

# NMRI

National Maritime Research Institute

一般社団法人日本船舶品質管理協会殿請負研究

## 鑄造品等検査技術に関する研究 報告書

令和 5 年 3 月

国立研究開発法人 海上・港湾・航空技術研究所  
海上技術安全研究所

## 目 次

1. まえがき	1
2. 鋳造品等の形状検査に関する研究	2
2.1 研究目的	2
2.2 図面の3次元モデル化アプリ (3D Drafter) の開発	2
2.3 タブレット版形状検査アプリ (形状検査官) の開発	5
2.4 ホロレンズ版形状検査アプリ (ShipComponentViewer) 開発	7
3. 鋳造品等の表面欠陥に関する AI 活用等の研究	9
3.1 鋳造品等の表面欠陥と対策	9
3.2 鋳造品欠陥知識を踏まえた注意喚起	13
3.2.1 全般	13
3.2.2 知識処理 AI について	13
3.2.3 鋳造品欠陥知識を踏まえた注意喚起アプリ制作	14
3.3 表面欠陥検出システム制作	21
3.3.1 画像認識 AI アプリ	21
3.3.2 表面欠陥検出システム予備実験	23
3.4 AI による表面欠陥認識	24
3.4.1 学習モデルの作成	24
3.4.2 学習モデル作成に使用した画像データ	25
3.4.3 作成した学習モデルの種類	43
3.4.4 テスト用鋳造品の再検出	67
3.5 表面欠陥検査技術まとめ	68
4. 鋳造品等の内部欠陥検査技術に関する AI 活用等の研究	68
4.1 鋳造品等の内部欠陥検査技術	68
4.2 鋳造品等の内部欠陥検査への画像認識 AI の適用	70
4.2.1 AI 技術	70
4.2.2 AI 学習のための画像変換と前処理	70
4.3 模擬試験体による予備的検討	71
4.3.1 試験体	71
4.3.2 AI の適用	72
4.4 追加試験体による検討	73
4.4.1 試験体	73
4.4.2 AI の適用	75
4.5 内部欠陥検査技術まとめ	87
5. 統合化システムの作成と検証	88
5.1 統合化システム概要	88
5.2 表面欠陥検査	88
5.3 形状検査	89
5.4 内部欠陥検査	89
6. まとめ	90
参考文献	91

## 1. まえがき

本報告書は、国立研究開発法人 海上・港湾・航空技術研究所 海上技術安全研究所（海技研）が、一般社団法人日本船舶品質管理協会から、「鑄造品等検査技術に関する研究」として、受託して実施したものである。本調査研究は、舶用品メーカーの要望を基に日本財団助成事業として、令和3年度より同協会が委員会を設置して進めている「鑄造品等検査技術の開発事業」の一環である。

製造事業場では、工程毎の各検査を経て、完成検査を行い出荷している。工程内で発生する不適合未然防止のため、外部との接点である受入検査が重要であるが、特に、鑄造品で不適合が多発している実状がある。鑄造品は複雑な形状を容易に造形できるメリットがあるが、反面、内部欠陥や表面欠陥等が生じやすく、特に表面近傍の内部欠陥は切削加工により表面に現れ、工程混乱を引き起こす要因となっている。

このような状況に対し、内部欠陥については、従来の非破壊検査手法である超音波探傷装置があるが、表面近傍の欠陥が発見しにくい等の問題があり多用されていない。また、形状検査や表面欠陥検査については、人の目視に依存しており、これらの問題を解決する安価で簡便な装置を用いた総合的な検査支援技術が求められている。

本調査研究の目的は、「鑄造品等検査技術に関する研究」を課題とし、AI・IoT技術の活用による品質管理の高度化を図ることを視野に入れ、形状検査、表面欠陥検査及び内部欠陥検査に関する研究により、多種少量生産を特徴とする舶用製品の製造現場で活用できる実用的な検査技術の確立に向けた具体的な進め方について立案することにある。

このような全体計画の中で、令和3年度並びに4年度に実施した以下の研究をとりまとめた総合報告である。

- (1) 鑄造品等の形状検査に関する研究と実用化
- (2) 鑄造品等の表面欠陥検査技術に関する AI 活用等の研究と実用化
- (3) 鑄造品等の内部欠陥検査技術に関する AI 活用等の研究と実用化
- (4) (1)～(3)の研究成果を検査現場で活用するための統合化システムの作成と検証
- (5) (1)～(3)に関する報告書の作成

## 2. 鋳造品等の形状検査に関する研究

### 2.1 研究目的

鋳造品製造業の現場では作成した製品が計画通りの形状・寸法を有しているか、すなわち図面と一致しているかを判定する検査が日常業務として行われている。現在この業務は定規などを用いて手作業にて行われているものの、複雑な形状を有する鋳造品では検査を要する箇所が多く、検査すべき箇所の見落としや図面の見間違いなどを引き起こしやすい。加えて、検査員の技量への依存度が極めて高く、検査手順の一般化が十分に成されていないため、検査員によって合否が変わることも多々発生し得る。作業自体も定規と図面を現場に持ち込んだ上、これらを同時に駆使して確認作業を行う必要があり、煩雑性が極めて高い。

以上の背景を踏まえると、検査現場にて簡易に活用可能な形状検査支援システムの開発は検査の簡易化・一般化・ヒューマンエラー防止の観点から非常に重要であると考えられる。詳細な寸法確認はやはり手作業による確認がどうしても必要であると思われるものの、付加物の配置箇所や図面の解釈違いによって生じた大きな寸法の違いと言った全体的な形状の不一致が明らかとなるだけでも上記の問題解決に大きく貢献できると考える。そこで、本研究にて図面と実際の製品の形状確認を行うアプリ群を開発した。2.2 節にて開発したアプリでは 2 次元図面から 3 次元モデルの生成を行う。この生成した 3 次元モデルを 2.3 節や 2.4 節にて作成したアプリにて読み込み、実際の製品と図面から生成した 3 次元モデルをオーバーレイし、形状の比較を行う。2.3 節のアプリはタブレットにて運用するものであり、現場で撮影した製品の写真上に 3 次元モデルのエッジをオーバーレイさせるものである。写真上の製品のエッジと 3 次元モデルのエッジに大きな乖離が見られた場合、図面どおりに製品が作成されていない可能性が極めて高く、重点的な検査を要する箇所が明示される。一方、2.4 節のアプリはウェアラブルデバイスであるホロレンズにて運用するものである。拡張現実 (Augmented Reality: AR) 技術を活用し、図面から生成した 3 次元モデルをあたかも実空間上に存在するかのように投影する。この 3 次元モデルを実際の製品に重なる、あるいは横に並べることにより、より視覚的な製品と図面の比較が可能となる。なお、2.2 節及び 2.3 節のアプリは C++/CLI を用いた Windows form アプリにて開発し、2.4 節では Unity を用いて開発している。

2021 年度の研究で 2 次元図面による検査の基本アプリが完成した。2022 年度は、さらに、3 次元補正機能の強化とホロレンズを用いた 3 次元モデルの重ね合わせ機能について研究した。

次節以降に開発したアプリの詳細を記載する。

### 2.2 図面の 3 次元モデル化アプリ (3D Drafter) の開発

本研究にて開発した図面を 3 次元モデル化するアプリ (以降、3D Drafter と呼称) の起動画面を図 2.2-1 に示す。



図 2.2-1 3D Drafter の起動画面

図面を3次元化する手続きとして、まずは画像ファイルに変換した図面を読み込む。この際に読み込む図面は検査対象となる製品の面に対応するものとする。また、図 2.2-2 に示すように隠れ線や寸法値、寸法線など実際の製品には現れない線や情報は予め取り除いておくことを推奨する。これは 3D Drafter では読み込んだ画像ファイルに基づいて3次元モデルを生成するため、取り除かない場合はこれらも3次元モデル上のエッジとして反映されてしまうためである。

図面の読み込み後の手続きとして図面上の2点とその実際の距離を入力する。これにより画像ファイルにおける単位ピクセル当たりの実距離を 3D Drafter 上で認識する。


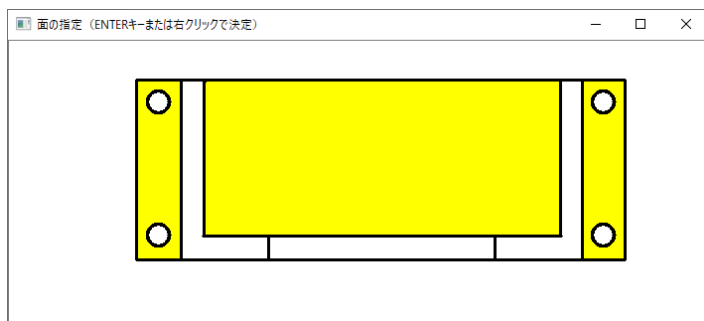


図 2.2-2 図面読み込み時のウィンドウ


図面の読み込み後、「面の座標指定」グループボックス内の「追加」ボタンを押し、図 2.2-3 に示すように面の指定とその紙面垂直方向座標の入力を行う。これにより各面における3次元空間上の位置を 3D Drafter に認識させる。なお、紙面垂直方向座標の入力は実数値を直接入力するだけでなく、別途読み込んだ側面図などを用いてその図面上の位置を指定することによる入力補助機能も有している。この面の指定を図 2.2-4 に示すように必要な全ての面に対して実施する。



(a) 「面の指定」ウィンドウ




(b) 垂直方向座標の入力




(c) 側面図/上面図を用いた奥行方向座標の指定


図 2.2-3 面の垂直方向座標入力プロセス



(a) 垂直方向座標が 10 mm の面



(b) 垂直方向座標が 64 mm の面



(c) 垂直方向座標が 80 mm の面

図 2.2-4 面の奥行き方向座標の指定の一例

全ての面に対してその座標を入力した後, 3次元モデル情報が格納されたファイルを出力する. 出力可能なファイルは次の3種類である.

- STL ファイル: Windows 上で生成した3次元モデルを確認するためのファイル
- SC ファイル: 2.3 節のタブレット用アプリにて読み込ませる3次元モデルファイル

- COMPMODEL ファイル : 2.4 節のホロレンズ用アプリにて読み込ませる 3 次元モデルファイル

出力された STL ファイルの一例を図 2.2-5 に示す。図のように指定した各面の座標に応じて 3 次元モデルが生成される。




図 2.2-5 STL ファイルの一例

### 2.3 タブレット版形状検査アプリ（形状検査官）の開発

本研究にて開発したタブレット版形状検査アプリ（以降、形状検査官と呼称）の起動画面を図 2.3-1 に示す。起動後、「寸法検査ファイル」ボタンを押し、2.2 節にて出力された SC ファイルを形状検査官に読み込ませる。続いて「実物写真」ボタンを押し、予め撮影された製品写真の画像ファイルを指定、あるいはその場で撮影を行う。




図 2.3-1 形状検査官の起動画面

3次元モデル及び実物写真の読み込み後、基準点の追加を行う。基準点とは3次元モデルと実物写真にて対応する位置である。基準点の指定の一例を図2.3-2に示す。




図 2.3-2 基準点の指定

この基準点の指定は少なくとも3点以上の複数箇所で行う必要がある。これは3次元モデルを写真上に投影する際の自由度として位置3自由度、角度2自由度、投影時の変数であるカメラの画角1自由度の計6自由度を有する一方、基準点あたりでは2次元空間上の位置である2変数が指定されるため、3点未満の基準点では上記6自由度の特定が不可能となるためである。なお、実際には3点の基準点では実物に則した位置・角度での投影が得られないことが多く、少なくとも5点以上の基準点の指定を推奨する。また明らかに実物に則していない投影となった場合には「表示」ボタンを押してきちんと対応した点が指定されているかを確認の後、要すれば基準点の更なる追加を推奨する。

基準点の選択後、「オーバーレイ実行」ボタンを押す。3次元モデルのエッジを実物写真上に投影する。ここでは実物写真への投影後の3次元モデルの基準点位置を計算し、モデルと写真の基準点間距離の二乗和が最小となるよう、準ニュートン法を用いて先述の6自由度を決定する。これにより決定された3次元モデルの位置・角度及びカメラの画角から3次元モデルのエッジが配置される写真上のピクセルを特定し、図2.3-3に示すようにエッジを写真上にオーバーレイする。写真上の辺やボルト穴といったエッジが3次元モデルのそれと位置・寸法が一致するかがより直感的・視覚的に確認可能となる。実際の鋳造品に対して生成された画像一覧を図2.3-4に示す。




(a) 実物写真




(b) オーバーレイ画像

図 2.3-3 形状検査官の出力結果





(a) Pipe Joint



(b) CL Piston



(c) HSG-1



(d) HSG-2

図 2.3-4 鋳造品に対する形状検査適用例

#### 2.4 ホロレンズ版形状検査アプリ (ShipComponentViewer) 開発

前節にて開発した形状検査官によって図面と実物の形状を簡易に比較可能なアプリの開発が達成された。ただし、より高度な技術が活用可能な事業者用にホロレンズを用いた形状検査アプリ（以下、ShipComponentViewer と呼称）を開発した。ShipComponentViewer の起動画面を図 2.4-1 に示す。ホロレンズ装着者の視界には現実世界とともに AR 技術によって投影されたメニュー画面が表示される。右上のファイル読み込みウィンドウから 3D Drafter にて作成した 3 次元モデルファイルを読み込むことにより、図 2.4-2 のように現実世界に投影される形でその 3 次元モデルが表示される。この読み込み時に QR コードが視界にあれば、図のとおりモデルの初期位置として QR コードの位置が参照される。

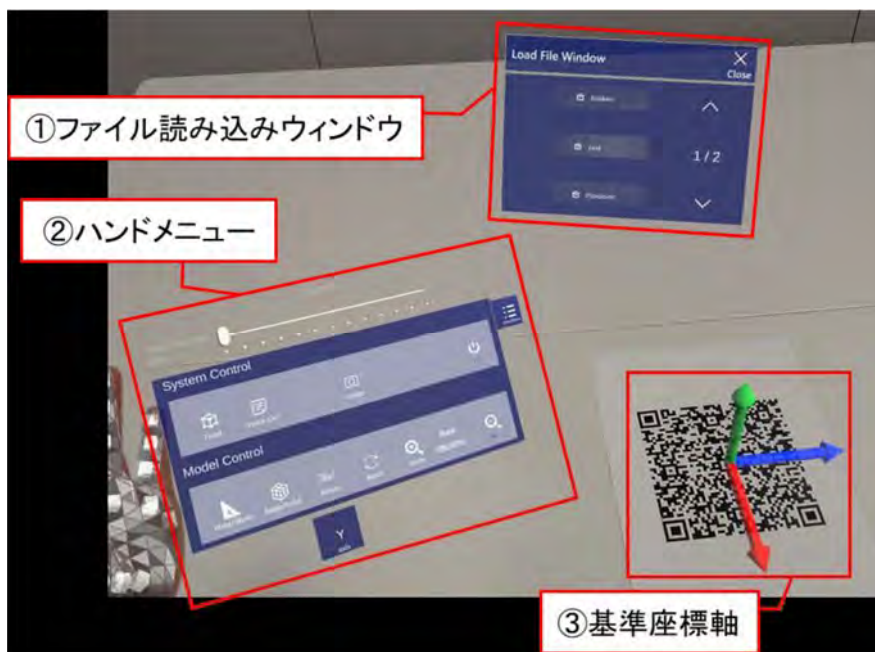


図 2.4-1 ShipComponentViewer の起動画面

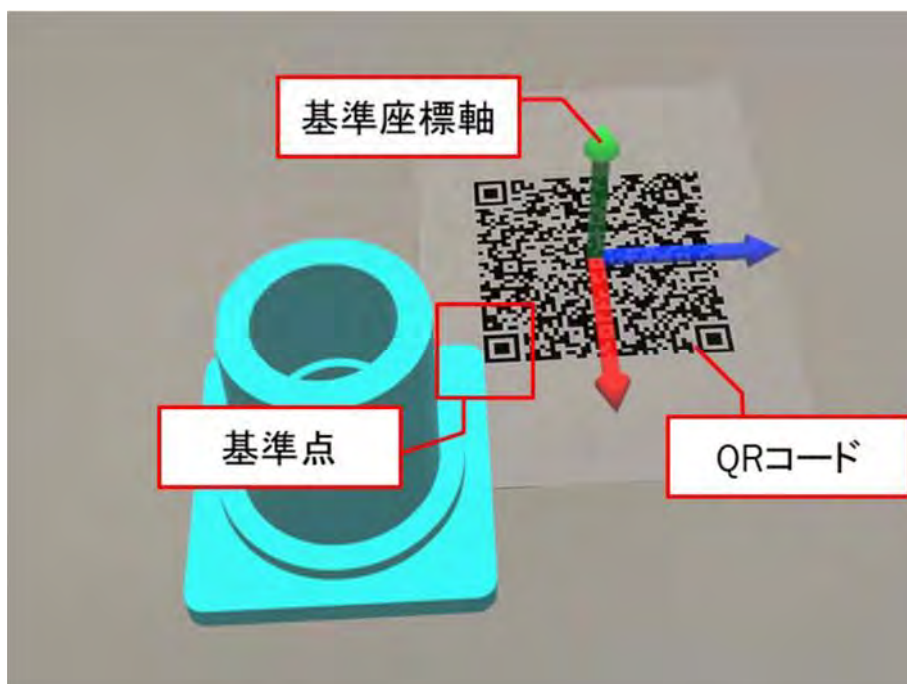


図 2.4-2 モデル表示一例

モデルの読み込み後、図 2.4-1 の左側に配置されているハンドメニューより、モデルの位置や回転、表示形式などを調整することが可能である。このハンドメニュー画面の詳細を図 2.4-3 に示し、各ボタンに対応する機能を表 2.4-1 に示す。これらの機能を活用し、3次元モデルを製品の横に配置、あるいは製品と重ねるように配置することにより、図面と製品をより視覚的に比較することが可能となる。

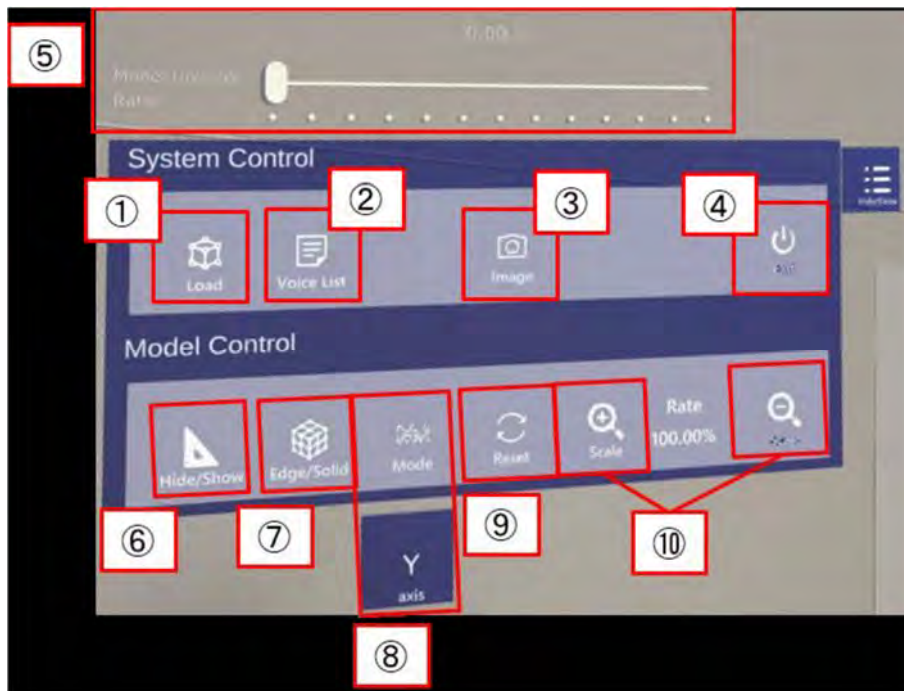


図 2.4-3 ハンドメニュー画面

表 2.4-1 ハンドメニュー機能一覧（番号は図 2.4-3 に対応）

番号	機能
①	3次元モデルファイル読み込み
②	ボイスコマンド一覧表示
③	視界の撮影
④	アプリの終了
⑤	モデルの透明度調整
⑥	スケールの表示/非表示切り替え
⑦	ワイヤーフレーム表示/ソリッド表示の切り替え
⑧	モデルの平行移動・回転移動のモード調整
⑨	モデル配置の初期化
⑩	モデルの拡張

### 3. 鋳造品等の表面欠陥に関する AI 活用等の研究

#### 3.1 鋳造品等の表面欠陥と対策

「鋳造品表面欠陥識別及び使用判定ガイド（以下、表面欠陥ガイドという）」の“鋳造品表面欠陥識別”シートに記載された内容を表 3.1-1 に示す。本表面欠陥ガイドを活用した注意喚起アプリを製作した。詳しくは、3.2 で説明する。表面欠陥ガイドには、表面欠陥事象の写真が添付されている。本表面欠陥事象の写真は、AIによる表面欠陥検出のための教師データとして活用した。詳しくは、3.4 で説明する。

表 3.1-1 (1) 鑄造品表面欠陥











欠陥事象	パターン (写真) (10円玉直径: 23.5mm)	欠陥状態/特徴	欠陥発生部位	推定原因	納入先の指示に従う (参考使用判定)	納入先の指示に従う (参考補修例)	納入先と協議する (参考その他確認事項・懸念事項)
砂カミ (部分的な砂カミ)		欠陥表面はざらつきあり。 欠陥表面に砂が付着。 凹凸大。	角部に発生。 砂の破片が内部に介在し加工後表面に現れることがある。 表面、内部どの場所でも発生し得る。	砂のつき固め不足。 型や湯道の破損。(模様)抜型時の主型の割れ。 砂の破片が鋳型内に侵入。	オイル浸漬部分は使用不可。 外部に発生し強度に影響が無い場合、補修して使用検討可。 軸受け部加工面の場合、砂を完全除去して強度に影響が無いと判断できれば使用検討可。 シール部分には使用不可。	付着した砂を除去。 パテ補修。 溶接補修。	納入先と協議する (参考その他確認事項・懸念事項) ・カミ込んだ砂の大きさ、欠陥深さ、シール部にかかっていないかを十分に観察する。 ・強度の点でも確認が必要。応力を受ける部分は十分注意。
砂カミ (黒皮表面全体の砂カミ)		黒皮表面全体に砂が残付いている。 表面や表面直下に生じる、かたまり状で不規則な形状。 事例: <a href="#">砂カミA1</a>	黒皮表面全体。 塗型が薄い部分。 凹みが深くショットの当たりが悪い部分。 鋳抜きが未貫通の袋形状でショット玉が流れにくい部分。	鋳型から砂が落ちる場合、砂が残っていた場合等。 塗型が不十分。 注湯温度が高い。 砂のつき固め不足。	加工時、チップ破損の可能性が大きいので使用不可。 表面の砂は除去できれば使用可能となる	補修不可。	加工時刃物が焼ける。 塗型が乗りにくい。 オイル浸漬部分の使用は不可。
ノロカミ (酸化ドロス)		異物が噛み込んだ状態。 凹凸大。 鋳型内で発生する場合はある。(硫酸化物等) 溶湯酸化物(ノロ)が噛み込み表面に生じる穴や凹み ・上面が平面の場合が多い。 事例: <a href="#">ノロカミA1</a>	表面、内部どの場所でも発生し得る。 角部に発生し易い。 上面(上型)や引っ掛かり形状の部分	注湯時のノロの除去不足。 取柄付着ノロの除去不足 溶湯温度の低下する部分 鋳込み時間長い。	加工時、チップ破損の可能性が大きいので使用不可。 完全除去できれば使用検討可能	噛み込んだノロを完全除去。 パテ補修。 溶接補修。	カミ込んだ砂の大きさ、欠陥深さ、シール部にかかっていないかを十分に観察する。 強度の点でも確認が必要。 応力を受ける部分は十分注意。
砂の焼付き		黒皮表面に砂が固まった状態で焼き付いている。 肉厚部で砂温が上がり易い部分。 砂の温度を上げないようにする ・除去できれば良い	中子部分に発生。 中子部分角部に発生し易い。 鋳グルも部分 ・狭い部分、凹み部 ・砂型が温度が高い部分 ・砂の詰まりが悪い分 ・腐部分	溶湯温度が高すぎる。 砂のつき固め不足。 塗型材不良。 ガス抜き不良 ・芯金の偏り ・芯金の太さ	完全除去できない場合、使用不可。 完全除去できた場合、使用可能。 オイル浸漬部分は使用不可。	グラインダーにより焼付いた砂を完全除去。 ガウジング 溶断線の熱で除去する。	グラインダー除去後も焼付きが残る可能性がある。 あるので注意。 グラインダー除去により加工面に傷をつける可能性大。
ピンホール		表面の小さな穴。 黒皮表面全体にφ2~3mm程度の巣(ピンホール)が点在している。	黒皮表面に発生。 ・上面面に発生し易い。	鋳込み温度低下、ガス量増加、鋳砂の水分等。 ・ガス抜きが不十分。	加工が行われOリングシールとなる場合は使用不可。 黒皮使用部で外部に発生した場合パテ補修も使用検討可。	パテ補修。	加工後に欠陥が残る可能性がある。 ・オイル浸漬部分との貫通が無いかに注意すること。

