

技術資料

Technical Data

磁粉探傷における AI を用いた鋼片表面きずの検出と深さ推定

山腰浩平*¹, 湯藤隆夫*¹, 森 大輔*², 有澤 亮*³, 大迫昭司*³, 宇佐美徹*³

Detection and Depth Prediction of Surface Defects on Steel Billets Using AI Technology in Magnetic Particle Inspection

Kohei YAMAKOSHI, Takao YUTO, Daisuke MORI, Ryo ARISAWA, Shoji OSAKO and Toru USAMI

Synopsis

Inspecting and removing surface defects on steel billets is crucial for maintaining product quality and preventing defects from propagating during the finishing rolling. In surface defect inspection, magnetic particle inspection is used to visualize defects. After visualization, inspection technicians manually judge the defects. This process depends heavily on labor, so that automation is necessary. Automation requires image processing techniques, but conventional rule-based methods fail to reliably detect subtle differences in magnetic particle patterns and accurately predict defect depth. These limitations often result in missed detections, where defects are not detected, or over detection, where non-defective areas are detected. To address these challenges, this study applies deep learning, which extracts complex features from magnetic particle patterns, improving both defect detection and depth prediction. Specifically, this paper presents:

- (1) a defect detection method based on an object detection AI model, and
- (2) a depth prediction method using a custom AI model.

1. 緒言

鉄鋼の製造プロセスでは、スクラップや鉄鉱石を原料として、溶解、精錬、鋳造した後、分塊圧延により加工しやすい形状（鋼片）に整え、製品圧延を経て最終製品に仕上げる。分塊圧延後は、製品圧延中に表面きずが拡大するため、鋼片段階で表面きずを検査し、検出したきずを除去している。この表面きず検査は、主に蛍光磁粉探傷試験（以下、磁粉探傷試験）が用いられ、鋼片表面

に付着する蛍光磁粉の模様（以下、磁粉模様）からきずの検出ときずの深さを推定している。この確認作業は人の目視に依存しており、作業者の負担が大きい。そのため、目視確認の自動化を目的として、1980年以降カメラで撮像した画像から画像処理によってきずを判定する方式が開発されてきた^{1)~4)}。

この方式は、自動化を目的として表面きずを除去するために、鋼片表面のきず分布をマップ化する。マップ化に必要な情報はきずの座標とその深さであり、これらを

2025年4月21日 受付

* 1 大同特殊鋼(株)技術開発研究所 (Corporate Research & Development Center, Daido Steel Co., Ltd.)

* 2 大同特殊鋼(株)技術開発研究所, 技術士(経営工学) (PEJp, Corporate Research & Development Center, Daido Steel Co., Ltd.)

* 3 大同特殊鋼(株)知多工場 (Chita Plant, Daido Steel Co., Ltd.)

画像処理によって求める必要がある。

しかし、従来の画像処理では、きずときずに似た健全部の磁粉模様（以下、疑似模様）を正確に分類することや磁粉模様の持つさまざまな特徴からきずの深さを推定することが困難であった。これは、従来の画像処理が模様様の微細な違いを認識する能力に限界があったためである⁵⁾。

近年、従来処理の能力限界を克服する手段として、人工知能の一種であるディープラーニング（以下 AI）を活用した高性能な画像処理手法が開発されている。AIによる画像処理技術は目覚ましい進化を遂げており、鉄鋼業界でも多くの分野で精度の向上および実用化が進められている⁶⁾。これを踏まえて、磁粉探傷におけるきず画像の検査を対象とした場合でも十分実用的な精度の達成が見込めると考えた。

以上を背景として、本研究では、画像処理に AI 技術を適用し、製造ラインでの実用が可能なきずの検出精度およびきず深さ推定精度の向上を目指した。特に本稿では、画像処理 AI の技術開発に焦点を当てて述べる。

2. 開発仕様

Table 1 に開発仕様を示す。検査対象は角形の銅片であり、非破壊検査手法の一つである磁粉探傷試験によってきずを可視化し、カメラによる撮像と、画像処理を行う。

なお、Fig. 1 に示す最終的なきず情報のマップ出力に必要な機能は以下 2 つであり、これら機能の高精度化を目指した。

- (1) きず検出・・・銅片表面に発生したきずの座標ときずの種類を判定（きずの種類によって有害性が変わる）
- (2) きず深さ推定・・・検出したきずの深さを定量化

3. 磁粉探傷結果の画像化

磁粉探傷は、試験片表面に磁束を発生させ、きず周りに生じる漏洩磁束を利用してきずを検出する⁷⁾。漏洩磁束により磁粉がきずの位置に吸着し、Fig. 2 に示すような特徴的な磁粉模様が形成される。手順としては、銅片を磁粉液の水槽に浸漬後、磁化パッドを銅片端部に密着させて軸方向に通電する。このとき、きず周りに発生した漏洩磁束に磁粉を付着させた後、銅片を水槽から取り出すことで磁粉模様が確認できる。磁粉模様はきずの種類によってさまざまな模様が形成される一方で、例えば酸化スケールにより表面が荒れた場合、きずに似た疑似模様も形成されるため、画像処理による判別を難しくしている。

磁粉探傷の画像化は、暗室下で銅片表面に付着した蛍

Table 1. Development specification.

