

## 画像解析を利用した生産現場の状態監視技術に関する研究（第2報）

生産技術部

中野太郎 大坪昭文 福島章吾

本研究は、生産現場における確認・監視作業に画像解析技術を適用することで、製造工程の状態の把握や管理を自動化する技術開発に取り組むものである。本年度は、機械学習モデルの学習に必要な訓練データの構築において、AR(Augmented Reality) マーカと動画像を利用した高度な Data Augmentation（データ拡張）について検討した。その結果、AR マーカの基準座標に基づき、動画像内の任意の作業領域画像を切り出しながら、複数種類の画像処理をランダムに適用することで、訓練データの効率的なデータ拡張が可能となり、機械学習の一種である Support Vector Machine の分類性能が向上することを確認した。

### 1. はじめに

ものづくりの生産現場においては、生産設備の稼働状態や製造品の外観品質などを恒常的に確認する必要がある。また、品質管理や生産性の改善活動に活用するために、加工工程の進捗状況をより細分化して把握することが求められている。しかし、その多くを目視確認や手書き入力等に頼っているため、個人差や見落としなどが生じる問題がある。さらに、検査や確認作業に掛かるコストの大部分は人件費であり、人手不足対策としても、自動機の導入による生産効率の向上・省人化が期待されている。そこで、本研究では、生産現場における確認・監視作業に画像解析技術を適用することで、製造工程の状態の把握や管理を自動化する技術開発に取り組む。

本年度は、旋盤加工装置の工程進捗を自動監視する技術について検討した。旋盤加工の工程を4つのクラスに分けて画像判定し、加工工程の進捗をより細分化して把握することを試みる。画像の分類には機械学習の一種である Support Vector Machine(SVM)を用いた。機械学習モデルの学習に必要な訓練データの構築において、AR マーカによる位置推定技術と動画像を活用したデータ拡張手法を適用し、解析画像の分類精度に対する効果を検証する。

### 2. Data Augmentation（データ拡張）

機械学習による画像認識は、訓練データの量が予測精度に大きく影響するため、様々な環境下で撮影した多量の画像を含む学習用データセットが必要である。しかし、実際の生産現場においては、多様な環境における撮像を収集することが現実的に困難である場合が多い。そこで、既存の画像データを加工・変形し、複数の異なるデータとみなすことで疑似的に学習データの量を増やす Data Augmentation と呼

ばれるデータ拡張手法が、機械学習モデルの不変性を高める効果的な方法として広く利用されている。

画像データの Data Augmentation を行う場合、一般的には、切り出し、変形、画素値の操作、ノイズの付与のような加工を行うことが考えられる。その際、画像を変形することで、既存の画像に存在しなかった領域が生じることがあるため、パディングと呼ばれる外挿処理を行い疑似的な画像を生成する。

図1は平行移動、縮小、回転とそれに伴うパディング（ゼロ埋め）処理の例を示したものである。元画像に映っていなかった部分を輝度0の画素値で外挿しているため、不自然な画像データとなっており、使用目的によっては学習用のデータとして適当でない可能性がある。

このような問題を解消するために、本研究では、動画像と AR(Augmented Reality) マーカを用いることで、高品質な訓練用疑似画像の生成を効率的に実現する Data Augmentation を提案する。




図1: 一般的な Data Augmentation に伴うパディング（ゼロ埋め）処理

### 3. 提案手法の概要

#### 3.1 AR マーカを利用した位置推定

AR(Augmented Reality) マーカとは、単眼カメラで撮影した画像からその位置や姿勢が推定可能な平面パターン像である。AR マーカの撮像を解析することで、位置・姿勢に関する情報を、マーカ座標系からカメラ座標系に座標変換する変換行列として得ることができる<sup>1)</sup>。AR マーカによる位置推定は、カメラ1台で実施可能な簡便な計測技術であるため、検出対象に所定の AR マーカを貼り付けることで、撮像範囲内の任意の空間座標を、画像座標として取得する計測システムを低コストに構築できる。

