

技術資料



ディープラーニングを用いたNi基超合金におけるSEM写真の相識別

原田絵美^{*1}, 森 大輔^{*2}

Phase Classification for Ni-Based Superalloys SEM Images Using Deep Learning

Emi HARATA and Daisuke MORI

Synopsis

Ni-based superalloys have excellent high temperature properties due to Ni_3Al (γ') precipitation from matrix (γ). It is important for material development to measure the amount of γ' precipitation, because it affects the properties greatly. We classify SEM images of Ni-based superalloys into γ' and γ by hand to measure the amount of γ' . However, there is variation in the classification results among operators. In this paper, we automated the classification by image processing and deep learning to eliminate variation. As a result, automation was achieved using ensemble learning of γ' and γ/γ' boundary, and we became able to measure the amount of γ' regardless of the operator.

1. 緒言

Ni 基超合金^{1)~5)}は、航空機エンジンや発電設備のタービンプレードに利用されるため、優れた高温強度が必要となる。Fig. 1 は、Ni 基超合金の走査型電子顕微鏡 (SEM) 写真である。Ni 基超合金では、時効処理を施すことで、Fig. 1 のように母相 (γ) から Ni_3Al 相 (γ') が析出する。この γ' 析出により、高温強度を発現させることができる。

γ' 析出量の測定は、Ni 基超合金の材料開発において重要となる。これは、 γ' 析出量が熱処理条件や化学組成などで変化し、高温強度に大きな影響を与えるためである。Fig. 2 は、 γ' 析出率とクリーブ破断寿命との関係を示したグラフである¹⁾。クリーブ破断寿命は γ' 析出率の増加に伴って延び、ある γ' 析出率でピーク値をとると、

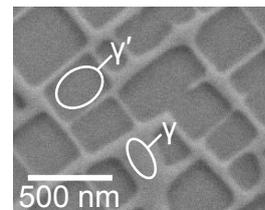


Fig. 1. Microstructure of Ni-based superalloy.

それ以降は短くなる。大同特殊鋼(株)でも Ni 基超合金の材料開発において、Fig. 2 のような γ' 析出率と高温強度との関係を重視し、研究している。

γ' 析出率は、SEM 写真から測定することができる⁴⁾。Fig. 3 は、作業者が SEM 写真内の γ と γ' を目視で識別し、手動で塗り分けた画像である。この画像から白色部の面積率を求めることで、 γ' 析出率を測定することができる。

2022年10月6日 受付

* 1 大同特殊鋼(株)技術開発研究所 (Corporate Research & Development Center, Daido Steel Co., Ltd.)

* 2 大同特殊鋼(株)技術開発研究所, 技術士(経営工学) (P.E.Jp, Corporate Research & Development Center, Daido Steel Co., Ltd.)

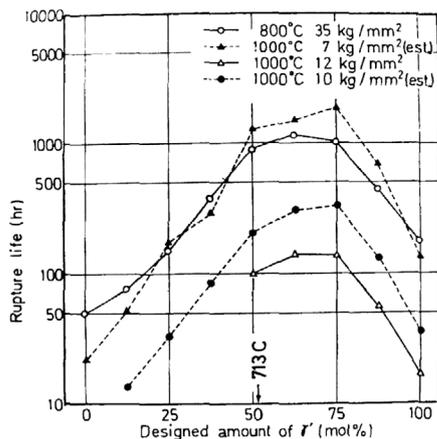


Fig. 2. Relationship between amount of γ' and creep rupture life¹⁾.

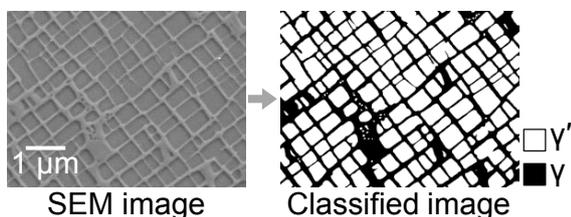


Fig. 3. Image classified into γ' and γ by manual work.

