

AI時代の画像検査 構造的／論理的異常検知技術の動向と研究事例

～ 古くて新しい課題を俯瞰し, 再考する ～

中京大学 工学部
橋本 学

mana@isl.sist.chukyo-u.ac.jp



講演資料等



公開画像DB

Advanced Sensing & Machine Intelligence Group,
Chukyo University

本日の話題

1. イントロダクション

異常検知(外観検査)の課題再考, 現況整理

2. 構造的異常検知

- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

3. 論理的異常検知

- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

4. 雑感

画像データセット, 残された課題, これからの課題

本日の話題

1. イントロダクション

異常検知(外観検査)の課題再考, 現況整理

2. 構造的異常検知

- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

3. 論理的異常検知


- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

4. 雑感

残された課題, これからの課題, 画像データセット

画像処理による外観検査(異常検知)……古くて新しい魅力的な課題

- 外観検査は, 無くしたいが無くならない工程の代表例




1990年頃の検査装置(出典:三菱電機技報)

- いまだに残っている基本課題


1. 要求精度が桁違いに厳しい(見逃しはほぼゼロ, 過検出1日1回以下など)
2. 現場での異常サンプルは入手困難

“正常” と “異常” の関係

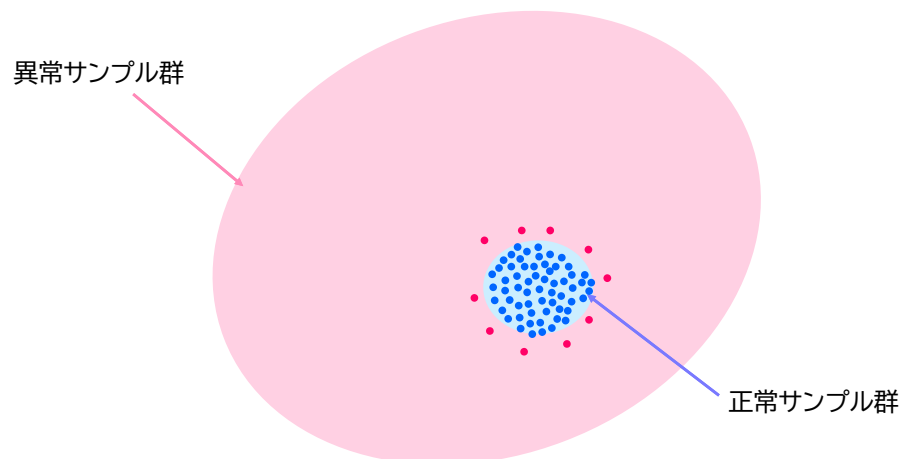
異常と正常はどのように分布しているか？（仮定）




異常と正常の分布（想像①）



異常と正常の分布（想像②）

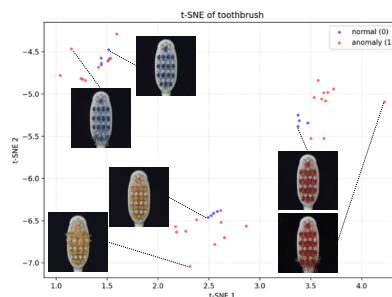


異常と正常の分布（想像③）



現実のデータ分布


t-SNEで可視化（Toothbrush）



色によって分布が分かれている. しかし, 正常／異常の区別はやや困難

現実のデータ分布


t-SNEで可視化 (Screw)




画像内のネジが回転 → 環状に分布. しかし, 正常／異常の区別は困難

そもそも, 可視化手法は有効か？


PCA, t-SNE, UMAPの比較 (Screw)



PCA



t-SNE




UMAP

可視化の手法によって結果が異なる

そもそも、可視化手法は有効か？

t-SNEパラメータ



与える乱数によっても結果が揺らぐことがある

異常検知の課題

基本課題

1. 要求精度が桁違いに厳しい(見逃しはほぼゼロ, 過検出1日1回以下など)
2. 現場での異常サンプルは入手困難



機械学習的に解くならば……

考えられるアプローチ

1. リアルで自然な異常サンプルを人工的に作る
2. 正常のみを学習する手法を作る

その他の課題

1. ローカル処理系はどこまで高級化できるか？すべきか？
2. 解像度 v.s. 処理時間 ……半導体製造などでは高解像度画像が必須

異常検知の分類

構造的異常検知 & 論理的異常検知

- **構造的異常**: 対象の物理的な構造が変化して生じる(キズやへこみ)
- **論理的異常**: 対象の個数や配置などが論理的なルールから逸脱して生じる




- どちらの異常検知も従来からある課題
- IJCV2022で異常検知が2種類に分類されてから, 論理的異常に注目が集まってきた

[1] P. Bergmann, et al. : "Beyond dents and scratches: Logical constraints in unsupervised anomaly detection and localization", International Journal of Computer Vision, Vol.130, pp.947-969, 2022.

MVTec ADに対する異常検知性能の動向

- データセット公開時期
 - 2019 年発表(CVPR2019)
- 性能の動向
 - 発表から2~3年で, AUC が 86% から 98% まで上昇
 - 最近では, GLASS が 99.3% を記録



構造的異常検知 世の中の主要技術

1. 正常サンプル活用型

1. 画像再構成ベース

1. RIAD (PR2021)
2. DDAD (DAGM2024)

2. 特徴抽出ベース

1. 距離ベース PaDiM (ICPR2021)
2. 距離ベース PatchCore (CVPR2022)
3. 生徒-教師モデルベース U-Student (CVPR2020)
4. 生徒-教師モデルベース EfficientAD (WACV2024)

2. 人工異常生成型

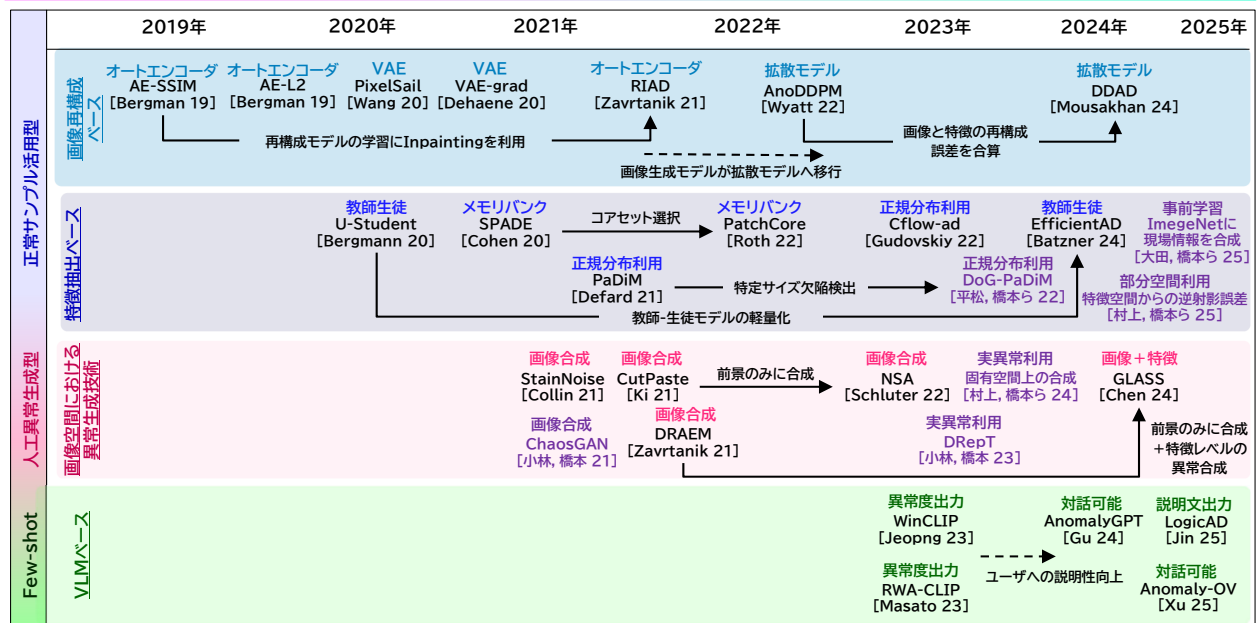
1. 画像空間での合成

1. StainNoise (ICPR2021)
2. CutPaste (CVPR2021)
3. DRAEM (ICCV2021)

2. 画像空間と特徴空間での合成

1. GLASS (ECCV2024)

構造的異常検知 研究マップ (MVTecADデータセット公開以降)



Advanced Sensing and Machine Intelligence, Chukyo Univ.

