研究論文

ディープラーニングによる鋼の結晶粒度の測定

斎藤　雄治*

Measurement of Steel Apparent Grain Size using Deeplearning

SAITO Yuji*

抄　　録

ディープラーニングによる画像認識を用いた鋼の結晶粒度の測定方法を提案した。データセットに用いた任意の粒度番号に対する組織画像は，顕微鏡観察で得られた組織画像を種々のサイズにトリミングして作成した。データセットを Keras の VGG16 モデルで学習・検証した結果，検証データに対して 94%以上の高い正解率が得られた。さらに，学習に用いていない組織画像を学習終了後のモデルで推論した結果，推論値は JIS の比較法・切断法による測定値とほぼ一致した。

1. 緒　　言

鋼材などの金属材料の多くは無数の結晶粒からできている。同じ金属材料においても熱処理などによって結晶粒の大きさすなわち結晶粒度が変化すると，材料の機械的性質も変化する。このため，結晶粒度は材料の機械的性質を推測する重要な手掛かりになる。

さて，鋼の結晶粒度の評価方法として， JIS G 0551（2020） 鋼－結晶粒度の顕微鏡試験方法[1]（以下， JIS と呼ぶ）がある。この規格では，試料を結晶粒界が明瞭になるようにエッチングした後，顕微鏡観察で得られる組織画像から，次式 (1) で定義される粒度番号 G を求める方法を規定している。

$$m = 8 \times 2^{G} \quad \cdots (1)$$

ここで，m は観察面の 1mm^2 あたりの平均結晶粒数を表す。

式 (1) の粒度番号 G を求める方法として， JIS では次のア～ウを規定している。

ア　結晶粒度標準図との比較による方法（比較法）

イ　単位面積当たりの結晶粒数を計数する方法

ウ　試験線 1mm 当たりの捕捉する結晶粒数又は交点の数を計数する方法（切断法）

作業者がこれらの方法から粒度番号を求める場合，アは迅速に求まるが結果にばらつきを生じやすく，イとウは正確に求まるが計数に時間を要する。このため最近では，省力化や個人誤差の少ない測定を目的として，市販のアプリケーションを利用した測定も行われている。

一方，現在では画像処理やディープラーニングの画像認識をするための無償ツールの利用も盛んである。本研究所においてもツールを用いた金属破断面や金属組織の画像分類[2),3)]などの実施例がある。

本研究では，ディープラーニングの画像認識のツールを用いて鋼の結晶粒度の測定を行った。はじめにデータセットとなる種々の粒度番号に対する組織画像をトリミングによって作成し，次にデータセットをディープラーニングのモデルで学習させた。さらに，学習終了後のモデルで学習に用いていない組織画像の粒度番号を推

＊　中越技術支援センター

論させて， JIS の方法による測定結果と比較した。本稿ではこれらの内容について報告する。

2. データセットの作成方法

2.1 種々の粒度番号に対する組織画像の作成

ここでは，粒度番号Gが既知の試料の金属組織を倍率T，サイズ$x \times y$（横方向×縦方向）で多数枚撮影した画像について考える。

これらの画像を倍率 100 倍の画像として見たときの見かけの粒度番号を G_0 とすると， G_0 は JIS の式 (3) において$M=$ G_0 ， $g = T$と置くことによって次式で表せる。

$$G_0 = G - 6.64\log(T/100) \quad \cdots (2)$$

これによって，撮影した画像を粒度番号 G_0 ，サイズ$x \times y$の画像として扱うことができる。

ここで，画像のサイズxおよびyは式 (1) の $\sqrt{m}$ と比例関係にあると仮定して，粒度番号 G_0 ，サイズ$x \times y$の画像をトリミングして任意の粒度番号 G_1 ，サイズ$x_1 \times y_1$の画像を作成する。