表 3.1-1 (2) 鑄造品表面欠陥

欠陥事象	パターン (写真) (10円玉直径: 23.5mm)	欠陥状態/特徴	欠陥発生部位	推定原因	納入先の指示に従う (参考使用判定)	納入先の指示に従う (参考補修例)	納入先と協議する (参考その他確認事項・懸念事項)
ブローホール		黒皮表面全体にφ20～30mm程度の巣(ブローホール)が点在している。 事例: ブローA1	黒皮表面に発生。 冷し金接触面。 上型面に発生し易い。	冷し金の酸化、乾燥不十分等。 ガス抜きが不十分。 冷やし金サビ、汚れ	外観上問題あり、使用不可。 加工で完全に消失すれば、使用検討可。 欠陥のフカサを確認する。	外側に発生するものについては他への影響が無いことを確認(肉厚確保)した後、ガスor電気溶接補修。	加工後に欠陥が残る可能性がある。 オイル浸漬部分との貫通が無いか注意すること。 部位と強度、外観品質
外ヒケ		肉厚部の表面。 黒皮表面が深固収縮により、正常面から大きく凹む。 削り代以上の凹み。 表面はうねり状態。 事例: 面ヒケA1	黒皮表面に発生。 肉厚部に発生し易い。 押湯直下に発生し易い。 凝固が遅い部分周辺。	押湯不足。 鋳型通気度不足。 方案の検討不足。	黒皮使用部の場合、肉厚が確保できれば使用可能。 加工する場合、黒皮残りが生じない削り代があれば使用可能。	ガス溶接。	加工部分の場合、黒皮残りとなる可能性がある。 加工後の表面にヒケ巣が発生している可能性がある。 加工後十分注意すること。 多発性がある。
ヒケ巣		加工後に露出するヒケ巣。 深固収縮により、内部でヒケが生じラジカ巣となる。 欠陥の深さ判定が困難。 事例: ヒケ巣A1	製品内部に発生。 肉厚部分に発生し易い。	凝固時の収縮による溶湯不足。(押湯不足) 適度な肉厚不均。	シールや強度に対して影響が大きく使用不可。	補修不可。	ヒケ部分の範囲を十分観察すること。 多発性がある。
湯境		凝固時に融合しない部分が発生し境ができる。(内外貫通) 表面のみで内外の貫通が無い場合がある。 すし杖の欠陥。 事例: 湯境A1	肉厚部分に発生し易い。 湯流れ合流部。	製造方案検討不足 低い温度や速度による湯の停滞。 注湯時のチョコ停。	亀裂の事象に近く、内外貫通が無い場合でも欠陥の進行性があるので使用不可。	補修不可。	欠陥が進行し拡大化する可能性がある。 欠陥の大きさや深さを確認すること。 オイル浸漬部分では、貫通する可能性がある。
バリ		砂型が割れたスキマ部分へ湯が差し込みバリとなる。	中子部に発生する。 主要部も発生する。 発生部位不特定。 巾木部分との境界部分。 砂型分割部分。	方案検討不足。 中子の強度不足。 主要部の強度不足。	グラインダーで除去後使用検討可。	グラインダー除去。	砂カミ部分が発生している可能性がある。 寸法公差外の可能性がある。 十分に湯が回っていない部分がないか確認すること。
打痕		落下等で強く打ち付けられ打痕を付ける。 ドラムショット工程等の製品間の干渉がある工程で発生し易い。	発生部位不特定。 角部分に発生し易い。	抜型時の落下等で打痕が付く。 ドラムショット等で部品間の干渉。 その他落下等。	歪の影響が無い場合、削り代範囲内であれば、使用検討可。 黒皮のまま使用される部分は滑らかに整えたと使用可能。	黒皮仕様の場合、電気溶接orガス溶接。 凸部分はグラインダー除去。	加工部分では黒皮残りが発生する可能性がある。 シール部分では、特に黒皮残り注意のこと。 シール面やボルト座面が確保できずか確認が必要。 歪や亀裂が無いか十分確認すること。

表 3.1-1 (3) 鑄造品表面欠陥

欠陥事象	パターン (写真) (10円玉直径: 23.5mm)	欠陥状態/特徴	欠陥発生部位	推定原因	納入先の指示に従う (参考使用判定)	納入先の指示に従う (参考補修例)	納入先と協議する (参考その他確認事項・懸念事項)
亀裂・割れ		欠陥の深さ判定が困難。 割れは進行性があるので、深さが浅い欠陥でも重大欠陥となる。 事例：亀裂	薄肉部分に発生しやすい。 急冷される部分。	材質組織の異常。 成分値の異常。 外的に何らかの衝撃が加わった。 急冷による収縮。 鑄型の歪	使用不可。	割れ部分を完全除去後、ガス溶接。 加工後は補修不可。	カーフェックで深さの程度を確認する。 割れは進行する欠陥のため十分注意すること。
型ズレ (PL: 砂型分割面)		砂型の上型と下型のズレ。 砂型分割面を境にズレが生じる。	全ての見切り部分。 中子部分砂型分割面のズレ。 主要部分砂型分割面のズレ。	位置決めピンの摩耗。 上型と下型セット時に傾けズレる。 上型と下型セット後、ライン上で押し出される時にズレる。	1 mm程度のズレは使用検討可。 削り代範囲内かつ肉厚が確保できる状態は使用検討可。	グラインダー成型等。	加工時黒皮残りの可能性あり。 各部位のズレを全て確認する。 外観品質を考慮する。 肉薄部分が発生するので注意。
肌荒れ		砂の焼き付きに似ている。 表面のザラつきが酷い。 表面に現れる巣に似ている。 表面剥離する場合がある。	凹みが深い部分に発生し易い。 抜き勾配がキツイ部分に発生し易い。	差型が不十分。 砂の詰まりが不十分。 模型老朽の影響。	外観判定が厳しい部分は使用不可。 グラインダーで表面を整えたと使用検討可。	グラインダーで表面を整える。 外部の場合はパテ補修検討可。	肉厚部分に発生している場合はヒケ巣が発生しているか確認する。 肉厚が薄い部分については、内外が貫通していないか確認が必要。 剥離の懸念があるので、内部であれば完全除去すること。
型崩れ		部分的に砂型が崩れ形状がぼやけた状態。 入れ干しの現象に似ている。	砂の詰まりが不足し易い エッジ部に発生することが多い。	差型が不十分。 砂の詰まりが不十分。 模型老朽の影響。	外観判定が厳しい部分は使用不可。 グラインダーで表面を整えたと使用検討可。 加工代の範囲であれば使用検討可。	グラインダーで表面を整える。 外部の場合はパテ補修検討可。	肉厚が確保できない可能性があるため、加工される部分に影響が無いかなど、十分確認を行うこと。 崩れた砂が製品内へ流れ込んでいる可能性があるので、欠陥の周辺を異常が無いか十分観察すること。
サビ		表面に酸化物付着 表面の色が赤くなる。 赤色が薄いと分り難い 油が付着していると分り難い 水分があると発生し易い	表面全体に発生する。 水分が溜まり易い凹み部分 防錆油が塗布されていない部分	仕上げ後放置している。 防錆油が塗布不足。 水分が付着。 長期放置している表面に汚れが溜まった状態。	サビた表面をグラインダーで削ると使用検討可。 表面をワイヤーブラシ等で完全にサビを除去できれば再ショットで未加工品であれば再ショットでサビを完全除去し使用可。	補修は不能。 サビは完全除去のみ。	サビが少しでも残っていると油圧性能に影響が出るので注意すること。 サビは異物なので、バルブ等の隙間で滞留し作動不良を起こすので注意すること。 油が汚れるので注意すること。

## 3.2 鋳造品欠陥知識を踏まえた注意喚起

### 3.2.1 全般

タブレット上に、3.1 で述べた表面欠陥ガイドや鋳造品欠陥識別等文書を保存しておき、場面（シナリオ）に応じて、それら文書情報から検査員に対話形式で注意喚起する機能を実装したアプリを制作する。本アプリを作成する目的は、タブレット上に表面欠陥ガイドを表示した場合、画面サイズによっては、画面をスクロールしなければ、知りたい情報がすぐに探せないことが懸念されるためである。そこで、表面欠陥ガイドの情報について、リンク先を飛び回ることなく、知りたい情報（気づき）を表示させることとする。

本アプリでは、以下の三つのシナリオを用意した。

シナリオ1：欠陥発見時

シナリオ2：検査前（準備）

シナリオ3：AI判定後判断

シナリオ1は、検査現場での活用をイメージしている。見つけた欠陥状態から同様の原因で、別の欠陥事象が無いかを本アプリにて推論し、検査員にわかりやすく画面表示する。シナリオ2は、検査前準備の段階で活用することをイメージしている。検査対象品の設計情報（製品としての使用部位）を画面上から選択し、表面欠陥ガイドの知識情報を踏まえて、検査員に重点検査箇所を事前に情報提供することを目的とする。シナリオ3は、3.3 で述べる AI システムと併用した場面での活用をイメージしている。画像認識 AI による欠陥判定は、AI による認識アルゴリズム上、すなわち、撮影画像のピクセル情報から欠陥の特徴抽出を行うアルゴリズムに限界がある。たとえば、ピンホールとブローホールは欠陥形状（特徴）が似ているが、欠陥サイズの違い等で欠陥種類が異なるような場合、欠陥事象を区別するのは困難である。本シナリオ3では、似た欠陥事象、似た欠陥状態、似た使用判定ごとに、検査員に情報提供する。

ベテランには「なるほど」、若手には「そうなんだ」といえるようなシナリオを目指して制作した。現時点、欠陥識別とその判定知識は、表面欠陥ガイドに記載されている情報がすべてである。使用者が社内で共有したい知識を追加していくことで、より拡張したアプリになる。

第三次 AI ブームでは、深層ニューラルネットワーク技術の活用が注目を浴びている。人工知能研究は、ニューラルネットワーク技術をベースにする“コネクショニズム”研究と知識処理を目的とする“記号論理”研究の大きく二つの流れがある。本節で述べる知識処理 AI は、オントロジー技術を活用した“記号論理”研究の流れを組む。

### 3.2.2 知識処理 AI について

#### 1) AI による知識表現、論理、推論

コンピュータに人間が知っている知識をプログラムする手法の一つに、プロダクションルール（if-then 形式）がある。プロダクションルールでプログラムした場合、想定したこと以上の汎用性を持った処理、たとえば推論処理等を期待することはできず、使用は大きく限定される。

AI 研究では、コンピュータ上に知識をどのように記述し、コンピュータが知識をどのように処理するかを長年行ってきた。そこで、これらの研究は、「知識表現」と呼ばれる分野である。「知識表現」研究は、知識を表現する際の一般的な形式（知識表現形式）や知識を用いる際の汎用な仕組み（推論方式）を研究してきた。代表的な研究に、エキスパートシステムがある。これは専門知識をコンピュータ上に知識として実装し、推論エンジンを使用してエキスパート（専門家）と同じ判断をコンピュータにさせることを目的とした。エキスパートシステムは、知識がベースになる。本報告では、表面欠陥ガイドにある情報（知識）をコンピュータに表現し、推論技術を使って使用者（特に、経験の浅い検査員）がベテラン（表面欠陥ガイドの内容を理解している検査員）と同じ判定を行うことを目指す。

#### 2) オントロジーについて

オントロジーは、対象世界の概念を明示化することを目的に使用される。対象世界を記述する知識、モデルに現れる基盤的な概念クラスとそれらの間の意味関係から構成された「概念体系」にあたる。意味関係は、主に、一般と特殊関係（分類関係、is-a 関係）や全体と部分関係（part-of 関係）などが一般的である。概念クラス間を意味関係で結びつけることで、「体系的に」概念クラスの意味が定義される。さらに、概念が満たすべき公理を記述することで、意味が厳密に定義される。

なお、本報告で制作したアプリは、Protégé（オントロジーエディタ）を使用した。Protégé では、クラス、関係と個体を定義して処理を行った。

### 3.2.3 鋳造品欠陥知識を踏まえた注意喚起アプリ制作

#### 1) 全般

鋳造品欠陥知識を踏まえた注意喚起アプリは、表面欠陥ガイドを参照しながら、推論処理をふまえて動作する。推論処理はオントロジーエディタ Protégé を使用したが、推論結果をマクロ入りエクセルファイルに取り込んでいるため、使用者は提供するマクロ入りエクセルファイルと表面欠陥ガイドのみを Windows10 のパソコン（タブレット）に保存するだけで利用できる。図 3.2-1 に、使用イメージを示す。



図 3.2-1 注意喚起アプリ使用イメージ

#### 2) 注意喚起アプリの使い方

Windows10 のタブレットの仕様フォルダ（同一フォルダに）に、以下の二つのファイルを保存する。

①鋳造品欠陥知識を踏まえた注意喚起アプリ.xlsm

②20220926 鋳造品表面欠陥識別及び使用判定ガイド（補修及び懸念事項検討）.xlsm

上記①のファイルを開くと、図 3.2-2 に示すように、トップページが表示される。3.2.1 で述べたように、三つのシナリオがボタン表示されている。

シナリオ 1：見つけた欠陥状態からスタート

シナリオ 2：使う場所によっては要注意！！

シナリオ 3：似ていて見分けがつかない？！

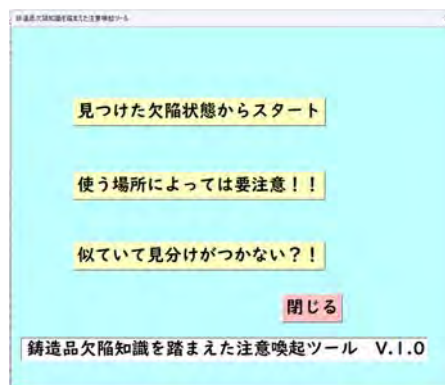


図 3.2-2 注意喚起アプリトップページ



シナリオ1（見つけた欠陥状態からスタート）について操作のイメージを説明する。例えば、検査現場において、**図 3.2-3**のような欠陥（砂カミ）を発見したとする。砂カミは、表面欠陥ガイドの欠陥状態にあるように、欠陥表面に砂が付着していることが特徴として挙げられる。



図 3.2-3 欠陥（砂カミ）を見つけた例（シナリオ1）

そこで、**図 3.2-4**に示すウィンドウの中から「欠陥表面に砂が付着」を選択して「実行」ボタンを押すと**図 3.2-5**に進む。基本的には、ウィンドウ内の指示にしたがって、対話形式で進む。

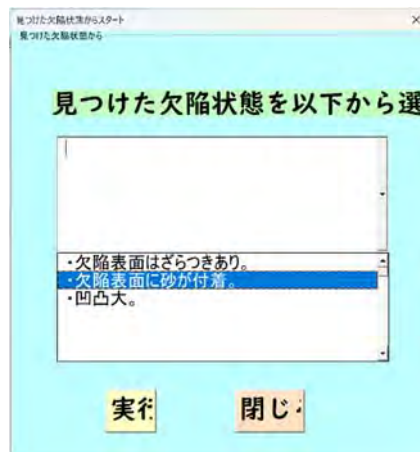


図 3.2-4 見つけた欠陥状態からスタートを選択する画面（シナリオ1）

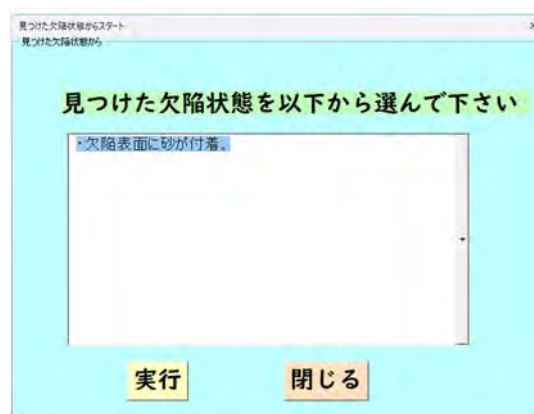


図 3.2-5 欠陥表面に砂が付着した欠陥状態を選択する画面（シナリオ1）

図 3.2-5 の画面で「実行」ボタンを押すと、図 3.2-6 のように、表面欠陥ガイドがあらわれ、欠陥の推定原因が似ている「砂の焼付き」が選択される。

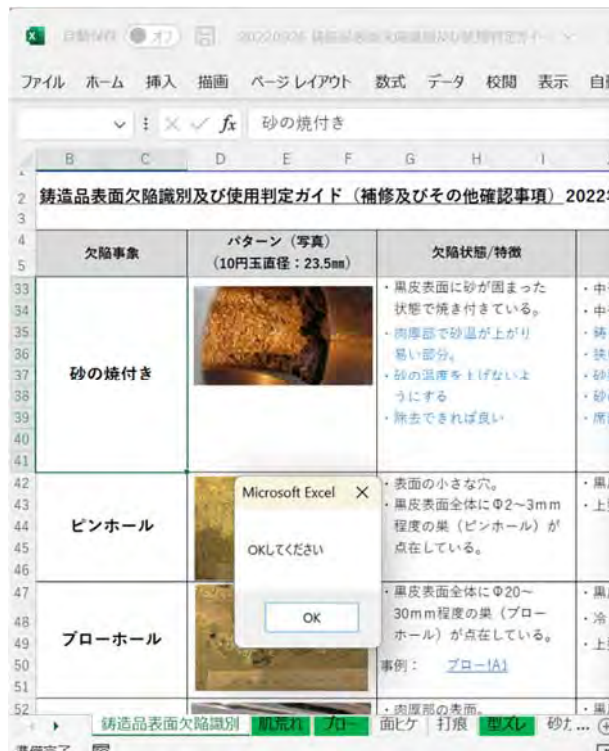


図 3.2-6 砂の焼付き (欠陥事象) をハイライト (シナリオ 1)

確認の上、「OK」ボタンを押すと、図 3.2-7 のように「砂の焼付き」が起こりやすい発生部位セルに移動する。このように、検査で発見した欠陥事象から別の欠陥が発生していないか、検査員に検査を促している。検査で見落としが無いように注意を促している。



図 3.2-7 砂の焼付き (欠陥発生部位) をハイライト (シナリオ 1)

このような手順を繰り返していると、鋳造品表面欠陥の検査知識が身につくことが期待される。

次に、シナリオ2（使う場所によっては要注意！！）について操作を説明する。図 3.2-8 の画面で、「使う場所によっては要注意！！」ボタンを押すと、図 3.2-9 の画面に移り、使用部位を選択する画面になる。

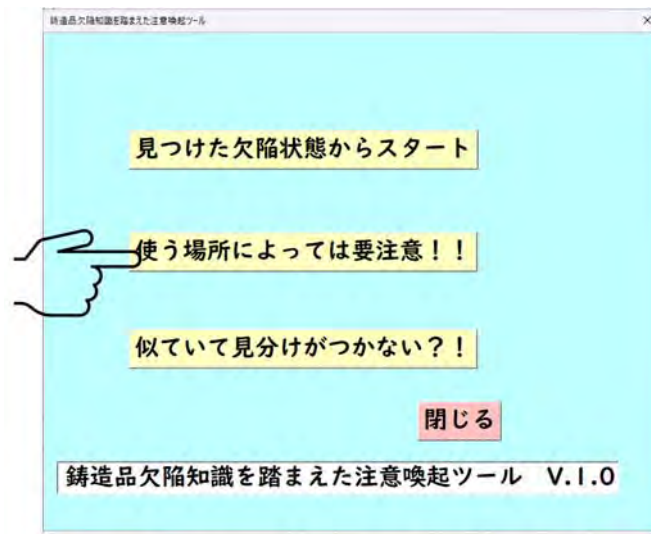


図 3.2-8 使う場所によっては要注意！！を選択する画面（シナリオ2）

これは、検査前準備として、検査対象製品の使用部位（設計情報）を念頭に検査時に注意する箇所を抑えておくことを目的とする。主に、若手検査員に向けた機能である。

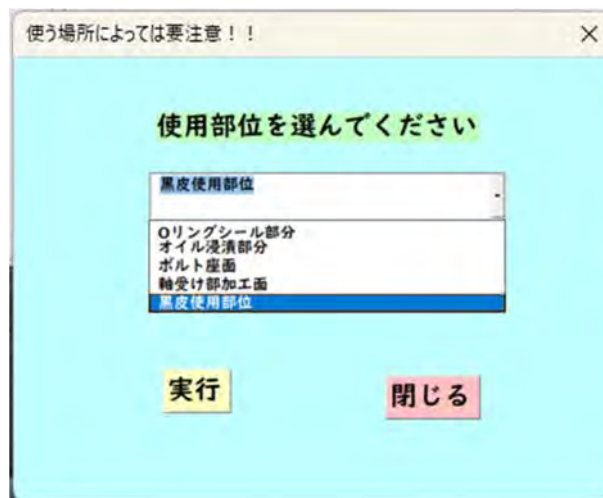


図 3.2-9 使用部位を選択する画面（シナリオ2）

使用部位を選択すると、図 3.2-10 のようなメッセージが表示される。「OK」を押すと、図 3.2-11 のように、使用判定に移動する。



図 3.2-10 使用判定へ誘導する対話メッセージ（シナリオ2）

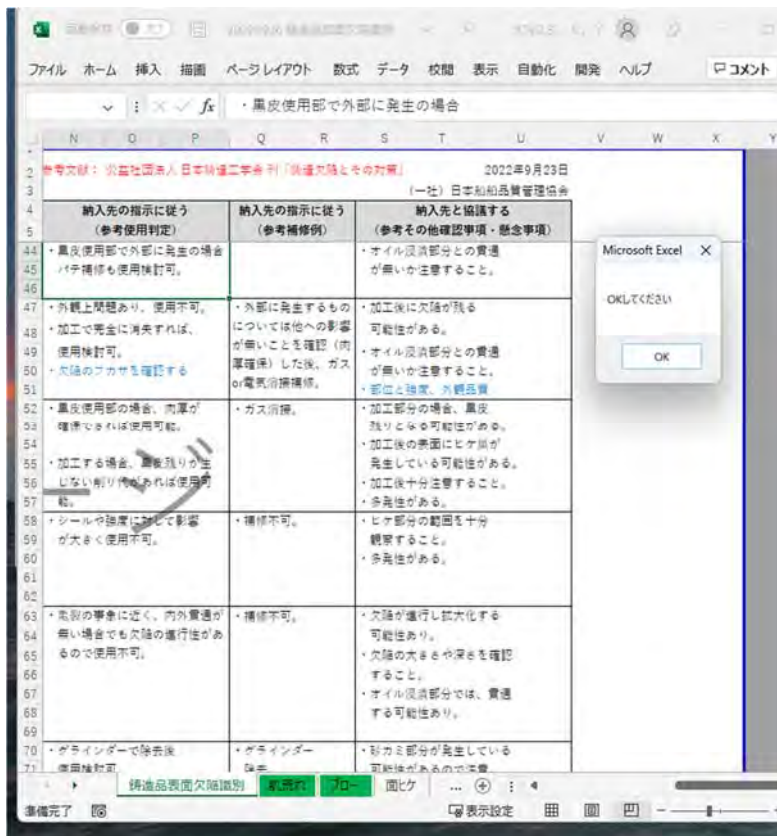


図 3.2-11 誘導された使用判定がハイライト (シナリオ 2)

図 3.2-11 で「OK」ボタンを押すと、類似の欠陥事象であるピンホールがハイライトされる (図 3.2-12 参照)。



図 3.2-12 類似の欠陥事象 (ピンホール) がハイライト (シナリオ 2)

