engineering, Hosei University, Tokyo, Japan[‡]Clinical Plant Science, Faculty of Bioscience and Applied Chemistry, Hosei University, Tokyo, Japan[§]Saitama Agricultural Technology Research Center, Saitama, Japan

{kaito.odagiri.8f@stu., kagiwada@, iyatomi@}hosei.ac.jp, uga.hiroyuki@pref.saitama.lg.jp

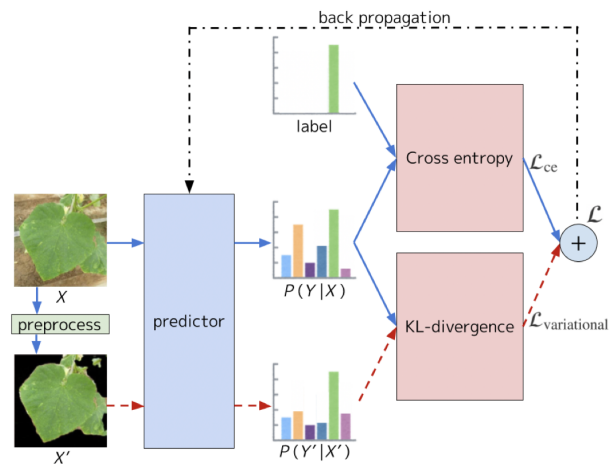


図 1: 提案手法を葉画像に適用した場合の例

このような問題に対し、敵対的生成ネットワークを活用することで、識別に関与しない背景を除去し、関心領域のみを抽出する anti-overfitting pretreatment (AOP) が提案されている [5]。AOP の適用によりキュウリの 7 種類の病害葉と健全葉の 8 クラス分類問題で未知の圃場の画像診断において 12.2% の精度向上が報告されている。しかし依然として、50,000 枚程度の学習データおよび、多くの汎化性向上策を活用する場合でも、平均識別率は 5 割程度にとどまっており、さらなる改善が求められる。AOP では診断に寄与する情報も同時に失っている可能性が考えられ、さらに使用する際には前段の AOP による抽出過程が必要となるため、実行時間が長くなる欠点も有する。また識別器構築の観点からは識別器単体が本質的に病気を見つけるための頑健性を獲得できていないことになる。

こうした背景から、識別対象を含む部位が与えられているという問題設定のもと、識別器そのものの頑健性を高めるための方策として、識別器の損失関数の新たな項である variational loss を提案する。本研究では、背景の影響により同一クラスでありながら多様な外観を持つキュウリ葉を対象とした自動診断システムを構築し、その効果を検証した。

2 Variational loss

Variational loss は、識別対象の特徴が表われる領域が、boundary box や segmentation などにより事前に与えられている場合を想定した識別器の頑健性をさらに高めるための誤差項である。これは、入力に対す

る擾乱に対して出力結果が同じになるような制約である stability training のアイデアに基づくものである。Variational loss は、元の画像を X として、 X 中の識別の根拠を含む何らかの領域が抽出された画像を X' としたとき、 X と X' は識別問題においては本質的に同じであるという考えのもと、それらを入力したときのクラス事後確率が等しくするようにする制約である。Variational loss は以下の式で表される。

$$\mathcal{L}_{\text{variational}} = D_{\text{KL}}(P(Y'|X'), P(Y|X)) \quad (1)$$

ここで D_{KL} は KL ダイバージェンスを表す。

3 実験

本研究では、上記の汎化性の高い識別器の構築が困難な植物病害自動診断タスクを行う識別器を構築し、提案手法である variational loss の有無による識別精度の比較実験を行った。

3.1 データセットと前処理

農水省委託プロジェクト「人工知能未来農業創造プロジェクト」参加地域から提供された、7種類のキュウリ病害感染葉および健全葉の画像合計 10,888 枚を学習に使用し、評価には病種等は同様だが他の圃場で撮影された画像合計 3,087 枚を使用した。今回の実験では学習に用いる画像を増やす目的で data augmentation を行った。どちらの場合も葉画像をそれぞれ 90 度刻みに 360 度回転処理を加え、4 倍に増やし、その中心を 224×224 でクロップすることで後述する識別器の学習データとした。

