

令和 5 年度
修士学位論文

画像を用いたカット野菜の不良検出の 研究

A Study on Defect Detection in Cut Vegetables
Using Images

1265090 伊藤 湧山

指導教員 栗原 徹

2024 年 2 月 28 日

高知工科大学大学院 工学研究科 基盤工学専攻
情報学コース

要 旨

画像を用いたカット野菜の不良検出の研究

伊藤 湧山

市販のカットサラダは野菜を適切なサイズにカットし、不良品を取り除いたのちに販売される。この作業は手作業で行われており、自動化は課題となっている。しかし、不良品の発生数が少なく、教師なし学習による手法が検討されている。

そこで我々は、外観検査向け異常検知手法である patchcore という手法に着目した。patchcore は事前学習されたトレーニングモデルを使用し、正常画像のみで構成されたデータセットで学習、異常検知を行える手法であり、MVTecAD データセットにおいて SOTA を達成した手法である。

本研究ではこの patchcore をベースとし、コアセットサンプリング部分を主成分分析に、近傍の計算をユークリッド距離からマハラノビス距離に変更することである程度の異常検出を行うことが出来た。

キーワード patchcore 異常検知 主成分分析

Abstract

A Study on Defect Detection in Cut Vegetables Using Images

ITO Yuzan

Commercially available cut salads are processed by cutting vegetables into appropriate sizes and removing defective products before sale. This process is currently performed manually, and automation remains a challenge. However, due to the low occurrence of defects, methods based on unsupervised learning are being considered.

In this context, we focused on an anomaly detection method for visual inspection called Patchcore. Patchcore utilizes a pre-trained training model and is capable of learning and detecting anomalies with a dataset composed solely of normal images. It has achieved state-of-the-art (SOTA) results on the MVTecAD dataset.

In our study, we based our approach on Patchcore, modifying the core-set sampling component to use Principal Component Analysis (PCA), and changing the calculation of proximity from Euclidean distance to Mahalanobis distance. These adjustments allowed us to achieve a certain level of anomaly detection.

key words Patchcore anomaly detection Principal Component Analysis

目次

第 1 章	はじめに	1
1.1	背景	1
1.2	目的	2
1.3	本論文の構成	2
第 2 章	関連技術	3
2.1	主成分分析	3
2.2	patchcore	4
2.3	resnet	4
2.4	コアセットサンプリング	5
2.5	産業用カメラ	7
2.6	AUROC	7
2.7	MVTecAD データセット	8
第 3 章	撮影機材・環境	9
3.1	使用装置	9
3.2	カメラの制御	10
3.3	撮影環境	11
第 4 章	提案手法	13
4.1	patchcore について	13
4.1.1	resnet を用いた特徴点の取り出し	14
4.1.2	コアセットサンプリングによる特徴量の削減	14
4.1.3	異常スコアの計算	15
4.2	提案手法	15

目次

4.3	実験条件	17
第 5 章	結果・考察	18
5.1	結果	18
5.2	考察	21
第 6 章	結論	23
	謝辞	24
	参考文献	25
付録 A	付録環境	26

目次

2.1	主成分分析の図	3
2.2	patchcore の構造 [1]	4
2.3	resnet の構造 1[4]	5
2.4	resnet の構造 2[4]	5
2.5	コアセットサンプリングによる特徴量の削減	6
2.6	使用した産業用カメラ	7
2.7	MVTecAD データセット [7]	8
3.1	設計したコンベア	10
3.2	コンベアの配線図配線図	11
3.3	撮影例	12
4.1	resnet を用いた特徴抽出	14
4.2	サブセットを用いたスコア計算	15
4.3	patchcore を用いた異常検出	16
4.4	提案手法	16
5.1	結果のヒートマップ	20
5.2	結果のヒートマップ	20

表目次

5.1	累積寄与率ごとの主成分数 (1024 次元中)	18
5.2	累積寄与率ごとの結果	19
5.3	削減法ごとの結果	19
5.4	手法毎の処理時間	21

第 1 章

はじめに

1.1 背景

市販のカットサラダは野菜を適切なサイズにカットした後、不良品を取り除き、販売される。この不良品を取り除く工程は手作業で行われる。検査対象の形状が一定である工業製品においても不良品の検出は課題である。しかし、検査対象である野菜において不良品の発生率は低く、教師なし学習による手法が検討されている [1]。学士の時の卒業研究では、CAE、畳み込みオートエンコーダを使用した異常検出を検討した。しかし、誤検出が多いという点で大きな課題を抱えていた。特に、葉の影、コンベアと葉の境界、光の反射部分に誤検出が見られ、ssim という画質評価指標を損失関数として使用することでこれらの誤検出を多少提言する事はできた。しかし、完全にこれらを除去する事は難しく、課題としては継続して存在していた [4]。そこで我々は外観検査向け異常検知手法である patchcore という手法に着目した。patchcore は事前学習されたトレーニングモデルを使用し、正常画像のみで構成されたデータセットと異常画像を含むデータセット間の距離を異常スコアとして計算する手法である。この patchcore は MvtecAD データセットにおいて最先端の精度を持つことを示す SOTA 達成をした手法である [3]。本研究では、MVTecAd データセットと異なり、自然物であるキャベツに対する異常検出を patchcore をベースとした手法で行うことができるかどうか検討する。