次に、シナリオ3（似ていて見分けがつかない?!）について操作を説明する。図 3.2-13 の画面で、「似ていて見分けがつかない?!」ボタンを押すと、図 3.2-14 のように、「似ている欠陥状態」なのか、「似ている欠陥事象」なのか、「似ている欠陥使用判定」なのかを選択する。

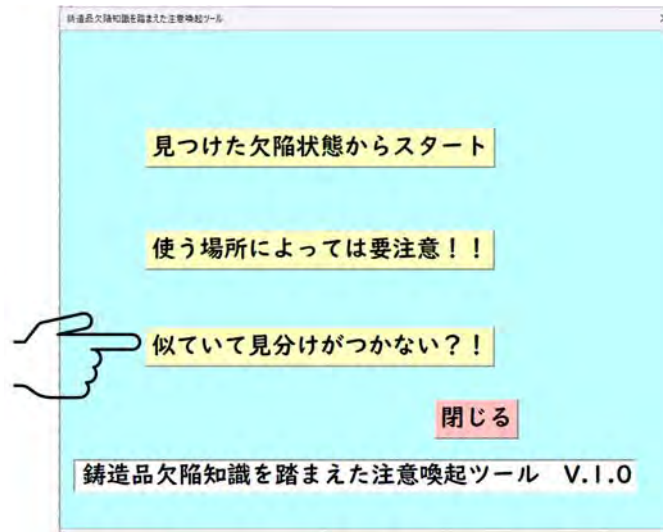


図 3.2-13 似ていて見分けがつかない?!を選択する画面（シナリオ3）

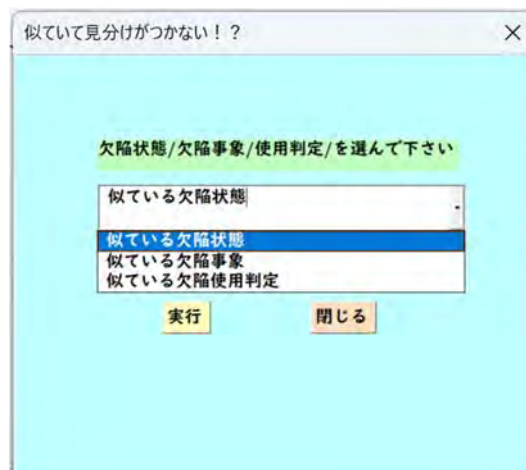


図 3.2-14 似たものを選択する画面（シナリオ3）

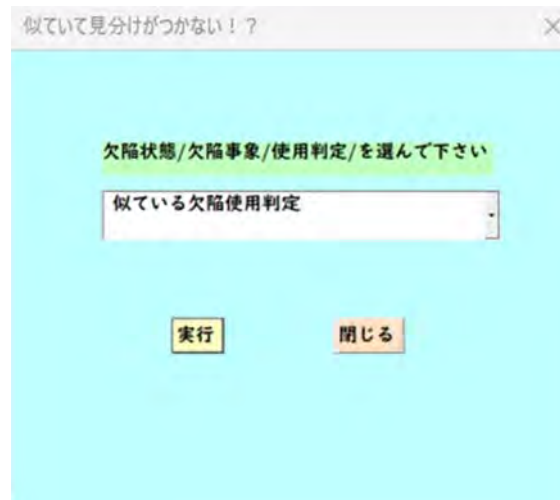


図 3.2-15 似ている欠陥使用判定を選択する画面（シナリオ3）

図 3.2-15 の画面で「似ている欠陥使用判定」を選択したとする。図 3.2-16 のように、使用判定へ誘導する画面が表示される（図 3.2-17 参照）。表面欠陥ガイド内で「似ている欠陥使用判定」を表示する。シナリオ 3 は、若手検査員が判断に迷ったとき、あるいは AI 判定結果を吟味するときをイメージしている。例えば、図 3.2-18 では湯境と似た欠陥事象が、図 3.2-19、図 3.2-20 に示すように対話を通じて、表面欠陥ガイド内で移動し、ポップアップする。そのため、知りたい情報を短時間で得ることができる。鋳造品の表面欠陥知識を、本表面欠陥ガイドを使用しながら習得することができる。



図 3.2-16 使用判定へ誘導する画面（シナリオ 3）

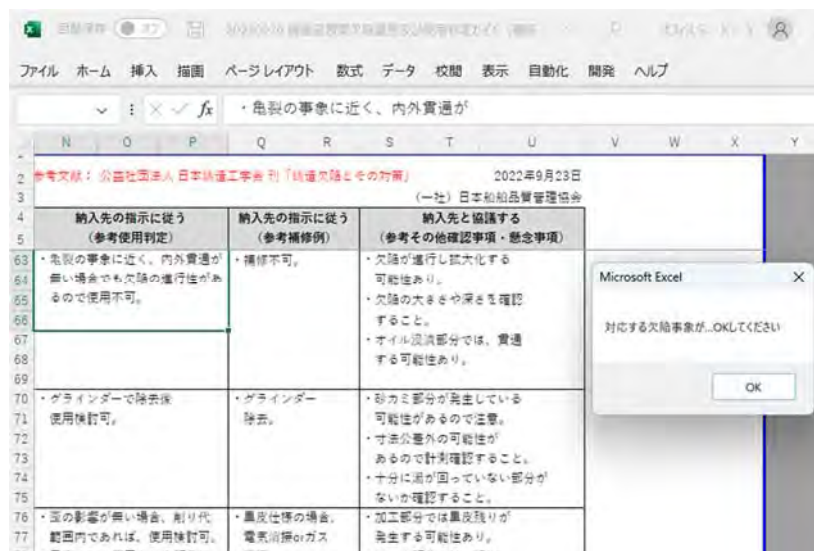


図 3.2-17 誘導された使用判定がハイライト（シナリオ 3）

鋳造品表面欠陥識別及び使用判定ガイド（補修及びその他確認事項）2022年度上期版

欠陥事象	パターン（写真） (10円玉直径：23.5mm)	欠陥特徴/特徴	欠陥発生部位	推定原因	納入先の指示 (参考使用)
湯境		<ul style="list-style-type: none"> <li>剥離時に融合しない部分が発生し残ることができる。(内外貫通)</li> </ul>	<ul style="list-style-type: none"> <li>導向部分に発生し多い。</li> <li>混流れ合流部。</li> </ul>	<ul style="list-style-type: none"> <li>積層方向検訂不足</li> <li>低い温度や速度による湯の停留。</li> <li>注湯時のチヨコ等。</li> </ul>	<ul style="list-style-type: none"> <li>急裂の事象に近く無い場合でも欠陥があるので使用不可。</li> </ul>
バリ			<ul style="list-style-type: none"> <li>砂型分割部分。</li> </ul>	<ul style="list-style-type: none"> <li>方向検訂不足。</li> <li>中子の強度不足。</li> <li>主製の強度不足。</li> </ul>	<ul style="list-style-type: none"> <li>グラインダーで除使用検訂可。</li> </ul>

図 3.2-18 類似の欠陥事象（湯境）がハイライト（シナリオ 3）

納入先の指示に従う (参考使用判定)	納入先の指示に従う (参考補修例)	納入先と協議する (参考その他確認事項・懸念事項)
・使用不可	・割れ部分を完全除去後、ガス消滅。 ・加工後は補修不可。	・カラーチェックで深さの程度を確認する。 ・割れは進行する欠陥のため十分注意すること
・1mm程度のズレは使用検討可。 ・削り代範囲内であつ肉厚が確保できる状態は使用検討可。	・グラインダー成型等。	・加工時黒皮残り ・各部位のズレを、 ・外観品質を考慮 ・肉厚部分が発生

図 3.2-19 類似の欠陥事象（湯境）の使用判定（シナリオ 3）

製造品表面欠陥識別及び使用判定ガイド（補修及びその他確認事項）2022年度上期案 [表面欠陥判定基準](#)

欠陥事象	パターン（写真） (10円玉直径：23.5mm)	欠陥状態/特徴	欠陥発生部位	推定原因
亀裂・割れ		・欠陥の深さ判定が困難。 ・割れは進行性があるので、深さが深い欠陥でも重大欠陥となる。 事例：亀裂	・導肉部分に発生しやすい。 ・急冷される部分。	・材質組織の異常。 ・成分値の異常。 ・外的に何らかの衝撃が加わった。 ・急冷による収縮。 ・成型の歪
型ズレ (PL：砂型分割面)		Microsoft Excel OK	・全ての見切り部分。 ・中子部分砂型分割面のズレ。 ・主型部分砂型分割面のズレ。	・位置決めピンの摩耗。 ・上型と下型セット時に挿げズレる。 ・上型と下型セット後、ライン上で押し出される時にズレる。
		Microsoft Excel OK	・凹みが深い部分に発生し多い。	・成型が不十分。 ・砂の詰まりが不十分。

図 3.2-20 類似の欠陥事象（亀裂・割れ）がハイライト（シナリオ 3）

### 3.3 表面欠陥検出システム制作

#### 3.3.1 画像認識 AI アプリ

ここで活用する画像認識 AI は、畳み込みニューラルネットワーク(Convolutional Neural Network : CNN)を発展させた物体検出技術の一つである Region Proposal Network (R-CNN)である。畳み込みニューラルネットワークは、特定の形状を捉える畳み込み層とプーリング層を階層的に配置した、図 3.3-1 に示したような構造となっている。これは人間の視覚機能を模したニューラルネットワーク構造である。画像処理としては、畳み込み層はフィルター処理に相当し、プーリング層は画像縮小に相当する。畳み込み層とプーリング層を重ねて層を深くし、最後は全結合層（パーセプトロン）で分類（識別）処理を行う仕組みとなっている。

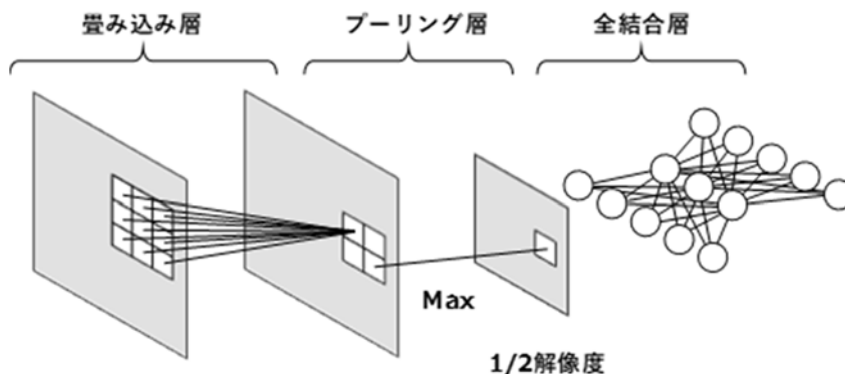


図 3.3-1 畳み込みニューラルネットワーク

畳み込みニューラルネットワークの畳み込み層は、図 3.3-2 に示すように、入力に対して重みフィルターの内積を計算する。1層目の畳み込み層では、入力サンプルに対して畳み込み処理を行い、特徴マップを求める。2層目以降の畳み込み層では、前層の特徴マップを入力として同様に畳み込み処理を行う。畳み込み処理で得られた値は、そのまま特徴マップの値とはしない。畳み込み処理で得られた値を活性化関数に与えて、その出力を特徴マップの値とする。活性化関数にはシグモイド関数や ReLU などを使用される。

プーリング層は、畳み込み層から出力された特徴マップを縮小する処理を行っている。その時、着目する領域を設定してその領域の特徴マップの値から新たな特徴マップの値を求める。これにより、幾何学変化などに対する普遍性を獲得することができる。プーリング層の処理として最もよく使われるのが、最大値プーリングである。最大値プーリングは、注目領域の中の最大値を新たに特徴マップの値とする手法である。

最後の全結合層は、多層パーセプトロンと同様にシナプスの重みを計算し、活性化関数によりユニットの値を求める。最初の全結合層の入力は、畳み込み層またはプーリング層の出力であり、2次元の特徴マップを1次元に展開して与える。識別層では、各クラスの尤度を求める。尤度が最大となるクラスを分類クラスとして出力する。ここまでの、Deep Learning を利用した物体の識別技術である。

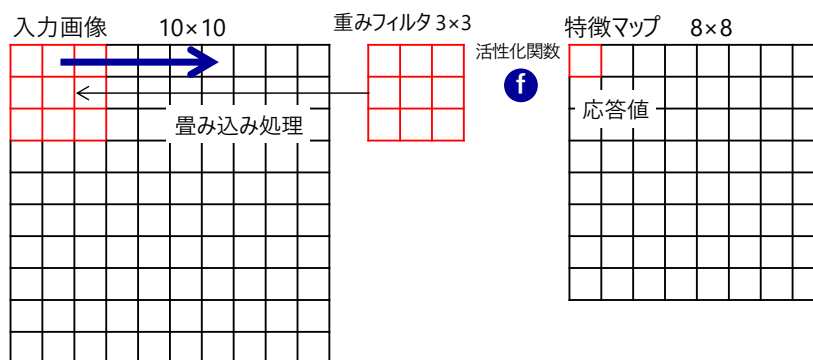


図 3.3-2 畳み込み層の処理

Deep Learning を利用した物体の識別技術を発展させ、物体検出技術が進歩した。物体検出技術（画像認識）は、写真の中にあらかじめ学習した物体がどこにあり、その認識精度を確率表示する技術である。本調査研究では、Faster R-CNN モデルを利用した<sup>1)</sup>。Faster R-CNN モデルを図 3.3-3 に示す。




図 3.3-3 Faster R-CNN モデル<sup>1)</sup>



表面欠陥を学習させるために、表面欠陥が撮影された画像を用意する必要がある。本事業に設置した作業部会メンバー（事業所）は、今後、鋳造品の表面欠陥画像を記録として保存し、蓄積していくことができる。そのため、「AI 技術の活用による不適合未然防止」事業で開発した「画像認識アプリ」を事業所で活用し、独自に画像認識 AI の学習効果の検証、欠陥認識精度の評価を行うことができる。事業所で独自に教師データ（欠陥画像）を整備し、画像認識 AI の学習を進めていくことができる。画像認識 AI の学習、認識精度を高めていく工夫（方法）、例えば、欠陥画像の撮影方法、多様で大量の欠陥画像を効率よく整備していく方法等、画一的な方法も検討していく必要がある。

### 3.3.2 表面欠陥検出システム予備実験

#### 1) 表面欠陥検出システム概要

検査員と並行して AI が鋳造品の表面欠陥検出を行うシステムとし、検査員の負担を軽減することを目的とする。本システムの実用イメージを図 3.3-4 に示す。

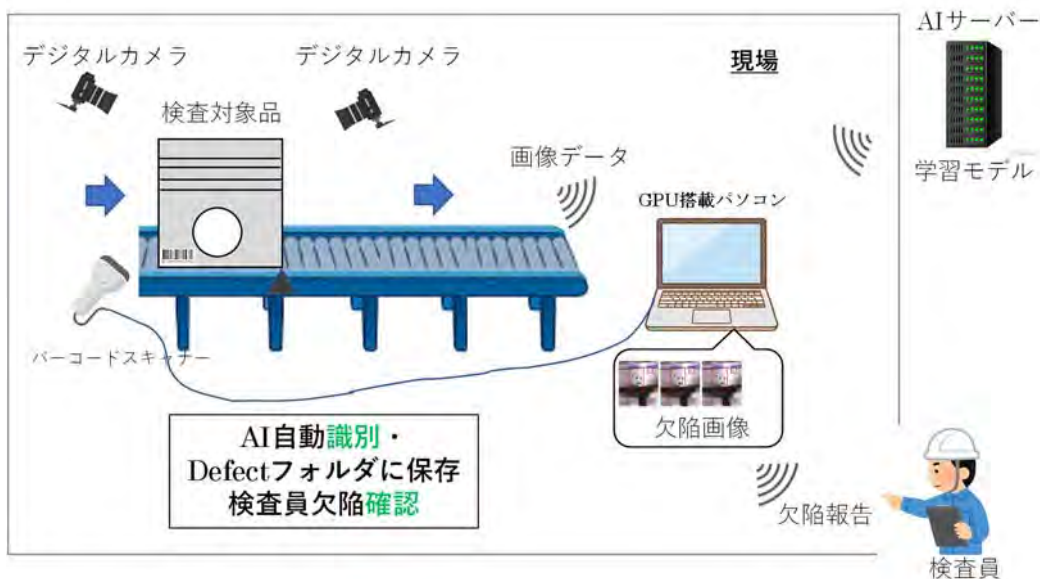


図 3.3-4 表面欠陥検出システムイメージ

#### 2) 表面欠陥検出システム予備実験

製造工場における実証実験の前に、表面欠陥検出システムを組んだ予備実験を海上技術安全研究所にて行った。実験風景を図 3.3-5 に示す。検査対象品（鋳造品）の全表面をもれなく撮影できるように、上面からの撮影（1 箇所）と側面からの撮影（4 箇所）をデジタルカメラ 2 台とウェブカメラ 3 台を使用して行った。デジタルカメラとウェブカメラを併用した理由は、撮影された画像の画質等性能の違い、ズーム等機能の違い、価格の違いを確認するためである。現場への展開を考えると、費用対効果の高いデバイスが求められる。この観点に立つと、ウェブカメラでも画像認識精度に遜色なければ導入にあたって問題ない。予備実験で使用した検査対象品（鋳造品）の表面に欠陥がある。表面欠陥はデジタルカメラにて撮影した。AI 解析用パソコンには、前述の「画像認識アプリ」の改良版が組み込まれている。改良版「画像認識アプリ」の画面では、を図 3.3-6 のように、それぞれのカメラによる画像が別々のウィンドウ画面で表示される。

「画像認識アプリ」の改良で、図 3.3-4 に示すように、検査員と並行して AI が鋳造品の表面欠陥検出を行い、表面欠陥を検出すれば、その旨を検査員にメールにて知らせる機能を追加した。




図 3.3-5 表面欠陥検出システム予備実験風景

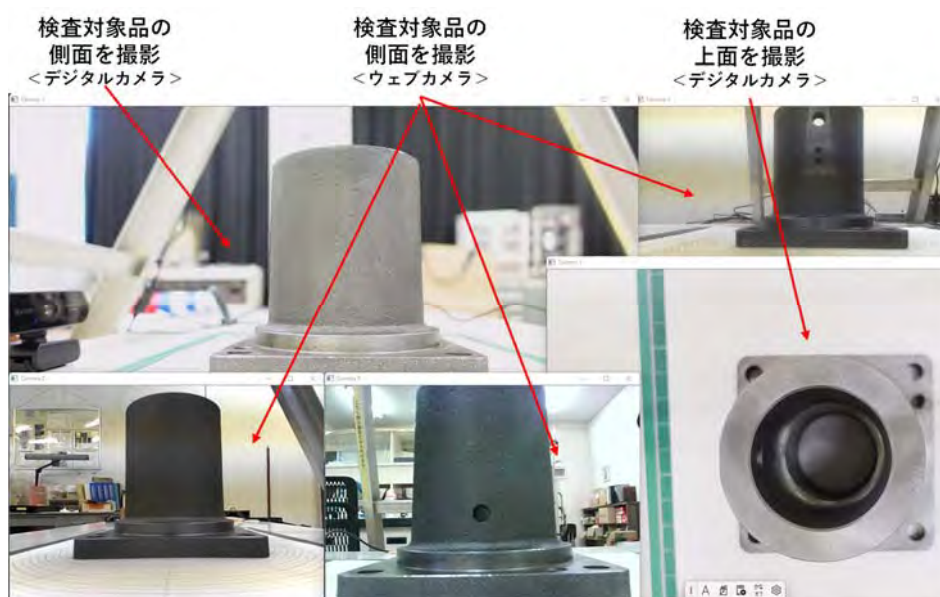


図 3.3-6 パソコンに読み込んだ撮影画像 (上面から1箇所, 側面から4箇所)

### 3.4 AIによる表面欠陥認識

AIによる内部欠陥判定支援をするために、本研究に参加している鋳造品製造会社が収集した鋳造欠陥の画像データを学習用データとテスト用データに分けて学習用データから学習モデルを作成し、このモデルをテストデータに適用して鋳造欠陥の検出を行い、有効性を検証した。

#### 3.4.1 学習モデルの作成

昨年度までは学習モデルは品質管理 WebAI システムを使用して、画像データの読み込み、アノテーションの実施、学習モデルの作成、という一連の作業を行っていた。しかし、品質管理 WebAI システムでは、仕様上学習モデル作成後にアノテーションしたデータを参照できない。そのためアノテーションの適・不適を検討できない、さらにアノテーション結果の再利用ができない等の不便さがあった。そこで、今年度は、アノテーションにはフリーソフトの labelImg を使用し、画像データと labelImg が生成した xml ファイルを直接 AI サーバーに転送して、Python によって記述された機械学習プログラムを直接実行することによって学習モデルを作成した。なお、xml ファイルはテキストファイルでありエディタで直接編集することができる。アノテーションの際に作成される xml ファイルの一例を図 3.4-1 に示す。

```

<annotation>    <folder>画像ファイルがあるフォルダ</folder>
                <filename>画像ファイル名</filename>
                <path>"画像のあるパス名"%画像ファイル名</path>
                <source>
                    <database>Unknown</database>
                </source>
                <size>
                    <width>4032</width>
                    <height>3024</height>
                    <depth>3</depth>
                </size>
                <segmented>0</segmented>
                <object>
                    <name>ラベル名</name>
                    <pose>Unspecified</pose>
                    <truncated>0</truncated>
                    <difficult>0</difficult>
                    <bndbox>
                        <xmin>1248</xmin>
                        <ymin>1157</ymin>
                        <xmax>3200</xmax>
                        <ymax>1741</ymax>
                    </bndbox>
                </object>
</annotation>

```

画像ファイルの幅、高さ、色深度

ラベリングすることによりラベル名...</object>が作成

アノテーションの範囲の座標値

図 3.4-1 アノテーションによって作成される xml ファイルの一例

また欠陥の検出にあたっては、海上技術安全研究所で開発した Windows 上で稼働するアプリ (通称 HinkanImage) に判定したい画像を読み込ませることによって行った。HinkanImage からの出力例を図 3.4-2 に示す。図は検出された場合であるが、元の画像に対して上部に欠陥の種類に応じてつけたラベル名とその個数、画像内では欠陥の範囲が四角く囲まれ欠陥のラベル名とその確率も表示される。また、検出されたファイルは、図のようにファイル名に”Recog”が追加され、検出されなかった場合は、”NoRecog”になる。

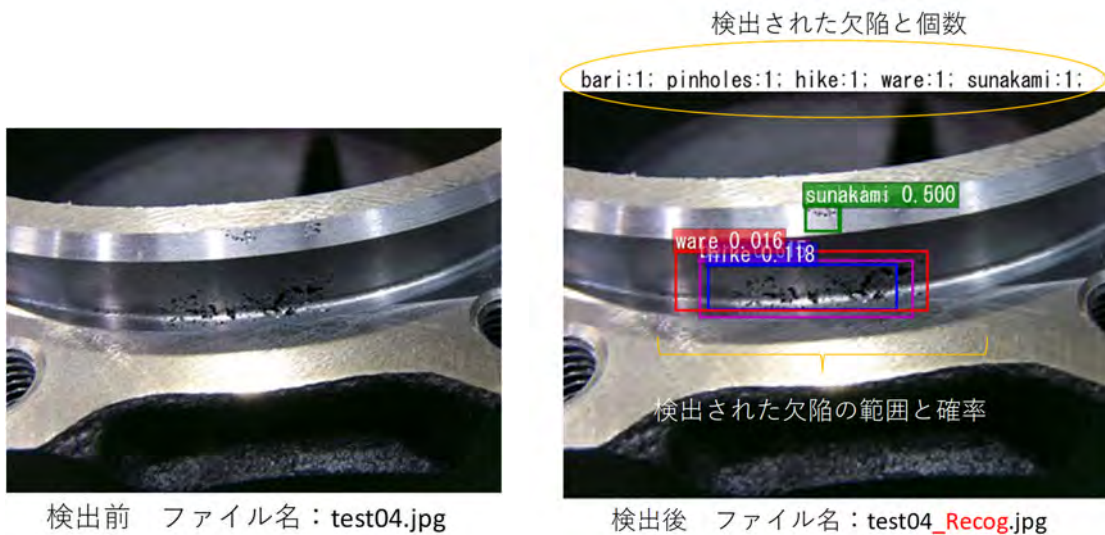


図 3.4-2 HinkanImage からの出力例 (左図：検出前、右図：検出後)

