

CNN を用いた金属組織画像の結晶粒径測定に適したデータ拡張 Data Augmentation for automatic grain size determination in metallographic images using CNN

上杉 徳照†
Tokuteru Uesugi

1. はじめに

金属材料の多くは結晶方位の異なる結晶粒が多数集まった多結晶材料である。この結晶粒の境界を結晶粒界と呼ぶ。結晶粒界は光学顕微鏡や走査型電子顕微鏡などを用いることで観察できる。部材から断面を切り出して試験片とし、断面を研磨して整え、エッチングで組織にコントラストを付け、顕微鏡で表面画像を取得する。取得した画像から結晶粒界の平均間隔である結晶粒径を計策する。

結晶粒径は、金属材料の強度やじん性などの力学特性に大きな影響を及ぼす。そのため、結晶粒径を正確に測定する技術の確立は、金属材料の力学特性を推測する上で重要な課題である。結晶粒径あるいは結晶粒度を測定するための方法としては、切断法（もしくは切片法）、比較法、計数方法が知られている。これらの方法は JIS に JISG0551 として定められている。特に図 1 で示すような切断法は物理的特性との関連付けが可能な結晶粒径を測定する手法であり、最も一般的な手法である。しかし、切断法による結晶粒径の測定には多大な労力を要する上に、手作業で測定を行うため、測定結果の個人差が大きいという問題が知られている。

そこで、切断法に伴う問題を改善する為に、二値化した結晶組織画像の各走査線が結晶粒界と交差する交差数を求め、切断法により結晶粒径を測定する方法が知られている [1]。この方法は、図 1 で示すように大津の方法などで画像を二値化することにより、結晶粒内を白色化、結晶粒界を黒色化し、走査線と黒色領域が交差した数を求めることにより、結晶粒径を測定する方法である。この方法では、黒色領域と走査線の交点の数をカウントするだけで結晶粒系を測定できるため、粒径測定を自動化して高速化することが可能である。しかし、この方法では、画像の各画素の画素値に対して二値化処理を施すと、断片化された黒色領域が多数存在し、これらの領域が結晶粒界に対応する領域なのか、あるいはノイズに対応するものなのか判断できない。ノイズには研磨傷のような人工的なものや、非金属介在物のような不純物だけでなく、析出物や晶出物のような材料組織に固有のものも含まれる。そのため、二値化を用いた粒径測定の自動化は析出物、晶出物を含む金属組織には用いることができない。

また、結晶粒界のコントラストは一様ではなく濃淡を有しているため、二値化の閾値を手動で調整して設定しなければならない。結晶粒界のコントラストが粒界により大きく異なる場合、作業によって二値化の閾値設定が異なれば、測定結果にばらつきが生じてしまう。そのため、析出物、晶出物を含む金属組織について、切断法を自動化して、結晶粒径を測定できれば、作業者によらず再現性の高い結果が得られるとともに、大幅な作業時間の短縮が達成できる。




図 1 切断法の例（上：二値化、下：手動）

2. 関連研究

近年、コンピュータビジョン技術の発展は目覚ましく、深層学習のニューラルネットワークを使用して、高い精度で画像分類、オブジェクト検出、セマンティックセグメンテーション、およびインスタンスセグメンテーションを実現している。このような技術の発展に伴い、金属組織にも深層学習の適用が試みられている。Azimi ら [2] は鉄鋼材料のマルテンサイト、パーライト、バーナイトといった組織を分類するために CNN (畳み込みニューラルネットワーク) の VGG16 [3] を用いるだけでなく、Fully Convolutional Network を用いることで、高い精度でこれらの組織のセマンティックセグメンテーションが可能であることを報告している。