Item	Specification
Target	Billet (160 mm × 160 mm × length)
Inspection method	Magnetic particle inspection
Detection method	Image processing + AI
Detection rate	Recall 100 %, Precision ≥ 95 %
Depth prediction accuracy	RMSE < 0.3 mm ※ ※ Error from the true value

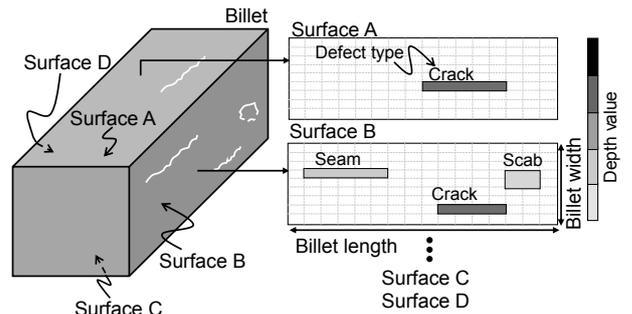


Fig. 1. Specification of defect map.

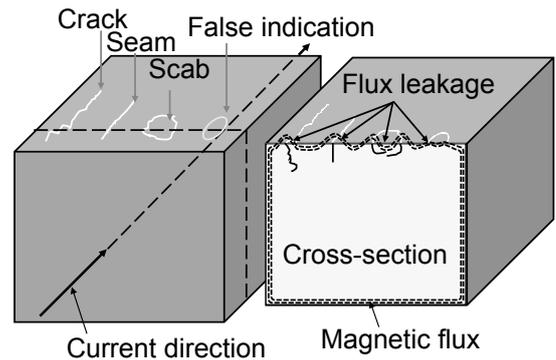


Fig. 2. Schematic illustration of defect patterns visualized by magnetic particle inspection.

光磁粉を紫外線照明で発光させカメラで撮像する。本研究では、エリアカメラを銅片の長手方向に配置して撮像する設計とした。Fig. 3 に撮影環境の模式図を示す。

ここで、中間製品である銅片は均一な形状ではないため、カメラと銅片表面の距離が変化し、焦点が合わない可能性がある。この問題を解決するために、製造ラインへの適用を想定したレンズ設計を行い、被写界深度内に収めた。

また、銅片表面は磁粉液によって濡れているため、紫外線（波長～400 nm）の拡散反射光が外乱となる可能性がある。そこで、蛍光磁粉の波長（530 nm）のみを透過するバンドパスフィルタをレンズに装着し、蛍光磁粉以外の波長をカットした。この撮影した画像を使い、本研究の画像処理を検討した。その他の光学設計は Table 2 に示す。

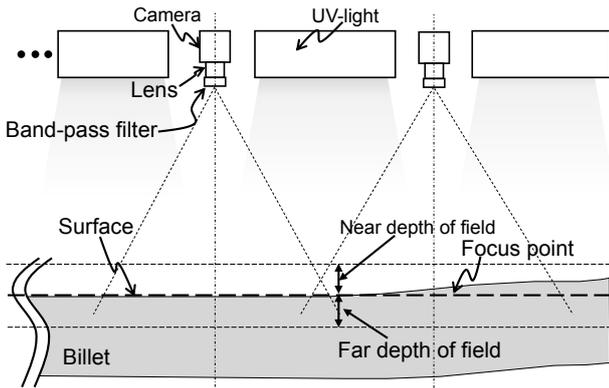


Fig. 3. Schematic illustration of a steel billet image taken by cameras.

Table 2. Shooting conditions.

Device	Parameter	Setting value
Camera	Sensor type	CMOS, Monochrome, 8 bit
	Resolution	2048 × 1536
Lens	Aperture	F4
	Focal length	12 mm
	Focus Distance	800 mm
Filer	Band-pass	500-600 nm

4. 画像処理検査

4. 1 従来画像処理の課題とAI適用

ここでは、従来の画像処理の課題を紹介し、その課題に対する AI を適用した画像処理手法について述べる。Fig. 4 に従来の画像処理によるきず (a) と擬似模様 (b) の判定例を示す。この画像処理では、入力した画像に対して二値化処理を行い、きずの範囲を直接抽出し、抽出範囲を測長してきずを判定する。従来は、このようなルールベースの方式が主流であったが、形状や輝度が近い擬似模様をへげきずと誤判定することがある。また、製造中に発生する磁粉模様は多種多様であるため、きずが持つ固有の特徴をルールベースに落とし込むことが難しく、この方法ではきず判定精度の向上に限界があった。