### 3.4.2 学習モデル作成に使用した画像データ

学習にあたっては、典型的な 16 種類の鋳造欠陥に着目して、欠陥を持つ鋳造品の欠陥部をデジタルカメラで撮影し JPEG ファイルとして保存することにより収集した。これらの画像についてアノテーションを行うことにより、学習モデル作成の元データとした。表 3.4-1 に収集した画像データの欠陥ごとの枚数、アノテーションした場所の数、水増しした画像枚数、学習モデル検証用のデータとするために、学習から除外した画像データ (テストデータ) の枚数を示した。画像は異なる鋳造品から撮影したものだけでなく、同じ鋳造品を撮影する位置、倍率

等を変えて撮影したものも含まれる。なお、画像の水増しについては、文献2)の2.2.2に従い、画像のコントラスト値、ガンマ値、平滑化のレベルを各々3段階に変化させることによって元の画像1枚から27枚の画像を作成した。

表3.4-1のNo.1から16の欠陥およびNo.17の機械加工穴について収集した画像から代表的な画像を15枚選択して(15枚以下の場合全数)図3.4-3～図3.4-19に示す。一部画像の中に、撮影した画像にパソコン作業で付与されたであろうアルファベット「A」の文字(余計な情報)が確認できる。これらについて、欠陥のみの画像が入手できなかった。今回は、欠陥画像を数多くそろえることを優先したため、このまま学習に使用した。また学習モデルの検出率を試験するためのテスト画像を図3.4-20に示す。No.16のサビは他の欠陥と比較すると、不定形で面積も一定しないためアノテーションが難しくサビと判断できる箇所の一部だけ行った。またNo.17の機械加工穴は鑄造欠陥ではないが、欠陥検出で機械加工穴がピンホールまたはブローホールと誤認識しないようにするために学習に組み入れている。No.18のテスト用鑄造品は、学習モデルの検証のために用意された欠陥および機械加工穴を持つ鑄造品である。

欠陥によっては、アノテーションの個数にばらつきが生じた。最も数が多かったのは機械加工穴を除けば、No.5のブローホールの33箇所、最も少ないのはNo.8の型ズレの3箇所だった。

表 3.4-1 学習モデル作成に使用した画像データ

No.	欠陥種類	ラベル名	画像枚数	アノテーション個数	水増し画像枚数	テストデータ枚数
1	ノロカミ	norokami	12	13	324	1
2	バリ	bari	7	11	189	1
3	ヒケ巣	hikesu	17	26	459	2
4	ピンホール	pinholes	5	19	135	1
5	ブローホール	blowholes	15	33	405	1
6	外ヒケ	hike	4	6	108	0
7	割れ	ware	19	19	513	2
8	型ズレ	zure	2	3	54	0
9	型崩れ	katakuzure	6	6	162	1
10	砂カミ	sunakami	20	29	540	1
11	砂焼き付き	yakituki	13	16	351	1
12	打痕	dakon	5	5	135	0
13	湯じわ	yujiwa	4	9	108	0
14	湯境	yuzakai	20	29	540	1
15	肌荒れ	hadaare	6	10	162	0
16	サビ	sabi	6	10	162	0
17	機械加工穴	hole	24	121	648	2
18	テスト用鑄造品		1	0	0	1
合計			186	365	4995	15

次にテストデータの画像ファイル名と元のファイル名との対応を表3.4-2に示す。

表 3.4-2 テスト画像データと正解となる欠陥の対応

テストファイル名	正解	元の画像ファイル
test01	ノロカミ	ノロカミ⑪
test02	バリ	バリ⑥
test03	ヒケ巣	ヒケ巣⑪
test04	ヒケ巣	ヒケ巣⑬
test05	ピンホール	ピンホール④
test06	ブローホール	ブローホール⑧
test07	割れ	割れ21
test08	割れ	割れ⑱
test09	型崩れ	型崩れ⑤
test10	砂カミ	砂カミ⑱
test11	砂焼付き	砂焼付き⑧
test12	湯境	湯境⑲
test13	加工穴	IMG_3312
test14	加工穴	IMG_3338
test15	加工穴他	hole




図 3. 4-3 学習に使用した画像データ ノロカミ (12 枚/12 枚中)



バリ①.JPG



バリ②.JPG



バリ③.JPG




バリ④.JPG



バリ⑤.JPG



バリ⑥.JPG



バリ⑦.JPG

図 3.4-4 学習に使用した画像データ バリ (7枚/7枚中)



ヒケ巣①.JPG



ヒケ巣②.JPG




ヒケ巣③.JPG



ヒケ巣④.JPG



ヒケ巣⑤.JPG



ヒケ巣⑥.JPG



ヒケ巣⑦.JPG



ヒケ巣⑧.JPG




ヒケ巣⑨.JPG



ヒケ巣⑩.JPG



ヒケ巣⑪.JPG



ヒケ巣⑫.JPG



ヒケ巣⑬.JPG



ヒケ巣⑭.JPG



ヒケ巣⑮.JPG

図 3. 4-5 学習に使用した画像データ ヒケ巣 (15 枚/17 枚中)





ピンホール①.JPG



ピンホール②.JPG



ピンホール③.JPG



ピンホール④.JPG



ピンホール⑤.JPG

図 3. 4-6 学習に使用した画像データ ピンホール (5 枚/5 枚中)



ブローホール①.JPG




ブローホール②.JPG



ブローホール③.JPG



ブローホール④.JPG



ブローホール⑤.JPG



ブローホール⑥.JPG



ブローホール⑦.JPG



ブローホール⑧.JPG



ブローホール⑨.JPG



ブローホール⑩.JPG



ブローホール⑪.JPG



ブローホール⑫.JPG



ブローホール⑬.JPG



ブローホール⑭.JPG



ブローホール⑮.JPG

図 3.4-7 学習に使用した画像データ ブローホール (15 枚/15 枚中)



外ヒケ◎.JPG



外ヒケ◎.JPG



外ヒケ◎.JPG



外ヒケ◎.JPG


図 3.4-8 学習に使用した画像データ 外ヒケ (4 枚/4 枚中)



割れ①.JPG



割れ②.JPG



割れ③.JPG



割れ④.JPG



割れ⑤.JPG



割れ⑥.JPG



割れ⑦.JPG



割れ⑧.JPG



割れ⑨.JPG



割れ⑩.JPG



割れ⑪.JPG



割れ⑫.JPG



割れ⑬.JPG



割れ⑭.JPG



割れ⑮.JPG

図 3.4-9 学習に使用した画像データ 割れ (15 枚/19 枚中)



型ズレ①.JPG



型ズレ②.JPG

図 3. 4-10 学習に使用した画像データ 型ズレ (2 枚/2 枚中)



型崩れ①.JPG



型崩れ②.JPG



型崩れ③.JPG



型崩れ④.JPG



型崩れ⑤.JPG




型崩れ⑥.JPG

図 3. 4-11 学習に使用した画像データ 型崩れ (6 枚/6 枚中)





砂焼き付き①.JPG



砂焼き付き②.JPG



砂焼き付き③.JPG



砂焼き付き④.JPG



砂焼き付き⑤.JPG




砂焼き付き⑥.JPG




砂焼き付き⑦.JPG



砂焼き付き⑧.JPG



砂焼き付き⑨.JPG



砂焼き付き⑩.JPG



砂焼き付き⑪.JPG



砂焼き付き⑫.JPG



砂焼き付き⑬.JPG




砂焼き付き⑭.JPG

図 3.4-13 学習に使用した画像データ 砂焼き付き (13 枚/15 枚中)



打痕①.jpg



打痕②.jpg



打痕③.jpg



打痕④.jpg



打痕⑤.jpg

図 3.4-14 学習に使用した画像データ 打痕 (5 枚/5 枚中)



湯じわ①.JPG



湯じわ②.JPG



湯じわ③.JPG



湯じわ④.JPG

図 3.4-15 学習に使用した画像データ 湯じわ (4 枚/4 枚中)






図 3.4-16 学習に使用した画像データ 湯境 (15 枚/20 枚中)



肌荒れ◎.JPG



肌荒れ◎.JPG



肌荒れ◎.JPG



肌荒れ◎.JPG



肌荒れ◎.JPG



肌荒れ◎.JPG

図 3.4-17 学習に使用した画像データ 肌荒れ (6枚/6枚中)



サビ◎.JPG



サビ◎.JPG



サビ◎.JPG



サビ◎.JPG



サビ◎.JPG



サビ◎.JPG

図 3.4-18 学習に使用した画像データ サビ (6枚/6枚中)




図 3.4-19 学習に使用した画像データ 機械加工穴 (15 枚/24 枚中)



Test01 (正解:ノロカミ)



Test02 (正解:バリ)



Test03 (正解:ヒケ巣)



Test04 (正解:ヒケ巣)



Test05 (正解:ピンホール)



Test06 (正解:ブローホール)



Test07 (正解:割れ)



Test08 (正解:割れ)



Test09 (正解:型崩れ)



Test10 (正解:砂カミ)



Test11 (正解:砂焼き付き)




Test12 (正解:湯境)



Test13 (正解:加工穴)



Test14 (正解:加工穴)



Test15 (正解:加工穴+欠陥)

図 3.4-20 テスト用画像 (赤枠は欠陥の位置. ただし機械加工穴は穴の数が多いので穴の分布している範囲を囲んだ)

### 3.4.3 作成した学習モデルの種類

学習モデルはアノテーション（ラベリング）の種類，機械加工穴をアノテーション（ラベリング）に含めるか含めないか（機械加工穴を学習させるか否か），水増し学習あり・なしで表 3.4-3 のように計 6 ケースを作成した。機械加工穴を学習させることは，機械加工穴を欠陥と誤認識する確率が下がることを期待している。オリジナルは，表 3.4-3 の欠陥種類に応じてアノテーションした場合であり，defect はすべての欠陥を defect という単一の名前に置き換えて行った場合である。これは，現状では欠陥のサンプルは少なく種類によってもばらつきがあるため，欠陥を個別に学習させるのではなく同一の名前でアノテーションをすれば検出率が向上すると考えられたためである。また水増し学習に関しては元の画像に輝度等を変化させて新たな画像を生成した。ただし，雑音付加のような水増しは行っていない。なお defect 用の xml ファイルの作成は，元の欠陥の種類に応じてアノテーションしてできた xml の<object>の<name>のフィールドを defect に置換することによって行った。

表 3.4-3 作成した学習モデルの種類

Case	ラベリング		
	欠陥	機械加工穴	水増し学習
1	オリジナル16種	なし	なし
2	オリジナル16種	あり	なし
3	オリジナル16種	あり	あり
4	defect	なし	なし
5	defect	あり	なし
6	defect	あり	あり

学習モデルの欠陥検出精度を評価するために次の二つの場合について検討した。第一に，学習に使用した画像データを，テストデータとして検出に用いた場合である。この場合は，HinkanImage で Thresh 値を 0.8 にして検出を行った。画像データファイルのうち検出されたファイル（すなわちファイル名に Recog が付加されたもの）の数と検出されなかったファイル（すなわちファイル名に NoRecog が付加されたもの）の数を比較することによって評価した。第二に，図 3.4-20 のテスト用画像を使用して，HinkanImage で Thresh 値を 0.1 または 0.01 にして検出を行い，欠陥として検出された「欠陥」の種類，範囲，確率について考察を行った。

1) Case1：欠陥オリジナル 16 種，機械加工穴なし（未学習），水増しなし

Case1 は欠陥名称をアノテーションし学習させた場合で，機械加工穴は学習させていない。

i) 学習に使用したデータを用いた欠陥検出

学習データに使用した画像をテスト画像にした。Thresh 値を 0.8 にして検出を行ったところ表 3.4-4 のような結果となった。検出されたものに関しては概ね 0.9 以上の確率で検出された。ただし，ピンホール④\_Recog.jpg と砂焼き付き⑦\_Recog.jpg で誤認識が確認された。機械加工穴はアノテーションに入れていないため，機械加工穴に対して，ピンホール，ブローホールと誤認識していた。また，サビ，型崩れ，湯じわ，肌荒れの検出率がよくなかった。

表 3.4-4 学習に用いた画像をテスト画像にして検出した結果 (Case1)

欠陥	総数	検出	非検出
ノロカミ	12	11	1
バリ	8	8	0
ヒケ巣	19	18	1
ピンホール	6	6	0
ブローホール	16	16	0
外ヒケ	4	4	0
割れ	21	21	0
型ズレ	2	2	0
型崩れ	7	3	4
砂カミ	21	19	2
砂焼き付き	15	15	0
打痕	5	5	0
湯じわ	4	1	3
湯境	21	19	2
肌荒れ	6	3	3
サビ	6	2	4
機械加工穴	56	37	19
合計	229	190	39

ii) テストデータを使用した欠陥検出


テスト用に用意した画像に関しては、Thresh 値が高いと検出率が悪かったため、0.01 という最低値および 0.1 にして行った。結果を図 3.4-21 と図 3.4-22 にそれぞれ示す。図中のファイル名に”Recog”が含まれている画像は欠陥が検出された場合で、”noRecog”は検出されなかった場合である。他のケースも同様なルールに従っている。

欠陥が検出されても正解でない場合や正解であっても確率が極めて低い場合が見られた。テストデータからどのような欠陥が検出されたか、およびその確率をまとめたのが表 3.4-5 である。正解の欠陥のセルに色をつけ、正解の欠陥の確率が一番高い場合は赤字で、それ以外は一番検出率の高い欠陥の数値を水色字で記した。また同じ欠陥が複数回検出された場合は一番高い確率を記述し、欠陥が検出されない画像のファイル名に色をつけた。他のケースの表も同様である。

表 3.4-5 の test01 の結果では、正解であるノロカミよりも割れと検出した確率の方が大きかった。図 3.4-21 と図 3.4-22 を見ると、試験体の境界部分を割れと誤認識しているようである。図 3.4-21 を見ると、ノロカミについては、確率は低いものの、検出できている。



test01\_Recog.jpg




test02\_Recog.jpg



test03\_Recog.jpg



test04\_Recog.jpg



test05\_Recog.jpg



test06\_Recog.jpg



test07\_Recog.jpg



test08\_Recog.jpg



test09\_noRecog.jpg



test10\_noRecog.jpg



test11\_Recog.jpg



test12\_noRecog.jpg



test13\_Recog.jpg



test14\_noRecog.jpg



test15\_Recog.jpg

図 3.4-21 Case 1: テストデータの欠陥検出 (Thresh  $\geq$  0.01)

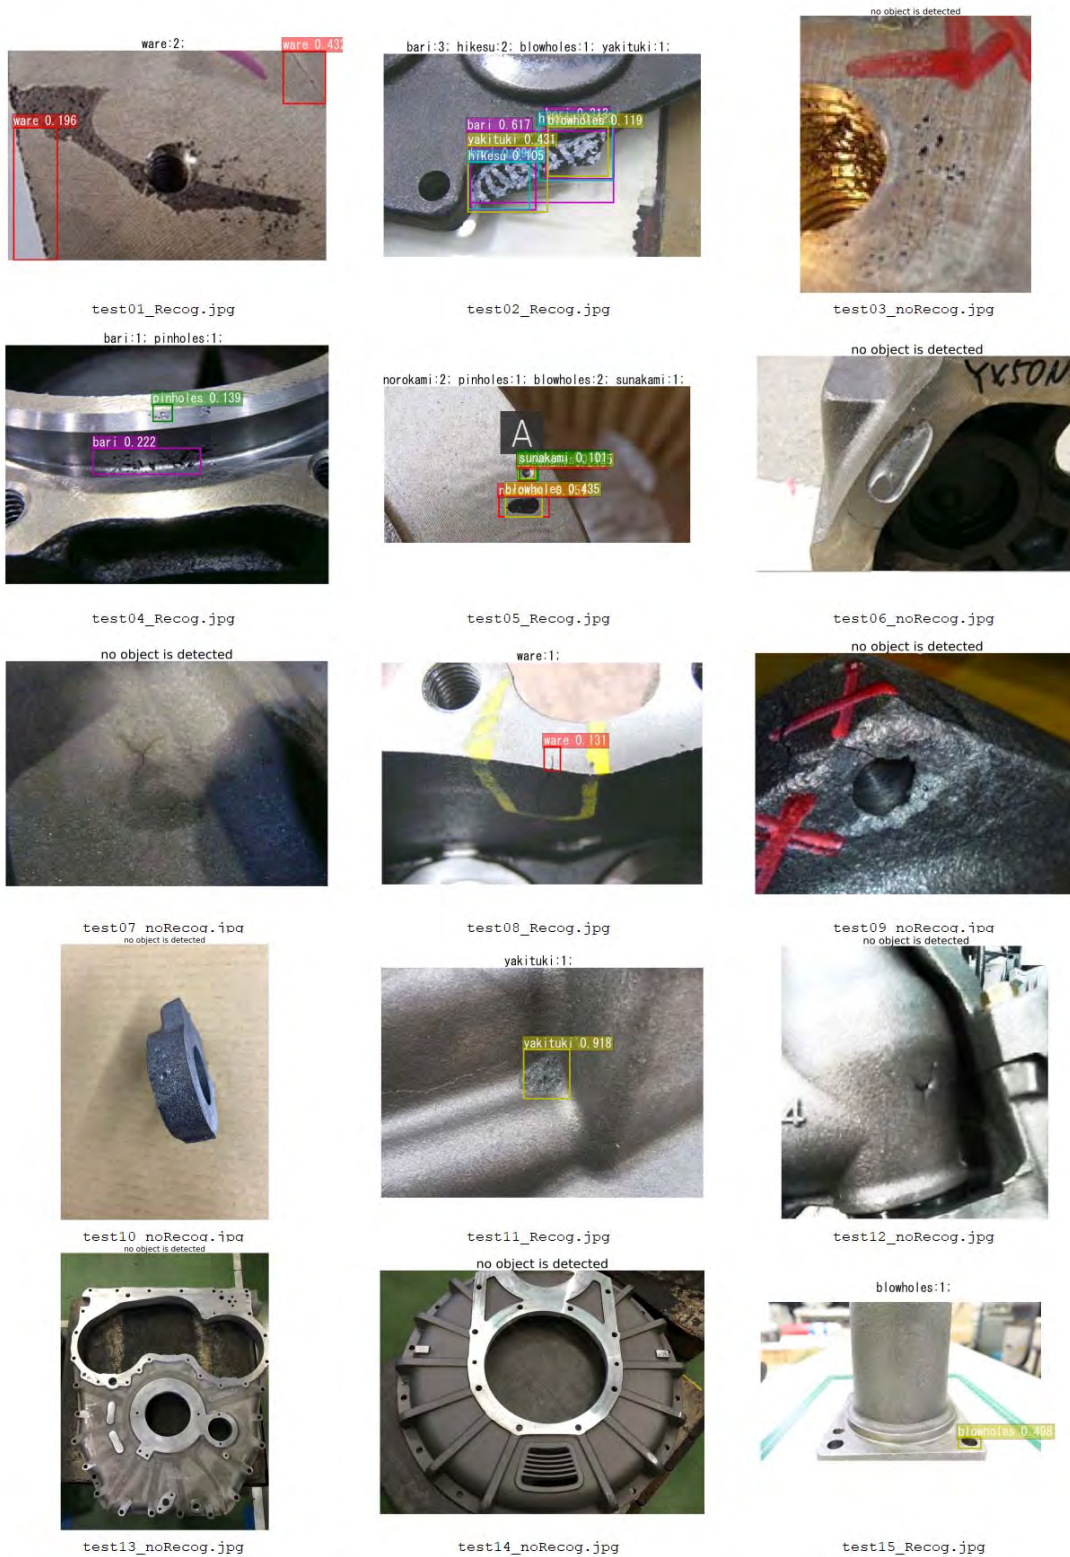


図 3.4-22 Case 1: テストデータの欠陥検出 (Thresh  $\geq$  0.1)



表 3.4-5 Case1 の検出結果 (Thresh  $\geq$  0.01)

(正解の欠陥のセルに色をつけ、正解の欠陥の確率が一番高い場合は赤字で、それ以外が一番高い欠陥の数値を水色字で記した。また同じ欠陥が複数回検出された場合は一番高い確率を記述。欠陥が検出されない画像ファイルに色をつけた。他のケースも同様)

テスト画像	欠陥の正解	検出された欠陥																
		ノロカミ	バリ	ヒケ巣	ピンホール	ブローホール	外ヒケ	割れ	型ズレ	型崩れ	砂カミ	砂焼き付き	湯じわ	湯境	肌荒れ	打痕	サビ	機械加工穴
test01	ノロカミ	0.02						0.43			0.02							
test02	バリ	0.03	0.62	0.92	0.02	0.12	0.02	0.03	0.02	0.02	0.02	0.43		0.04	0.03		0.02	
test03	ヒケ巣										0.02							
test04	ヒケ巣		0.22	0.01	0.14			0.04						0.02				
test05	ピンホール	0.95		0.07	0.19	0.73					0.10	0.02						
test06	ブローホール					0.01												
test07	割れ													0.04				
test08	割れ				0.01			0.13	0.01				0.04	0.06				
test09	型崩れ																	
test10	砂カミ																	
test11	砂焼き付き											0.92				0.05		
test12	湯境																	
test13	機械加工穴				0.01													
test14	機械加工穴																	
test15	機械加工穴他					0.50												

2) Case2 : 欠陥オリジナル 16 種, 機械加工穴あり (学習), 水増しなし

Case2 は, Case1 でブローホールまたはピンホールと誤認識されやすかった機械加工穴をアノテーションし, 学習させた場合である。

i) 学習に使用したデータを用いた欠陥検出

学習データに使用した画像をテスト画像にした。Thresh 値を 0.8 にして検出を行ったところ表 3.4-6 のような結果となった。検出されたものに関しては概ね 0.9 以上の確率で検出されたが、データの少ないサビ、型崩れ、肌荒れの非検出が目立った。ただし、検出された場合においても、誤認識されたケースがあった。機械加工穴をアノテーションに組み入れた結果、機械加工穴を認識できるようになり、誤認識が減った。しかし、一部ブローホールと誤認識することもあった。

表 3.4-6 学習に用いた画像をテスト画像にして検出した結果 (Case2)

	総数	検出	非検出
ノロカミ	12	10	2
バリ	8	8	0
ヒケ巣	19	18	1
ピンホール	6	6	0
ブローホール	16	16	0
外ヒケ	4	4	0
割れ	21	21	0
型ズレ	2	2	0
型崩れ	7	3	4
砂カミ	21	20	1
砂焼き付き	15	15	0
打痕	5	5	0
湯じわ	4	4	0
湯境	21	20	1
肌荒れ	6	3	3
サビ	6	2	4
機械加工穴	56	56	0
合計	229	213	16

ii) テストデータを使用した欠陥検出

一方、テスト用に用意した画像に関しては、Case1 同様 Thresh 値が高いと検出率が悪かったため、Thresh 値を 0.01 および 0.1 にして欠陥検出を行った。結果を図 3.4-23 と図 3.4-24 にそれぞれ示す。

各テストデータについてどのような欠陥が検出されたかを表 3.4-7 に示す。表では、正解の欠陥のセルに色をつけ、正解の欠陥の確率が誤認識の欠陥よりも高い場合は赤字で記した。それ以外の場合は誤認識で一番高い確率の欠陥の数値に水色字を記した。なお同じ欠陥が複数回検出された場合は一番高い確率を記述した。表 3.4-7 のテスト画像名を赤字で記したように、欠陥が検出されない画像が 5 枚あった。

機械加工穴をアノテーションに追加した結果、ブローホールと判定された穴を機械加工穴として認識できるようになった。表 3.4-7 の test02 (バリ) の結果では、機械加工穴が最も高い確率となったものの、図 3.4-26 の test02 の認識結果を見てわかるように、機械加工穴を高い確率で認識した結果である。表 3.4-7 の test02 (バリ) でバ리를 0.79 の確率で検出できていた。また、Case1 と同様にピンホール、ブローホール、機械加工穴は混同しやすい傾向が見られた。