画像応用技術専門委員会 研究会 Jan. 16, 2026

21

画像再構成ベース

1. RIAD (PR2021)
2. DDAD (DAGM2024)




正常画像のみで学習された再構成モデルに異常画像が入力されたときには、うまく再構成できないはずという性質を利用

DDAD: 画像レベルと特徴レベルの再構成誤差の組合せに基づく異常検知

- アイデア: 異常と正常の差異には2種類ある. 画像レベルの異常度マップは局所的, 特徴レベルの異常度マップはやや大局的(広範囲). これらを組み合わせて, 両方に対応させる.


Step1 画像レベルの異常度マップ算出

正常画像の再構成が得意な拡散モデルを作り, 被検査画像と再構成画像の差を画像レベルの異常度マップとして出力



Step2 特徴レベルの異常度マップ算出

被検査画像の特徴量と拡散モデルが再構成した画像の特徴量の誤差を, 特徴レベルの異常度マップとして計算
最終的には, Step1の画像レベル異常度マップと, Step2の特徴レベルの異常度マップ組み合わせて判定する.

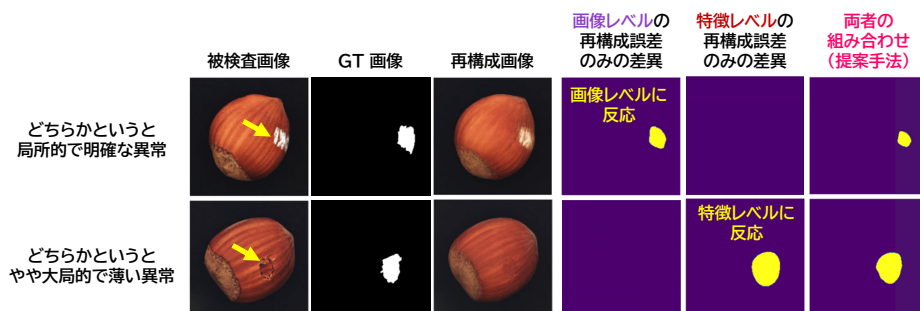


DDAD: 画像レベルと特徴レベルの再構成誤差の組合せに基づく異常検知

- 実験結果: 当時のSOTA手法 SimpleNet と同等の異常検出精度 98.1% を達成

実験結果

画像レベルと, 特徴レベルの異常度マップを組み合わせることで, 片方だけでは検出できない異常を検出可能




異常領域の検出精度(画素レベルの AUROC で評価, MVTec AD の平均値)

PatchCore: 98.1%, SimpleNet: 98.1% → DDAD: 98.1%


特徴抽出ベース

1. 距離ベース PaDiM (ICPR2021)
2. 距離ベース PatchCore (CVPR2022)
3. 生徒-教師モデルベース U-Student (CVPR2020)
4. 生徒-教師モデルベース EfficientAD (WACV2024)

1&2 入力と正常分布との距離が異常度

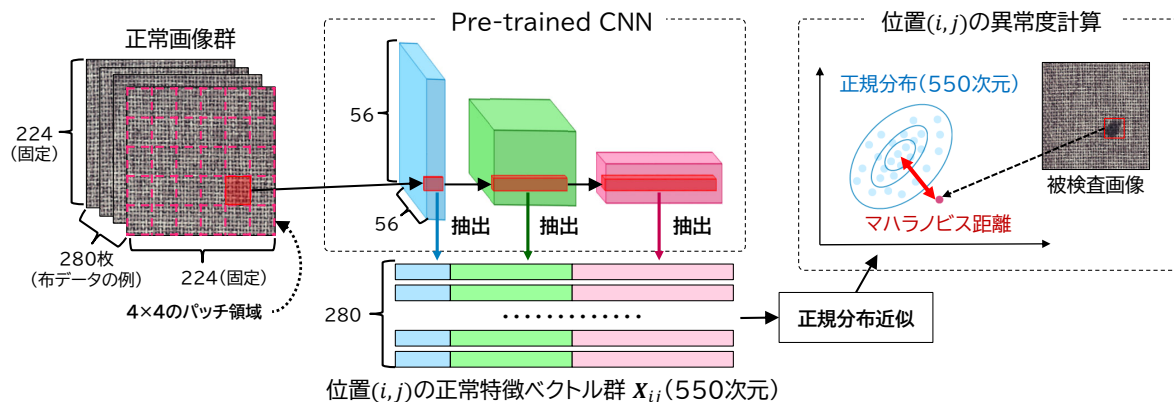


3&4 生徒-教師モデルの出力差が異常度



PaDiM: 正常サンプルの正規分布近似に基づく異常検知


- 目的: 現場でのニューラルネットワーク学習を必要としない検査手法の提案
 - ニューラルネットワークを検査に適用する場合は, 学習コストの高いことが課題
- アイデア
 1. 大規模一般データを事前学習した CNN を特徴抽出器として利用
 2. 正常サンプルのばらつきを正規分布で近似して利用



PaDiM: 正常サンプルの正規分布近似に基づく異常検知

- 実験結果: 当時のSOTA手法 P-SVDD よりも高い異常検出精度 **97.5%** を達成

実験結果



異常領域の検出精度(画素レベルの AUROC で評価, MVTec AD の平均値)

SSIM-AE: 86.2%, P-SVDD: 95.7% → PaDiM: **97.5%**

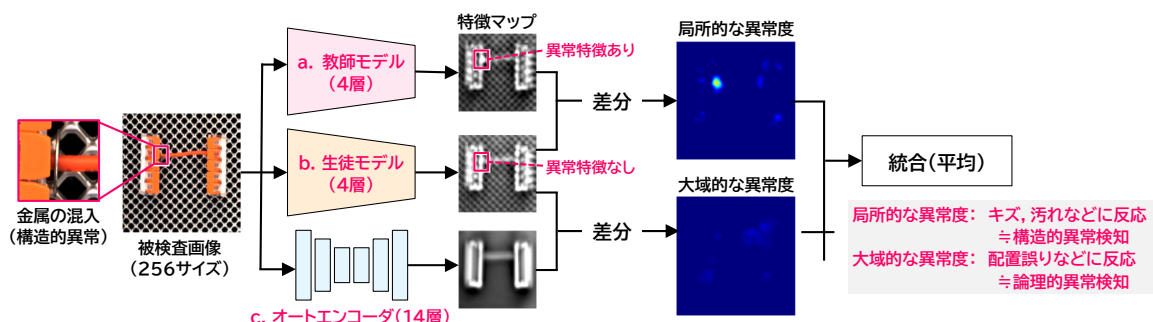
【文献】 T. Defard, et al., PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization, ICPR2021.