また、Ajioka ら [4] は α Fe の結晶粒界とマルテンサイト組織のセマンティックセグメンテーションを試みており、Fully Convolutional Network の中でも、SegNet と比して U-Net [5] は少ない訓練データ数でも高い精度を示すことを報告している。なお、U-Net は細胞膜の高精度なセグメンテーションを出力する方法として提案されたものであり、金属組織の結晶粒界のセグメンテーションに近いタスクと言える。ただし、Ajioka らの方法でも粒界は完全には分類できていないため、セグメンテーションされた画像から切断法を行うことは出来ておらず、結晶粒径の自動推定には至っていない。そのため、析出物、晶出物を含む金属組織について、切断法を自動化して、結晶粒径を測定できる手法は未だ完成していない。

3. 提案手法

これまでの関連研究を踏まえ、析出物、晶出物を含む金属組織について、切断法を自動化して、結晶粒径を測定できる手法の開発における課題は、セグメンテーションの精度不足にある。そこで、本研究ではセグメンテーションと切断法の処理を除き、End-to-End に結晶粒径を自動推定する手法を採用することにした。自動推定には CNN を用いて、CNN の学習には教師あり機械学習を用いる。これは金

属組織画像の入力を CNN に与え、出力に結晶粒径を推定する回帰問題である。そのため、学習データの金属組織画像に対して事前に正解データとして、結晶粒径の対応付けを行う必要がある。ただし、金属組織画像のデータセットは取得コストの問題があるため量に限りがある。よって、少ないデータセットで高精度な学習を行うため、データ拡張を採用する。

データ拡張には多くの手法があるが、大きく分けて、反転などの幾何学的な操作を加える方法と、明度を変えるなど色空間を操作する方法が取られる。しかし、結晶粒界の判別には色みや明度よりも形状が重要な特徴として捉えられているという前提に基づき、本研究では幾何学的な操作のみを検討することにした。

幾何学的な操作には、反転、クロップ(切り抜き)、回転、平行移動などが含まれる。画像の一部領域に物体が含まれる画像分類と異なり、結晶粒径の情報は組織画像の全領域に含まれている。反転では画像の全領域が維持され、縦横比も変わらないので、粒径情報は反転に対して不変性を有している。そのため、反転では正解データを変更せずにデータ拡張が可能である。しかし、クロップや回転により、画像の一部領域を CNN に与えるには、正解データの結晶粒径を再度取得する必要がある、そのコストは極めて高い。

そこで、本研究では、クロップにおいて近似的に正解データの結晶粒径を再度取得する手法を提案する。切り抜き後に元画像サイズにリサイズされた組織画像の結晶粒径 d は次式により算出した。

$$d = d_0 / \rho \quad (1)$$

ただし、 d_0 は元画像の結晶粒径 d であり、 ρ はクロップ後の画像サイズを元画像サイズで除したクロップ率である。

4. 実験

4.1 データセット

実験に用いるため 261 枚のマグネシウム合金の光学顕微鏡写真を準備した。マグネシウム合金を対象とした理由は、マグネシウム合金は鉄鋼材料と比べて強化機構が限られており、析出物や晶出物を含む合金が多数あるためである。261 枚の内、248 枚は大阪府立大学工学研究科マテリアル工学分野東研究室および瀧川研究室にて蓄積されていたものであり、AZ 系、AZX 系、AMX 系、Mg-Al 系の幅広いマグネシウム合金を含んでおり、また押出材、焼鈍材、溶接部材とプロセス条件も多岐に渡っている。261 枚の内、残り 13 枚は学術論文および Google 画像検索[6]より収集した公開データである。

公開データ 13 枚の撮影時の倍率は不明であるが、その他の対物レンズの倍率は 20 倍 16 枚、50 倍 195 枚、150 倍 34 枚、200 倍 3 枚である。最もデータが多い対物 50 倍での実視野サイズ(FOV: Fields of View)は $280\mu\text{m} \times 210\mu\text{m}$ である。そこで、全ての光学顕微鏡写真の FOV を $280\mu\text{m} \times 210\mu\text{m}$ と仮定して切断法により結晶粒径を事前に測定した。