1.2 目的

1.2 目的

1.1 節から本研究での目的は以下の 2 つである。一つ目は産業用のカメラを使用して、コンベア上の野菜の撮影を行う。次に撮影された画像を用いてキャベツの葉の異常を検出する、という 2 点を目標とし、実験を行っていく。

1.3 本論文の構成

本論文の構成として、第 2 章で関連技術について述べ、第 3 章では、実験に使用した環境や機材について述べる。第 4 章ではベースとした patchcore や提案手法について述べる。第 5 章では結果と考察について述べ、第 6 章では結論を述べる。

第 2 章

関連技術

2.1 主成分分析

主成分分析は高い次元の情報をできるだけ損なわず、低次元で表現をできる手法である [2]。この主成分分析は機械学習においてしばしば特徴の削減に用いられる。分散が最大の軸を新たな主成分とすることで、より効率的な特徴の表現ができ、データの圧縮を行うことができる。多次元の特徴に対しては、データに最も近接する超平面を見つけることでより少ない次元での表現を行う。主成分には寄与率が存在し、これはそのデータの表現にどれだけ寄与しているかを示している。一般的にはこの寄与率の合計が 80%を超えればデータ全体を表現できているとされる。

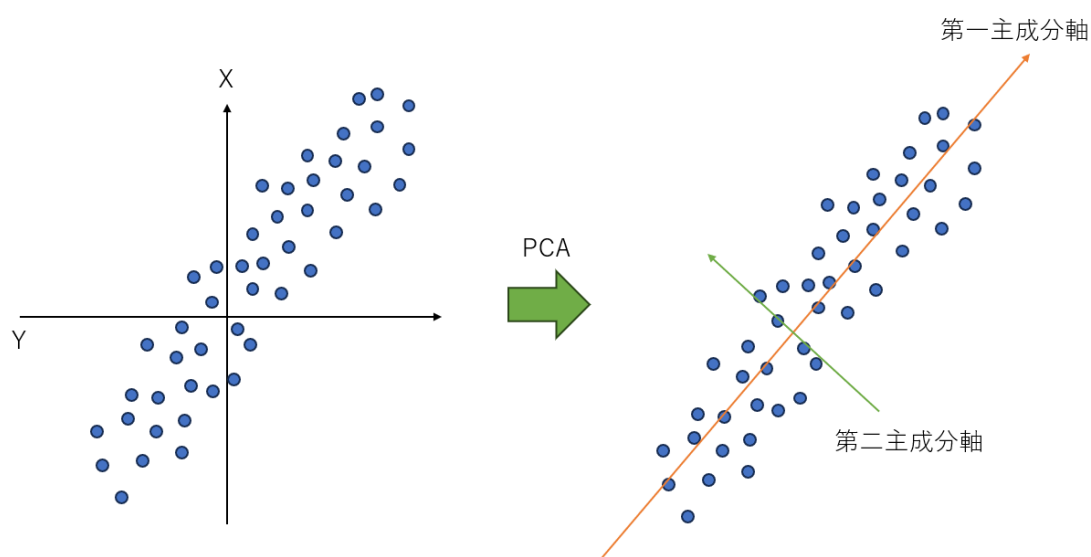


図 2.1 主成分分析の図

2.2 patchcore

patchcore は ImageNet のデータセットで学習されたモデルを用いて異常検知を行う，教師なし学習の一種 [3]．正常画像のみで構成されたデータセットから特徴を抽出し，メモリバンクに保存する．この状態では計算量が膨大になってしまい，現実的な時間で推論が終わらない為，コアセットサンプリングと呼ばれる特徴量削減手法を用いて大きなデータセットを近似する小さなサブセットを作成する．作成されたデータセットと異常が写った画像を含むデータセットから抽出した特徴との最小の距離を求め，その最大値を異常スコアのベースとする．つまり，作成されたサブセットの特徴から遠い箇所に位置する特徴点が異常箇所となる．

