IVI 先進研究分科会ホワイトペーパーVol.10

# AI・データ分析活用研究分科会

# 画像解析による外観検査自動化の事例とその 技術





インダストリアル・バリューチェーン・イニシアティブ



1.	はじる	めに1
	1.1.	本書の目的1
	1.2.	対象読者1
	1.3.	関連ドキュメント1
	1.4.	用語略称2
2.	用語	の説明3
3.	活動	の経緯4
	3.1.	活動方針4
	3.2.	活動概要とスケジュール4
4.	画像	解析技術5
	4.1.	撮像および画像処理5
	4.2.	機械学習による画像解析11
5.	画像	解析取組結果13

5.1.	評価対象画像の	準備 13
5.2.	画像解析事例1	画像解析ツール ViMo 19
5.3.	画像解析事例2	AI 画像認識ソフトウェアパ
ッケー	·ジNAIT	
5.4.	画像解析事例3.	
5.5.	画像解析事例4.	
5.6.	まとめ	
6. 課是	夏と今後の展望	97
6.1.	取り組みの成果.	97
6.2.	今後の課題	97
参考文南	伏	
著者およ	マンバー	
付録		

● 一般社団法人 インダストリアル・バリューチェーン・イニシアティブ



# 1.1. 本書の目的

本書は、外観検査の自動化を実現するための画像解析を通して得られた知見・ノウハウを解析事例に 基づき整理したものである。本書では、実際に利用した撮像環境および画像解析手法についても紹介す ることで読者の理解を深められるようにした。

検査対象は、精密機械部品向けの高速プレス機で生産されたプレス製品であり、画像解析により製品 の良否判定を自動化することを目指す。本書の内容は、IVI 先進研究分科会「AI・データ分析活用研究分 科会」の 2~3 年の活動成果をまとめたものである。

## 1.2. 対象読者

本書の対象読者は、画像データ分析者、機械設計技術者、機械設備によるプラント運営者、画像解析 分野の研究者の方々、さらに、技術分野のアナリストやデータ標準化を推進する方々を対象読者とす る。

1.3. 関連ドキュメント

なし。

# 1.4. 用語略称

本文中参照。



高速プレス機:高い剛性と精度を備え、高速で加工を可能としたプレス機械。

金型:素材の塑性または流動性の性質を利用し成形加工して製品を得るための、主として金属素材を 用いてつくった型 [1]。

その他の用語は本文中を参照。



# 3.1. 活動方針

IVI 先進研究分科会「AI・データ分析活用研究分科会」では、「全員が自ら手を動かし AI・データ分析を身に つけると同時に、現実の課題解決にチャレンジする」方針の下で活動を行ってきた。本分科会では、IVI の業務 シナリオ WG や他の先進研究分科会と連携し、分科会メンバーが自身の知見を活かしてデータ分析を実施し て課題解決に生かすとともに、メンバー間での切磋琢磨の場としてきた。

# 3.2. 活動概要とスケジュール

本書に記載の内容は、IVI 業務シナリオ WG にて採取した精密機械部品向け高速プレス機のプレス製品(良品・不良品)の提供を受けて分科会メンバーが撮像および画像解析を実施したものである。図 3.2-1 に示すようにプレス製品の撮像から開始し、同じ画像を複数のメンバーで異なるアプローチで解析を行った。



図 3.2-1 分科会の活動概要と推進スケジュール



#### 4.1. 撮像および画像処理

4.1.1 はじめに

産業用途・モノづくりの領域に特化した画像処理の分野であるマシンビジョン(MV)の観点から記す。 マシンビジョンが他の画像処理分野と違う点として抑えたい処は撮像画像から得られる情報が対象とする 物体そのものを忠実に写実した映像情報を必要とされるのではなく、任意の検出したい事象を正確に、 より早く判断し処理できる画像情報を取得することが第一にある。そのためには高コントラストな撮像画像 を生成することに重点がおかれる点を認識頂きたい。本章では所望の撮像画像を取得するために必要と される照明および照明機器に関して解説する。

4.1.2 光の特性

光は電磁波の一種と言われる。ただ多様な側面を持っていることから特性を大きく区分し、『光線 としての光』の性質についてみてみる。光線という概念から均質な媒体中において直進性を有する。鏡や 研磨された金属の表面にあたると反射する。一方、空気とガラスとの境界面や空気と水との境界面のよう に媒質の密度が異なる境界面では、光は屈折して進む。





反射光:



鏡面上の物体表面にあたって反射する際、入射光が表面にあたった点から面と垂直方向に法線を描き 入射光と、この法線を含む面を入射面という。光線は、この入射面から外れることなく反射する。 入射光と法線のなす角を入射角、反射光と法線のなす角を反射角といい、それぞれの角が等しい時、

いわゆる反射の法則を満たし、物体表面で反射することを正反射(または鏡面反射)という。ただ通常の 物体はきれいな鏡面状ではなく凸凹しているため、いったん物質内に入った光(屈折光)が内部で多重に 吸収・散乱され一部が再び表面に戻り、ほぼ等方的に反射する。そのことを拡散反射という。

拡散反射についてもう少し詳しくみてみる。光が物体表面で完全に拡散しているとすれば表面の明るさに 対応する輝度は観測方向によらず一定になる。拡散反射にはその特性に2通りの要因が考えられる。

①表面の粗さに基づく拡散反射である。物体と空気の境界面に 細かな凸凹がある場合、この境界面において反射光はあらゆる 方向に散乱し、その結果として均等な輝度分布になる。この事象は

表面で発生するのが特徴で、すりガラスやざらついた金属面で



みられる。②物体内部での光の散乱に基づく拡散反射である。塗装物体をイメージすると捉えやすい。境 界面を通過した光が媒体中を透過すると、色素との間いで衝突を繰り返し再び境界面から空気中に出射 した光は指向性がなく均一な輝度分布をもつ。このとき、色素により特定の波長領域の光が吸収されるた め拡散反射成分は物体(媒体)に固有の色をもつことになる。なお完全拡散体では輝度は入射角の余弦 に比例する。この性質をランバートの余弦則と呼ぶ。また理想的拡散反射をランバーシアンという。



2色性反射モデル:

実際の物体表面の見え方は完全拡散とは異なり光源と物体の位置関係に依存して変化する。例えば、観 測する位置によって、表面が明るく見えたり、暗く見えたりするし、光沢感をもったり、強いハイライトが現 れたりする。光沢やハイライトは表面がなめらかなプラスチックなどの物体表面に現れやすい。つまり光の 反射の仕方は表面を形成する材質と観測条件に依存すると言える。自然界に存在する多くの物体表面の 材質はペイントやプラスチックのような不均質誘電体の構造に近く、その媒体と埋め込まれた色素のよう に異なった成分材料から構成される。このようにして物体表面から反射した光は物理的に異なった2経路

で反射する。このとき反射光の輝度は右図のような

分布になる。拡散反射が観測方向によらず一定である のに対し、鏡面反射は観測範囲が限られ、入射角と 観測角が一致する正反射方向でのみ観測される。鏡面 反射の鋭さは表面の滑らかさで決まる。このように物体



表面の反射の仕方を記述したものを反射モデルという。前述のような拡散反射と鏡面反射からなる モデルを2色性反射モデルという。

BRDF および BSSRDF:

物体表面の明るさは物体を照らす光源の方向と物体を観察する視線の方向の両方に依存する。石膏や セラミックなどの不透明物体では物体表面上のある点に入射した光は同じ点から出射するとみなすことが できる。不透明物体の反射特性は物体表面上のある点への入射光の方向(θi,Φi)とその点からの出射 光の方向(θo,Φo)の4つの角度の関数として記述でき、不透明物体の反射特性を記述する4次元の関 数を双方向反射率分布関数(BRDF)と呼ぶ。また皮膚や大理石などの半透明物体では、物体表面のある 点に入射した光は物体内部に深く浸透して散乱を繰り返したのち入射した点とは異なる点から出射する。 したがって、半透明物体の反射特性は入射光の入射位置と入射方向および出射光の出射位置と出射方 向に依存する。半透明物体の反射特性を記述する関数を双方向散乱面反射率分布関数(BSSRDF)と呼 ぶ。







色知覚:

人間が見ることができる光のことを可視光と呼ぶ。可視光とは波長が 380nm~780nm の範囲の電磁波で ある。人間はこのようなわずかな波長範囲の光から色と形状を認識する。実際には、人間はシーンをかな り詳細に認識することができる。コンピュータビジョンにおいてはカメラをベースとする機器で視覚系を構築 し、その出力に対して種々のアルゴリズムを適応してシーンを認識している。



色の反射と吸収:

スマホなどカメラ機能を有するデバイスでは白色の光源を用いたカラーによる撮像が一般的である。 前述のようにマシンビジョンは対象物を忠実に写実する撮像が必要か?というと、そうではなく、 高コントラストな画像を生成し、欠陥など抽出したい箇所を検出できる。そのような撮像画像が重要 であるため、カラー撮像するのではなく、モノクロの撮像画像が重宝されるシーンが多くある。マシンビ ジョンが進化した背景には、昨今のような人手を自動化する。ということではなく、そもそも人間が処理でき ない領域の自動化において活用されるシーンで進化してきた経緯がある。例えば、半導体製造装置は ほぼ完全自動で稼働することから装置内部では人の目に変わる機能が多く存在する。メカ部の位置決め 動作およびワークの搬送や検出など物体検知の処理においてマシンビジョンは機能している。その際 用いられる画像処理はモノクロ処理で十分であり、後で説明する高コントラストな画像を生成するために 用いる光源は単色光照明が大いに機能する。対象とするワークおよびその背景との関係から照射する 光源の波長に配慮するべきポイントがある。下図は単色光照明を使用した際の事例である。被写体色と 単色光照明の対比 = 同色か、補色かの違いを明示したものである。被写体色への単色光照明が同色 系の場合には反射され明るく見える。補色であれば(シアンの場合には赤色)、吸収され暗く見えている という具合になる。このように被写体と背景のそれぞれの分光特性と、これに対する単色光照明の選定 を工夫することで、ワーク対背景間のコントラスト比を強化することが出来る。

	被写体色	赤LED照射	緑LED照射	青LED照射	色の三原色
シアン	Augustion 57		1		R G B R:吸収★ G:反射 B:反射 C(シアン)
		吸収	反射	反射	W(ホワイト)-R(レット*)=C(シアン)
イエロー					R G B R:反射 G:反射 B:吸収★ Y(イエロー)
		反射	反射	吸収	W(ホワイト)-B(フ <sup>*</sup> ル-)=Y(イエロ-)
マゼンタ					R G B R:反射 G:吸収★ B:反射 ● M(マゼンタ)
		反射	吸収	反射	W(ホワイト)-G(グリ-ン)=M(マセ <sup>*</sup> ンタ)

出典:(㈱レイマックの HP (https://leimac.jp/lighting/light\_tech\_quality-html/)

4.1.3 3次元復元のための照明法

マシンビジョン用途で照明機器を使用する際、撮像に必要な光量を適切なタイミングにて照射することで カメラは対象ワークを的確に捉え、2Dの画像情報を取得できる。近年、ワークの形状を認識する際、2D 画像の情報から3D形状を認識できる手法が実用化してきた。その一つに照度差ステレオ(フォトメトリック ステレオ)の活用がある。2D画像から明るさ解析を行い3Dの画像情報を生成する手法である。カメラと3 つ以上の光源を使用する。各デバイスの配置は固定する。カメラの撮像タイミングと同期させながら複数 に配置した光源を時分割に照射する。撮像し得られた複数枚の画像を合成処理することで3D復元した 画像データが得られる。

照度差ステレオ法とは:

物体の3D形状を2Dテクスチャの撮像画像から切り出すコンピュテーショナルイメージング手法である。 2Dテクスチャ(ざらざらした表面や凸凹のある表面を指す)を3D表面から除去した後に明るさ解析によっ て物体の表面曲率を算出し、従来の画像処理手法では検出し難い小さな欠陥や特徴を検出することがで きる。カメラは照明に対して固定する。複数台の照明機器を切り替え照射し、一連の画像を撮像する。 その間、カメラの設定は変更しない。このようにして得られた複数枚の画像を合成処理し、1枚の画像を 生成する。生成した画像から対象とするワークの表面の向きと曲率の局所的な値が得られる。



事例紹介:

ワーク(カップ容器)を中心に分割リング照明を配置して照射する構成である。下左側の8個の生画像は 8方向に均等分割されたリング照明を順次点灯することで得られた撮像画像である。右側の2画像は、そ の撮像画像を合成処理した画像データで、カップ上面から見た①平均画像と②曲率画像である。上側の 平均画像ではマークや印字などフィルム状の凹凸が確認できる。下側の曲率画像ではストロー用の切れ 目加工された部分が認識しやすくなっているのがわかる。



出典:(株)レイマック(<u>https://leimac.jp/hs\_imaging/</u>)

以降の章にて説明される検証報告では本手法を利用し撮像した類似の画像を使った実証である。 照度差ステレオ法の原理を用いて撮像し得られた画像データからは、従来のような一様に光を照射し 撮像し取得した画像では認識し難い事象を捉えることができる。

撮像および画像処理に関する参考文献をリストするので適宜参照されたい。 [2] [3] [4] [5] [6] [7] [8] [9] [10] [11] [12] [13]

#### 4.2. 機械学習による画像解析

本ホワイトペーパーで利用する機械学習による画像認識技術には、画像分類、物体認識、セマンティックセグメンテーションの3つの主要な手法がある。各手法の概要を説明する。

4.2.1 画像分類 (Image Classification)

画像分類は、画像全体に1つのラベルを割り当てる手法である。学習モデルは、画像を入力として受け 取り、その画像がどのクラス(カテゴリー)に属するかを予測する。比較的シンプルで、データセットが十分 に揃っていれば高い精度を達成できる。例えば、猫や犬の画像をそれぞれ「猫」「犬」と分類する、手書き 数字を 0~9 のクラスに分類するといった利用ができる。

画像分類の代用的手法に畳み込みニューラルネットワーク(CNN, Convolutional Neural Network) [14] [15]がある。CNN は、ディープラーニングの一種であり、畳み込み層とプーリング層を利用して、画像の特 徴を自動的に抽出する。一般的には、大規模データセットで訓練された CNN モデル(例: VGG, ResNet)を ベースにして、特定のタスクに微調整する転移学習(Transfer Learning)の方法がとられる。

4.2.2 物体認識 (Object Detection)

物体認識は、画像内に存在する複数のオブジェクトの位置とそのクラスを特定する手法である。画像内 の各オブジェクトにバウンディングボックスを描画し、それぞれにラベルを付与する。画像内の複数のオブ ジェクトに対してラベルを付与し、各オブジェクトの位置情報(バウンディングボックス)を提供する。例え ば、道路の画像内に複数の車、人、自転車などがある場合、それぞれのオブジェクトの位置とクラス(車、 人、自転車など)を特定するといった利用ができる。

物体認識の手法は、R-CNN(Region-based Convolutional Neural Network)、Fast R-CNN、 YOLO(You Only Look Once)、SSD(Single Shot MultiBox Detector)など多岐にわたる [16]。

4.2.3 セマンティックセグメンテーション (Semantic Segmentation)

セマンテイックセグメンテーションは、画像内の各ピクセルに対してラベルを付与する手法である。画像 全体をクラスごとにピクセル単位で分類する。各ピクセルに対してラベルを付与するため、詳細な分類が 可能である。例えば、道路の画像に対して、道路、車、歩行者、建物などのピクセルをそれぞれのクラスに 分類するといった利用ができる。セマンテイックセグメンテーションの手法は、U-Net およびその派生形の U-Net++、ResUNet など多岐にわたる [17]。



### 5.1. 評価対象画像の準備

5.1.1 はじめに

今回画像解析に使う対象の製品は、株式会社ミスズ工業にて量産生産している金属部品とした。 この部品の代表的な不良モードと良品のサンプルを準備し、画像取込みは2種類のシステムを用意し それぞれで画像データの取り込みを行った。

5.1.2 対象製品について

今回の対象品は、株式会社ミスズ工業で量産生産している車載用の金属パーツ部品で、順送金型 を使ったプレス工法で生産しているものである。



高速プレス機



順送金型







対象製品



5.1.3 製品の不良モード

代表的な不良モードの4種類を準備。

① Bダコン

B面の突起部先端にある打痕で

中心穴に掛る打痕

- Sダコン
  S面平面部に発生している打痕
- ③ Sアタリキズ

S面外周部に凹みのあるキズ

④ 材料不良



S面平面部に発生してる材料の表面の荒れや浮きになっているもの

#### 5.1.4 対象製品サンプル数

- I.良品 50個
- Ⅱ. 不良品 160個

	<ul><li>・①Bダコン</li></ul>	50個
±=	・②Sダコン	50個
内訳	・③Sアタリキズ	50個
	・④材料不良	10個

Ⅲ. MC 不良品

90個

	・①Bダコン	30個
内訳	·②Sダコン	30個
	・③Sアタリキズ	30個

MC 不良品は MC(マシーン:ミスズ工業の自動外観検査装置)で不良判定したもの。

実際に不良品なのかは人が再検査し判定して決める。

5.1.5 不良モードの内容

・不良モードについては代表的な不良を4項目(Bダコン、Sダコン、Sアタリキズ、材料不良)を選定し 以下にその不良サンプルを2例ずつ紹介する。(赤印:不良、黄印:良品限界)

① Bダコン(中央凸部の内側に掛るキズや打痕)



Sダコン(平面部にキズや面押し跡が付いたもの)





③ Sアタリキズ(製品外周部にキズや打痕が付いたもの)



④ 材料不良(材料表面が荒れているもの、浮いているもの)



5.1.6 画像データの取り込み

今回は2つのシステムを使い画像データの取り込みを行った。一つは株式会社レイマックのシステム構成を使い、もうひとつは株式会社ミスズ工業の自動外観検査装置のシステムに合わせた構成を 作りこの2つのシステムを使って行った。

#### ・2社のシステムのセッティング状況



#### ・(株)ミスズ工業の自動外観検査装置



5.1.7 取込み画像について

・良品と不良品の画像を取込み、不良品画像にはその場所が分かる様に〇印で囲って印を付けた。

・赤丸印は不良レベルで、黄丸印は良品限界レベル。

1. 株式会社レイマック



2. 株式会社ミスズ工業



5.1.8 取込画像データ数

解析するための学習データは多く欲しいと要望があるが不良品の数は限られていたため今回はデー タ数を増やす手段として各サンプルの取込画像を1製品につき2枚ずつデータ取得した。

この2枚の画像が同じにならない様に製品を回転させ角度を変えて画像取得した。

取得した画像データ数は下以下の通りである。

			取得画像	データ数
-		サンプル数	レイマック	ミスズ工業
	Bダコン	50	100	100
	Sダコン	50	100	100
不	Sアタリキズ	50	100	100
良	材料不良	10	20	20
品	MC_Bダコン	30	60	60
	MC_Sダコン	30	60	60
	MC_Sアタリキズ	30	60	60
良	良品_B面	50	100	100
묘	良品_S面	50	100	100
		合計	700枚	700枚

【1製品2ショットでデータ数アップ】

同ーサンプルを角度を変えて2ショットず つ撮像することでデータ数を倍にした





サンプルを回転し1製品で2画像取得



#### 5.2. 画像解析事例1 画像解析ツール ViMo

SmartMore 社(<u>https://www.smartmore.jp/</u>)のノーコード画像解析ツール"ViMo"を使って4種類の不良検 出を行った。画像解析アルゴリズムにはセグメンテーション、物体検知、画像分類の3種類のモデルを使 用した。





#### 図 5.2.1-1

図 5.2.1-2

図 5.2.1-1 に使用した各不良タイプと良品の画像数をしめす。例えば B ダコンの不良検知の場合は、M\_B ダコン 100 枚と M\_良品 B 面 100 枚を合わせて 200 枚の画像を学習:検証=7:3 で分割し、140 枚の画 像で学習、60 枚の画像で検証を行った。M\_材料不良の場合のみ、不良画像が 20 枚しかないので、84 枚で学習、36 枚で検証を行った。図 5.2.1-2 は今回使用したノーコードの画像解析ツール ViMo の初期画 面である。アルゴリズムとして分類、物体検出、セグメンテーション(画像分割)の 3 モデルを選択できる。

