

複数の異常検出手法を組み合わせたブドウ葉の健康状態識別手法

下總 有芽
小嶋研究室




研究背景

- 近年、農業従事者の数が減少している
→人手不足の問題が深刻化



- 農業従事者の負担を軽減が課題
→IoTやAIの活用が推進されている



農業でのドローン活用

- 農林水産省が行った令和2年度のスマート農業に関する調査では、148地区中77地区でドローンを活用
 - そのうち中山間部にある果樹園での活用事例は9件、
 - 農業散布:6件, 肥料散布:2件, センシング:3
- 中山間部でのドローンの活用が進んでいない

- 農業では品質管理のために確認作業が重要
 - ブドウは中山間部で栽培されるため見回り作業の負担が大きい
- ドローンを巡回させることで見回り作業の負担の軽減


ドローンの取組内容
https://www.maff.go.jp/j/kanbo/smart/at_tech/pdf/drone-147.pdf

区分	ドローン取組件数
水田作	34
畑作	14
露地野菜	15
果樹	9
茶	2
畜産	1
5G	2
合計	77



本研究でのドローン活用方法

- ドローンにより動画の撮影
- 動画から画像の切り抜き
- 切り抜いた画像から、ブドウ葉を抽出
- 抽出した葉の画像を異常検知手法を用いて健康状態の識別



研究の概要図



研究目的

- 山口、伏屋が行った先行研究では、ドローンを活用したブドウ葉の自動識別システムの提案した
→異常葉の識別精度は高くなかった



異常葉の識別精度の向上



異常検知手法

- CNN(Convolutional Neural Network)ベース異常検知
→正常データと異常データを用いて異常検知
- GAN(Generative Adversarial Networks)ベースの異常検知
→GANに正常データのみを学習させ、生成できない物を異常とする
- 特徴量ベースの異常検知
→学習済みモデルを使用し、中間の情報を特徴量として取得



AnoGANを用いた先行研究

- 2021年、山口がAnoGAN(Anomaly Detection with Generative Adversarial Networks)を用いた手法を提案
- AnoGANは、GANベースの異常検知手法
- 健康葉のみを学習に使用している
- AnoGANにより、異常葉と健康葉のデータの偏り問題の解決
- 健康葉の識別精度の向上を実現

課題:異常葉の識別精度が低い



PaDiMを用いた先行研究

- 2023年、伏屋がPaDiM(Patch Distribution Modeling)を用いた手法を提案
- PaDiMは特徴量ベースの異常検知手法
- 健康葉のみの特徴量を使用する
- 2021年山口の研究より、異常葉の識別精度の向上と推論時間の短縮を実現

課題:明らかな異常画像を誤検知



関連研究

- 2022年Joaらが、CIE Lab色空間を用いた2ブランチDCNNを使用した植物病害検出手法を提案
- CIE LabはCIFAR-10を使用しDCNNを学習場合、他の色空間より優れていることが示されている
- Lとabをそれぞれ学習し、全結合層で結果を結合することで植物病害のクラス分類を行う
- PlantVillageとCropped PlantDoCで、RGBを使用した研究結果より優れた識別精度を記録

課題:ピクセルレベルの正確性が確認できない
背景が複雑なデータセットで識別精度が落ちる



本研究で使用する画像データ

- 関連研究で使用されている植物の葉の画像は、背景が整備された画像(左の図)
- 本研究で使用するのは、背景が複雑な画像(右の図)
- 背景が整備されたものに比べ、背景が複雑な画像は識別精度影響を与えやすい



背景の整備された画像



背景が複雑な画像




提案手法

- 複数の異常検知手法とU-Netを用いることで異常葉の検出精度の向上を目指す
- 異常検知手法は、事前に複数の異常検知手法を実験調査し、結果のよかったPaDiM, PatchCore, Cs-Flowを使用
- 各手法から得られるヒートマップとU-Netの異常箇所の予測マスクを結合することで、ヒートマップを作成
- 作成したヒートマップから異常値を算出し、異常葉の判定