なお，トリミングの際， x と y の比率は変えないこととする。

式 (1) において， G_0 および G_1 に対するmをそれぞれ m_0 および m_1 とすると，次式が成り立つ。

$$x_1 : \sqrt{m_1} = x : \sqrt{m_0} \quad \cdots (3\text{-}1)$$

$$y_1 : \sqrt{m_1} = y : \sqrt{m_0} \quad \cdots (3\text{-}2)$$

これに，式 (1) の関係を代入して整理すると

$$x_1 = \sqrt{m_1/m_0}\, x = 2^{(G_1 - G_0)/2} x \quad \cdots (4\text{-}1)$$

$$y_1 = \sqrt{m_1/m_0}\, y = 2^{(G_1 - G_0)/2} y \quad \cdots (4\text{-}2)$$

を得る。式 (4-1)， (4-2) から，種々の粒度番号 G_1 に相当する画像のトリミングサイズ$x_1 \times y_1$を求めることができる。

2.2 試料の粒度番号

2.1 節の方法で任意の粒度番号 G_1 に相当する組織画像のトリミングサイズ$x_1 \times y_1$を決定するには，あらかじめ試料の粒度番号Gを求める必要がある。

このため本研究では，表 1 に示す試料 A， B について撮影した組織画像を用いて， JIS の比較法および切断法によって粒度番号を測定した。表 1 に示す試料はいずれも直径 19mm× 長さ 20mm の機械構造用合金鋼 SCM435 である。

表 1　試料

試料	熱処理
A	850℃×15 分保持後油冷
B	850℃×15 分保持後油冷 ＋600℃×1 時間保持後水冷

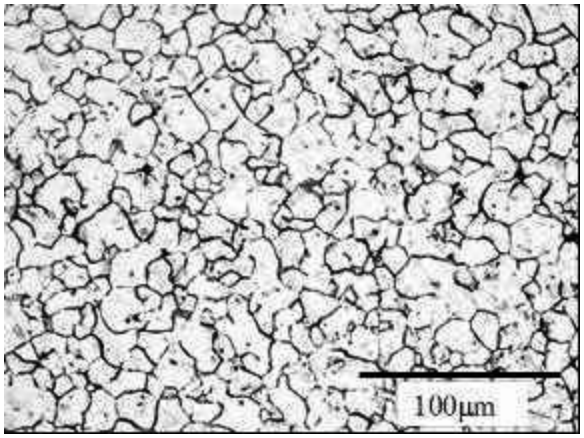

(a)　試料 A

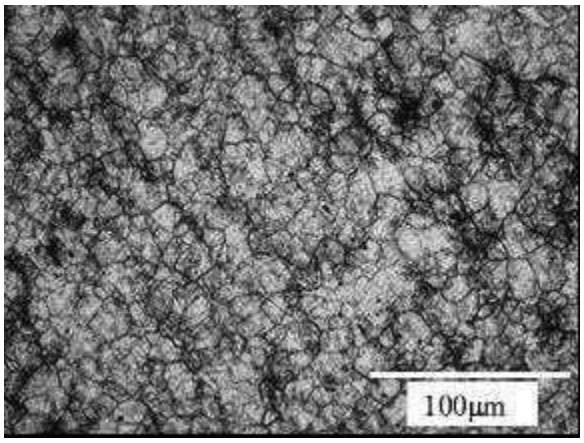

(b)　試料 B

図 1　粒度番号を測定した組織画像の一例

組織画像は，試料の断面を鏡面研磨して（株）山本科学工具研究社製 AGS エッチング液で結晶粒界を現出してから，金属顕微鏡を用いて倍率 500 倍で撮影した。金属顕微鏡にはオリンパス（株）製 BX53MRF-S(D)を用いた。

表 2　試料の粒度番号

試料	比較法	切断法
A	9.6±0.5	9.4
B	10.0±0.9	9.8

撮影した組織画像の一例を図 1 に示す。（a）の試料 A は基地組織の腐食が少なく結晶粒界が明瞭に認められるが，（b）の試料 B は基地組織が腐食され結晶粒界が不明瞭になっている。

試料 A，B の組織画像から求めた粒度番号を表 2 に示す。ここで，比較法は10視野の平均値とその95%信頼限界（ t 分布），切断法は 5 視野の平均値である。これらの結果のうち，本研究では切断法から得られた粒度番号を 2.1 節の粒度番号 G として画像のトリミングサイズを決定した。