しかし、この手法で γ' 析出率を測定すると、作業者の技量により結果にばらつきが生じる。Fig. 4 は、作業者 A と B の γ' 識別結果である。A は識別に熟練した作業者で、B は経験の浅い作業者である。作業者 B は、A に比べて γ' を多く見積もっており、 γ' 析出率の差は 10 % 以上となった。Fig. 4 のようなばらつきが生じると、 γ' 析出率と高温強度との関係を、正確に解析できないおそれがある。

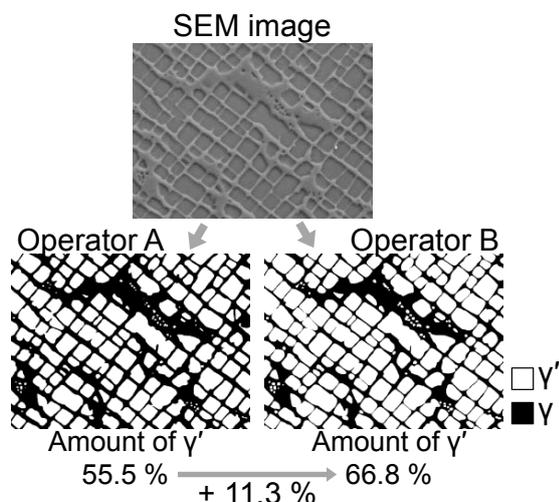


Fig. 4. Difference of classification between operator A and operator B.

そこで本稿では、作業者間における γ' 析出率の測定ばらつきを無くするために、画像処理とディープラーニング（以下、DL という）を用いた、 γ' 識別の自動化に着手した。今回は、Fig. 4 の熟練した作業者 A による識別を正として、開発を進めた。目標精度は、作業者 A が手動で γ' 識別した画像と、自動で γ' 識別した画像を比較して、

- ① γ' 析出率の差が $\pm 5\%$ 以内
- ② γ' の Dice 係数が 0.95 以上

とした。ここで、Dice 係数^{6), 7)} は式(1) で算出され、1 に近いほど画像の一致率が高いことを表す。

$$D = \frac{1 + 2 \sum_i t_i p_i}{1 + \sum_i t_i + \sum_i p_i} \tag{1}$$

D: Dice 係数

t_i : 手動で識別した画像の、 i 番目の画素値

p_i : 自動で識別した画像の、 i 番目の画素値

γ は画素値 0、 γ' は画素値 1 とする。

目標①と②は、自動での γ' 識別のばらつきが、作業者 A による識別のばらつきより小さくなるように設定した。作業者 A が同じ SEM 写真で γ' 識別を 2 回実施し、1 回目と 2 回目とを比較することで、作業者 A のばらつきを測定した。測定には、複数の SEM 写真から任意の範囲 (512×512 ピクセル $\approx 2.4 \times 2.4 \mu\text{m}$) を 4 枚切り出して利用した。作業者 A のばらつきを 4 枚で確認した結果、1 回目と 2 回目で γ' 析出率の差が最大 5%、Dice 係数が最低 0.95 となった。この結果から、目標①と②を決定した。

2. 画像処理の適用

画像処理は、組織写真の解析によく使われる手法である。例えば文献 8) では、Al-Cu 合金の铸造組織写真にフーリエ変換を適用し、デンドライト 2 次アーム間隔や凝固の進行方向を測定している。また文献 9) では、鉄鋼の結晶粒写真を二値化し、結晶粒径の分布を測定している。

本稿でも、画像処理を用いた γ' 識別を試みた。Fig. 5 は、実施した画像処理の手順である。まず、SEM 写真をぼかすことでホワイトノイズを除去し、コントラストを調整した。その後、画像の小領域ごとに輝度しきい値を決めて二値化し、細かい白点や黒点を除去することで、 γ' を識別した。SEM 写真 14 枚を用い、すべて同じ条件で処理した。Fig. 6 に、結果の一例を示す。

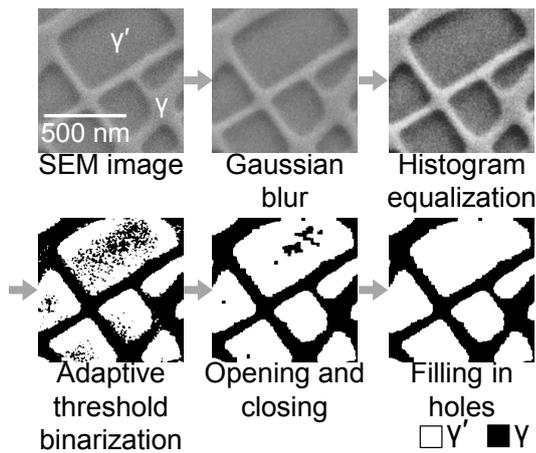


Fig. 5. Procedure of image processing.

