2C-03

合金種を考慮した深層学習による金属材料の破面分類

上杉 徳照† 近藤 充晟† 濱田 真行‡ 喜多 俊輔‡ 平田 智丈‡
大阪府立大学† 大阪産業技術研究所‡

1. はじめに

破面解析（フラクトグラフィ）とは、破面に残された痕跡を調査することにより得られた情報を元に、破壊の機構や原因を解析する手法である。しかし、破面解析には多くの経験・知識が必要であり、リソース不足が叫ばれる昨今、破面解析専門の技術者を育成することは、多大な労力が必要である。そのため、人工知能システムにより破面を分類することができれば、破面解析の省力化とともに、技術者育成に役立つものと考えられる。本研究は CNN(畳み込みニューラルネットワーク)を用いて、SEM(走査型透過電子顕微鏡)観察によるミクロ破面の破面形態を自動分類するシステムの構築を目的としており、合金種別を考慮することによる分類精度の向上を報告する。

2. 関連研究

破断面の分類にはこれまでも、エキスパートシステムを活用した報告 [1]、人工ニューラルネットワークやサポートベクターマシーンを活用した報告 [2]もあるが、最近では、CNN を用いて、破面形態を自動分類する試みが報告されている。山際 [3]は ImageNet データベースで学習させた Inception-v3 により 6 種類の破断面の分類を報告している。Bastidas-Rodriguez らは [4]VGG-16 などのファインチューニングおよび M-DAWN と呼ばれるアーキテクチャを用いた 3 種類の破断面の分類を報告している。しかし、これまでの先行研究は、材料の違いを考慮しておらず、すべての金属・合金を同一の破断面のクラスで分類をしている。

3. 提案手法

Fig. 1 は従来のすべての金属・合金を同一の破断面のクラスで分類する手法である。しかし、観察される破断面の特徴は材料によって異なっている。例えば疲労破壊で観察されるストライエーションの特徴は、合金種によって異なっている。また、オーステナイト系ステンレス鋼や銅・銅合金ではへき開破壊が生じることは稀であり、へき開破面や擬へき開破面が観察されることはない。

合金種の情報は材料証明書もしくは蛍光 X 線分析などを用いて容易にかつ、原理上は正確に取得できる。よって、破面解析専門の技術者は、事前に調査した合金種の情報を考慮して、総合的に破断面を分類していると思われる。

そこで、提案手法では合金種を考慮するため、合金種のラベル付き画像を入力画像とし、合金種と同じ数のネットワークを構築する。Fig. 2 に提案手法の概略を示す。提案手法では従来手法と異なり合金種のラベルが必要である。

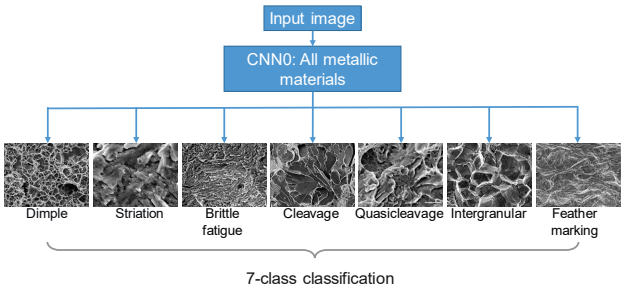

Fig. 1 The Existing method for fractographic classification in metallic materials by deep learning.

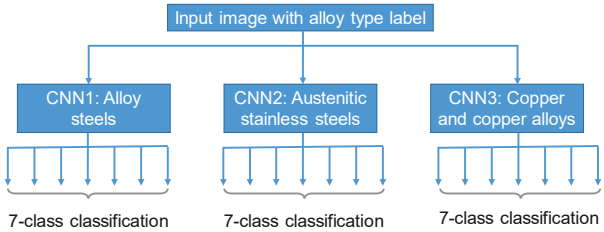

Fig. 2 The proposed method for fractographic classification in metallic materials by deep learning considering type of alloy.

4. 実験

4.1 データセット

本研究で使用したミクロ破面画像のデータセットの構成を Table 1 に示す。合金種は、合金鋼、オーステナイト系ステンレス鋼、銅・銅合金の 3 種類である。破面は、ディンプル、ストライエーション、脆性疲労破面、へき開破面、擬へき開破面、粒界破面、羽毛状模様の 7 クラスである。全ての画像は、SEM を用いて、破面の特徴が判別できる観察倍率に調整して撮影を行った。画像サイズは 1280×960 もしくは 2560×1920 である。ただし、CNN への入力画像には全てサイズを 256×192 に調整した RGB の 3 チャンネルのカラー画像を用いた。

破面の分類については、破面解析の経験が豊富な専門の技術者が判断したクラスをラベル付けした。合金種の分類については、材料証明書もしくは蛍光 X 線分析から判明した合金種に従い 3 種類に分類し、分類を行わないものを全金属材料とした。各合金種・各クラスの画像の中で、無作為に選んだ 5 枚ずつを評価用として除いた上で、残りの 7 割を訓練用に、3 割を検証用に分割した。訓練用と検証用にはデータ拡張を行ったが、分割後の訓練用と検証用のそれぞれに、データ拡張を行った。データ拡張には反転、輝度変更、回転を用いることで、全金属材料を含む各合金種の訓練データを 45 万枚程度に拡張した。拡張前の枚数は多い順に全金属材料、合金鋼、オーステナイト系ステンレス鋼、銅・銅合金となり、枚数にばらつきがある。データ拡張により訓練用の枚数が増えるほど、正解率は向上する傾向がある。そこで、画像枚数の影響を除去するため、拡張後の各合金種の訓練データは 45 万枚程度に揃えた。

Fractographic classification in metallic materials by deep learning considering type of alloy
† Osaka Prefecture University
‡ Osaka Research Institute of Industrial Science and Technology

Copyright ©2021 Information Processing Society of Japan.
All Rights Reserved.

