

AI 技術を活用した検査工程の省力化・効率化（第7報）

—欠陥画像分類モデルへのマルチタスク学習の適用—
渡辺博己*、生駒晃大*、松原早苗*

A study on artificial intelligence for labor savings and efficiency improvements of inspection process (VII)

—Application of multitask learning for defect image classification model—

WATANABE Hiroki*, IKOMA Akihiro*, MATSUBARA Sanae*

単一のモデルで複数の予測タスクを同時に学習させるマルチタスク学習と呼ばれる機械学習手法がある。各タスクの学習に要する時間削減だけでなく、主となるタスクの汎化性能を向上させることが可能である。本研究では、欠陥画像分類モデルをマルチタスク学習が可能なモデルに再構成した。実験では、欠陥画像データセットを用いて、タスクの数や組み合わせが異なる場合のクラス分類における正解率を求め、マルチタスク学習が汎化性能を向上させることを確認した。

1. はじめに

単一のモデルで複数の予測タスクを同時に学習させるマルチタスク学習¹⁾と呼ばれる機械学習手法がある。関連する複数のタスクを同時に予測できるように学習することで、各タスクの学習に要する時間削減だけでなく、主となるタスクや他のタスクの汎化性能（未知データに対する識別能力）を向上させることが可能である。そのため、近年、深層学習においても様々な分野でマルチタスク学習が検討されている²⁾。

本研究では、欠陥画像データセット³⁾における欠陥 15 クラス、正常 4 クラスの 19 クラス分類を主タスクとし、画像データに付加された他の分類情報を元にしたタスクを補タスクとするマルチタスク学習が可能な欠陥画像分類モデルを構成した。実験では、有効な補タスクを見出すため、タスクの数や組み合わせが異なるマルチタスク学習を行い、主タスクにおける汎化性能を比較した。本稿では、これらの内容について報告する。

2. マルチタスク学習の適用

2. 1 欠陥画像分類モデルへの適用

本研究では、前報の EfficientNet を適用した欠陥画像分類モデル⁴⁾について、マルチタスク学習が可能なモデルを構成した。図 1 に、新たに構成した欠陥画像分類モデル（以下、MTL モデル）を示す。

MTL モデルでは、タスク数に応じて、出力層に全結合（FC）層を持つ構成となる。学習の際には、入力画像と同時に、タスクに応じた正解ラベルを入力し、各タスクの予測が、正解ラベルと一致するようネットワークの重みを学習する。各 FC 層では、タスクに応じたユニット数（ $M_1 \sim M_N$ ）を持ち、各ユニットからの出力は、ソフトマックス関数により各クラスの確率に変換される。なお、マルチタスク学習では、タスク数に応じて正解ラベルを付与する作業が必要であり、この作業に時間を要




図1 マルチタスク学習用欠陥画像分類モデルの構成

するため、マルチタスク学習の導入が困難になる場合がある。

2. 2 補タスクの選定

マルチタスク学習では、タスク間にある程度の相関関係が必要である。タスク間で共有される情報が、各タスクに対する予測を行う上で有用である場合、汎化性能が向上するためである。

本研究では、欠陥画像データセットの欠陥 15 クラス、正常 4 クラスの 19 クラス分類を主タスク（以下、タスク A）としている。そのため、類似したタスクではあるものの、新たなラベル付け作業が不要であることから、欠陥と正常に分類する 2 クラス分類を二つ目の補タスク（以下、タスク B）とした。

また、欠陥画像データセットには、検査対象部品の構造上、端部やテーパ部を撮影した画像データが含まれる。これらの画像データには、照明条件により暗領域や明領域が存在し、欠陥種別によっては欠陥による明暗領域も存在することから、端部・テーパ部と、これらの部位が含まれない胴周部との 2 クラス分類を三つ目の補タスク（以下、タスク C）とした。図 2 (a)に、タスク C の画像データ例を示す。

さらに、欠陥画像データセットの画像データを撮影した検査装置は、一つの検査対象部品について照明条件を 4 回変更して検査する機構を持つ。そこで、どの照明条件で撮影された画像データかを予測する 4 クラス分類を四つ目の補タスク（以下、タスク D）とした。図 2 (b)

