

技術資料

Technical Data

磨き丸棒鋼の外観検査技術

森 大輔*¹, 湯藤隆夫*², 岡本有史*³

Appearance Inspection Technology for Cold Finished Round Steel Bars

Daisuke MORI, Takao YUTO and Yuji OKAMOTO

Synopsis

Automatic appearance inspection technology for cold finished round steel bars has been developed. Stainless steel is used in important parts in automobiles, bearings and industrial machines. Such parts are used in harsh environments requiring high heat conductivity and mechanical strength, and high resistance to heat and corrosion. It is important to have bright round stainless steel bars for this, so strict surface inspection precision is required. Until now, surface defects were detected by eddy current nondestructive testing; however in that method, the detection repeatability is unstable and the setup is complicated. So, we developed an image processing method for surface inspection of bright round bars by a line scan camera, two types of lighting and AI technology. This has enabled inspection with high speed and resolution, simple setup change, and accurate judgement. This paper describes the following development results of the image processing method for surface inspection:

- (1) Optimization of the image processing method and signal processing.
- (2) Solution to problems inherent in round bar steel shape.
- (3) Overmark reduction by deep learning, a form of machine learning.

From these results, this development achieved the following performance: "Detect various surface defects by image processing", "Correct measurement of surface defects even in the round bar shape", and "Expected 21% drop in overmark by applying deep learning".

1. 緒言

ステンレス鋼は耐食性、高強度、温度特性などさまざまな特徴を有している。そのため、特定の分野に偏らず、多種多様に用いられており、特に、自動車、軸受、産業機械などの重要部品に広く用いられる¹⁾。これら重要部品に用いられることから、品質要求は厳しく、特に精整プロセス（矯正・検査・表示・結束など）技術は、

製品の信頼性向上のため、重要な役割を担っている。その中でも検査プロセスは、製品の性能や寿命を保証するための重要工程である。一般にステンレス丸棒鋼の検査工程は、客先要求によって、表面に生成する酸化スケールを除去するため、ピーリング加工、センタレスグラインダ加工、酸洗などをおこなう。これにより、表面は銀色の輝きをもつ磨き丸棒鋼となる。その後、曲がり矯正をおこない、検査が実施される。検査項目としては、き

2019年5月8日 受付

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

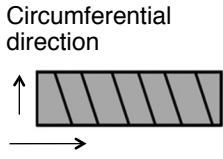
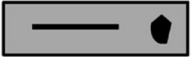
* 2 大同特殊鋼(株)技術開発研究所 (Corporate Research & Development Center, Daido Steel Co., Ltd.)

* 3 大同特殊鋼(株)星崎工場 (Hoshizaki Plant, Daido Steel Co., Ltd.)

ず（表面、内部）、寸法（測長、直径）、曲がり、端面形状、表面肌が挙げられる²⁾。これらの検査は、一貫ラインの中で自動検査がおこなわれる。きず検査については非破壊検査³⁾が用いられ、寸法・曲がりの計測はレーザや画像処理法が用いられることが多い。本稿では、磨き丸棒鋼表面きずの検査方法を対象とする。

ここで、表面きずの主な発生要因について述べる。ピーリング加工は、熱処理後の表面酸化スケールを除去するため、丸棒鋼が製造ラインを直進しながら、切削工具が円周方向に回転することで、りんごの皮をむくように切削加工する。これにより、光沢表面をもつ磨き丸棒鋼が仕上がる。しかしながら、ピーリング加工は、安価で高速に加工ができる反面、切削工具の刃先の状態や配置・材料の曲がりによって、表面きずが発生する。その表面きずの一例を Table 1 に示す。

Table. 1 Examples of surface defect by peeling process.

Defect type	Spiral surface defect by single-point cutting tool	Liner scratch and black scale residue Remainder of the black skin
Image	Circumferential direction  Longitudinal direction	
Size	Width and depth is 0.1 mm.	Length is about 5 mm.