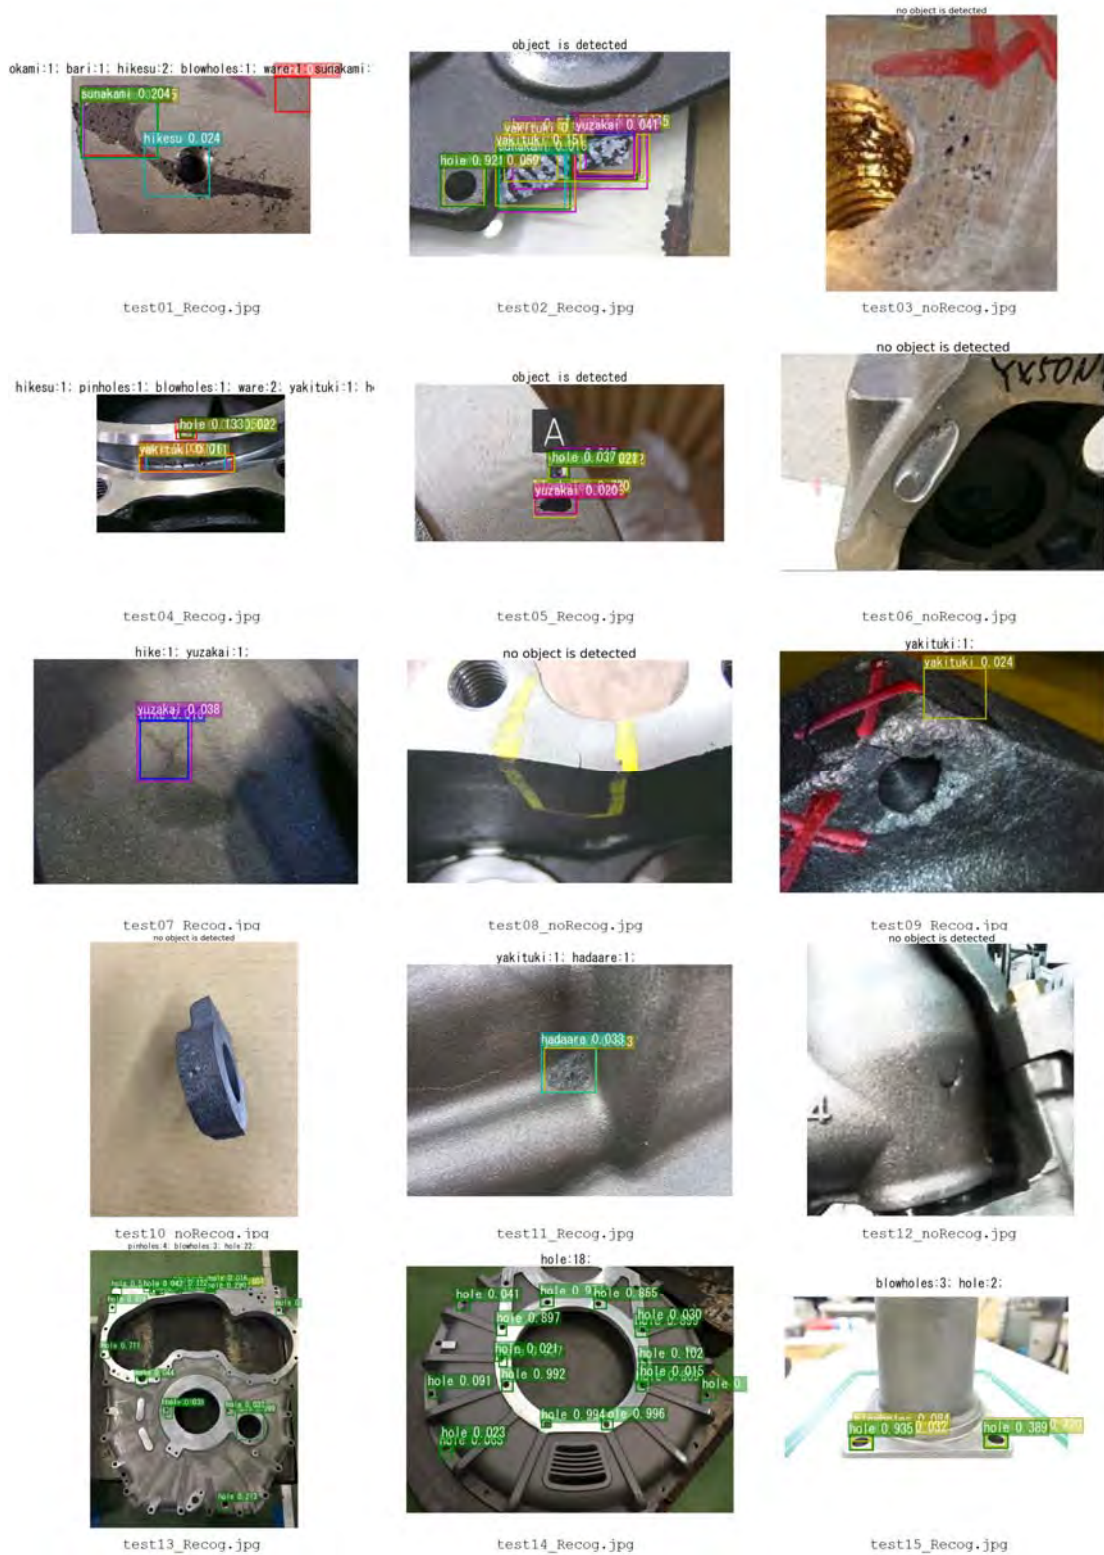


図 3.4-23 Case 2: テストデータの欠陥検出 (Thresh  $\geq$  0.01)

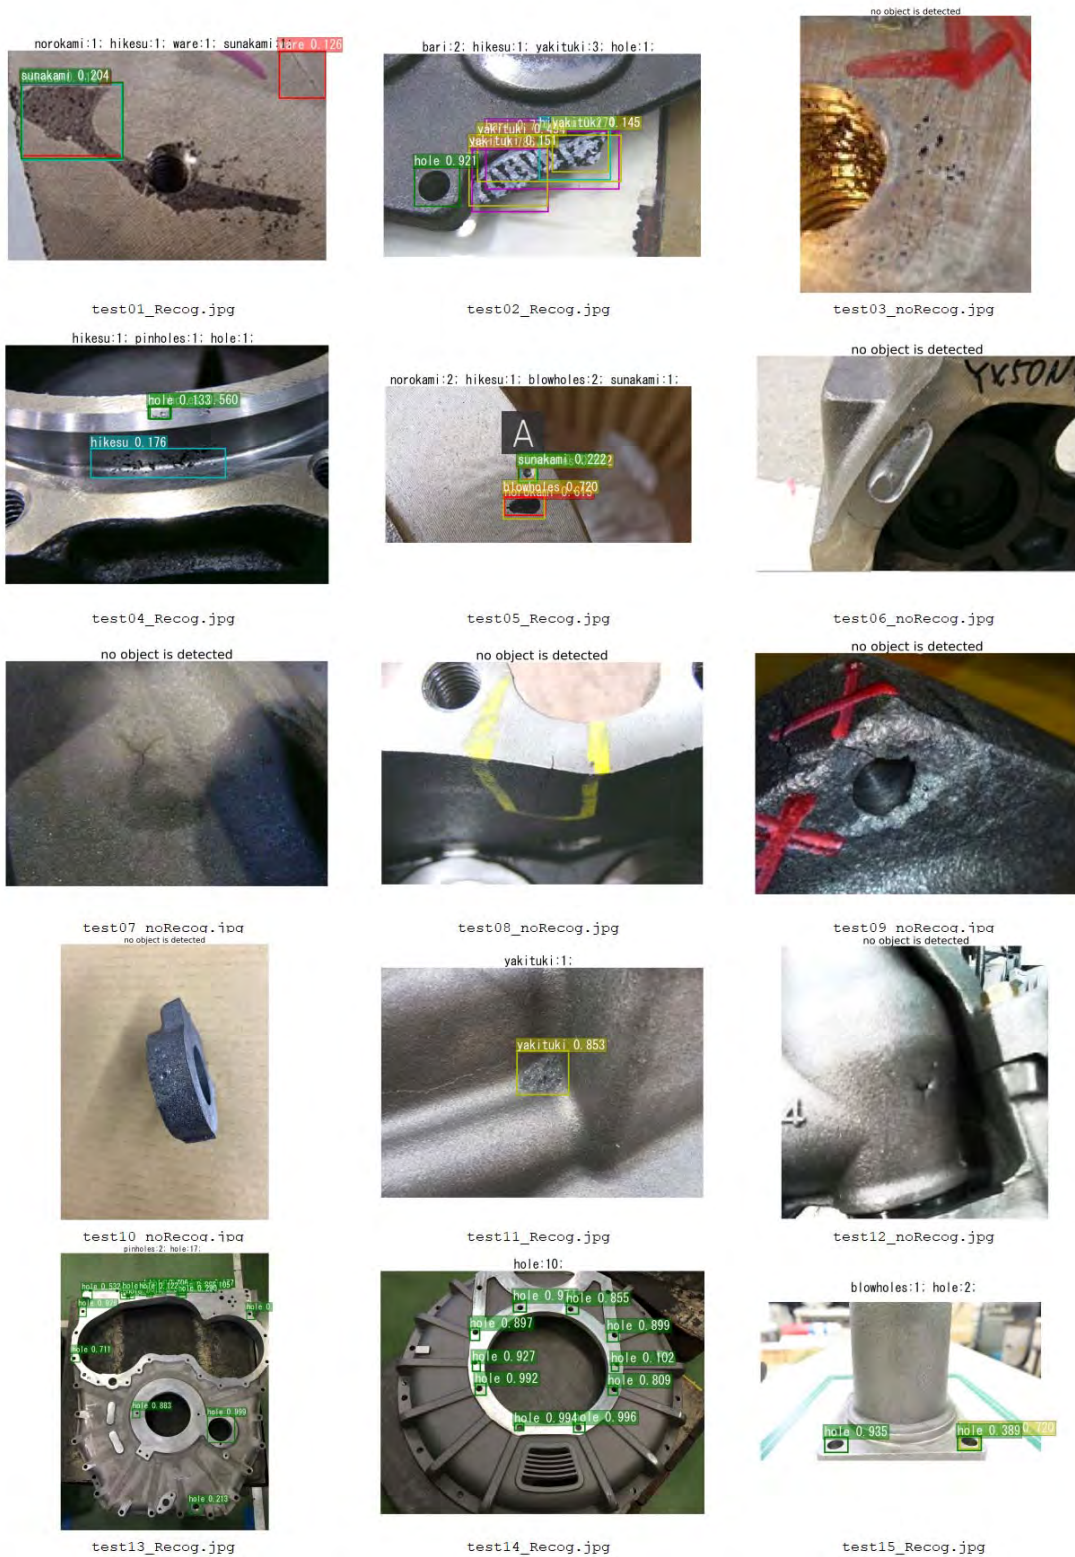


図 3.4-24 Case 2: テストデータの欠陥検出 (Thresh  $\geq$  0.1)

表 3.4-7 Case2 の検出結果 (Thresh  $\geq$  0.01)

テスト画像	欠陥の正解	検出された欠陥																
		ノロカミ	バリ	ヒケ巣	ピンホール	ブローホール	外ヒケ	割れ	型ズレ	型崩れ	砂カミ	砂焼き付き	湯じわ	湯境	肌荒れ	打痕	サビ	機械加工穴
test01	ノロカミ	0.17	0.01	0.12		0.05		0.13			0.20							
test02	バリ	0.04	0.79	0.27		0.06	0.01	0.02	0.01		0.07	0.49		0.04				0.92
test03	ヒケ巣																	
test04	ヒケ巣		0.05	0.18	0.56	0.02		0.07				0.01						0.13
test05	ピンホール	0.61	0.02	0.23	0.09	0.72	0.02		0.01		0.22	0.02		0.02				0.04
test06	ブローホール																	
test07	割れ						0.02							0.04				
test08	割れ																	
test09	型崩れ											0.09						
test10	砂カミ																	
test11	砂焼き付き											0.85					0.03	
test12	湯境																	
test13	機械加工穴				0.18	0.03												1.00
test14	機械加工穴																	1.00
test15	機械加工穴他					0.72												0.94

3) Case3 : 欠陥オリジナル 16 種, 機械加工穴あり (学習), 水増しあり

Case3 は Case2 に水増し学習を行った場合である。機械加工穴を学習させ、かつ、学習させる画像を水増しで増やしているため、Case1 や Case2 よりも認識率が上がることが期待されるケースである。

i) 学習に使用したデータを用いた欠陥検出

学習データに使用した画像で水増し前の画像をテスト画像にした。Thresh 値を 0.8 にして検出を行ったところ表 3.4-8 のような結果となった。検出されたものに関しては概ね 0.9 以上の確率で検出された。表 3.4-6 と表 3.4-8 を比較すると、ノロカミでは非検出の数が減ったものの、データの少ないサビ、型崩れ、肌荒れでは、依然として非検出であった。

表 3. 4-8 学習に用いた画像をテスト画像にして検出した結果 (Case3)

	総数	検出	非検出
ノロカミ	12	12	0
バリ	8	8	0
ヒケ巣	19	18	1
ピンホール	6	6	0
ブローホール	16	16	0
外ヒケ	4	4	0
割れ	21	20	1
型ズレ	2	2	0
型崩れ	7	3	4
砂カミ	21	20	1
砂焼き付き	15	15	0
打痕	5	5	0
湯じわ	4	4	0
湯境	21	21	0
肌荒れ	6	3	3
サビ	6	0	6
機械加工穴	56	56	0
合計	229	213	16

ii) テストデータを使用した欠陥検出

Thresh 値を 0.01 および 0.1 にした場合のテスト画像の欠陥検出結果を図 3.4-25, 図 3.4-26 と表 3.4-9 にそれぞれ示す。全テストデータで欠陥または機械加工穴が検出された。表 3.4-9 より、正解の確率が最も高かったテストデータは 4 つ、確率が低くても正解が検出されたテストデータは 3 つであった。表 3.4-5, 表 3.4-7 と比較すると、学習画像の水増し効果が表れて、欠陥の位置の検出率および欠陥の種類に改善がみられた。しかし、欠陥位置は誤認識している場合もあった。

次節以降の Case4 から Case6 では、欠陥の種類は度外視して、一律「欠陥」と学習させて、欠陥の位置の検出に重点を置いた学習モデルを作成した。

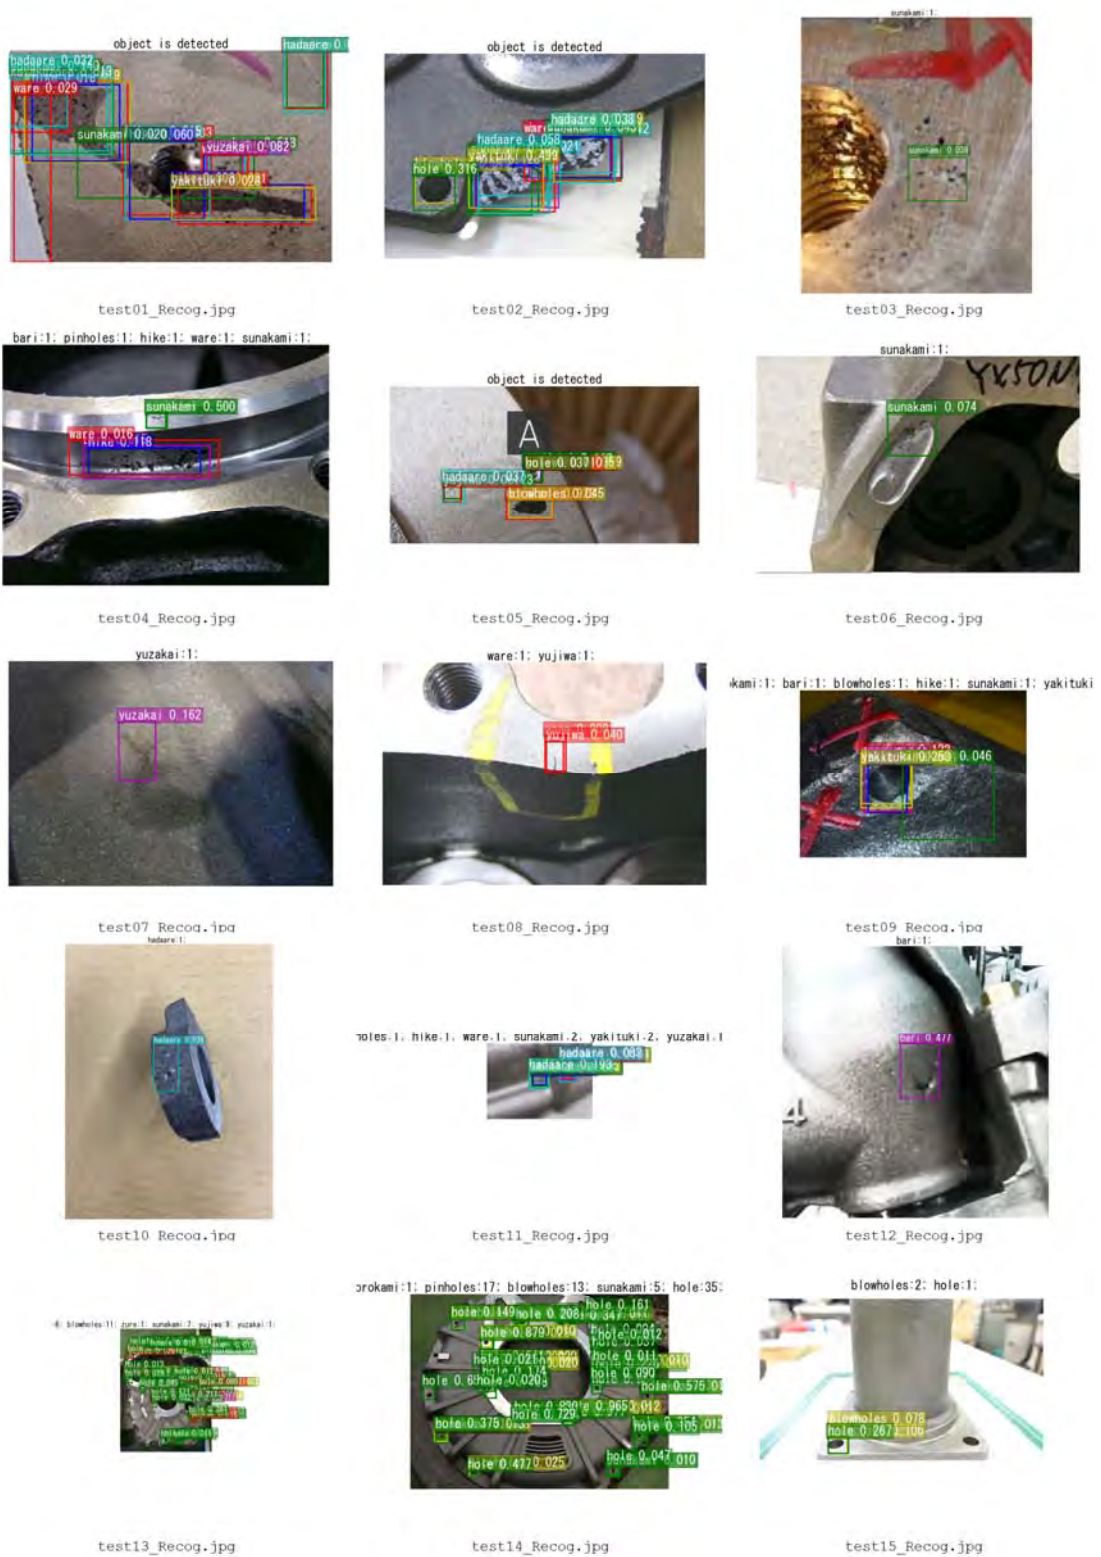


図 3.4-25 Case 3: テストデータの欠陥検出 (Thresh  $\geq$  0.01)

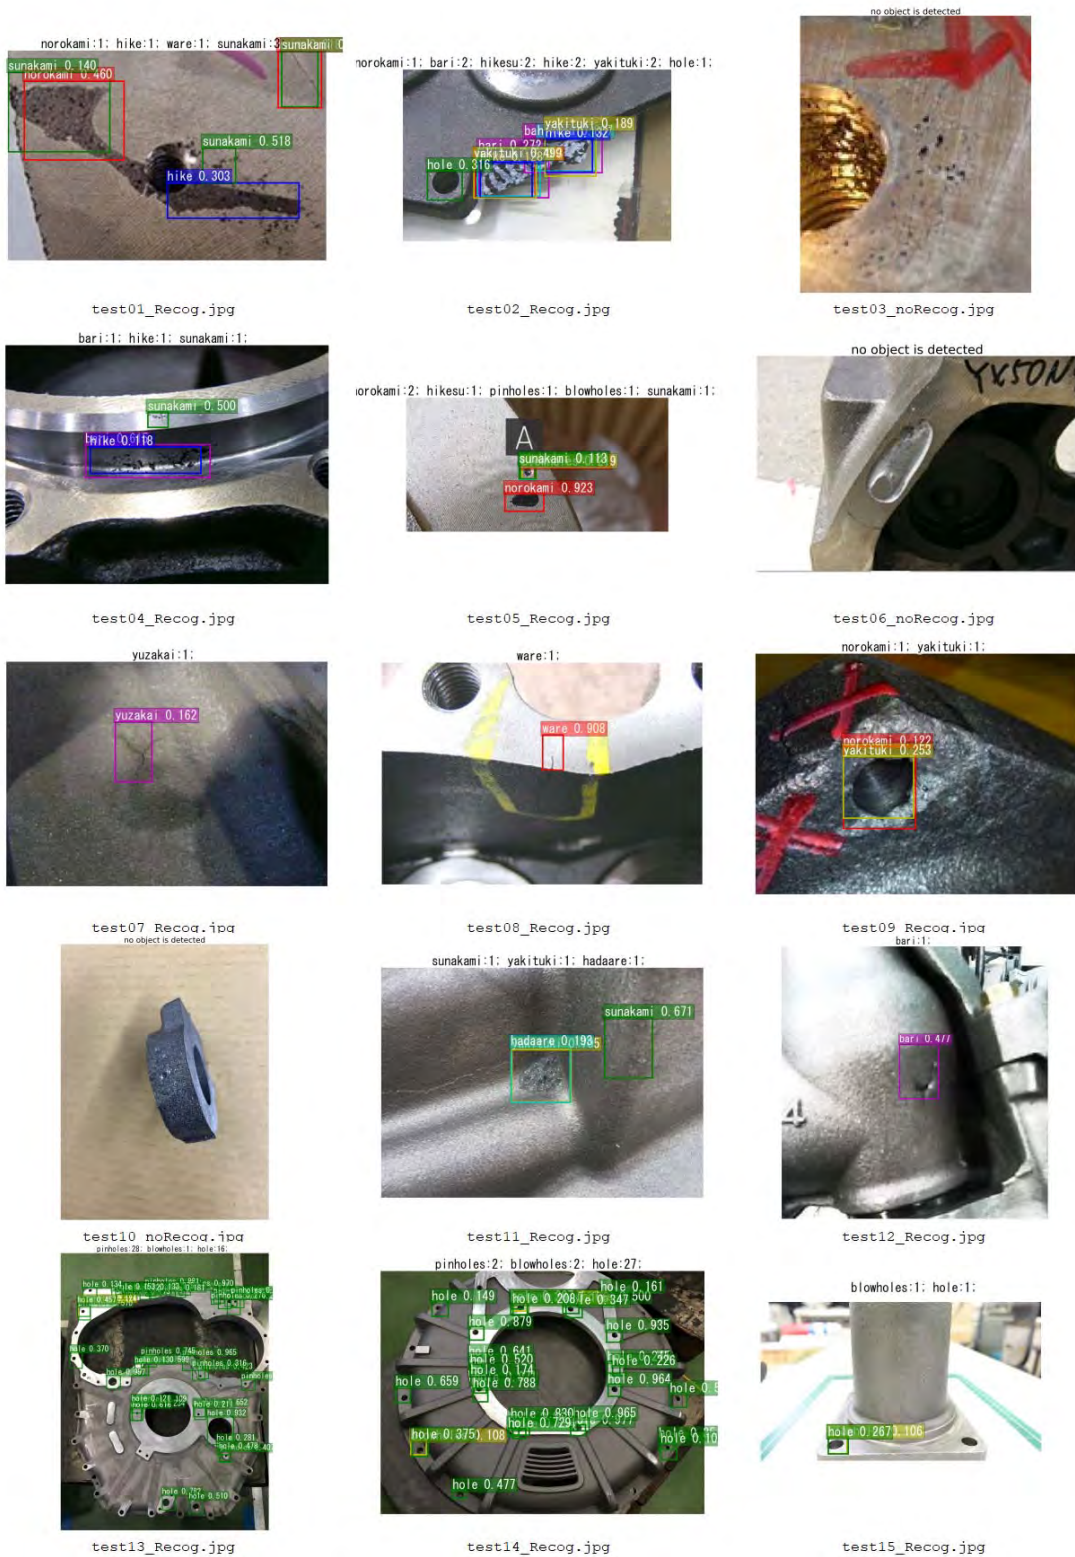


図 3.4-26 Case 3: テストデータの欠陥検出 (Thresh  $\geq$  0.1)