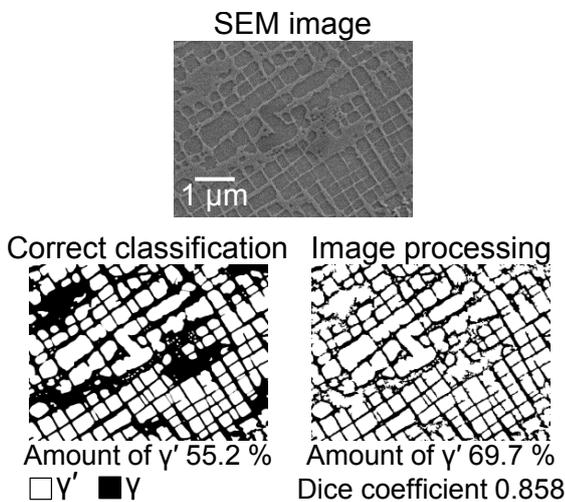


Fig. 6. Comparison between correct classification result by manual work and image processing.

Fig. 6 に示したように、画像処理では目標精度を達成することができなかった。Fig. 6 では、画像処理で識別した場合の γ' 析出率が手動で識別した場合より 14.5 % 多くなり、目標①を達成できなかった。Dice 係数も、目標②を下回っている。これ以外も、14 枚ほとんどの画像で目標精度を満たせなかった。今回の結果は、 γ と γ' の輝度差が小さいことが原因である。Fig. 7 は、Fig. 6 の SEM 写真における各相の輝度分布であり、 γ' と γ の輝度が大きく重なっていることが確認できる。つまり、輝度のしきい値で二値化すると、 γ を過剰に検出する箇所や、逆に γ' を見逃す箇所が必ず生じてしまう。また、すべての写真を同じ条件で処理することは難しい。上記の理由から、画像処理の適用は困難と判断した。

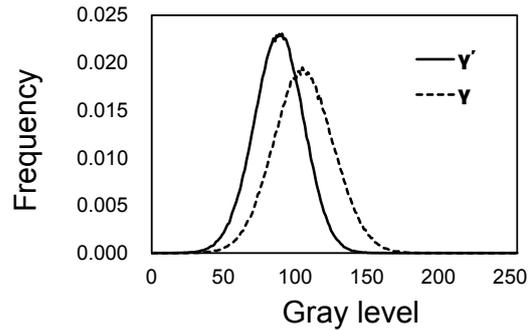


Fig. 7. Gray level histograms of Fig. 6 SEM image.

3. ディープラーニングの適用

3. 1 ディープラーニングによる γ' 識別

画像処理と同様に、DL も組織写真の解析によく使われる手法である。例えば文献 10) では、畳み込みニューラルネットワーク (Convolutional Neural Network : CNN) を利用し、鉄鋼の組織写真をフェライトやパーライトなどに分類している。文献 11) では、完全畳み込みネットワーク (Fully Convolutional Network : FCN) を利用し、鉄鋼の組織写真について、マルテンサイトやパーライトなどの相を識別している。どちらの文献も、畳み込み層をもつモデルを使用している。Fig. 8 は、畳み込み層の模式図である。例として、バツ印の画像を入力している。畳み込み層では、画像にフィルタをかけることで、画像の特徴を抽出した特徴マップを生成している。例えば、Fig. 8 のフィルタ 1 は右下がりの直線を表しており、入力画像の中で同じ特徴を持つ箇所が、白く表示された特徴マップを得ることができる。フィルタを複数枚使用することで、組織写真中の輝度や形状、テクスチャなど、複数の特徴を考慮できる。

本稿でも Ni 基超合金の SEM 写真に、DL の手法の 1 つであるセマンティックセグメンテーションを適用し、 γ' 識別を試みた。セマンティックセグメンテーションは、文献 11) にも利用されており、Fig. 9 のように、入力画像についてピクセル単位でクラスを識別する手法である。 γ' 析出率を精度良く測定するには、 γ' と γ をできるだけ細かく識別する必要があるため、本手法を適用した。また、学習には入力する組織写真に対応した、正しい出力 (教師データ) を準備する必要がある。本手法を適用した場合、手動で γ' 識別した画像を、そのまま教師データとして利用できるため、新たにデータを作成する手間を省くことができる。