学習は 90 epoch を基本とし、検証精度としては、① 正解率(Accuracy) ②適合率(Precision) ③再現率 (Recall) を評価した。特に今回は不良見逃しを極 力0にする目標があるので、①だけでなく、③の精 度にも注目した。

		推論		
		ОК	合計	
10	ОК	TN	FP	30
ΪŅ	NG	FN	ТР	30

図 5.2.1-3



図 5.2.2-2 Val2

#### 5.2.2 S アタリキズ@セグメンテーション



合計

30

30

図 5.2.2-1,2 に示すように良品は全て正しく良品と認識しているが、不良品を良品と誤認識(不良見逃し)しているケースが~10%ある。正解率=93~95%,再現率=87~90%。と比較的良い結果。



図 5.2.2-3





図 5.2.2-4

図 5.2.2-3 に不良見逃しのケースの S アタリキズ画像を、図 5.2.2-4 に S アタリキズを正しく不良と認識しているケースのサンプル画像を示す。





図 5.2.3-1,2 に示すように良品を不良品と認識するケースと不良品見逃しのケース、共に多い。正解率= 73~77%,再現率=73~87%。とあまり良くない結果であり、S アタリキズの検出には、画像分類モデルは適 してない。

#### 5.2.4 S アタリキズ@物体検出



図 5.2.4-1,2 に示すように良品は全て正しく良品と認識しているが、不良品を良品と誤認識(不良見逃し)しているケースが 13~40%とかなり多い。正解率=80~93%, 再現率=60~87%であり、セグメンテーションモデルより悪い結果。



図 5.2.4-3

図 5.2.4-3 に不良見逃しのケースとS アタリキズを正しく不良と認識したケースの S アタリキズサンプル画像を示す。赤い実線の Box と点線の Box が重なっているのは正しく認識しているケース、赤い実線の Box のみのものは不良見逃しのケースである。

以上の結果から、S アタリキズの検出には「セグメンテーション」モデルが最も適していると言える。

5.2.5 材料不良@セグメンテーション



図 5.2.5-1,2 に示すように良品を不良と認識しているケースが若干あるものの、セグメンテーションモデル で不良見逃しゼロとなった。



図 5.2.5-3

図 5.2.5-3 にラベル画像とAI が検出した画像を示す通り、ほぼ正しく不良エリアを検出している。

		推論	結果				推論	結果	
		ОК	NG	合計			ОК	NG	合計
10	ОК	30	0	30	10	ОК	22	8	30
Ν	NG	4	2	6	N N	NG	0	6	6
図 5.2.6-1						図 5.2.6-	-2		

5.2.6 材料不良@画像分類

画像分類モデルでは、図 5.2.6-1,2 に示すように、不良見逃しのケースを良品を不良と判断するケースの 両方がある。正解率=78~89%, 再現率=33~100%と、精度のバラつき幅が大きく、材料不良の検出には あまり適してない。

5.2.7 材料不良@物体検出

2回の検証結果は共に図 5.2.7-1 のような結果となり、不 良全数見逃しとなった。学習結果も不良を全数良品と判定 しており、全く学習できていないことが要因である。材料不 良のように不良形状が様々に変化するケースでは、物体 検知モデルが全く適していない。



以上から、材料不良はセグメンテーションモデルが最も適しており、不良見逃しはゼロである。



図 5.2.8-1,2 に示すように良品を不良品と判断するケースがあるものの、不良見逃しは 30 個中 1~2 個と かなり少ない。正解率=~93%, 再現率=90~93%と、精度としては良好な結果である。



図 5.2.8-3

図 5.2.8-3 に S ダコンのラベル画像と AI で検出した画像サンプルを示す。ラベルとほぼ同じエリアを AI で 正しく推論できているケースもあれば、ラベルエリアと検出エリアの形状が異なっているケースもあり、不 良見逃しの要因と思われる。

5.2.9 Bダコン@セグメンテーション

図 5.2.9-1,2 に示すように良品を不良品と判断するケースが若干あるが、不良見逃しは 30 個中 1 個と非常に少ない。正解率=95~98%,再現率=~97%と、精度としても非常に良好な結果である。





図 5.2.9-3

図 5.2.9-3 に B ダコンのラベル画像と AI で検出した画像サンプルを示す。ラベルとほぼ同じエリアを AI で 正しく推論できているケースもあれば、ラベルエリアと検出エリアの形状が異なっているケースや、ラベル の不良箇所を全て検出できてないケース(M\_B\_dakon\_31-1)がある。

ここまで全体を通して、4 種類の不良検出全てにおいてセグメンテーションモデルが最も優れている。不良 見逃しの観点では、材料不良は見逃しゼロ、S ダコン及び B ダコンは 3~7%、S アタリキズは~10%であり、S アタリキズが最も検出が難しいことがわかる。

5.2.10 Sアタリキズ@アンサンブル検証

ここで不良見逃しゼロを目標に、3つの AI モデルによるアンサンブル検証を行う。個々の AI モデルで不 良見逃しがあっても、AI モデルごとに不良見逃し傾向が異なれば、3つのモデルの不良検出結果の「OR」 をとることによって、不良見逃しをゼロにできる可能性がある。

図 5.2.10-1 はデータセット(画像良品 100 枚+不良品 100 枚)を学習用:検証用=7:3=140 枚:60 枚に分割する際、検証用 60 枚が異なる画像データセットになるようにして、検証を 3 回行った結果である。



図 5.2.10-1

セグメンテーションと物体検出で同じ不良サンプルを見逃しているケースのサンプル No を黄色マーカー で示すように、セグメンテーションと物体検出は同じサンプルを見逃す傾向にあることがわかる。ただ画像 分類では見逃し傾向が異なるため、3つのモデルの OR を取ることによって不良見逃しを減らすことができ る。図 5.2.10-1 では3つのモデルで不良見逃ししているのは M\_S\_atari\_41-1 のみとなる。

5.2.11 Sダコン@アンサンブル検証



図 5.2.11-1

図 5.2.11-1 は S ダコン不良のアンサンブル検証結果である。S ダコンではセグメンテーションでの不良見 逃しが S アタリキズより少ないものの、やはりセグメンテーションと物体検知で同じ不良サンプルを見逃す 傾向にある(共通している不良サンプル No を黄色マーカーで表示)。さらに物体検出モデルでは、不良見 逃しが非常に多く、最も適してないモデルである。ここで注目したい点として、画像分類の結果が非常に良 く、セグメンテーションよりも高い精度が出ており、S ダコン検出には最も適したモデルであることがわか る。結果として、Sダコンではセグメンテーション+画像分類のアンサンブル検証により、不良見逃しをゼロ にできる。また良品の不良判定も非常に少ない。



5.2.12 Bダコン@アンサンブル検証

図 5.2.12-1 に B ダコン不良のアンサンブル検証結果を示す。B ダコンでは3つのモデル全てにおいて比 較的良好な精度が得られている。また不良見逃し数については、セグメンテーション(9 個)よりも画像分類 と物体検出(それぞれ 5 個)の方が少ないことがわかる。ここでもセグメンテーションと物体検知は、同じ不 良サンプルを見逃す傾向にあるものの(共通している不良サンプル No を黄色マーカーで表示)、画像分類 では見逃し傾向が異なっている。結果として、B ダコンでは物体検出+画像分類のアンサンブル検証によ



5.2.13 材料不良@アンサンブル検証

り、不良見逃しをゼロにできる。また良品の不良判定も非常に少ない。

図 5.2.13-1 に材料不良のアンサンブル検証結果を示す。材料不良では物体検出モデルが使えなかったので(5.2.7 参照)、セグメンテーションと画像分類の 2 モデルによるアンサンブル検証を行った。セグメンテ

ーションでは3つのデータセット全てにおいて不良見逃しゼロという良好な結果である。また良品の不良判 定も非常に少ない。

5.2.14 アンサンブル検証の効果

図 5.2.14-1 にアンサンブル検証結果(5.2.10~13)を纏める。外観 不良検査でよく用いられるセグメンテーションモデルでは不良見 逃しが散見されたが、アンサンブル学習(セグメンテーション+画 像分類+物体検知)では S アタリキズを除いて不良見逃しをゼロ にできている。精度を高める上でアンサンブル検証は大きな効果 があることがわかる。また4つの不良タイプの中での AI 判別の難 しさは S アタリキズ が最も難しく、S アタリキズ > B ダコン > S ダ コン > 材料不良という順番になる。

		不良見逃し数		
不良タイプ (母数)	Data Set	セグメ ンテー ション	アンサ ンブル	
	А	2	0	
Sアタリキズ (30)	В	5	1	
(00)	С	6	0	
	А	1	0	
Sタコン (30)	В	3	0	
(00)	С	1	0	
. 11	А	2	0	
Bダコン (30)	В	4	0	
(30)	С	3	0	
	А	0	0	
材料不良 (6)	В	0	0	
(0)	С	0	0	

図 5.2.14-1

5.2.15 S アタリキズ@セグメンテーション+画像データ拡張

学習工程にて良品画像及び不良品画像のデータ拡張を行い、学 習サンプル数を増やすことで検証精度が上げることができるか、

検証した。まずは S アタリキズ不良における、セグメンテーション+画像データ拡張有り無しの結果を図 5.2.15-1 に示す。





左はデータ拡張無しの結果、右は学習データを30%の確率でランダムに-90°から+90度の範囲に回転さ せてデータ拡張を行った結果である。データ拡張を行った方が若干不良見逃しが減る傾向にあるが、見 逃した不良サンプルはデータ拡張有り無しで共通しているものが多い。報告には掲載しないが、50%の確 率で回転させたり、ランダム回転の角度を大きくしたりして、学習データにおけるデータ拡張の比率を高く すると、逆に検証精度が落ちる現象が見られた。データ拡張をする場合は、元データとの比率やデータ拡 張方法について注意する必要がありそう。

5.2.16 Sアタリキズ@物体検出+画像データ拡張

S アタリキズ不良における、物体検出+画像データ拡張有り無しの結果を図 5.2.16-1 に示す。物体検知 モデルでもデータ拡張を行った方が不良見逃しが減る傾向にあり、検証精度が向上している。データ拡張 無しで不良見逃ししたサンプル 8 個の内 6 個を、データ拡張有りで不良として検出している。



5.2.17 Sダコン@セグメンテーション+画像データ拡張



S ダコン不良における、セグメンテーション+画像データ拡張有り無しの結果を図 5.2.17-1 に示す。S ダコ ン不良ではセグメンテーションの検出精度が高かったので、データ拡張有りでもほぼ同等の不良見逃し数 と検出精度になった。

5.2.18 Sダコン@物体検出+画像データ拡張



S ダコン不良における、物体検出+画像データ拡張有り無しの結果を図 5.2.17-1 に示す。S ダコン不良に おいては、物体検出モデルは最も適していない(不良見逃しが最も多い)モデルであったが、データ拡張を 適用すると劇的に不良見逃し数が減少した(13 個→1個)。ここでも 50%のデータをランダム回転 ±120° でデータ拡張をした場合は、全く学習が進まず全数不良見逃しとなってしまった。やはり適度なデータ拡 張(元データとの比率,拡張方法)が大変重要である。

5.2.19 Bダコン@セグメンテーション+画像データ拡張



図 5.2.19-1

B ダコン不良における、セグメンテーション+画像データ拡張有り無しの結果を図 5.2.19-1 に示す。B ダコ ン不良では、データ拡張有りの方が若干良好な検出精度であり、不良見逃し数も減少する(3 個→1 個)結 果となった。

5.2.20 Bダコン@物体検出+画像データ拡張





B ダコン不良における、物体検出+画像データ拡張有り無しの結果を図 5.2.20-1 に示す。ここではデータ 拡張有り無しで、ほぼ同等の検出精度及び不良見逃し数となった。

5.2.21 画像データ拡張まとめ

適度なデータ拡張(ランダム回転 30%, ±90°)は、推論の不良見逃し数に改善が見られ、学習データバ リエーションを増やす効果があると考えられる。Sアタリキズでは、不良見逃し数がセグメンテーションでは 6→3 個、物体検出では 8→2 個と共にデータ拡張の効果あり。S ダコンでは、セグメンテーションではデ ータ拡張有り無しでほぼ同等。物体検出ではデータ拡張の効果が絶大で、推論の不良見逃し数が 13→1 個と大幅に減少。B ダコンでは、セグメンテーションは若干のデータ拡張効果あり。物体検出はデータ拡張 有り無しでほぼ同等となった。

5.2.22 MC 不良品 S ダコン検査@セグメンテーション+データ拡張

図 5.2.1-1 の表内にある ③MC 不良品について、不良品を正しく判別できるかどうかの検証を行った。この MC 不良品は、マシンビジョンで一度不良とはじかれたサンプルなので、①不良品②良品の判別(5.2.2 ~ 5.2.20)より難易度は高いと思われる。ここでは①の 100 個と②の 100 個を全数使って学習を行い、③の 60 個を検証(本当の不良品を検出)した。

MC 不良品 S ダコン不良における、セグメンテーション+画像データ拡張有り無しの結果を図 5.2.22-1 に、 MC 不良サンプル No と不良見逃しケースの画像を図 5.2.22-2 に示す。





図 5.2.22-1

MC 不良品は良品限界も含めて 6 個であり、不良品画像は 12 枚(1 サンプルあたり 2 枚撮影)である。不 良見逃し数は 1/12 ~ 2/12 個と少なく、共通で見逃している「MC\_25-1」は学習データに含まれてないタイ プの不良形状と思われる。全体的にはデータ拡張有り無し共に良好な検出精度である。



5.2.23 MC 不良品 S ダコン検査@物体検出+データ拡張





図 5.2.23-2

MC 不良品 S ダコン不良における、物体検出+画像データ拡張有り無しの結果を図 5.2.23-1 に、実際の 不良部位検出画像を図 5.2.23-2 に示す。データ拡張無しでは、セグメンテーションと同じ不良サンプル 「MC\_25-1」「 MC\_25-2」を不良見逃しているが、データ拡張有りでは図 5.2.23-2 に示すように全て正しく 検出しており、不良見逃しゼロである。5.2.11 S ダコン@アンサンブル検証では、物体検出モデルの結果 が悪かったが、MC 不良品判別では「物体検出+データ拡張」が最も良好な結果となった。

5.2.24 MC 不良品 B ダコン検査@セグメンテーション+データ拡張









MC 不良品 B ダコン不良における、セグメンテーション+画像データ拡張有り無しの結果を図 5.2.24-1 に、実際の不良部位検出画像を図 5.2.24-2 に示す。ここでは、図 5.2.24-2 の MC 不良品 2 個(不良画像 4 枚)を判別するのであるが、データ拡張無しで不良見逃しゼロ、データ拡張有りで不良見逃し 1 個となっ た。図 5.2.24-2 の画像に示す通り、不良サンプル 2 個の不良部位は全て正しく検出できていることが分かる。

5.2.25 MC 不良品 B ダコン検査@物体検出+データ拡張



図 5.2.25-2

MC 不良品 B ダコン不良における、物体検出+画像データ拡張有り無しの結果を図 5.2.25-1 に、実際の 不良部位検出画像を図 5.2.25-2 に示す。MC 不良品 2 個(不良画像 4 枚)の内、サンプル#MC\_15 は正し く不良と判定しているが、サンプル#MC\_3 の 2 枚はデータ拡張有り無し共に共通して見逃している。これ は#MC\_3 のような不良形状が B ダコンとしては稀であり、学習データの中に十分含まれてなかった為と考 えられる。

5.2.26 MC 不良品 S アタリキズ検査@セグメンテーション+データ拡張

MC 不良品 S アタリキズ不良における、セグメンテーション+画像データ拡張有り無しの結果を図 5.2.26-1 と図 5.2.26-2 に示す。





図 5.2.26-2 に示すように MC 不良 S アタリキズで不良品としてラベル付けしたものは写真 14 枚(7 サンプ ル)である。その内不良品を良品と判断したものがデータ拡張無しで 9/14、データ拡張有りで 6/14 であ り、データ拡張有りの方が若干不良見逃しが少ないものの、かなり高い確率で不良を見逃している。ま た、データ拡張有り無しで、同じサンプルを見逃している傾向にある。更に良品を不良と判定しているケー スも、データ拡張無しで 10/46、データ拡張有りで 13/46 と多い。



図 5.2.26-3 に不良品を正しく判定したサンプル、不良品を良品判定したサンプル、良品を不良品判定した サンプルそれぞれの画像を示す。S アタリキズの大多数のケースは、周辺の黒いリング状のエリアが内側 に向かって突起している部分であり、不良品を正しく判定しているサンプルはそのケースである。不良品を 良品判定(不良見逃し)しているサンプルは、不良部位が内側に向けて白っぽく削れたような跡であり、内 側に向けた黒い突起とは異なる。不良品の良品判定は、この白っぽく削れたような不良部位の画像が学 習データの中に少なく、学習できていない事が原因と考えられる。一方良品を不良品判定しているサンプ ルは、周辺部に黒い小さい突起が見られるが、そのサイズが許容範囲にある為に良品にカテゴライズし ているものである。今回のセグメンテーションモデルでは、不良部位サイズまで見ていないので、黒い突 起部を全て不良部位と認識した為に不良品と判定したと思われる。

今回検証に用いた MC 不良品は、元々マシンビジョン検査で不良と判定されたサンプルなので、このよう な微小な黒い突起部位が画像に多く含まれていると考えられ、それが良品を不良判定しているケースが 多い要因と思われる。

5.2.27 MC 不良品 S アタリキズ検査@物体検出+データ拡張

MC 不良品 S アタリキズ不良における、物体検出+画像データ拡張有り無しの結果を図 5.2.27-1 と図 5.2.27-2 に示す



図 5.2.27-2 に示すように MC 不良 S アタリキズで不良品としてラベル付けしたものは写真 14 枚(7 サンプ ル)である。その内不良品を良品と判断したものがデータ拡張無しで 9/14、データ拡張有りで 3/14 であ り、データ拡張有りの方が不良見逃しが少なく良好な結果である。一方で、良品を不良と判定しているケ ースは、データ拡張無しで 11/46、データ拡張有りで 27/46 とかなり多い。図 5.2.27-2 で赤いムとなってい るサンプル#2 は 2 枚の画像の内 1 枚を不良と判定したが、もう一枚を良品と判定したケース。またサンプ ル#23 は 2 枚中 1 枚で正しい不良部位とは異なる場所を不良部位として認識して不良品と判定したケー スである。これら一部画像で不良を見逃しているサンプル #2, #23, #5 はセグメンテーションモデルでの 不良見逃しサンプルと一致している。


図 5.2.27-3 にそれぞれのサンプル画像を示す。物体検出+データ拡張で不良品を正しく判定した画像 11 枚の中で、サンプル#23(MC\_23-1)はラベリングした S アタリキズ不良箇所とは異なる場所を不良部位とし て認識していることがわかる。不良品を良品と判定しているサンプル#2,#23 はセグメンテーションモデル における不良見逃しと同じく、学習データにあまり含まれてない不良形状であることが要因と思われる。良 品を不良品と判定しているケースは周辺部のリング状の黒い部分の微小突起だけでなく、MC\_21-2, MC\_23-1 のように内部にある黒い点を不良と認識しているケースがある。不良部位検出エリアを周辺のド ーナッツ状エリアに限定するなどの工夫で対策できる可能性がある。

5.2.28 MC 不良品検査まとめ

S ダコン MC 不良ではデータ拡張有りの方が不良見逃しが少なく、物体検出+データ拡張有りでは不良 見逃しゼロ(0/12)である。また良品の不良品判定も少ない(2/48)。B ダコン MC 不良ではデータ拡張有り無 しで精度はほぼ同等であり、セグメンテーション+データ拡張無しでは不良見逃しゼロ(0/4)である。但し良 品の不良品判定は比較的多い(19/56)。S アタリキズ MC 不良の結果まとめを図 5.2.28-1 に示す。



