ノート

ディープラーニングによる金属破断面観察画像の分類

福嶋　祐一*　石澤　賢太*　樋口　智*　斎藤　雄治*　大野　宏*

Classification of Metal Fracture Surface Observation Image using Deeplearning

FUKUSHIMA Yuichi*, ISHIZAWA Kenta*, HIGUCHI Satoru*, SAITO Yuji* and OHNO Hiroshi*

1. 緒　　言

県内で盛んな機械部品産業において部品の破損事故が発生した場合，再発防止には破損に至った原因や経緯を明らかにする必要がある。原因の解明には破断面の観察が有効であるが，破断面の特徴を捉え，原因を正しく推測するには多くの経験・知識が必要である。リソース不足が叫ばれる昨今，そのような技術者を育成することは，大変な労力が必要である。

一方，画像認識分野で高い認識精度が得られるディープラーニングが近年注目を集めており，産業利用が盛んになっている。ディープラーニングによって破断面を自動で分類することができれば，破損事故解析の省力化が期待できる。さらに，正しい分類とその特徴を示すことで，若手技術者育成にも役立つものと考えられる。

本稿では，ディープラーニングによる金属破断面観察画像の分類およびその精度向上に取り組んだ内容を示すとともに，分類の決め手となった特徴を可視化する手法について述べる。

2.　金属破断面とディープラーニング

2.1　金属破断面の種類

破損事故の要因は，負荷の種類によって静的破壊と動的破壊に大別できる。静的破壊の代表的なものとして延性破壊や脆性破壊，動的破壊の代表的なものとして疲労破壊が挙げられる。

それぞれの破断面を走査型電子顕微鏡でミクロ的に観察すると特徴的な形態を確認できる。延性破壊ではディンプル（くぼみ），脆性破壊では粒界破面（例えばロックキャンディ），疲労破壊ではストライエーションと呼ばれる多数の平行線からなる縞状模様が観察できる。他にも，粒内で脆性的に破壊が起きた場合（へき開破壊）に現れるリバーパターンなどがある。

今回は，破断面の中でも特徴的かつ実例も多いディンプル，粒界破面，ストライエーションの 3 種類を画像認識による分類の題材とした。

2.2　畳み込みニューラルネットワーク

ディープラーニングは人工知能の一分野であり，生物の脳神経回路網を計算機上でモデル化したニューラルネットワークを基盤としている。画像認識の分野では，LeCun らが提案した畳み込みニューラルネットワーク（Convolutional Neural Network：以下，CNN）[1] を基にしたネットワークがよく用いられる。図 1 に基本的な CNN の構成を示す。CNN は，入力画像が持っている特定の特徴をとらえる畳み込み層，データの次元数の削減や，画像の位置ずれなどを吸収するプーリング層，抽出した特徴量と出力とを紐づけ，分類を行う全結合層などから構成されている。出力層から誤差を逆伝搬し，正しく認識できるよう特徴量を各層に学習させることで，入力画像を正しく認識できるようになる。

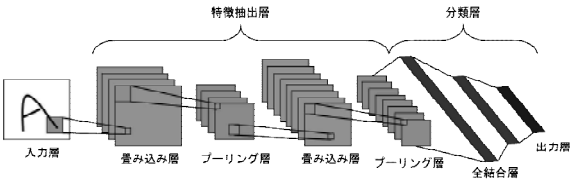

図 1　基本的な CNN の構成

* 中越技術支援センター

2.3　ディープラーニング用ツール Keras

Keras はオープンソースのディープラーニング用ソフトウェアライブラリであり，Google が開発したディープラーニング用ライブラリ TensorFlow の上位で動作するように設計されている。TensorFlow においてもニューラルネットワークの構築・学習を行うことができるが，各層の設定などを細かく定義する必要があり，使いこなすにはある程度の修練が必要となる。Keras では，そのような定義がすでに行われており，簡単にネットワークを構築できるため，プログラムなどの経験が少なくても比較的扱いやすい。今回は，この Keras を主体とし，バックエンドに TensorFlow を使用して，画像を分類した。

3.　ResNet50 を用いた破断面の分類

自身で CNN のネットワークを構築し，学習を行う場合，良好な結果を出すまでに多くの試行錯誤が必要になり，膨大な時間が必要となる。また，画像枚数が少ない場合，良好な学習が行えず，学習データでは認識率が高いにもかかわらず検証データでは認識率が上がらない過学習という現象に陥りやすい。それらの対策として，転移学習がある。