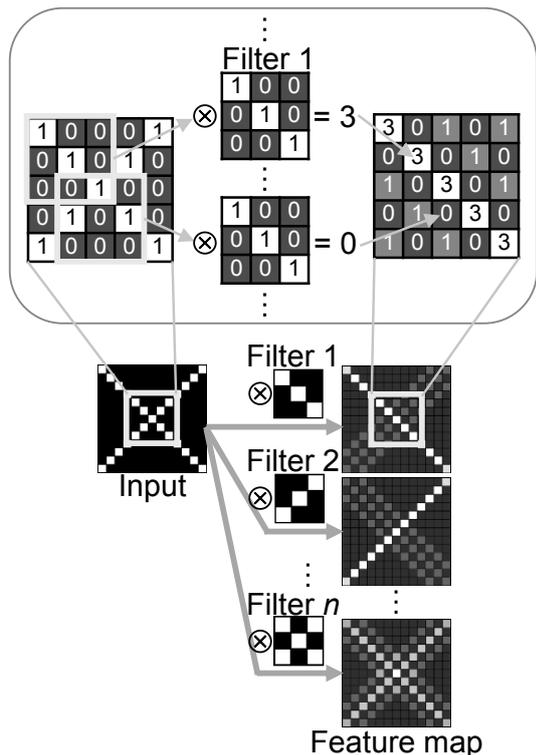


Fig. 8. Schematic diagram of convolution layer.

使用したモデルは、Fig. 10 の、U-Net^{(7), (12)} をベースとしたモデルである。U-Net は、畳み込み層で得られた特徴マップを、アップサンプリング層で合成、拡大することで、識別結果を出力している。また、U-Net では、畳み込み層とアップサンプリング層を連結している。畳み込み層における特徴マップの方が、入力画像に近いため、アップサンプリング層の特徴マップより正確な位置

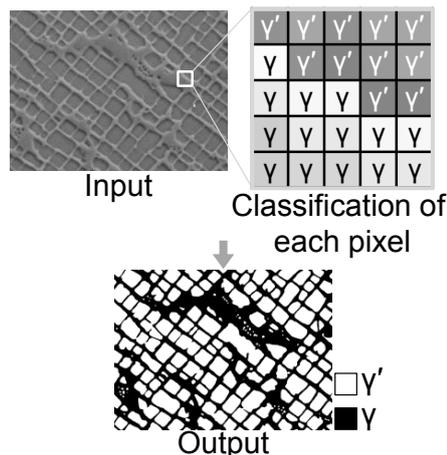


Fig. 9. Schematic diagram of semantic segmentation.

情報を有している。この位置情報を利用して、アップサンプリングの精度を向上させている。

学習条件を、Table 1 に示す。教師データは、学習データとテストデータに分けられる。学習データはモデルの学習に使用するデータであり、テストデータは学習には使用せず、学習が終了したモデルに入力して、識別精度を確認するためのデータである。テストデータには、2章で使用した14枚と同じデータを用いた。さらに、学習データ10枚から2枚を選び、検証データとした。学習は、モデルの出力と教師データとの誤差を示す損失が、小さくなるように進む。検証データは、学習中に損失の推移を確認するためのデータである。検証データの損失が最小となった時点を、学習の終了点とした。入力画像のサイズについて、学習、検証データは、Fig. 10 のよう

