

深層学習と金属種間の転移学習による破断面 SEM 画像の分類 Fractographic classification of SEM images using deep learning and transfer learning between metal types

上杉 徳昭[†] 濱田 真行[‡] 喜多 俊輔[‡] 平田 智文[‡]
Tokuteru UESUGI Naoyuki HAMADA Shunsuke KITA Tomotake HIRATA

1. はじめに

金属材料は、多くの製品に使用されており、その寿命は、使用状況や周囲環境によって影響を受け、誤った使用を続けると、やがて破損する。その破壊原因を特定するためには、破断面の破面解析が用いられる。破面解析において、解析者は破断面の模様を解釈し、破壊機構の観点から破面分類を行う。この作業は熟練者による観察と経験に基づく複雑な知的判断を必要とする。解析者の経験は、言語化できない暗黙知として蓄積され、伝承が容易ではない。そのため、破面解析の初心者をサポートし、熟練した解析者の経験を伝承するシステムが求められる。

最近では、深層学習の畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を用いることで、破断面を分類できることが報告されている[1]。しかし、学習に用いる破断面画像のデータ数は材料によっては少ないため、そのまま CNN に学習させただけでは十分な精度が得られない。そのため、他の材料からの学習結果を利用する転移学習手法として、ステップワイズ元クラス選択法 (SSSC: Stepwise Selection of Source Classes) が提案されている[2]。本研究では、合金鋼、ステンレス鋼、銅合金という 3 つのドメインで、破面分類の深層学習に SSSC を用いた結果を報告する。

2. ステップワイズ元クラス選択法

転移学習では、知識の転移元を元ドメイン、知識の転移先を目標ドメインと呼ぶ。既存手法の破断面の分類では、材料を区別しないため、元ドメインのみを用いた学習になる。ディンプル、ストライエーション、明瞭なストライエーションが認められない疲労破面 (ぜい性疲労破面)、へき開破面、擬へき開破面、粒界破面、ファンシェーブトパターン の 7 クラス ($m=7$) の分類で、元ドメインのみを用いた分類モデルを図 1(a) に示す。一方で、材料の種類ごとにそのまま用いた学習を図 1(b) に示すが、これは目標ドメインのみを用いた学習となる。元ドメインのデータセットの中で、同じラベルを有する部分集合を元クラス、目標ドメインのデータセットの中で同じラベルを有する部分集合を目標クラスと定義する。

転移学習では元ドメインと目標ドメインの類似性を仮定して、仮定された類似性の観点から転移学習手法を適切に選択する必要がある。転移学習手法としては、元ドメインのデータそのものを目標ドメインのデータとして扱う事例転移がある。破断面の分類では、どの材料でも粒界破面の

特徴は似ているが、例えばストライエーションの特徴は材料によって異なるというように、元ドメインと目標ドメインでの事例の類似性はクラスによって異なる。この観点に基づけば、クラスごとに転移させる事例の選択を行うことが有効であると考えられる。

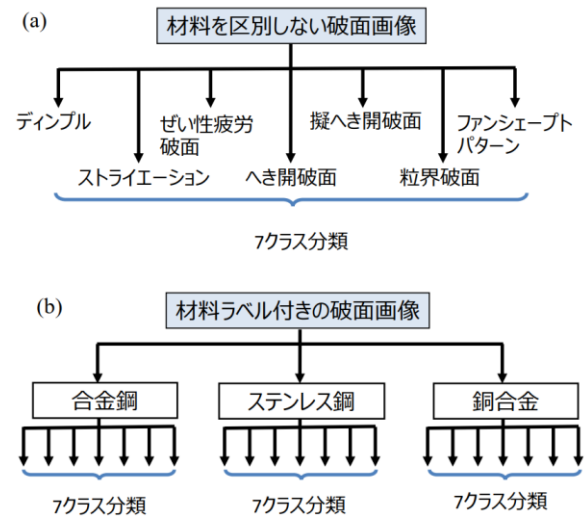


図 1 (a)元ドメインでの学習と (b)材料の種類を区別した目標ドメインでの学習

SSSC では、元クラスと目標クラスを混合した事例で弱学習器を学習し、目標ドメインのデータで評価を行い、ステップワイズ法により元クラスと目標クラスの組み合わせを探索する。ステップワイズ法に前進法を用いる場合は、目標ドメインから開始する。目標クラスの 1 つを元クラスに交換して学習を行い、目標ドメインの評価データで評価する。目標クラス数だけ、この学習と評価を行い、最も有用な元クラスに交換する。次に、残された目標クラスに対して同じように、残された目標クラス数だけ、学習と評価を行い、最も有用な元クラスを 1 つ交換する。以上を繰り返して、すべてが元クラスつまり元ドメインになるまで繰り返して、最適な元クラスと目標クラスの組み合わせを探索する。後退法でも目標ドメインの評価データの評価を用いるが、元ドメインから出発して、目標ドメインになるまで繰り返して、最適な組み合わせを探す。前進法と後退法のどちらでも学習と評価の必要回数は $m(m+1)/2$ である。

3. 実験方法

データセットには、破面解析の熟練者がラベル付けした走査型電子顕微鏡 (SEM) 画像の 1362 枚の破断面画像を用いた。このデータセットにはドメイン別 (ここでは材料

[†] 大阪公立大学大学院 情報学研究科 Graduate School of Informatics, Osaka Metropolitan University

[‡] (地独) 大阪産業技術研究所 Osaka Research Institute of Industrial Science and Technology

別) では, 合金鋼は 757 枚, ステンレス鋼は 386 枚, 銅合金は 219 枚の画像が含まれている. クラス別 (ここでは破面形態の違い) では, ディンプルは 332 枚, ストライエーションは 255 枚, ぜい性疲労破面は 256 枚, へき開破面は 140 枚, 擬へき開破面は 105 枚, 粒界破面は 222 枚, ファンシュープトパターンは 52 枚の画像が含まれている.