なお，切断法の粒度番号は画像処理[4]によって求めた。

2.3　データセット

2.2 節の試料 A，B について，倍率 $T = 200$ 倍で 100 枚の組織画像（画像サイズ $x \times y = 1920 \times 1440$）を撮影した。それらを 2.1 節の方法でトリミングして，粒度番号 $G_1 = 2.0 \sim 7.0$（ 0.5 刻み，11種類）に相当する組織画像を得た。トリミング後の試料 A，B の組織画像の一例を図 2 に示す。ここで，画像の一片の長さを105mmにすると実際の画像の大きさとなる。

このような画像から，次に示す a ～ c のデータセットを作成した。

a ：試料 A の画像（11種類× 100 枚＝1100枚）
b ：試料 B の画像（11種類× 100 枚＝1100枚）
c ：試料 A と B の画像（11種類× 200 枚＝2200 枚）

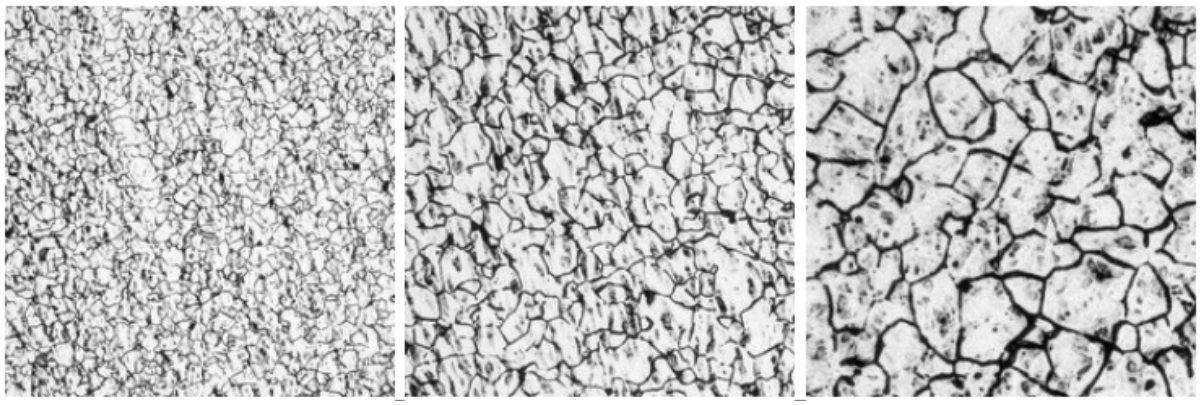

(a)　試料 A （左：粒度番号 7.0，中：粒度番号 5.0，右：粒度番号 3.0）

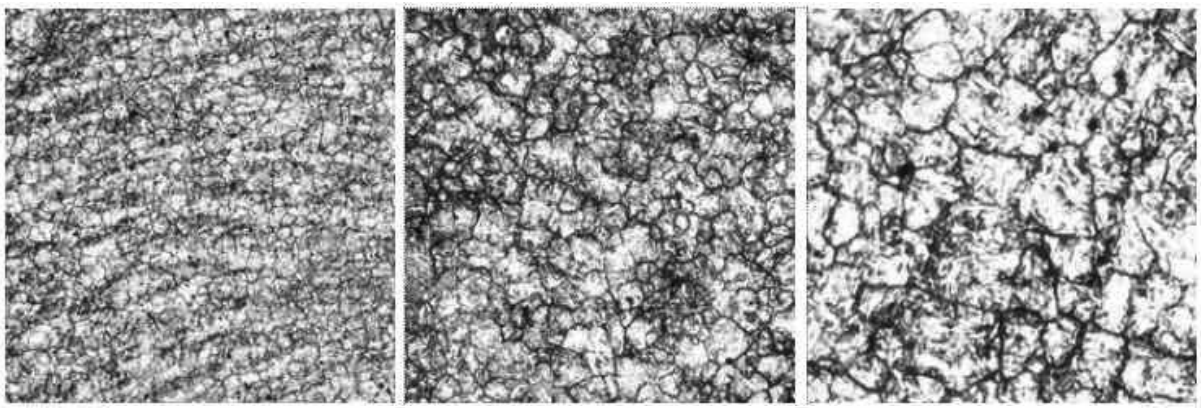

(b)　試料 B （左：粒度番号 7.0，中：粒度番号 5.0，右：粒度番号 3.0）

図 2　トリミング後の組織画像の一例

ここで，データセット a は結晶粒界が明瞭な画像， b は結晶粒界が不明瞭な画像， c は結晶粒界が明瞭な画像と不明瞭な画像の組み合わせとなる。

