研究論文

AIを用いた1液潤滑剤塗布検出装置の開発

菅家　章*　阿部　淑人*　高橋　靖**　木嶋　祐太**　土田　真伯***　村山　一成***　諏佐　大夢***

Development of AI Detection System for Single Liquid Lubricant Application

KANKE Akira*, ABE Yoshito*, TAKAHASHI Yasushi**, KIJIMA Yuta**,
TSUCHIDA Masanori***, MURAYAMA Kazunari*** and SUSA Hiromu***

抄　録

冷間鍛造前のワークへ1液潤滑剤を塗り，それが適正に塗られたかどうかを検査する必要がある。1液潤滑剤の塗布量の違うワークをモノクロカメラと偏光カメラで撮影し，その画像を AI（Artificial Intelligence）に学習させて，ワークへ1液潤滑剤が適正に塗られたかどうかを検査で AI に検出させる装置を開発した。AI の判定において高い正解率が得られた。

1. 緒　言

自動車などの部品が製造される冷間鍛造の工程において，部品の材料になる円柱形状ワークの表面の滑りは鍛造金型の寿命に影響する。滑りをよくするため，冷間鍛造の前工程で従来はボンデ処理でワークに金属石けん皮膜を付けていたが，マコー（株）はワークに 1 液潤滑剤を塗布する装置として WLS（Wetblast Lubricant System：ウェットブラスト・1 液潤滑剤塗布装置）を製造販売している。WLS を用いた処理は，一般的なボンデ処理と比べて設置面積が 1/10，水の使用量が 1/30，産業廃棄物の排出が 1/20 などの利点があるため，SDGs（Sustainable Development Goals）に取り組む企業から注目されている。WLS の内部では，ウェットブラストによるスケール除去，湯洗，1 液潤滑剤塗布，乾燥が行われ，ワーク検査で，正常品と不良品に選別される。

従来はセンサで検出できる 1 液潤滑剤を使用して検査を自動化していたが，センサで検出できない 1 液潤滑剤も使用できるよう，画像処理による検査の検討を始めた。1 液潤滑剤なしとありのワークの写真を図 1 に示す。1 液潤滑剤なしとありを比較したところ，ワーク表面の色の違いはわずかで，1 液潤滑剤なしはワーク表面に湯洗ムラが，1 液潤滑剤ありは塗布ムラがみられた。この場合の画像処理プログラムや判定プログラムは難しくなることが予想できた。

そこで本研究では AI を用いた 1 液潤滑剤塗布検出装置の開発を試みた。1 液潤滑剤塗布量（0，1，5，10，20g/m^2）を変えたワークの画像をカメラで撮影し，AIに学習させ，ワーク検査でAIが塗布量を判定し，正常品（5，10g/m^2）と不良品（0，1，20g/m^2）を判別する装置を開発した。

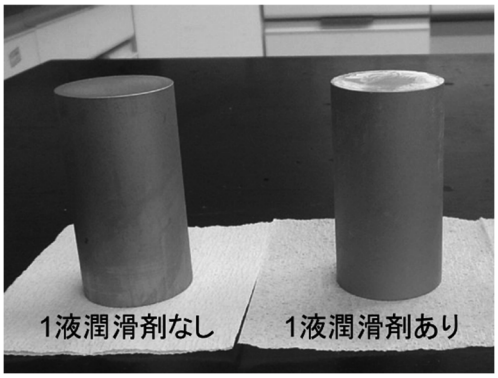

図1　1液潤滑剤なしとありのワークの写真

*　研究開発センター
**　下越技術支援センター
***　マコー（株）

2.　検出装置の開発

2.1　開発方法

AIの学習と判定には1液潤滑剤塗布量0，1，5，10，20g/m^{2}で各々特徴のみられる画像を撮影する必要がある。塗布量，ワークの大きさなど，条件を変えて撮影した画像を比較しながら，検出装置の構成を検討した。