Efficient AD: 軽量生徒-教師モデルの改良版

- 目的: 生徒-教師モデルの計算コストの改善と, 大域的異常検知(≒論理的異常検知)への拡張
- アイデア: 生徒-教師モデル**両方**の軽量化と, **オートエンコーダモデル**の追加

手法概要

- 学習時: 以下の3種類のモデルを学習
 - 事前学習済みCNNの特徴マップを真値として, ImageNetを用いて**教師モデル**(軽量4層)を学習 (**汎用的に特徴抽出可能**)
 - 教師モデルの出力を真値として, **正常画像を用いて生徒モデル**(軽量4層)を学習 (**正常画像の局所の特徴抽出が得意**)
 - 教師モデルの出力を真値として, **正常画像を用いてオートエンコーダ**(14層)を学習 (**正常画像の大域的特徴抽出が得意**)
- 検査時: 被検査画像を3種のモデルに入力した際の出力差を異常度とする。(モデルbとcは, 異常画像の特徴抽出に失敗するため)




Efficient AD: 軽量生徒-教師モデルの改良版

- 実験結果: GPU環境下において, **614fps** の処理時間で検査精度 **98.8 %** を達成

検査速度の比較結果

GPU(RTX A6000) では, 被検査画像 1枚(256サイズ)あたり最速 2.2 ms で検査可能



異常領域の検出精度(画素レベルの AUROC で評価, MVTec AD の平均値)

U-Student: 93.9%, PatchCore: 98.1% → Efficient AD-S: **98.8%**

【文献】 K. Batzner, et al., EfficientAD: Accurate Visual Anomaly Detection at Millisecond-Level Latencies, WACV2024.


DRAEM: 異常除去と異常領域の推定学習に基づく異常検知

- 目的: 人工異常画像生成と画像再構成モデルを組み合わせる, 異常領域を推定
- アイデア: 異常画像を正常画像に再構成するモデル, 異常領域を推定するモデルを学習

人工異常画像の生成



モデルの学習と検査




1. 画像再構成モデルには異常を正常に復元する能力, 異常領域推定モデルには異常領域を検出する能力を学習させる.
2. 検査時は, 被検査画像を学習済の画像再構成モデルに入力することによって, 最終的に異常領域が出力される.

DRAEM: 異常除去と異常領域の推定学習に基づく異常検知

- 実験結果: 当時のSOTA手法 PaDiM よりも高い異常検出精度 **98.0%** を達成

実験結果

DRAEM は, 従来手法よりも高精度に異常領域を検出可能



異常領域の検出精度(画素レベルの AUROC で評価, MVTec AD の平均値)

U-Student: 93.9%, PaDiM: 97.5% → DRAEM: **98.0%**

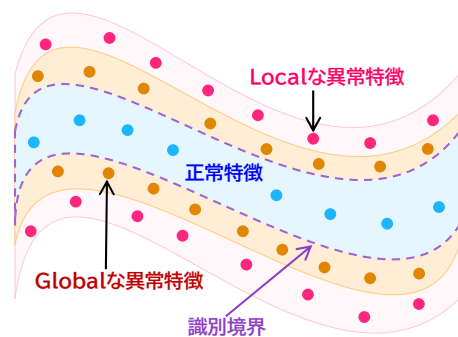
【文献】 V. Zavrtanik, et al., Draem-a discriminatively trained reconstruction embedding for surface anomaly detection, ICCV2021.

GLASS: 人工異常特徴と正常特徴の識別境界の学習に基づく手法

- 目的: 正常領域に似た異常も高精度に検出可能な手法の提案
- 仮説: 正常特徴量は, 多様体分布もしくは超球分布となり, その周辺に2種の異常特徴が分布
 - **Globalな異常**: 正常分布からわずかに離れている異常特徴
 - **Localな異常**: 正常分布から大きく離れている異常特徴


多様体分布仮説

- 正常特徴は多様体を成すように分布
- 正常特徴の周辺に異常特徴が分布



超球分布仮説

- 正常特徴は超球の中心に分布
- 超球中心から遠ざかるように異常特徴が分布




GLASS: 人工異常特徴と正常特徴の識別境界の学習に基づく手法

アイデア: 画像レベルの局所的な異常生成に加え, 正常特徴付近に異常特徴を外挿して異常生成

異常生成法として GAS と LAS の2つを提案


GAS: Global Anomaly Synthesis (特徴レベルで異常合成)

特徴量全体にノイズを付与し, さらに法線方向に摂動させて異常特徴を外挿



LAS: Local Anomaly Synthesis (画像レベルで局所的に異常合成)

正常画像の前景に人工欠陥を合成して異常画像を生成




GLASS: 人工異常特徴と正常特徴との識別境界の学習に基づく異常検知

- 実験結果: 当時のSOTA手法 RD++ よりも高い異常検出精度 99.3% を達成

実験結果

GLASS は, 正常領域とのコントラストが弱い異常領域を高精度に検出可能



異常領域の検出精度(画素レベルの AUROC で評価, MVTec AD の平均値)

SimpleNet: 98.1%, RD++: 98.3% → GLASS: 99.3%

当研究室での取り組み事例

■ 正常サンプル活用型

1. DoG-PaDiM (CASE2024)
2. 特徴量の正常部分空間からの逆射影誤差に基づく異常検知技術 (JSPE誌2025)
3. ImageNetと現場正常画像の周波数合成に基づく特徴抽出器の事前学習 (SSII2025)

■ 人工異常生成型

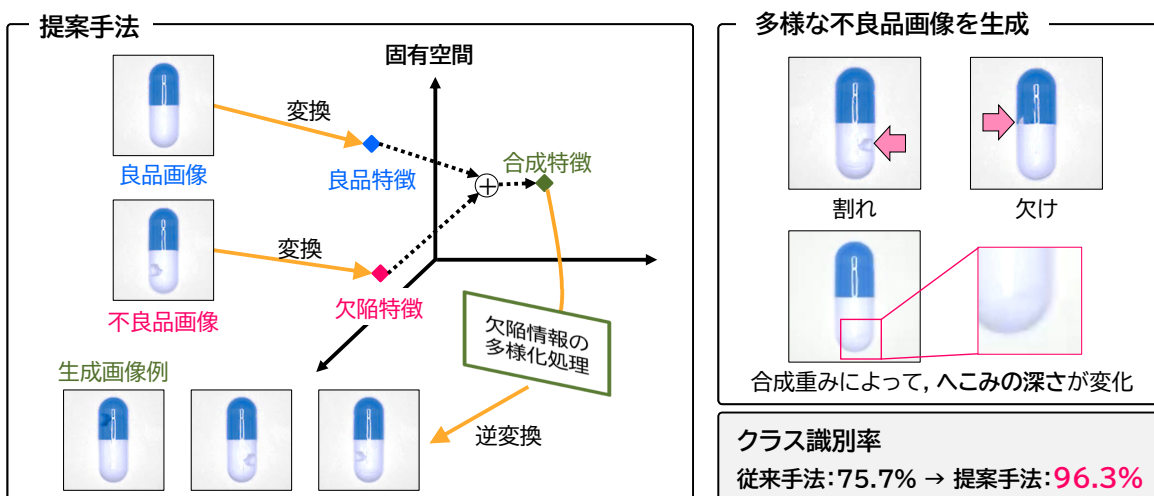
1. 固有空間における異常情報合成 (JSPE誌2024)
2. ChaosGAN「未知の異常」をランダム画像で表現 (ISVC2021)
3. DRepT (IJCNN2023)

■ そのほかの異常検知関連研究

1. キズ発生前後のペア画像を用いた異常検知 (JSPE誌2021)
2. 画像変換に基づく異なるカメラ間のギャップ低減 (JSPE誌2025)
3. AMAR (MIRU2025)

固有空間における異常情報合成：少量の実異常を用いた自然な異常画像生成

- 目的：高精度な識別器を獲得するための自然な不良品画像の生成
- アイデア：特徴空間上で、良品サンプルと少量の不良品サンプルを合成し、画像に復元



【文献】村上, 平松, 小林, 秋月, 橋本, 固有空間における情報合成に基づく高リアリティ不良品画像生成, 精密工学会誌, Vol.90, No.8, pp.662-668, 2024.