用いたデータ量は十分とは言えず, また不均衡データである. そのため, 様々なチューニングにより性能向上を行った. 訓練データについてはオーバーサンプリングにより少数クラスの画像を複製し, データ数を増やしてクラス不均衡を解消した. 元ドメインにて, 検証データの事例数を各クラスで 20 として, チューニングを行った. 前処理ではチューニングの結果, 入力画像はサイズ 512×384, 疑似カラーに変換を行った. 正則化手法としては, 早期打ち切り, ドロップアウト, バッチ正則化を使用し, ハイパーパラメータのチューニングも検証データを用いて行った. データ拡張は訓練データに対してのみ行い, 検証データを用いて検証を行い, 画像に対してランダムに移動, 拡大・縮小, 回転, せん断, 反転の操作を行った. CNN のアーキテクチャについては, VGG16, VGG19, ResNet50V2, ResNet101V2, ResNet152V2, InceptionV3, InceptionResNetV2, MobileNetV2, Xception, DenseNet121, DenseNet169, DenseNet201 の候補の中から, 検証データでの結果に基づき, DenseNet201 でのファインチューニングを採用した.

以上のチューニング後に, 各目標ドメインでデータセットを分割し, 検証データとテストデータの事例数はそれぞれ各クラスで 5 とし, 残りを訓練データとした. 元ドメインでは, データリークageを防ぐため, 各目標ドメインで分割済みの訓練データを混合し, 元ドメインの訓練データとした.

4. 結果と考察

前処理を行ったデータとチューニングされた DenseNet201 モデルで SSSC による元クラス選択を行った. 図 2 に前進法と後退法での, ステンレス鋼での正解率と元クラス数の関係を示す. 元クラス数が 0 と 7 の時は転移学習ではなく, それぞれ, 目標ドメインでの学習と元ドメインでの学習である. ステンレス鋼では, 元クラス数が 3 から 5 の時に最も高い正解率を示していた. 同様に合金鋼では元クラス数が 1 から 6 の時に, 銅合金では元クラス数が 2 から 7 の時に最も高い正解率を示していた.

SSSC で最も正解率が高い時に選択されていた目標クラスと元クラスについて, 両者の訓練データ数の比率の分布を箱ひげ図として図 3 に示す. 図 3 より目標クラスの訓練データが十分に多ければ, 目標クラスが選択されていたが, 目標クラスの訓練データが少なければ元クラスが選択されていたことが読み取れる.

表 1 に目標ドメインでの学習, 元ドメインでの学習, SSSC を用いた時のテストデータの正解率を示す. 元ドメインでの学習は, 材料を区別しない既存手法であり, 平均正解率は 91.3%であった. 目標ドメインでの学習では, 材料の種類を考慮し, 材料ごとにそのまま学習させたが, 平均正解率は 91.1%であった. 一方で, SSSC では平均正解率は 98.7%であり, 既存手法から 7.4%向上しており, SSSC の有効性が確認できた.




図 2 ステンレス鋼での正解率と元クラス数の関係




図 3 最も正解率が高い時に選択されていた目標クラスと元クラスの訓練データ数の比率の分布

表 1 テストデータの正解率

ドメイン	目標ドメイン	元ドメイン	SSSC
合金鋼	0.933	0.900	1.000
ステンレス鋼	0.880	0.880	1.000
銅合金	0.920	0.960	0.960
平均	0.911	0.913	0.987

5. まとめ

本研究は転移学習の SSSC を用いることで材料の種類を考慮することにより, CNN を用いた破面分類の高精度化を行った. 材料を区別しない既存手法では平均正解率は 91.3%であった. 材料の種類を考慮し, 材料ごとにそのまま学習させると, 平均正解率は 91.1%に悪化した. 一方で, 材料の種類を考慮し, SSSC を用いた時の平均正解率は 98.7%に向上した. 元クラスと目標クラスの選択には, 両者のデータ数の比率が関係しており, 目標クラスの訓練データが十分に多ければ, 目標クラスが選択されるが, 目標クラスの訓練データが少なければ元クラスが選択されていた.

参考文献

- [1] K. Yamagiwa, "Application of deep-Learning for classification of fracture surface's SEM image", Journal of the Society of Materials Science, Japan, Vol. 69, pp.644-649 (2020).
- [2] T. Uesugi, M. Kondou, N. Hamada, S. Kita and T. Hirata, "Fractographic Classification by Transfer Learning Considering Material Types", Journal of the Society of Materials Science, Japan, Vol. 72, pp.376-383 (2023).