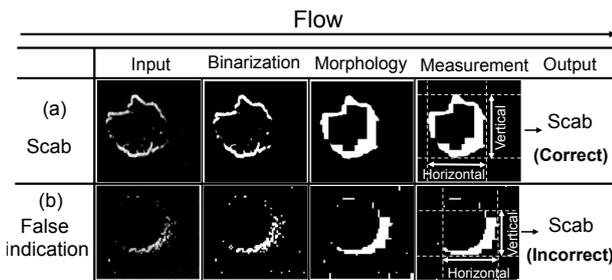


Fig. 4. Example of a misjudgment by rule-based image processing.

判定精度の向上を目的として、最新の画像処理では AI の適用が盛んに研究されている。特に、畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) は、画像処理において高い性能を発揮する AI であり、模様の細部まで抽出して自動で学習できる特徴がある。ここで、学習とは AI がデータから特徴を見つけて判定精度を向上することを指す。画像から磁粉特徴を学習することで、例えば Fig. 5 のように、AI へ入力した磁粉模様が 4 つのクラス (きず種あるいは擬似模様) のうち、どこに属するか判定することができる。

CNN は中間層に畳み込み層 (Convolution layer) とプーリング層 (Pooling layer) を有しており、それぞれ以下の役割を担う。

畳み込み層: 入力データからエッジ、線、角、模様などの局所的なパターンを検出する。

プーリング層: 特徴マップの次元を縮小することで重要な特徴を保持しつつ小さな平行移動や変形に対する位置の不変性を強化する。

これらの層を有する CNN は、磁粉模様のように局所的な模様の変化や発生位置、サイズがランダムな対象の画像判定に有効と判断できる。

以上から、本研究では従来のルールベース方式に変わり、CNN を活用することで、きず判定 (検出・深さ推定) の精度向上を図ることとした。なお、本稿では CNN の説明は割愛するが、詳細については文献⁸⁾を参照されたい。

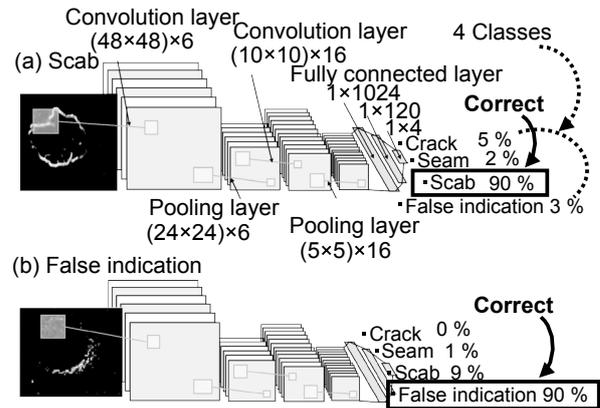


Fig. 5. Example of Image classification using a CNN architecture.

4. 2 磁粉探傷検査へのAI適用

2章で述べたように、磁粉探傷を自動化するための最終的なきず情報のマップ出力には (1) きず検出と (2) きず深さ推定という 2 つの機能が必要である。

しかし、この 2 つの機能を両立する手法は提案され

ていない。そこで、(1)、(2)の機能ごとにAIモデルを開発し、その2つを組み合わせる方法を検討した。ここでAIモデルとは、目的の出力(きず種の分類や深さの値)を得るためのネットワークを指す。1つ目のモデル(Fig. 6 AI model 1)では、CNNベースの物体検出(Object detection)モデルを活用する。物体検出モデルでは、鋼片画像からきずの位置・サイズ・種類などを抽出できる。そして2つ目のモデル(Fig. 6 AI model 2)では物体検出モデルによって抽出されたきずの深さを推定する。

次章からは、これら2つのモデルにおける、学習、評価までの流れを述べる。

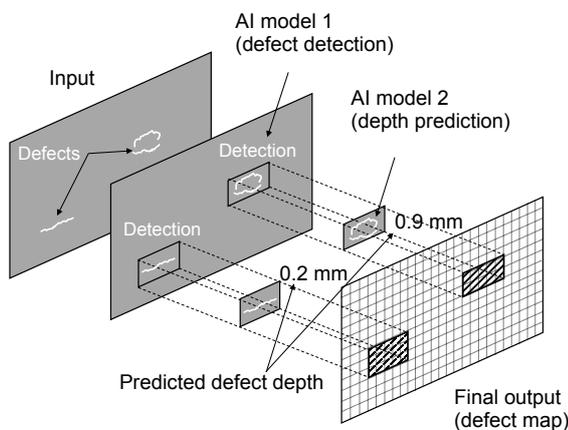


Fig. 6. Respective roles of two AI models in the processing pipeline.