特徴空間における合成の考え方

- 固有空間での合成時に, さまざまな工夫を加えて, バリエーションを増やす。

$$\mathbf{x}_{\text{output}} = \bar{\mathbf{x}} + \sum_{i=1}^M s_{\text{good}(i)} \mathbf{a}_i + W \sum_{i=M+1}^{N-1} s_{\text{bad}(i)} \mathbf{a}_i$$

工夫① 重みをつける

工夫② いったん画像空間に戻して幾何変換を施し, 固有空間に戻す




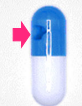





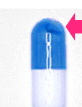








欠陥特徴ベクトル $\sum_{i=M+1}^{N-1} s_{\text{bad}(i)} \mathbf{a}_i$ → 欠陥情報 → 変換後の欠陥情報

【文献】

村上, 平松, 小林, 秋月, 橋本, 固有空間における実欠陥情報の合成に基づく異常検知の高精度化, ビジョン技術の実利用ワークショップ(VIEW2023), 2023.

実験結果

- 実良品 300 枚, 実不良品 60 枚に対して提案手法を適用

	データセットの画像		生成画像			
	実良品画像	実不良品画像	強度の多様化	幾何学的な多様化		
			重み係数	上下の鏡映	左右の鏡映	縮小
割れ						
へこみ						
欠け						

※ 実際には濃淡情報のみで処理(カラーは不使用)

実験結果

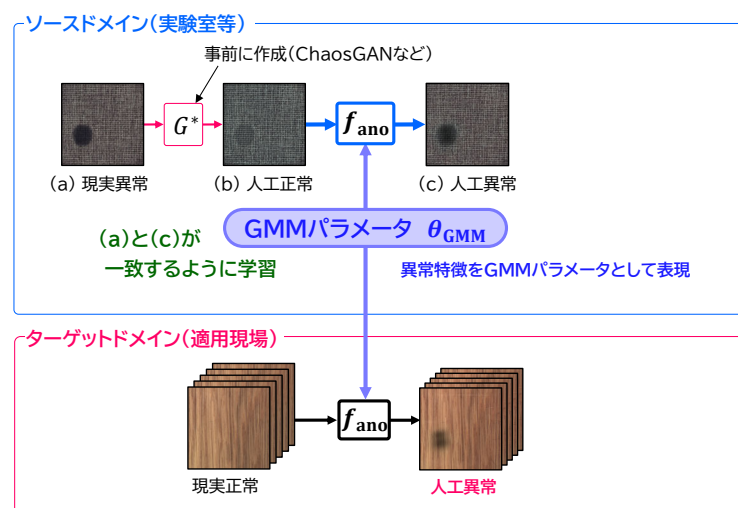
		識別結果	
		良品	不良品
真値	良品 300枚	97% → 99.4%	3% → 0.6%
	不良品 300枚	45.7% → 6.9%	54.3% → 93.1%

不均衡データ(良品300枚, 不良品60枚)
提案手法(良品300枚, 不良品60枚, 生成240枚)


見逃し率が 6.9%
正解率が96.3% に改善

DRepT: 実欠陥特徴をGMMパラメータとして表現

- ソース側で模擬的な異常情報を生成し、ターゲット側の正常画像に付加
- 異常情報の表現 → **GMMパラメータを利用**



DRepT: 実験結果



異常検出性能 AUC [%]

カテゴリ	基本型	提案手法
Carpet	62.2	98.0
Leather	92.8	100.0
Tile	92.6	99.7
Wood	81.1	96.7
Mean	82.2	98.6


異常表現としてGMMパラメータは有効

DRepT: 実験結果

従来のデータ拡張手法との性能比較(Image/Pixel AUROC)

	StainNoise	CutPaste	DRAEM	提案手法
Carpet	85.3 / 90.7	72.2 / 69.1	56.9 / 86.5	98.0 / 93.7
Leather	93.8 / 87.8	99.7 / 95.1	98.2 / 86.5	100.0 / 97.5
Tile	94.4 / 95.8	99.6 / 96.2	65.0 / 76.0	99.7 / 97.8
Wood	97.1 / 84.6	97.6 / 85.4	79.7 / 87.6	96.7 / 85.2

DRepT: デモシステム




AMAR: 異常度マップ補正モデルを用いた異常領域検出の高精度化

- 目的: 異常検知手法が出力する異常度マップが実際の異常領域と整合しない問題を改善
- アイデア: 異常検知手法の後段に補正モデル(AMAR)を追加し, 異常度マップをリファイン

手法概要

1. 学習時は, 擬似異常画像を用いて補正モデル(AMAR: Anomaly-map Refiner)を学習
 - a. 正常画像に擬似異常を付与し, その擬似異常画像を異常検知手法に入力し, 異常度マップを出力
 - b. 擬似異常画像と異常度マップを **AMAR** に入力し, 補正結果を出力(補正結果とGTの誤差を最小化)
2. 検査時は, 被検査画像と異常検知手法が出力した異常度マップを **AMAR** に入力し, 補正結果を出力




AMAR: 実験結果①

- 実験結果: AMAR は誤判定傾向の異なる 2つの異常検知手法(f-AnoGAN, PaDiM)の画素レベルの異常検出精度を最大で **0.29** 改善

実験結果

異常度マップ補正モデル(AMAR)は, 従来手法の出力を GT と整合するように補正可能




異常領域の検出精度(画素レベルの F 値で評価, MVTec AD の平均値)

比較① f-AnoGAN: 0.23% → AMAR 適用: **0.56**, 比較② PaDiM: 0.56 → AMAR 適用: **0.59**

AMAR: 実験結果②

- 実験結果: AMAR は, f-AnoGANやPatchCore, DRAEMなど多様な異常検知手法に対しても汎用的な補正能力を示す.



【文献】村上尚生, 平松直人, 小林大起, 秋月秀一, 橋本学, 誤判定傾向の学習に基づく外観検査の汎用高精度化のための出力リファインモデルの提案, ビジョン技術の実利用ワークショップ(VIEW2025).

Advanced Sensing and Machine Intelligence, Chukyo Univ.

画像応用技術専門委員会 研究会 Jan. 16, 2026

45

本日の話題

1. イントロダクション

異常検知(外観検査)の課題再考, 現況整理

2. 構造的異常検知

- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

3. 論理的異常検知

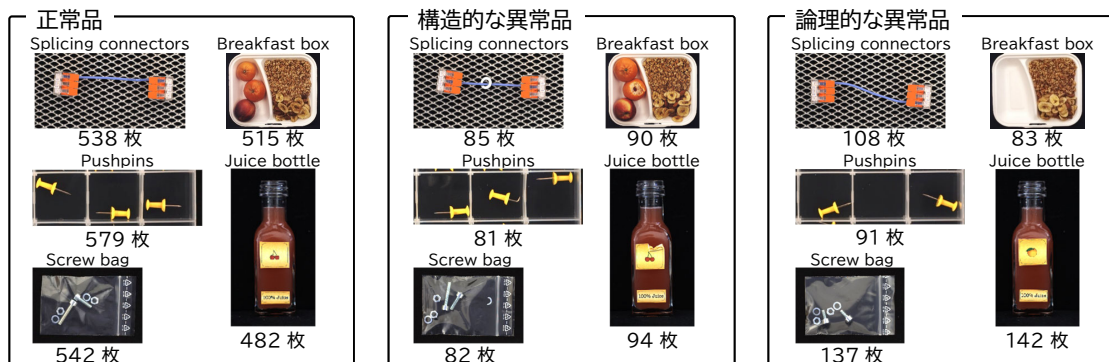
- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