本研究でワークはS45Cの大ワーク（φ45 mm×L85mm）と小ワーク（φ25mm×L25mm）を使用し，1液潤滑剤はWLSの納品先でよく使われるものを使用した。カメラはモノクロカメラの構成と偏光カメラの構成を検討した。

2.2　カメラ・レンズ・照明について

2.2.1　モノクロカメラの構成

WLSの内部では，スケール除去，湯洗，1液潤滑剤塗布，乾燥の処理が施される。ワークはワーク搬送駆動装置で押されて各処理を搬送され，回転ローラ上で回転しながら処理される。ここで，搬送中に回転ローラとワークが擦れてワークに付けられた傷が，スケール除去後と1液潤滑剤塗布後で異なることに気がつき，それを特徴として利用できる撮影条件を調べたところ，塗布量が増えるにつれて傷はみえにくくなり，ワーク表面の塗布ムラは増えることがわかった。そこでレンズは，傷と塗布ムラが撮影できるよう，マクロズームレンズを使用した。照明は，LED照明を反射板で反射させた拡散照明を使用した。

2.2.2　偏光カメラの構成

ワークに塗布された1液潤滑剤塗布量の違いや塗布ムラは，偏光カメラで撮影したDOLP（Degree of Linear Polarization）画像の明暗で観察できた。そこでレンズは，1pixelごとに0°，45°，90°，135°の偏光フィルタが構成されている偏光カメラの仕様を考慮し，高解像度レンズを使用した。照明は，LED照明に偏光シートを付け，光を1方向へ偏光させた偏光照明を使用した。

2.3　検出装置の構成について

検出装置は，AI装置，制御盤，ワーク搬送駆動装置，カメラスタンドなどで構成される。AI装置は，学習用の画像撮影，AIの学習，AIによる1液潤滑剤塗布量の判定，ワークの正常品と不良品の判別で使用した。制御盤のPLC(Programmable Logic Controller)では，ワークの搬送タイミングなど，ワーク搬送駆動装置の動作を制御した。AI装置とPLCはI/Oボードで接続し，動作タイミングを伝えた。カメラスタンドの部分で，モノクロカメラの構成（図2）と偏光カメラの構成（図3）を変更した。