表 3.4-9 Case3 の検出結果 (Thresh  $\geq$  0.01)

テスト画像	欠陥の正解	検出された欠陥																
		ノロカミ	バリ	ヒケ巣	ピンホール	ブローホール	外ヒケ	割れ	型ズレ	型崩れ	砂カミ	砂焼き付き	湯じわ	湯境	肌荒れ	打痕	サビ	機械加工穴
test01	ノロカミ	0.46		0.02		0.02	0.30	0.32		0.01	0.52	0.03		0.08	0.03			
test02	バリ	0.11	0.41	0.81	0.01	0.04	0.13	0.01		0.02	0.04	0.50			0.06			0.32
test03	ヒケ巣										0.04							
test04	ヒケ巣		0.62		0.07		0.12	0.02			0.50							
test05	ピンホール	0.92	0.03	0.17	0.18	0.22	0.02				0.11	0.03	0.06		0.04			0.04
test06	ブローホール										0.07							
test07	割れ													0.16				
test08	割れ							0.91					0.04					
test09	型崩れ	0.12	0.07			0.10	0.09				0.05	0.25						
test10	砂カミ														0.04			
test11	砂焼き付き			0.03	0.03		0.04	0.01			0.67	0.70		0.01	0.19			
test12	湯境		0.48															
test13	機械加工穴				0.97	0.12			0.01		0.03		0.03	0.02				0.96
test14	機械加工穴	0.01			0.61	0.11					0.02							0.98
test15	機械加工穴他					0.11												0.27

4) Case4 : 欠陥は defect に統一, 機械加工穴なし (未学習), 水増しなし

Case4 は, Case1~3 と異なり 16 種類の欠陥はすべて defect でアノテーションした. ただし, 機械加工穴はアノテーションをしていない. Case1~3 の結果からわかるように正解と同じ位置に欠陥は検出されても欠陥の種類は必ずしも正解と一致しない. そこで Case4~6 は, Case1~3 のオリジナルの欠陥 16 種をすべて単一の defect に置き換えて学習を行った. なお, 機械加工穴で検出となっている場合は, 機械加工穴は学習に含まれていないため, defect として検出 (すなわち誤検出) されたことを意味している.

i) 学習に使用したデータを用いた欠陥検出

学習データに使用した画像をテスト画像にした場合は, Thresh 値を 0.8 にして検出を行ったところ表 3.4-10 のような結果となった. 検出されたものに関しては概ね 0.9 以上の確率で検出された. ただし, 機械加工穴をアノテーションして学習していない. 機械加工穴はすべて defect と判定された. データの少ないサビ, 型崩れ, 肌荒れは予想通り検出精度は低かった.

ii) テストデータを使用した欠陥検出

テスト用に用意した画像については, Case1~3 と比較するために Thresh 値を 0.01 および 0.1 にして検出を行った. テスト画像の欠陥検出結果を図 3.4-27, 図 3.4-28 と表 3.4-11 にそれぞれ示す. 欠陥の種類についてはわからないものの, Case1~3 より高い確率で欠陥を検出できた. しかし, Thresh を最低値の 0.01 にしても全く欠陥が検出されない画像が 1 枚 (test03) あった. また, 間違った場所を欠陥として検出した test10~test12 のような画像もあった. test12 は数字の 4 を欠陥と誤認識していた.

概ね欠陥位置を検出しているが, 図 3.4-20 と比較すればわかるように, test10~test12 は欠陥位置とは全く違う場所を欠陥と認識していた.

表 3. 4-10 学習に用いた画像をテスト画像にして検出した結果 (Case4)

	総数	検出	非検出
ノロカミ	12	12	0
バリ	8	8	0
ヒケ巣	19	18	1
ピンホール	6	6	0
ブローホール	16	16	0
外ヒケ	4	4	0
割れ	21	21	0
型ズレ	2	2	0
型崩れ	7	3	4
砂カミ	21	21	0
砂焼き付き	15	15	0
打痕	5	5	0
湯じわ	4	4	0
湯境	21	19	2
肌荒れ	6	4	2
サビ	6	1	5
機械加工穴	56	45	11
合計	229	204	25

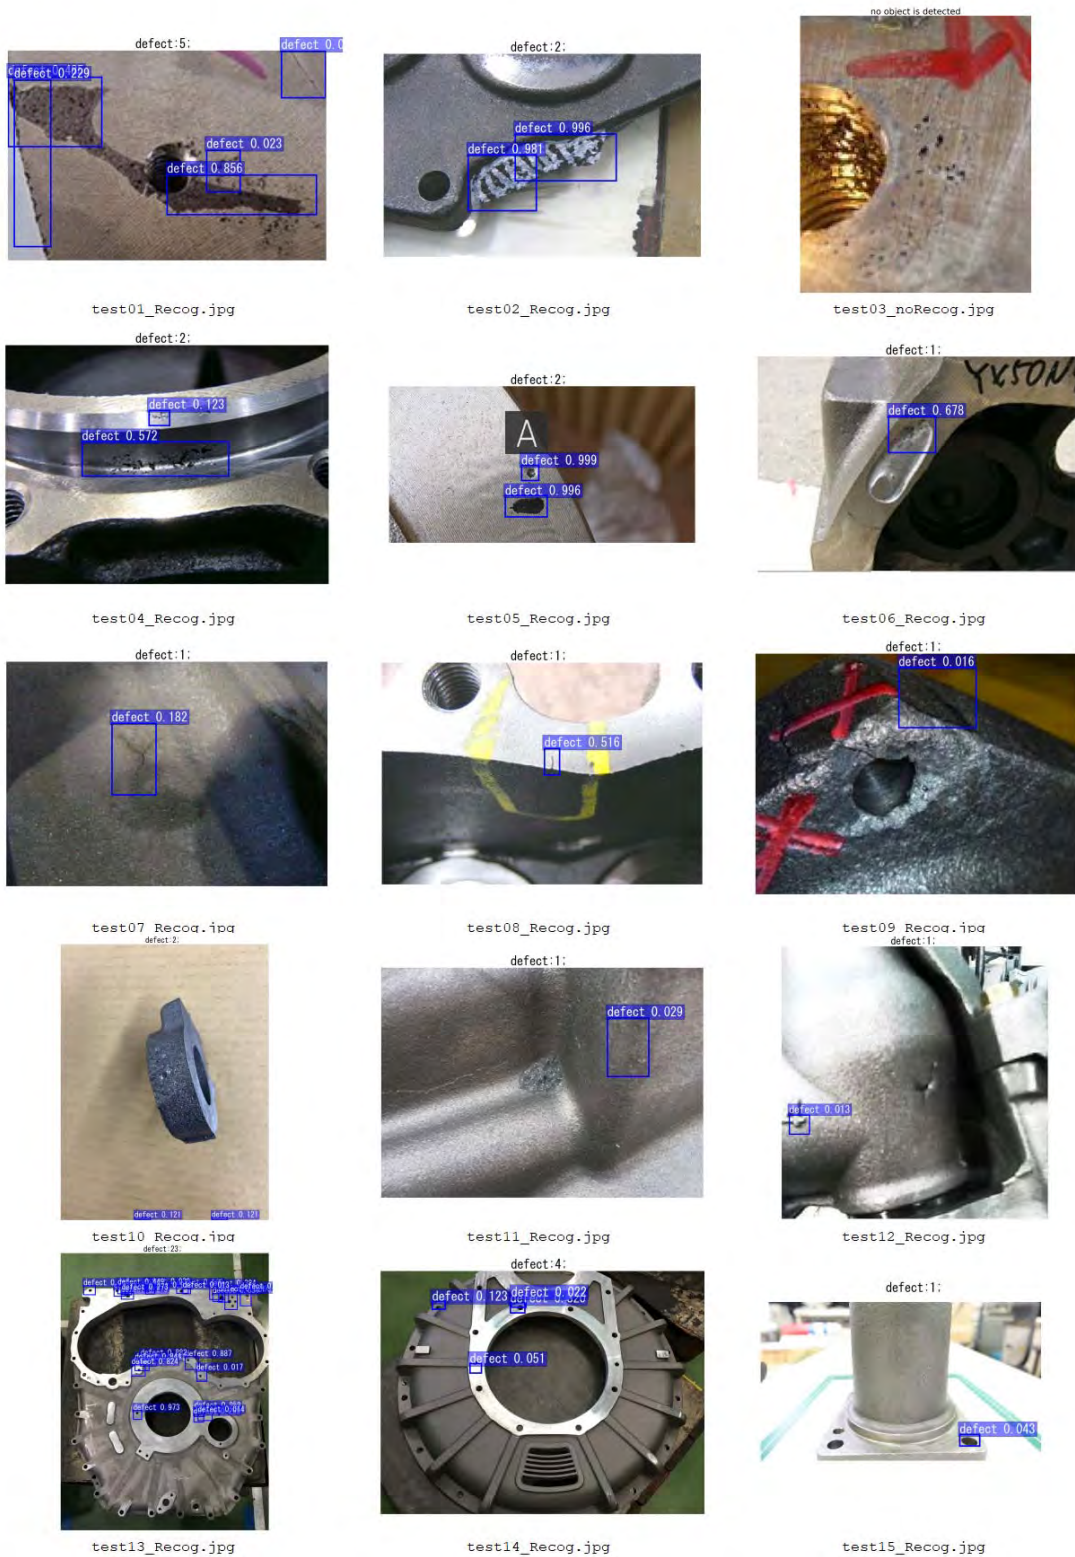


図 3.4-27 Case 4: テストデータの欠陥検出 (Thresh  $\geq$  0.01)

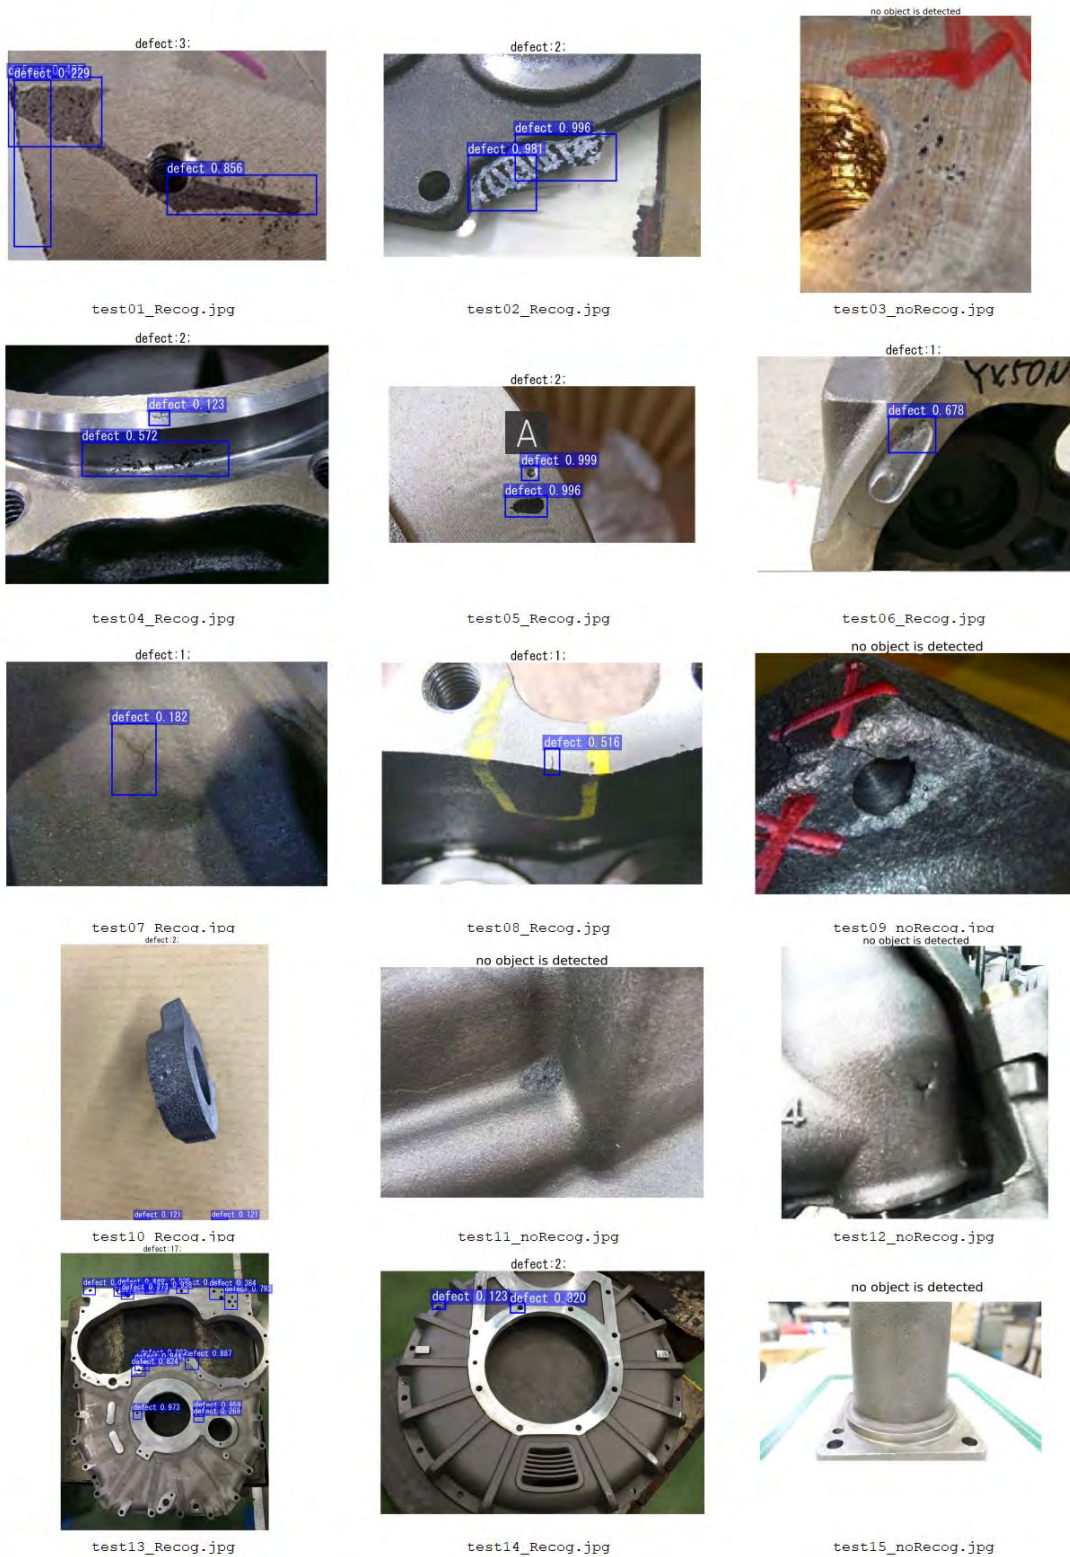


図 3.4-28 Case 4: テストデータの欠陥検出 (Thresh  $\geq$  0.1)

表 3.4-11 Case4 の検出結果 (Thresh  $\geq$  0.01)

テスト画像	欠陥の正解	defect		
		検出個数	max	min
test01	ノロカミ	5	0.86	0.02
test02	バリ	2	1.00	0.98
test03	ヒケ巣		N.D.	
test04	ヒケ巣	2	0.57	0.12
test05	ピンホール	2	1.00	1.00
test06	ブローホール	1	0.68	
test07	割れ	1	0.18	
test08	割れ	1	0.52	
test09	型崩れ	1	0.02	
test10	砂カミ	2	0.12	0.12
test11	砂焼付き	1	0.03	
test12	湯境	1	0.01	
test13	機械加工穴	23	0.97	0.01
test14	機械加工穴	4	0.32	0.02
test15	機械加工穴他	1	0.04	

5) Case5 : 欠陥は defect に統一，機械加工穴あり（学習），水増しなし

Case5 は，Case4 で機械加工穴を hole とアノテーションして学習させたケースである。

i) 学習に使用したデータを用いた欠陥検出

学習モデルに使用した画像を用いて検出を行った。検出されたものに関しては概ね 0.9 以上の確率で検出された。Case4 の結果 (表 3.4-10) と Case5 の結果 (表 3.4-12) を比較すると，機械加工穴の非検出数がゼロになった。

図 3.4-29，図 3.4-30 より，機械加工穴が正しく判定されたことがわかる。またデータの少ないサビ，型崩れ，肌荒れは，予想どおり精度は低かった。

表 3.4-12 学習に用いた画像をテスト画像にして検出した結果 (Case5)

	総数	検出	非検出
ノロカミ	12	12	0
バリ	8	8	0
ヒケ巣	19	19	0
ピンホール	6	6	0
ブローホール	16	16	0
外ヒケ	4	4	0
割れ	21	21	0
型ズレ	2	2	0
型崩れ	7	3	4
砂カミ	21	20	1
砂焼き付き	15	15	0
打痕	5	5	0
湯じわ	4	4	0
湯境	21	19	2
肌荒れ	6	4	2
サビ	6	2	4
機械加工穴	56	56	0
合計	229	216	13

ii) テストデータを使用した欠陥検出

Thresh 値を 0.01 および 0.1 にした場合のテスト画像の欠陥検出結果を図 3.4-29, 図 3.4-30 及び表 3.4-13 にそれぞれ示す. 欠陥の種類についてはわからないものの個別の欠陥についてアノテーションしていた Case1 および Case2 より概ね高い確率で欠陥を検出できた. それでも全く欠陥が検出されない画像が 1 枚あった (test12). 欠陥位置に関しては概ね正しく検出できているが, 図 3.4-20 と比較すればわかるように, test10 は 10 箇所場所で欠陥が検出されたが, 欠陥位置とは全く違う場所を誤認識していた.

一方, Case4 と比較すると test02 (バリ) の機械加工穴を正しく hole と認識できるようになった. test05 (ピンホール) では, defect と同時に hole も検出しているが, 確率は defect が 1.0, hole が 0.02 なので正しく認識できているといえる. しかし, ピンホールが存在しない test15 では, defect と hole の確率は, 0.35~0.58 の範囲にありお互いに拮抗していた. 原因としては, 機械加工穴は写真上では円形ではなく歪んだ形をしているため, このことが hole と認識する確率を下げているからと考える.



図 3.4-29 Case 5: テストデータの欠陥検出 (Thresh  $\geq$  0.01)

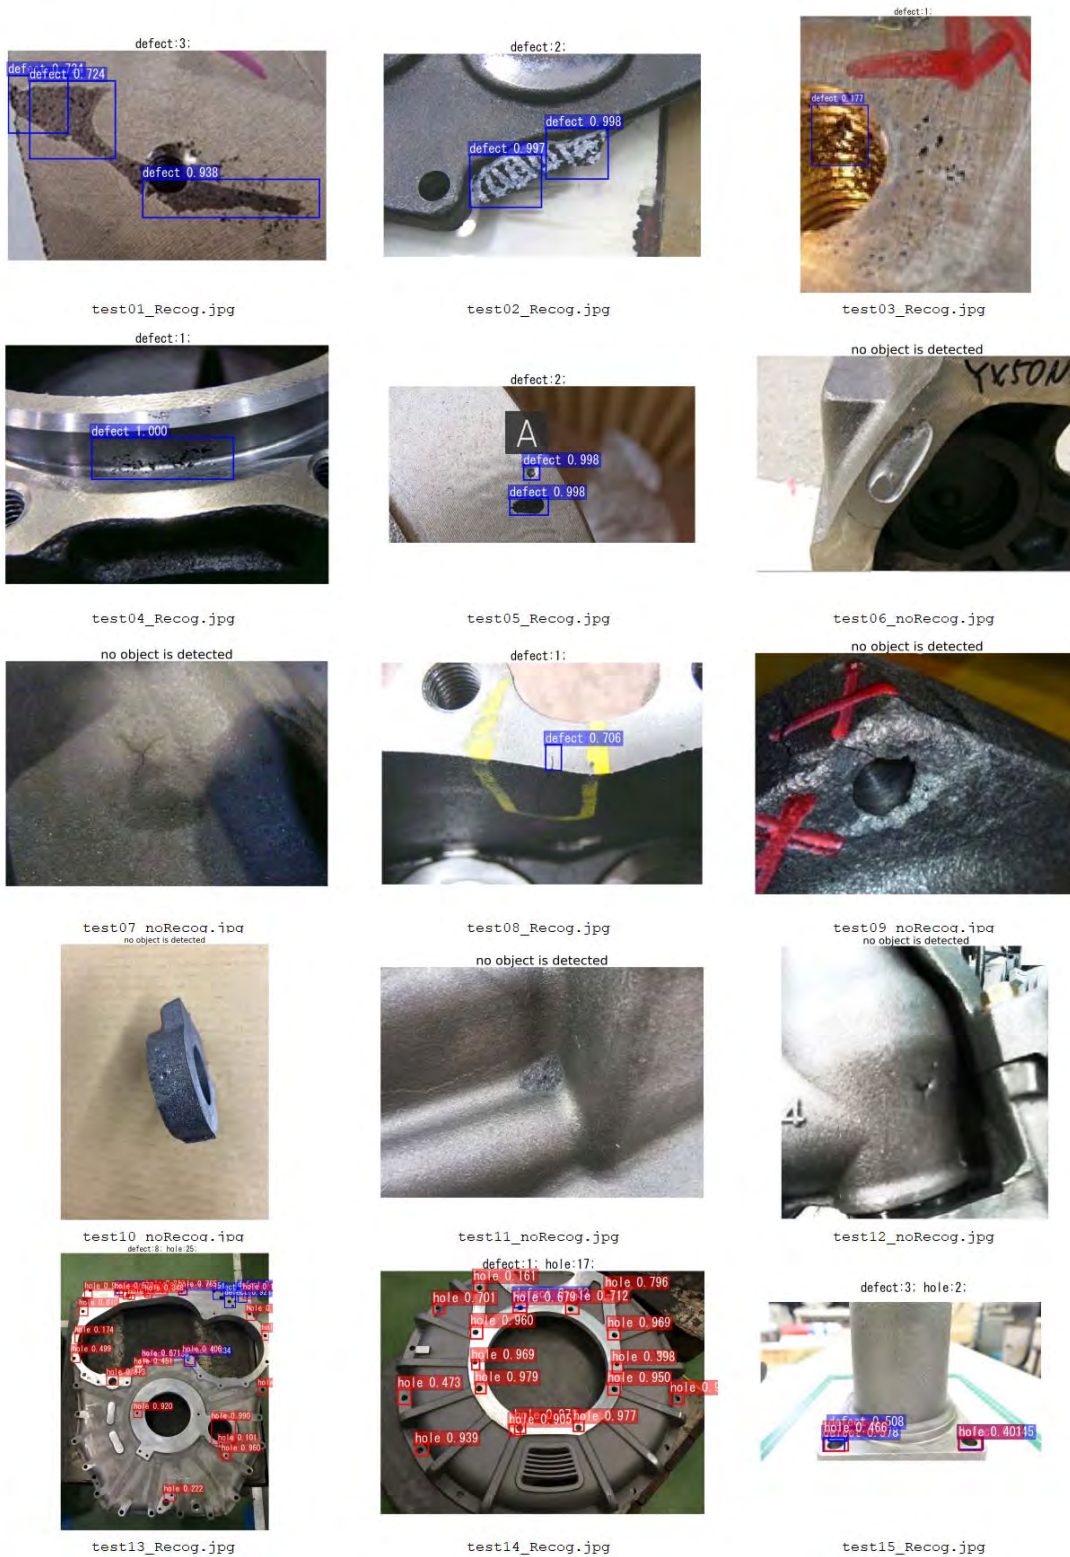


図 3.4-30 Case 5: テストデータの欠陥検出 (Thresh  $\geq$  0.1)



表 3.4-13 Case5 の検出結果 (Thresh  $\geq$  0.01)

テスト画像	欠陥の正解	defect			加工穴		
		検出個数	max	min	検出個数	max	min
test01	ノロカミ	4	0.94	0.07		N.D.	
test02	バリ	2	1.00	1.00	1	0.05	
test03	ヒケ巣	2	0.18	0.03		N.D.	
test04	ヒケ巣	2	1.00	1.00		N.D.	
test05	ピンホール	2	1.00	1.00	1	0.02	
test06	ブローホール	1	0.04			N.D.	
test07	割れ	1	0.09			N.D.	
test08	割れ	1	0.71			N.D.	
test09	型崩れ	2	0.03	0.01		N.D.	
test10	砂カミ	11	0.10	0.10		N.D.	
test11	砂焼付き	2	0.09	0.04		N.D.	
test12	湯境		N.D.			N.D.	
test13	機械加工穴	22	0.92	0.01	35	0.99	0.01
test14	機械加工穴	5	0.13	0.01	22	0.98	0.01
test15	機械加工穴他	3	0.58	0.35	2	0.47	0.40

6) Case6 : 欠陥は defect に統一, 機械加工穴あり (学習), 水増しあり

Case6 は, Case5 に水増し学習を行った場合である. 機械加工穴を学習させ, かつ, 学習させる画像を水増しし, 欠陥を一律「defect」と学習させているため, 認識率が全ケースのなかで最も期待されるケースである.

i) 学習に使用したデータを用いた欠陥検出

学習データに使用した画像をテスト画像にした場合は, Thresh 値を 0.8 にして検出を行ったところ表 3.4-14 のような結果となった. 検出されたものに関しては概ね 0.9 以上の確率で検出された. しかしデータの少ないサビ, 型崩れ, 肌荒れは, 検出精度は低かった.