4. 雑感

残された課題, これからの課題, 画像データセット

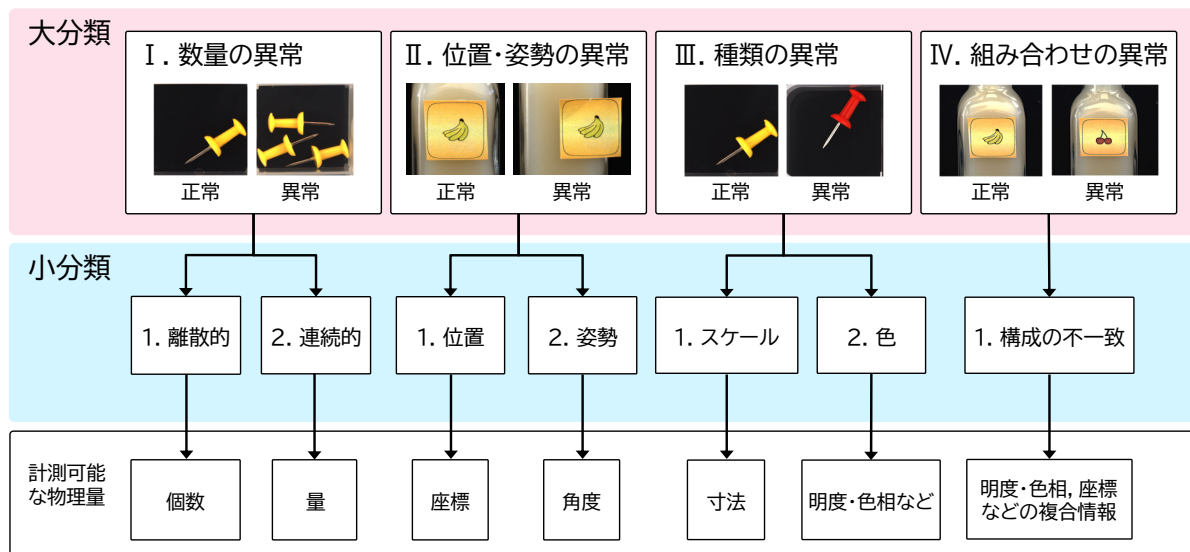
論理的異常検知: MVTec LOCO AD

- データセット公開時期: 2022 年公開(IJCV 2022)
- データセットの構成
 - 5 種類の産業製品で構成されている。(正常 2656 枚, 異常 993 枚)
- 異常の種類
 - 構造的異常: 切り傷や凹み, 変色などの検査対象の形状や表面状態に生じる異常
 - 論理的異常: 検査対象の数量の誤り, 部品の欠如など, ルール違反によって生じる異常




【文献】P. Bergmann, et al. "Beyond dents and scratches: Logical constraints in unsupervised anomaly detection and localization", International Journal of Computer Vision, Vol.130, pp.947-969, 2022.

論理的異常の分類



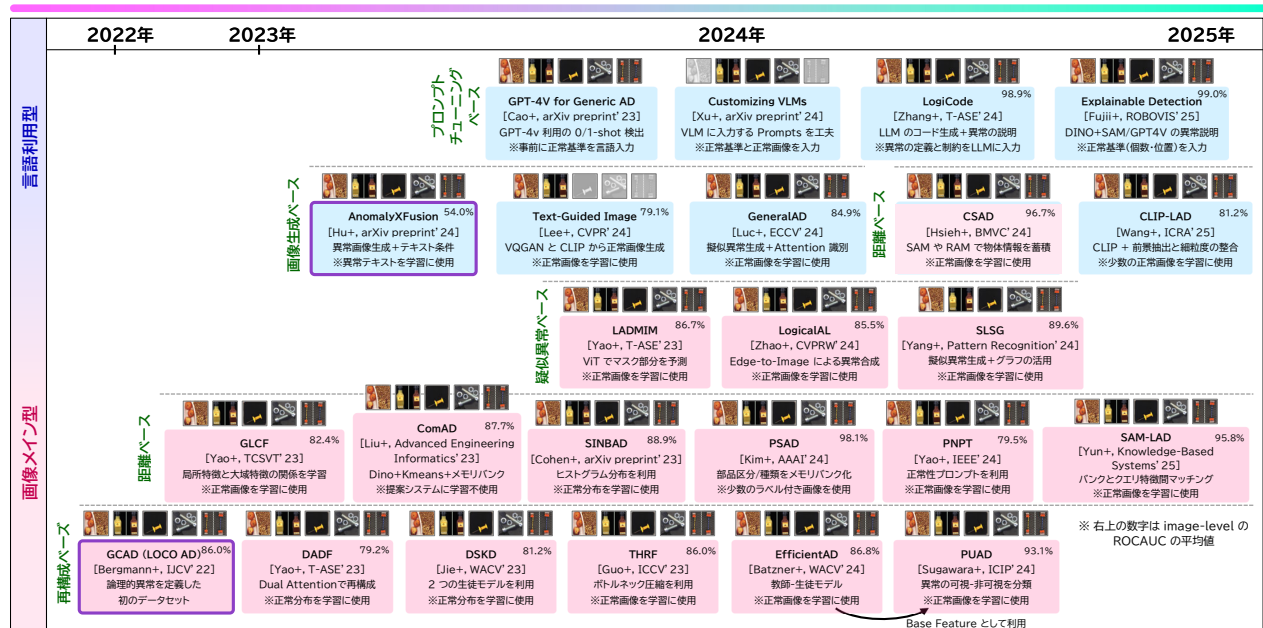
MVTec LOCO AD に対する異常検知性能の動向

- データセット公開時期
 - 2022 年発表(IJCV2022)
- 性能の動向
 - 公開当初は, AUC が 80%後半~90%前半
 - 最近では, PSAD が AUC 98.1% を記録



サーベイマップ (Logical AD)

...評価に使用したカテゴリ, 使用していない場合は白抜き()で表示, ...データセットと併せて提案している手法



論理的異常検知 世の中の主要技術

1. 画像メイン型

1. 領域セグメンテーション活用

1. ComAD (Advanced Engineering Informatics2023)
2. CSAD (BMVC2024)
3. PSAD (AAAI2024)

2. 画像特徴量ベース

1. EfficientAD (WACV2024)……構造的異常検知手法でもある
2. SINBAD (TMLR2024)


2. 言語利用型

1. Logicode (IEEE2024)

領域セグメンテーション活用

1. ComAD (Advanced Engineering Informatics2023)
2. CSAD (BMVC2024)
3. PSAD (AAAI2024)


“領域”単位で情報を扱う




入力画像



セグメンテーション
マップ



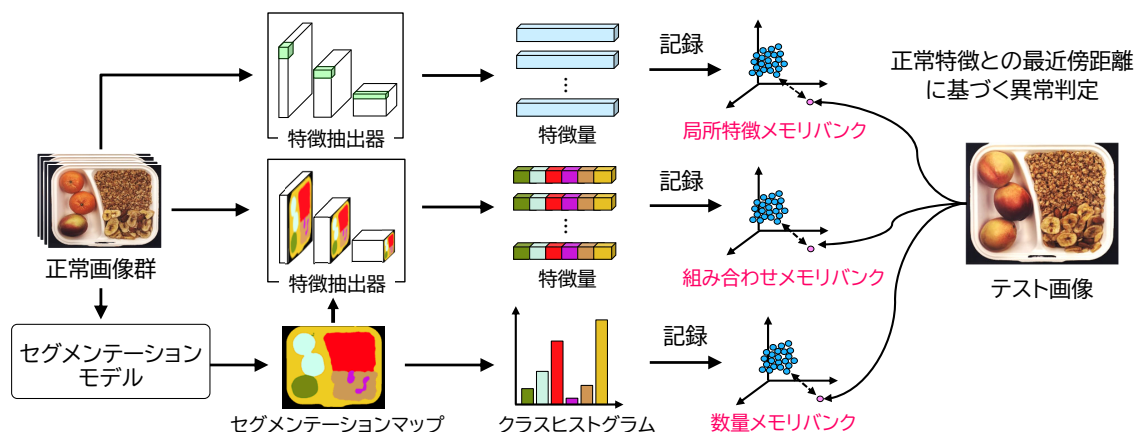
セグメント特徴を
抽出・記録



正常特徴・分布からの
距離に基づく異常判定

PSAD: 領域セグメントの分布・構成分析に基づく論理的異常検知



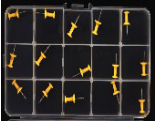

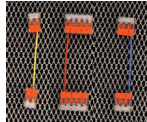
- 課題: 従来の異常検知モデルは、主に局所的な画像特徴を利用しており、部品単位の検査ができないため、部品の数や組み合わせなどの論理的異常の検出が困難
- アイデア: 領域セグメンテーションに基づいて、局所特徴・組み合わせ・数量の3つの観点から異常を判定