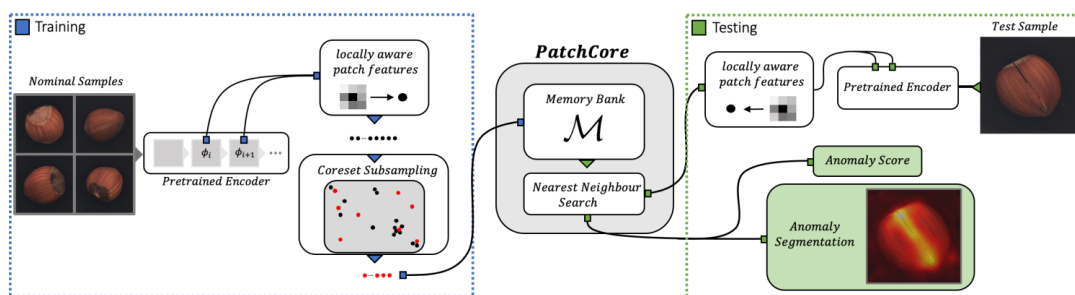


図 2.2 patchcore の構造 [1]

2.3 resnet

従来のニューラルネットワークでは層を深くしていくと，勾配消失によって学習を上手く進めることが難しかった．これは，出力層で計算した誤差を誤差逆伝播入力法を用いて入力層まで戻したときに，層が深すぎるとその誤差が入力層まで伝わらなかったことが原因である．resnet はそれを Residual block と呼ばれる skip connection を提案、勾配消失を回避している [5]．これは，学習したい関数との”差”を学習することで勾配の消失を回避している．これにより，層をより深くすることが出来るようになったが増やしすぎると過学習の問題も発生する．下の図 2.3 と図 2.4 は resnet のネットワーク図である．

2.4 コアセットサンプリング

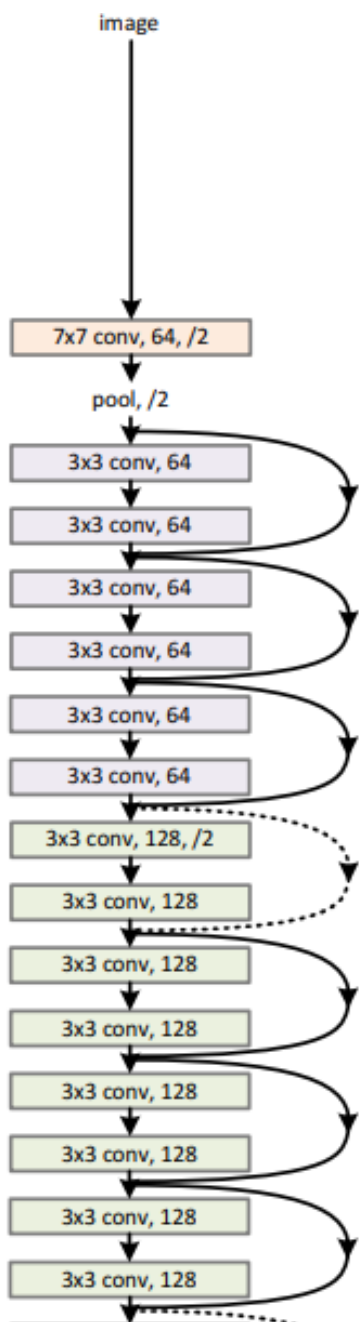


図 2.3 resnet の構造 1[4]




図 2.4 resnet の構造 2[4]

2.4 コアセットサンプリング

コアセットサンプリングはユークリッド空間においてある特徴 P においてその特徴を近似する小さなサブセット Q を少ない時間で計算するためのアルゴリズムである [6]. patchcore

2.4 コアセットサンプリング

では, resnet で抽出した特徴を削減するために使用されている. コアセットサンプリングは以下の式 2.1 によって定義され, その特徴量の削減は以下の図 2.5 のように行われる.

$$M_C^* = \arg \min_{M_C \subset M} \max_{m \in M} \min_{n \in M_C} \|m - n\|_2. \quad (2.1)$$

図の灰色の点を抽出した特徴量, 赤い点を近似されたサブセットに加えられた特徴量とする. 図では簡単にするため, 2次元で説明しているが実際は多次元の特徴量となる. 1番では, 抽出された特徴量点からランダムに一つ選び, サブセットに加える. 2番では, 1番で選んだ特徴点から最も遠い特徴点を同じようにサブセットに加える. 3番では, サブセットに存在する特徴点全てに対して距離を計算し, その最大距離が最も短い点をサブセットに加える. これをサブセットとして選択した数を満たすまで繰り返すことで元の特徴を引き継いだコンパクトなサブセットを作ることが出来る.




