

2段階の画像生成を活用した 不均衡データセットに対する実践的なデータ拡張

菅野怜¹ 長澤駿太² 鍵和田聡³ 宇賀博之⁴ 彌富仁¹

¹ 法政大学 大学院 理工学研究科 応用情報工学専攻 ² 法政大学 理工学部 応用情報工学科
³ 法政大学 生命科学部 応用植物科学科 ⁴ 埼玉県農業技術研究センター

概要

高精度な画像を生成可能である敵対的生成ネットワーク (GAN) を用いた、画像識別器の学習用画像の拡張手法が複数提案されている。しかし、このようなネットワークによる生成画像は学習データの確率分布に基づくため、データが少ないクラスにおいてその多様性は制限される問題がある。これに対し本研究では、特にデータ数の少ないクラスに対し多様性を増強するデータ拡張手法を提案する。具体的には、データ数の多いクラスの画像から GAN を用いて多様な画像を生成した後、1対1対応のスタイル変換を行う GAN により、生成された画像に他クラスの視覚的特徴を付加する。本報告では、学習データ取得のコストが大きく、クラス間のデータ数が不均衡な植物病害自動診断タスクにおいて提案手法を検証し報告する。

1 はじめに

深層学習を用いた画像識別器の構築が行われているが、多様かつクラスごとに量が均一な学習用データ入手のコストは大きい。不均衡データに対する手法として、weighted loss [1] が提案され一定の成果を挙げているが、著者らの経験からは依然として精度向上の余地が残る。データ拡張の枠組みでは、generative adversarial networks (GAN) を用いて画像を生成し、画像識別器の学習データに加える試みがある [2, 3]。GAN は与えられたデータの確率分布を学習するモデルであるため、十分量のデータが与えられた場合には、この手法による識別器の精度向上が望める。しかし、学習データの数が少ないクラスに対しては多様な画像を生成できな

A practical image augmentation for biased dataset using two-stage image generation

Sato KANNO¹, Shunta NAGASAWA², Satoshi KAGIWADA³, Hiroyuki UGA⁴ and Hitoshi IYATOMI¹

¹ Applied Informatics, Graduate School of Science and Engineering, Hosei University, 184-8584, Koganei, Tokyo, Japan

² Applied Informatics, Science and Engineering, Hosei University, 184-8584, Koganei, Tokyo, Japan

³ Clinical Plant Science, Faculty of Bioscience and Applied Chemistry, Hosei University, 184-8584, Koganei, Tokyo, Japan

⁴ Saitama Agricultural Technology Research Center, Saitama, Japan

{sato.kanno.2r@stu., iyatomi@}hosei.ac.jp

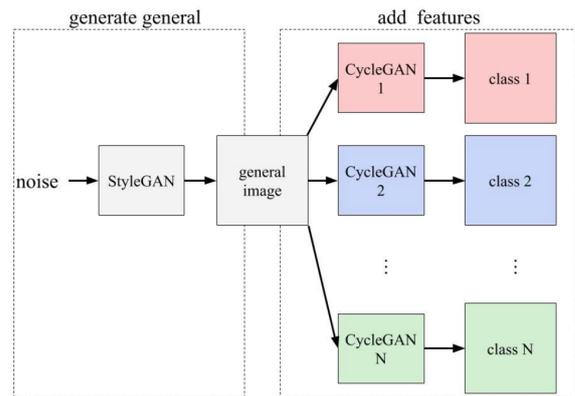


図 1: 2段階画像生成

い。本研究では、スタイル変換を行う GAN を使用することでデータ数が少ないクラスのデータを補う。さらに、データ数が多いクラスのデータを学習した GAN を用いて生成された多様な画像にスタイル変換を行うことで、データ数が少ないクラスの多様性を増強する。本実験では、クラス間で均一な量のデータ取得のコストが大きく、汎化性向上が困難なタスクである植物病害自動診断問題を用いて、提案手法の有効性を検証する。

2 2段階画像生成によるデータ拡張

学習時の少ないクラスへの過学習抑制のため、図1のように2段階の画像生成を行い識別器の学習に用いる。

Step1: 最多クラスのGANによる画像生成 学習データの中で最も多数のデータを持つクラスを選び、その画像をGANあるいはその改良版のネットワークを用いて多様な画像を生成する。

Step2: CycleGANによる各クラス特徴付加 Step1で使用したクラスから他クラスへの変換をCycleGAN [4] にそれぞれ学習させる。これらのモデルを用い、step1で生成された画像に対し各クラスの特徴を付加する。これにより各クラスの画像の多様性の増強に効果が期待できる。