3.2 識別器

識別器には一般物体認識分野で広く活用されていた ResNet50 [6] を ImageNet データセットで pre-training したモデルを使用した。

3.3 本課題における variational loss の実装

図 1 に本課題における variational loss の実装の概要図を示す。Variational loss を求めるため、今回は AOP を利用した葉領域の抽出を行い、入力画像 X とその背景を切り抜いた背景除去画像 X' を用意した。AOP の学習画像には前述のデータセットの一部を含む 8,000 枚の画像を使用した。識別器の学習の際に、損失関数に通常使用される X の識別結果の交差エントロピー \mathcal{L}_{ce} のみならず、 X と X' のクラス事後確率の KL ダイバージェンスで表される $\mathcal{L}_{\text{variational}}$ を加える。全体の損失関数 \mathcal{L} を以下に示す。

$$\mathcal{L} = \mathcal{L}_{\text{ce}} + (1 - \lambda^t) \times \mathcal{L}_{\text{variational}} \quad (2)$$

ここで t は学習時の epoch 数であり、 $1 - \lambda^t$ は学習が進むに連れて値が 1 に近づく重みの調整項である。今回の実験では $\lambda=0.99$ を使用した。

4 結果、考察およびまとめ

学習データのうち、75%を学習に使用し、25%を評価に使用した場合では平均識別精度が 97.6%であった。一方で、本質的に未知の他の圃場で撮影された画像に対する評価を行った結果、variational loss を含まない識

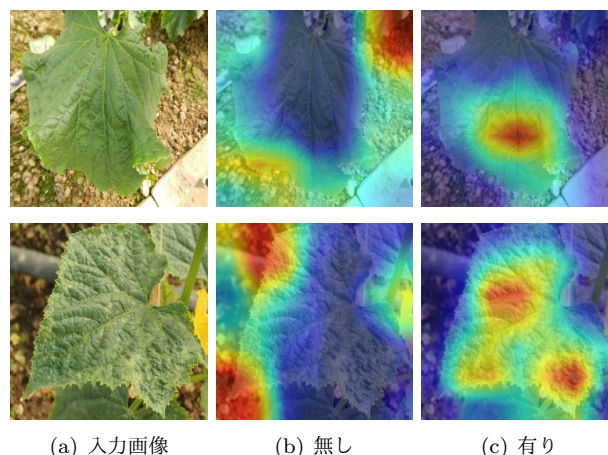


図 2: variational loss の有無による GradCAM の比較

別器は平均識別精度が 47.0%まで大幅に低下した。これに対し、variational loss の導入により同精度は 52.7%まで向上した。また GradCAM[7] と呼ばれる CNN の識別根拠を可視化する技術を用いて、variational loss の有無による着目領域の変化を図 2 に示す。図 2 より、variational loss がない時に対して variational loss がある時の方がより葉に着目していることが確認できる。

今回対象とした問題は、クラス (病気) 間の特徴差が画像のばらつきに対し小さく、かつ学習データと評価データの環境が異なる状況での評価のため、上記の結果のように識別器に汎化性を持たせるのが難しい問題である。Variational loss の導入により過学習の抑制を行い、かつ識別に寄与しうる情報を残したまま識別器がより正しい診断を行えるようになったと言える。今後より良い variational loss の改善ならびに、効果的な過学習抑制手法の模索を行っていく。

謝辞

本研究は JSPS 科研費 基盤研究 (C) 17K08033, (2017-2020) の助成を受けたものである。

参考文献

- [1] S. Zheng, Y. Song, T. Leung, and I. Goodfellow, "Improving the robustness of deep neural networks via stability training," *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4480–4488, 2016.
- [2] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Frontiers in plant science*, vol. 7, pp. 14–19, 2016.
- [3] A. Fuentes, S. Yoon, S. C. Kim, and D. S. Park, "A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition," *Sensors*, vol. 17, no. 9, pp. 20–22, 2017.
- [4] K. Suwa, Q. H. Cap, R. Kotani, H. Uga, S. Kagiwada, and H. Iyatomi, "A comparable study: Intrinsic difficulties of practical plant diagnosis from wide-angle images," *CoRR arXiv:1910.11506*, 2019.
- [5] T. Saikawa, Q. H. Cap, S. Kagiwada, H. Uga, and H. Iyatomi, "Aop: An anti-overfitting pretreatment for practical image-based plant diagnosis," *CoRR arXiv:1911.10727*, 2019.
- [6] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.
- [7] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-cam: Visual explanations from deep networks via gradient-based localization," *Proceedings of the IEEE International Conference on Computer Vision*, pp. 618–626, 2017.