図 2.5 コアセットサンプリングによる特徴量の削減

2.5 産業用カメラ

本研究で用いた Baumer 社製の産業用カメラ VCXG-51c(図 2.3) を使用する。高画質の CMOS Pregius センサーを搭載し、解像度 2448×2048 で 24fps の取り込みが可能である。カメラの機能として、トリガー撮影が可能なオーバーラップトリガーモードを搭載し、連続した画像の撮影が可能となっている。また、LAN につなげることが可能で、python のライブラリである、neoAPI での制御が可能となっている為、LAN 経由で PC からの制御が可能となっている。



図 2.6 使用した産業用カメラ

2.6 AUROC

AUROC は二値分類タスクにおいて用いられる評価指標の一つ。ROC 曲線の下面積を指し、0~1 の間の値を取り、その値が 1 に近いほど性能が良いとされる。

例として、ある機械学習モデルにおいて、予測ラベルがすべて正解である場合、AUROC

2.7 MVTecAD データセット

は 1.0 となり，そのモデルは理想の性能を持つことを示す．AUROC が 0.5 であった場合，それはモデルがランダムな推測と同じであることを示し，予測性能が低いことを示す．

2.7 MVTecAD データセット

2019 年に公開された外観検査にフォーカスされた異常検知データセット [7]．新しい教師なし学習のトレーニング、及び評価のために作られたデータセットであり，様々なオブジェクト，およびテクスチャで構成されている．このデータセットには傷，へこみなど 70 を超える異常が含まれており，またすべての異常に対してマスク画像が提供されている．



図 2.7 MVTecAD データセット [7]

第3章

撮影機材・環境

本研究では専用に設計されたコンベアを使用してカットされた野菜を撮影する。本章では撮影に使用したコンベアや機材について説明する。

3.1 使用装置

本研究にあたり、図 3.1 のコンベアの設計から行った。Rei*Design 製のベルトコンベアの回転をロータリエンコーダ (OMRON 製) を用いてパルス信号に変換する。この信号をパルスアイソレータ (渡辺電気工業製) を介して電圧変換し、撮影に用いる産業用カメラ (Baumar 社製) に入力する。

カメラは研究室 LAN を介して pc から制御され、17 パルスごとに撮影を行う。これにより、コンベアのベルトが 97mm 移動するごとに撮影する事が出来、オーバーラップ率 40% で撮影を可能としている。

使用するカメラの解像度は 2448×2048 であり、コンベアのベルト面から高さ 185mm に設置することで縦 156mm 横 209mm の範囲を撮影でき、1 画素あたり 0.08mm となる。

3.2 カメラの制御



図 3.1 設計したコンベア

3.2 カメラの制御

コンベア上部に固定したカメラは、LAN を経由して pc と接続されており、python コードを使用した制御を可能としている。制御用の API である Neo API を導入した Anaconda 環境を作成し、専用のツールでカメラとの接続を行う。

図 3.2 は設計したコンベアの配線図である。

3.3 撮影環境

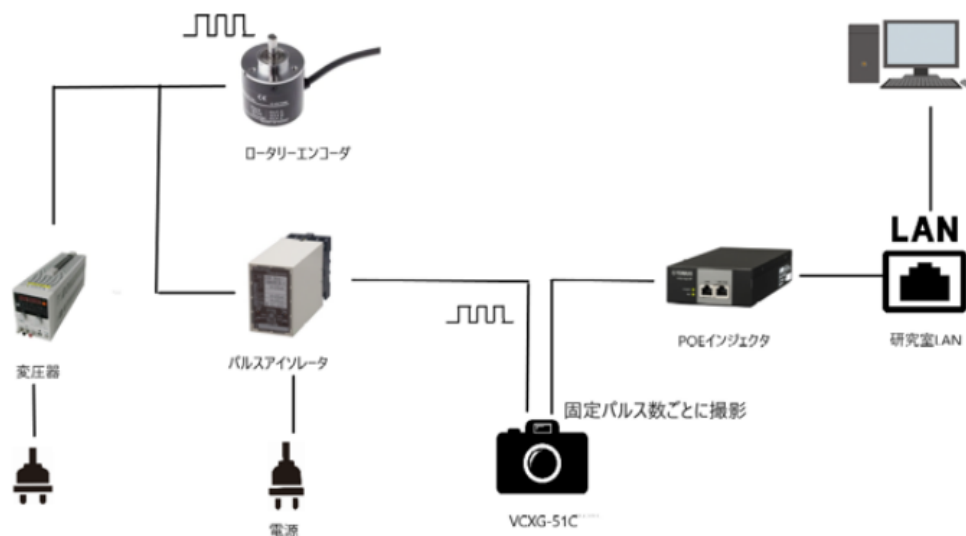


図 3.2 コンベアの配線図配線図

3.3 撮影環境

撮影にあたり、野菜は市販されているキャベツをカットして使用した。カットのサイズは $30\text{mm} \times 40\text{mm}$ 以下になるようにカットし、正常品のみデータセットを 522 枚、不良品を含むデータセットを 27 枚撮影した。撮影にあたり、照明をコンベアの前後に配置し、コンベア上を一様に照らせるように工夫した。コンベアを設置した部屋の照明は点灯したまま撮影を行い、時間帯は可能な限り統一して 14 時から 17 時の間に撮影を行った。また、カメラには付属の防塵、防滴カバーを装着し撮影を行った。撮影された画像の例を以下の図 3.3 に示す。