これら磨き丸棒鋼の表面きずを、自動で高速に検査する手法としては、漏洩磁束探傷法、渦電流探傷法に加え、表面きずをカメラで撮像することで、きずを判定する画像処理法が挙げられる⁴⁾。ただし、一貫ラインの中で生産性を維持しながら、表面きずを検出する必要がある。

そこで本稿では、画像処理法を用いた表面きず検査手法について、下記3点の検討結果を述べる。

- (1) 画像処理の撮像方法の最適化
- (2) 丸棒鋼形状固有の問題点とその解決方法
- (3) 機械学習(Deep Learning)による判定精度向上の検討

2. 表面きず検査手法

2. 1 非破壊検査方法

前述の通り、磨き丸棒鋼の表面きず検査手法として、漏洩磁束探傷法、渦電流探傷法、画像処理法が挙げら

れる。この中で、漏洩磁束探傷は、磁化を伴う検査であるため、強磁性体にしか適用できない。今回は、ステンレス丸棒鋼の中でも、非磁性であるオーステナイト系を検査対象に含むため適用外となる。そこで、導体であれば検査可能な渦電流探傷法が、ステンレス丸棒鋼の表面きず検査に広く適用されている⁵⁾。この渦電流探傷法は、コイルによって励起された磁束により、表面に渦電流を発生させる。表面にきずがあれば、渦電流は流れにくくなり乱れる。この時の磁束の変化をきず信号として検出する⁶⁾。Fig. 1 に示すように、長手方向に差動コイルを配置すれば、円周方向の螺旋状きずを検出することができる。また、自己比較方式プローブを丸棒鋼の周りを回転させることで、長手方向の線状きずを検出することができる。これらの組合せによって、各種表面きずを検出することができるが、一方で以下の問題点が挙げられる⁷⁾。

- (1) コイルの配置や回転速度によって、検出能のばらつきが起こる。
- (2) 回転機構を有するため、モータ起因の電気ノイズが発生しやすい。
- (3) コイルと丸棒鋼の間隔により渦電流の強度が変わるため、位置調整の段取りが煩雑である。




Fig. 1. Explanation of eddy current inspection method.

2. 2 画像処理法

これらの問題を解決する表面きず検査手法として、画像処理法を検討することとした^{8)~9)}。一般に、金属表面の画像処理検査システムは、(1)カメラ、(2)照明、(3)画像処理部により構成される。

2. 2. 1 カメラ

丸棒鋼を直進搬送しながら検査する場合、円周方向にラインスキャンカメラを配置し、丸棒鋼全周の画像を輪切り状に取り込む。ラインスキャンカメラは、素子が1列に並んでいるタイプで、素子数が少なく、高速に画像を取得することができる。本事例では、円周方向90度ごとに4台のラインスキャンカメラを配置することで、丸棒鋼の全周検査をおこなう。なお、ラインスキャンカメラの仕様は、丸棒鋼の距離関係や、撮像に必要な視野サイズから1×4096画素とした。そして、分解能は約37 μm/画素となるように、レンズ設計をおこなった。

2. 2. 2 照明

円周方向の螺旋状きずと、長手方向の線状きずを検出するために、2種類の照明を使用することとした。円周方向のきずには、同軸落射照明、長手方向の線状きずには、リング照明を適用した。ラインスキャンカメラと各照明の位置関係を Fig. 2 に示す。また、光源はランプ光源と比較して長寿命である白色 LED を採用した。




Fig. 2. Image-acquisition method for surface defect.

2. 2. 3 画像処理部

Fig. 2 のように、ラインスキャンカメラで連続撮像した画像を矩形状に並べる。そして、以下のステップで表面きずの良否判定をおこなうテスト環境を構築した。

- (1) 検査範囲の画像切出し
- (2) 二値化処理
- (3) ノイズ処理, 細かな検出点の除去
- (4) 角度, 長さ, 面積, 連続性など表面きず特徴量の抽出
- (5) 健全部と表面きずの輝度比較

3. 画像処理法における問題点

前述の画像処理法を検討するにあたり、丸棒鋼形状固有の問題点として、実際の表面きずよりも見かけ上、小さく撮像されてしまうことについて述べる。

3. 1 二次元投影における問題

まず Fig. 3 に示すような幅 1 mm の表面きずを加工し、カメラに対して直上位置と、30 度回転させた時の取得画像から算出した幅の値を確認した。その結果、直上位置の場合は、1 mm となったが、30 度回転した時は、0.8 mm と実際より小さい値を示した。これは、曲率を持つ丸棒鋼を撮像するのに対してカメラの素子は、平面状に配置しているからである。そのため、Fig. 4 に示すように、2次元に投影する際、円周方向の表面きず位置によって、見かけ上小さく撮像されてしまう。




Fig. 3. Size change depending on circumferential position of surface defect.