図 5.2.28-1

不良と不良限界の 5 サンプル(画像 10 枚)の判定結果を見ると、物体検出 + データ拡張有りが最も不良 見逃しが少なく、2/10 である(サンプル#23-1 は不良見逃しにカウント)。但しこの時の良品の不良品判定 は 28/46 とかなり多い。これは MC 不良品がマシンビジョンで一度不良判定されたサンプルであることが 要因である。不良見逃しの観点からは、S ダコン・B ダコン不良に比べて、S アタリキズ不良が最も検出が 難しい。

5.2.29 全体を通しての考察

- 学習における適度なデータ拡張は学習データのバリエーションを増やし、精度向上に効果がある。
- 外観不良のケースに応じて、セグメンテーション,物体検出,画像分類のモデルから適切な AI モデル を選ぶのが良いが、一つのモデルだけでは不良見逃しをゼロにするのは困難である。その場合は複 数のモデルの結果の AND もしくは OR を取る「アンサンブル検証」によって、不良見逃しをゼロにする ことが可能である。但しその時は良品の不良品判定数が増加してしまう副作用がある。
- AI 画像判定で「総合精度を上げたい」のか、「不良見逃しを極力ゼロにしたい」のか、「良品の不良判定を減らしたい」のかなど目的を明確にし、その目的に応じた判定方法を選ぶ必要がある。

- 不良見逃しの要因の一つは学習データ不足である。学習できていない不良形状は不良部位と判定できない。不良見逃しサンプルの不良形状に似たサンプル画像を学習データに加え、学習させることにより不良見逃し精度はかなり向上すると考えられる。

# 5.3. 画像解析事例2 AI 画像認識ソフトウェアパッケージNAIT

### 5.3.1 はじめに

本画像解析事例では、AI 画像認識ソフトウェアパッケージNAITを使用した事例を紹介する。 昨 今、ディープラーニングを用いた画像認識は、外観検査において大きな進歩をもたらしている。 ディー プラーングは、ニューラルネットワークを多層に重ねた構造を用いて、画像やデータから特徴を学習する 技術になる。

ディープラーングを用いない従来の画像処理では、判定ロジックを手動で構築する必要があり、その精 度向上が困難でした。ディープラーニングでは、学習データさえあればシステムを構築でき、継続的なデー タの精度維持も可能になる。そして、何よりも従来の画像処理では、官能試験的な外観検査(しみ、汚れ、 様々な傷、パターンむら、他所謂計測という手段では判定できないようなもの)のロジックを構築すること 自体が容易ではなく、開発に相当なリソースをかけても、際立った効果が期待できなかった。また、新たな タイプの外観事象が生じた場合には、判定ロジックの変更・改善が難しく精度向上が困難でした。

一方、ディープラーニングを用いた場合には、人間が判定ロジックを構築する必要は全くなく、学習画像 データ(検出したい画像、例えば傷、汚れなど)さえあれば、自動的に特徴学習して、判定ロジックを自動 生成することができる。そして、ディープラーニングで自動生成された判定モデル(判定ロジック)は、大規 模な非線形パラメータフィッティングアルゴリズムにより、複雑な特徴でも抽出することが出来るようにな る。本画像解析事例では、AI 画像認識ソフトウェアパッケージNAITの最大の特徴は、ディープラーニン グの知識、プログラミングの知識がなくても、ノーコーディングで容易に画像認識モデルを作成することが 出来る仕組みが提供されている。

NAIT(ナイト)独自のオートディープラーニングアルゴリズムは、最適なディープラマウング構造 とハイパーパラメータを見つけ、高性能な検査モデルを作成します。従来のディープラーニング検 査の場合、必要なレベルのパフォーマンスを達成する検査モデルが作成されるまで継続的に調整と 再学習が必要です。一方、NAIT はワンクリックで最適な検査モデルを作成できるため、ディープ ラーニングの専門家でなくても高性能なディープラーニングモデルを作成できます。





5.3.2.1 NAIT による実証実験の結果について

#### (1) 実証実験におけるスコープ

【課題】

200 ショット/分を超えるプレス部品の自動外観検査をしているが、不良が最大20%出ることがあり、人が目視検査するとそのほとんどが良品となっている。また、材料ロットが変わると誤報がさらに増加することがあり、その度に検査アルゴリズムを手直しする必要がある。

【To be】

撮像条件の調整と画像 AI の組合せで、誤報のない自動検査を実現する。また、材料ロットによる影響のない検査を目論む。

【ゴール】

最適な撮像条件を実現する光学系と画像 AI と組合せることで、不良品を見逃さないかつ誤報を最 小限に抑えた検査を実現する(現行の最大誤報率 20%を限りなくゼロにする)。

## (2) 画像収集概要

今回は、2種類の撮像系を使って同一のサンプルからそれぞれ撮像して画像収集を実施した。

<mark>アタリキズ</mark>	26個
材料不良	9個
<mark>Bダコン</mark>	8個
<mark>Sダコン</mark>	40個
<mark>MC_</mark> Bダコン_サビ	40個
MC_Sあたりキズ	41個
<mark>S面良品</mark>	30個
B面良品	30個
MC_Sダコン	35個

収集した画像は、撮像系に応じて下記のようにファイル名を付けた。

Leimac xxxxx : レイマックの撮像系を使って撮像した画像ファイル

MSZ xxxxx : ミスズ工業の撮像系を使って撮像した画像ファイル

### 5.3.2.2 撮像の現場と方法

本実証実験では、下記<図-19>、<図-20>のような撮像系を使用した。





■それぞれの撮像系をセットアップしているところ。 左側:レイマックの高速同期撮像キット 右側:既存検査装置の撮像系を再現し

たもの





5.3.2.3 各サンプルの撮像画像

本実証実験では、二つの撮像系を使って撮像した画像を混合して学習することで認識モデルを作成し評価を実施した。

### (1) B 面良品: 下記のような 30 枚の良品画像

それぞれの撮像系で撮影した B 面の良品画像は下記のようになる。学習データは、実質 ×2の枚数に なっている。それぞれの撮像系で同じサンプルでも見え方が異なることに着目。



## (2) S 面良品: 下記のような 30 枚の良品画像

それぞれの撮像系で撮影した S 面の良品画像は下記のようになる。学習データは、実質 ×2の枚数に なっている。 撮像系で同じサンプルでも見え方が異なることに着目。





(3) B 面ダコン:下記のような8枚のダコン画像

それぞれの撮像系で撮像したので学習データは、実質 x2の枚数になっている。

Leimac L\_Bダコン2



<図-23>

MSZ\_M\_B M\_ Bダコン2



(4) S 面ダコン: 下記のような 40 枚のダコン画像

それぞれの撮像系で撮像したので学習データは、実質 x2の枚数になっている。 撮像系で同じサンプルでも見え方が異なることに着目。



(5) S 面アタリキズ: 下記のような 26 枚

それぞれの撮像系で撮像したので学習データは、実質 x2の枚数になっている。 撮像系で同じサンプルでも見え方が異なることに着目。



(6) S面材料不良:下記のような9枚

それぞれの撮像系で撮像したので学習データは実質 x2の枚数になっている。 撮像系で同じサンプルでも見え方が異なることに着目。

<図-26>



## (7) MC\_B ダコン\_サビ: 下記のような 40 枚

それぞれの撮像系で撮像したので学習データは実質 x2の枚数になっている。これらサンプルは、ダ コン\_サビが疑われる画像であり、検査装置が不良にしたが、目視での再検査はしていない、ほとんど が誤報とおもわれる。撮像系で同じサンプルでも見え方が異なることに着目。

Leimac L\_MC\_Bダコン\_サビ1\_IDR MSZ\_M\_B M\_mcBダコン&サビ1



(8) MC\_S アタリキズ: 下記のような 41 枚

それぞれの撮像系で撮像したので学習データは実質 x2の枚数になっている。これらサンプルは、アタ リキズが疑われる画像であり、検査装置が不良にしたが、目視での再検査はしていない、ほとんどが誤 報とおもわれる。撮像系で同じサンプルでも見え方が異なることに着目。

<図-28>

<図-27>

Leimac L\_MC\_Sあたりキズ1\_IDR MSZ\_M\_S M\_mcSアタリキズ1





MSZ M S M mcSダコン1

<図-29>

(9) MC\_S ダコン: 下記のような 35 枚

それぞれの撮像系で撮像したので学習データは実質 ×2の枚数になっている。これらサンプルは、ダコ ンが疑われる画像であり、検査装置が不良にしたが、目視での再検査はしていない、ほとんどが誤報と おもわれる。撮像系で同じサンプルでも見え方が異なることに着目。

Leimac L MC Sダコン1



本件では、ディープラーニングを用いて欠陥の検出を行うため、あえてそのような撮像系による常套手段 を使わずに、むしろ表面の細かい変化も撮像出来るような撮像系にしている。 そのようなので、上記のそ れぞれのサンプル画像を比較すると Leimac ラベルの撮像画像のほうが、どちらというとザラザラ感があ り、MSZ ラベルの撮像画像のほうが、ザラザラ感のないソフトな観えかたになっている。 5.3.2.4 欠陥サンプルの欠陥箇所の確認作業(アノテーション前に)

本項では、アノテーション前に(確実に欠陥であるところにしるしを付ける作業)、予め指示された欠陥箇 所の画像をベリファイする作業である。欠陥かどうか疑わしいもの、良品ではなく欠陥らしいものを見つけ て再確認する作業である。

# 

### (1) Bダコン欠陥の場所確認作業の一例

上記 No.3-1 の拡大図



実体顕微鏡で観察すると欠陥ではなく材料の凹凸の影のようである。



上図右の黄色?の部分についても No.3-1 同様に欠陥ではない。

<図-33>



実体顕微鏡での観察によると上図の黄色?の部分についても材料表面の反射影らしいものであり、 欠陥ではない。



<図-34>

## (2) s ダコン欠陥の場所確認作業の一例



上図では、いくつかのダコン欠陥が連なったようにも観えるが拡大観察する、一つのダコンであった。



上図では、もともと指摘された欠陥が、大きなL字状のひっかき傷であることが判明した。

実体顕微鏡で観察すると良くわかる。



上図において、上部の黄色い3つの口部分がダコンとして疑われたが、実体顕微鏡で観察すると何 もないことが判明。

(3) s アタリキズ欠陥の場所確認作業の一例

No,1-1

No,1-1

No,1-2

No,1-2

上図のようにすべて本当の欠陥。



<図-36>

<図-36>

nut tooparty attemption Rooparty attemption Roopa

上図では、最初に確認された赤い楕円で囲まれた部分の欠陥は、アタリキズではなく材料表面の凹凸で あることが後で確認された。本当の不良は黄色い楕円で囲まれたところにあった。実体顕微鏡で確認す ると良くわかる(上図右端の画像)。



上図では、最初のチェックでは欠陥として把握されておりませんでしたが、2度目のチェックで見つかりました。実体顕微鏡で観察すると不良レベルの盛り上がりが確認されました。

<図-38>



上図では、最初のチェックでは欠陥として把握されておりませんでしたが、2度目のチェックでこの微小 欠陥が見つかりました。実体顕微鏡で観察すると大きく観えます。



上図では、最初のチェックでは左上部の赤く囲まれた欠陥はチェックされていたが、右下の黄色の部分の欠陥は見落とされていた。、2度目のチェックでこの黄色の部分の微小欠陥が見つかりました。 実体顕微鏡で観察しても極小さな欠陥である。

このように、学習するためのアノテーションを行うまえにダブルチェックは、重要である。特に欠陥かどう か曖昧な画像、微小な欠陥などが見逃しがちになる。 今回上げた事例の中でもそのようなものが散見 され、実体顕微鏡で観察すると明らかになる。 特に欠陥画像かどうか曖昧なものは、実体顕微鏡で観 察すると、欠陥らしきものが何も見当たらないか、凹凸の影だったりする疑似欠陥である。

アノテーションの是非は、画像認識モデルの完成度に影響を与えるので確実に行う必要がある。

本件では、セグメンテーションでのモデルを作成して評価をおこなうため、下記のようにセグメンテーションのためのアノテーションを行った。



上図のようにアノテーションツールにより任意の形状を選択し、画像上で対象となる画像を囲うように描 画してアノテーションを行うことが出来る。



### 5.3.2.5 NAIT による評価結果

【課題】

200ショット/分を超えるプレス部品の自動外観検査をしているが、不良が最大20%出ることがあり、 人が目視検査するとそのほとんどが良品となっている。また、材料ロットが変わると誤報がさらに増 加することがあり、その度に検査アルゴリズムを手直しする必要がある。

【To be】

撮像条件の調整と画像 AI の組合せで、誤報のない自動検査を実現する。また、材料ロットによる影響のない検査を目論む。

【ゴール】

最適な撮像条件を実現する光学系と画像 AI と組合せることで、不良品を見逃さないかつ誤報を最小限に抑えた検査を実現する(現行の最大誤報率 20%を限りなくゼロにする)。

【本件のスコープ】

1. レイマックの照明機器を用いて最適な撮像条件の試行をしつつ画像収集を実施する。

2. 既存の検査装置の撮像系と同じものでも画像収集を行い画像 AI の検査結果を検討する。

3. 上記1, 2で収集した画像を NAIT 及び AI チームで評価検討する。

(1) 2つの撮像系で撮像した画像を混合して学習モデルを作成

それぞれ別々に評価するのではなく、2つの撮像系で撮像した画像を混合して評価を行った。 そのために、認識モデルを作成するための学習データは、2つの撮像系で撮像したそれぞれの画像を 混合して学習した。

学習に使用した画像(総数278枚)下記のようになる。

学習画像総数:	278
---------	-----

	学習セット
Bダコン不良	13
S当りキズ	45
Sダコン	95
材料不良	14
Unlabeled Images	111

学習情報

最短再学習: Off 全てのテスト画像にラベルを付けましたか?: Yes パッチサイズ (幅 x 高さ): 512X512 リサイズ方法: Linear バリデーションセットの固定:未設定 データ拡張 (オーギュメンテーション)をオフ:未設定 スペース検索:最短 トレーニングの時間: 01h 33m スケールファクター: 1

Unlabeled Images は良品画像になる。

\* 最短学習: off は、再学習の有/無の設定、ここでは無し

- \*バリデーションセットの固定: 未設定は、ランダムサンプリング法になる
- \*スペース検索: 最短は、画像枚数、特徴量から推察し設定したハイパーパラメータ探査領域
- \*スケールファクター: 1は、画像を等倍でディープラーニングするという設定
- (2) 全クラスにおける総合評価結果

作成した認識モデルに右記のような評価セット画像でテストしました。

Unlabeled Images は良品画像と検査装置が不良とした画像(xxx\_mc\_xxxx)からなります(ほとんどが 誤報で良品画像になるハズのものです)。

総合評価画像: 308

評価セット(テストセット)

Bダコン不良	3
S当りキズ	6
Sダコン	20
材料不良	3
Unlabeled Images	276

下記は、全クラス(Bダコン、S当たりキズ、Sダコン、材料不良)における評価結果である。



評価オプション:メトリックで評価する

正解率が高いのは、良品画像の占める割合が高いからである。

本件の評価において、NG 領域がきちんと予測領域に入っているかの指標となる"再現率"(NG をきちんと NG として判断できたか)をみることで判別の是非をみると 59.17%となり十分な結果を得られていないので、判別 済みの不良サンプル数を増やす必要があることがわかる。 特に B ダコンと材料不良、S アタリキズのサンプル数がもっと必要である。 (3) Confusion マトリックスの結果

この結果から分かるように B ダコン不良、S 当りキズ、材料不良のサンプル数が少なく、結果が良くない ことが分かる。これが、再現率が低い主な要因である。

```
混同行列 (by class)
```

- ∎

	Total	Good	Intermediatē
Background	276	245	0
Bダコン不良	3	0	1
S当りキズ	7	3	2
Sダコン	20	14	5
材料不良	3	2	1

Confusion Matrix: Accuracy(正解率)/Precision(適合率)/Recall(再現率)とは・・・・・・

① 判別結果が Positive であり、予測結果が正しい場合 : 真陽性 (True Positive)

② 判別結果が Positive であり、予測結果が誤りの場合: 偽陽性 (False Positive)

③ 判別結果が Negative であり、予測結果が正しい場合: 真陰性 (True Negative)

④ 判別結果が Negative であり、予測結果が誤りの場合: 偽陰性 (False Negative)

正解が陽の場合

正解が陰の場合

分類した結果が 陽の場合	TP 真陽性 True Positive	FP 偽陽性 False Positive
分類した結果が 陰の場合	FN 偽陰性 False Negative	TN 真陰性 True Negative

例えば画像認識などで、ライオンの画像を正しくライオンと判別した場合はその判定結果は真陽性に、ライオンではない と判別されれば偽陰性にカウントされる。同様に、ライオンではない画像をライオンであると判別した場合は偽陽性に、ラ イオンではないと正しく判別した場合は真陰性にカウントされる。

		算出式	概要
Accuracy (	正解率)	(TP + TN) / (TP + FP + TN + FN)	判別の正解率。全体のうちでどれだけが正しく判別できたか。
<b>Recall</b> (‡	再現率)	TP / (TP + FN)	Positiveのデータのうち、どれだけをPositiveと判別できたか
Precision (	適合率)	TP / (TP + FP)	Positiveと判断されたデータのうち、どれだけが正しく判別できたか
Specificity (	(特異性)	TN / (TN + FP)	Negativeのデータのうち、どれだけをNegativeと判別できたか



## (4) それぞれの撮像系での検知結果の対比 (既に目視で検査確認されているサンプル)

	ファイル名	判定	Class	ファイル名	判定	Class
	レイマック撮像系			ミスズ工業の撮像系		
1	Leimac L_Bダコン1.png	NG	Class1(Bダコン不良)	MSZ_M_B M_B外 コン1.png	NG	Class1(Bダコン不良)
2	Leimac L_Bダコン2.png	NG	Class1(Bダコン不良)	MSZ_M_B M_B୬ ፝ጋን2.png	NG	Class1(Bダコン不良)
3	Leimac L_Bダコン3.png	NG	Class1(Bダコン不良)	MSZ_M_B M_B୬ ፝ጋን3.png	NG	Class1(Bダコン不良)
4	Leimac L_Bダコン4.png	NG	Class1(Bダコン不良)	MSZ_M_B M_B୬ ፞ጏን4.png	NG	Class1(Bダコン不良)
5	Leimac L_Bダコン5.png	NG	Class1(Bダコン不良)	MSZ_M_B M_B外 コン5.png	ОК	
6	Leimac L_Bダコン6.png	ОК		MSZ_M_B M_B୬ ፝ጋን6.png	NG	Class1(Bダコン不良)
7	Leimac L_Bダコン7.png	NG	Class1(Bダコン不良)	MSZ_M_B M_B୭゙コン7.png	NG	Class1(Bダコン不良)
8	Leimac L_Bダコン8.png	ОК		MSZ_M_B M_B外 3>8.png	NG	Class1(Bダコン不良)