撮影にあたり、目標処理量を設定した。目標処理量 1 時間に 200kg とした。これを 200mm 幅のコンベアで処理を行うとすると、 83mm/s で動かす必要がある。しかし、これは密に並べた場合の話であり、現実では密に並べることは不可能である。よって、余裕を取るために、1.5 倍し、 125mm/s でコンベアを動かす。また、オーバーラップは 40% なので撮影間隔は 96mm ごと、時間にすると 0.7 秒で 1 枚の撮影となる。

3.3 撮影環境

以下の図 3.3 に示すのが撮影された画像の一例である。示している画像は正常画像の例である。




図 3.3 撮影例

第 4 章

提案手法

本研究では異常検知手法として patchcore をベースとした手法を用いた。本章では、ベースとした patchcore について、そして本研究で使用する提案手法について説明する。

4.1 patchcore について

関連研究の章で示したように、patchcore は教師なし外観検査手法の一つで、MVTecAD データセットにおいて SOTA を達成した手法である。この patchcore は具体的に以下の手順で構成される。

1. resnet を使用した、正常画像からの特徴点の取り出し
2. コアセットサンプリングを用いた特徴点の削減
3. 削減した特徴とテスト画像から取り出した特徴との特徴点間の距離を計算し、その後異常スコアの計算のベースとする。

これまで、教師なし学習の一つである畳み込みオートエンコーダを使用して野菜の欠陥を検出できないか検討してきた。この畳み込みオートエンコーダはピクセルごとに再構成誤差をしきい値で処理することで異常検知を行う。この畳み込みオートエンコーダの欠点として再構成時にエッジ周辺にわずかでも位置ずれが起きた場合、そのずれが大きな残差として残ってしまい、それが欠陥領域として表現される [8]。これは変分オートエンコーダなどの複雑なアーキテクチャを使用しても容易に回避できず、画質評価指標の SSIM を評価に用いることで多少低減できたが完全に回避することは難しかった。そこで本研究では patchcore

4.1 patchcore について

をベースとした手法を提案する.

4.1.1 resnet を用いた特徴点の取り出し

patchcore では学習済みモデルを用いて正常画像のみから構成されるデータセットから特徴を抽出する. この時のパッチサイズは 3×3 である. また, この patchcore の特徴として resnet の 4 つのブロックのうち, 2 つ目と 3 つ目の特徴量を取り出すという点がある. この取り出した 2 つの特徴は 2 ブロック目の大きさに合わせて 3 ブロック目がバイリニア補間により保管され, 大きさを合わせた後に連結される. これによって, 2 ブロック目と 3 ブロック目を一つの特徴量として扱うことが出来る.

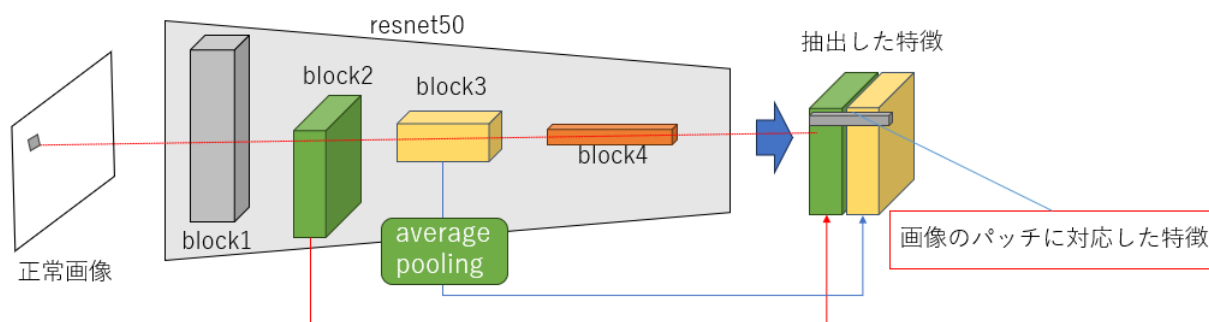


図 4.1 resnet を用いた特徴抽出

4.1.2 コアセットサンプリングによる特徴量の削減

前章で取り出された特徴量をそのまま使用して異常検知を行うと, 特徴量の数が多く, 計算時間の大きな増加を招いてしまう. そこで patchcore ではコアセットサンプリングによる特徴量の削減を行う. 関連技術で説明したように, コアセットサンプリングは貪欲法を用いた特徴点の削減であり, これによって元の集合の特徴を引き継いだ部分集合を作成できる.

