

Sparse Subspace Clustering を用いた 頑健な植物病自動診断のための基礎検討

榊原友助[†] 藤田恵梨香[†] 川崎雄介[†] 宇賀博之[‡] 鍵和田聡[†] 彌富 仁[†]

[†]法政大学 [‡]埼玉農業技術研究センター

概要

現在、正確な植物病害の診断には十分な知識と経験が必要である。専門知識や経験を持たない人間でも、診断を可能にすることを目的とした機械学習手法を用いた植物病害自動診断システムが提案されている。しかし、学習データの数や撮影環境の多様性に対して十分でないことから、過学習を引き起こしやすく、実用化を想定した場合に本来期待される精度が得られない。本研究では植物画像群のもつ特徴空間を、はるかに低い次元の部分空間の和で表すことができる sparse subspace clustering を用いることで過学習を低減し、より頑健な識別器を構築する手法について検討を行う。

1 背景

これまで、画像解析をもとにした植物病に対する診断手法は提案されてはいた。しかしながらそれらの多くは、従来のパターン認識技術に立脚していたため、設計者が識別に有効な特徴量を手動で設定する必要があり、限られた用途しか活用できなかった。近年、急激な発展ならびに多くの成果が報告されている深層学習技術は、画像認識タスクをはじめ優れた成果を挙げている。我々は、画像認識に特化した convolutional neural networks (CNN) を利用し、キュウリの主要なウイルス病7種と健全葉に対して約 83.2% で識別を可能とした [1]。現 CNN は画像そのものを入力とし、識別のために重要な特徴量を学習により自動的に獲得することが可能であるという大きな利点を持つ。一方で、CNN は極めて自由度の高い識別器のため、過学習への対策として data augmentation や dropout などの代表される様々な対策がとられている。今回の場合、撮影される葉の画像は葉の大きさや状態といった葉自体の多様性の他に、カメラ

の絞りや、撮影距離、明るさや背景などの影響を受ける撮影による多様性は、病気そのものが及ぼす葉の変化よりもしばしば大きい。

本研究では、当該画像識別問題における過学習を抑制するために、解析対象のデータの次元削減を検討する。具体的には一般画像認識コンテスト (ILSVRC) で 2014 年度に優勝した Simonyan らの 19 層からなる CNN モデルである VGG-net モデル [2] を画像からの特徴抽出器として用いたうえで、高次元データを複数の低次元の subspace で表現する sparse subspace clustering (SSC) [3] をキュウリの葉の持つ画像に適用し、元の高次元のデータの低次元化を試みる。問題を複数の低次元の問題に分割することができれば、それぞれを小さい次元の問題として解き、アンサンブル学習を行うことで、過学習を抑えながら全体の識別能を高くできることが期待できる。

2 データセットと解析手法

2.1 データセット

本研究では、先行研究と同様に、キュウリの7種類の典型的なウイルス病に感染した画像、並びに健全葉それぞれ 500 枚、合計 4000 枚を利用した。解析に用いる写真は圃場において、葉が画像の中心部に入ることを条件とする以外、特に制約を設けず、様々な背景、撮影条件で撮影されたものを 224×224 画素に縮小したものをを用いた。

2.2 SSC によるクラスタリング

汎用的な植物病害自動診断システム構築のために、我々は ImageNet データセットで学習済みの 19 層の CNN モデルである VGG-net を活用し、対象となる作物、病気ごとに fine tuning を行っており、これまで良好な結果を得ている。そこで本研究では、VGG-net の FC6 層 (第 17 層) までを特徴抽出器として捉え、ここで 224×224×3 次元のキュウリの葉画像から生成される 4096 次元の特徴ベクトルを用いる。しかしなが

Basic study of robust Automated Diagnosis of Plant Diseases using Sparse Subspace Clustering

[†] Yusuke Sakakibara, Erika Fujita, Yusuke Kawasaki, Satoshi Kagiwada, Hitoshi Iyatomi (Hosei University)

[‡] Hiroyuki Uga (Saitama Agricultural Technology Research Center)

ら、ここで得られる特徴行列のランクは 4,000(=データ数<4,096)であり、PCA などの次元圧縮の効果が期待できない。そこで本研究では SSC を用いて複数の低次元の問題に変換できないか検討する。