① B ダコン不良について、本来であれば NG であるが、下記のように OK と判別されるケースがある。

それぞれの B ダコンサンプルの画像は下記のようになる。









② S アタリキズについて、本来であれば NG であるが、下記のように OK と判別されるケースがある。

180 Leimac L_Sアタリキズ_白1-1.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ1.png NG Class2(S当りキズ)
181 Leimac L_Sアタリキズ_白10.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ10.png NG Class2(S当りキズ)
182 Leimac L_Sアタリキズ_白11.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ11.png NG Class2(S当りキズ)
183 Leimac L_Sアタリキズ_白12.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ12.png NG Class2(S当りキズ)
184 Leimac L_Sアタリキズ_白13.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ13.png NG Class2(S当りキズ)
185 Leimac L_Sアタリキズ_白14.png	ОК		MSZ_M_S M_Sアタリキズ14.png NG Class2(S当りキズ)
186 Leimac L_Sアタリキズ_白15.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ15.png NG Class2(S当りキズ)
187 Leimac L_Sアタリキズ_白16.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ16.png NG Class2(S当りキズ)
192 Leimac L_Sアタリキズ_白20.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ20.png NG Class2(S当りキズ)
193 Leimac L_Sアタリキズ_白21.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ21.png NG Class2(S当りキズ)
-194 Leimac L_Sアタリキズ_白22.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ22.png OK
-195 Leimac L_Sアタリキズ_白24.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ24.png NG Class2(S当りキズ)
199 Leimac L_Sアタリキズ_白4.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ4.png NG Class2(S当りキズ)
200 Leimac L_Sアタリキズ_白5.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ5.png NG Class2(S当りキズ)
201 Leimac L_Sアタリキズ_白6.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ6.png <b>OK</b>
202 Leimac L_Sアタリキズ_白7.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ7.png NG Class2(S当りキズ)
203 Leimac L_Sアタリキズ_白8.png	NG	Class2(S当りキズ)	MSZ_M_S M_Sアタリキズ8.png NG Class2(S当りキズ)

## それぞれの S アタリキズサンプルの画像は下記のようになる。









③ S ダコンについて、本来であれば NG であるが、下記のように OK と判別されるケースがある。

220 Leimac L_Sダコン17_I	DR.png NG	Class3(Sダコン)	M	SZ_M_S M_Sダコン17.png	NG	Class3(Sダコン)
221 Leimac L_Sダコン18.p	ng NG	Class3(Sダコン)	M	SZ_M_S M_Sダコン18.png	NG	Class3(Sダコン)
222 Leimac L_Sダコン18_I	DR.png NG	Class3(Sダコン)				
223 Leimac L_Sダコン19.p	ng NG	Class3(Sダコン)	M	SZ_M_S M_Sダコン19.png	NG	Class3(Sダコン)
224 Leimac L_Sダコン19_I	DR.png NG	Class3(Sダコン)				
225 Leimac L_Sダコン1_1_	IDR.png NG	Class3(Sダコン)				
226 Leimac L_Sダコン1_ID	R.png NG	Class3(Sダコン)				
227 Leimac L_Sダコン2.pn	g NG	Class3(Sダコン)	M	SZ_M_S M_Sダコン2.png	NG	Class3(Sダコン)
228 Leimac L_Sダコン20.p	ng OK		М	SZ_M_S M_Sダコン20.png	NG	Class3(Sダコン)
229 Leimac L_Sダコン20_I	DR.png NG	Class3(Sダコン)				
230 Leimac L_Sダコン21.p	ng NG	Class3(Sダコン)	M	SZ_M_S M_Sダコン21.png	NG	Class3(Sダコン)

それぞれの S ダコンサンプルの画像は下記のようになる。



④ S 材料不良については、どちらもすべて NG と判別されており、判別の違いはなかった。

320 Leimac_L_S材料不良1.png	NG	Class4(材料不良)	MSZ_M_S Sボウチョウ・ハクリ(材料不良)1.p NG	Class4(材料不良)
321 Leimac_L_S材料不良2.png	NG	Class4(材料不良)	MSZ_M_S Sボウチョウ・ルクリ(材料不良)2.p NG	Class4(材料不良)
322 Leimac_L_S材料不良2_1.png	NG	Class4(材料不良)		
323 Leimac_L_S材料不良3.png	NG	Class4(材料不良)	MSZ_M_S Sボウチョウ・ハクリ(材料不良)3.p NG	Class4(材料不良)
324 Leimac_L_S材料不良4.png	NG	Class4(材料不良)	MSZ_M_S Sボウチョウ・ルクリ(材料不良)4.p NG	Class4(材料不良)
325 Leimac_L_S材料不良5.png	NG	Class4(材料不良)	MSZ_M_S Sボウチョウ・ルクリ(材料不良)5.p NG	Class2(S当りキズ)
326 Leimac_L_S材料不良6.png	NG	Class4(材料不良)	MSZ_M_S Sボウチョウ・ルクリ(材料不良)6.p NG	Class4(材料不良)
327 Leimac_L_S材料不良7.png	NG	Class4(材料不良)	MSZ_M_S Sボウチョウ・ルクリ(材料不良)7.p NG	Class4(材料不良)
328 Leimac_L_S材料不良8.png	NG	Class4(材料不良)	MSZ_M_S Sボウチョウ・ハクリ(材料不良)8.p NG	Class4(材料不良)

⑤ 唯一良品を不良品に判別したケースが MSZ の撮像系で発生

329	MSZ_M_B M_B良品1.png	OK	
330	MSZ_M_B M_B良品10.png	OK	
331	MSZ_M_B M_B良品11.png	ОК	
332	MSZ_M_B M_B良品12.png	NG	Class1(Bダコン不良)
333	MSZ_M_B M_B良品13.png	ОК	
334	MSZ_M_B M_B良品14.png	OK	
335	MSZ_M_B M_B良品15.png	OK	
336	MSZ_M_B M_B良品16.png	OK	
337	MSZ_M_B M_B良品17.png	OK	
338	MSZ_M_B M_B良品18.png	ОК	





⑥ 既存の検査装置が不良と判定した製品に関するそれぞれの撮像系での検知結果の対比

下記は、不良と判定されたが誤報である可能性が高いものである。

	Βダコン	サビ
-	0/-/	~ _

46	 Leimac L_MC_Bダコン_サビ10_IDR.pr OK		MSZ_M_B M_mcB9 ፞]ን&ቻኒ 10.pn OK	
47	7 Leimac L_MC_Bダコン_サビ11_IDR.pr OK		MSZ_M_B M_mcB9 ፞]ን&サビ11.pn OK	
48	B Leimac L_MC_Bダコン_サビ12_IDR.pr OK		MSZ_M_B M_mcB9 ፞]ን&サビ12.pn OK	
49	) Leimac L_MC_Bダコン_サビ13_IDR.pr <b>NG</b>	Class1(Bダコン不良)	MSZ_M_B M_mcB9 ፝]ን&サビ13.pn OK	
50	) Leimac L_MC_Bダコン_サビ14_IDR.pr OK		MSZ_M_B M_mcB9 ንጋን& ታኒ 14.pn OK	
51	Leimac L_MC_Bダコン_サビ15_IDR.pr OK		MSZ_M_B M_mcB9 ንጋን & ምኒ ነ5.pn OK	
52	2 Leimac L_MC_Bダコン_サビ16_IDR.pr OK		MSZ_M_B M_mcB9 ንጋን & ምኒ ነ6.pn OK	
53	3 Leimac L_MC_Bダコン_サビ17_IDR.pr OK		MSZ_M_B M_mcB9 ንጋን & ምኒ ነ 17.pn OK	
54	Leimac L_MC_Bダコン_サビ18_IDR.pr OK		MSZ_M_B M_mcB9 ፝]ን&ቻኒ ፝18.pn OK	
55	5 Leimac L_MC_Bダコン_サビ19_IDR.pr OK		MSZ_M_B M_mcB9 ፝]ን&ቻኒ ፝ 19.pn OK	
56	5 Leimac L_MC_Bダコン_サビ1_1_IDR.r OK			
57	7 Leimac L_MC_Bダコン_サビ1_2_IDR.r OK			
58	3 Leimac L_MC_Bダコン_サビ1_IDR.pncOK		MSZ_M_B M_mcB9 ፝]ን&サビ1.png OK	
59	) Leimac L_MC_Bダコン_サビ20_IDR.pr OK		MSZ_M_B M_mcB9 ንን& ታኒ 20.pn NG	Class1(Bダコン不良)
60	) Leimac L_MC_Bダコン_サビ21_IDR.pr OK		MSZ_M_B M_mcB9 ) & #t 21.pn OK	
61	Leimac L_MC_Bダコン_サビ22_IDR.pr OK		MSZ_M_B M_mcB9 ) & 世 22.pn OK	
62	2 Leimac L_MC_Bダコン_サビ23_IDR.pr OK		MSZ_M_B M_mcB9 ) & 世 23.pn OK	
63	3 Leimac L_MC_Bダコン_サビ24_IDR.pr OK		MSZ_M_B M_mcB9 ) & #½ 24.pn OK	
64	Leimac L_MC_Bダコン_サビ25_IDR.pr OK		MSZ_M_B M_mcB9 ፝]ን&サビ25.pn OK	
65	Leimac L_MC_Bダコン_サビ26_IDR.pr OK		MSZ_M_B M_mcB9 ፝]ን&サビ26.pn <b>NG</b>	Class1(Bダコン不良)
66	Leimac L_MC_Bタコン_サビ27_IDR.pr OK		MSZ_M_B M_mcB9 ) & #t 27.pn OK	
67	Leimac L_MC_Bタコン_サビ28_IDR.pr OK		MSZ_M_B M_mcB9 <sup>*</sup> ]>&#t<sup>*</sup>28.pn NG</td><td>Class1(Bタコン个良)</td></tr><tr><td>68</td><td></td><td></td><td>MSZ_M_B M_mcB9 12&9(29.pn NG</td><td>Class1(Bタコン不良)</td></tr><tr><td>65</td><td></td><td></td><td> MSZ_M_B M_mcB9 J2&9( 2.png OK</td><td></td></tr><tr><td>70</td><td></td><td></td><td>MSZ_M_B M_mcB/ ]/&/( 30.ph OK</td><td></td></tr><tr><td>71</td><td></td><td></td><td>MSZ_M_B M_mcB# ]/&#( 31.ph OK</td><td></td></tr><tr><td>72</td><td></td><td></td><td>MSZ_M_B_M_mcB#_J2&9t_32.pn NC</td><td>Class1/Dダコン不自)</td></tr><tr><td>73</td><td>Leimac L_MC_Bタゴノ_9E33_IDR.pr OK</td><td></td><td>MSZ_M_B_M_mcB/ 1/8/f 33.ph NG</td><td>Class1(Bタコノ小皮)</td></tr><tr><td>7</td><td></td><td></td><td>MSZ_M_B_M_mcB#128.#k*25 pp NC</td><td>Clace1(Dダコン,不白)</td></tr><tr><td>70</td><td></td><td></td><td>MS7_M_B_M_mcB/*128.9#k*26 np_OK</td><td></td></tr><tr><td></td><td></td><td></td><td></td><td></td></tr><tr><td>11</td><td>Leimac L_MC_BYJY_7E37_IDR.pr OK</td><td></td><td> MSZ_M_B M_mcB9 J2&90 37.pn OK</td><td></td></tr><tr><td>78</td><td>Leimac L_MC_Bダコン_サビ38_IDR.pr OK</td><td></td><td>MSZ_M_B M_mcB9*]>&#t*38.pn OK</td><td></td></tr><tr><td>79</td><td>Leimac L_MC_Bダコン_サビ39_IDR.pr OK</td><td></td><td>MSZ_M_B M_mcBダ]ン&サビ39.pn OK</td><td></td></tr><tr><td>80</td><td>Leimac L_MC_Bダコン_サビ3_IDR.pncのK</td><td></td><td>MSZ_M_B M_mcB9°]>&#t°3.png OK</td><td></td></tr><tr><td>81</td><td>Leimac L_MC_Bダコン_サビ40_IDR.pr OK</td><td></td><td>MSZ_M_B M_mcB9*ጋን&ቻኒ*40.pn NG</td><td>Class1(Bダコン不良)</td></tr><tr><td>82</td><td>Leimac L_MC_Bダコン_サビ4_IDR.pnc NG</td><td>Class1(Bダコン不良)</td><td>MSZ_M_B M_mcB9°]>&#t°4.png OK</td><td></td></tr><tr><td>83</td><td>Leimac L_MC_Bダコン_サビ5_IDR.pnc OK</td><td></td><td>MSZ_M_B M_mcBፇ*]ን&サヒ*5.png NG</td><td>Class1(Bダコン不良)</td></tr><tr><td>84</td><td>Leimac L_MC_Bダコン_サビ6_IDR.pnc OK</td><td></td><td>MSZ_M_B M_mcB9°]>&#t°6.png OK</td><td></td></tr><tr><td>85</td><td>Leimac L_MC_Bダコン_サビ7_IDR.pnc OK</td><td></td><td>MSZ_M_B M_mcB9°]>&#t°7.png OK</td><td></td></tr><tr><td>86</td><td>Leimac L_MC_Bダコン_サビ8_IDR.pnc OK</td><td></td><td>MSZ_M_B M_mcB9° ]>&#t°8.pna OK</td><td></td></tr><tr><td>87</td><td>Leimac L MC Bダコン サビ9 IDR.pnc OK</td><td></td><td> MSZ M B M mcB9*1>&#t*9.png OK</td><td></td></tr><tr><td></td><td>and a state of the state of the</td><td></td><td>and the second state of th</td><td></td></tr></tbody></table>	

> 傾向としては、MSZ 撮像系で多くNGとして検出されている

> NGとして検出されている個所の大きさは微小である傾向がある

> 10個が NG として判別された。



それぞれの画像は下記のようになります。



● 一般社団法人 インダストリアル・バリューチェーン・イニシアティブ



Leimac L\_MC\_Bダコン\_サゼ28\_IDFOK MSZ\_M\_B M\_mcBがつう&サビ\*28,p NG Class1(Bグコン不良)

















Leimac L\_MC\_Bダコン\_サビ5\_IDR OK MSZ\_M\_B M\_mcBダコン&サビ5.p NG Class1(Bダコン不良)





# ● MC\_S アタリキズ

88	Leimac L_MC_Sあたりキズ10_IDR.pncのK			MSZ_M_S M_mcSアタリキズ10.png	OK	
89	Leimac L_MC_Sあたりキズ11_IDR.pnc <b>NG</b>	Class2(S当りキズ)		MSZ_M_S M_mcSアタリキズ11.png	OK	
90	Leimac L_MC_Sあたりキズ12_IDR.pncのK			MSZ_M_S M_mcSアタリキズ12.png	OK	
91	Leimac L_MC_Sあたりキズ13_1_IDR.r OK					
92	Leimac L_MC_Sあたりキズ13_IDR.pncのK			MSZ_M_S M_mcSアタリキス*13.png	NG	Class3(Sダコン)
93	Leimac L_MC_Sあたりキズ14_IDR.pn <u>c</u> OK			MSZ_M_S M_mcSアタリキズ14.png	OK	
94	Leimac L_MC_Sあたりキズ15_IDR.pncのK			MSZ_M_S M_mcSアタリキズ15.png	OK	
95	Leimac L_MC_Sあたりキズ16_IDR.pn <u>c</u> OK			MSZ_M_S M_mcSアタリキズ16.png	OK	
96	Leimac L_MC_Sあたりキズ17_1_IDR. <mark>r NG</mark>	Class3(Sダコン)				
97	Leimac L_MC_Sあたりキズ17_IDR.pn <u>c</u> OK			MSZ_M_S M_mcSアタリキズ17.png	OK	
130	Leimac L_MC_Sあたりキズ3_IDR.png OK			MSZ_M_S M_mcSアタリキズ3.png	ОК	
131	Leimac L_MC_Sあたりキズ40_IDR.pnc OK			MSZ_M_S M_mcSアタリキズ40.png	OK	
132	Leimac L_MC_Sあたりキズ41_IDR.pnc OK			MSZ_M_S M_mcSアタリキズ41.png	OK	
133	Leimac L_MC_Sあたりキズ4_IDR.png NG	Class2(S当りキズ)	Class3	MSZ_M_S M_mcSアタリキズ4.png	OK	
134	Leimac L_MC_Sあたりキズ5_1_IDR.pr OK					

# それぞれの画像は以下の通り。





レイマックの撮像系で同じサンプルに対して照明の当て方の角度が変わってしまった撮像を比較したものになるが、右 図では S ダコン様のアタリキズとして判別されている。照明の入射角によっては、このような事になることを示唆してい る。