4.2 提案手法

4.1.3 異常スコアの計算

ここまでの手順で、正常画像から特徴を抽出し、その特性を引き継いだサブセットを作ることが出来た。次に、正常画像と同様に学習済みモデルを用い、特徴を取り出す。この取り出した特徴と正常画像の特徴のサブセット間の距離を計算し、異常スコアのベースとする [9]。これを図を用いて説明したのが図 4.2 である。図中の灰色の点が正常画像の特徴点、赤色の点が異常画像の特徴点である。

正常画像の場合、特徴点は図 4.2 の上側のように、正常画像の特徴点の近くに分布すると考えられる。しかし、異常箇所の特徴は下側のように正常画像の特徴点から離れた箇所に分布する事が考えられる。この特徴点間の距離を利用して異常スコアを計算する。




図 4.2 サブセットを用いたスコア計算

4.2 提案手法

本研究では patchcore の手法の中で以下の 2 点に着目した。

- コアセットサンプリングによる特徴量の削減

4.2 提案手法

- ユークリッド距離を用いた近傍の計算

本手法ではまず、コアセットサンプリングによる特徴量の削減を主成分分析を用いた特徴量の削減に、ユークリッド距離を用いた近傍の計算をマハラノビス距離を用いた近傍の計算に変更することでコンベア上の野菜の異常検出を検討する。以下の図 4.3 に patchcore による異常検出と、提案手法それぞれの手法を示す。

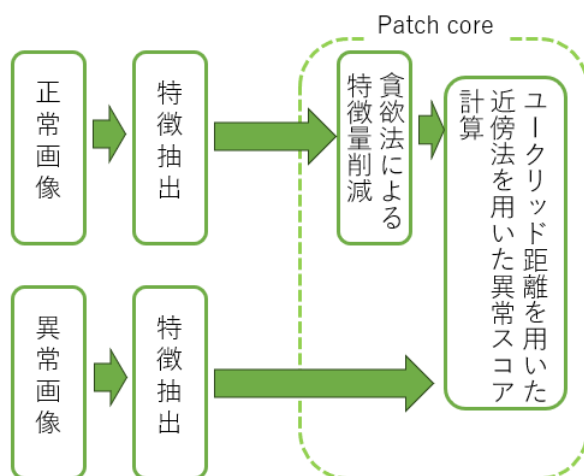


図 4.3 patchcore を用いた異常検出

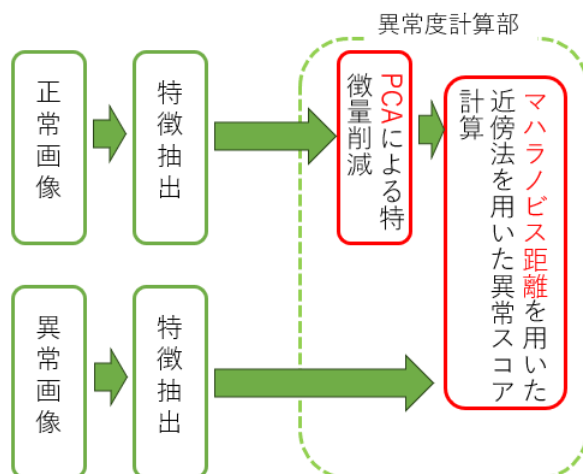


図 4.4 提案手法

4.3 実験条件

正常画像のみで構成されたデータセットとしてコンベアで撮影された正常画像 522 枚をすべて使用した。ただし，gpu のメモリの都合上，画像を縦横 1/4 に縮小し， 1224×1024 画素とした。また，評価用画像は撮影された画像 24 枚を用いて実験を行った。評価用画像も同様に縦横 1/4 に縮小する。データ拡張などは行わない。また，元の手法との比較として MVTECAD データセットの bottle データセットと cable データセットでも同様に実験を行う。

特徴抽出器には Imagenet で学習された resnet50 を使用し，4 つあるブロックのうち，2 つ目と 3 つ目のブロックから特徴量を取り出す。

主成分分析は sikit-learn のライブラリを使用し，累計寄与率 80%，70%，60%，50% ごとに主成分数を計算し，それぞれの条件で比較を行う。近傍の計算はマハラノビス距離を用い，それら以外の変更は行っていない。

評価方法は AUROC を用いる。

第 5 章

結果・考察

本章では実験の結果と考察について述べる。

5.1 結果

まず初めに、主成分分析を用いた特徴量削減を行った場合の累計寄与率ごとの主成分数を表 5.1 に表す。この表より、削減後の次元が最も多い 35 次元の場合でも、データ全体を表現できているといわれる累積寄与率を超えており、十分にデータの特性を引き継いだサブセットを作ることが出来たと考える。

表 5.1 累積寄与率ごとの主成分数 (1024 次元中)

累積寄与率	50%	60%	70%	80%
cabbage	6	10	17	34
bottle	3	4	6	8
cable	10	18	25	35

次に表 5.2 に累積寄与率ごとの AUROC を表す。表の中の数字は計算結果より 100 倍されており、100 に近いほどより正確に分類できていることになる。この表から、今回検出対象としたキャベツのデータは、累積寄与率 60%の時に、最も性能が良くなることが分かった。また、MVTecAD データセットの時は、cable が累積寄与率 80%の時、bottle データは 60%の時に異常をよく分類できた。