PaDiM

- PaDiMは、正常画像のみを利用
- ImageNetで事前学習させた、ResNetを特徴抽出器として使用
- 学習済みモデルの1~3層の特徴を抽出
- マハラノビス距離を用いて異常値の算出




PatchCore

- 正常画像のみを特徴抽出に使用
- ResNetの中間層を用いて特徴を抽出
- テスト画像の特徴も同様に抽出し、正常画像の特徴と最近傍探索で最大距離を求める




Cs-Flow

- Cs-Flowは、正常画像のみを使用
- 画像をリサイズして異なる3つのスケールで入力
- 特徴抽出器は、ImageNetで事前学習したEfficientNetを使用
- スケール別の特徴量を結合し、特徴マップをガウス分布で作成
- 特徴マップの値を集計し異常値を算出



U-Net

- FCN(Fully convolution network)の一種
- 画像のセグメンテーションをするためのネットワーク
- エンコーダーとデコーダーから構成
- スキップ接続をすることで分類精度向上



実験概要

- 複数の異常検知手法とU-Netを組み合わせた手法と単一の手法でブドウ葉の健康状態の識別を行う
- 画像の識別精度と、ピクセルの識別精度を算出し、各手法で性能比較を行う



データセット（異常検知手法）

- 異常検知手法の学習用データとして、1603枚の健康葉の画像を用いる
- テスト用画像は、健康葉と異常葉どちらも150枚

データセットの内容

	健康葉	異常葉	合計
学習データ	1603	—	1603
評価データ	150	150	300
合計	1753	150	1903



事前学習済みモデル

- PaDiMはWideResNet50を使用
- PatchCoreはWideresnet101を使用
- Cs-FlowはEfficientNet-B6を使用



U-Net学習条件

- U-Netの学習条件は以下の表の通り
- 異常葉のみを学習に使用する
- 学習枚数は27枚と127枚で精度を比較する

U-Net学習条件

	予備審査	本審査
学習画像枚数	27	27,127
学習:テスト	4:1	4:1
画像サイズ	256×256	256×256
バッチサイズ	8	8,16
学習回数	100	200
学習率	0.001	0.001



関連研究学習条件

- 関連研究を実装し、画像レベルでの性能比較を行う
- 学習条件は以下の通り、

関連研究学習条件

画像枚数	健康葉:160, 異常葉:127
学習:検証:テスト	6:2:2
画像サイズ	224×224
バッチサイズ	16
学習回数	240
学習率	0.01



評価方法

- 混同行列をもとに、Accuracy, Precision, Recall, F1を算出
- $$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{FP} + \text{TN} + \text{FN})$$
- $$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$
- $$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$
- $$\text{F1} = (2 * \text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$$

評価に使用する混同行列

		予測	
		異常葉	健康葉
正解	異常葉	True Positive (TP)	False Negative (FN)
	健康葉	False Positive (FP)	True Negative (TN)



各異常検知手法の結果


各異常検知手法の性能比較

	Accuracy	Precision	Recall	F1
PaDiM(WideResNet50)	0.78	0.76	0.83	0.79
PatchCore(WideResNet101)	0.78	0.76	0.83	0.79
Cs-Flow(EfficientNet-B6)	0.81	0.80	0.84	0.82



各手法の特徴まとめ

- PaDiM
 - 葉の端が変色している画像が誤検知しやすい
 - 背景に写りこんでいる物に反応する傾向
- PatchCore
 - 細かい変色の部分を範囲的にであるが、とらえている画像もある
 - 全体的に変色箇所が少ないと誤検知しやすい
- Cs-Flow
 - 異常箇所を広く認識している
 - 変色箇所の小さいものには識別できていない