切断法は同一の熟練作業者が行い、切断法により得られた結晶粒径の値を正解ラベルとして用いた。切断法は組織画像に対して横 5 本、縦 5 本の全長 L の直線を引き、直線が横切った粒界の数 n を求めた。この時、横切ったものが粒界であるか、析出物や晶出物のノイズであるかは、全て

同一の熟練作業者の判断に委ねた。また、10 本の直線の端が粒内にある場合は 0.5 個と数えた。最終的に結晶粒径 d は補正係数[7]をかけて次式により算出した。

$$d = 1.74L/n \quad (2)$$

測定された 261 枚の組織画像の結晶粒径 d の平均値は $23.3\mu\text{m}$ 、最小値は $11.1\mu\text{m}$ 、最大値は $58.5\mu\text{m}$ であった。

4.2 データ拡張

261 枚の画像のサイズは 1024×768 が 232 枚、 800×600 が 13 枚、 750×563 が 16 枚である。CNN への入力画像には全てサイズを 320×240 に調整し、輝度を正規化した RGB の 3 チャンネルのカラー画像を用いた。総数 261 枚の画像の内、250 枚を訓練用、50 枚を検証用、11 枚を評価用に無作為に分割した。分割前のデータに拡張を行うと、分割した際に拡張元が同一のデータが訓練データと検証データに存在することになり、汎化性能が正しく評価できない可能性がある。そこで、分割した後の訓練データと検証データを反転とクロップにより拡張した。反転は上下反転、左右反転、上下・左右反転の 3 種類で 4 倍のデータ拡張を行った。

クロップには提案手法による正解データの結晶粒径の変更を伴う方法で行った。クロップ率 ρ は 0.95, 0.90, 0.85, 0.80, 0.75, 0.70, 0.65, 0.60, 0.55, 0.50 の 10 種類とし、クロップ領域は元画像の四隅の 4 種類としたので、合計で 41 倍のデータ拡張を行った。反転とクロップにより、訓練データは 32,800 枚、検証データは 8,200 枚に拡張された。また、評価データに対しては結晶粒径が不変となる反転のみを行い、44 枚に拡張した。

4.3 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、明記されていないハイパーパラメータはライブラリの初期値を用いた。なお、データ拡張に必要な画像処理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。動作環境には OS: Windows 10 Pro、CPU: Intel Core i7-9700K、GPU: NVIDIA Titan RTX を用いた。

学習には、事前に ImageNet で学習済みの VGG16 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。図 2 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、Conv4-3 までの重みデータを固定し、それ以降の畳み込み層と全結合層においては重みデータを再学習した。出力層には結晶粒径の平均二乗誤差(MSE: Mean Squared Error)を損失関数に使用した。すべての層で畳み込み層はフィルタサイズ 3×3 、パディングを 1 で行い、max pooling は 2×2 のフィルターで行った。全結合層では、活性化関数は ReLu を使用し、FC-256 と FC-10 にそれぞれ Batch Normalization を追加し、確率 0.5 の Dropout を FC-256 に追加した。学習はミニバッチ学習で行い、ミニバッチサイズは 100 とし、最適化アルゴリズムには Adam を用いた。

320×240 のカラー画像を入力として受け取った CNN は回帰問題として 1 次元の結晶粒径を出力する。そのため、粒界のセグメンテーションと切断法の処理を経ることなく、End-to-End に結晶粒径を自動推定することが期待される。