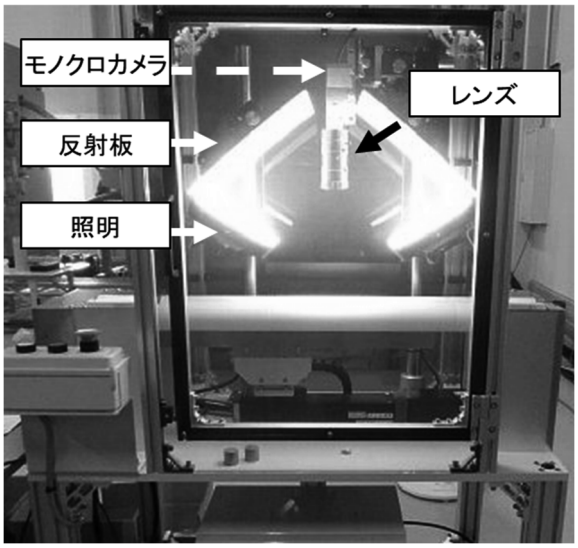

図2　モノクロカメラの構成

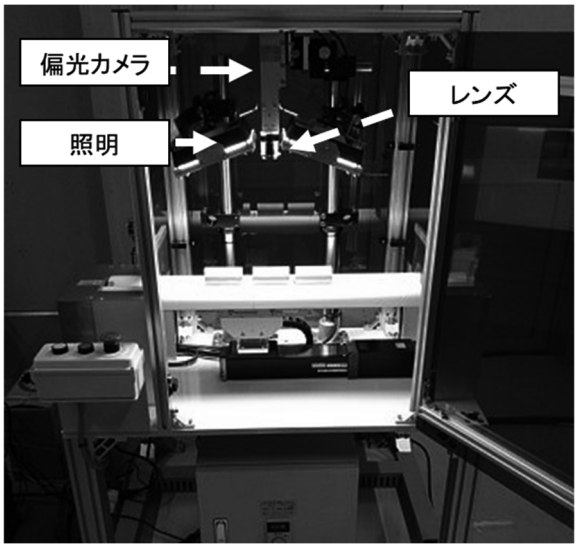

図3　偏光カメラの構成

2.4 AI 装置のソフトウェアについて

2.4.1 AI 学習用の画像撮影ソフトウェア

AI の学習で使われる画像を撮影するソフトウェアを試作した。AI 装置でこのソフトウェアを動作させると，AI装置はPLCの撮影信号を受け，設定されたディレイ時間後，設定されたサイズの画像を，設定された枚数だけ撮影し，画像を保存する。AI 装置の画面で，ディレイ時間，ワーク番号，ワークサイズ，照明の明るさ，塗布量などの情報を設定でき，設定された情報と画像のファイル名を情報管理用データベースへ画像ごとに登録できる。AI 装置画面には，撮影中の画像や保存された画像を表示できる。

2.4.2 AI 学習用ソフトウェア

AI に画像を学習させるため，学習用ソフトウェアを試作した。プログラムは，「データセット用ファイルの作成」，「データの読み込み」，「データセットクラスの作成」，「データローダの作成」，「データの表示」，「学習モデルの定義」，「学習に関する損失関数などの設定」，「学習用関数の定義」，「学習の実行」，「テスト用関数の定義」，「テストの実行」を試作した。プログラムを順番に実行することでAI の学習とテストができる。

2.4.3 検出装置搭載用ソフトウェア

ワークの検査において，1 液潤滑剤の塗布量をAIで判定し，ワークの正常品と不良品を判別するソフトウェアを試作した。AI 装置でこのソフトウェアを動作させると，AI装置はPLC撮影信号を受け，設定されたディレイ時間後，設定されたサイズの画像を，設定された枚数だけ撮影する。撮影された画像すべてをAIで判定し，正常品と不良品を判別する。AI 装置画面には，撮影中のワークの画像上に，OK（正常品）とNG（不良品）の判別結果を表示できる。

3. 使用した画像について

3.1 学習用・検証用・テスト用画像について

AI は学習用の画像を用いて学習し，検証用の画像を用いて損失が最も小さくなるネットワークモデルに対して，テスト用の画像を用いて評価する。画像は 60%を学習用，20%を検証用，20%をテスト用の 3 グループにランダムで振り分けた。同じワーク番号の画像は同じグループで使用した。

3.2 各カメラの画像について

3.2.1 モノクロカメラの画像について

モノクロカメラでは，大ワークと小ワークで撮影視野サイズを同じにするため，小ワークの輪郭より小さい 15×12.6mm で撮影した。画像の解像度は 1440×1080pixel である。ワークが回転ローラ上で回転している円周方向と，ワーク送りで押されて搬送されている軸方向の両方向へ動いている間，大ワークは 8 枚，小ワークは 2 枚の画像を連続撮影した。

照明の明るさについて，学習用はレベル 1（暗い）とレベル 2（明るい）の画像を使用し，検証用とテスト用はレベル 2 の画像を使用した。

以上の条件で，大ワークは，塗布量 0，1，5，10，20g/m^{2}を合計 5448 枚撮影し，小ワークは，塗布量 0，1，5，20g/m^{2}を合計 2140 枚撮影した。撮影した大ワークの画像の例を図 4 に示す。