転移学習とは，すでに学習を実施した CNN の特徴量抽出層（畳み込み層やプーリング層など）の重みデータを利用することで，好結果を得られる手法である。学習済みモデルの特徴量抽出層の重みを使い，結合層，出力層を含む分類層のみを，対象の画像を用いて新たに学習させることで，試行錯誤の労力を減らしつつ，高い認識率を得ることが可能である。

学習済みモデルにはいくつかの種類があるが，今回は，スキップ接続を有する Residual モジュールを利用し，ネットワークの層が深くても効率的な学習が行える ResNet50 を用いて破断面を分類した。図 2 に示すような ResNet50 の特徴抽出層を用いたネットワークによって学習および認識の検証を行った。

3.1　学習および検証データ

学習および認識率の検証を行うための画像として，ディンプル画像を 42 枚，粒界破面画像を 22 枚，ストライエーション画像を 79 枚用意した。各画像を学習用画像と検証用画像の割合がおおよそ 8 : 2 になるように分け，それぞれで使用した。

3.2　転移学習結果

図 3 に学習および検証データの正解率を示す。検証データの正解率は最終的に 82.8 %となり，比較的高い正解率を示した。しかし，学習データでは正解率が 100 %に達しているのに対し，検証データでは 82.8 %と少し差がある。転移学習だけでは過学習が抑えられておらず，さらなる改善が必要であることがわかる。

図 2　ResNet50 を用いた転移学習のネットワーク構造

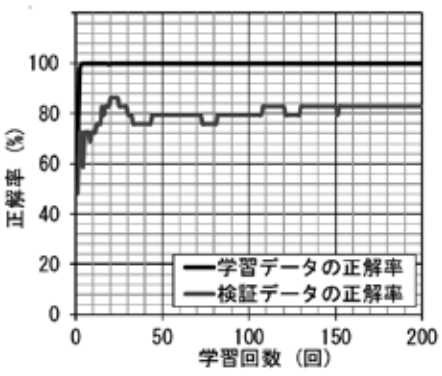

図 3　ResNet50 を用いた転移学習の結果

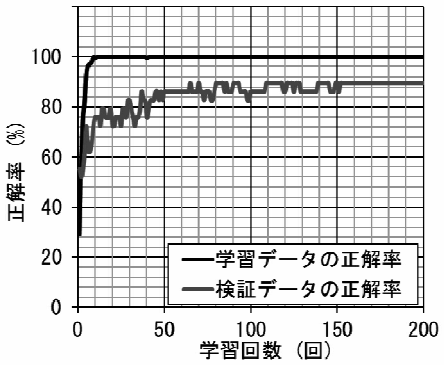

図 4　GAP2D 層を使用した場合の正解率

3.3　過学習対策

3.2 項において確認された過学習の追加対策として，一般的によく用いられる 3 種類の対策を適用した。その内容について報告する。

3.3.1　Global Average Pooling 2D 層

Global Average Pooling 2D 層（以下，GAP2D 層）は，モデルを単純にして計算するパラメータを減らすことで，過学習に対して一定の効果を発揮することが知られている [2]。従来の Flatten 層は，特徴抽出層の複数ある 2 次元データをそのまま 1 次元に順に配列するため，計算パラメータ数が多くなる。一方，GAP2D 層は前段の特徴抽出層にある 2 次元データの平均値を 1 次元に配列する機能を持つため，パラメータ数は少なくなる。

図 2 における Flatten 層を GAP2D 層に置き換えたネットワークにて，学習および認識の検証を行った結果を図 4 に示す。検証データの正解率は 89.7 %となった。図 3 と比較すると，学習の収束は遅くなったが，検証データの正解率は増加したため，GAP2D 層への変更は過学習対策として効果があることを確認できた。

3.3.2　画像データの水増し

過学習が起きる要因の一つは，学習対象の画像データが少ないことに起因する。そのため，画像データを水増しすることが対策として有効である。Keras では，ImageDataGenerator 関数

表 1　画像の水増しの設定

設定項目	設定内容
画像の回転 (rotation_range)	0 ~ 40 deg
画像のシフト (width_shift_range) (height_shift_range)	0 ~ 20 %
せん断変換 (shear_range)	0 ~ 0.2 deg
ズーム (zoom_range)	0 ~ 20 %
水平方向反転 (horizontal_flip)	あり