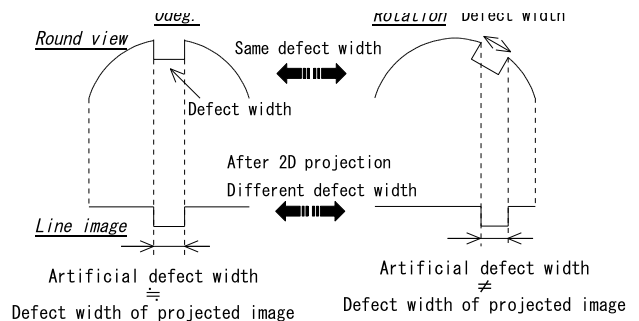


Fig. 4. Explanation of why defect width seems to be small.


3. 2 解決方法

その解決方法を、Fig. 5 により説明する。丸棒鋼の直径は既知である。その直径と画像の座標から、検出されたきずの丸棒鋼における円周位置を算出できる。この円周位置は角度情報に置き換えられるため、実際のきずの幅を算出することができる。


- (1) まず、既知の丸棒鋼の半径と 1 画素あたりの寸法 (mm) をメモリしておく。
- (2) 実際に得られた画像から、距離 x_1 , 2 を算出し、見かけ上の表面きず幅 w_1 を求める (①)。また、 x_1 , 2 と半径 r から、回転角度 θ_1 , 2 を算出する (②)。

- (3) 次に、曲率によって発生する表面きず高さの差 Y を算出する(③)。
- (4) 最後に、三平方の定理より、実際のきず幅 w0 を算出する(④)。


① Calculate x1 and x2 using image data.



② The angles θ1 and θ2 are calculated by known material diameters.



③ Calculate Y using the heights y1 and y2 generated by the curvature



④ Calculate w0




Fig. 5. Description of solution.

3. 3 精度検証

解決方法の精度検証として、直径 16 mm の丸棒鋼に加工した 1 mm 幅のスリットを用いたテスト結果を Fig. 6 に示す。回転角度約 30 度において、実際 1 mm の表面きずが見かけ上 0.814 mm となってしまう。前述の解決方法を適用したところ、表面きずの幅は 0.965 mm となり、実際の表面きず幅 1 mm に対して、誤差は -0.035 mm と良化し、有効性を確認した。

$$\begin{aligned}
 x1 &= 105 \text{ pixels} \times 0.037 \text{ mm/pixels} = 3.885 \text{ mm} \\
 x2 &= 127 \text{ pixels} \times 0.037 \text{ mm/pixels} = 4.699 \text{ mm} \\
 \theta 1 &= \cos^{-1}(x1/r) = 60.95^\circ \\
 \theta 2 &= \cos^{-1}(x2/r) = 54.03^\circ \\
 Y &= 8 \times (\sin 60.95^\circ - \sin 54.03^\circ) = 0.519 \text{ mm} \\
 w0 &= \sqrt{(w1)^2 + (Y)^2} = \mathbf{0.965 \text{ mm}}
 \end{aligned}$$

Fig. 6. Result of accuracy verification.

4. 機械学習適用の検討

前述の画像処理方法により、表面きずを 100% 検出できる閾値において、過剰検出率（表面きず無しを有りと過剰に判定する割合）の評価を実施した。その結果、螺旋状の表面きずの過剰検出率は、約 27% であった。過剰検出となった画像を確認したところ、無害レベル（深さ数十 μm）の浅い加工跡を、有害レベル（深さ 100 μm 程度）の表面きず有りと判定していた。従来の画像処理法では、表面きずの幅は評価できても、深さの評価は難しい。また、過剰検出が多くなると、実際の生産ラインに適用した時に、リードタイムや歩留まりに大きく影響することが懸念される。