PSAD: 領域セグメントの分布・構成分析に基づく論理的異常検知

- 実験結果: 論理的異常カテゴリにおいて, AUROC 98.1% を達成(2024年時点のSoTA)

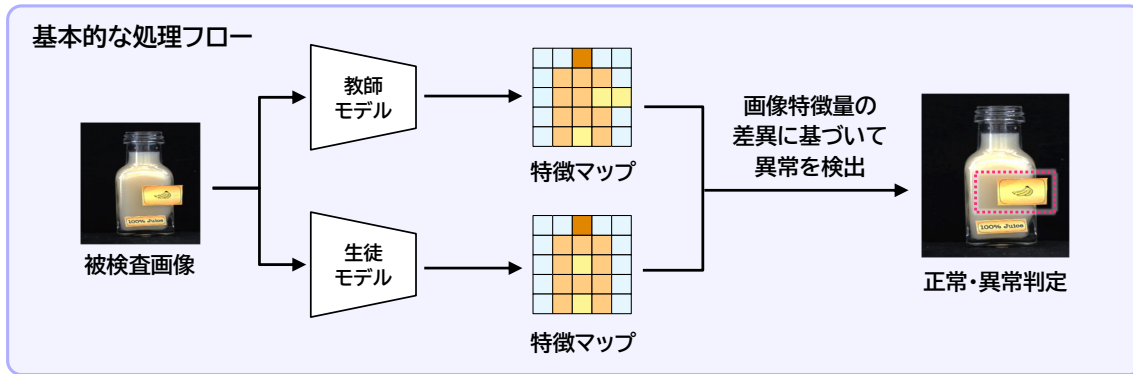
MVTec LOCO ADを用いた比較実験

	Image-AUROC の比較結果				
					
SINBAD	96.5	96.6	83.4	78.6	89.3
ComAD	91.1	95.5	95.7	71.9	93.3
CSAD	94.4	94.9	99.5	99.9	94.8
PSAD	100	99.1	100	93.3	91.9

【文献】 Soopil Kim, et al. Few Shot Part Segmentation Reveals Compositional Logic for Industrial Anomaly Detection, AAAI, 2024.

画像特徴量ベース

1. EfficientAD (WACV2024) ……構造的異常検知手法でもある
2. SINBAD (TMLR2024)

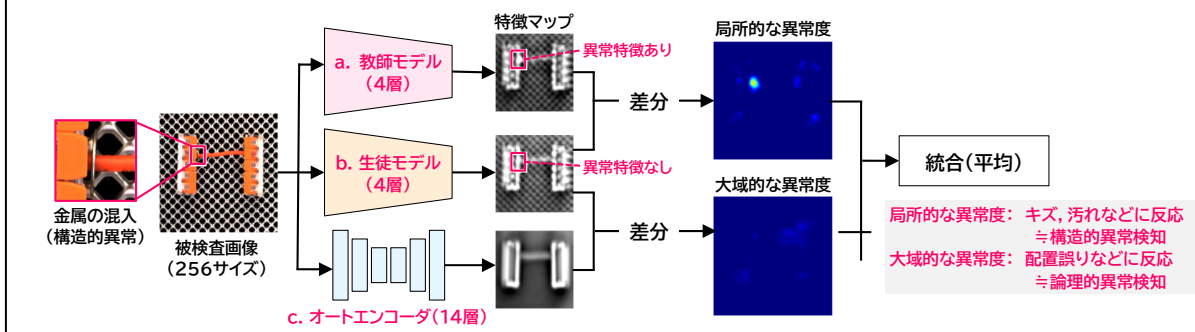


(再掲) Efficient AD: 軽量生徒-教師モデルの改良版

- 目的: 生徒-教師モデルの計算コストの改善と, 大域的異常検知(≡論理的異常検知)への拡張
- アイデア: 生徒・教師モデル**両方**の軽量化と, **オートエンコーダモデル**の追加

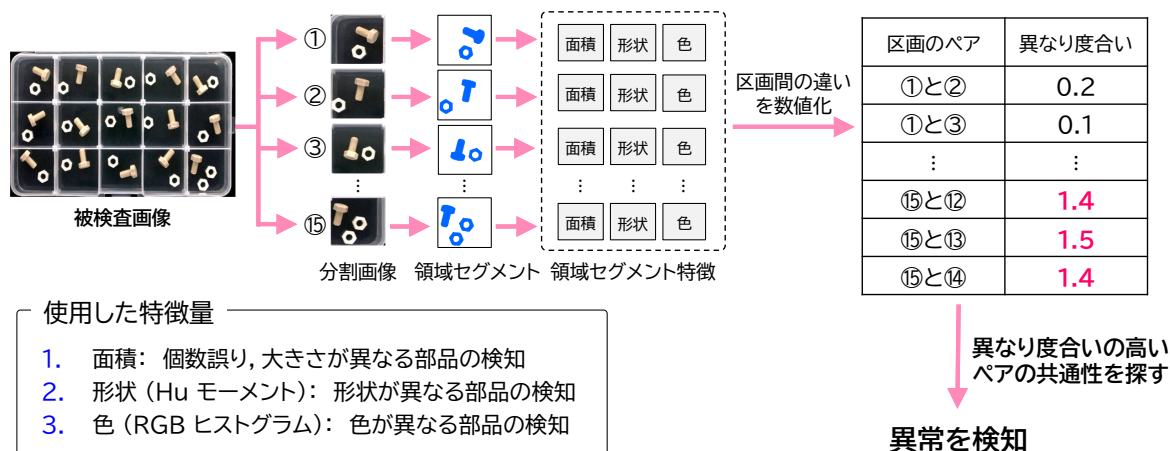
手法概要

1. 学習時: 以下の3種類のモデルを学習
 - a. 事前学習済みCNNの特徴マップを真値として, ImageNetを用いて**教師モデル**(軽量4層)を学習 (**汎用的に特徴抽出可能**)
 - b. 教師モデルの出力を真値として, **正常画像を用いて生徒モデル**(軽量4層)を学習 (**正常画像の局所の特徴抽出が得意**)
 - c. 教師モデルの出力を真値として, **正常画像を用いてオートエンコーダ**(14層)を学習 (**正常画像の大域的特徴抽出が得意**)
2. 検査時: 被検査画像を3種のモデルに入力した際の出力差を異常度とする. (モデルbとcは, 異常画像の特徴抽出に失敗するため)



RSBAD: 領域セグメント間の相互類似性に着目した論理的異常検知

- 目的: 人間なら, ぱっとみて違和感を感じる → 被検査画像のみから異常を検出
- アイデア: 2区画ずつ比較して, 「他とは異なる区画」を異常として自動的に検知



Tomohiro Yamada, Naoki Murakami, Naoto Hiramatsu, Hiroki Kobayashi, Shuichi Akizuki, Manabu Hashimoto, Logical Anomaly Detection based on Relative Similarity Analysis of Region Segments, International Workshop on Advanced Image Technology 2026 (IWAIT2026), 2026/1/12.

Advanced Sensing and Machine Intelligence, Chukyo Univ.