● MC\_S ダコン

142Leimac L MC $S$ $S$ J $\Sigma$ J $\Omega$ , mgOKMSZ M $S$ M $C$ $S$ $T$ $\Sigma$ J $\Omega$ , mgOK143Leimac L MC $S$ $S$ $T$ $\Sigma$ $S$ $T$ $T$ $S$										
143      Leimac L_MC_Sゲコン10.png      OK      MSZ_M_S M_mcS%" j>10.png      OK        144      Leimac L_MC_Sゲコン11.png      OK      MSZ_M_S M_mcS%" j>121.png      OK        144      Leimac L_MC_Sゲコン12.png      OK      MSZ_M_S M_mcS%" j>121.png      OK        146      Leimac L_MC_Sゲコン13.png      OK      MSZ_M_S M_mcS%" j>14.png      OK        147      Leimac L_MC_Sゲコン15.png      OK      MSZ_M_S M_mcS%" j>16.png      OK        148      Leimac L_MC_Sゲコン15.png      OK      MSZ_M_S M_mcS%" j>16.png      OK        150      Leimac L_MC_Sゲコン15.png      OK      MSZ_M_S M_mcS%" j>17.png      OK        151      Leimac L_MC_Sゲコン17.png      OK      MSZ_M_S M_mcS%" j>18.png      OK        152      Leimac L_MC_Sゲコン2.png      OK      MSZ_M_S M_mcS%" j>19.png      OK        153      Leimac L_MC_Sゲコン2.png      OK      MSZ_M_S M_mcS%" j>22.png      OK        154      Leimac L_MC_Sゲコン2.png      OK      MSZ_M_S M_mcS%" j>22.png      OK        154      Leimac L_MC_Sゲコン2.png      OK      MSZ_M_S M_mcS%" j>23.png      OK        155      Leimac L_MC_Sゲコン3.png      OK <td< td=""><td></td><td>142 Leim</td><td>ac L_MC_Sダコン1.png</td><td></td><td>OK</td><td>MSZ_M_S M</td><td>_mcSダ]ン1.png</td><td>OK</td><td></td><td></td></td<>		142 Leim	ac L_MC_Sダコン1.png		OK	MSZ_M_S M	_mcSダ]ン1.png	OK		
144      Leimac L_MC_SAJ>11.png      OK      MSZ_M_S M_mcSAJ11.png      OK      MSZ_M_S M_mcSAJ11.png      OK      Class3(SAJ2)        145      Leimac L_MC_SAJ2113.png      OK      MSZ_M_S M_mcSAJ113.png      OK      Class3(SAJ2)        146      Leimac L_MC_SAJ2113.png      OK      MSZ_M_S M_mcSAJ114.png      OK         147      Leimac L_MC_SAJ2114.png      OK      MSZ_M_S M_mcSAJ114.png      OK         148      Leimac L_MC_SAJ215.png      OK      MSZ_M_S M_mcSAJ114.png      OK         149      Leimac L_MC_SAJ215.png      OK      MSZ_M_S M_mcSAJ114.png      OK         150      Leimac L_MC_SAJ215.png      OK      MSZ_M_S M_mcSAJ114.png      OK         151      Leimac L_MC_SAJ217.png      OK      MSZ_M_S M_mcSAJ114.png      OK         152      Leimac L_MC_SAJ214.png      OK      MSZ_M_S M_mcSAJ114.png      OK         154      Leimac L_MC_SAJ22.png      OK      MSZ_M_S M_mcSAJ12.png      OK         155      Leimac L_MC_SAJ22.png      OK      MSZ_M_S M_mcSAJ12.png      OK    <		143 Leim	ac L_MC_Sダコン10.png		OK	MSZ_M_S M	_mcSダコン10.png	OK		
145      Leimac L_MC_Sダコン12.png      OK      MSZ_M_S M_mcS9" 12.png      NG      Class3(Sダコン)        146      Leimac L_MC_Sダコン13.png      OK      MSZ_M_S M_mcS9" 113.png      OK         147      Leimac L_MC_Sダコン14.png      OK      MSZ_M_S M_mcS9" 114.png      OK         148      Leimac L_MC_Sダコン15.png      OK      MSZ_M_S M_mcS9" 115.png      OK         149      Leimac L_MC_Sダコン16.png      OK      MSZ_M_S M_mcS9" 117.png      OK         150      Leimac L_MC_Sダコン17.png      OK      MSZ_M_S M_mcS9" 117.png      OK         151      Leimac L_MC_Sダコン18.png      OK      MSZ_M_S M_mcS9" 117.png      OK         152      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9" 112.png      OK         155      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9" 112.png      OK         156      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9" 112.png      OK         156      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9" 112.png      OK         157      Leimac L_MC_Sダコン20.p		144 Leim	ac L_MC_Sダコン11.png		OK	MSZ_M_S M	_mcSダ]ン11.png	OK		
146      Leimac L_MC_Sダ⊐>13.png      OK      MSZ_M_S M_mcS9*]>13.png      OK        147      Leimac L_MC_Sグ⊐>14.png      OK      MSZ_M_S M_mcS9*]>14.png      OK        148      Leimac L_MC_Sグ⊐>15.png      OK      MSZ_M_S M_mcS9*]>15.png      OK        149      Leimac L_MC_Sグ⊐>15.png      OK      MSZ_M_S M_mcS9*]>15.png      OK        150      Leimac L_MC_Sグ⊐>15.png      OK      MSZ_M_S M_mcS9*]>17.png      OK      Class3(Sグ⊐>)        151      Leimac L_MC_Sグ⊐>18.png      OK      MSZ_M_S M_mcS9*]>19.png      OK		145 Leim	ac L_MC_Sダコン12.png		OK	MSZ_M_S M	_mcSダ]ン12.png	NG	Class3(S5	<b>ブコン)</b>
147      Leimac L_MC_SIJ > 14.png      OK      MSZ_M_S M_mcSiJ > 14.png      OK      MSZ_M_S M_mcSiJ > 14.png      OK        148      Leimac L_MC_SIJ > 15.png      OK      MSZ_M_S M_mcSiJ > 15.png      OK      OK        150      Leimac L_MC_SIJ > 15.png      OK      MSZ_M_S M_mcSiJ > 15.png      OK      OK        151      Leimac L_MC_SIJ > 17.png      OK      MSZ_M_S M_mcSiJ > 17.png      OK      OK        152      Leimac L_MC_SIJ > 17.png      OK      MSZ_M_S M_mcSiJ > 19.png      OK		146 Leim	ac L_MC_Sダコン13.png		OK	MSZ_M_S M	_mcSダコン13.png	OK		
148      Leimac L_MC_Sダコン15.png      OK      MSZ_M_S M_mcS9* jン15.png      OK        149      Leimac L_MC_Sダコン15_1.png      OK      MSZ_M_S M_mcS9* jv16.png      NG      Class3(Sダコン)        150      Leimac L_MC_Sダコン15.png      OK      MSZ_M_S M_mcS9* jv17.png      OK      Class3(Sグコン)        151      Leimac L_MC_Sグコン17.png      OK      MSZ_M_S M_mcS9* jv18.png      OK		147 Leim	ac L_MC_Sダコン14.png		OK	MSZ_M_S M	_mcSダ]ン14.png	OK		
149    Leimac L_MC_Sダコン15_1.png    OK    MSZ_M_S M_mcS%*)16.png    NG    Class3(Sダコン)      150    Leimac L_MC_Sダコン17.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(Sダコン)      152    Leimac L_MC_Sダコン17.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(Sダコン)      153    Leimac L_MC_Sダコン18.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(Sダコン)      154    Leimac L_MC_Sダコン19.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(SØ3)      154    Leimac L_MC_SØコン2.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(SØ3)      155    Leimac L_MC_SØコン2.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(SØ3)      155    Leimac L_MC_SØコン2.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(SØ3)      156    Leimac L_MC_SØコン2.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(SØ3)      159    Leimac L_MC_SØコン2.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(SØ3)      159    Leimac L_MC_SØコン3.png    OK    MSZ_M_S M_mcS%*)17.png    OK    Class3(SØ3)      159    Leimac L_MC_SØ33.png    OK		148 Leim	ac L_MC_Sダコン15.png		OK	MSZ_M_S M	_mcSダ]ン15.png	OK		
150      Leimac L_MC_Sダコン16.png      OK      MSZ_M_S M_mcS%"]ン16.png      NG      Class3(Sダコン)        151      Leimac L_MC_Sダコン17.png      OK      MSZ_M_S M_mcS%"]ン17.png      OK        152      Leimac L_MC_Sダコン18.png      OK      MSZ_M_S M_mcS%"]ン18.png      OK        153      Leimac L_MC_Sダコン19.png      OK      MSZ_M_S M_mcS%"]ン19.png      OK        154      Leimac L_MC_SØコン2.png      OK      MSZ_M_S M_mcS%"]ン20.png      OK        155      Leimac L_MC_SØコン20.png      OK      MSZ_M_S M_mcS%"]ン20.png      OK        155      Leimac L_MC_SØコン20.png      OK      MSZ_M_S M_mcS%"]ン20.png      OK        156      Leimac L_MC_SØコン20.png      OK      MSZ_M_S M_mcS%"]ン20.png      OK        158      Leimac L_MC_SØコン20.png      OK      MSZ_M_S M_mcS%"]ン20.png      OK        159      Leimac L_MC_SØコン20.png      OK      MSZ_M_S M_mcS%"]ン20.png      OK        159      Leimac L_MC_SØコン20.png      OK      MSZ_M_S M_mcS%"]ン30.png      OK        159      Leimac L_MC_SØコン30.png      OK      MSZ_M_S M_mcS%"]ン30.png      OK        1      Leimac L_MC_SØコン30.png      O		149 Leim	ac L_MC_Sダコン15_1.pn	g	OK					
151      Leimac L_MC_Sダコン17.png      OK      MSZ_M_S M_mcS9*j)17.png      OK      MSZ_M_S M_mcS9*j)17.png      OK        152      Leimac L_MC_Sダコン18.png      OK      MSZ_M_S M_mcS9*j)18.png      OK         153      Leimac L_MC_Sダコン19.png      OK      MSZ_M_S M_mcS9*j)19.png      OK         154      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*j)20.png      OK         155      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*j)20.png      OK         156      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*j)22.png      OK         157      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*j)22.png      OK         159      Leimac L_MC_Sダコン32.png      OK      MSZ_M_S M_mcS9*j)24.png      OK         1      Leimac L_MC_Sダコン32.png      OK      MSZ_M_S M_mcS9*j)24.png      OK         1      Leimac L_MC_Sダコ>3.png      OK      MSZ_M_S M_mcS9*j)24.png      OK         1      Leimac L_MC_Sダコ>3.png      OK      MSZ_M_S M_mcS9*j)34.png      OK         2      L		150 Leim	ac L_MC_Sダコン16.png		OK	MSZ_M_S M	_mcSダ]ン16.png	NG	Class3(S5	ブコン)
152      Leimac L_MC_Sダコン18.png      OK      MSZ_M_S M_mcS9*3/18.png      OK        153      Leimac L_MC_Sダコン19.png      OK      MSZ_M_S M_mcS9*3/19.png      OK        154      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*3/20.png      OK        155      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9*3/20.png      OK        156      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9*3/20.png      OK        157      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9*3/20.png      OK        157      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9*3/20.png      OK        158      Leimac L_MC_Sダコン20.png      OK      MSZ_M_S M_mcS9*3/20.png      OK        159      Leimac L_MC_Sダコン30.png      OK      MSZ_M_S M_mcS9*3/20.png      OK        1      Leimac L_MC_Sダコン30.png      OK      MSZ_M_S M_mcS9*3/30.png      OK        1      Leimac L_MC_Sダコン30.png      OK      MSZ_M_S M_mcS9*3/30.png      OK        1      Leimac L_MC_Sダコン30.png      OK      MSZ_M_S M_mcS9*3/30.png      OK        1      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9*3/		151 Leim	ac L_MC_Sダコン17.png		OK	MSZ_M_S M	_mcSダ]ン17.png	OK		
153      Leimac L_MC_Sダコン19.png      OK      MSZ_M_S M_mcS9*J>19.png      OK        154      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*J>2.png      OK        155      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*J>2.png      OK        155      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*J>2.png      OK        156      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*J>2.png      OK        157      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*J>2.png      OK      Class3(Sダコン)        158      Leimac L_MC_Sダコン2.png      OK      MSZ_M_S M_mcS9*J>2.png      OK      Class3(Sダコン)        159      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9*J>2.png      OK      OK        9      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9*J>3.png      NG        1      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9*J>3.png      OK        1      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9*J>3.png      OK        1      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9*J>3.png      OK        1      Leimac L_MC_SØJ>3.pn		152 Leim	ac L_MC_Sダコン18.png		OK	MSZ_M_S M	_mcSダ]ン18.png	OK		
154      Leimac L_MC_Sゲコン2.png      OK      MSZ_M_S M_mcS9*]>2.png      OK      MSZ_M_S M_mcS9*]>2.png      OK        155      Leimac L_MC_Sゲコン2.png      OK      MSZ_M_S M_mcS9*]>2.png      OK      Image: Comparison of the partial state of the		153 Leim	ac L_MC_Sダコン19.png		OK	MSZ_M_S M	_mcSダコン19.png	OK		
155    Leimac L_MC_Sダコン20.png    OK    MSZ_M_S M_mcS𝔅*j>20.png    OK      156    Leimac L_MC_Sダコン21.png    OK    MSZ_M_S M_mcS𝔅*j>22.png    OK      157    Leimac L_MC_Sダコン22.png    OK    MSZ_M_S M_mcS𝔅*j>22.png    OK      158    Leimac L_MC_Sダコン23.png    OK    MSZ_M_S M_mcS𝔅*j>22.png    NG    Class3(Sダコン)      159    Leimac L_MC_Sダコン32.png    OK    MSZ_M_S M_mcS𝔅*j>24.png    NG    Class3(Sダコン)      159    Leimac L_MC_Sダコン32.png    OK    MSZ_M_S M_mcS𝔅*j>24.png    OK    MSZ_M_S M_mcS𝔅*j>24.png    OK      159    Leimac L_MC_Sダコン33.png    OK    MSZ_M_S M_mcS𝔅*j>33.png    NG      0    Leimac L_MC_Sダコン35.png    OK    MSZ_M_S M_mcSF*j>33.png    OK      1    Leimac L_MC_Sダコン35.png    OK    MSZ_M_S M_mcSF*j>3.png    OK      2    Leimac L_MC_Sダコン35.png    OK    MSZ_M_S M_mcSF*j>4.png    OK      3    Leimac L_MC_Sダコン3.png    OK    MSZ_M_S M_mcSF*j>4.png    OK      4    Leimac L_MC_Sダコン3.png    OK    MSZ_M_S M_mcSF*j>5.png    OK      5    Leimac L_MC_Sダコン3.png    OK    MSZ_M_S M_mcSF*j>6.png<		154 Leim	ac L_MC_Sダコン2.png		OK	MSZ_M_S M	_mcSダコン2.png	OK		
156    Leimac L_MC_Sダコン21.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )21.png    OK      157    Leimac L_MC_Sダコン22.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )22.png    OK      158    Leimac L_MC_Sダコン23.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )22.png    OK    Class3(Sダコン)      159    Leimac L_MC_Sダコン24.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )23.png    OK    OK      9    Leimac L_MC_Sダコン32.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png    OK    OK      9    Leimac L_MC_Sダコン32.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png    OK    OK      9    Leimac L_MC_Sダコン32.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png    OK    OK      9    Leimac L_MC_Sダコン33.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png    OK      1    Leimac L_MC_Sダコン35.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png    OK      1    Leimac L_MC_Sダコン35.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png    OK      1    Leimac L_MC_Sダコン35.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png    OK      1    Leimac L_MC_Sダコン3.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png    OK      2    Leimac L_MC_Sダコン4.png    OK    MSZ_M_S M_mcS% <sup>1</sup> )24.png		155 Leim	ac L_MC_Sダコン20.png		OK	MSZ_M_S M	_mcSダ]>20.png	OK		
157    Leimac L_MC_Sダコン22.png    OK    MSZ_M_S M_mcS9* J>22.png    OK      158    Leimac L_MC_Sダコン24.png    OK    MSZ_M_S M_mcS9* J>24.png    OK    Class3(Sダコン)      159    Leimac L_MC_Sダコン32.png    OK    MSZ_M_S M_mcS9* J>24.png    OK    OK      9    Leimac L_MC_Sダコン32.png    OK    MSZ_M_S M_mcS9* J>24.png    OK    OK      9    Leimac L_MC_Sダコン33.png    OK    MSZ_M_S M_mcS9* J>32.png    OK    OK      9    Leimac L_MC_Sダコン34.png    OK    MSZ_M_S M_mcS9* J>34.png    OK      1    Leimac L_MC_Sダコン35.png    OK    MSZ_M_S M_mcS9* J>35.png    OK      1    Leimac L_MC_Sダコン35.1.png    OK    MSZ_M_S M_mcS9* J>4.png    OK      2    Leimac L_MC_Sダコン3.1.png    OK    MSZ_M_S M_mcS9* J>4.png    OK      3    Leimac L_MC_Sダコン5.png    OK    MSZ_M_S M_mcS9* J>4.png    OK      4    Leimac L_MC_Sダコン5.png    OK    MSZ_M_S M_mcS9* J>5.png    OK      5    Leimac L_MC_Sダコン5.png    OK    MSZ_M_S M_mcS9* J>6.png    OK      6    Leimac L_MC_Sダコン5.png    OK    MSZ_M_S M_mcS9* J>5.png    OK		156 Leim	ac L_MC_Sダコン21.png		OK	MSZ_M_S M	_mcSダ]ン21.png	OK		
158      Leimac L_MC_Sダコン23.png      OK      MSZ_M_S M_mcS9* j>23.png      NG      Class3(Sダコン)        159      Leimac L_MC_Sダコン32.png      OK      MSZ_M_S M_mcS9* j>24.png      OK      MSZ_M_S M_mcS9* j>24.png      OK        8      Leimac L_MC_Sダコン32.png      OK      MSZ_M_S M_mcS9* j>24.png      OK      MSZ      MSZ_M_S M_mcS9* j>32.png      OK        9      Leimac L_MC_Sダコン33.png      OK      MSZ_M_S M_mcS9* j>33.png      NG        1      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9* j>35.png      OK        1      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9* j>35.png      OK        2      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9* j>4.png      OK        2      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9* j>4.png      OK        3      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9* j>4.png      OK        4      Leimac L_MC_Sダコン4.png      OK      MSZ_M_S M_mcS9* j>4.png      OK        5      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9* j>5.png      OK        6      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mc		157 Leim	ac L_MC_Sダコン22.png		OK	MSZ_M_S M	_mcSダコン22.png	OK		
159      Leimac L_MC_Sダコン24.png      OK      MSZ_M_S M_mcS9* ]ン24.png      OK      MSZ_M_S M_mcS9* ]ン24.png      OK        9      Leimac L_MC_Sダコン32.png      OK      MSZ_M_S M_mcS9* ]ン32.png      OK      MSZ_M_S M_mcS9* ]ン32.png      OK        9      Leimac L_MC_Sダコン33.png      OK      MSZ_M_S M_mcS9* ]ン34.png      NG        0      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9* ]ン34.png      OK        1      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9* ]ン35.png      OK        2      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9* ]ン4.png      OK        2      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9* ]ン4.png      OK        3      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9* ]ン4.png      OK        4      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9* ]ン4.png      OK        5      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9* ]ン5.png      OK        6      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9* ]ン5.png      OK        7      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9* ]ン5.png      OK		158 Leim	ac L_MC_Sダコン23.png		ОК	MSZ_M_S M	_mcSダコン23.png	NG	Class3(S소	ブコン)
8      Leimac L_MC_Sダコン32.png      OK      MSZ_M_S M_mcS9*1>32.png      OK        9      Leimac L_MC_Sダコン33.png      OK      MSZ_M_S M_mcS9*1>33.png      NG        0      Leimac L_MC_Sダコン34.png      OK      MSZ_M_S M_mcS9*1>33.png      OK        1      Leimac L_MC_Sダコン35.png      OK      MSZ_M_S M_mcS9*1>35.png      OK        2      Leimac L_MC_Sダコン35.1.png      OK      MSZ_M_S M_mcS9*1>35.png      OK        3      Leimac L_MC_Sダコン31.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        4      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        5      Leimac L_MC_Sダコン3.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        5      Leimac L_MC_Sダコン4.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        6      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9*1>5.png      OK        5      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9*1>5.png      OK        6      Leimac L_MC_Sダコン7.png      NG      Class3(Sダコン)      MSZ_M_S M_mcS9*1>7.png      OK        7      Leimac L_MC_Sダコン7.png      NG      MSZ_M_S M_mcS9*1		159 Leim	ac L_MC_Sダコン24.png		ОК	MSZ_M_S M	_mcS9°]>24.png	OK		
Leimac L_MC_Sダゴン33.png    OK    MSZ_M_S M_mcS9*]ン33.png    NG      Leimac L_MC_Sダゴン34.png    OK    MSZ_M_S M_mcS9*]ン34.png    OK      Leimac L_MC_Sダゴン35.png    OK    MSZ_M_S M_mcS9*]ン34.png    OK      Leimac L_MC_Sダゴン35.png    OK    MSZ_M_S M_mcS9*]ン35.png    OK      Leimac L_MC_Sダゴン35.png    OK    MSZ_M_S M_mcS9*]ン4.png    OK      Leimac L_MC_Sダゴン3.1.png    OK    MSZ_M_S M_mcS9*]ン4.png    OK      Leimac L_MC_Sダゴン4.png    OK    MSZ_M_S M_mcS9*]ン5.png    OK      Leimac L_MC_Sダゴン5.png    OK    MSZ_M_S M_mcS9*]ン6.png    OK      Leimac L_MC_Sダゴン6.png    OK    MSZ_M_S M_mcS9*]ン7.png    OK      Leimac L_MC_Sダゴン7.png    NG    Class3(Sダゴン)    Class4(材料不良 MSZ_M_S M_mcS9*]ン7.png    NG      Leimac L_MC_Sダゴン9.png    OK    MSZ_M_S M_mcS9*]ン9.png    OK      Leimac L_MC_Sダゴン9.png    OK    MSZ_M_S M_mcS9*]ン9.png    OK	Le	imac L_MC	こ_Sダコン32.png	ОК			MSZ_M_S M_m	cSダコン	32.png	OK
Leimac L_MC_Sダコン34.pngOKMSZ_M_S M_mcS9*)ン34.pngOKLeimac L_MC_Sダコン35.pngOKMSZ_M_S M_mcS9*)ン35.pngOKLeimac L_MC_Sダコン35_1.pngOKMSZ_M_S M_mcS9*)ン35.pngOKLeimac L_MC_Sダコン3_1.pngOKMSZ_M_S M_mcS9*)ン4.pngOKLeimac L_MC_Sダコン4.pngOKMSZ_M_S M_mcS9*)ン5.pngOKLeimac L_MC_Sダコン5.pngOKMSZ_M_S M_mcS9*)ン5.pngOKLeimac L_MC_Sダコン5.pngOKMSZ_M_S M_mcS9*)ン5.pngOKLeimac L_MC_Sダコン7.pngNGClass3(Sダコン)MSZ_M_S M_mcS9*)ン7.pngNGLeimac L_MC_Sダコン9.pngOKMSZ_M_S M_mcS9*)ン9.pngOKNGLeimac L_MC_Sダコン9.pngOKMSZ_M_S M_mcS9*)ン9.pngOK	l Le	imac L_MC	C_Sダコン33.png	OK			MSZ_M_S M_m	cSダコン	33.png	NG
Leimac L_MC_Sダコン35.pngOKMSZ_M_S M_mcSタ*j>35.pngOKLeimac L_MC_Sダコン35_1.pngOKLeimac L_MC_Sダコン3_1.pngOKLeimac L_MC_Sダコン4.pngOKMSZ_M_S M_mcSタ*j>4.pngOKLeimac L_MC_Sダコン5.pngOKMSZ_M_S M_mcSタ*j>5.pngOKLeimac L_MC_Sダコン5.pngOKMSZ_M_S M_mcSタ*j>5.pngOKLeimac L_MC_Sダコン5.pngOKMSZ_M_S M_mcSタ*j>5.pngOKLeimac L_MC_Sダコン7.pngNGClass3(Sダコン)Class4(材料不良 MSZ_M_S M_mcSタ*j)7.pngNGLeimac L_MC_Sダコン9.pngOKMSZ_M_S M_mcSŷ*j>9.pngOK	Le	imac L_MC	こ_Sダコン34.png	OK			MSZ_M_S M_m	cSダコン	34.png	OK
2      Leimac L_MC_Sダコン35_1.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        3      Leimac L_MC_Sダコン4.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        4      Leimac L_MC_Sダコン4.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        5      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9*1>5.png      OK        6      Leimac L_MC_Sダコン6.png      OK      MSZ_M_S M_mcS9*1>6.png      OK        7      Leimac L_MC_Sダコン7.png      NG      Class3(Sダコン)      Class4(材料不良 MSZ_M_S M_mcS9*1)7.png      NG        8      Leimac L_MC_Sダコン9.png      OK      MSZ_M_S M_mcS9*1)8.png      OK        9      Leimac L_MC_Sダコン9.png      OK      MSZ_M_S M_mcS9*1)9.png      OK	1 Le	imac L_MC	こ_Sダコン35.png	OK			MSZ_M_S M_m	cSダコン	35.png	OK
3      Leimac L_MC_Sダコン3_1.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        4      Leimac L_MC_Sダコン4.png      OK      MSZ_M_S M_mcS9*1>4.png      OK        5      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcS9*1>5.png      OK        6      Leimac L_MC_Sダコン6.png      OK      MSZ_M_S M_mcS9*1>5.png      OK        7      Leimac L_MC_Sダコン7.png      NG      Class3(Sダコン)      Class4(材料不良 MSZ_M_S M_mcS9*1)7.png      NG        8      Leimac L_MC_Sダコン8.png      OK      MSZ_M_S M_mcS9*1>8.png      OK        9      Leimac L_MC_Sダコン9.png      OK      MSZ_M_S M_mcS9*1>9.png      OK	2 Le	imac L_MC	_Sダコン35_1.png	ОК						
4    Leimac L_MC_Sダコン4.png    OK    MSZ_M_S M_mcSタ*jン4.png    OK      5    Leimac L_MC_Sダコン5.png    OK    MSZ_M_S M_mcSタ*jン5.png    OK      6    Leimac L_MC_Sダコン5.png    OK    MSZ_M_S M_mcSタ*jン5.png    OK      7    Leimac L_MC_Sダコン7.png    NG    Class3(Sダコン)    Class4(材料不良 MSZ_M_S M_mcSタ*j)7.png    NG      8    Leimac L_MC_Sダコン9.png    OK    MSZ_M_S M_mcSŷ*j)9.png    OK	3 Le	imac L_MC	_Sダコン3_1.png	OK						
5      Leimac L_MC_Sダコン5.png      OK      MSZ_M_S M_mcSタ*コン5.png      OK        6      Leimac L_MC_Sダコン6.png      OK      MSZ_M_S M_mcS9*コン6.png      OK        7      Leimac L_MC_Sダコン7.png      NG      Class3(Sダコン)      Class4(材料不良 MSZ_M_S M_mcS9*コ)7.png      NG        8      Leimac L_MC_Sダコン8.png      OK      MSZ_M_S M_mcS9*コ)7.png      OK        9      Leimac L_MC_Sダコン9.png      OK      MSZ_M_S M_mcS9*コ)7.png      OK	4 Le	imac L_MC	ニSダコン4.png	OK			MSZ_M_S M_m	cSダコン	4.png	OK
6      Leimac L_MC_Sダコン6.png      OK      MSZ_M_S M_mcS9*1>6.png      OK        7      Leimac L_MC_Sダコン7.png      NG      Class3(Sダコン)      Class4(材料不良 MSZ_M_S M_mcS9*1>7.png      NG        8      Leimac L_MC_Sダコン8.png      OK      MSZ_M_S M_mcS9*1>8.png      OK        9      Leimac L_MC_Sダコン9.png      OK      MSZ_M_S M_mcS9*1>9.png      OK	5 Le	imac L_MC	_Sダコン5.png	ОК			MSZ_M_S M_m	cSダコン	5.png	OK
NG      Class3(Sダコン)      Class4(材料不良 MSZ_M_S M_mcS9*])7.png      NG        8      Leimac L_MC_Sダコン9.png      OK      MSZ_M_S M_mcS9*])8.png      OK        9      Leimac L_MC_Sダコン9.png      OK      MSZ_M_S M_mcS9*])9.png      OK	6 Le	imac L_MC	_Sダコン6.png	ОК			MSZ_M_S M_m	cSダコン	6.png	OK
8 Leimac L_MC_Sダコン8.png OK MSZ_M_S M_mcSダ]ン8.png OK 9 Leimac L_MC_Sダコン9.png OK MSZ_M_S M_mcSダ]ン9.png OK	7 Le	imac L_MC	_Sダコン7.png	NG	Class3(Sダコン)	Class4(材料不	良MSZ_M_S M_m	cSダコン	7.png	NG
9 Leimac L_MC_Sダコン9.png OK MSZ_M_S M_mcSダ]ン9.png OK	8 Le	imac L_MC	こSダコン8.png	OK			MSZ_M_S M_m	cSダコン	8.png	OK
	9 Le	imac L_MC	ニSダコン9.png	OK			MSZ_M_S M_m	cSダコン	9.png	OK