5. きず検出 AIモデル

物体検出モデルはこれまでに多くの種類が提案されており、画像から物体の位置を検出するタスクにおいて広く利用されている^{9), 10)}。特にCNNベースの物体検出モデルは構造が比較的シンプルであり、きず判定への適用実績が多いため、本研究でもCNNベースのモデルを採用した¹¹⁾。また、独自のデータセットを用いてチューニングが可能であり、鋼片の磁粉探傷画像に特化したAIモデルの構築にも適している¹²⁾。この物体検出モデルに対し撮影した磁粉探傷画像を学習させ、その有効性を評価した。

5. 1 きず検出AIモデルの学習

物体検出モデルの学習条件をTable 3に示す。本モデルの学習には、3章の撮像条件で得られた画像データを訓練用とテスト用に分割して使用した。また、汎用的な画像を膨大に事前学習して得られる重みを使って磁粉模様の画像に調整する転移学習(チューニング)を行っ

た。これによりネットワーク全体のパラメータを効率的に調整した。

学習の安定性と精度を確保するため、AIモデルの学習挙動を事前に制御するハイパーパラメータを調整し、学習用データセットにおける正解とAIの予測の誤差が十分小さくなるように学習することとした。

Table 3. Training condition for defect detection AI.

AI model	Object detection (CNN)
Number of training data	2000
Number of test data	250
Optimizer	Adam

5. 2 評価方法

きず検出AIの評価には物体検出モデルの評価指標として代表的なPrecision(適合率)およびRecall(再現率)を用いた。これらは、AIモデルの検出性能を異なる観点から評価する指標である。Precisionは、AIモデルが検出したきずが正しかった割合を示す指標であり、式(1)で定義される。

$$\text{Precision} = \frac{TP}{TP + FP} \quad (1)$$

ここでTP(True Positives)は、正しく検出されたきずの数、FP(False Positives)は、誤ってきずと検出された数をあらわす。Precisionが高いほど、過検出が少なく、AIモデルの信頼性が高いことを意味する。一方Recallは、実際に存在するきずをAIモデルが正しく検出できた割合を示す指標であり、式(2)で定義される。

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2)$$

ここでFN(False Negatives)は、見逃したきずの数をあらわす。すなわち、見逃しがなければRecallは100%になる。これらの指標を用いることで、AIモデルの過検出と見逃しをバランスよく評価した。

5. 3 きず検出結果・考察

次に、開発したきず検出AIの評価結果について述べる。Table 4にAIで分類する3つのきず種を示す。3クラスのきず種に対する検出結果は、ヘゲきず(Scab)とカキきず(Seam)がRecall 100%を達成した一方で、割れきず(Crack)はRecall 75%となり、25%の不一致が発生した(Table 5)。また、Precisionはカキきずのみ0.77%と顕著な不一致が確認された。

Table 4. Types of defects detected by AI model.

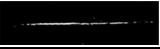
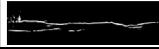
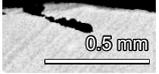
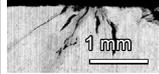
	Scab	Seam	Crack
Surface			
Cross-section			

Table 5. Initial detection results for each type of surface defect.

Item	Scab	Seam	Crack
Recall	1	1	0.75
Precision	0.96	0.77	0.95

そこで不一致の大きい2クラスの関係調べたところ、割れきずの Recall 25% 不一致はすべて AI がカキきずと誤分類した結果であることがわかった。

Fig. 7 は、すべてのきずが割れきずの画像に対し、一部カキきずと誤分類した例を示している。誤分類した割れきずは、模様がカキきずと類似している。CNN は模様そのものがどのきず種に類似しているかで判定するため、このような場合、正確な分類が難しい。そこで、割れきずの検出精度を向上させるため、割れきずの重みを大きくし、割れきずの検出を重視した AI モデルを作成した。式 (3) は、きず種の分類に影響を与える損失 L_{cls} の計算式である。損失は AI を学習するときに使われ、この値が大きいほどそのクラスを優先的に学習することができる。ここで N は学習させる画像の数であり、 C はきず種の数、 w_c はクラスに対する重み、 $y_{i,c}$ は正解ラベル (0 または 1)、 $\hat{p}_{i,c}$ はクラスに対して出力した予測確率である。

$$L_{cls} = - \sum_{i=1}^N \sum_{c=1}^C w_c \cdot y_{i,c} \cdot \log(\hat{p}_{i,c}) \quad (3)$$

さらに、重みを調整しても誤判定してしまう割れきずについては、ルールベースの (Fig. 8) 後処理を適用した。この処理は、割れきずが集団で発生する性質を利用しており、AI がカキきずと判定した場合でも、判定したカキきずの周辺 (100 mm² 以内) に割れきずが存在する場合は、割れきずと判定するよう修正する。上述した、2つの処理により、割れきずの Recall が 100% を達成でき、カキきずの Precision も 96% に上昇した (Table 6)。なお、種類にこだわらないきずの検出性能 (Total) は Recall が 100%、Precision は 96% となり、開発目標を達成した。これは AI によって疑似模様の過検出を減らせたことが大きく寄与している。

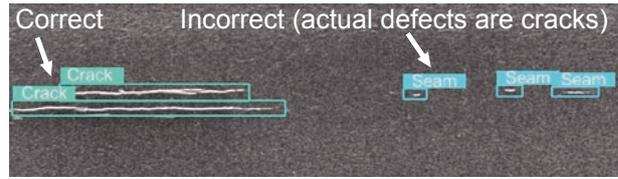


Fig. 7. Example of cracks misclassified as seams.