各手法誤検知例
左:元画像, 中:ground_truth, 右:予測マスク




異常検知手法の結果を組み合わせた手法

- 公開ゼミナールで発表した手法
- 各手法の出力結果から、多数決の異常値の平均値による識別を行う
- PaDiM, PatchCore, Cs-Flowの結果を使用する
- 多数決は、各手法の判別結果をもとに行う
- 異常値平均は、各手法の異常値の平均値で判定する



U-Netによる重み付け手法

- 各異常検知手法で健康葉の特徴抽出, U-Netで異常箇所の特徴抽出のモデル学習
- 異常検知手法からテスト画像のヒートマップ出力, U-Netで異常箇所の予測マスク作成
- ヒートマップをピクセル平均で結合, 予測マスクを重みとして結合
- 異常値を算出し, 予測マスクの作成と異常判定




提案手法概要図



ヒートマップの重み付け


- U-Netの予測マスクをヒートマップに重みとして結合
- 予測マスクのピクセルには, 0~1の値が格納されている
- 重み付けの閾値を0.5とし, 閾値より下のピクセルに予測マスクの値を重みとして乗算する



重み付け概要



予測マスク作成と異常値算出



異常検知手法とU-Net組み合わせ

- 各異常検知手法とU-Netの組み合わせ
 - PD+U-net : PaDiM+U-Net
 - PC+U-net : PatchCore+U-Net
 - CF+U-net : Cs-Flow+U-Net
- 2つの異常検知手法とU-Netの組み合わせ
 - PD+PC+U-net : PaDiM+PatchCore+U-Net
 - PD+CF+U-net : PaDiM+Cs-Flow+U-Net
 - PC+CF+U-net : PatchCore+Cs-Flow+U-Net
- 3つの異常検知手法とU-Netの組み合わせ
 - PD+PC+CF+U-net : PaDiM+PatchCore+Cs-Flow+U-Net



予備審査結果

- 予備審査でのピクセルのAccuracyが以下の通り

ピクセルレベルのAccuracy比較

	Pixel Accuracy
PaDiM	0.77
ParchCore	0.86
Cs-Flow	0.37
U-Net	0.72
PD+U-Net	0.90
PC+U-Net	0.84
CF+U-Net	0.89
PD+PC+U-Net	0.89
PD+CF+U-Net	0.90
PC+CF+U-Net	0.87
PD+PC+CF+U-Net	0.86



ピクセルレベルの性能比較

ピクセルレベルの性能比較

	Accuracy		Precision		Recall		F1	
PaDiM	0.77		0.43		0.63		0.51	
ParchCore	0.86		0.63		0.69		0.66	
Cs-Flow	0.38		0.21		0.84		0.34	
U-Net学習枚数	27枚	127枚	27枚	127枚	27枚	127枚	27枚	127枚
U-Net	0.92	0.90	0.83	0.78	0.72	0.66	0.77	0.72
PD+U-Net	0.90	0.93	0.69	0.78	0.84	0.89	0.76	0.83
PC+U-Net	0.91	0.93	0.74	0.79	0.83	0.88	0.78	0.84
CF+U-Net	0.89	0.93	0.69	0.76	0.80	0.90	0.74	0.83
PD+PC+U-Net	0.91	0.92	0.72	0.72	0.83	0.92	0.77	0.81
PD+CF+U-Net	0.88	0.93	0.66	0.79	0.78	0.90	0.71	0.84
PC+CF+U-Net	0.88	0.92	0.66	0.75	0.79	0.90	0.72	0.82
PD+PC+CF+U-Net	0.86	0.92	0.59	0.74	0.79	0.91	0.68	0.82