## 5個が NG として判別された。

それぞれの画像は以下の通り。

Leimac L\_MC\_Sダコン12.;OK

















5.3.2.6 NAIT による評価結果の考察

■ レイマックの撮像系、ミスズ工業の既存の検査装置の撮像系の2種類の撮像系で同一サンプルを撮像して、それらの撮像画像を混合して学習、認識モデルを作成、その認識モデルを用いてそれぞれで撮像した各サンプル画像を評価したが、混合したことによる誤報とみられるものはないことが判明しました。また、それなりに認識モデルが出来上がり、有効であることも確認できました(今回のように異なる撮像系のデータも共有して使える)。

■ 目視で既に確認されている不良サンプルについて

それぞれの撮像系において、不良として明確に確認出来ないような撮像画像を OK にしてしまっている 事象が見受けられる。次に不良と判別されなかった撮像画像を列挙する。

改善策として、

- a. 似たような不良及び際どい不良サンプルをさらに増やし、学習させる
- b. 撮像系の倍率を上げる













■ 良品サンプルを不良品として判別してしまった(唯一一つだけだが・・・・・)

このような良品サンプルを追加して学習することで誤報にならないモデルを作る。







#### 5.3.2.7 まとめ

(1) 今回の結果から、さらに不良サンプルを増やして評価することが必要であることが判明した。

再現率が 59.1 パーセントと低いためそのようになっている。

また、Confusion Matrix においても、下記のようになり不良サンプル数が少なすぎることを示唆してる。 混同行列(by class)

	Total	Good	Intermediate
Background	276	245	0
Bダコン不良	3	0	1
S当りキズ	7	3	2
sダコン	20	14	5
材料不良	3	2	1

- (2) AI 画像認識 NAIT を用いることで、複雑な画像処理アルゴリズムを開発する必要もなく、撮像画像デー タを学習することでシンプルに対応出来そうな感触がつかめた(不良個所さえ見えていれば)。 また、今回 2 つの全く異なる撮像系で収集した画像を混合して用いても支障なく動作することが確認でき たことで、材料ロットによる違いによる疑似不良続出といった課題も解決できそうな指標を得ることが出来 た(2 つの全く異なる撮像系で撮像した画像が、材料ロットの違いによる見え方の違いと疑似的に同じと考 えることが出来れば)。
- (3) 今回の不良サンプル数が不十分であるので、さらに不良サンプルを増やして(今回の撮像系を使って) 学習することで、認識モデルに対するさらに緻密な評価が可能となり、実装に向けて具体的な検討が出 来きるようになる。
- (4) AI 画像認識 NAIT においては、撮像系の違いにより見え方というよりも、不良個所が明確に見えている かどうかが重要なポイントである(画像処理では当たり前と言えば当たり前であるが)。 通常の画像処理 では、不良個所が見えていても背景画像の影響も相当受けるので、照明系の調整がたいへんなことにな るのですが、そのようなことによる影響が相当少ない。単純ではあるが、撮像系を試行するとすれば、さら に倍率を上げる、モノクロではなくカラーカメラを使ってみるなどの工夫も有効である。もちろん、照明のあ たる角度も重要である。
- (5) 自動検査装置で不良判別された 116 個のサンプルについては、98%以上が誤報であるが、今回 2 つの 撮像系にて取り込んだ画像を NAIT で判別したところ、116 個中それぞれ 4 個、12 個を不良とした。もし、 これらが誤報としても、116 個あった誤報が 4 個または 12 個になったということでは Over kill が大幅に削 減されたことになる。もちろん、これによって本当の欠陥を見逃していては大いに問題であるが今回は、不 良品サンプル数が少なく厳密な検証が出来ていないため、不良品サンプル数を増やし判別精度を更に追

い込む必要がある。画像 AI を使う事で誤報を最小限に抑え、不良も見逃さないというゴールが期待でき そうである。

混同行列(by class)					
	Total	Good	Intermediate		
Background	276	245	0		
Bダコン不良	3	0	1		
S当りキズ	7	3	2		
sダコン	20	14	5		
材料不良	3	2	1		



前項でも述べたように、正解率が高いのは、良品画像の占める割合が高いことが要因である。今回の評価において、 NG 領域がきちんと予測領域に入っているかの指標となる判別が確実になされているかどうかの是非を"再現率"(NG を きちんと NG として判断できたか) により評価できるが、59.17%となり十分な結果を得られていない。これは、不良サンプ ル数が不足していることを示しており、さらなる不良サンプルを学習させる必要があることを示している。

同ーサンプルを2つの全く異なる撮像系で撮像したものを混合して NAIT ディープラーニングの学習セットとして、判別 モデルを作成したが、顕著な誤報や異常な判別をすることなく使えるものになった。ただし、不良サンプル数が少ない ため再現率を十分上げることが出来なかった。これについては、不良品のサンプル数を増やして学習させることで解消 できる。 本件における実証実験により、ディープラーンングによる画像認識では、ディープラーニングを使わない従来型の画像処理よりも遥かに Robust であり、ある意味人間が画像認識する性能に近いともいえる。

そして、何よりも最大の違いは、従来型画像処理では、人間が画像処理のためのアルゴリズム自体(特徴を抽 出するためのロジック、ルールなど)を開発する必要があるが、ディープラーニングでは、抽出したい画像をアノ テーションするという作業と、それらを学習させれば認識モデルが出来てしまうという、言わば自動化されてい る(特に NAIT の場合には)ので、認識対象が異なる度に画像認識アルゴリズムを開発・作成することが必要な いという点も大きな違いである。また、これまでの従来型画像処理で認識できなかったものが認識できるよう になってしまうといことである。

下記のそれらディープラーンングによる画像認識の5つのアドバンテージを列挙する。

- ① 画像認識のためのアルゴリズム開発を認識したい画像に合わせて、対象物が変わるたびする必要がない
- ② したがって、従来型画像処理よりも開発コストを下げることが出来る
- ③ 背景画像、照明の具合に関わらず、認識したい対象画像が観えていれば問題ない

(但し、対象画像が観えないとか、かなり異なるように観えてしまうような事象がある時には、撮像環境を考慮 する必要がある(人間でも間違えそうなケース)

- ④ 概ね人間が画像認識可能なものであれば、画像認識できると考えて良い
  (従来型画像処理では、そうでもなく、画像認識できないものが圧倒的に多い)
- ⑤ 新しい事象が発生しても追加学習することで対応できるので運用が容易である (従来型画像処理では、その都度、アルゴリズムの修正・変更、または、大がかりな改造が必要となる。 最悪の場合には、作り直しになる。)

部品画像種類ごとに AI 学習モデルを作成し、不良個所を判定する。画像解析には、AI セグメンテー ション手法の 1 つである U-Net [18]を利用する。U-net では、図 5.4-1 に示すように元画像と不良個所を マーキングしたマスク画像(人手でマーキング)を準備して不良品種別ごとに学習モデルを作成した。



図 5.4-1 U-net による学習モデルの作成

学習モデル作成に用いた画像を表 5.4-1 に、評価に用いた画像を表 5.4-2 に示す。

表 5.4-1 学習データに用いた画像

部品	良品画像	不良品画像
5M_S側	21枚 (3倍に水増L)	ダコン:28枚 アタリキズ:18枚

表 5.4-2 評価に用いた画像

部品	MC画像
5M_S側	ダコン:35枚(うち4枚が不良) アタリキズ:41枚(うち3枚が不良)

評価結果を表 5.4-3(アタリキズ)、ダコンの評価結果を表 5.4-4(ダコン)に示す。

表 5.4-3 評価結果(アタリキズ)

	予測+	予測-
正解+	37	2
正解一	2	1

正解率:37/41=0.90 再現率(Recall):37/39=0.94 適合率(Precision):37/39=0.94 特異性(Specificity):1/3=0.33



表 5.4-4 評価結果(ダコン)

	予測+	予測-	
正解十	26	5	
正解一	0	4	

正解率:26/35=0.74 再現率(Recall):26/31=0.83 適合率(Precision):26/26=1.0 特異性(Specificity):4/4=1.0

### 各画像ごとの評価結果を図 5.4-2(アタリキズ)、図 5.4-3(ダコン)に示す。

過剰検知 見逃し M\_mcSa05.jpg M\_mcSa01.jpg M\_mcSa02.jpg M\_mcSa03.jpg M\_mcSa04.jpg M\_mcSa06.jpg M\_mcSa07.jpg M\_mcSa08.jpg M\_mcSa09.jpg M\_mcSa10.jpg M\_mcSa11.jpg M\_mcSa12.jpg M\_mcSa13.jpg M\_mcSa14.jpg M\_mcSa15.jpg M\_mcSa16.jpg M\_mcSa17.jpg M\_mcSa18.jpg M\_mcSa19.jpg M\_mcSa20.jpg M\_mcSa21.jpg M\_mcSa22.jpg M\_mcSa23.jpg M\_mcSa24.jpg M\_mcSa25.jpg M\_mcSa26.jpg M\_mcSa27.jpg M\_mcSa28.jpg M\_mcSa29.jpg M\_mcSa30.jpg M\_mcSa31.jpg M\_mcSa32.jpg M\_mcSa33.jpg M\_mcSa34.jpg M\_mcSa35.jpg M\_mcSa36.jpg M\_mcSa37.jpg M\_mcSa38.jpg M\_mcSa39.jpg M\_mcSa40.jpg M\_mcSa41.jpg

図 5.4-2 画像ごとの評価結果(アタリキズ)







図 5.4-3 画像ごとの評価結果(ダコン)



M\_mcSd10(過剰検知)



M\_mcSd08(過剰検知)



M\_mcSd24(過剰検知)



M\_mcSd35(過剰検知)



M\_mcSd33(過剰検知)



M\_mcSd07(正しく検知)



M\_mcSd12(正しく検知)



M\_mcSd23(正しく検知)

アタリキズ、ダコンともに過剰検知が発生したものの従来の検査装置と比較すると大幅に減少できた。一方、アタリキズ では不良品の見逃しが発生し、課題が残った。



## 5.5. 画像解析事例4

5.5.1 はじめに

OpenCV は、Open Source Computer Vision Library の略称であり、画像処理・画像解析を簡潔なコードで 記述できるライブラリ群である。Linux, Windows などのプラットフォームで利用でき、C++, python 等、多く のプログラミング言語に対応している。とくに python では、配列演算が簡潔に記述できるため、OpenCV と Python の組み合わせは開発効率が極めて高い。

本章では、外観検査の事例において、OpenCV-Python を用いた具体的なプログラミング方法を紹介する。

なお、以下の説明では PyPI(pip でパッケージをインストールする配布形態)を前提としている。

5.5.2 インストール

opencv-python パッケージをインストールすることで OpenCV をすでにインストールされている python へ追加することができる。

pip install opency-python ( $\times$ 1)

使用する場合は

import cv2

でライブラリにアクセスできるようになる。以下、OpenCV-Python を cv2 と表現する。

5.5.3 cv2 での画像ファイルの読み込み

cv2 では、BMP, JPEB, PNG, TIFF, GIF など多くの画像ファイル形式に対応している。このなかで BMP 以 外は、データ圧縮によりファイルサイズを小さくしているが画像の品質が損なわれない可逆圧縮とファイル サイズは小さくなるが保存・読み出しすることで品質が劣化する非可逆圧縮がある。

以下に、それぞれの画像ファイル形式の特徴をまとめた。

BMP (.bmp) : 非圧縮のファイル形式

画像データの配列をそのままファイル化したもの

JPEG (.jpg): 非可逆圧縮のファイル形式

圧縮レベルによりファイルサイズと画像劣化の度合いを調整できる。圧縮率を高くすると ノイ ズが発生する場合があり、画像処理に使用する場合は、圧縮率を低く設定する必要があり注 意が必要である。

PNG (.png): 可逆圧縮のファイル形式

写真のような多数の色がある場合にファイルサイズが大きくなる傾向がある。ノイズが発生す ることがなく画像処理に向いている。

TIFF (.tif): 高解像度・可逆圧縮のファイル形式

ファイルサイズは比較的大きい(1ファイルで複数画像を持てる)

GIF (.gif): 256 色までしか表現できないため画像処理には不向き

複数画像をアニメーション動作させる機能を持ち WEB ページ上で多く利用されている。

これらの画像ファイルを読み込むためには、

img = cv2.imread(<ファイル名>, <読み込み形式>)

とする。画像形式は、自動判別される。

ここで <読み込み形式> は、1: カラーに変換,0: グレースケールに変換,-1: 変換なし であり、読み込 んだ結果 (上の式の img 変数の形式) は、グレースケールの場合、縦画素数×横画素数の2次元配列 であり、カラーの場合は、縦画素数×横画素数×RGB(サイズ3) である。

配列の要素は輝度を表す符号なし8ビット(1 バイト)整数であり、カラーの場合は、各色の輝度である。な お、cv2.imread で読み込んだカラー画像の配列において、色の順序が RGB ではなく BRG となっている ので注意が必要である。Matplotlib など画像を扱う python のライブラリは RGB の順である必要があ り、cv2 には、BGR から RGB に色の順序を変える cv2.cvtColor 関数が用意されている。このとき変換オ プションに cv2.COLOR\_BGR2RGB を指定する。

5.5.4 2 値化

2 値化とは、画像データの配列の各要素を 0(黒) または 255(白) のいずれかの値にすることであり、中間の輝度を持たない完全な白黒画像を生成する処理である。

カラー画像を2値化する場合は、グレースケールに変換する必要があり、画像ファイルを読み込み時にグレースケールを指定するか、カラー画像として読み込んだ後に cv2.cvtColor() 関数を使用して変換オプション cv2.COLOR\_BGR2GLAY を指定する。

また、R,G,B の1つの色空間のみを抽出することでグレースケール画像とすることができる。特定の色の みを抽出したほうが鮮明なグレースケール画像が得られる場合は、この方法が有効である。



例えば、上記のように 緑色のみを抽出する場合は、img[:,:,1] となる。 B, G, R の順序なので 青を抽 出する場合は、img[:,:,0]、赤を抽出する場合は、img[:,:,2] である。