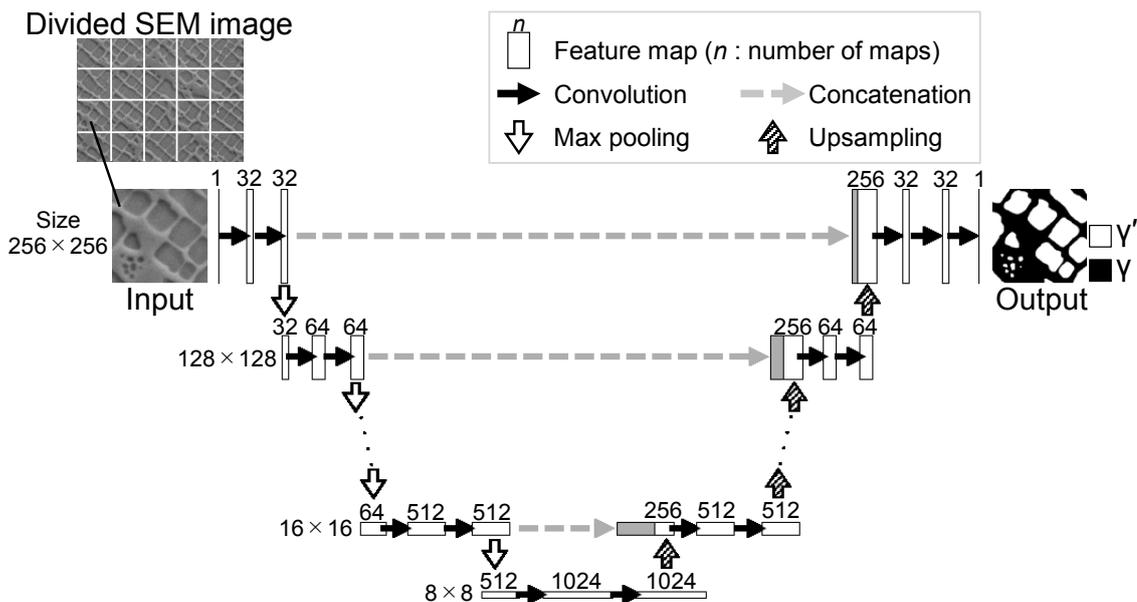


Fig. 10. Schematic diagram of model based on U-Net.

に1枚あたり20分割(256×256ピクセル≒1.2×1.2 μm)して使用した。テストデータは分割せず、そのまま入力した。

今回の学習では、交差検証を実施した。交差検証は、学習データと検証データの組合せを変えて、複数のモデルを作成する手法である。学習データ10枚すべてを検証データとして利用できるように、5つのモデルを作成した。Fig. 11のように、5つのモデルについて、出力の平均をとり、二値化した画像を、最終的な出力とした。交差検証で得られたモデルの平均をとることで、汎化性能を向上させることができる。

Table 1. Calculation conditions.

Model	Based on U-Net
Amount of training data	200 (10 x 20-division) Training : Validation = 4 : 1
Amount of test data	14 (not divided)
Optimizer	Adam ¹³⁾ ($\alpha = 0.001, \beta_1 = 0.900, \beta_2 = 0.999, \epsilon = 1 \times 10^{-8}$)
Loss	Dice loss
Data augmentation	<ul style="list-style-type: none"> ・Change in gray level (x0.8 ~ 1.1) ・Scaling (x0.8 ~ 1.2) ・Rotation (-20 ~ 20 degrees)

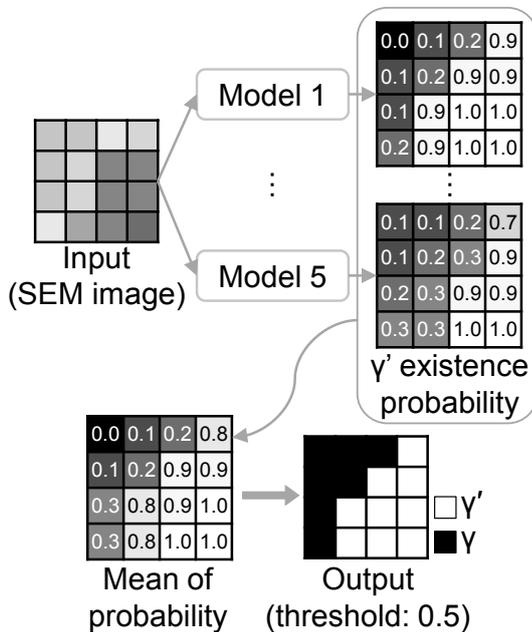


Fig. 11. Procedure of generating output.

損失関数には、式(2)のDice損失関数^{6, 7)}を使用した。式(2)が小さくなる、つまりDice係数が1に近づくよう学習した。

$$L = 1 - D = 1 - \frac{1 + 2 \sum_i t_i p_i}{1 + \sum_i t_i + \sum_i p_i} \quad (2)$$

L: Dice損失

Fig. 12は、データ拡張の様式図である。測定対象のSEM写真では、写真の輝度、サイズ、傾きが変化しうると考え、この3つのパラメータについて、ランダムに変更を加え、学習データを水増しした。以上の条件で構築したモデルの、 γ' 識別結果をFig. 13に示す。Fig. 13は、Fig. 6のSEM写真を識別した結果である。

