

GUI を用いたノーコードクラスター解析による異常画像の検出

福垣内 学^{*1)}

Detection of anomalous images using No-Code clustering analysis with a GUI

FUKUGAUCHI Manabu^{*1)}

検査工程を自動化する手法として、画像検査装置を Python で制御する方法がある。しかし、基本的なプログラミングスキルに加え、自社向け製品に合わせたカスタマイズが必要であり、高度な知識が必要である。プログラミング初級者でも自社用プログラムを開発する手法として Node-Red や Orange3 などの GUI を用いたツールを活用する手法がある。今回は、Orange3 を用いて画像データの入力からクラスター解析までノーコードで実施した事例を紹介する。

1. 緒言

AI を用いた異常検出では、正常なデータに対して、異常データが非常に少ない偏ったデータを用いる場合が多い。こうした場合に「教師あり」学習を用いると、異常データが少なすぎて機械学習が不完全となる点や予測外の異常に対して判定が正しく行えないという問題点がある。こうした異常検知をするには「教師なし」学習を用い、正常値が持つ共通の特徴をあらかじめ学習しておき、特徴量が異なるデータが入力された場合、異常と出力するシステムが望ましい。「教師なし」学習のソースコードはオープンソースで提供されているが、データ処理の手順とコードの記述方法をリンク付けすることが、プログラミング初級者には難しく、GUI ツールの併用をすることで、こうした解析を比較的簡単に扱うことができる。

2. 実験方法

2.1 検出画像の想定と画像生成

本検証では、リング状の製品の異常検出を想定し、ランダムに生成したグレースケール画像を用いて比較検証を行った。生成画像は、試料の重なりを排除し、撮影時の 360° 回転による揺らぎと矩形検出時の XY 方向の位置決め誤差を 2% 付与した。正常品画像として直径 80px のリング形状の 100 枚の画像 (OK) を生成した。比較対象として異常形状は異形状・突起 (異物)、サイズ違い (寸法不良)、切りかけ (欠損不良) およびライン・点 (汚れ) を想定した画像を用い、各 50 枚 (100px × 100px) の png データを生成し、検証を行った。基準画像を図 1 に示す。

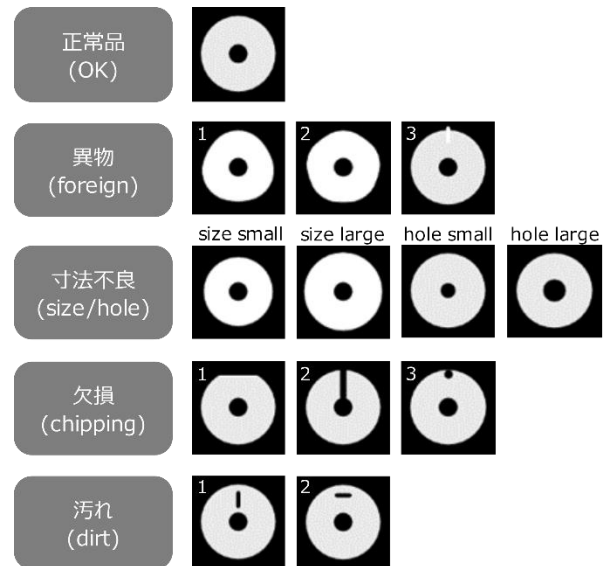


図 1 テストに用いた基準画像

2.2 GUI を用いた作業の流れ

データの評価は GUI を用いた Python のツールである Orange3 (ver3.36.2) ¹⁾ を用いた。こうしたツールを使うことで、プログラミング初級者でも GUI のプロパティの設定だけで機械学習のテストプログラムが組め、業務量を大幅に軽減できる。また、プログラムの流れが可視化できることから、処理の流れを共有しやすい ²⁾。Orange3 では一次元の csv データを用いるのが基本であるが、Image Analysis 追加モジュールと Python Script GUI に自作コードを組み込み、100px×100px の二次元データを 1×10000 の一次元データに変換しラベル付けを行い、Table 形式にデータ化した。Orange3 では Scikit-learn のライブラリが GUI ツールとして提供されているので、目的となる解析の手順に従い、GUI をドラッグアンドドロップすれば、グラフによる可視化ができる (図 2)。

*1) デジタル技術支援科 (当時: IoT 推進グループ)

2.3 教師なし学習

教師なし学習の事例として、画像データを入力値として、PCA と多様体学習である t-SNE, MDS および ISOMAP を用いて解析³⁾⁴⁾⁵⁾した事例を示す(図3). PCA を用いて 10000

次元の 255 階調のピクセルデータを正規化した後、100 次元まで圧縮しデータを軽量化しても 99.9%以上の信頼度で特徴量を維持できた. さらに多様体解析を用いて 10 次元まで圧縮し、クラスター分類について評価を行った.