4. 1 機械学習について

近年、AI（Artificial Intelligence：人工知能）の第3次ブームの最中にあり、人間が与えたデータをもとに、コンピュータが学習、つまり、データに潜むルールやパターンなどの特徴量を抽出し、処理することができるようになってきた。その機械学習の1つである Deep Learning は、人間の脳を模した数理モデルであるニューラルネットワークが複数層あるモデルにより、与えられた画像データを認識し、人が思いつかないパターンを見つけ出すことができることから、汎用性が高く注目されている¹⁰⁾。現在は、この Deep Learning を複雑な鉄鋼生産プロセスへ適用するための検討が広く進められている¹¹⁾。

Fig. 7 に Deep Learning 手法の1つである畳み込みニューラルネットワーク（CNN：Convolutional Neural Network）の概念図を示す¹⁰⁾。CNN は、中間層に畳み込み層とプーリング層を有しており、この2種類の層で、データの特徴量を自動で抽出することに着目した手法である¹²⁾。鉄鋼業においては、鋼の組織評価や錆びの検出、ラベルの文字認識などの報告がされている^{13)~16)}。

また、画像を用いた表面きず検査への適用検討も進められているが、きずの有無を判定する内容が多い^{17)~18)}。しかし、本件のように2次元の画像から「無害レベルの浅い表面きず（過剰検出）」と「有害レベルの深い表面きず」の弁別を目的とした事例は少ない。そこで、丸棒鋼表面きずの過剰検出低減を目的とした、Deep Learning 技術の適用可否を検討した。

4. 2 Deep Learningの検討

前述の通り、Deep Learning を適用するにあたっては、CNN という手法を採用した。採用の根拠としては、畳

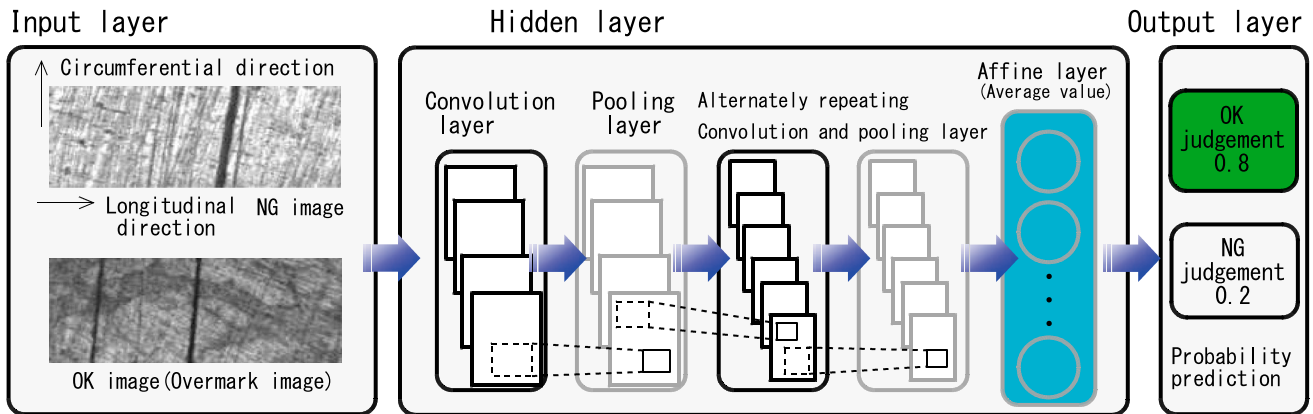


Fig. 7. Conceptual diagram of CNN.

み込み層にて、2次元画像データのフィルタ処理を施すことで、表面きずの特徴量を抽出できる。さらに、プーリング層にて、きずの特徴量を残しつつ、コンパクトに表現できるため、表面きずの発生位置の変動に強い点が挙げられる。これらの概念図を Fig. 8 に示す。

Deep Learning による評価にあたり、Table 2 の開発ツールにより実行した。

Table 2. Test development environment.