* 情報技術部




図2 タスク C、D の画像データ例

に、タスク D の画像データ例を示す。

なお、タスク C、D の学習に必要な正解ラベルについては、欠陥画像データセットのデータ収集時にラベル付けしているため、新たなラベル付け作業は不要である。

3. MTL モデルによる画像分類

3. 1 実験

実験では、欠陥画像データセットを用いて、ファインチューニングにより MTL モデルを学習させ、タスク A にタスク B～D を 1～3 個組み合わせた 7 通りの 19 クラス分類を行った。また、前報と同一の検証用データを用いて、各クラスに対する正解数の和を、データの総和で除した、全クラスに対する正解率に加え、欠陥クラス、正常クラス毎の正解率を求めた。なお、実験で用いた MTL モデルにおける EfficientNet には B4 を利用した。

3. 2 結果と考察

タスク A のみの場合の分類結果を表 1 に、タスク数が 2～4 の場合におけるタスク A の分類結果を順に表 2～4 に示す。

表 2、3 の結果から、タスク B～D の何れか一つ、または二つを加えた場合においては、タスク A のみの場合の全クラスに対する正解率を上回ることができなかった。しかし、表 2 のタスク C、D を個々に加えた場合、及び表 3 のタスク D を含む場合については、正常クラスの正解率がタスク A のみの場合を上回る結果となった。これらのことから、本稿で選定した三つの補タスクについては、主タスクの学習に対するタスク D の学習の相乗効果が最も高いと考えられる。

また、表 4 の全ての補タスクを学習した場合には、欠陥クラス、正常クラスともに正解率がタスク A のみの場合を上回り、結果として全クラスに対する正解率が 93.53% となった。ここで、表 5 に示す同検証用データにおける補タスクの正解率から、タスク数が 4 の場合に

表 1 タスク A のみの場合の正解率

タスク	欠陥クラス	正常クラス	全クラス
A	0.9420	0.8875	0.9305

表 2 タスク数が二つの場合のタスク A の正解率

タスク	欠陥クラス	正常クラス	全クラス
A+B	0.9387	0.8850	0.9274
A+C	0.9333	0.8925	0.9247
A+D	0.9387	0.8925	0.9289
平均	0.9369	0.8900	0.9270

表 3 タスク数が三つの場合のタスク A の正解率

タスク	欠陥クラス	正常クラス	全クラス
A+B+C	0.9380	0.8825	0.9263
A+B+D	0.9333	0.8975	0.9258
A+C+D	0.9373	0.9050	0.9305
平均	0.9362	0.8950	0.9275

表 4 タスク数が四つの場合のタスク A の正解率

タスク	欠陥クラス	正常クラス	全クラス
A+B+C+D	0.9453	0.8975	0.9353

表 5 各タスク数における補タスクの正解率

タスク数	タスクB	タスクC	タスクD
2	0.9726	0.9974	0.9963
3(平均値)	0.9692	0.9963	0.9945
4	0.9705	0.9937	0.9979

において、タスク数が 2 の場合と比較し、タスク D のみ正解率が向上していることが分かる。そのため、先述のとおりに、タスク D の相乗効果が高いと考えられることから、全ての補タスクの学習により、主タスクに対してのみならず、補タスク間の学習においても相乗効果が発現し、主タスクの性能向上に寄与したと考えられる。

4. まとめ

本研究では、欠陥画像分類モデルをマルチタスク学習が可能なモデルに再構成し、欠陥画像データセットを用いてタスクの数や組み合わせが異なる場合の汎化性能を検証した。その結果、タスク数が 4 の時に、シングルタスクモデルの正解率を 0.48% 向上することができ、マルチタスク学習による汎化性能の向上を確認した。

今後も、モデルの改良を継続し、さらなる汎化性能の向上を目指す。

【謝 辞】

本研究を遂行するにあたり、欠陥画像データセットをご提供いただきました株式会社前田精工の皆様に深く感謝の意を表します。

【参考文献】

- 1) R. Caruana, Machine Learning, vol.28, pp.41-75, 1997
- 2) S. Ruder, arXiv:1706.05098, 2017
- 3) 渡辺ら, 岐阜県産業技術総合センター研究報告, No.1, pp.81-84, 2020
- 4) 渡辺ら, 岐阜県産業技術総合センター研究報告, No.3, 2022