なお，データセットの画像については正方形にトリミングおよび画像サイズを 224 × 224 に変更後， 3 節の学習と検証に用いた。

3. ディープラーニングによる学習と検証

2.3 節のデータセット a ， b および c について，ニューラルネットワークのライブラリである Keras[5] の VGG16[6] というモデルで表 3 の条件によって学習・検証した。データセットにおいて，学習データと検証データの比率は 8 ： 2 とした。以下では，データセット a ， b および c で学習したモデルをそれぞれモデル①，②および③と呼ぶ。

図 3 に，各モデルの学習曲線を示す。図には学習データおよび検証データについて，学習回数に対する正解率を示した。図3(a)のモデル①は少ない学習回数で高い正解率が得られているが，図3(b)のモデル②は学習回数を多くしても高い正解率が得られにくく，図3(c)のモデル③はモデル①と②の中間の正解率となっていることが分かる。これによって，結晶粒界が明瞭な画像からなるデータセットのほうが結晶粒の

表 3　学習・検証の条件

モデル	VGG16（Imagenet 学習済み）
学習方法	ファインチューニング （最後の畳込み層以降を学習）
入力画像サイズ	224×224
プーリング	Maxpooling
活性化関数	Relu, Softmax
最適化アルゴリズム	Adam
誤差関数	多クラス交差エントロピ
学習率	5×10^{-5}：学習回数 100 まで 1×10^{-6}：学習回数 101 以降
ドロップアウト率	0.5
バッチサイズ	32
学習回数	150
学習用画像の水増し	チャンネルシフト