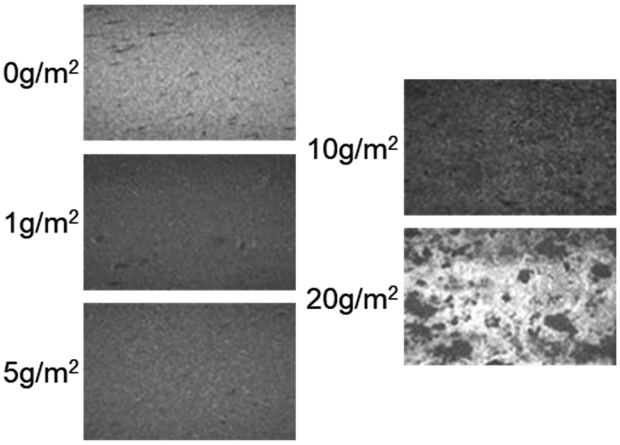

図 4 画像の例（モノクロカメラ）

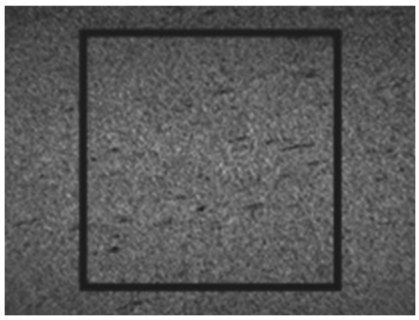

図 5　トリミングの位置（モノクロカメラ）

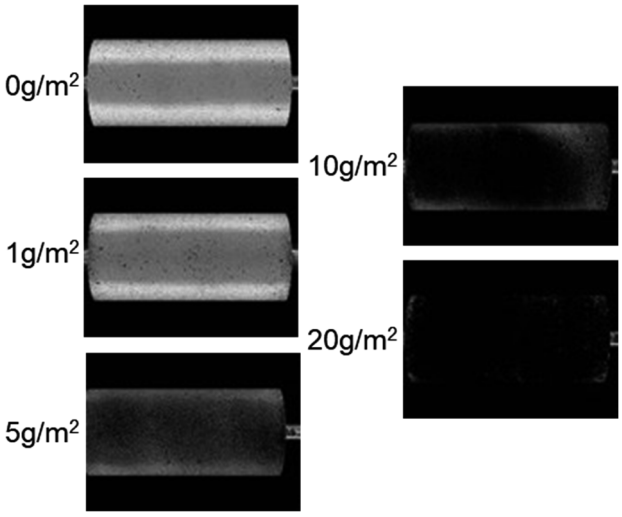

図 6　画像の例（偏光カメラ）

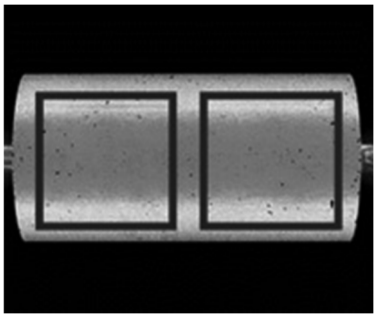

図 7　トリミングの位置（偏光カメラ）

撮影した画像は中央の 896×896pixel の範囲をトリミングした。トリミングの位置を図 5 に示す。4.2.1 に記載するファインチューニングでは，学習済みネットワークモデルを使用するが，この学習済みネットワークモデルを学習するときに使用された画像サイズは 224×224pixel なので，画像を 224×224pixel へリサイズした。データ拡張として，10%のランダムスケーリング，ランダムフリップ（水平・垂直），360°のランダム回転を施した。

3.2.2　偏光カメラの画像について

偏光カメラでは，大ワークのみ撮影した。本研究中に得られた経験から，撮影視野サイズは，大ワークの輪郭より大きい 90×75mm で撮影した。画像の解像度は 1224×1024pixel である。ワークが回転ローラ上で円周方向へ動いている間，学習用は 16 枚，検査用は 4 枚，テスト用は 16 枚の画像を連続撮影した。

照明の明るさは，レベル 1(暗い）とレベル 2（明るい）の画像を使用した。

以上の条件で，塗布量 0，1，5，10，20g/m^2 を合計 4256 枚撮影した。撮影した画像の例を図 6 に示す。

撮影した画像は大ワーク上の 460×460pixel の範囲を重なりがないように 2 箇所トリミングし，224×224pixel へリサイズした。トリミングの位置を図 7 に示す。データ拡張として，10%のランダムスケーリング，ランダムフリップ（水平・垂直），10°のランダム回転を施した。