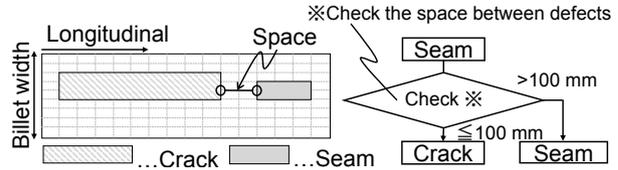


Fig. 8. Workflow to change “seam” to “crack” after AI judgment.

Table 6. Improved detection results for defect detection AI.

Item	Scab	seam	Crack	Total
Recall	1	1	1	1
Precision	0.96	0.97	0.95	0.96

6. きず深さ推定 AI モデル

本章では、5章のきず検出 AI モデルによって抽出したきず画像に対し、その深さを推定する AI について述べる。

先行研究では、磁粉の輝度からきずの深さを推定する画像処理⁵⁾が検討されたが、深さ推定精度が低いため、緒言で述べた通り AI を適用することとした。

6. 1 きず深さ推定 AI のネットワーク構成

AI を適用した先行研究では、画像分類モデルを用いて浅いきずと深いきずを分類できることが報告されている¹³⁾。そこで、本研究では、画像分類モデルのなかで模様の抽出に優れている ResNet を使用した^{14), 15)}。

ここで、一般的な画像分類モデルでは、画像内の特徴から出力クラスの中で最も確率が高いものに分類される。画像分類モデルに画像を入力すると、CNN で得られた特徴が全結合層 (Fully connected layer) に入力され、最終的に確率に変換できる活性化関数 (Softmax 関数) により、Fig. 9(a) のように、最も確率が高いクラスを予測して分類できる。しかし、今回の目的は、きずの深さを連続値で出力することである。そのため、最終出力に活性化関数を適用せず、Fig. 9(b) のように、きずの深さを連続値で出力する AI モデルを作成した。

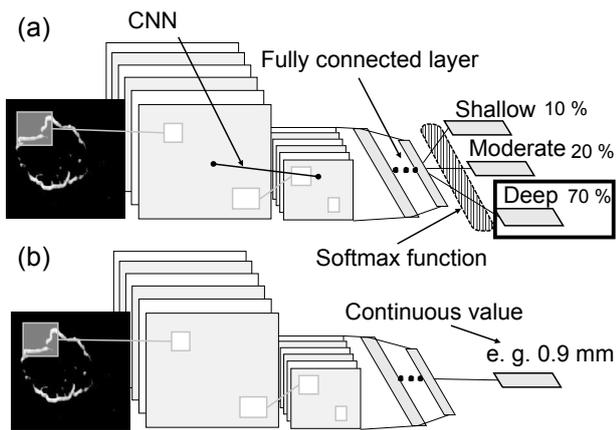


Fig. 9. Output differences from each AI model: (a) Classification, (b) Continuous value.

さらに、このAIモデルの精度を向上させるため、きず画像以外の情報を入力するAIモデルを開発した (Fig. 10)。

目視検査によるきずの深さ推定では、磁粉模様だけでなく、模様やきずの種類から総合的に深さ推定している。しかし、きず検出AIで抽出したきずを通常の方法でCNNに入力する場合、画像以外の情報（模様やきずの種類）は失ってしまう。サイズ情報は、CNN (ResNet) にきず画像を入力する際、画像のサイズを一定にしなければならない。また、きず種情報は、5. 3で述べたように、抽出した単体の模様のみから、明確にきずの種類は特定できない。そこで、これらの失った情報をCNN後の全結合層に直接入力することでマルチモーダル(多情報の入力)に深さ推定を可能にした。この開発したマルチモーダルAIを使って学習、評価することとした。

6. 2 きず深さ推定AIの学習

開発したAIによってきず深さを高精度に推定するに

は、学習用のデータセットとして、磁粉模様の画像ときず深さを紐づけて取得する必要がある。そこで、磁粉探傷試験できずと認められた模様を研削し、きずの跡が完全に除去された時点で、デプスゲージによりその深さを測定した。得られたデータ数ときず深さ推定AIの学習条件を Table 7 に示す。

本研究では、AI学習条件について、種々の検討を行った。ここでは画像データ数の検討について述べる。AIモデルの精度は学習させるデータ数に大きく影響する¹⁶⁾。Fig. 11 に示す通り、実例では300以上のデータ数で精度向上は頭打ちとなるため、本研究では取得しているデータ数で十分な精度評価ができると判断した。よって500枚の画像で学習させたAIモデルを使って以降の評価を実施した。

Table 7. Training condition for depth prediction AI.