Table 1 Number of images for each class.

Alloy type	Class						
	1: Dimple	2: Striation	3: Brittle fatigue	4: Cleavage	5: Quasi-cleavage	6: Inter-granular	7: Feather marking
All metallic materials	179	178	160	27	10	80	33
Alloy steels	58	61	127	27	10	34	0
Austenitic stainless steels	77	91	33	0	0	0	20
Copper and copper alloys	44	26	0	0	0	46	13

4.2 CNN の実装

CNN の実装には、深層学習フレームワークである TensorFlow(tensorflow-gpu 2.2.0) をバックエンドとした Keras (keras 2.3.1)を利用した。データ拡張にはコンピュータビジョンライブラリである OpenCV を用いた。実験環境の OS は Windows 10 Pro、CPU は Intel Core i7-9700K, GPU は NVIDIA Titan RTX、CUDA は CUDA 10.1 である。

学習には、事前に ImageNet で学習済みの VGG16[5]のパラメータを初期値としたファインチューニング にて行った。Fig. 3 に本研究で用いたニューラルネットワークの構造を示すが、conv3-3 までのパラメータを固定し、それ以降の畳み込み層と全結合層においてはパラメータを再学習した。全結合層では、活性化関数は ReLu を使用し、FC-256 には Batch Normalization と確率 0.5 の Dropout を追加した。学習はミニバッチ学習で行い、ミニバッチサイズは 512 とし、最適化アルゴリズムには Adam を用いて、エポック数 100 まで学習を行った。

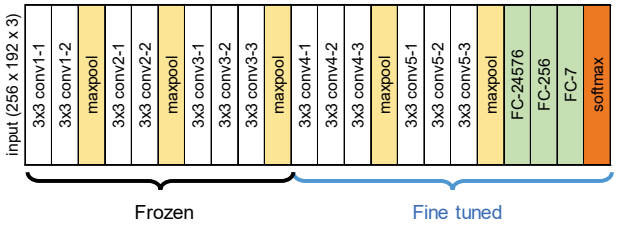

Fig. 3 The network architecture for fine-tuning on VGG16.

4.3 実験結果

評価用データでの正解率を Table 2 に示す。CNN0 では従来手法として合金種の分類を行わない全金属材料のデータセットを用いたネットワークでの結果である。一方で、CNN1、CNN2、CNN3 は合金種を分類したデータセットを用いたネットワークでの結果である。CNN1、CNN2、CNN3 はいずれも、CNN0 の正解率以上の高い正解率を示した。CNN1、CNN2、CNN3 の平均正解率は 83.2%であり、CNN0 の平均正解率の 78.3%よりも約 5%向上した。合金種を考慮するため、合金種のラベル付き画像を入力画像とし、合金種と同じ数のネットワークを構築する提案手法は、破面分類の精度向上に有効であった。

4.4 考察

本研究ではデータ拡張後の訓練用データの枚数は揃えているが、拡張前の枚数は多い順に全金属材料、合金鋼、オーステナイト系ステンレス鋼、銅・銅合金となる。それゆえ、データ量の観点からは、CNN0 は最も精度向上が期待される。一方で、破断面の特徴は同じクラスであっても合金種によって微妙に異なるものもあり、データの質の観点からは、CNN0 は精度の低下に作用する。結果としては、本研究ではデータの質の影響が大きく、合金鋼、オーステナイト系ステンレス鋼では CNN1、CNN2 のほうが CNN0 よりも精度は高かった。銅・銅合金はデータ量が最も少ないので、データの量と質の影響が拮抗することで、CNN0 と CNN3 の精度が等しくなったと考えられる。それゆえ、銅・銅合金ではデータを追加すれば、提案手法が有利となることが予想される。

Table 2 Results of the test accuracy on four networks.

	CNN0	CNN1	CNN2	CNN3
Alloy steels	0.80	0.87		
Austenitic stainless steels	0.80		0.88	
Copper and copper alloys	0.75			0.75

5. 結論

合金種を考慮して、合金種のラベル付き画像を入力画像とし、合金種と同じ数のネットワークを構築する手法を提案し、3 種類の合金の破面画像を用いて本手法の有効性を検証した。その結果、正解率が最大で 8%、平均して約 5%向上し、本手法が破面分類の精度向上に有効であることを明らかにした。

参考文献

1) 駒井謙治郎, 箕島弘二, 小山昌宏, "環境助長割れ診断エキスパートシステムの開発と診断知識の重要度評価", 日本機械学会論文集 A 編, Vol. 57, pp.188-194 (1991).
2) M.X. Bastidas-Rodriguez, F.A. Prieto-Ortiz and E. Espejo, "Fractographic classification in metallic materials by using computer vision", Engineering Failure Analysis, Vol. 59, pp.237-252 (2016).
3) 山際謙太, "破断面解析におけるディープラーニングの活用事例の紹介", 材料, Vol. 69, pp.644-649 (2020).
4) M.X. Bastidas-Rodriguez, L. Polania, A. Gruson and F. Prieto-Ortiz, "Deep Learning for fractographic classification in metallic materials", Engineering Failure Analysis, Vol. 113, pp.104532 (2020).
5) K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition", The 3rd International Conference on Learning Representations Vol. (2015).

Copyright ©2021 Information Processing Society of Japan.
All Rights Reserved.