表の一番右に示している数字は、patchcore を使って今回のデータの異常分類を行った数

5.1 結果

字で、MVTecAD データセットでは分類性能が最も高い数字を示していたが、コンベアを使って撮影したキャベツのデータでは最も低い精度を示し、MVTecAD データセットでは patchcore を用いた異常検出が最も適していることも分かった。

表 5.2 累積寄与率ごとの結果

累積寄与率	50%	60%	70%	80%	patchcore
bottle	78.3	80.2	77.5	73.4	60.7
cable	81.4	84.4	83.3	85.5	98.8
cabbage	85.5	87.8	89.1	89.4	99.0

表 5.3 に提案手法と、patchcore を用いた異常検出での精度の比較を示す。表の「coreset」としてしているところはコアセットサンプリングによる特徴量の削減を示し、「PCA」は主成分分析を用いた特徴量の削減を示す。また、アルファベットの「E」と「M」はそれぞれ近傍法の計算を行うときの距離尺度を示し、「E」がユークリッド距離、「M」がマハラノビス距離を示している。つまり、patchcore を用いた異常検出は「coreset + E」と示され、提案手法は「PCA + M」と示される。

表より、コンベア上のキャベツを最もよく検出できる手法は提案手法であることが示され、逆に最も精度の悪い手法は patchcore を用いた異常検出であることが分かった。また、MVTecAD データセットにおいては patchcore を用いた異常検出が最も精度が高い結果となり、提案手法はコンベア上のキャベツを検出する場合で有効でのみあることが分かった。

表 5.3 削減法ごとの結果

手法	coreset + E	coreset + M	PCA + E	PCA + M
bottle	60.7	70.7	76.2	80.2
cable	98.8	98.2	80.3	84.4
cabbage	99.0	98.6	86.9	87.8

次に図 5.1 と図 5.2 に、テスト画像での異常検出例を示す。この異常検出例は、ヒート

5.1 結果

マップで表現されており、暖色に近いほど異常度が高くなっている。また、テスト画像において赤丸で囲われている箇所が異常箇所になる。図 5.1 のヒートマップを見ると、赤丸と同じ個所に異常度が高い特徴が存在しており、異常を正常に検出できていることがわかる。

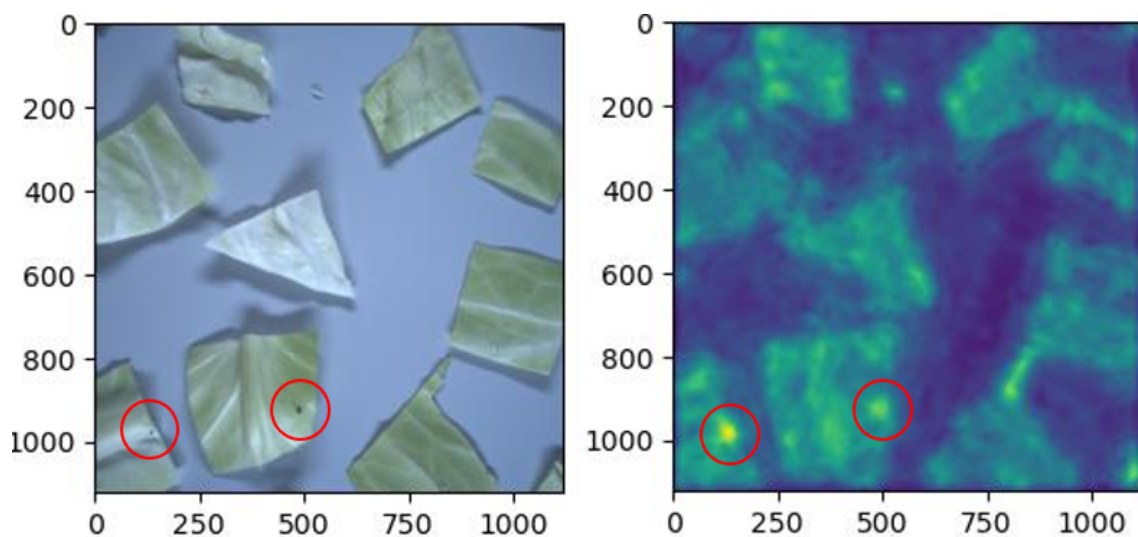


図 5.1 結果のヒートマップ

一方、図 5.2 では赤丸で囲われた異常箇所に異常こそ出ているものの、同じ葉の他の箇所、具体的には葉の影の部分により強い異常が現れており、本来検出したい異常箇所が埋もれてしまっていることが分かる。




