

良品サンプルのみを学習した Stacked Autoencoder による異物検知方式の考察 A Study of Anomaly Detection Method Using Stacked Autoencoder Trained by Only Normal Samples

秋山 達勇[†]
Tatsuo Akiyama

西脇 大輔[†]
Daisuke Nishiwaki

1. はじめに

フードディフェンスの意識の高まりにより、食品製造工場における異物検知のニーズが高まっている。画像認識技術を異物検知に適用する際の課題は、製造物、異物ともに多くのバリエーションが存在するにも関わらず、実際の食品製造工程において異物が混入する頻度が低いため、異物の学習サンプルがほとんど得られないことである。そこで、本論文では、良品のサンプルは大量に存在する前提のもとで、製造物、異物の種類によらず、良品サンプルのみを学習することで異物を検出する方法について考察する。入力画像は一般的に高次元の情報であるから、クラス分類前に次元圧縮する方法が一般的であるが、古くから次元圧縮に用いられる主成分分析 (PCA) は線形変換の一種であるので、表現力が限定的である。非線形変換を可能にするカーネル主成分分析は、少数の固有ベクトルへの射影を取った結果得られた点が、一般的に、その原像が入力画像空間上に存在しないため、次元圧縮に不向きであると言われている[1]。近年、深層学習技術の進展に伴い、Autoencoder を多層に拡張した Stacked Autoencoder (SAE) [2]が提案されている。SAE は多層のネットワークで構成されているために非線形な次元圧縮を行える利点がある。そこで本研究では、良品のみを用いて学習した SAE による不良品検出の評価実験を行い、PCA と比較することで、SAE の特徴抽出としての有効性を示した。

2. 提案手法

2.1 Stacked Autoencoder による特徴抽出

SAE は多層で構成されるニューラルネットワークであり、入力層よりも少ない素子数で構成される中間層を持つ。このネットワークを、良品サンプルデータのみにより学習し、中間層の出力を特徴として使用する。

本実験では[3]で公開されているサンプルコードを用いた、9層のSAEで、各層の素子数は786, 1000, 500, 250, 2, 250, 500, 1000, 786である(図1参照)。SAEの学習にはミニバッチ法を用い、入力画像自身が復元されるように学習する。学習の流れを図2に示す。Layer-wise pre-training と Fine-tuning を行い、最後に各学習サンプルに対して第5層の出力を特徴として取得する。学習にはランダム性があるため、各実験において複数回の結果を取得した。

2.2 評価方法

SAE による特徴抽出の有効性を評価するため、特徴抽出後に良品か不良品かを判定する識別器を付加し、検出に関する recall, precision を求められるようにする。識別器は、不良品サンプルに対する汎用性を確保するため、特徴空間

[†] NEC データサイエンス研究所




図1 Stacked Autoencoder

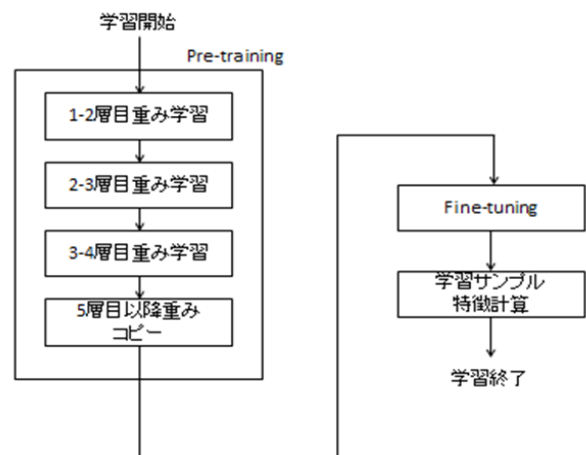


図2 Stacked Autoencoder の学習フロー

上でノンパラメトリックな推定を行う方針とし、次に述べるような識別器を設計した。概念図を図3に示す。テストサンプルから n 番目に近い良品サンプルとの距離 d に基づいて、良品か不良品かを判定することで解決する。 n 番目に近い近傍との距離を取るのには、例えば、図3(c)のように孤立したような出現頻度の低い領域の学習サンプルの影響を無視するためである。

3. 評価実験

提案手法はパラメータ n と d の組み合わせで検出精度が変化する。そこで、不良品が漏れなく検出 (不良品検出 recall 100%) できた n と d の組み合わせにおいて、precision (不良品と判定されたサンプルのうち実際に不良品だったサンプルの割合) の最大値を評価する実験を行った。