画像応用技術専門委員会 研究会 Jan. 16, 2026

57

RSBAD: 実験方法

- 目的
提案手法による, 物品種類や個数に関する検知性能を評価
- 実験条件
MVTec LOCO AD プッシュピン + 自作データセットを使用



公開データセット (MVTec LOCO AD)
プッシュピン



自作データセット
コネクタ



自作データセット
ボルト・ナット

RSBAD: 実験結果① ……検出された異常の例

データセット	公開データセット(MVTec LOCO AD)		自作データセット	
対象部品	プッシュピン		コネクタ	ボルト・ナット
被検査画像				
正解				
検出結果				

提案手法は、他とは異なる区画を的確に検出できている

RSBAD: 実験結果② ……従来手法との比較

従来手法との異常検知性能の比較

良品学習の要否		必要	必要	必要	必要	不要
	比較手法	ComAD	EfficientAD	CSAD	PSAD	提案手法
公開データ	プッシュピン	64.7	56.2	72.5	59.3	89.6
自作データ	コネクタ	66.6	81.9	88.3	58.3	98.0
	ボルト・ナット	65.9	69.2	74.3	45.3	95.4
平均		65.7	69.1	78.4	54.3	94.3

- 提案手法(94.3%)は、事前の良品学習が必要な従来手法である ComAD(65.7%), EfficientAD(69.1%), CSAD(78.4%), PSAD(54.3%) より高性能

本日の話題

1. イントロダクション

異常検知(外観検査)の課題再考, 現況整理

2. 構造的異常検知

- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

3. 論理的異常検知

- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

4. 雑感




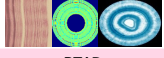
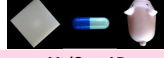


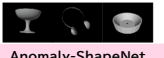



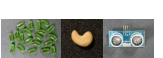
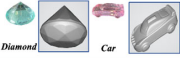


画像データセット, 残された課題, これからの課題

異常検知分野の画像データセット

データセット サーバイ



などの画像は提供しているデータベース内の検査画像の例

	2019	2021	2022	2023	2024	2025
論理的異常のデータセット			 MVtec LOCO AD [Bergmann+, IJCV' 22] MVtec Software 社が公開している論理的異常に焦点を当てた工業製品	 CAD-SD [Liu+, arXiv' 23] ComAD フレームワークの評価に使用されたボルト製品	 VAD [Baitieva+, CVPR' 24] valeo社が公開しているルールの違反と物理的な異常に関する圧電素子部品	
		 BTAD [Mishra+, arXiv' 21] BeanTech 社が公開しているテクスチャ異常に焦点を当てた工業製品				 MulSen-AD [Li+, CVPR' 25] RGB・赤外線・3次元点群を統合した初の工業製品データベース
		 MVtecAD 3D [Bergmann+, arXiv' 21] MVtec Software 社が公開している工業製品の3次元点群	 Eyecandies [Bonfiglioli+, ACCV' 22] Eyecan.aiが公開している3Dモデリングとレンダリングによる合成菓子製品		 Anomaly-ShapeNet [Li+, CVPR' 24] ShapeNetの3Dモデルを基に、人工的に異常を付与した合成3次元点群	 MVtec AD2 [Heckler-Kram+, arXiv' 25] MVtec Software 社が提供しているCVPR2025のコンテスト用の工業製品
	 MVtec AD [Bergmann+, CVPR' 19] MVtec Software 社が公開している多様な工業製品	 MPDD [Jezek+, ICUMT' 21] 異常検知手法のベンチマークを目的とした工業用金属部品	 VisA [Zou+, arXiv' 22] Amazon 社が提供する複数の検査環境を想定した工業製品	 Real3D-AD [Liu+, NeurIPS' 23] 中山大學およびM-3LABによって構築された12種類の工業製品の3次元点群	 BrokenChairs-180K [Bhunia+, CVPR' 24] エディンバラ大学の研究チームVICOが公開している多様な椅子製品	 MANTA [Fan+, CVPR' 25] 北京大学・上海人工知能実験室が公開している複数視点で撮影された工業製品

Advanced Sensing and Machine Intelligence, Chukyo Univ.

画像応用技術専門委員会 研究会 Jan. 16, 2026

63



異常検知関係の画像データベース(公開中)

- 異常検知 実験用データベース
<https://isl.sist.chukyo-u.ac.jp/archives4/>



■ 構造的異常検知

1. キズ発生前後のペア画像データベース (約10,000枚, 1GB)
2. 異なる撮影環境間におけるキズ検査のためのペア画像データベース (約1,500枚, 2GB)
3. 薬用カプセル外観検査データベース (約1,200枚, 10MB)
4. 欠陥様相テキスト付き素地画像データベース (約6,500枚, 600MB)



■ 論理的異常検知

1. 区画化部品外観検査データベース (約1,200枚, 4GB)

Advanced Sensing and Machine Intelligence, Chukyo Univ.

画像応用技術専門委員会 研究会 Jan. 16, 2026

64

まだまだ残る課題

基本課題

1. 要求精度が桁違いに厳しい
2. 現場での異常サンプルは入手困難

いま興味をもっている課題

1. 処理系の負荷分担 エッジ側GPUの許容度増加, VLM学習も視野に
2. 解像度 v.s. 処理時間 高解像度画像を扱えるか？(ex. 半導体製造)
3. ロボット+異常検知 身体の人間化にともなう照明・撮影系とのトータル設計

まとめ

1. イントロダクション

異常検知(外観検査)の課題再考, 現況整理

2. 構造的異常検知

- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

3. 論理的異常検知

- 研究動向
- 世の中の主要技術
- 当研究室での取り組み事例

4. 雑感

残された課題, これからの課題, 画像データセット



講演資料等



公開画像DB

連携相談の連絡先

中京大学 工学部 橋本学

mana@isl.sist.chukyo-u.ac.jp



【参考資料】 参考文献リスト

構造的異常検知 1/5

2020

- P.Bergmann, et al. "MVTec AD--A comprehensive real-world dataset for unsupervised anomaly detection", In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp.9592-9600,2019.
- P.Bergmann, et al. "Uninformed students: Student-teacher anomaly detection with discriminative latent embeddings", In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp. 4183-4192, 2020.
- L.WANG, et al. "Image anomaly detection using normal data only by latent space resampling", Applied Sciences, 2020.
- D.Dehaene, et al. "Iterative energy-based projection on a normal data manifold for anomaly localization", arXiv preprint arXiv:2002.03734, 2020.
- Cohen, Niv, and Yedid Hoshen. "Sub-image anomaly detection with deep pyramid correspondences." arXiv preprint arXiv:2005.02357 2020.

2021

- Collin, Anne-Sophie, and Christophe De Vleeschouwer. "Improved anomaly detection by training an autoencoder with skip connections on images corrupted with stain-shaped noise." 2020 25th International Conference on Pattern Recognition (ICPR). IEEE, 2021.

構造的異常検知 2/5

2021

- Hiroki Kobayashi, Ryo Miyoshi, Manabu Hashimoto, Normal Image Generation-Based Defect Detection by Generative Adversarial Network with Chaotic Random Images, 16th International Symposium on Visual Computing (ISVC2021), Lecture Notes in Computer Science (LNCS), Vol.13017, pp.353-365, Virtual Event, 2021.
- T.Defard, et al. "Padim: a patch distribution modeling framework for anomaly detection and localization". In International conference on pattern recognition. Cham: Springer International Publishing, pp. 475-489, 2021.
- Li, Chun-Liang, et al. "Cutpaste: Self-supervised learning for anomaly detection and localization." Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021.
- Zavrtanik, Vitjan, Matej Kristan, and Danijel Skočaj. "Draem-a discriminatively trained reconstruction embedding for surface anomaly detection." Proceedings of the IEEE/CVF international conference on computer vision. 2021.
- Liu, Yunfei, Chaoqun Zhuang, and Feng Lu. "Unsupervised two-stage anomaly detection." arXiv preprint arXiv:2103.11671, 2021.
- V.Zavrtanik, et al. "Reconstruction by inpainting for visual anomaly detection." Pattern Recognition 112, 2021.