#### 3.2 AR マーカを活用した Data Augmentation

図2に提案する Data Augmentation の概要を示す。解析対象となる加工装置の作業領域の近傍に、基準とする AR マーカを設置した状態で、加工装置の上方からビデオカメラを用いて動画を撮影する。その際、基準となる AR マーカと解析対象領域の両方が映り込むように図2の青枠で示すような広い画角で動画像を取得する。複数工程分の動画を撮影した後、動画を構成する1コマ1コマの静止画像（フレーム）から、基準マーカを原点とした任意の空間座標を抽出することで、特定の領域の画像を切り取る。さらに、切り取る画像の空間的な位置を、図2の黄色枠で示すように、ランダムに平行移動したり回転させた後に射影変換することで、幾何学的に多様なデータ拡張を、外挿処理を伴わずに自然な撮影状態で実現できる。




図2 AR マーカを利用した Data Augmentation

一般的な Data Augmentation は、カメラ等で撮影した複数の静止画に対し実施することが多い。この場合、複数の静止画を現場で撮影する労力が必要なおうえ、拡張したデータに不自然な画像が混在する可能性がある。一方、提案手法の場合、短時間の動画撮影で多量の静止画像を得ることができ、より高度なデータ拡張が実現できるという利点がある。

### 4. 作業工程のクラス定義

#### 4.1 多クラス分離問題

作業工程の多クラス分離問題を設計するために、図3に示すような工程の違いを反映した4つの作業工程クラスを定義した。各クラスの概要は以下の通りである。

- 被削材無し : 加工装置に被削材が設置されておらず、加工装置の主軸とワーク設置治具が確認できる状態。
- 加工開始 : 加工により成形される前の被削材が加工装置に設置された状態。
- 加工中 : 加工が始まり、成形によって被削材の形状が変化した状態。
- 段取り替え : 被削材の取り替えや手作業により、作業者の手や帽子が映り込んだ状態。

#### 4.2 データセットの構築

定義した作業工程クラスに基づき、機械学習モデルを訓練させるための学習用データセットと、最終的な性能評価を行う評価用データセットを構築した。

##### 4.2.1 学習用データセット

前述した提案手法により、AR マーカを基準として動画の各フレームから画像を切り出した後、学習モデルの汎化性を向上させるための輝度操作を伴うデータ拡張を行い、4クラス各220枚、合計880枚の学習用画像を抽出した。




図3 作業工程（4クラス）

表1 データセットとデータ拡張処理の内容

| 処理内容   | 学習用データセット   | 評価用データセット |
|--------|-------------|-----------|
| 上下左右移動 | ± 5cm の範囲   | ± 5cm の範囲 |
| 回転     | ± 3° の範囲    | ± 3° の範囲  |
| 色相の増減  | ± 2.5 % の範囲 | 無し        |
| 彩度の増減  | ± 20 % の範囲  | 無し        |
| 明度の増減  | ± 10 % の範囲  | 無し        |
| 画像枚数   | 880 枚       | 480 枚     |

データ拡張を実施する際に適用した画像処理内容を表1に示す。これらのデータ拡張処理を、表1に示す数値の範囲内で一様乱数を用いてランダムに実施した。

#### 4.2.2 評価用データセット

最終的な分類性能評価の信頼性を担保するために、学習データに用いていない性能評価専用のデータセットを別途用意する。評価用のデータセットは、学習用データセットに用いた類似製品の生産工程を別途動画で撮影し、分類の難易度を上げるために学習用データセットと同様の手順で構築した。ただし、評価用データセットの生成においては、輝度の変動に係わる処理は採用せず、位置や回転等の幾何学的な処理のみを適用し、4クラスの各120枚ずつの合計480枚データセットとした。適用したデータ処理の内容を表1に示す。

## 5. 画像データの前処理

### 5.1 前処理

機械学習では、特定の次元や情報に偏った学習になることを防ぐために、学習手法に合わせたデータの前処理が必要である。前処理が不適切な場合、学習が進まなかったり、学習モデルの性能が低下する等の問題が発生する。本研究では、データの前処理として以下の処理を行った。

- 画像縮小 (300x150 画素にリサイズ)
- ガウス平滑化によるノイズ除去
- RGB 画像から HSV 画像への変換
- 主成分分析による次元削減と標準化

### 5.2 色空間変換

H (色相), S (彩度), V (明度) 表色系は知覚的表色系と呼ばれ、「鮮やかさ」や「明るさ」といった人間の色彩感覚に比較的近い表色系として定義されている。H,S,V 各成分は, R (赤), G (緑), B (青) の画素値に非線形変換を施して得られるものであり, 照明条件による変動を受けにくいとされる H 成分<sup>2)</sup>や, 色の鮮やかさを示す S 成分が, 今回のタスクで