図 3 評価方法概念図

3.1 実験 1: MNIST 手書き数字データセット画像

まず、サンプルのバリエーションが比較的大きいと考えられる MNIST 手書き数字データセットを評価画像として実験を行った。SAE の有効性を検証するため、比較手法として PCA を用いた。手書き数字の字種「1」の画像 6742 枚を良品と見立てて学習し、学習に用いなかった「1」を含む数字（「1」1135 枚、それ以外 8865 枚）をテストサンプルとして評価し、47 回の繰り返し実験を行った。SAE の活性化関数、最適化手法、学習パラメータや n 、 d の具体的な値を表 1 に示す。結果、precision が 88.66%~96.28% となる n と d が存在した（表 2 参照）。特徴空間上にマッピングされた学習サンプルの良好な一例を図 4(a) に示す。赤で示す点が学習した字種「1」のテストサンプル、緑で示す点が学習しなかった字種の中の一つ「7」のテストサンプルである。分布に多少オーバーラップがあるものの概ね両者が分離されていることがわかる。また、比較手法として次元圧縮方法に PCA を用いた方法を試したところ precision が 88.68% であり、47 回中 46 回で SAE の precision の方が高い結果となった。従って、サンプルのバリエーションが比較的大きい場合には、非線形な関数による特徴抽出を行う SAE が特徴抽出として有効と考えられる。

3.2 実験 2: スライスチーズ上の人工異物画像

次に SAE を用いて、良品画像としてスライスチーズを撮影した画像（高さ 28 画素、幅 28 画素）を 789 枚準備し、このうち 500 枚を学習用良品サンプル、残りの 289 枚をテスト用良品サンプルとした実験を行った。同一種のスライスチーズを使用したため、サンプルのバリエーションは比較的小さい。不良品画像は、良品サンプルの上に人工的に線を重畳した画像 789 枚を用いた。SAE の学習パラメータ等を表 2 に示す。実験の結果、50 回の試行のうち 46 回で precision 100% を達成する n と d が存在した。特徴空間上にマッピングされたテストサンプルの良好な一例を図 4(b) に示す。良品と不良品がきれいに分離していることがわかる。

なお、SAE の出力にはランダム性があるため、結果を統合することでアンサンブルの効果が得られる。本実験では 4 回は precision が 100% にはならなかったが、10 回の個別の学習・識別結果の多数決（アンサンブル）をとることにすれば、6 回は precision が 100% であるため、多数決を取った結果、precision も 100% となる。以上より、サンプルのバリエーションが小さい場合でも SAE は特徴抽出として有効と考えられる。

表 1. 実験条件 (実験 1)

活性化関数	ReLU
最適化手法	確率的勾配法 (SGD)
Pre-training バッチサイズ	400
Pre-training エポック数	200
Fine-tuning バッチサイズ	100
Fine-tuning エポック数	100
n	6 (1, 50, 100, 150, 200, 250)
d	8 (0.05, 0.1, 0.15, 0.2, 0.25, 0.3, 0.35, 0.4)

表 2. Precision 値の比較 (実験 1)

PCA	88.68%
SAE	88.66%~96.28%

表 3. 実験条件 (実験 2)

活性化関数	Sigmoid
最適化手法	Adam[4]
Pre-training バッチサイズ	2000
Pre-training エポック数	500
Fine-tuning バッチサイズ	2500
Fine-tuning エポック数	100
n	6 通り (1, 50, 100, 150, 200, 250)
d	8 通り (0.01, 0.02, 0.03, 0.04, 0.05, 0.06, 0.07, 0.08)

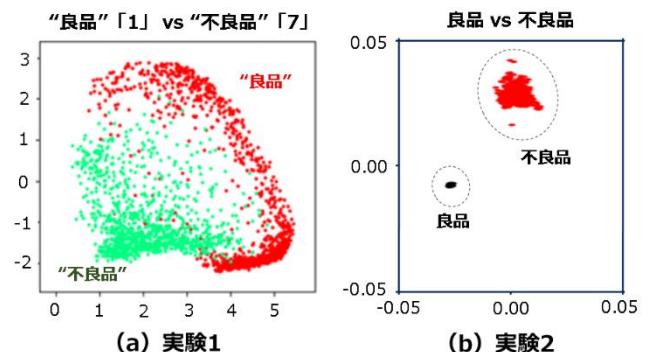


図 4 特徴空間上の散布図 (SAE)

4. まとめと今後の課題

良品サンプルのみを学習することで異物を検出する方法に関して、SAE により特徴抽出を行う方法を提案した。特徴空間上で n 番目に近い学習サンプルとの距離に基づく識別器を用いた評価実験で、非線形な関数による特徴抽出を行う SAE の有効性を示した。今後の課題は、 n と d を自動的に選定する方法の確立、実画像を用いた評価である。

参考文献

- [1] C. M. ビショップ, “パターン認識と機械学習 下”, シュブリンガー・ジャパン, pp.307-308, 2008.
- [2] Y. Bengio et al., “Greedy Layer-Wise Training of Deep Networks”, Proceedings on Neural Information Processing Systems, 2006
- [3] https://github.com/ISP-Kazuki-Nagasawa/chainer_1.6_sda_mnist_sample
- [4] D. Kingma et al., “Adam: a method for stochastic optimization”, 3rd International Conference for Learning Representation, 2015.