構造的異常検知 3/5

2022

- K.Roth, et al. "Towards total recall in industrial anomaly detection", In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp. 14318-14328, 2022.
- J.Wyatt, et al. "Anoddpm: Anomaly detection with denoising diffusion probabilistic models using simplex noise". In: Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, pp. 650-656, 2022.
- Schluter, Hannah M., et al. "Natural synthetic anomalies for self-supervised anomaly detection and localization." European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022.
- D.Gudovskiy, et al. "Cflow-ad: Real-time unsupervised anomaly detection with localization via conditional normalizing flows", In Proceedings of the IEEE/CVF winter conference on applications of computer vision, pp. 98-107, 2022.

2023

- J.Jeong, et al. "Winclip: Zero-/few-shot anomaly classification and segmentation", In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 19606-19616, 2023.
- Hiroki Kobayashi, Manabu Hashimoto, DRepT: Anomaly Detection Based on Transfer of Defect Representation with Transmittance Mask, 2023 International Joint Conference on Neural Networks (IJCNN), pp.1-8, Gold Coast Convention and Exhibition Centre, Queensland, Australia, 2023.
- T.Masato. "Random word data augmentation with clip for zero-shot anomaly detection." arXiv preprint arXiv:2308.11119, 2023.

構造的異常検知 4/5

2024

- N.Hiramatu, et al. "DoG-PaDiM: Anomaly Detection Based on Bandpass Filtering for Arbitrary Size Defect Extraction", In 2024 IEEE 20th International Conference on Automation Science and Engineering (CASE). IEEE, pp. 4140-4145 2024.
- K.Batzner, et al. "Efficientad: Accurate visual anomaly detection at millisecond-level latencies" In Proceedings of the IEEE/CVF winter conference on applications of computer vision. pp. 128-138 2024.
- Z.GU, et al. "Anomalygpt: Detecting industrial anomalies using large vision-language models", In Proceedings of the AAAI conference on artificial intelligence, pp. 1932-1940, 2024.
- A.Mousakhan, et al. "Anomaly detection with conditioned denoising diffusion models."In DAGM German Conference on Pattern Recognition. Cham: Springer Nature Switzerland, 2024.
- Q.Chen, et al. "Unified Anomaly Synthesis Strategy with Gradient Ascent for Industrial Anomaly Detection and Localization", European Conference on Computer Vision, 2024.
- 村上, 平松, 小林, 秋月, 橋本, 固有空間における情報合成に基づく高リアリティ不良品画像生成, 精密工学会誌, Vol.90, No.8, pp.662-668, 2024.

2025

- 大田直輝, 杉本健輔, 村上尚生, 平松直人, 小林大起, 秋月秀一, 橋本学, ImageNetと現場正常画像の周波数合成による事前学習画像を用いた異常検知の精度向上, 第31回画像センシングシンポジウム, IS3-32, pp.1001-1005,2025.
- 村上尚生, 平松直人, 小林大起, 秋月秀一, 橋本学, 特徴量の正常表現空間からの逆射影誤差指標に基づく対象物の回転に頑健な異常検知の提案, 精密工学会誌, Vol. 91, No.5, pp.597-604, 2025.

構造的異常検知 5/5

2025

- E.JIN, et al. "Logicad: Explainable anomaly detection via vlm-based text feature extraction" In Proceedings of the AAAI Conference on Artificial Intelligence, pp. 4129-4137, 2025.
- J.Xu, et al. "Towards zero-shot anomaly detection and reasoning with multimodal large language models" In Proceedings of the Computer Vision and Pattern Recognition Conference, pp. 20370-20382, 2025.

論理の異常検知 1/3

2022

- P. Bergmann, et al. "Beyond dents and scratches: Logical constraints in unsupervised anomaly detection and localization", International Journal of Computer Vision, Vol.130, pp.947-969, 2022.

2023

- Cao, Yunkang, et al. "Towards generic anomaly detection and understanding: Large-scale visual-linguistic model (gpt-4v) takes the lead", arXiv preprint arXiv:2311.02782, 2023.
- H.Yao, et al. "Learning global-local correspondence with semantic bottleneck for logical anomaly detection", IEEE Transactions on Circuits and Systems for Video Technology, Vol.34, no.5, pp.3589-3605, 2023.
- T. Liu, et al. "Component-aware anomaly detection framework for adjustable and logical industrial visual inspection", Advanced Engineering Informatics, Vol.58, pp.102161, 2023.
- H.Yao, Wei Luo, and Wenyong Yu. "Visual anomaly detection via dual-attention transformer and discriminative flow", arXiv preprint arXiv:2303.17882, 2023.
- H.Yao et al., "Dual-Attention Transformer and Discriminative Flow for Industrial Visual Anomaly Detection", IEEE Transactions on Automation Science and Engineering, vol.21, no.4, pp. 6126-6140, 2023.

2024

- H. Guo et al., "Template-guided Hierarchical Feature Restoration for Anomaly Detection", 2023 IEEE/CVF International Conference on Computer Vision (ICCV), pp. 6424-6435, 2023
- J. Zhang, M. Suganuma and T. Okatani, "Contextual Affinity Distillation for Image Anomaly Detection," 2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), pp. 148-157, 2024.

論理の異常検知 2/3

2024

- S.Sakai, Tatushito Hasegawa, and Makoto Koshino. "LADMIM: Logical anomaly detection with masked image modeling in discrete latent space." arXiv preprint arXiv:2410.10234, 2024.
- X.Xu, et al. "Customizing visual-language foundation models for multi-modal anomaly detection and reasoning", arXiv preprint arXiv:2403.11083, 2024.
- M.Lee and J.Choi. "Text-guided variational image generation for industrial anomaly detection and segmentation", Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2024.
- Luc PJ, et al. "Generalad: Anomaly detection across domains by attending to distorted features", European Conference on Computer Vision. Cham: Springer Nature Switzerland, pp. 448-465, 2024.
- Y.Zhao, "LogicAL: Towards logical anomaly synthesis for unsupervised anomaly localization." Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 4022-4031, 2024.
- M.Yang, "SLSG: Industrial image anomaly detection with improved feature embeddings and one-class classification", Pattern Recognition, Vol.156, 2024
- S. Kim, et al. "Few-shot part segmentation reveals compositional logic for industrial anomaly detection", Proceedings of the AAAI Conference on Artificial Intelligence, Vol.38, No.8, pp.8591-8599, 2024.
- H.Yao, et al. "Prior normality prompt transformer for multiclass industrial image anomaly detection." IEEE Transactions on Industrial Informatics, Vol.20, No.10, pp.11866-11876, 2024.
- Y. H. Hsieh and S. H. Lai, "CSAD: Unsupervised component segmentation for logical anomaly detection", arXiv preprint arXiv:2408.15628, 2024.

論理的異常検知 3/3

2024

- K. Batzner, et al. "EfficientAD: Accurate visual anomaly detection at millisecond-level latencies", Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, WACV, pp.128-138, 2024.
- S.Shota and I.Ryuji: "PUAD:Frustratingly simple method for robust anomaly detection." IEEE International Conference on Image Processing, pp.842-848, 2024.

2025

- Y. Zhang, et al. "LogiCode: An LLM-Driven Framework for Logical Anomaly Detection", IEEE Transactions on Automation Science and Engineering, vol.22, pp.7712-7723, 2025.
- P.Yun, et al. "SAD-LAD: Segment anything model meets zero-shot logic anomaly detection." Knowledge-Based Systems, Vol.314, 2025.
- N.Fujii, et al. "Explainable Detection of Logical and Structural Anomalies based on Multimodal Large Language Models", ROBOVIS, 2025.
- G.Wang, et al. "CLIP-LAD: Unleash the Potential of CLIP for Few-shot Logical Anomaly Detection", 2025