今回使用したサンプル画像では、R,G,B のなかで G(緑色)の成分の変化量が大きく、G(緑色)の成分を 抽出してグレー画像化を行った。



2 値化には、しきい値を指定して cv2.threshold() 関数を用いて行う。

引数は、<グレースケール画像(1 バイトの 2 次元の配列)>,<しきい値>,<しきい値以上の画素に対して割り 当てる値(通常は 255) >,<変換フラグ> であり、<変換フラグ> は、cv2.THRESH\_BINARY を指定する。たと えば、しきい値 120 で 2 値化を行う場合は、

ret, img1 = cv2.threshold( img, 120, 255, cv2.THRESH\_BINARY)

となる。戻り値は2つあり、2つめが2値化画像である。1つめの戻り値は、適用した閾値がそのまま返される。なお cv2 には、しきい値を自動的に設定する機能もあり、その場合、設定されたしきい値が返される。

2 値化を行う前に、コントラスト強調を行うと、画像が鮮明になりしきい値を設定しやすくなる。たとえば、グレースケールの輝度が 100~200 の画像を 0~255 の値を取るように変換するには、一次式を使用して 画素ごとに以下のような計算を行い x(変換前の輝度) → y(変換前の輝度) とする。



Python には、配列のすべての要素に対して、まとめて演算や関数を適用する場合、1行で記述することができる。変換前のグレースケール画像 img に対し、

img2 = ((img - 100.) \* 2.55).clip(0,255).astype(np.uint8)

とすることで、コントラスト強調を行うことができる。ここで clip は、下限、上限で値を制限する関数であり、astype(np.uint8) は、浮動小数点配列で得られた結果を1バイト整数の配列、すなわちグレースケー ル画像に変換するためのものである。

2 値化後の画像に対し、白の部分を含む長方形を切り出す場合は、cv2.boundingRect() 関数を使用し

bx,by,bw,bh = cv2.boundingRect(img1)

とすると bx,by に左上の座標、bw,bh に幅と高さが画素数の単位で得られる。この値を使用して、2次元 配列の一部分を抽出すれば画像を切り出すことができる。配列の部分抽出は、python のスライスという 機能を使用すれば1行で記述することができる。



Img3 = img[by: by + bh, bx: bx + bw]

この範囲を使用して元画像も切り出して、処理の過程を並べたものが下の図である。





5.5.5 疑似カラー化

グレースケール画像を疑似カラー化することで、傷、すなわち、不良箇所を鮮明に可視化することができる。疑似カラー化は、0~255の値を連続的に変化する RGB 値に変換するもので、どのような RGB 値に 変換するかのパターンをカラーマップと呼ぶ。代表的なものとして JET と呼ばれるサーモグラフィーなどに よく使用されるカラーマップがある。



疑似カラー画像への変換は、カラーマップを指定して、cv2.applyColorMap() 関数を用いて行う。カラーマップ JET を用いた疑似カラー化の場合は、

Img4 = cv2.applyColorMap(img, cv2.COLORMAP\_JET)

となる。



疑似カラー化により、アタリキズが鮮明に可視化できることを示したものが以下の図である。



元のグレースケール画像では不鮮明な赤丸部分のアタリキズがコントラスト強調後さらに疑似カラー化を行うことで傷の箇所を見つけやすくなっていることがわかる。

5.5.6 輪郭線抽出

輪郭線抽出は、2 値化画像の黒の部分と白の部分の境界を抽出するものである。輪郭線を抽出する関数 は、cv2.findContours であり、引数の詳しい説明は省略するが以下のようにすることで、輪郭線を階層てき に得ることができる。輪郭線の階層については、後述する。

contours, hierarchy = cv2.findContours(img1,cv2.RETR\_TREE,cv2.CHAIN\_APPROX\_NONE)

2 値化後のサンプル画像の輪郭線を抽出し赤の線で描画したものが以下の図である。アタリキズ付近を拡 大した図において、アタリキズのある個所は外から3番目の輪郭であることが分かる。



実際の画像においては 2 値化を行ってもノイズのような小さな白い点や黒い点が残ることがある。その場合、アタリキズのある輪郭が 3 番目の輪郭にならない場合がある。輪郭は外から順に抽出されるが、輪郭が見つかると、その輪郭の中にある輪郭を優先的に抽出するアルゴリズムになっている。したがって以下の例において、まず1の輪郭が抽出され、次にその中の輪郭を抽出するが、3 の輪郭の前に 2 の輪郭が見つかると 3 の中の 4 の輪郭が外から 3 番目の輪郭にも関わらず 4 番目となる。



実際の例を以下の図に示す。この場合、小さな赤い点が2番目の輪郭となり、アタリキズのある輪郭が4 番目になってしまう。



この状況を回避するためには、たとえば、輪郭を構成する点数が少なければ、ノイズとして無視するように すれば、必要な輪郭のみを抽出することができ、アタリキズのある輪郭を常に3番目にすることができる。 たとえば、輪郭を構成する画素が2000以下のものを無視するようにするのであれば、 idxs = []

for n, cnt in enumerate(contours):

if len(cnt) > 2000: idxs.append(n)

if len(idxs) == 3: break

のようにすれば、必要な輪郭番号のみのリストが idxs に登録され、idxs[2] (リストの番号は 0 から始まるの で idx2[2] が 3 番目) で得られる輪郭番号がアタリキズのある輪郭番号となり、contours(idxs[2]) がアタリ キズのある輪郭となる。

5.5.7 極座標変換

円形の物体の周囲の画像の状況を画像処理する場合において、極座標変換を行うことで処理を単純化で することができ、また可視化において、より異常箇所を見つけやすくすることができる。

極座標変換は、(x, y) 座標を中心からの距離 r と角度 θ で表現するものである。

もっとも簡単な例を以下に示す。内側から赤、緑、青の円があるが、これらは極座標変換すると3本の直線 となる。



たとえば円形のメーターの針の位置を画像処理によって求める場合、メーターの中心に対する極座標変換 を行うことで、目盛りが横に並び、針は左右に動くことになる。ただし、cv2 の極座標変換は、下図の上の図 のように x 軸方向を 0 度として時計回りの角度が θとなる。したがって針の動く範囲、言い換えれば、目 盛りのある範囲が分断されてしまうが、処理後に画像を分割しつなぎなおすことで針の動く範囲を連続にす ることができる。

下図の上の画像目盛りのは 0.5 のところで分断されているが、①と②の部分に分割し下の図ようにつなぎ なおすことで、①、②の部分の目盛りが連続し、針は左右に動くようになるため、針の位置を求める処理が 単純化できる。



下図はアタリキズの疑似カラー化画像を極座標変換し、さらに、アタリキズのある可能性のある部分を 12 倍に引き伸ばしたものである。この画像から傷の程度が容易に判別できるようになり、また、傷の深さを定 量化するアルゴリズムも単純になる。



このときの python プログラムを以下に示す。

img3 = cv2.applyColorMap(img, cv2.COLORMAP\_JET)

axs[0].imshow(cv2.cvtColor(img3, cv2.COLOR\_BGR2RGB))

img4 = cv2.resize(img2[:30], (img.shape[1], 30 \* 12))

img4 = cv2.applyColorMap(img4, cv2.COLORMAP\_JET)

axs[1].imshow(cv2.cvtColor(img4, cv2.COLOR\_BGR2RGB))

なお、axs[0].imshow は、 グラフ描画ライブラリの matplotlib の機能を利用し、画像を出力する関数である。

下図は、同じ方法で2つのアタリキズを極座標変換したものである。(傷部を拡大している)



さらに2つの画像の傷の深さをグラフ化したものが下図である。



深さはアタリキズ①のほうが大きく、幅はアタリキズ②のほうが大きいことわかる。人が目視で判定した良品、不良品の傷の深さのグラフを多数収集し分析することで、傷の深さのグラフの形から不良品判別を自動化できる可能性がある。

5.5.8 まとめ

画像処理と聞くと専門家がいないと手も足も出ないというイメージを持たれると思うが、OpenCV-Python を 利用することで、多少のプログラミングの知識を身につければ、製造現場でもある程度は自前化できる技術 である。本章の内容が画像処理へ一歩足を踏み出すきっかけとなれば幸いである。

## 5.6. まとめ

本書では、2 種類の撮像系で撮像した画像を元に、4 ケースの画像解析による外観異常判定を実施 した。5.2 ではミスズ工業の自動外観検査装置による撮像画像を用いて画像分類、物体検出、セグメン テーションの4種類の画像分析を実施した。5.3では2種類の撮像系による画像を一体でセグメンテー ションによる画像解析を行った。5.4 ではミスズ工業の自動外観検査装置による撮像画像を用いてセグ メンテーションの4種類の画像分析を実施した。いずれのケースでも従来のミスズ工業の自動外観検 査装置よりも異常の過剰判定を大幅に減らせることが明らかになった。今回のような不定形のキズの 検出ではセグメンテーションが有効とされるが、5.2の結果からは画像分類、物体検出も合わせたアン サンブルによる方法が有効であること、一定条件下でのデータ拡張が有効であることを示している。ま た、5.3 の結果からは複数の撮像系の画像を用いることで精度向上を図れる可能性があることを示して いる。一方、精度向上のためには不良サンプルを増やす必要性が明らかになった。特にSアタリキズは 立体的な再現が求められ、2次元画像による判別が難しい点は各分析ケース共通の課題である。5.5 はSアタリキズの課題を解決するアプローチとして、サンプルの円周上に発生するアタリキズの鮮明化 を図る方法として、極座標変換による直線化と画像のカラーマップ化を実施し、アタリキズ個所の変化 パターンを確認した。この方法は、5.2~5.4の深層学習による画像解析との組み合わせで精度を上げ られる可能性を示唆している。また、アタリキズのように立体的な再現が求められるケースは撮像方式 にエ夫が必要であり、今後の取り組み課題である。



## 6.1. 取り組みの成果

本書では、画像解析による外観異常判定を撮像方式の側面と画像解析の側面から複数のアプローチを 試みた。複数のアプローチは、単独ではなく、組み合わせが有効であることを示した。また、今回の取り組 みを通して、分科会メンバーの機械学習を含めた画像認識、画像処理に関するスキル向上が図れたと考え る。

# 6.2. 今後の課題

今回の取り組みを通して不良品の過剰判定は大幅に削減できる見通しを得たが、不良見逃しはゼロに なっておらず更なる精度向上が求められる。今後は、不良品の蓄積ばかりではなく、生成系 AI の活用 による不良品データの拡充や撮像方式の工夫といった方向性からのアプローチが考えられる。



参考文献

- [1] 日本金型工業会, "日本金型工業会," [オンライン]. Available: https://www.jdmia.or.jp/.
- [2] CG Magic:レンダリング,オーム社 https://www.ohmsha.co.jp/book/9784274066924/.
- [3] コンピュータビジョン 最先端ガイド 4, アドコム・メディア https://acm-book.shop/?pid=37383004.
- [4] コンピュータビジョン 最先端ガイド 5, アドコム・メディア https://acm-book.shop/?pid=51572600.
- [5] ディジタル画像処理, CG-ARTS 協会 https://www.cgarts.or.jp/books\_detail/eip\_2/.
- [6] フォトメトリック法の反射解析による画像コントラストの強調, VISION SYSTEMS DESIGN JAPAN 2019/12 https://express.jp/wp-content/uploads/2019/09/036\_photometric\_stereo\_techniques.pdf.
- [7] 光の教科書, オプトロニクス社 http://shop.optronics.co.jp/products/detail.php?product\_id=618.
- [8] 光技術入門, 東京電機大学 https://www.tdupress.jp/book/b350322.html.
- [9] "分光画像処理入門,"東京大学出版会 https://www.utp.or.jp/book/b305435.html.
- [10] 池内克史、松下康之,照度差ステレオの原理と実際,光学、Vol.41、No.5、pp281-286 https://annex.jsap.or.jp/photonics/kogaku/public/41-05-kaisetsu4.pdf, 2012.
- [11] 色彩工学入門, 森北出版 https://www.morikita.co.jp/books/mid/084681.
- [12] "画像処理と色空間,"映像情報メディア学会誌: Vol.70、No3、pp.306-314
  https://www.jstage.jst.go.jp/article/itej/71/5/71\_306/\_article/-char/ja/, 2017.
- [13] 基礎からはじめる物理ベースレンダリング, https://zenn.dev/mebiusbox/books/619c81d2fbeafd/viewer/239ee2.
- [14] Y. LeCun, B. Boser, J. Denker, D. Henderson, R. Howard, W. Hubbard, a. L. Jackel, "Backpropagation applied to handwritten zip code recognition," Neural Computation, Vol.1, No.4, pp.541-551, 1989.

- Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-based learning applied to document recognition,"
  Proceedings of the IEEE, Vol.86, No.11, pp2278-2324, 1998.
- [16] W. O. X. W. P. F. J. C. X. L. M. P. Li Liu, "DeepLearningforGeneric Object Detection: A Survey," International Journal of Computer Vision, 2019.
- [17] Y. B. F. P. A. P. N. K. a. D. T. Shervin Minaee, "Image Segmentation Using Deep Learning: A Survey," arXiv:2001.05566v5 [cs.CV] 15 Nov 2020, 2020.
- [18] P. F. a. T. B. Olaf Ronneberger, "U-Net: Convolutional Networks for Biomedical Image Segmentation," arXiv:1505.04597v1 [cs.CV] 18 May 2015, 2015.
- [19] L. Maaten, G. Hinton, "Visualizing Data using t-SNE," Journal of Machine Learning Research 9 (2008) 2579-2605,
  2008.
- [20] "アコースティック・エミッション,"フリー百科事典『ウィキペディア(Wikipedia)』,5日3月2021年. [オンライン].
  Available:

https://ja.wikipedia.org/wiki/%E3%82%A2%E3%82%B3%E3%83%BC%E3%82%B9%E3%83%86%E3%82%A3%E3%83 %83%E3%82%AF%E3%83%BB%E3%82%A8%E3%83%9F%E3%83%83%E3%82%B7%E3%83%A7%E3%83%B3.



### 1. AI 画像認識ソフトウェアパッケージNAITについて

### (1) 現場で直ぐに使えるディープラーニングを実現

- ① NAIT は、誰でも使える、プログラミングが必要ないディープラーニングによる AI 画像認識を実現
  - ✓ NAIT の操作を覚えて頂き、良品画像、不良品画像を収集して、学習するだけで認識モデルを作成することが出来ます。ノーコードでプログラミング作成が全く必要なく認識モデルを生成できる。 (図-1参照)
  - ✓ 他のディープラーニングを用いた AI 画像認識ソフトウェアとは異なり煩わしいハイパーパラメータ などの調整は必要ない。NAIT が最適なパラメータを自動的に決定する。したがって、通常はハイパ ーパラメータの設定に相当な時間を要するが、NAIT では自動設定によって大幅に時間が削減する ことができる。(<図-2参照)</p>
  - ✓ 導入後に新たな対象物を検査したい場合にも、自社にて NAIT を使って新たに認識モデルを作成 することが出来ますので、開発費を抑えることができる。
- ② NAIT で作成した認識モデルは、容易に実装することが可能
  - ✔ NAIT で作成した認識モデルは、.net 形式になりますのでユーザアプリケーションに容易に実装して使うことができる。
  - ✔ 各種装置、製造ラインでの検査システムへの実装。
  - ✔ 監視カメラシステムなどへの実装。
  - ✔ 画像認識が必要なあらゆる用途に実装して使うことができる。



<図-2>







2. NAIT の提供する認識モデルのタイプ



NAITには、上<図-4>の5つの認識モデルの機能がある。

(1) Classification(クラシフィケーション)

Classification は画像全体が何であるかをラベルしてクラスを区別する。このモデルタイプは画像単位で 特定のオブジェクトを認識する必要がある場合に有効である。



上図<図-5>左では、『Street』、『mountain』、『street』の3種類のラベルを画像に付与して、学習させる ことで『Street』、『mountain』、『street』としてクラス分けすることができる画像認識モデルになる。また、上 図<図-5>右のように、部品の外観により、OK、NGを判別するクラス分けも可能です。

### (2) Segmentation(セグメンテーション)

Segmentation は画像内の物体を認識するだけではなく、物体、その位置、及び画像1ピクセルごとの 正確な形状を認識することができます。Segmentation は物体の正確な領域と位置を検出、もしくは画像 内の異なる種類の物体を別々に検出する必要がある際に有効である。 <図-6>



上図<図-6>では、左は、それぞれ、対象物毎に『car』、『person』というラベルを付与している。 ては、対象物毎に『house』、『plant』、『dog』というラベルを付与しており、このように対象物毎にラベ ルを付与して学習することで、画像内にあるそれぞれの対象物を個々に認識できる。



上図<図-7>では、電子基板上での不良個所をそれぞれ『Missing hole』、『Mouse bites』、『Open circuit』、の3種類の欠陥をラベルして学習することで、これら3種類の欠陥をそれぞれに検出で きるようにしている。

## (3) Object Detection (オブジェクトディテクション)

Object Detection は画像内の物体のクラスと位置を認識するモデルタイプです。 Object Detection は、 シーン内の特定のオブジェクトを、路上駐車の車や人の顔などのクラスに区別する必要がある場合に 役立ちます。







<図-8>

(4) Anomaly Classification (アノマリークラシフィケーション)

アノマリークラシフィケーションモデルは教師なし学習に特化しており、異常な画像を検出するために正常な画像のみで学習する。このモデルは汎用性が高く、特に使用できる欠陥画像の数が限られている場合に、さまざまな分野に適用できる。



(5) Anomaly Segmentation (アノマリーセグメンテーション)

アノマリーセグメンテーション モデルは、通常の画像のみを使用した教師なし学習を通じて、単に画像の 異常を検出するだけではありません。 画像内の欠陥の位置を正確に特定することもできます。 このモデ ルは、正常クラスと異常クラスの分類と正確な欠陥位置特定の両方が不可欠な分野に適用できます。



<図-10>
(6) OCR (光学式文字認識)

OCR は、スキャンされた文書、バーコード、標識や広告看板の文字列のような、画像内の文字やテキストの認識に特化したモデルタイプです。このモデルは、指定された画像内のテキストを検出し、それらを文字レベルに分割して、各文字を認識します。



<図-12>

3. NAIT の提供するラベルセットタイプ





ラベル付けオプションには、クラスラベル、領域ラベル、ボックスラベル、OCR ラベルの 5 つある。

- Classification: クラシフィケーションでは各画像をクラスごとに分類するクラシフィケーションでは、 クラスラベルを使用する。
- ② Segmentation: セグメンテーションでは、領域ラベルを使用して、関連領域を自由に描画する。 画像はピクセルレベルで分析される。
- ③ Object Detection: ディテクションでは、検出したいオブジェクトの周りにボックスラベルを描画する。
- ④ Anomaly Detection: 異常検出の場合、学習セットを正常クラスとして設定し、「正常」と「異常」を分類 する。
- ⑤ OCR ラベル: OCR ラベルを使用すると、画像内のテキストと数字を文字レベルで認識および解釈できる。

## 4. NAIT の提供する評価指標

ここでは、NAIT が提供する評価指標について述べます。 ディープラーニングで用いられている一般的な 評価指標でもある。

(1) Precision & Recall

先ずは、ディープラーンングによる評価結果として、以下に示す4つの結果がある。 この表は実際の答えと予測された答えを2x2の表にしている。

		予》	則
_		Positive	Negative
	Desitive	True Positive	False Negative
中欧	Positive	(TP)	(FN)
美際		False Positive	True Negative
	Negative	(FP)	(TN)

2 True Positive(TP、真陽性):モデルが陽性クラスを正しく予測する結果

<sup>12</sup> True Negative(TN、真陰性):モデルが陰性クラスを正しく予測する結果

☑ False Positive(FP、偽陽性):モデルが陽性クラスを誤って予測する結果

☑ False Negative(FN、偽陰性):モデルが陰性クラスを誤って予測する結果

例えば、モデルがリンゴの画像をリンゴと正しく判定した場合は真陽性となり、リンゴの画像をバナナと 予測した場合は偽陰性となる。

Precision は陽性と予測されたものに対する実際の陽性の割合である。

$$(Precision) = \frac{TP}{TP + FP}$$

Recall は実際に陽性であるものに対する陽性と予測されたものの割合である。

$$(Recall) = \frac{TP}{TP + FN}$$

Precision と Recall はどちらもモデルが実際に陽性であるものを陽性と判断した場合を扱いますが、観 点が異なる。例えば、10枚の画像の中からリンゴの画像を見つけるタスクを想定してみる。10枚の内6 枚のリンゴの画像と4枚のバナナの画像がある場合の様々な状況での Precision と Recall の違いを以 下に示す。