表 3.4-14 学習に用いた画像をテスト画像にして検出した結果 (Case6)

	総数	検出	非検出
ノロカミ	12	12	0
バリ	8	8	0
ヒケ巣	19	18	1
ピンホール	6	6	0
ブローホール	16	16	0
外ヒケ	4	4	0
割れ	21	20	1
型ズレ	2	2	0
型崩れ	7	3	4
砂カミ	21	20	1
砂焼き付き	15	15	0
打痕	5	5	0
湯じわ	4	4	0
湯境	21	21	0
肌荒れ	6	3	3
サビ	6	0	6
機械加工穴	56	56	0
合計	229	213	16

ii) テストデータを使用した欠陥検出

テスト用に用意した画像については, Case1~3 と比較するために Thresh 値を 0.01 および 0.1 にして検出を行った. テスト画像の欠陥検出結果を図 3.4-31, 図 3.4-32 と表 3.4-15 にそれぞれ示す. 欠陥の種類についてはわからないものの個々の欠陥についてアノテーションしていた Case1~3 より高い確率で欠陥を検出できた. しかし, Thresh を最低値の 0.01 にしても全く欠陥が検出されない画像が 1 枚 (test06) あった. 間違った場所を欠陥として検出したケース (test07, test09, test10) も見られた. また, test02 では機械加工穴を正しく認識できた一方, 低い確率ながら test05 ではピンホールを機械加工穴と誤認識していた. Case4 と Case5 と比べると test13 と test14 で機械加工穴を正しく検出できた個数も増えたが, 欠陥と誤認識する個数も増えた.

Case6 に限らずテスト用鑄造品の欠陥はすべてのケースで検出されなかったため, 次節で検討する.

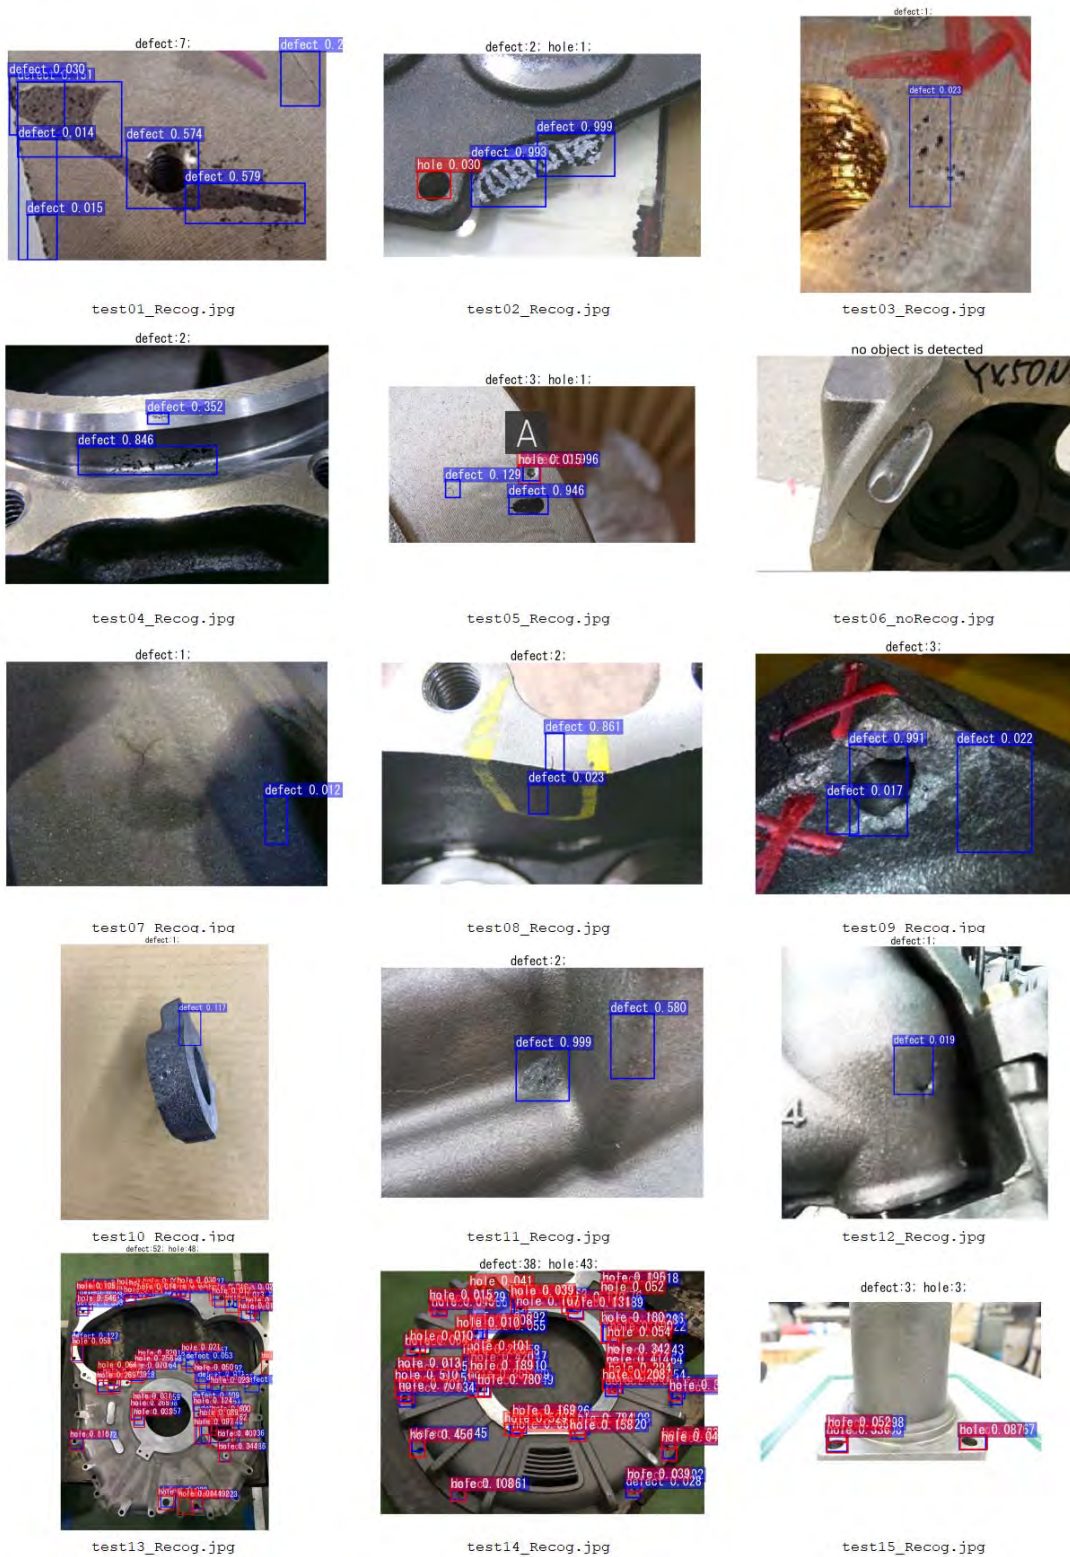


図 3.4-31 Case 6: テストデータの欠陥検出 (Thresh  $\geq$  0.01)

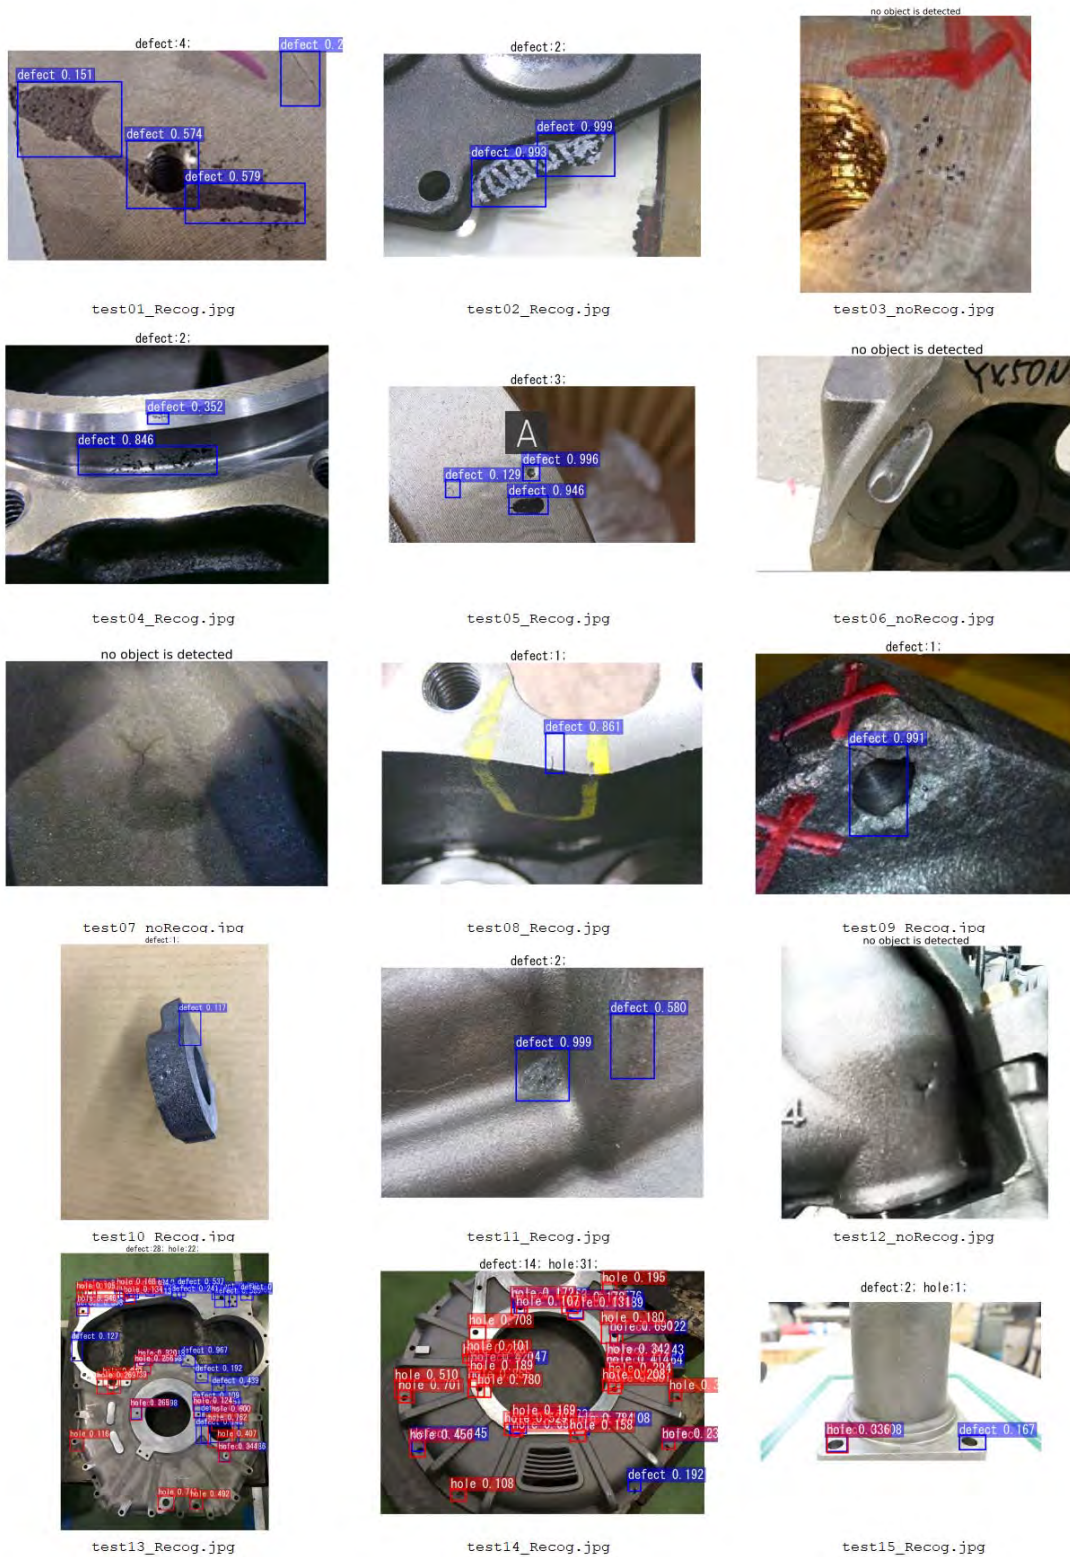


図 3.4-32 Case 6: テストデータの欠陥検出 (Thresh  $\geq$  0.1)

表 3.4-15 Case6 の検出結果 (Thresh  $\geq$  0.01)

テスト画像	欠陥の正解	defect			加工穴		
		検出個数	max	min	検出個数	max	min
test01	ノロカミ	7	0.58	0.01		N.D.	
test02	バリ	2	1.00	0.99	1	0.03	
test03	ヒケ巣	1	0.02			N.D.	
test04	ヒケ巣	2	0.85	0.35		N.D.	
test05	ピンホール	3	1.00	0.13	1	0.01	
test06	ブローホール		N.D.			N.D.	
test07	割れ	1	0.01			N.D.	
test08	割れ	2	0.86	0.02		N.D.	
test09	型崩れ	3	0.99	0.02		N.D.	
test10	砂カミ	1	0.12			N.D.	
test11	砂焼付き	2	1.00	0.58		N.D.	
test12	湯境	1	0.02			N.D.	
test13	機械加工穴	52	0.97	0.01	48	0.84	0.01
test14	機械加工穴	38	0.74	0.01	43	0.86	0.01
test15	機械加工穴他	3	0.17	0.10	3	0.34	0.05

### 3.4.4 テスト用鋳造品の再検出

テスト用鋳造品では、Case1～6 で機械加工穴は検出されたが欠陥は検出されなかった。この原因として画像中の欠陥部位が不鮮明であった可能性がある。そこで欠陥部位が明瞭になるよう再度写真を取り直し最も多くの画像で学習した Case3 (個々の欠陥名でアノテーション) と Case6 (欠陥名はすべて defectde でアノテーション) で検出をやり直した。結果を図 3.4-33 に示す。

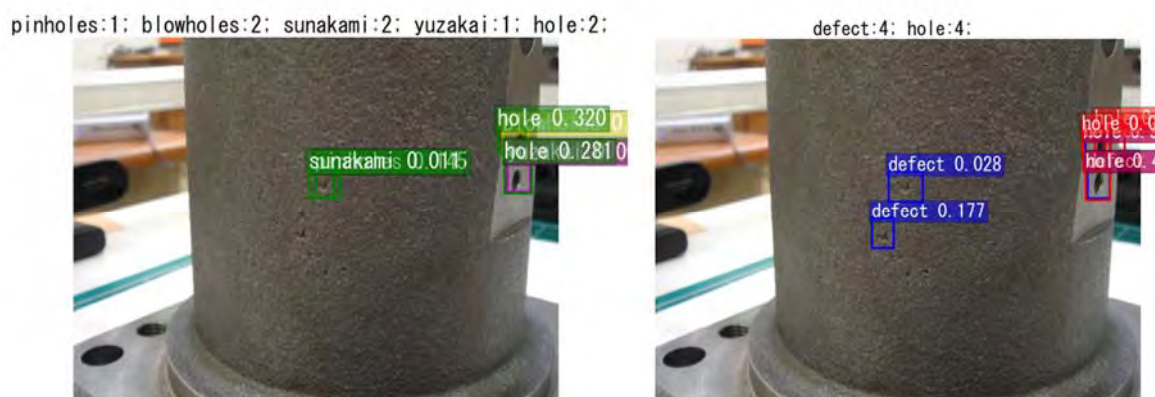


図 3.4-33 テスト用鋳造品の Thresh0.01 で再検出 (左図 : Case3 使用, 右図 : Case6 使用)

Case3 を使用した場合は、欠陥の 1 箇所がピンホール 0.145, 砂カミ 0.011 と検出された。一方、Case6 を使った場合は、2 箇所が defect として、それぞれ 0.028, 0.177 と検出することができた。また、両ケースとも右側の機械加工穴は、一部ブローホールと誤認識するものもあったが、概ね機械加工穴と検出できた。より鮮明な画像を用いれば検出の精度が向上することが確認できた。

### 3.5 表面欠陥検査技術まとめ

機械学習により鑄造欠陥の種類と場所を検出することを試みた。サンプルデータの少ない型崩れとサビは、検出が難しかった。図 3.4-11 に示すように、型崩れの学習に使用した画像データでは、AI の画像認識上の特徴を、アノテーションで抽出しきれなかった可能性がある。その結果、検出が難しかったことが予想される。また、図 3.4-18 に示すように、サビの学習に使用した画像データは、画面全体にサビが確認され、サビの特徴を学習させることが困難であったためと考える。サビの学習で有効だった画像は、サビ⑤のみであったと考える。実際の検査においては、サビの場合、色や手触りで判断は可能である。型崩れの場合は、2 章で述べた形状検査で不適合品か否かの判断は可能である。今後のサンプルデータ増加で、検出精度の向上が期待できる。

欠陥の種類に関して誤認識があっても欠陥の位置に関しては概ね正しい範囲を示していた。

欠陥種類ごとの欠陥写真の数が十分でない現状の AI では、3.4.3 で述べたように、同一の名前「defect」と学習させ、検査し、これに引っ掛かった場合に種類別に調べる手順が実用的である。すなわち、深層学習 AI で無人検査を行い、選別された対象品を欠陥使用判定ガイドと知識処理 AI を用いて有人で詳細検査を行うことにより、検査の効率化が図られ実用的な表面欠陥検査手法が得られたと考える。

## 4. 鑄造品等の内部欠陥検査技術に関する AI 活用等の研究

### 4.1 鑄造品等の内部欠陥検査技術

内部欠陥の非破壊検査においては、超音波を送受信して、受信波形の中にある欠陥エコーを信号波形で観察して検出するため、専門性が求められる課題があった。また、広範囲の検査に時間を要すること、さらにセンサー（超音波探触子）直下は不感帯となっており、表面近傍の欠陥が発見しにくい等の課題もあった。最近では、これらの課題を解決するために、内部欠陥を映像で検出できるつくばテクノロジー（株）製の非破壊検査装置が出てきた。昨年度に引き続き、当該社製のレーザー超音波可視化検査装置（Laser Ultrasonic Visualizing Inspector）を鑄造品検査に適用した。

本検査装置<sup>3)</sup>は、超音波の伝播をその場で動画映像として観察しながら傷を見つける検査手法であり、

- ① 分かりやすい
- ② 広い範囲を迅速に検査できる
- ③ 曲面部等の複雑形状部の検査が容易
- ④ 不感帯（表面直下の探傷不可領域）がない

といった特徴がある。

本レーザー超音波可視化システム（以下 LUVI と呼ぶ）は、図 4.1-1 に示すような構成をしている。本検査システムの外観を、図 4.1-2 に示す。パルスレーザーから周期的に発振されたレーザー光を検査体表面で高速走査させる。各走査点では急激な熱歪によって超音波が発生し、その伝搬波形を固定点に取り付けた超音波探触子で検出する。検出波形は、A/D 変換されてパソコンに収録される。収録された波形列をデータ処理して固定点の超音波探触子から発信された超音波の伝搬映像をパソコン画面上に動画表示する。

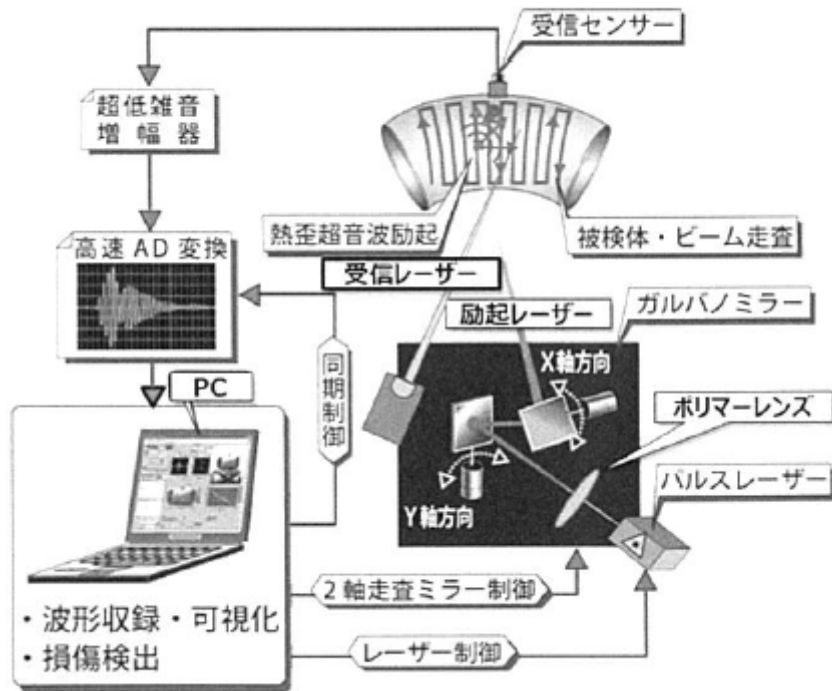


図 4. 1-1 レーザー超音波可視化システムの構成図<sup>3)</sup>



図 4. 1-2 レーザー超音波可視化システム外観<sup>3)</sup>

## 4.2 鋳造品等の内部欠陥検査への画像認識 AI の適用

### 4.2.1 AI 技術

AI 技術は、3.3 で説明した畳み込みニューラルネットワークを発展させた物体検出技術の一つである Faster Region Proposal Network (Faster R-CNN) とする。4.1 で述べたように、内部欠陥検査に LUVI を用いるため、図 4.2-1 に示したように、レーザーを照射した範囲の動画画面を見ながら、内部欠陥がある場合は、欠陥位置を波紋として確認することができる。




図 4.2-1 内部欠陥が発見された後の波紋画像

### 4.2.2 AI 学習のための画像変換と前処理

図 4.2-1 に写っている波紋の源に内部欠陥があることを人間は視覚で認識する。このような視覚認知機能を画像認識 AI で認識できるように、画像認識 AI の機械学習の方法を工夫する必要がある。