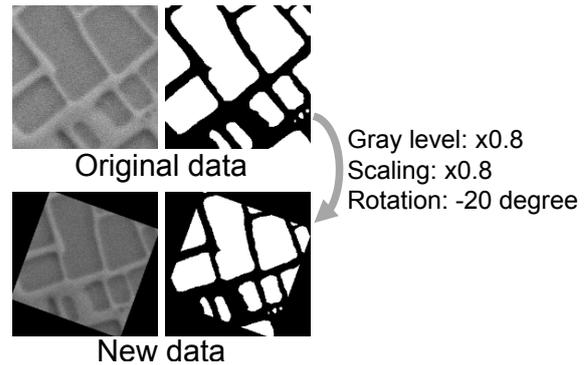


Fig. 12. Example of data augmentation.

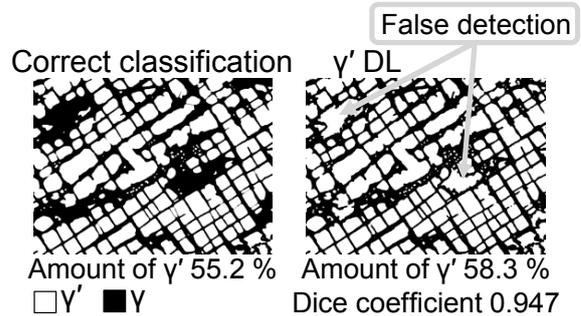


Fig. 13. Comparison between classification results by correct manual work and γ' DL.

3. 2 ディープラーニングによる相界面識別

Fig. 6とFig. 13で使用したSEM写真は、 γ' と γ の輝度が近いにもかかわらず、目視で γ' を識別できている。これは、 γ' と γ との相界面を認識し、 γ' 識別に利用しているためだと推定した。Fig. 14は、SEM写真の断面模式図である。相界面には、腐食によって段差ができるため、影が生じる。この特徴を活用することで、 γ' を識別できると考えた。

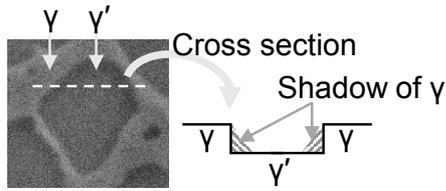


Fig. 14. Cross section of etched microstructure.

3. 1節と同様に、Ni基超合金のSEM写真にセマンティックセグメンテーションを適用し、 γ' と γ の相界面識別を試みた。学習データはFig. 15のように、手動で γ' 識別した画像から、画像処理で相界面のみを抽出して作成した。学習は、3. 1節と同じ条件、モデルで実施した。Fig. 16に、構築したモデルによる相界面の識別結果を示す。入力したSEM写真は、Fig. 6, Fig. 13と同じものである。

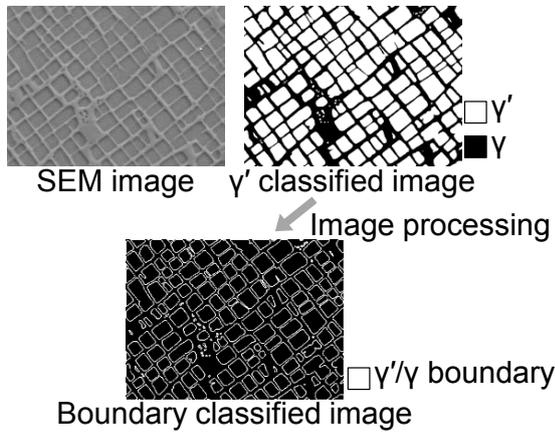


Fig. 15. Training data of γ' and γ boundary.

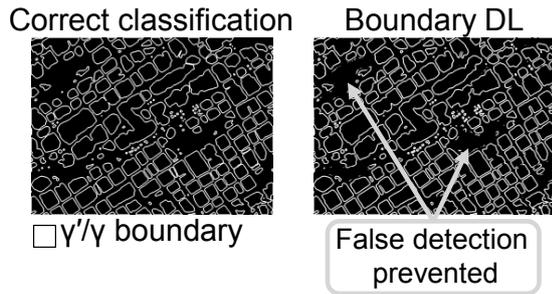


Fig. 16. Comparison between boundary classification results by correct manual work and DL.