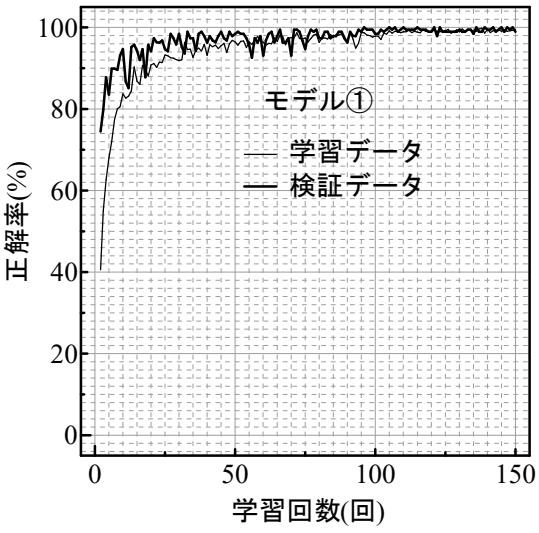

(a) モデル①

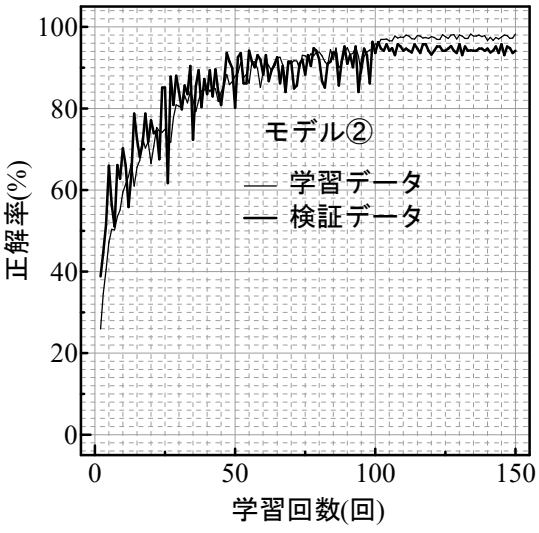

(b) モデル②

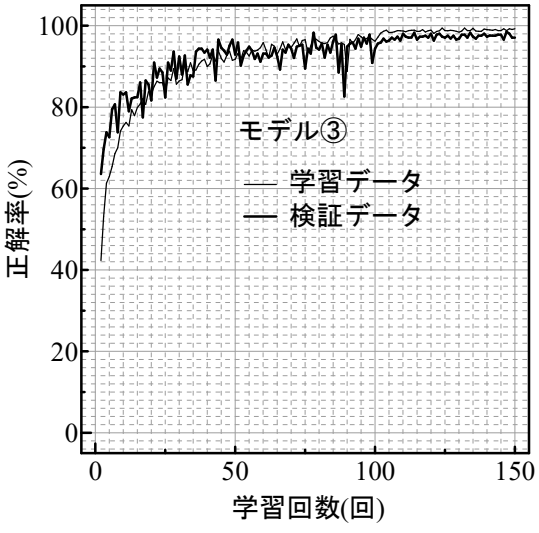

(c) モデル③

図 3　学習曲線

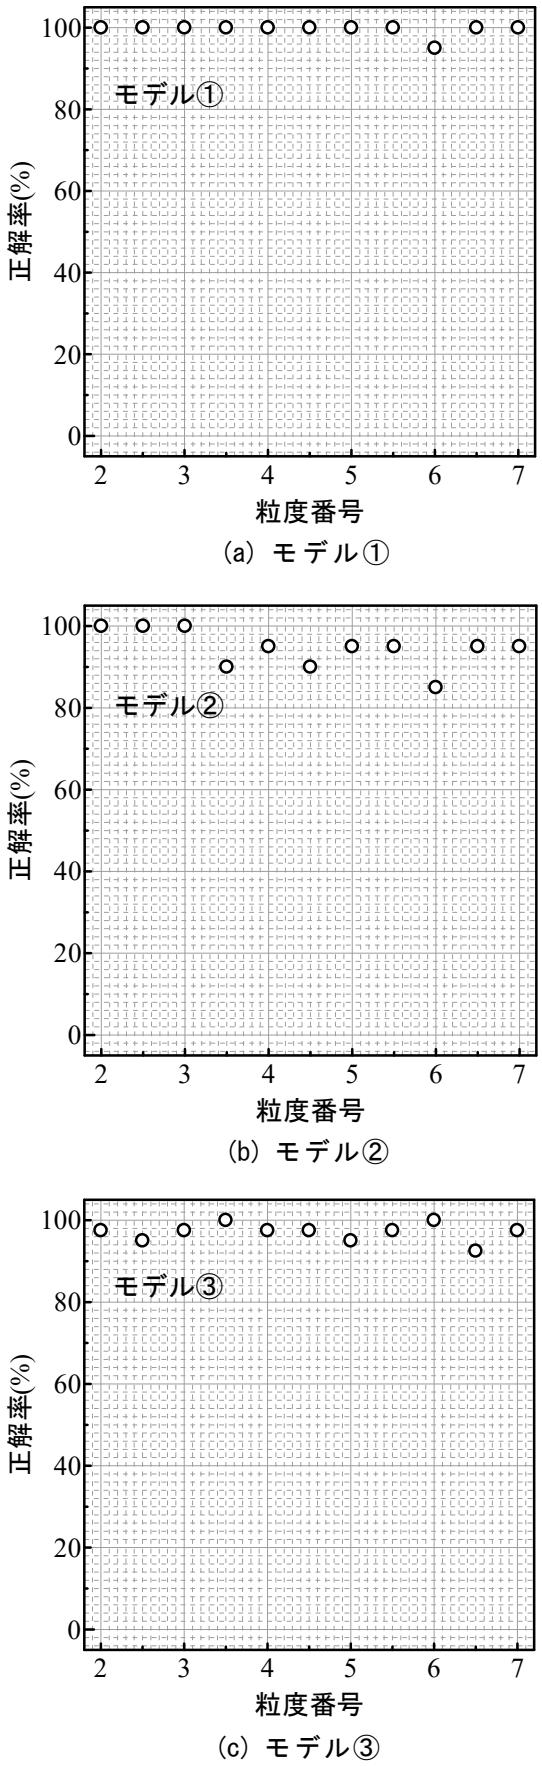

図 4　粒度番号に対する検証データの正解率

表 4　各モデルから得られた試料の粒度番号の推論値

試料	モデル①	モデル②	モデル③
A	9.4±0.6	9.3±0.6	9.4±0.6
B	10.6±1.0	10.2±0.8	10.2±0.8

大きさの違いをよく学習していることが推察される。学習終了後の検証データの正解率は，モデル①は99%，モデル②は94%，モデル③は97%となった。

ここで，学習終了後の検証データの正解率を粒度番号に対してプロットした結果を図 4 に示す。各結晶番号に対して，図4(a)のモデル①は95%以上，図4(b)のモデル②は85%以上，図4(c)のモデル③は92.5 %以上の正解率が得られていることが分かる。

4.　ディープラーニングによる粒度番号の推論

2.2 節で粒度番号の測定に用いた組織画像（倍率 500 倍，各試料につき10枚）について，正方形にトリミングおよび 224 × 224 にリサイズ後，学習終了後のモデルで粒度番号を推論した。

表 4 に結果を示す。表において，記号 ± の前後の数値は推論値の平均値とその95%信頼限界（t 分布）を表す。表 4 のモデル①～③の推論値は，表 2 に示した JIS の比較法および切断法による測定値とほぼ一致していることが分かる。

なお，モデル①～③の推論で得られる結果は倍率 100 倍の画像に対する値であるため，倍率 500 倍の画像に対しては，モデルから得られた推論値に JIS による修正値 4.6 を加えている。

また，本報告書の結果については当研究所のホームページに掲載している [7),8)] 。

5.　結　　言

(1) 組織画像を種々のサイズにトリミングして任意の粒度番号に対する組織画像を作成する方法を示した。