各手法の画像レベル精度比較

各手法との性能比較

	Accuracy		Precision		Recall		F1	
PaDiM	0.78		0.76		0.83		0.79	
ParchCore	0.78		0.76		0.83		0.79	
Cs-Flow	0.81		0.80		0.84		0.82	
多数決	0.85		0.86		0.84		0.85	
関連研究	0.53		0.53		0.46		0.49	
U-Net学習枚数	27枚	127枚	27枚	127枚	27枚	127枚	27枚	127枚
PD+U-Net	0.92	0.93	0.96	0.92	0.87	0.94	0.92	0.93
PC+U-Net	0.94	0.94	0.92	0.93	0.97	0.95	0.94	0.94
CF+U-Net	0.90	0.93	0.88	0.93	0.92	0.92	0.90	0.93
PD+PC+U-Net	0.86	0.94	0.82	0.93	0.93	0.94	0.87	0.93
PD+CF+U-Net	0.90	0.93	0.87	0.93	0.95	0.92	0.90	0.93
PC+CF+U-Net	0.84	0.94	0.77	0.94	0.97	0.93	0.86	0.94
PD+PC+CF+U-Net	0.82	0.94	0.77	0.94	0.90	0.95	0.83	0.94



提案手法の正常検知例

健康葉

元画像 ground_truth 予測マスク

- 枝などの移りこみが少ないものに正常に検知できていた
- 異常でない部分を正確にとらえられている

異常葉

元画像 ground_truth 予測マスク

- 細かい異常箇所を正確にとらえることができていた
- 変色箇所が広い画像にも対応できている



提案手法の誤検知例

健康葉



- 元画像
- ground_truth
- 予測マスク
- 背景や映り込んでいる枝、他の葉、といったものに反応してしまう

異常葉



- 元画像
- ground_truth
- 予測マスク
- 異常箇所を正確にとらえることはできている
- 異常箇所が少なすぎると誤検知



まとめ

- 異常検知手法とU-Netを組み合わせることで、異常検知手法単一の画像レベルとピクセルレベルでの識別精度の向上を上回ることができた
- 背景の枝やほかの映り込んだ葉に強く反応しまう課題が残った
- U-Netの枚数を増やしたことで指標が全体的に向上することが確認できた
- 複雑な背景の画像で病害葉の識別精度が向上すればドローンによる植物管理に活用ができ、農業従事者の負担の軽減が期待できる



今後の展望

- 今回は、ヒートマップの結合に平均という方法を用いたが、手法にそれぞれ重みを付けることで手法の最適化を検討
- 背景処理をすることで、注目領域を絞り、さらなる精度の向上
- U-Netの学習条件による精度の変化についての検証



実績

- FIT2024(第23回情報科学技術フォーラム)
「PaDiMを用いたブドウ葉の健康状態識別システムの提案」
H-058, 241-242, 2024年9月6日, 広島工業大学で発表
- 情報処理学会 第87回全国大会
「複数の異常検知手法とU-Netを組み合わせたブドウ葉の健康状態識別手法」
2025年3月12日, 立命館大学で発表予定



参考文献

- [1]山口幹生, AnoGANを用いた異常ブドウ葉検出手法の提案, 岩手県立大学ソフトウェア情報学部卒業論文, 2022年3月
- [2]伏屋 博貴, PaDiMを用いた異常ブドウ葉検出の検討, 岩手県立大学ソフトウェア情報学部卒業論文, 2023
- [3]Joa Palulo,Schwarz,Santiago Romani et al,Color-Aware Two-Branch DCNN for Efficient Plant Disease Classification, Mendel2022,2022
- [4]Thomas Defard et al, PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization, <https://arxiv.org/pdf/2011.08785.pdf>,2020
- [5] Karsten Roth et al, Towards Total Recall in Industrial Anomaly Detection, CVPR,2022
- [6] Marco Rudolph, Tom Wehrbein, et al., Fully Convolutional Cross-Scale-Flows for Image-based Defect Detection,WACV,2022,
- [7] Olaf Ronneberger,Philipp Fischer,Thomas Brox,U-Net:Convolutional Networks for Biomedical Image Segmentation,MiCCAI,2015