3 Sparse Subspace Clustering

データの低次元表現は、識別器の過学習を根本的に抑制する最も効果のある方策である。SSC は、高次元のデータを (1) 各データを他のデータの線形結合で表現し、これを元にデータ間の類似度マップ (affinity map) を作成する。(2) affinity map に対して spectral clustering[4] を行うことでデータを任意のグループに分割する。の 2 段階から構成されるクラスタリング手法である。これにより SSC は元の高次元データを、複数の低次元空間の集合で表現することができる。SSC ではまず N 個の D 次元のデータ $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n, \dots, \mathbf{x}_N\}$, $\mathbf{x}_n \in \mathbb{R}^D$ を

$$\begin{aligned} \mathbf{C}^* &= \operatorname{argmin}_{\mathbf{C}} \{ \|\mathbf{X} - \mathbf{X}\mathbf{C}\|_F^2 + \lambda \|\mathbf{C}\|_1 \} \quad (1) \\ \text{s.t. } \operatorname{diag}(\mathbf{C}) &= \mathbf{0}, \mathbf{C}^T \mathbf{1} = \mathbf{1} \end{aligned}$$

となる係数行列 \mathbf{C}^* を見つける。ここで、 \mathbf{C} は L1-norm の正規化が付いているため、疎な行列となる。つまり、任意の n 番目以外のデータの数少ないデータの線形結合で表現するような係数行列を見つかることに相当する。これにより、 N 個のデータは、それぞれ異なる複数のデータの線形結合で構成されるよう表現される。 λ は、疎性を決めるパラメータで大きいほど係数 \mathbf{C} に含まれる 0 が多くなる。データ間の類似度マップは、得られた係数行列を対称行列にして $\mathbf{W} = |\mathbf{C}| + |\mathbf{C}|^T$ で作成される。後段の spectral clustering を含めた SSC の処理により、複数の類似したデータが集まるグループ (subspace) に分けることができる。各 subspace が持つ次元は、 \mathbf{C} により、低く抑えられたデータの連結数が理論的な上限となるため、良好なクラスタが生成できれば結果として大幅な次元削減が期待できる。本研究では、SSC により得られた各グループ (subspace) の持つ次元数を singular value decomposition(SVD) にて解析した。また、SSC の挙動を特徴づける λ の値は grid search により決定した。

4 結果

$\lambda=0.05$ における SSC の前段処理より得られた類似度マップ (\mathbf{W}) を図 1 に示す。これはデータ間の類似度を表し、明るい点がデータの連結が強いことを表す。類似度マップで大まかに対角線上にブロック状に並んでいる




図1 SSC の前段処理より得られた類似度マップ ($\lambda=0.05$) ことが確認できる。本実験ではデータは種類ごとに順番に並んでいるため、同じ病気に感染している葉に属するデータ間の類似度が高くなっていることが確認できる。これを元に後段の subspace clustering により得られた 8 つのクラスタに属するデータの特異値の分布は、どのクラスタでも最大値：最小値=150 : 1 程度の差にとどまった。つまり \mathbf{W} のランクとデータ数が等しくなり次元の低減は実現できなかった。

5 考察とまとめ

比較的良好な類似度マップが作成されているにも関わらず、得られた各 subspace はフルランク、つまりすべてのデータがその空間の作成に寄与していることを意味し、残念ながら低次元化を実現できなかった。これは VGG-net が作り出す高次元の特徴量を他の特徴量の線形結合で表せないことが理由として挙げられる。この問題を解決する方策の一つに、生成される特徴量 \mathbf{X} が入力される画像 \mathbf{I} と、CNN の重み \mathbf{W} からなる関数、つまり $\mathbf{X}(\mathbf{W}, \mathbf{I})$ とみなし、(1) 式を、 $\mathbf{X}(\mathbf{W}, \mathbf{I})=0$ にならないようにする制約をつけた上で、 \mathbf{W} を勾配法を用いて更新しながら最小化する方法が考えられる。こうした手法により将来、元の問題を複数の独立性の高い低次元の問題に分割することができれば、識別器全体の精度、頑健性を高めることができると期待される。

参考文献

- [1] E.Fujita et al. , “Basic investigation on a robust and practical plant diagnostic system”, IEEE Proc. on ICMLA, pp. 989-992, 2016.
- [2] K.Simonyan, A.Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition”, CoRR, abs/1409. 1556,2014.
- [3] E.Ehhamifar, R.Vidal, “Sparse Subspace Clustering: Algorithm, Theory, and Applications.” IEEE Trans. PAMI, Vol.35, No.11, pp.2765-2781, 2013.
- [4] U. V Luxburg et al., “A Tutorial on Spectral Clustering”, Statistics and Computing, 17 (4), 2007.