AI model	ResNet50
Image size	224*224 pixels
Number of training data	500
Number of test data	80
Optimizer	SGD

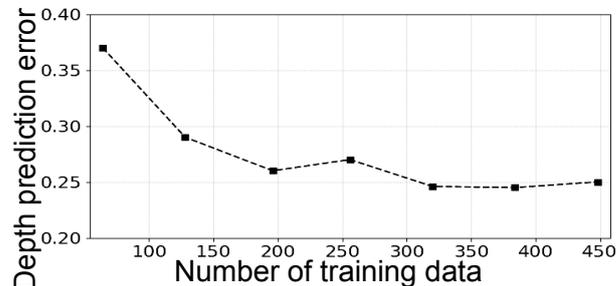


Fig. 11. Correlation between data size and depth prediction error.

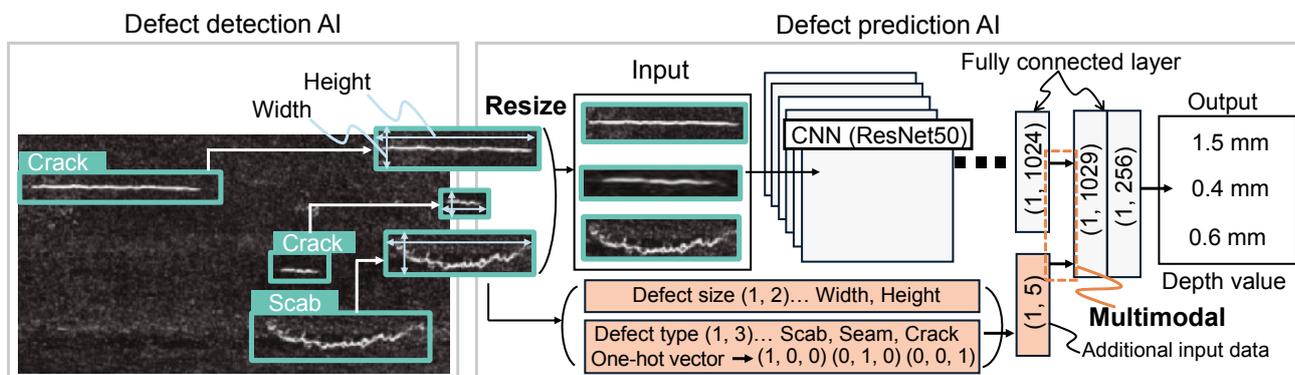


Fig. 10. Multimodal AI model.

6. 3 評価方法

開発した AI のきず深さ推定精度を評価するため、評価指標には予測誤差の平均を用いた。回帰予測において、予測誤差の代表的な評価指標としては MAE (Mean Absolute Error, 平均絶対誤差) があげられる。しかし、推定したきず深さの誤差が大きい場合、きずの除去時にきず残りや過剰なきず取りを引き起こす可能性がある。そこで、大きな誤差の発生を評価に強く反映することができる RMSE (Root Mean Squared Error, 二乗平均平方根誤差) を採用した。各指標は式 (4)、(5) で表される。ここで、 n はデータのサンプル数であり、 z はきず深さ実測値、 \hat{z} はモデルのきず深さ予測値である。

$$MAE = \frac{1}{n} \sum_{i=1}^n |z_i - \hat{z}_i| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (z_i - \hat{z}_i)^2} \quad (5)$$

6. 4 深さ推定結果・考察

ここでは、従来のルールベース画像処理、画像のみ入力した AI および今回開発したマルチモーダル AI のきず深さ推定性能を比較した。各手法のきず深さの推定精度は、実測したテストデータ 80 枚を用いて算出した。

Fig. 12 に従来のルールベース画像処理と画像のみ入力した AI モデルの深さ推定結果を示す。プロット (a)、(b) はそれぞれ同じきずに対する各手法の予測結果であり、どちらも高い精度であることが分かる。ルールベースの場合は輝度のみからきず深さを予測するため、大きな誤差を生じたが、AI の場合はきず模様の特徴からきず深さを推定するので、予測精度が向上したと考えられる。

Fig. 13 に画像のみ入力した AI とマルチモーダル AI の深さ推定結果を示す。(c)、(d) は同じきずに対する各手法の予測プロットである。サイズの小さいへげきず (c) と大きいへげきず (d) どちらも画像入力 AI 対比マルチモーダル AI の推定精度が高い。これは画像から得られなかったサイズの情報を考慮して深さを推定できるため、精度が向上したと考えられる。