4.　AI 作成・学習・評価

4.1　AI 作成・学習・評価について

5 値分類，2 値分類，回帰の AI を作成し，データ拡張したデータを用いて学習させて，テスト用画像を用いて評価した。

4.2　5 値分類・2 値分類・回帰について

4.2.1　5 値分類

5 値分類は，「入力した画像が，5 分類の塗布量 0，1，5，10，20g/m^2 のうち，どれである確率が高いか」を出力した。

AI はディープニューラルネットワークの ResNet101 をベースに使用し，ファインチューニングした。ResNet101 は画像を 1000 分類する

ネットワークモデルであるが，今回必要な分類は 5 分類である。そこでネットワークモデルの最終層サイズを 1000 から 100 へ変更し，さらに 100 から 5 への全結合層を追加した。損失関数はクロスエントロピーロスを使用した。ネットワークモデルの出力はソフトマックス処理を用いて確率分布へ変換した。最適化手法は SGD（Stochastic Gradient Descent）を用いた。学習率は 0.001 を超えないようにした。エポック数は 100 にした。

5 値分類は，画像のリサイズが 224×224pixel と 448×448pixel の場合について，正解率を比較した（表 1）。カメラは偏光カメラの正解率が高く，画像のリサイズは 448×448pixel の正解率が高かった。ここで 896×896pixel のトリミング画像を用いて 5 値分類を試みたところ，正解率は 97.7%であり，448×448pixel の結果より悪かった。

4.2.2 2 値分類

2 値分類は，「入力した画像が正常品と不良品のどちらの確率が高いか」を出力した。

5 値分類のネットワークモデルと異なる点として，100 から 2 への全結合層を追加した。

モノクロカメラの正解率は 99.3%，偏光カメラの正解率は 100%であった（表 2）。真陽性率（True Positive Rate）と偽陽性率（False Positive Rate）をプロットした ROC（Receiver Operating Characteristic）カーブの結果を，モノクロカメラは図 8 に，偏光カメラは図 9 に示す。偏光カメラの AUROC（Area Under ROC）は 1 であり，正常品と不良品は完全に判別できた。

4.2.3 回帰

回帰は，ワークの画像を入力すると 1 液潤滑剤の塗布量の推定値が出力される。

5 値分類のネットワークモデルと異なる点として，100 から 1 への全結合層を追加した。損失関数は 2 乗誤差を使用した。塗布量 0g/m^2 と 1g/m^2 の差が 1 に対し，10g/m^2 と 20g/m^2 の差は 10 であり，10 倍異なることから，塗布量は自然対数の値を使用し，0g/m^2 は 0.1 を使用した。

AI から出力された推定値の平均値，標準偏差，最小値，最大値の結果について，モノクロカメラは表 3 に，偏光カメラは表 4 に示す。偏光カメラのほうが標準偏差は小さく，両カメラとも，塗布量 5，10，20g/m^2 の判定は範囲の重なりがあり，難しい傾向がみられた。

表 1　5 値分類の正解率

	画像サイズ(pixel)	正解率(%)
モノクロカメラ	224×224	97.1
	448×448	98.8
偏光カメラ	224×224	98.8
	448×448	99.6