Operation system	Windows 10
Programming language	Python 3.5.2 TensorFlow 1.2.1
Preprocessing	Opencv 3.1.0.1

4. 2. 1 前処理(リサイズ)

まず最初に、画像データを Deep Learning によって学習および判定おこなうため、画像サイズを画一化した。

その理由は、材料の直径が変わることで、カメラと丸棒鋼のワークディスタンスが変化するため、1画素あたりの分解能が変化する。そのため、画像は線形補間で伸縮し 200 × 80 pixel に揃えた。

4. 2. 2 表面硬さによる分類

同じ照明の強度で丸棒鋼の表面を撮像しても、丸棒鋼の表面硬さによって、画像の明るさが変わる。これは、鋼種による表面硬さの違いによって、同じ切削工具で加工しても、表面の粗さが異なるためで、丸棒鋼の表面に照射された光は、粗さの違いによって散乱が変化するので、その結果、画像に明暗の違いが起こる。ここで、Fig. 9 に横軸をロックウェル硬さ (HRB)、縦軸に画像の相対的な平均背景輝度をプロットしたグラフを示す。硬さと輝度に関係性があることが分かり、Table 3 のように3グループに分類することとした。

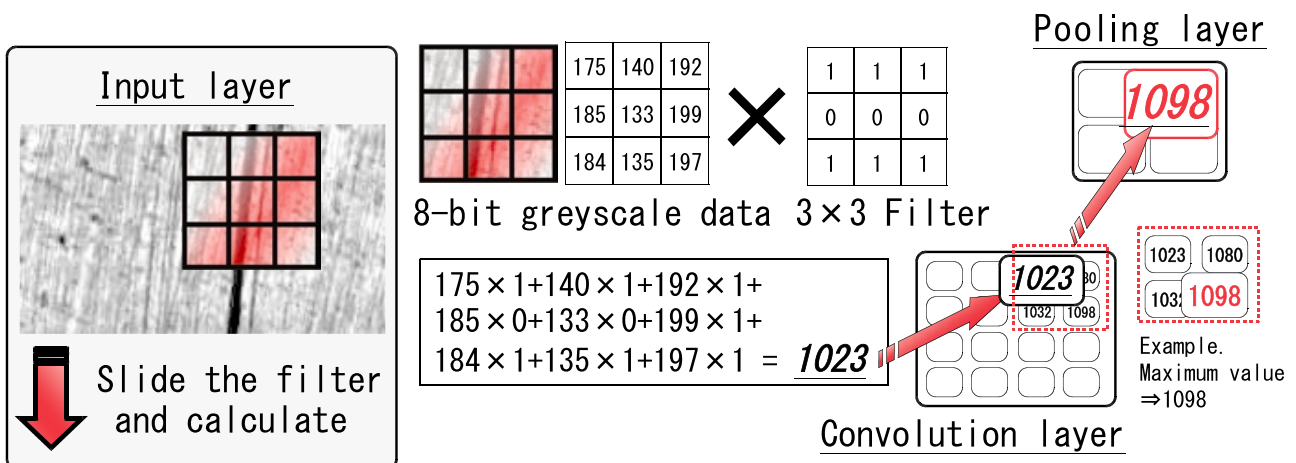


Fig. 8. Description of the filtering and pooling layer.

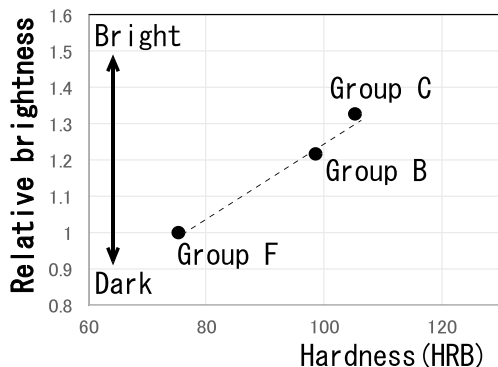


Fig. 9. Relationship between hardness and relative brightness.

Table 3. Grouping of stainless steel types.

Class	Hardness	Brightness	Steel type
Group C	Hard	Bright	Ni-stainless (Austenitic), etc.
Group B	Middle	Middle	Cr-stainless (Martensite), etc.
Group F	Soft	Dark	Electro magnetic stainless, etc.