Fig. 16のように、相界面を学習したモデルを利用することで、3. 1節のモデル (Fig. 13) よりも γ' の過剰な検出を抑制できる可能性がある。相界面を識別できれば、Fig. 17(a)のように線の内側を γ' とみなし、 γ' 析出率を測定できる。しかし、Fig. 17(b)のように、線の閉じていない相界面が存在した。この場合、線の端点がどの端点と、どのようにつながっているかを、自動で判断す

ることは難しい。そのため、このモデルでは γ' の領域を判断できず、 γ' 析出率を測定できなかった。

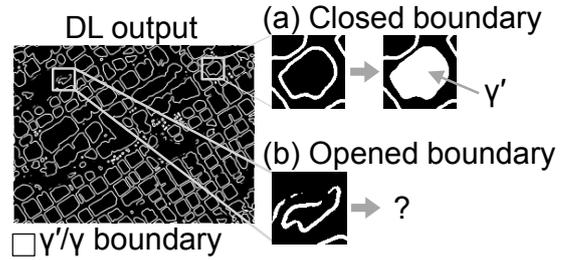


Fig. 17. (a) Closed and (b) open boundary on classification result of DL.

4. アンサンブル学習の適用

3章で構築した2つのモデルには、 γ' 識別に得手不得手がそれぞれ存在する。3. 1節のモデル (以下、モデルAという) は、 γ' の領域を塗りつぶして出力するため、 γ' 析出率をそのまま測定できる。しかし、 γ' を過剰に検出して目標未達となった。一方で3. 2節のモデル (以下、モデルBという) は、 γ' の過剰な検出を抑制することができた。しかし、相界面が一部開いており、 γ' 析出率を測定できなかった。そこで、両モデルの欠点を補完する手法を考えた。

3章のモデルについて、アンサンブル学習^{14), 15)}を適用することで、 γ' 識別の精度向上を試みた。アンサンブル学習は、複数のモデルを融合することで、単一のモデルよりも精度を向上させる手法である。今回は、モデルAとモデルBの出力を、Fig. 18のように統合した。まず、両モデルの出力を重ね合わせ、モデルAが γ' と識別した各領域について、式(3)の被覆率を算出した。この被覆率が0.5以上の場合、モデルA、モデルBともに γ' と識別したとみなし、 γ' として出力した。逆に、被覆率が0.5未満の場合、モデルAが γ' を過剰に検出しているとみなし、 γ に塗り替えて出力した。Fig. 6, Fig. 13と同じSEM写真に適用した結果を、Fig. 19に示す。

$$C = \frac{l_B}{l_A} \tag{3}$$

C: 被覆率

l_A : モデルAが識別した γ' の周長

l_B : モデルAが識別した γ' に接する、モデルBが識別した相界面の長さ

Fig. 19のように、アンサンブル学習では、モデルA

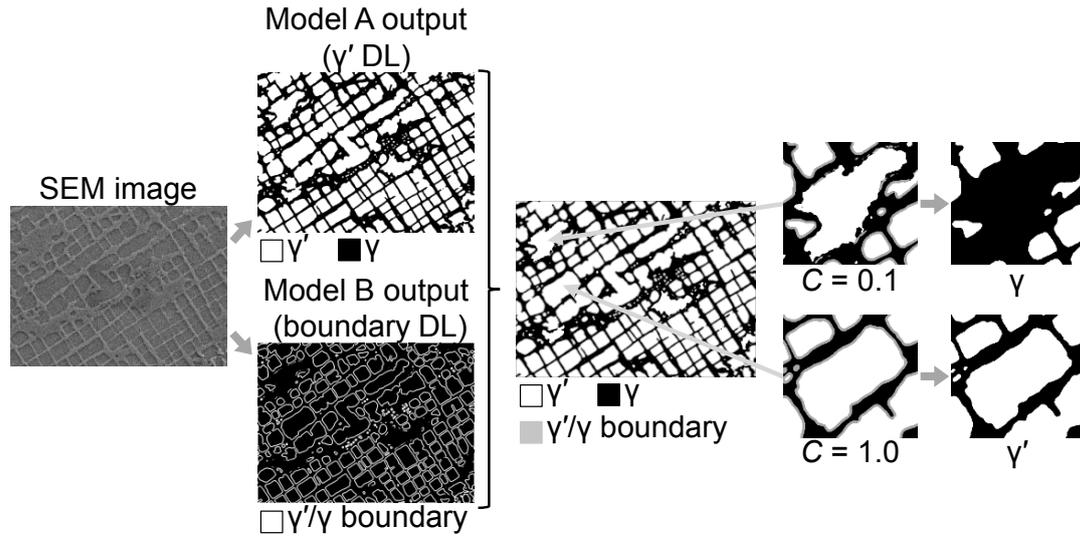


Fig. 18. Combination of outputs from each model.