(2) 上記 (1) の方法から作成したデータセットに対して， Keras の VGG16 モデルで学習

・検証した結果，検証データに対して94％以上の高い正解率が得られた。

(3) 上記 (2) のモデルによる推論結果は， JIS の比較法および切断法による測定結果とほぼ一致した。

参考文献

1) 日本規格協会 , JIS G0551 （2020） 鋼－結晶粒度の顕微鏡試験方法.

2) 福嶋祐一，石澤賢太，樋口智，斎藤雄治，大野宏，“ディープラーニングによる金属破断面観察画像の分類”，工業技術研究報告書，49，2020， pp.37-41 .

3) http://www.iri.pref.niigata.jp/topics/R2/2kin3 . html ，ディープラーニングによる金属組織画像認識「新潟県工業技術総合研究所ホームページ」，2021年 2 月 4 日.

4) http://www.iri.pref.niigata.jp/topics/R2/2kin16.ht ml ， 画像処理による鋼の結晶粒度の測定について「新潟県工業技術総合研究所ホームページ」，2021年 2 月 4 日.

5) https://keras.io/ja/#keras，「 Keras Document 」，2021年 2 月 4 日.

6) https://arxiv.org/pdf/1409.1556.pdf，K.Simonyan and A.Zisserman，“Very Deep Convolutional N etworks for Large-Scale Image Recognition ”，*International Conference on Learning Representat ion* ，2015，2021年 2 月 4 日.

7) http://www.iri.pref.niigata.jp/topics/R2/2kin19. ht ml ，ディープラーニングによる金属組織の結晶粒度の評価「新潟県工業技術総合研究所ホームページ」，2021年 2 月 4 日.

8) http://www.iri.pref.niigata.jp/topics/R2/2kin26.ht ml ，ディープラーニングによる鋼の結晶粒度の測定「新潟県工業技術総合研究所ホームページ」，2021年 2 月 4 日.