ある作業工程クラスの画像判定において, 加工物の有無やオペレータの手の映り込みなどを分類するうえで有効に機能すると考えられる。

### 5.3 主成分分析による次元削減

HSV 変換を行った画像データは 300×150 画素のカラー画像である。この画像データは, 300×150 画素の H (色相), S (彩度), V (明度) の 3 つのチャンネルで構成されている。各画素の値は 0 から 255 までのいずれかの値をとっており, このデータを H, S, V の順に繋げることで特徴量ベクトルを生成することができるが, その次数は  $300 \times 150 \times 3 = 135,000$  次元という非常に高い次数の特徴量になってしまう。

高い次数を持つデータの解析においては, 次数に応じて計算量が増大する次元の呪い<sup>3)</sup>や, 特徴量表現空間上での距離によるクラスタリングを困難にする球面集中現象<sup>3)</sup>といった問題が生じる。したがって, 一般的には, 高次元空間における特定の性質を保持したまま, 不要な情報をそぎ落とした低次元データに変換する次元削減を, クラスタリングの前に実施することが望ましい。ここでは教師なし次元削減の一般的な手法である主成分分析 (PCA) を用いて次元削減を行うことにした。

主成分分析 (PCA) は, 特徴ベクトルの集合から射影成分の分散が大きい射影軸を求め, 特徴ベクトルをその射影軸の成分で表す基底変換の一種である。互いに独立な射影軸を基底とした直交変換を行うことで, 変数間に相関のない主成分と呼ばれる合成変数を作り出すことができる<sup>4)</sup>。また, 分散の大きさが小さい主成分を無視し, 重要な情報を選択的に抽出することで, より低次元の変量によって元のデータの特性を表現することが可能となる。直交基底に基づく次元削減により, 各成分間の相関が無くなる無相関化が行われ, 相関の高い複数の特徴量が混在することで学習が不安定になる多重共線性といった問題を避けることができる<sup>5)</sup>。

## 6. 機械学習による工程分類

### 6.1 分類器の選定

機械学習を用いた分類器としては, ニューラルネットワークや決定木, SVM (Support Vector Machine) などがあげられる。SVM は入力データを高次元空間に写像し, その高次元特徴空間上に分離超平面を生成することによって, 入力空間上でのクラス識別器を生成する学習アルゴリズムである。カーネル関数を用いることで複雑な非線形分離問題に拡張することができるため汎用性が高く, 分類精度も比較的高い。

本研究では、SVM を使用して、工程画像のクラスタリングを行う。

## 6.2 実験方法

SVM の実装には Python の機械学習ライブラリである scikit-learn を用い、SVM のカーネルとして非線形 Radial Basis Function (RBF) カーネルを採用した。RBF カーネルの非線形の複雑さに係わるパラメータ  $\gamma$  と、正則化に係わるパラメータ  $C$  については、 $\gamma = 0.1, 0.01, 0.001, 0.0001$  と  $C = 1, 10, 100, 1000, 10000$  の範囲において、各実験毎に交差検証法を適用し、学習データに対して最も高い判定精度が得られた  $\gamma$  と  $C$  の組み合わせにおける評価テスト結果を、その機械学習モデルの最終的な分類精度と判断した。

## 6.3 次元削減次数の影響

次元削減の次数が分類精度に与える影響を確認するために、前処理による次元削減後の次数を変え、分類の正解率がどのように変化するか確認した。分類器のトレーニングおよび正解率の検証には、表 1 に示す学習用データセットと評価用データセットを用いた。

主成分分析 (PCA) による次元削減の次数が分類精度に与える影響を確認した結果を表 2 に示す。

一般的に、次元削減後の次数が高いほど累積寄与

表 2 次元削減次数と分類正解率の関係

| PCA 次数   | 10     | 20    | 30    | 40     |
|----------|--------|-------|-------|--------|
| 正解率      | 0.8312 | 0.889 | 0.895 | 0.8479 |
| C        | 1      | 10    | 100   | 100    |
| $\gamma$ | 0.1    | 0.1   | 0.1   | 0.01   |