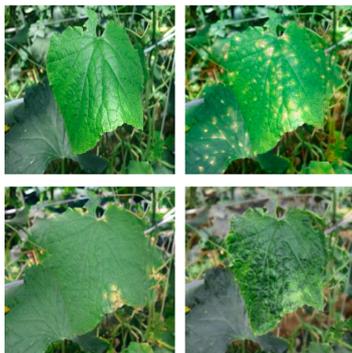


図 2: 生成画像例 (上段:左から健全, BS 下段:DM, ZYMV)

表 1: 平均識別率の比較

Model	accuracy [%]
Baseline	57.9
+ weighted loss [1]	66.4
+ CycleGAN [6]	68.1
+ 2-step GAN(提案手法)	68.2

3 評価実験

提案手法の有効性を検証するために、クラスごとにデータ数の偏りがあるキュウリの植物病自動診断の問題を対象に評価を行った。植物病自動診断は、病害の特徴(クラス間の分離の手がかり)が極めて小さい一方、画像背景や葉形状の多様性が大きいため、過学習を引き起こしやすい困難な問題である。提案手法の有無により、植物病の自動診断精度の変化を検証した。

識別器は、ResNet50 [5] の ImageNet 学習済みモデルを基に、fine-tuning を行って構築した。識別器の評価には学習用データと全く違う圃場で撮影された画像 (brown spot (BS):424 枚, downy mildew (DM):380 枚, zucchini yellow mosaic virus (ZYMV):3,364 枚, 健全:717 枚) を用いた。以下の条件で識別器をそれぞれ構築し、性能を比較した。

Baseline 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」から提供された、キュウリの 3 種の病害感染葉 (BS:2,238 枚, DM:1,457 枚, ZYMV:10,210 枚) および健全葉:14,379 枚, 計 28,284 枚の画像を使用した。各画像を 256×256 pix. にリサイズした。その後、識別器の学習データを 10 度刻みに 360 度回転させ、中央 181×181 pix. をクロップした。

Baseline + weighted loss [1] Baseline の損失関数を、クラスの偏りを考慮したものに変更した。

Baseline + CycleGAN [6] CycleGAN に健全葉画像から各病害葉画像へのスタイル変換を学習させた。健全葉画像を病害クラスごとの CycleGAN モデルで変換

した画像 (BS:12,141 枚, DM:12,922 枚, ZYMV:4,169 枚) を baseline の学習データに追加し各クラスの画像を 14,379 枚に統一した。

Baseline + 2-step GAN (提案手法) 多数の画像を確保できた健全葉画像 14,379 枚を用いて StyleGAN [7] を学習した。StyleGAN によって生成された健全葉画像は多様であることが期待されるため、そのモデルで健全葉画像を生成する。それらを病害クラスごとの CycleGAN モデルで変換した画像 (BS:12,141 枚, DM:12,922 枚, ZYMV:4,169 枚) を baseline の学習データに追加し各クラスの画像を 14,379 枚に統一した。

4 結果と考察

生成画像の例を図 2 に示す。また、各条件で学習を行い、評価用データの 4 種の識別問題において求めた平均識別率の比較を表 1 に示す。提案手法を用いると、baseline や weighted loss を用いた場合より精度が向上した。これは、画像生成により学習画像の多様性が增强され、さらにクラス間の学習画像数の偏りが小さくなったことで識別器の汎化性が高まったためである。

5 おわりに

生成モデルにより生成された画像でデータ数が少ないクラスの学習データを拡張することにより、識別器の精度が向上することが示唆された。今後、より有効な画像生成の手法を検討することが望まれる。

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。

参考文献

- [1] C. Huang, Y. Li, C. Change Loy, and X. Tang, "Learning deep representation for imbalanced classification," *IEEE Proc. conference on computer vision and pattern recognition*, pp. 5375–5384, 2016.
- [2] M. Frid-Adar, E. Klang, M. Amitai, J. Goldberger, and H. Greenspan, "Synthetic data augmentation using gan for improved liver lesion classification," *IEEE Proc. International Symposium on Biomedical Imaging (ISBI)*, pp. 289–293, 2018.
- [3] X. Zhu, Y. Liu, Z. Qin, and J. Li, "Data augmentation in emotion classification using generative adversarial networks," *CoRR arXiv:1711.00648*, 2017.
- [4] J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros, "Unpaired image-to-image translation using cycle-consistent adversarial networks," *IEEE Proc. international conference on computer vision*, pp. 2223–2232, 2017.
- [5] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *IEEE Proc. conference on computer vision and pattern recognition*, pp. 770–778, 2016.
- [6] Y. Tian, G. Yang, Z. Wang, E. Li, and Z. Liang, "Detection of apple lesions in orchards based on deep learning methods of cyclegan and yolov3-dense," *Journal of Sensors*, vol. 2019, 2019.
- [7] T. Karras, S. Laine, and T. Aila, "A style-based generator architecture for generative adversarial networks," *IEEE Proc. Conference on Computer Vision and Pattern Recognition*, pp. 4401–4410, 2019.