4. 2. 3 Deep Learningモデル

Deep Learning を実行するにあたり、学習とテストに用いる画像枚数を、Table 4 に示す。学習モデルの生成は、あらかじめ表面きず画像が無害であるか有害であるかを Deep Learning に教示し学習させる。その教示画像により、判定誤差が最も小さくなるように学習モデルを生成した。そして、学習用とは別に除けておいたテスト画像を使って、有害と無害の表面きず判定精度を検証した。

本論では、Deep Learning モデル生成の詳細については割愛する。巻末の文献^{10), 12), 19)}を参考にさせていただきたい。

その他の Deep Learning に必要な各種設定パラメータは、Table 5 に示す数値を採用した。これらは、学習に用いる画像の枚数、判定画像の画素数、検出したいきずのサイズなどを考慮して決定した。Table 5 のパラメータを固定値として、機械学習アルゴリズムの挙動を制御する一部のハイパーパラメータ (drop out, learning rate, batch and hidden layer) と呼ばれる条件を変えながら 20 回試行した。

5. Deep Learningによる評価

5. 1 評価方法

Deep Learning の評価として、各 20 回試行して得ら

Table 4. Number of images used for Deep Learning.

Image type		Number of images		
		Group C	Group B	Group F
NG Spiral defect	Training	958	866	20
	Test	958	866	20
OK Overmark	Training	714	452	7182
	Test	13849	20895	39634

Table 5. Parameter used for Deep Learning (CNN).

Item	Parameters		
	Group C	Group B	Group F
Layers	3	4	
Matrix filter	10, 20, 40	10, 20, 40, 60	
Pooling size	3, 3, 3	3, 3, 3, 3	
Pooling stride	2, 2, 2	2, 2, 2, 2	

れた学習モデルを使ってテスト画像の判定精度を評価した。学習モデルの選定基準は、NG (有害な表面きず) 画像の判定精度が高くなるものと決めた。その理由は、NG 品が製品特性上の問題になることから、NG 品を OK と誤判定することは避けなければならないからである。NG 品を正しく NG と判定する条件下で、本来の OK 品 (無害の表面きず) を、NG と判定 (過剰検出) する割合を評価する。

5. 2 評価結果

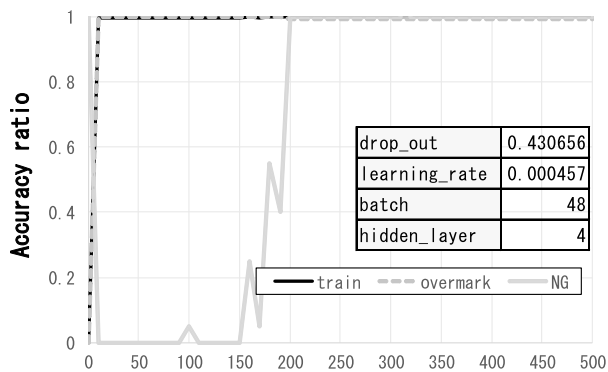
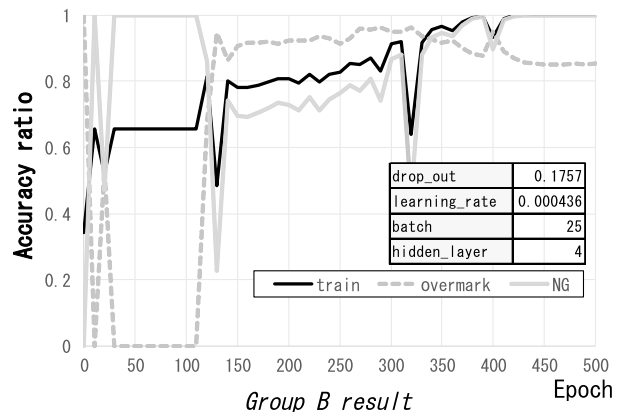
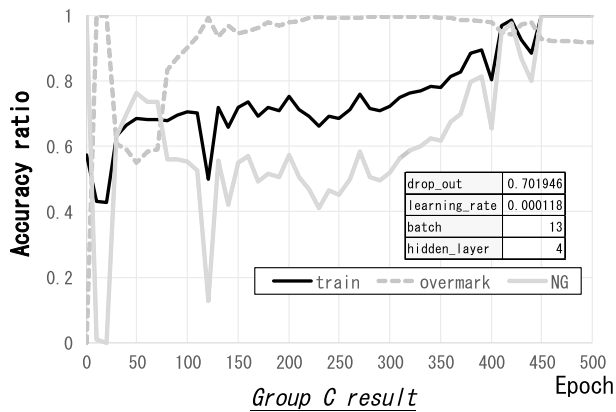
Deep Learning による表面きずの判別精度として、学習回数に対する、学習、テスト画像の正解率を Fig. 10 に示す。その結果、おのおのの過剰検出率 (OK を NG と判定する割合) は、C 分類で 8.3 %, B 分類で 14.7 %, F 分類で 0.7 % となり、3 種類の平均では約 6 % となった。