3.3 で述べた機械学習を行うには、認識させたい特徴を学習させる必要がある。そこで、一般的には静止画に対して、アノテーションと呼ばれる作業を行う。

本調査研究では、図 4.2-2 右図に示した変換後の画像に対して、欠陥位置のアノテーション（図 4.2-3 では黄色く枠を囲む）を行った。LUVI による内部欠陥検査動画で超音波センサー位置は、図 4.2-2 左図の場合、画面上端にあるが、検査状態に応じて、上下左右様々である。アノテーション用に変換する画像では、図 4.2-2 に示すように、画面上から下に向かって時間軸をとり、画面左（超音波センサー位置）から画面右に向かって超音波が進行するように統一する。

したがって、超音波の進行波はアノテーション用画像では、右肩下がりの線で表示される。逆に、右肩あがりの線は、進行波に対して逆方向の波となる。その結果、欠陥位置で画面上波紋が確認される位置では、図 4.2-2 右図ではギリシャ文字の  $\lambda$  に似たような特徴が確認できる。

図 4.2-2 左図のような LUVI による内部欠陥検査動画では、時間の経過とともに、進行波が試験体の壁面にあって反射してくる波も確認される。壁面にあって反射した波が、超音波の進行波と逆方向であれば、図 4.2-2 右図では、アルファベット文字の X に似たような特徴が確認できる。反射波が進行波と同一方向であれば、図 4.2-2 右図では、右肩下がりで傾きが異なる 2 本の線が確認できる。検査時間が十分長いと、様々な成分の波の線がアノテーション用画像に現れるため、アノテーションする人間が欠陥位置を判別するのに困難をきたす。また、動画での画質が悪い、あるいは反射波の区別が動画画面上で困難であるほど、アノテーション作業に困難が生じる。アノテーション作業は、AI による画像認識のための学習・予測精度に大きく影響するため、動画の画像品質を上げていく等配慮が必要である。






図 4.2-2 鋳造品内部欠陥検査動画からアノテーション画像への変換（左図：動画一部，右図：変換後画像）




図 4.2-3 欠陥位置学習のためのアノテーション

#### 4.3 模擬試験体による予備的検討

##### 4.3.1 試験体

模擬試験体を図 4.3-1 に示す。模擬試験体は、図 4.3-1 左写真のように、試験体裏側からキリで人工的な穴を、表 4.3-1 に示す寸法（穴径、深さ）であけた試験体である。試験では、穴をあけた側を裏側にして、反対側に超音波センサーを置いて測定することになる。

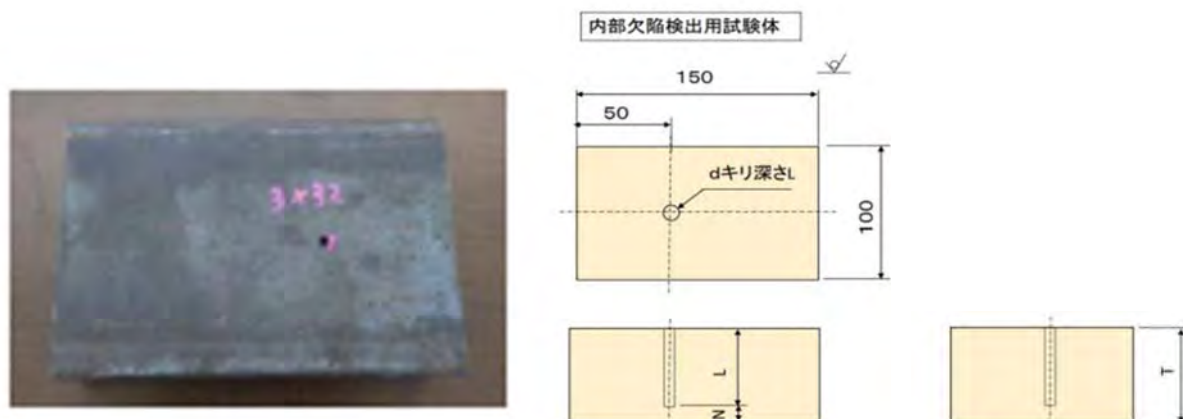


図 4.3-1 欠陥位置学習のためのアノテーション

#### 4.3.2 AI の適用

表 4.3-1 に示した試験体を、4.2.2 の方法に従って内部欠陥検査動画から、アノテーション用の画像変換を行った。アノテーションは、10 ケースの全ての試験体に対して行った。

表 4.3-1 予備的検討模擬試験体

試験体 No.	d	L	N	T
1	3	33.5	1.5±0.5	35
2	3	32	3±0.5	35
3	3	30	5±0.5	35
4	3	25	10±0.5	35
5	3	15	20±0.5	35
6	1.5	33.5	1.5±0.5	35
7	1.5	32	3±0.5	35
8	1.5	30	5±0.5	35
9	1.5	25	10±0.5	35
10	1.5	15	20±0.5	35

4.2.2 で述べたように、アノテーション作業の段階で、反射波によるノイズを除去するために、欠陥位置での反射（アノテーション画像における“λ”）の学習と、壁面からの反射（アノテーション画像における“X”）の学習を同時に行った。図 4.3-2 左図は、欠陥の学習を踏まえて、欠陥位置で緑色に正しくハイライトされていることを示している。図 4.3-2 右図は、壁面での反射と進行波が重なった位置で緑色に正しくハイライトされていることを示している。このように、壁面からの反射と進行波が重なった、いわゆる欠陥位置でないノイズを除去できることが確認できた。






図 4.3-2 欠陥からの反射を緑色にハイライト（左図），反対壁面からの反射を緑色にハイライト（右図）



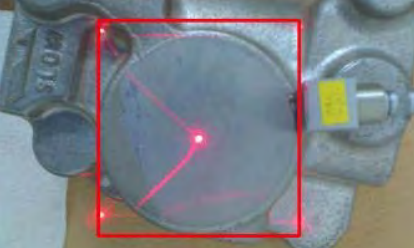
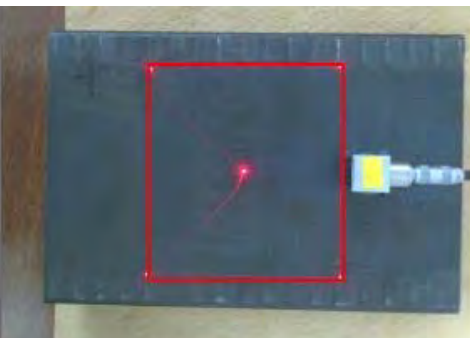

#### 4.4 追加試験体による検討




##### 4.4.1 試験体

表 4.4-1 に示す試験体を用いて追加検討した。表 4.4-1 に示す追加試験体の中には，No.1，No.2，No.5 のように実製品もある。これらは X 線で損傷箇所があらかじめ特定されている。各試験体の欠陥位置は，表 4.4-1 の備考に示す。なお，LUVI による内部欠陥検査動画では，欠陥位置の特定にあたって困難さに違いはあるものの，欠陥位置を LUVI で作成された動画画面で波紋を確認することができた。

表 4.4-1 追加検討試験体

試験体 No.	試験体の種類	試験体外観	備考
1	クドウリング/No.4 (凸部)		X 線で欠陥確認済み 欠陥の深さ 9mm (UT)
2	クドウリング/No.4 (凹部)		X 線で欠陥確認済み 欠陥の深さ 9mm (UT)

3	模擬欠陥試験体		<p>模擬欠陥 φ 3mm,          模擬欠陥 表面から 5mm</p>
4	アルミ模擬欠陥試験体		<p>横穴 φ 1mm          横穴位置 表面から          2mm と 10mm (計 4 箇所)</p>
5	バルブボディ/No. 3		<p>欠陥 7 箇所確認済み</p>
6	模擬欠陥試験体		<p>模擬欠陥 φ 3mm,          模擬欠陥 表面から 10mm</p>
7	模擬欠陥試験体		<p>横穴 φ 3mm,          横穴位置 表面から 10mm</p>


8	模擬欠陥試験体		横穴 φ3mm, 横穴位置 表面から 5mm
9	模擬欠陥試験体		横穴 φ3mm, 横穴位置 表面から 5mm
10	模擬欠陥試験体		横穴 φ3mm, 横穴位置 表面から 10mm

#### 4.4.2 AI の適用

表 4.4-1 に示す試験体を、4.2.2 の方法に従って内部欠陥検査動画から静止画に切り出した後、アノテーション用の画像変換を行った。アノテーションは、全ての試験体に対して行った。LUVI による内部欠陥検査動画は、試験体によって画質に違いが見られた。比較的画質が良かった No.4 を検証に用いた。すなわち、No.4 を除いた No.1 ~No.10 を学習させ、その学習モデルを使用して No.4 に対して欠陥位置を認識できるかをテストした。

図 4.4-1 は、No.4 の動画の一部である。表 4.4-1 に示すように、超音波センサーが照射したレーザー（赤枠）の右側にある。図 4.4-1 の画面右側から超音波が左側に向かって進行する。図 4.4-1 の動画からアノテーション用の画像変換を行うにあたって、図 4.4-1 の画面を水平に上端（Row=00000）から下端（Row=00067）に等間隔に分割した。

Row=00000



Row=00067

図 4.4-1 試験体 No. 4 の動画一部

図 4.4-2 は、アノテーション用の画像の一例である。図 4.4-2 の左図は Row=00022, 同右図は Row=00057 にあたる。あらかじめ LUVI による内部欠陥検査動画によって、欠陥（波紋）が確認された範囲である。図 4.4-2 に示すように、進行波（右肩下がりの線）と反射波（右肩あがりの線）が読み取れる。追加試験体 No.4 の動画画質は比較的良かったため、アノテーション作業も他の追加試験体の作業と比較して順調に行えた。

表 4.4-1 に示すように、追加試験体 No.4 横穴（ $\phi 1\text{mm}$ ）を、表面から 2mm, 10mm の位置に合計 4 箇所あけている。欠陥位置のアノテーション（アノテーション画像に欠陥位置（ $\lambda$ ）を四角に囲む）は、Row=00022 から Row=00057 の 29 枚に対して行った。その他のアノテーション画像にはアノテーションを行っていない。




図 4.4-2 試験体 No. 4 のアノテーション画像（左図：Row=00022, 右図：Row=00057）

AI による学習では、No.4 のアノテーション作業結果を採用せず、No.4 を除いた No.1 から No.10 のアノテーション作業結果を用いて行った。No.4 のアノテーション画像以外は、No.4 のアノテーション画像よりも全般的に

画質が劣っていた。試験体によっては、アノテーション画像上で欠陥位置（ $\lambda$ ）を判別することが、人間の眼でも困難な場面があった。

No.4 以外のアノテーション結果を用いて学習を行い、No.4 のアノテーション用画像に対して、 $\lambda$  位置を正しく認識できているかテストを行った。その結果を図 4.4-3 (1)～図 4.4-3 (4)に示す。アノテーション作業で欠陥位置と学習させた位置を、概ね認識していた。

V04-row=00036\_Recog

V04-row=00038\_Recog

V04-row=00040\_Recog






図 4.4-3 (1) 試験体 No. 4 アノテーション画像認識結果

V04-row=00041\_Recog



V04-row=00042\_Recog




V04-row=00043\_Recog




図 4.4-3 (2) 試験体 No. 4 アノテーション画像認識結果



V04-row=00044\_Recog



V04-row=00045\_Recog



V04-row=00047\_Recog






図 4.4-3 (3) 試験体 No. 4 アノテーション画像認識結果

V04-row=00048\_Recog



V04-row=00049\_Recog



V04-row=00051\_Recog




図 4.4-3 (4) 試験体 No. 4 アノテーション画像認識結果

図 4.4-3(1)～図 4.4-3(4)の結果を動画に編集し、AI の認識結果を緑色に着色した。図 4.4-4 は、その動画の一部、欠陥位置を捉えた瞬間を示す。動画波紋の位置とほぼ同じ位置を、緑色にハイライトできていることが確認できた。ただし、合計 4 箇所 の穴があけられていたのに対して、AI では 3 箇所 の認識にとどまった。試験体の側面を認識していたものの、試験体表面を捉えることができていない。ただし、試験体表面の波紋は、人間の目視でも困難に思えた。今後、画質の改善等に向けたさらなる取り組みが必要であると考えられる。





図 4.4-4 試験体 No. 4 認識結果動画（一部）

次に、No.10 の検証のため、No.10 を除いた No.1 から No.9 のアノテーション作業結果で学習を行った。No.10 のアノテーション画像は、No.4 のアノテーション画像よりも画質が劣っていた。また、全体から見ても画質が良くなかった。すなわち、アノテーション画像上で欠陥位置（ $\lambda$ ）を判別することが、人間の眼でも困難であった。

図 4.4-5 は、No.10 の CH1 の動画の一部である。No.10 は超音波センサーを右側（CH1）と左側（CH2）に設置して実験を行っている。表 4.4-1 に示すように、超音波センサーが照射したレーザー（赤枠）の右側にある。図 4.4-5 の画面右側から超音波が左側に向かって進行する。図 4.4-5 の動画からアノテーション用の画像変換を行うにあたって、図 4.4-5 の画面を水平に上端（Row=00000）から下端（Row=00143）に等間隔に分割した。No.4 の動画と比較すると、あまり画質が良くないことがわかる。

Row=00000



Row=00143

図 4.4-5 試験体 No. 10 の動画一部

図 4.4-6 は、アノテーション用の画像の一例である。図 4.4-6 の左図は Row=00103，同右図は Row=00114 にあたる。あらかじめ LUVI による内部欠陥検査動画によって、欠陥（波紋）が確認された範囲である。図 4.4-6 に示すように、進行波（右肩下がりの線）と反射波（右肩あがりの線）が読み取れる。ただし、欠陥位置“ $\lambda$ ”の判定は No.4 よりは困難であった。

表 4.4-1 に示すように、追加試験体 No.10 横穴（ $\phi 3\text{mm}$ ）を、表面から 10mm の位置にあけている。欠陥位置のアノテーション（アノテーション画像に欠陥位置（ $\lambda$ ）を四角に囲む）は、Row=00103 から Row=00114 の 12 枚に対して行った。その他のアノテーション画像にはアノテーションを行っていない。

Row=00103

Row=00114






図 4.4-6 試験体 No. 10 CH1 のアノテーション画像（左図：Row=00103，右図：Row=00114）

No.10 以外のアノテーション結果を用いて学習を行い，No.10 のアノテーション用画像に対して， $\lambda$  位置を正しく認識できているかテストを行った．その結果を図 4.4-7 (1)～図 4.4-37(3)に示す．AI は欠陥があると認識したものの，アノテーション作業を行っていない，すなわち誤まった認識となっていた．

V10 (CH1)-row=00006\_Recog



V10 (CH1)-row=00048\_Recog



V10 (CH1)-row=00051\_Recog




図 4.4-7 (1) 試験体 No.10 アノテーション画像認識結果

V10 (CH1)-row=00065\_Recog

V10 (CH1)-row=00066\_Recog

V10 (CH1)-row=00068\_Recog




図 4.4-7 (2) 試験体 No. 10 アノテーション画像認識結果

V10(CH1)-row=00077\_Recog

V10(CH1)-row=00078\_Recog




図 4.4-7 (3) 試験体 No. 10 アノテーション画像認識結果

図 4.4-7(1)～図 4.4-7(3)の結果を動画に編集し、AI の認識結果を緑色に着色した。図 4.4-8 は、その動画の一部を示す。本ケースでは、欠陥位置を認識することができなかった。図 4.4-7(1)～図 4.4-7(3)で AI が誤認識した箇所には共通の傾向がある。それは、アノテーション画像で誤認識した（四角に囲んだ）箇所から下方に、すなわち LUVI 動画画面上において、同じ箇所ですっと点滅しているような場所であることを確認した。これは、試験体の表面の凹凸に対して反応しているものと考えられる。このような現象への対応は、今後の課題である。






図 4.4-8 試験体 No. 10 認識結果動画（一部）

#### 4.5 内部欠陥検査技術まとめ

不慣れた検査員でも着色で欠陥位置が分かりやすくなる支援ツールとして実用化できたと考える。ただし、誤認識するケースもあった。これは表面の凹凸による反射や複雑な物理境界による反射に対して発生していたことが考えられる。アノテーション作業において不明確なケースは、欠陥位置の特定に不慣れか、または元の情報が不鮮明かのいずれかである。表面にある微小な欠陥や境界条件でレーザー超音波による反射波の検知が難しい部位もあることに留意が必要である。

また、本研究では理想的な場合の検討において試験体に人為的に円柱状の穴を作製して欠陥とみなして超音波試験を行った。しかし実際の鋳造品に存在する欠陥は粒子状や亀裂状であるため、理想的な場合と比べて超音波の欠陥からの反射の様子が異なっている可能性も考えられる。そこで、今後、超音波による反射をシミュレーションによって、より科学的に解明していくことも、アノテーション作業を支援する上で必要になる。このような改善を繰り返すことで、AI の予測精度が改善し、人間と同程度の判定を行えるようになると期待する。

## 5. 統合化システムの作成と検証

### 5.1 統合化システム概要

2章から4章にて開発したアプリについては実際の検査現場での活躍が期待されるものの、これらはいくまで独立したアプリであるため、このままでは得られた結果の相互活用が困難となる。そこで、これらのアプリを統合的に管理・運用することを目的としたアプリ（以下、統合検査システム）を開発した。

統合検査システムの起動画面を図5.1-1に示す。起動画面では「表面欠陥検査」、「形状検査」及び「内部欠陥検査」の3種類の検査を支援する機能を有しており、これらの機能が2章から4章までの研究成果に対応する。また、これらの機能を使用する際には予め検査に関するデータが取り纏められているサーバーを画面下部の「保存先」ボタンより指定する必要がある。これによって検査現場で撮影した写真、所感がまとめられたテキストデータ、及び検査結果と言った情報が自動的に且つ機能的なファイル構造へ保存される。

各機能に関する詳細を次節以降に記載する。



図 5.1-1 統合検査システムの起動画面

### 5.2 表面欠陥検査

表面欠陥検査の画面を図5.2-1に示す。表面欠陥検査画面は、特に「表面欠陥検査」の作業の効率化を目的として用いる。検査時、要すれば「個体識別番号」テキストボックスに検査対象を特定可能な文字列（例えばバーコード番号等）を入力する（入力せずとも下記の作業は実行可能である）。

検査時の所感をまとめた文章や製品の写真などを記録したい場合には、右上の「検査記録」グループボックスからそれぞれのボタンをクリックする。

- ・ 「MEMO」ボタンをクリックするとメモ帳が表示される。検査に関する文書を記載の後、「保存」ボタンをクリックすると5.1にて指定した「保存先」フォルダの下に「日付 (yyyy-mm-dd)」サブフォルダ、及び「個体識別番号」サブフォルダを作成し、その「個体識別番号」サブフォルダへ「Memo.txt」ファイルを作成する。なお、このメモ帳を閉じた後、再度開くと先ほど作成した Memo.txt が改めて開かれる。
- ・ 「Photo」ボタンをクリックすると接続されているカメラデバイスの画面が表示される。画面をクリックすると MEMO と同様に「個体識別番号」フォルダの下へ「Capture-1.jpg」ファイルを出力する (Capture-1.jpg が存在する場合には2,3 と連番で保存する)。

下部のリストボックスはファイルやフォルダへのリンクとなる。例えば検査のガイドラインや過去の欠陥写真などが保存されたフォルダへのリンクを作成すると、この画面からスムーズにアクセスすることができる。



図 5.2-1 表面欠陥検査の画面

### 5.3 形状検査

形状検査の起動画面を図 5.3-1 に示す。ここでは 2 章にて開発した形状検査官の実行を行う。なお、この実行の際に 5.1 にて指定したサーバーを引数として形状検査官に渡しており、これにより形状検査官で作成したオーバーレイ画像が 5.2 にて記載した保存先と同様の箇所へ自動的に保存される。そのため、5.2 では説明を省略していたが、形状検査官にも個体識別番号を入力するテキストボックスが配置されている。



図 5.3-1 形状検査の起動画面

### 5.4 内部欠陥検査

内部欠陥検査の画面を図 5.4-1 に示す。内部欠陥検査そのものについては、基本的に超音波測定器やそれに付随するアプリにて行うが本機能ではこれらの検査記録のアクセサビリティを向上させるため、指定フォルダ下(サブフォルダを含む)から特定の名前を有するファイルを検索し、それを一覧表示する機能を実装した。

例えば図 5.4-1 のように検索ファイル名に「Photo.JPG」と記入した場合、左に配置されたフォルダツリーにて指定したフォルダ下より「Photo.JPG」ファイルを検索し、その検査結果を右下に表示する。画像ファイルの場合はファイルパスに合わせてサムネイル画像も表示する。これらファイルパスやサムネイル画像をクリックすると、その保存先のフォルダが開かれ、元ファイルや関連するデータが直ちに参照可能となる。内部欠陥検査にて欠陥の有無の判定に疑問を生じた場合、この機能を使用することにより、過去に実施した類似例を参照することが容易となる。



図 5. 4-1 内部欠陥検査の画面

## 6. まとめ

鋳造品を加工する船用製品製造事業所は、工程内で発生する不適合未然防止のため、外部との接点である受入検査において、①鋳造品の形状検査、②表面欠陥検査、③内部欠陥検査をより高めていくための、総合的な検査支援技術が求められている。令和3年度並びに4年度に実施した研究を、以下のようにまとめる。

### ① 鋳造品等の形状検査に関する研究と実用化

- ・ 2次元図面を3次元モデル化するアプリ(3D Drafter)を制作した。
- ・ 写真画像と上記3次元モデルを対比し、相違点を抽出するタブレット版形状アプリを制作した。
- ・ タブレット版形状検査アプリを現場検査で使用し、その有効性を確認し実用化の目途を立てた。
- ・ 3D Drafter で作成した3次元データと製品を比較できるホロレンズ版形状検査アプリを製作した。
- ・ ホロレンズ版形状検査アプリを現場検査で使用した。習熟する必要があるものの実用化の目途が立った。

### ② 鋳造品等の表面欠陥検査技術に関する AI 活用等の研究と実用化

- ・ 表面欠陥ガイド等文書を取り込み、知識処理 AI 技術を活用した注意喚起アプリを制作した。
- ・ 注意喚起アプリをベテラン検査員が活用して、現場での実用性を確認した。
- ・ 鋳造品表面欠陥検出の現場での活用をイメージして、画像認識アプリを改良した。
- ・ 画像認識アプリの改良によって、カメラ画像をリアルタイムで取り込み、欠陥を判別できるようになった。
- ・ 欠陥の種類ごとに判別できるようになるためには、さらに多くの画像を整備する必要がある。ただし、欠陥があるか否かを検査員に情報提供できるようになったと考える。
- ・ 鋳造品表面欠陥検査に AI を活用できる実用化の目途が立った。

### ③ 鋳造品等の内部欠陥検査技術に関する AI 活用等の研究と実用化

- ・ レーザー超音波可視化システム(LUVI)の動画を処理し、AI で内部欠陥位置を認識できる見通しが立った。
- ・ 表面の凹凸による反射や複雑な物理境界による反射が起こるようなケースにおいては誤認識もあった。
- ・ 人間がアノテーション作業で判断できるレベルまで画質が良くなれば、誤認識は低減する見通しが立った。
- ・ 誤認識を低減させるためには、超音波による反射をシミュレーションによって、より科学的に解明してアノテーション作業を支援することが必要である。その結果、人間と同程度の判定を行えるようになると思われる。

### ④ ①～③の研究成果を検査現場で活用するための統合化システムの作成と検証

- ・ ①～③で制作したアプリを統合的に管理・運用することを目的とした統合検査システムを制作した.
- ・ 本統合システムを活用することによって、各検査記録が一元的に管理できる.
- ・ 将来の検査において検査履歴を有効に活用して、鋳造品等検査の品質を高めることが期待できる.

#### 参考文献

- 1) Shaoqing Ren et. al., Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks ,2015
- 2) 「日本船舶品質管理協会殿請負研究 AIによる船用機器の品質管理高度化に関する基礎的調査研究報告書」(令和2年2月, 国立研究開発法人 海上・港湾・航空技術研究所 海上技術安全研究所)
- 3) 高坪純治, 王波, 鈴木俊一, 劉小軍, 齊藤典生, レーザー超音波可視化探傷技術の新展開<特集: レーザー超音波の革新性①>, 光アライアンス, 2020