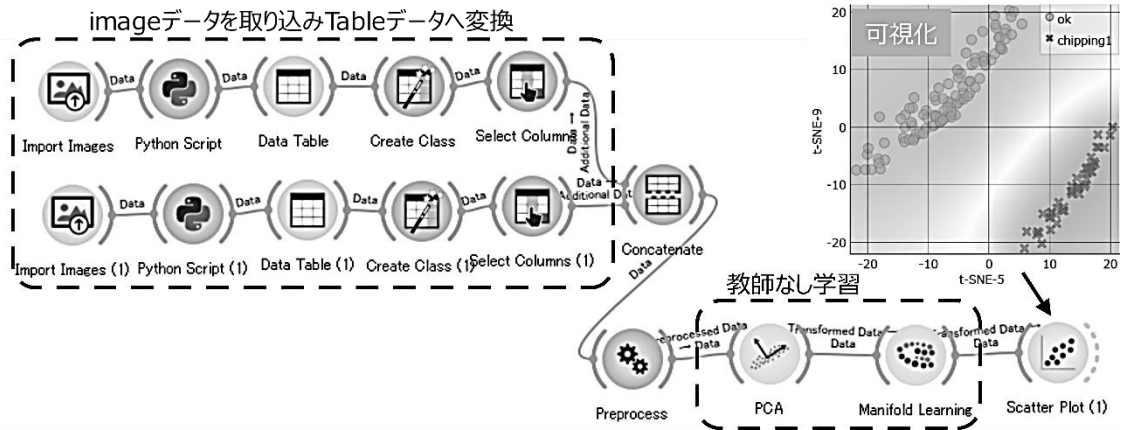


図 2 Orange3 の標準 GUI




図 3 教師なし学習の流れ

3. 結果と考察

GUI を用いたクラスター解析による結果を表 1 に示す. 分類の可否は 10 次元に圧縮した多様体解析の最も良い 2 次元分類性能を示す解析値から評価した. 図 4 に ok vs foreign2 と ok vs chipping2 の解析例を示す. クラスターリングに成功した場合は、ok 画像のクラスター外を異常値と判定することで異常検出できる. 分類性能は MDS と ISOMAP が同程度となったが、突起、小穴の寸法異常および欠損については同一クラスターとなり、分類出来なかった. t-SNE は欠損に対して分類ができず、全般的にクラスターリング性能が劣っていた. GUI を用いた解析はエラーが起きにくく、パラメータ調整と計算結果の可視化が素早く行え、プログラミング初級者が、Orange3 を用いることで、性能評価を短時間で比較解析が行えることは大きなメリットである. ただし、Orange3 では作成した手順を Python プログラムとして出力する機能が现阶段では備わっていないので、得られた手順とパラメータを元にプログラムに落とし込む必要がある.

表 1 クラスター解析結果

	t-SNE	MDS	ISOMAP
foreign1	○	○	○
foreign2	○	○	○
foreign3	×	×	×
size_small	○	○	○
size_large	×	○	○
hole_small	×	×	×
hole_large	×	○	○
chipping1	×	×	×
chipping2	×	○	○
chipping3	×	○	○
dirt1	○	○	○
dirt2	○	○	○

Classification Result (○ : OK / × : NG)