以上の結果から、CNN の活用、さらにマルチモーダル AI の開発により深さ推定精度の向上に一定の効果が確認できた。最後に、各手法のまとめを Table 8 に示す。開発したマルチモーダル AI は、RMSE が目標精度の 0.3 mm

未満を達成し、従来のルールベースから約 35 % 精度が向上した。また、相関係数もマルチモーダル AI が最も高い結果となった。

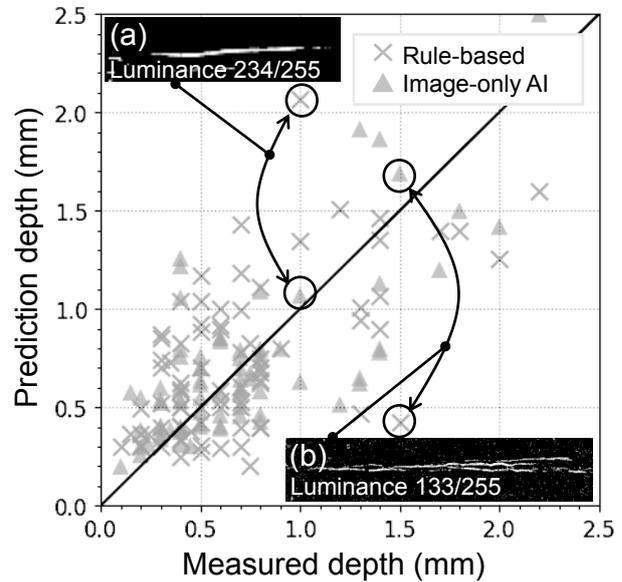


Fig. 12. Defect depth prediction results by rule-based method and image-only AI.

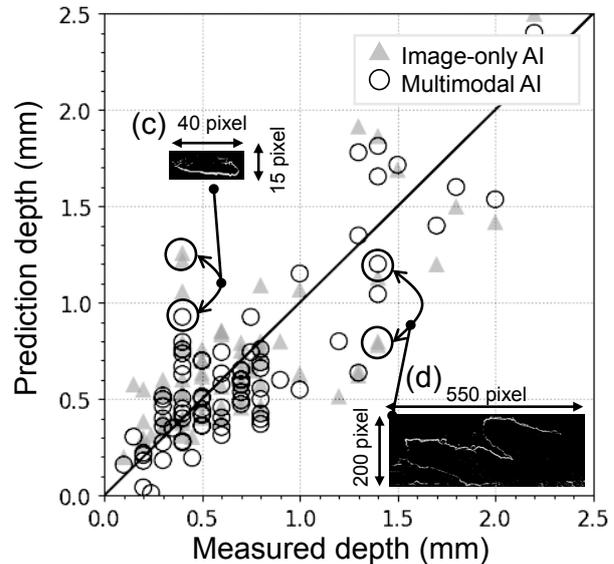


Fig. 13. Defect depth prediction results by image-only AI and multimodal AI.

Table 8. Prediction results of each method.

AI	Method	RMSE	Correlation function
	Rule-based	0.37 mm	0.28
○	Image-only	0.31 mm	0.49
○	Multimodal	0.24 mm	0.71

7. 実用化テスト

以上の検討により開発したAI評価機の機器構成をFig. 14に示す。鋼片全周の画像を撮影するために、鋼片を90度ずつ回転させ、コーナー部を含む4面の画像を取得する仕様とした。本装置によって、製造ライン内で鋼片全長を採傷したきずを定量化し、Fig. 15のようにマップを出力できた。今後は本開発AIの更なる評価および自動化に向けた運用体勢の取り組みを進める。

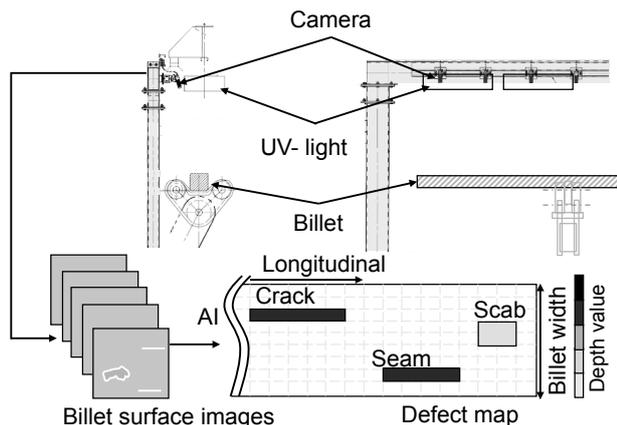


Fig. 14. Hardware configuration of the developed AI evaluation system.