精度指標には結晶粒径(μm)の平均絶対誤差 (MAE: Mean Absolute Error) を用いた。

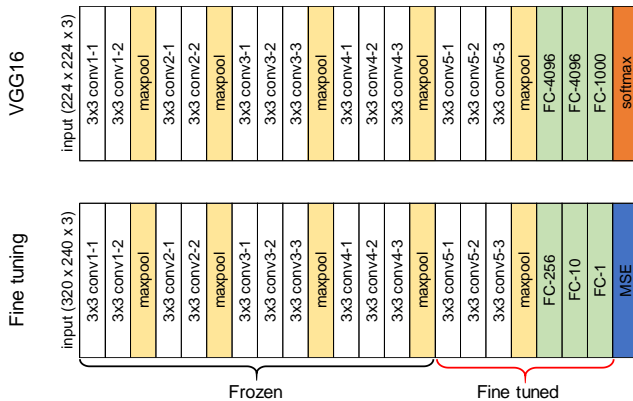


図2 VGG16のファインチューニング

4.4 実験結果

データ拡張を行った画像をファインチューニングにて学習し、検証を行った結果を図3に示す。図の縦軸は結晶粒径(μm)の平均絶対誤差であり、横軸は epoch 数、青色の線は訓練データの誤差、橙色の線は検証データの誤差を表す。検証データの誤差は振動しているものの、訓練データの誤差は $1.2\mu\text{m}$ 、検証データの誤差は $1.5\mu\text{m}$ であった。学習済みモデルを用いて、得られた評価データの誤差は $1.3\mu\text{m}$ であった。評価データについて作業者を変えて切断法を行い、結晶粒径を再測定したところ、誤差は $2.0\mu\text{m}$ であった。

評価データの誤差が作業者による測定のばらつき以下であることを考えれば、析出物、晶出物を含む金属組織について、結晶粒径を自動測定する手法の構築が実現できた。ただし、検証データの誤差を詳しく見てみると、結晶粒径が大きいほど誤差が大きくなる傾向が明らかになった。その原因としては、クロップでデータ拡張した画像の正解データは、クロップ率で除した結晶粒径の近似値を用いているため、クロップ率が小さく結晶粒径が大きいほど訓練データの信頼性が低いと考えられる。




図3 学習グラフ

5. まとめと今後の課題

本研究では、析出物、晶出物を含む金属組織について、切断法を自動化して、結晶粒径を測定できる手法の開発するため、金属組織画像に対して結晶粒径測定に適したデータ拡張の提案を行い、作業者による測定のばらつき以下の精度で End-to-End に結晶粒径を自動推定する手法を実現した。今後の課題としては、適切なクロップ率を検討することで、より高精度な結晶粒径の自動推定を達成できると考えている。また、本研究では事前に検討から外した色空間を操作するデータ拡張や、ノイズを加えるデータ拡張についても検証実験を行う価値があると考えている。

謝辞

本研究の実施にあたり、データ収集にご協力を頂きました大阪府立大学の東健司教授、瀧川順庸教授に深く感謝いたします。

参考文献

- [1] H. Peregrina-Barreto, I.R. Terol-Villalobos, J.J. Rangel-Magdaleno, A.M. Herrera-Navarro, L.A. Morales-Hernández and F. Manríquez-Guerrero, “Automatic grain size determination in microstructures using image processing”, *Measurement*, 46 (2013), 249.
- [2] S. M. Azimi, D. Britz, M. Engstler, M. Fritz and F. Mücklich, “Advanced Steel Microstructural Classification by Deep Learning Methods.” *Scientific Reports*, 8 (2018), 2128.
- [3] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition”, *The 3rd International Conference on Learning Representations* (2015).
- [4] F. Ajioka, Z.L. Wang, T. Ogawa and Y. Adachi, “Development of High Accuracy Segmentation Model for Microstructure of Steel by Deep Learning.” *ISIJ International*, 60 (2020), 954.
- [5] O. Ronneberger, P. Fischer and T. Brox, “U-net: Convolutional networks for biomedical image segmentation.” *International Conference on Medical Image Computing and Computer-Assisted Intervention*, (2015), 234
- [6] Google 画像検索, “<https://www.google.co.jp/imghp/>”
- [7] A.W. Thompson, “Calculation of true volume grain diameter”, *Metallography*, 5, (1972), 366.