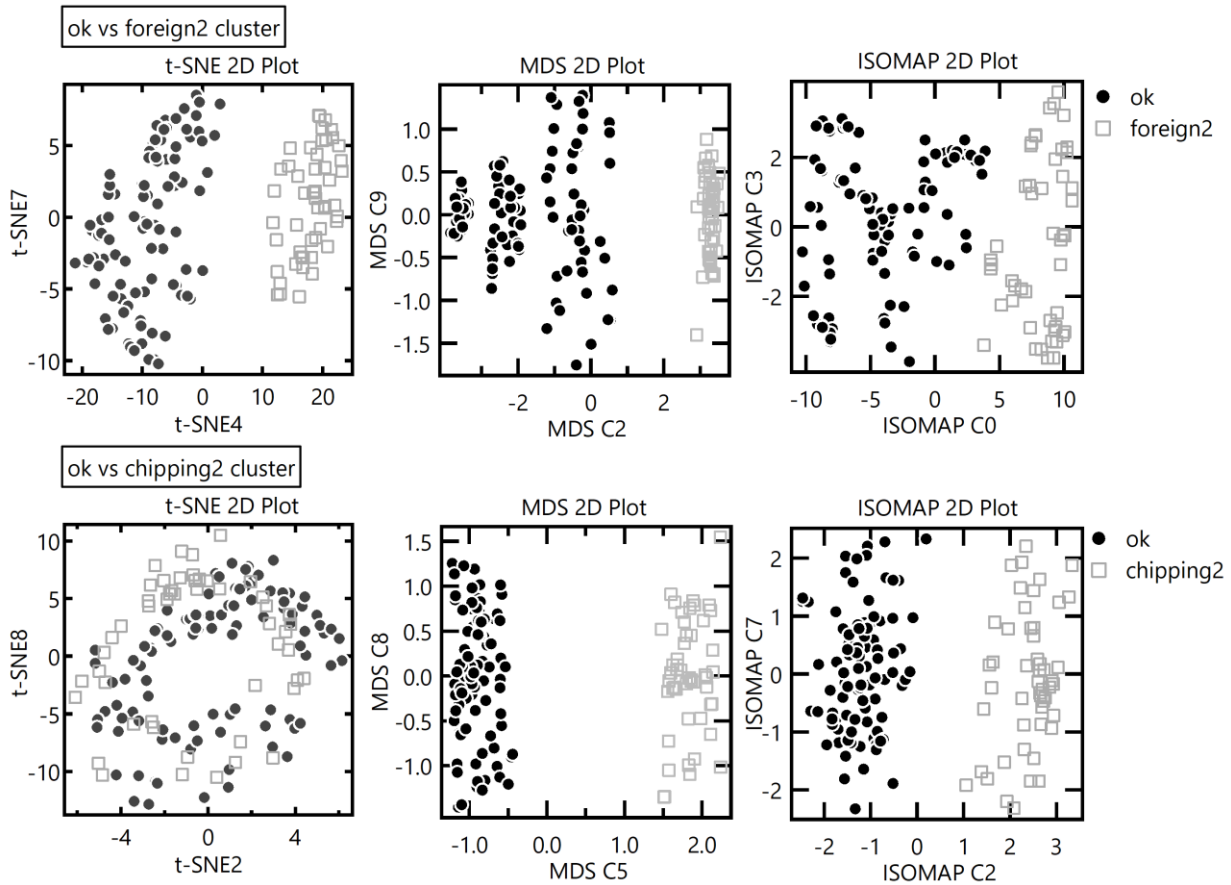


図 4 クラスタ解析結果抜粋

4. 結言

GUI を用いた Python のツールである Orange3 を用いてリング形状の教師なし学習について評価を行った。Python Script GUI を組み合わせることで、ノーコードでクラスタ解析の評価を行うことが可能となる。評価に用いたリング形状の分類性能はMDSとISOMAPが同程度となったが、異物、小穴の寸法不良および欠損不良については分類出来なかった。測定画像の揺らぎの影響が小さく、パターンマッチをせずとも異形状や汚れの異常検出は可能であった。未知形状に対して対応出来ることはメリットであるが、細かい形状異常検出に課題がある。プログラミング作成による画像解析と比較して、GUIによる解析はプログラミング初級者にも手順がわかりやすく、パラメータ調整と結果確認がプロパティ調整で行えることから、自社用プログラムの開発初期には有効なツールとなり得る。また機械学習の教育用として用いる場合も有用となる。欠点として、GUIの処理をプログラムで出力出来ない点やScikit-learnのすべてのパラメータを網羅していない点がある。そのため開発初期はOrange3、実環境はPythonを用いるというのが現実的な手法となる。

参考文献

- 1) “Orange3”, <https://orange.biolab.si/>, (3.36.2)
- 2) 木野日織, Orange Data Mining ではじマティクス, 近代科学社, 2021
- 3) Andreas C. Muller, Sarah Guido, Python ではじめる機械学習, オライリージャパン, 2017
- 4) Ankur A, Patel, Python ではじめる教師なし学習, オライリージャパン, 2020
- 5) Michael Beyeler, OpenCV と Python による機械学習プログラミング, マイナビ出版, 2018