表 3 Data Augmentation 有り 正解率 : 0.895

|    |      | 予測   |      |     |      |
|----|------|------|------|-----|------|
|    |      | 被削材無 | 加工開始 | 加工中 | 段取り替 |
| 真値 | 被削材無 | 120  | 0    | 0   | 0    |
|    | 加工開始 | 0    | 94   | 0   | 26   |
|    | 加工中  | 1    | 2    | 111 | 6    |
|    | 段取り替 | 0    | 2    | 13  | 105  |

表 4 Data Augmentation 無し 正解率 : 0.772

|    |      | 予測   |      |     |      |
|----|------|------|------|-----|------|
|    |      | 被削材無 | 加工開始 | 加工中 | 段取り替 |
| 真値 | 被削材無 | 119  | 0    | 0   | 1    |
|    | 加工開始 | 0    | 73   | 2   | 45   |
|    | 加工中  | 21   | 4    | 83  | 12   |
|    | 段取り替 | 2    | 15   | 7   | 96   |

率が増加するため、特徴ベクトルの表現力は向上すると考えられるが、今回のクラス分類問題においては次数が 40 次元を超えると分類精度が悪化し、次元数 30 の時に最も高い正解率が得られた。

## 6.4 Data Augmentation の効果確認

提案する Data Augmentation の効果を検証するために、データ拡張を行った学習用データセットと、データ拡張を行っていない学習用データセットを用い、そのそれぞれのデータセットによって訓練した機械学習モデルの分類精度を確認した。

Data Augmentation 有りの学習用データとして、表 1 に示す学習用データセットを用い、Data Augmentation 無しのデータセットには、動画の各フレーム像から単純に同一位置の画像を切り取った画像データを用いた。学習データ量の差が影響しないように、どちらのデータセットも 4 クラス各 220 枚、合計 880 枚の画像データとした。

主成分分析による次元削減後の次数を 30 次元として検証した際の、多クラス混同行列と正解率の結果を表 3 および表 4 に示す。Data Augmentation を適用していない場合の正解率が 77.3 % であるのに対し、提案手法を適用した学習モデルの正解率は 89.5 % と大きく分類精度が向上している。

## 7. おわりに

動画と AR マーカを用いた提案手法による Data Augmentation を行い、主成分分析による次元削減を主体とした前処理を行うことで、SVM によるクラスタリングにより比較的高い正解率で作業工程を分類できることを確認した。その正解率は、Data Augmentation を適用しない場合と比較して、77.3 % から 89.5 % に向上した。

提案手法による Data Augmentation は、幾何学的に自然な画像のデータ拡張が可能であることに加え、動画を活用することで、比較的手間を掛けずに多量の画像データを入手できるという利点がある。実際の生産現場では、生産ラインが稼働している状態で学習用の画像データを収集することになり、生産作業の妨げにならないように、手作業で多量の静止画像を撮影することは困難な場合が多い。提案手法は、AR マーカを設置できるスペースさえあれば、動画撮影のみで手軽に実施できるため、データ収集における作業コストの面でもメリットがある。

今回、SVM を用いることで特定の品番の工程分類において比較的高い分類精度が得られたが、学習データに含まれていない、形状が大きく異なる品番に対

する工程分類に関しては，精度が保証されないと考えられる．今後は製品形状や撮影環境の変動にも対応できるような汎化性の向上に取り組み，安定して自動監視できるシステムの実装検討を行っていきたい．

#### 参考文献

- 1) 中野太郎，田中徹，福島章吾，画像解析を利用した生産現場の状態監視技術に関する研究（第1報），令和元年度佐賀県工業技術センター研究報告書，2019，No.28，p.63-66.
- 2) 松橋聡，藤本研司，中村納，南敏，顔領域抽出に有効な修正 HSV 表色系の提案，テレビジョン学会誌，1995，49.6，p.787-797.
- 3) 石井健一郎，前田英作，上田修功，村瀬洋，わかりやすいパターン認識，オーム社，1998
- 4) 桑谷立，中村謙吾，渡邊隆広，小川泰正，駒井武，主成分分析を用いた次元圧縮に基づく東北地方太平洋沖地震による津波堆積物の地球化学的特性評価，地学雑誌，2014，123.6，p.923-935.
- 5) 松嶋道也，福本信次，藤本公三，はんだ接合部のニューラルネットワーク視覚検査における主成分分析を用いた入力次元数削減効果，エレクトロニクス実装学会誌，2013，16.3，p.206-210.