8. おわりに

本稿では、鋼片を対象とした磁粉探傷試験の目視検査に対し、AIを適用した画像処理の性能を評価することで、以下の結論を得た。

(1) きず検出 AI

物体検出モデルを使ったきず検出により、Recall 100 %、Precision 95 % 以上を達成した。

(2) きず深さ推定 AI

マルチモーダル化したAIの開発により、磁粉模様以外の情報も取り入れることで、RMSE 0.3 mm 以内を達成した。

(3) きず情報のマップ化

これらのAIを組み合わせることで、きず情報を高い精度で定量化したマップを作成することが可能になった。

今後は、実用化を見据え、AIを用いた本評価装置の運用・保守システムの開発を進めていく。

(文 献)

- 1) 遠藤敏夫, 八木富一, 高田健一, 矢野泰三, 中村薫, 藤田裕司: 電気製鋼, 64(1993), 235.
- 2) 高田健一, 矢野泰三: 電気製鋼, 74(2003), 173.
- 3) 高橋幸弘, 平安名啓介: 新日鉄住金技法, 406(2016), 77.
- 4) 小川岳夫, 和佐泰宏, 赤松勝, 岡本陽, 宮本均, 田中浩信: 神戸製鋼技法, 50(2000), 69.
- 5) 関根和喜, 鈴木聡, 岩井修: 圧力技術, 35(1997), 210.
- 6) 筒井和政, 難波時永, 木原研吾, 平田純一, 松尾翔平, 伊藤一真: 鉄と鋼, 109(2023), 464.
- 7) 日本非破壊検査協会: 磁気探傷試験II, 2018.
- 8) A. Krizhevsky, I. Sutskever and G. E. Hinton: NeurIPS, 25(2012), 1097.
- 9) W. Liu, D. Anguelov, D. Erhan, C. Szegedy and S. Reed, C.-Y. Fu and A. C. Berg: ECCV, 9905(2016), 21.
- 10) Z. Ge, S. Liu, F. Wang, Z. Li and J. Sun: YOLOX: Exceeding YOLO Series in 2021 (arXiv:2107.08430).
- 11) Q. Jiang, D. Tan, Y. Li, S. Ji, C. Cai and Q. Zheng: Applied Sciences, 10(2020), 87.

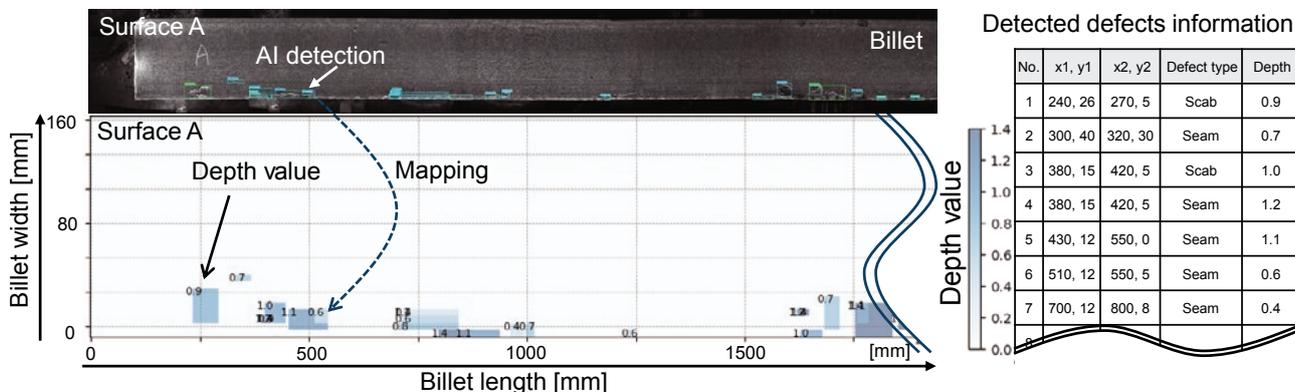


Fig. 15. Defect map (Types of defects listed in the table on the right).

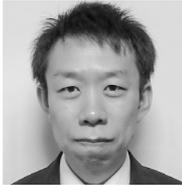
- 12) S. Ren, K. He, R. Girshick and J. Sun: NeurIPS, 28 (2015), 91.
- 13) 森大輔, 湯藤隆夫, 岡本有史: 電気製鋼, 90(2019), 53.
- 14) K. He, X. Zhang, S. Ren and J. Sun: CVPR 1(2016), 770.
- 15) N. J. Shipway, P. Huthwaite, M. J. S. Lowe and T. J. Barden: NDE&E International, 119(2021), 102400.
- 16) 大同特殊鋼(株): 特許第 7618963号(2025).



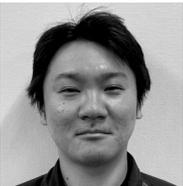
山腰浩平



湯藤隆夫



森 大輔



有澤 亮



大迫昭司



宇佐美徹