のみの場合 (Fig. 13) よりも、 γ' 析出率の測定精度が向上した。つまり、モデル B で出力される相界面の情報により、モデル A で過剰に検出した γ' を修正することができた。Table 2 は、テストデータ 14 枚に各手法を適用した結果をまとめた表である。手動で γ' 識別した画像と比較した場合の、① γ' 析出率の差 (絶対値)、② Dice 係数について、平均値、精度が最良の値、最悪の値を記載している。Table 2 のとおり、アンサンブル学習により、すべてのテストデータについて目標精度を達成することができた。

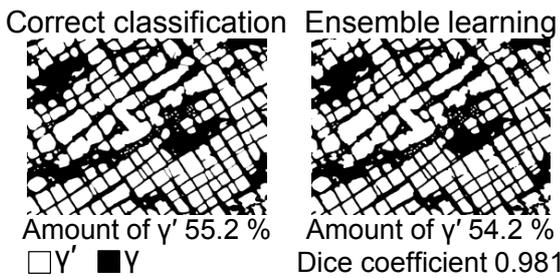


Fig. 19. Comparison between classification results by correct manual work and ensemble learning.

Table 2. Results of each method.

	Image processing		γ' DL		Ensemble learning	
	①	②	①	②	①	②
Mean	8.5	0.893	1.6	0.968	1.3	0.972
Best	3.7	0.922	0.2	0.985	0.1	0.988
Worst	14.6	0.858	4.4	0.947	4.4	0.955

① Absolute error of γ' amount %
 ② Dice coefficient

5. 結 言

本稿では、Ni 基超合金の SEM 写真について、画像処理と DL を利用し、 γ' 識別の自動化を試みた。Table 2 のとおり、DL を利用することで、識別精度が画像処理から大きく向上した。さらに、アンサンブル学習により、相界面の特徴を考慮することで、目標精度を満たすことができた。今回の開発で、手動での γ' 識別が不要となり、作業者の技量によらない γ' 析出率測定が可能となった。実用化へ向けて継続中であり、製品検査への適用を目指している。

(文 献)

- 1) 原田広史, 山崎道夫, 小泉裕: 鉄と鋼, 65(1979), 1049.
- 2) Y. Ro, Y. Koizumi and H. Harada: Mater. Sci. Eng. A, 223(1997), 59.
- 3) T. Murakumo, T. Kobayashi, Y. Koizumi and H. Harada: Acta Mater., 52(2004), 3737.
- 4) T. M. Smith, P. Bonacuse, J. Sosa, M. Kulis and L. Evans: Mater. Charact., 140(2018), 86.
- 5) F. G. Caballero: Encyclopedia of Materials: Metals and Alloys, Elsevier, 2022, Volume 1, 294.
- 6) F. Milletari, N. Navab and S. -A. Ahmadi: International Conference on 3DV Proc., 4(2016), 565.
- 7) 藤田一弥, 高原歩: 実装ディープラーニング, オーム社, 2016, 168.
- 8) 舟窪辰也, 新山英輔: 軽金属, 40(1990), 445.
- 9) V. García-García, I. Mejía and F. Reyes-Calderón:

Mater. Charact., 147(2019), 1.

- 10) 足立吉隆, 田口茂樹, 弘川奨悟:鉄と鋼, 102(2016), 722.
- 11) S. M. Azimi, D. Britz, M. Engstler, M. Fritz and F. Mücklich: Sci. Rep., 8(2018), 2128.
- 12) O. Ronneberger, P. Fischer and T. Brox: MICCAI Proc. Part III, 18(2015), 234.
- 13) D. P. Kingma and J. L. Ba: ICLR Proc., 3(2015), Adam: A Method for Stochastic Optimization.
- 14) L. Breiman: Mach. Learn., 24(1996), 123.
- 15) 上田修功: コンピュータビジョンとイメージメディア, 46(2005), 11.



原田絵美



森 大輔