モデルがリンゴと予測した画像が2枚しかない場合を想定してみる。それら2枚の画像の正解がリンゴ だった場合、Precisionは100%となる。他に4枚のリンゴの画像があるため、モデルが予測できなか った画像が未だあるということになる。しかし、Precisionからはこのことはわからない。Precisionは陽 性と予測された画像の中の実際の陽性の枚数であるからである。



モデルが6枚の画像をリンゴと予測した場合を想定すると、Recallは100%となる。しかし、モデルがバ ナナの画像数枚を誤ってリンゴと予測する場合があり、言い換えるならば、6枚は実際のリンゴの画像 ですが、リンゴと予測された画像は8枚なので、誤検出がある。そのため、PrecisionとRecallは高けれ ば高いほど良いのですが、そのどちらか一方のみが高い場合は必ずしもモデルが高性能であるとは言 うことはできないわけで、両方の数値を考慮する必要がある。

#### (2) Accuracy & F1 score

Precision と Recall が陽性を実際の陽性としてのみ扱う場合、Accuracy は実際の陰性が陰性として予測 される全てのケースを包括的に扱う。 一般に、Accuracy はモデルの精度を最も直感的に理解できる指 標となっている。

Accuracy = 全画像の中でラベルとして正しく予測された画像の割合

 $Accuracy = \frac{Number \ of \ correct \ predictions}{Total \ number \ of \ predictions}$ 

$$(Accuracy) = \frac{TP + TN}{TP + FN + FP + TN}$$

例えば、全ての画像の中でリンゴとして正しく予測している画像とバナナとして正しく予測している画像の割合が Accuracy と呼ばれる。

F1 スコアはテスト精度の尺度の一つであり、Accuracyを補完する指標として用いられる。

F1 スコアは Precision と Recall の調和平均であり、最大で1、最小で0となる。

 $(F1\text{-}score) = 2 \times \frac{1}{\frac{1}{Precision} + \frac{1}{Recall}} = 2 \times \frac{Precision \times Recall}{Precision} + Recall$ 

(3) ROC 曲線と AUC

ROC 曲線(Receiver Operating Characteristic Curve)は、識別のしきい値を変化させた際の分類モデルの診断能力を表すグラフである。ROC 曲線は様々なしきい値の設定で真陽性率(TRP)を偽陽性率(FRP)に対してプロットすることで作成される。

```
真陽性率(=recall): 実際の結果が陽性である場合に、モデルがどの程度正確に陽性のクラスを
予測しているかを表す
```

$$TPR = \frac{TP}{TP + FN}$$

偽陽性率: 実際の結果が陰性である場合に、陽性クラスと予測される頻度を表す

$$FPR = \frac{FP}{FP + TN}$$

AUC と ROC 曲線の下の領域のことです。AUC は座標(0.0)から(1.1)までの全ての ROC 曲線の下の領域を計測することになる。

AUC は考えられる全ての分類のしきい値に対してのモデルの性能を表す。一般に、AUC が高いほどモ デルのクラスの識別は良好となる。





# (4)物体検出における評価指標

IoU (Intersection over Union)



IoU、特定のデータセットに対するオブジェクト検出器のパフォーマンスを評価するために使用される評価指標である。

IoU の計算に必要なバウンディング(境界)ボックスには 2 つのタイプがある。 グラウンドトゥルース バウンディングボックスと予測境界ボックスである。

- ・-グラウンドトゥルース バウンディングボックスは、ユーザー入力として ラベル付け された 領域であり、画像内の特定のオブジェクトの場所を指定する。
- -予測されるバウンディングボックスは、特定のオブジェクトの場所と存在を指定する、深層学習モデル からの予測される領域となる。

IoU が高くなるほど、グラウンドトゥルースと予測されるバウンディングボックスの重複が多くなる。

下記は、さまざまな IoU を持つバウンディングボックスの例である。



5. NAIT のパラメーターの設定

(1) パッチサイズ

Classification アルゴリズムが画像単位で学習していたのに対し、Segmentation ではパッチ単位で学習する。パッチは四角形で、NAIT Developer では 128 x 128 と 256 x 256、512 x 512 の3つのサイズを選択できる。学習に使用される画像が 512x512 ピクセルより小さい場合、パッチは画像のトリミングやサイズ変更プロセスなしで自動的に 512 x 512 として設定される。



<図-15>

正しいパッチサイズの選択ガイド

- -パッチサイズと元の画像サイズが同じ大きさの場合、モデルの性能が向上する。 もし画像サイズ が 512x512 であれば、パッチサイズは 512x512 を選択。
- -画像の大きさが利用できるパッチサイズよりも大きい場合、パッチサイズを欠陥領域よりも若干大きくすることが望ましい。例として、1024x1024の画像の中の欠陥が 200x200 の場合、パッチサイズは 256x 256 が推奨される。
- (2) スケールファクター

スケール係数は、セグメンテーションモデルのパラメーターである。スケールファクターを2に設定した場合、次のような結果が得られる。例えば、元画像サイズが256x256の場合、512x512の画像に変換され、高さと幅がそれぞれ2倍になった画像となる



Scale Factor : 2



(3) 感度

感度とは、正常クラスと異常クラスを区別する基準になる。たとえば、感度が 30 に設定されてい 場合、異常スコアが 30 を超える画像は「異常」クラスとして分類される。異常スコアが 30 未満の 像は「通常」クラスとして分類される。



感度は、「結果」タブと「データ」タブにある感度ヒストグラムを参照して設定できる。ヒストグラムは、テ スト結果を含む画像の異常スコアで構成される。X軸は異常スコアを表し、Y軸は異常スコアをX軸で 示す画像の数を表す。

## 6. NAIT の結果の評価とレポート

NAIT デベロッパーはモデルの性能を評価するためのいくつかの指標を提供する。モデルの全体的なパフォーマンスと、各ラベルの正解率、適合率、再現率、および F1 スコアを示す。

#### (1) **主要な指標**

評価結果											前 消去 ± CSVと	してダウンロード 🕒 モデルの取	2.2 🕒 モデル出力
モデルタ	ラベルセット名	モデル名	編集	評価セット	# 画像の数	正解率	這合率	再現率	F1スコ7	学習時間	要求時間	完了した時間	アカウント
SEG	Battery scratch	Scratch	Ø	テストセット	31	99.93	96.60	92.70	94.60	00h 22m	April 4, 2022, 05:06	April 4, 2022, 05:28	NAIT1
L間値	Battery scratch	Scratch	Ø	テストセット	31	99.93	97.78	92.88	95.27	00h 22m	April 5, 2022, 02:17	April 5, 2022, 02:17	NAIT1

すべてのタイプのモデルについて、4 つの異なる主要なメトリックが提供される(正解率、適合率、再 現率、F1 スコア)。同じ画像セット内のモデルのリストとその結果を表から見つけることが可能。 モデル名をクリックして結果の詳細を確認すると、同じ数値がドーナツグラフの形式で表示される。



- 正解率 (Accuracy): すべての画像の中でラベルが正しく予測されている画像の比率

- 適合率 (Precision):ポジティブであると予測されたものの中での実際のポジティブの比率

- 再現率(Recall):実際にポジティブだったものの中で予測されたポジティブの比率



<sup>-</sup> F1 スコア(F1 Score): 適合率と再現率の調和平均

(2) Classification の場合の評価結果のみかた

#### -混合行列

	予測										
		Class 1	Class 2	Class 3	Class 4						
宇欧	Class 1	100	0	1	0						
, Ground	Class 2	0	99	0	0						
(Ground Truth)	Class 3	0	0	120	0						
	Class 4	1	0	0	87						

モデルによる予測と、ユーザーによって付けられたラベル(正解)を比較する表になる。

行列の各行は予測されたクラスを表し、一方で各列は実際のクラスを表します。各セルは画像枚数を表 す。対角線に位置する数値は予測と実際のクラスが一致している画像枚数である。そのため、対角線 上に位置する画像枚数が増えれば、より精度の高い結果となる。

#### -ROC 曲線(Receiver operating characteristic curve)

識別のしきい値を変化させた際の分類モデルの診断能力を表すグラフである。

ROC 曲線は様々なしきい値の設定で真陽性率(TRP)を偽陽性率(FRP)に対してプロットすることで作成 される。



デフォルトでは、モデルのすべてのクラスがグラフに表示される。 目のアイコンをクリックすると、特定の クラスのグラフを表示または非表示にできる。

## -信頼区間(Classification)

通常、テストデータの確度は1に近づく傾向がある。信頼区間を示すために各テストデータはランダムに サンプリングされ、サンプルグループを形成し、各サンプルグループの平均を用いて分布を作成する。 評価タブの信頼区間はこの分布に基づいて表示される。



## -スコア

Classification では、"スコア"はクラス毎の Probability になる。以下の画像に示す通り、スコアが 99.92 の場合、モデルは"Choco\_12"の画像を 99.92%の確率で Choco であると予測したことを意味する。

		(ラペルセット)2	.0.2_Chips_cla	(モデル) 2.0.2_Chi	ps_Cla_512_fast		
No	画像名	画像サイズ ROI マスク	ラペル ▽	セット 再テ ROI マスク	判定結果 ▽	スコ7 ⑦	ステー
			choco	テスト	choco		
52	Choco_12.png	512 x 512	Choco	テスト	Choco	99.92	Good
55	Choco_15.png	512 x 512	Choco	テスト	Choco	99.88	Good
54	Choco_14.png	512 x 512	Choco	テスト	Choco	99.84	Good
65	Choco_25.png	512 x 512	Choco	テスト	Choco	99.57	Good
170	Choco_4.png	512 x 512	Choco	テスト	Choco	99.22	Good
60	Choco_20.png	512 x 512	Choco	テスト	Choco	99.11	Good
81	Choco_41.png	512 x 512	Choco	テスト	Choco	99.09	Good
59	Choco_19.png	512 x 512	Choco	テスト	Choco	98.97	Good
46	Choco_6.png	512 x 512	Choco	テスト	Choco	90.06	Good
58	Choco_18.png	512 x 512	Choco	テスト	Choco	76.76	Good

#### -Probability threshold



分類モデルでは、しきい値を使用して偽陽性を減らすことができる。

しきい値の使用には2つのアプローチがある:

- 不明なクラス:指定されたしきい値よりも低い確率値を持つ画像は、[Unknown(不明)]クラスとして 分類される。たとえば、ある画像が[OK]クラスとして 56%の信頼度で予測されている場合、しかし [OK]クラスのしきい値が 56%以上に設定されている場合、その画像はもはや[OK]クラスとして予測 されず、[Unknown]クラスとして分類される。
- 次に高い確率クラス:指定されたしきい値よりも低い確率値を持つ画像は、2番目に高い確率のクラスとして分類される。たとえば、[OK]、[Pass]、[NG]のクラスを持つモデルで、ある画像が[OK]クラスに 56%の確率、"NG"クラスに 43%の確率、"Pass"クラスに 1%の確率で予測されている場合、そして[OK]クラスのしきい値が 50%に設定されている場合、このモードでは画像は次に高い確率を持つ[NG]クラスとして分類される。

確率しきい値は現在生成されているモデルの結果に適用され、新しいモデルは作成されない。

- 確率しきい値

分類モデルにしきい値を適用することにより、誤検知を減らすことができる。 確率しきい値を適用す ることにより、確率スコアが低い予測クラスを「不明」クラスとして再分類する。

たとえば、モデルが「Image\_01」を 56%の確率で OK クラスとして予測する場合、この画像は 56%より高いしきい値の OK クラスとして割り当てられない。

確率しきい値機能を使用すると、新しいモデルを作成するのではなく、既存のモデルの予測結果にし きい値を適用することに注意が必要である。

確率 しきい値のガイド

・確率 しきい値は分類モデルにのみ適用される。

・モデルごとに最大3つの異なるしきい値を適用でき、新しいしきい値を作成するためには既存の しきい値を削除する必要がある場合がある。

・しきい値の結果は元のモデルに依存するため、元のモデルを再テストすると既存のしきい値に影響する。再テスト後にしきい値を再適用する必要がある場合がある。

・しきい値の際は、[評価]および「[値」]タンはグレー表示される。

・[エクスポート]ボタンをクリックすると、モデルとそのしきい値をエクスポートできる。これにより、追加のプロセスなしでしきい値を使用してモデルを推定できる。

・しきい値を下回る画像は不明なクラスとして分類され、主要なメトリック(正解率、適合率、再現 率、F1 スコア)を計算するときに除外される。

評価結果											@ 消去 ⊥	CSVとしてダウンロード 上 モデルの取込み	🕒 モデル出力
モデルタ	ラベルセット名	モデル名	編集	評価セット	# 画像の数	正解率	這合平	再現率	F1スコア	学習時間	要求時間	完了した時間	アカウント
SEG	Battery scratch	Scratch	P	テストセット	31	99.93	96.60	92.70	94.60	00h 22m	April 4, 2022, 0	05:06 April 4, 2022, 05:28	NAIT1
L間値	Battery scratch	Scratch	Ø	テストセット	31	99.93	97.78	92.88	95.27	00h 22m	April 5, 2022, 0	02:17 April 5, 2022, 02:17	NAIT1

(2) Segmentation の場合の評価結果のみかた

# -混合行列

Segmentation ではピクセル、クラス、画像毎の混合行列が提供される。

# - 混同行列 (ピクセルから)

行列の各行は予測されたクラスの角度を表し、一方で各列は実際のクラスの確度を表す。

	予測						
		Class 1	Class 2 (Background)				
実際 (Ground Truth)	Class 1	87.2 (%) A	12.8 (%) B				
	Class 2 (Background)	4.4 (%) C	95.6 (%) D				



- 混同行列 (クラスごと)

各クラスの予測結果を表す。

一つの画像に複数のクラスでラベルが付けられている場合は、行列内では重複してカウントされる。

	Total	良い	中間	悪い
Background	number of images			
Class1				
Class2				

※ 良い結果 ラベル付け領域が画像内に無く予測領域が無い。 ラベル付け領域が画像内にあり、予 測領域 IoU が 0.5 以上である。

※ 中間の結果 ラベル付け領域が画像内にあり、予測領域の IoU が 0 より大きく 0.5 より小さい。

※ 悪い結果 ラベル付け領域が無く、予測領域がある。ラベル付け領域があり、予測領域の IoU が 0

-混合行列(画像ごと)

行列は各画像の予測結果を表す。

一つの画像に複数のクラスでラベルが付けられている場合、画像は良い/中間/悪いに分類される。

全ての予測結果は全てのクラスにて総合的に考慮される。

	Total	良い	中間	悪い
# of images				

- ※ 良い結果 ラベル付け領域が画像内に無く予測領域が無い。 ラベル付け領域が画像内にあり、予 測領域の IoU が 0.5 以上である。
- ※ 中間の結果 ラベル付け領域があり、予測領域の IoU の一つ以上クラスで 0.5 以上であり、残りの クラスが 0.5 以下である。
- ※ 悪い結果 画像にはグラウンドトゥルースがあり、予測領域の loU は=0 です。

画像にはグラウンドトゥルースがあり、すべてのクラスの予測領域の loU は 0.5 未満です。

※ IOU (Intersection over Union)





(3) Object Detection の場合の評価結果のみかた

## - 混合行列(オブジェクトごと)

	# ラベルの数	# 予測されるラベルの数	#一致するラベルの数
Class1			
Class2			
Class3			

- ラベルの数: クラス毎に表示
- ・ 予測ラベルの数: モデルによって予測ラベルの数をクラス毎に表示
- 一致しているラベル: ラベル付けされたラベルと予測されたラベルの IoU が 0.5 以上のラベルの数を 表示

### -混合行列(画像ごと)

画像毎の予測された結果の行列を表示する。一つの画像に複数のクラスでラベルが付けられている場合、画像は良い/中間/悪いに分類される。全ての予測結果は全てのクラスにて総合的に考慮される。

	Total	良い	中間	悪い
# of images				

- ※ 良い結果 ラベル付け領域が画像内に無く予測領域が無い。 ラベル付け領域が画像内にあり、予測 領域の IoU が 0.5 以上である。
- ※ 中間の結果 グラウンドトゥルースが 4 つを超えるオブジェクトである場合、すべてのグラウンドトゥル ースは良好であり、バックグラウンドで 2 つだけオーバーキルする場合、または予測カウントとラベル カウントは同じであるが、2 つのラベルのみが不良である場合。
- ※ 悪い結果 ラベル付け領域が無く、予測領域がある。ラベル付け領域があり、予測領域の loU が 0 である。
- ※ IOU (Intersection over Union)



#### -スコア

Detection の場合、"Score"は各ボックスの分類確度の平均値を意味する。例として、下図のようにクラス1とクラス2の両方が存在する場合を想定する。この場合、スコアが 94.18 であればその時クラス1の物体をクラス1として分類する確度とクラス2の物体をクラス 2 として分類する確度の平均値が 94.18%となる。



## -確率しきい値

確率しきい値機能を使うと、確率の低い領域を削除することができる。しきい値の基準は、エリアごとの 平均確率であり、「エリア内の各ピクセルの確率の合計をエリア内のピクセル数で割ったもの」として定義 される。もし 56%未満の確率領域を削除する場合は、確率しきい値を使用してそのような領域を削除で きる。このような領域は背景と見なす。これは、ラベルを付けて特定のクラスとして割り当てていないすべ てのピクセルと同じである。確率しきい値機能を使用することは、新しいモデルを作成しているのではな く、既存のモデルの予測結果にしきい値を適用している事になる。

## -サイズのしきい値

ディテクションモデルでは、予測された領域に対象物ではない非常に小さな領域が含まれる場合がある。 サイズのしきい値を使用することにより、モデルのパフォーマンスを低下させるこのような領域を予測領 域から削除できる。たとえば、特定の画像の予測領域に 2x2 ピクセルより小さい無視できる領域が含ま れている場合、サイズのしきい値を使用してそのような領域を除外できる。そのような領域は背景と見な される。これは、ラベルを付けておらず、特定のクラスとして割り当てられないすべてのピクセルと同じで ある。サイズしきい値機能を使用すると、新しいモデルを作成するのではなく、既存のモデルの予測結果 にしきい値を適用する。



## 著者

秋元	ー泰(5.2節を担当)		
佐藤	博義(5.3節を担当)		
遠塚	弘(4.1節を担当)		
土屋	春幸(5.1節を担当)		
河田	健一(5.5節を担当)		
平田	俊明(1章~3章、5.4節、	5.6節、	6 章を担当)

研究会メンバー

平田 俊明 (東京情報デザイン専門職大学) 個人会員:主査 牛山 順一 (ミスズ工業)正会員:副査 秋元 一泰 (華為技術日本)正会員 活番 忠満 (AAC)正会員 石川 晴行 (華為技術日本)正会員 伊藤 憲秀 (イトウプリント)正会員 伊藤 憲秀 (イトウプリント)正会員 佐藤 博義 (ADSTEC) サポート会員 土屋 春幸 (ミスズ工業)正会員 遠塚 弘(レイマック)正会員 長洲 慶典(長野県工業技術総合センター)サポート会員 松岡康男 (東芝) 正会員 森 満帆(ニチダイ)正会員





# 画像解析による外観検査自動化の事例とその技術

発行者 一般社団法人インダストリアル・バリューチェーン・イニシアティブ 理事長 西 岡 靖 之

〒102-0073 東京都千代田区九段北4-3-28-302

電子メール: office@iv-i.org URL: https://iv-i.org

発行日 2024年10月1日

定価 非売品

(発行者に無断で複製または印刷を禁止します。)