図 5.2 結果のヒートマップ

5.2 考察

今回の検出結果は CAE を用いた異常検出と比べ、葉とコンベアの境界線、コンベアの表面に落ちた影など CAE で誤検出していた箇所を正常に検出できるようになったなど課題を解決できた箇所もあったが、依然として葉自体に落ちている影など、誤検出を完全に無くすることが出来たわけではなく、今後照明条件や影を除去する手法など改良できる点は多々ある結果となった。

最後に表 5.4 に各手法ごとの 1 枚当たりの処理時間を示す。本研究で設計したコンベアは 0.7 秒で 1 枚撮影するため、理想としては 0.7 秒以内に処理を行うことが理想だったが、表より、0.7 秒には全く届いておらず、撮影間隔中には処理できない結果となった。

表 5.4 手法毎の処理時間

推論時間 (1 枚当たり)	patchcore	提案手法
cabbage	10.7ss	36.6s
cable	0.16s	2.1s
bottle	10.7s	1.8s

5.2 考察

結果より、提案手法がある程度 cabbage データセットに有効であることが分かった。しかし、課題点もあり、まず誤検出が課題となる。例として図 5.2 に示したように、光の反射部分が異常領域として検出されてしまっている。また、同じ画像において影の部分が誤検出されてしまっている為、照明などの改善が必要である。

主成分分析の累計寄与率 60%の時に最も高い AUROC を記録した理由としては 60%の時に適切にノイズが除去され、正常な葉として重要な除法を保持したまま特徴量の削減が行われたためであると考えられる。また、MVTecAD データセットにおいて提案手法の AUROC が下がった原因としては cabbage データセットには複数の製品が写っているが MVTecAD データセットには 1 枚の画像に 1 つの製品のみが写っている。その為、MVTecAD データセットに比べて特徴量が複雑になり、これを主成分分析することで特徴量を適切に保持でき

5.2 考察

たためであると考えられる。

ただ、本研究では主成分分析を用い、特徴点 1 つ当たりの特徴量を減らすことで計算時間の削減を図った。しかし、patchcore 手法は特徴点の数自体を貪欲法を用いたコアセットサンプリングによって減らしており、その点において提案手法はコアセットサンプリングと異なる。本研究では計算時間に課題が残る結果となったが、提案手法を用いた特徴量の削減だけでなく、特徴点 1 つ 1 つの特徴量を削減した後にコアセットサンプリングによる特徴点削減を行うことでより効果的な特徴点の削減を行うことが出来るのではないかと考える。

また、ユークリッド距離からマハラノビス距離に変えたことで AUROC の向上がみられた。これはマハラノビス距離がユークリッド距離と異なり、特徴量間の相関関係を考慮するため、AUROC が向上したのではないかと考えられる。

第 6 章

結論

本研究では、patchcore をベースとし、コアセットサンプリングによる特徴量削減を主成分分析に、よる特徴量削減に、近傍の計算法をユークリッド距離からマハラノビス距離に変更することでコンベア上のキャベツの異常を検出する事を検討した。

その結果、ある程度不良の検出が出来る事が分かった。しかし、光の反射箇所や、葉の影など、誤検出が若干存在し、計算時間についても課題が存在した。今後これらの観点からさらなる精度向上を目指す必要があると考える。

謝辞

最後に本研究をまとめるにあたり、指導や、研究に関する提案をしていただいた栗原 徹教授には心から感謝申し上げます。また、本研究の副査を引き受けてくださった、吉田 真一教授並びに、妻鳥 貴彦准教授においては適切なお指導いただき深くお礼申し上げます。

参考文献

- [1] Samet ら: "GANomaly: Semi-Supervised Anomaly Detection via Adversarial Training", In Asian Conference on Computer Vision, Springer, 2018
- [2] Svante ら"Principal component analysis" In Chemometrics and Intelligent Laboratory Systems , Volume 2, Issues 1–3,1987
- [3] Karsten ら: "Towards Total Recall in Industrial Anomaly Detection", In Computer Vision and Pattern Recognition. 2022
- [4] 伊藤ら: "畳み込みオートエンコーダを使用したカット野菜の不良検出", 第 28 回画像センシングシンポジウム IS2-29.2022
- [5] Kaiming He ら: "Deep Residual Learning for Image Recognition", In Computer Vision and Pattern Recognition.2015
- [6] Pankaj ら: "Geometric Approximation via Coresets", Combinatorial and Computational Geometry, 52, 11 2004.
- [7] Michael ら: "Mvtec ad – a comprehensive real-world dataset for unsupervised anomaly detection", In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 2019
- [8] Paul ら: "Improving Unsupervised Defect Segmentation by Applying Structural Similarity to Autoencoders", Proceedings of the 14th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, 2019
- [9] Liron ら: "Deep Nearest Neighbor Anomaly Detection", CoRR, abs/2002.10445, 2020.

付録 A

付録環境