表 2　2 値分類の正解率

	画像サイズ(pixel)	正解率(%)
モノクロカメラ	224×224	99.3
偏光カメラ	224×224	100

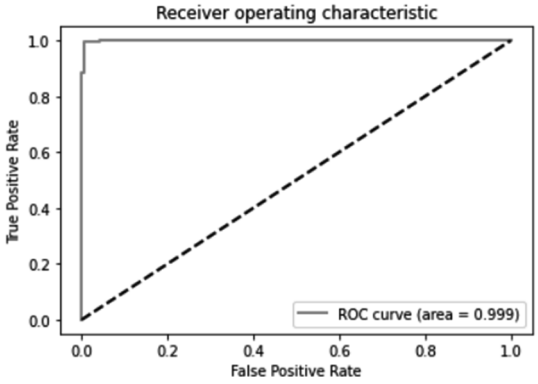

図 8　ROC カーブ（モノクロカメラ）

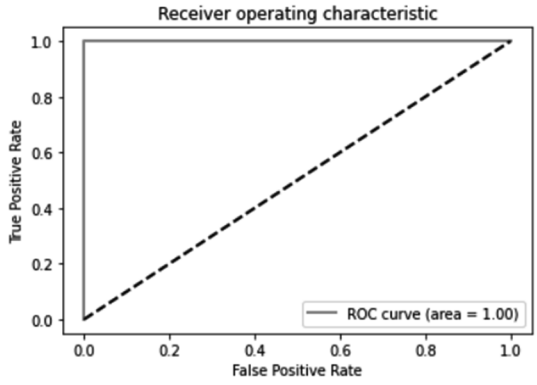

図 9　ROC カーブ（偏光カメラ）

表 3　回帰の結果（モノクロカメラ）

塗布量(g/m^2)	平均値	標準偏差	最小値	最大値
0　[0.1]	0.10	0.02	0.07	0.15
1	1.03	0.28	0.14	2.22
5	6.01	1.59	1.46	12.0
10	10.2	1.97	2.05	16.3
20	21.4	5.60	1.17	33.1

画像サイズは224×224pixel

表 4　回帰の結果（偏光カメラ）

塗布量(g/m^2)	平均	標準偏差	最小値	最大値
0　[0.1]	0.10	0.01	0.08	0.15
1	0.96	0.10	0.52	1.26
5	5.24	0.68	3.61	7.72
10	9.40	1.73	5.96	15.5
20	19.0	2.02	13.7	28.2

画像サイズは224×224pixel

5.　検出装置でのテスト

偏光カメラの検出装置を用いて，ワークの検査を試みた。判別結果は OK（正常品）と NG（不良品）をAI装置の画面へ表示した。回転しているワークの画像 4 枚を連続撮影し，各画像を 5 値分類した結果について，塗布量 0，1，20g/m^{2}をNG判定，塗布量5，10g/m^{2}をOK判定にした。NG判定された画像が1枚でもあった場合，そのワークは不良品としてAI装置の画面へNGを表示した。4枚の判定結果がすべてOK判定だった場合，正常品として AI 装置の画面へOKを表示した。塗布量0，1，5，10，20g/m^{2}のワークを各10個ずつ検査したところ，正常品と不良品を完全に判別できた。

1枚でもNG判定があれば不良品にする方法は厳しい判別方法なので，検査数を増やしたときに貴重な正常品を不良品へ判別する可能性が考えられる。そこで，撮影した画像のうち半数以上が NG 判定だった場合を不良品にするなどの改善を検討している。偏光カメラの正解率はモノクロカメラより高かったが，モノクロカメラより偏光カメラは高価であるため，判別方法の改善によっては安価なモノクロカメラを選択できる。今後，共同研究で実施した研究成果をもとに，製品化へ向けた研究開発を継続する。

6.　結　　言

(1) 塗布量の特徴が撮影できるモノクロカメラと偏光カメラのレンズと照明を選定した。
(2) ワークを回転させながら連続撮影し，AI で OK/NG 判定が可能な検出装置を開発した。
(3) 各カメラを用い，AI で使用する学習用・検証用・テスト用の画像を数千枚撮影した。
(4) 5値分類，2値分類，回帰のAIを作成し，学習・評価した。5値分類と 2 値分類において，97%以上の高い正解率が得られた。
(5) 検出装置でのテストは，正常品と不良品の判別を試み，判別方法の改善を検討した。
(6) 今後，共同研究で実施した研究成果をもとに，製品化へ向けた研究開発を継続する。