従来の画像処理法の過剰検出率と比較し、21 % 低減した。この結果より、画像処理を用いた表面きず判定に対する Deep Learning (CNN 法) の有効性を確認した。

6. まとめ

本稿では、ラインスキャンカメラと LED 照明を組み合わせた画像処理法を用いて、高速に磨き丸棒鋼の表面きずを検出するための手法について紹介した。

- (1) 磨き丸棒鋼の表面きず検査方法として、ラインスキャンカメラと LED 照明を用いた撮像方法と画像処理方法を紹介した。



Evaluation item	Accuracy results(%)		
	Group C	Group B	Group F
Train	100	100	100
OK+NG images	100	100	100
Test image OK(overmark)	91.7	85.3	99.3
Test image NG(defect)	100	100	100

Fig. 10. Evaluation results by Deep Learning of spiral surface defect judgement.

- (2) 丸棒鋼形状固有の問題点として、二次元投影による課題の解決方法を提案した。これにより、表面きず幅のサイジング精度が向上した。
- (3) 機械学習の1つである Deep Learning (CNN法) を用いた過剰検出低減方法を提案し、従来の画像処理法と比較して 21% の過剰検出低減見込みを得た。

(文 献)

- 1) 菊池正夫: 電気製鋼, 86(2015), 37.
- 2) 石田二郎: 電気製鋼, 60(1989), 66.
- 3) 松實敏幸: 鉄と鋼, 79(1993), 823.
- 4) 山田龍三, 木村良久, 片桐和雄, 古瀬奏輔, 奈良光洋: 電気製鋼, 80(2009), 65.
- 5) 吉川仁: 特殊鋼, 65(2016), 20.
- 6) 星川洋: IEEJ Journal, 124(2004), 106.
- 7) 渡邊裕之, 山田外史, 伊藤光宏: 電気製鋼, 79(2008), 271.
- 8) 釜三夫: 鉄と鋼, 70(1984), 10, 1326.
- 9) 新田雅康: 電気製鋼, 79(2008), 299.
- 10) 足立悠: 初めての TensorFlow, リックテレコム, 2017.
- 11) 中川繁政, 吉沢一郎: ふえらむ, 23(2018), 713.
- 12) 久保田進也: 三次元工学シンポジウム, 28(2018).

- 13) 足立吉隆, 田口茂樹, 弘川奨悟: 鉄と鋼, 102(2016), 722.
- 14) 河村圭, 荒瀬陽平, 後藤悟史, 宮本文穂: Fuzzy System Symposium, 24(2008), TB4-1.
- 15) Gyogwon KOO, Jong Pil YUN, Sang Jun LEE, Hyeeyeon CHOI and Sang Woo KIM: ISIJ International, 59(2019), 98.
- 16) Sang Jun LEE, Wookyong KWON, Gyogwon KOO, Hyeeyeon CHOI and Sang Woo KIM: ISIJ International, 158(2018), 696.
- 17) Xian Tao, Dapeng Zhang, Wenzhi Ma, Xilong Liu and De Xu: Appl. Sci., 8(2018), 1575.
- 18) Shiyang Zhou, Youping Chen, Dailin Zhang, Jingming Xie and Yunfei Zhou: Materials and technology, 51(2017), 123.
- 19) 斎藤康毅: ゼロから作る Deep Learning, オライリージャパン, 2016.



森 大輔

湯藤隆夫

岡本有史