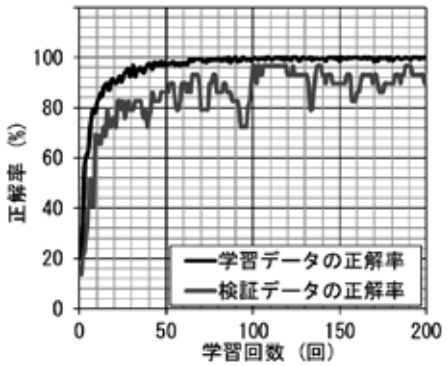

図 5　画像データの水増しを追加した場合の正解率

を用いることで，簡単に反転画像や，回転画像などを生成できる。3.3.1 項の対策に加えて，表 1 に示す設定で画像データを水増しし，学習および認識の検証を行った結果を図 5 に示す。図 4 と比較すると，学習の収束はより遅くなったが，検証データの正解率は，93.1 %と高い数値を示した。このことから，画像データの水増しも過学習対策に効果があることがわかる。ただし，画像の水増しはランダムに行われているため，学習を行う度に結果が変動しやすくなることに注意が必要である。

3.3.3　Dropout 層

Dropout 層は，学習時に一定の割合で出力データを不活性化（無視）することで，過学習を

緩和し，精度を上げるための手法である。今回は，図 2 における全結合層と出力層との間にDropout層を追加した。

3.3.1，3.3.2 項の対策に加えて，Dropout層を追加して学習および認識の検証を行った結果を図 6に示す。検証データの正解率は，96.6 %であった。学習データの正解率と検証データの正解率がほぼ同じ軌跡を描いており，過学習がほとんど起きていないことがわかる。ただし，図 5と比較すると，学習の収束までに多くの学習回数が必要である。

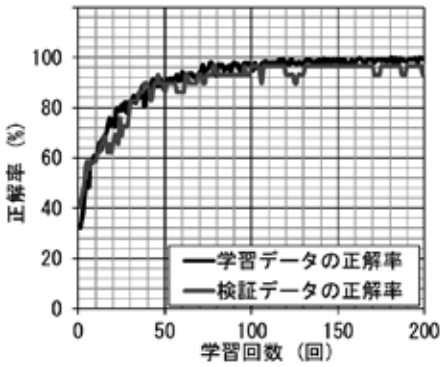

図 6　Dropout 層を追加した場合の正解率

表 2　今回使用した学習済みモデル

モデル名	概要
VGG16 (2014)	・シンプルに畳み込み層などの特徴抽出層を積み重ねた構造 ・インターネットや書籍での実施例が多い
Inception V3 (2014)	・Inceptionモジュールという並列の畳み込み層からなるモジュールを積み重ねたネットワーク
ResNet50 (2015)	・スキップ接続を有するResidualモジュールを導入し，層が深いネットワークでも効率よく学習することが可能
Xception (2017)	・Inceptionの改良版という位置づけ。ただし方法論が異なる。 ・Depthwise Separable Convolutionとと，Residualモジュールを組み合わせようなネットワーク構造
MobileNet V2 (2018)	・携帯機器でも扱えるよう計算量を少なくしていることが特徴 ・Depthwise Separable Convolutionという畳み込み手法を採用

4. 学習済みモデルごとの転移学習の比較

4.1　学習済みモデル

画像認識のコンペティションであるILSVRCで使用されている画像データセットImageNetには，1,000種類の画像がそれぞれ約1,000枚用意されている。この画像データセットを用いて学習を行った学習済みモデルを表 2に示す。3章では，ResNet50を用いたが，ここでは表 2に示すモデルで転移学習を行い，比較した。

4.2　比較条件

学習および検証用の画像データについては，3.1 項に示す内容と同様である。各学習済みモデルには，3.3 項の過学習対策を適用した。図 7に，そのネットワーク構造を示す。

4.3　転移学習の結果

表 3に各学習済みモデルを用いて転移学習を行った結果を示す。今回試した学習済みモデルの中では，Xceptionが最も高い検証データの正解率を示した。しかし，学習データの正解率が99 %以上になるまでに要した学習回数は，Xceptionが最も多く必要とした。ResNet50およびInception V3が学習時間と得られる結果のバランスが良かった。

図 7　比較を行う際のネットワーク構造

表 3　各学習済みモデルの転移学習の結果

学習済みモデル	60 回学習後の検証データの正解率(%)	学習データの正解率が99 %以上になるまでに要した学習回数 (回)
VGG16	89.7	17
Inception V3	93.1	22
ResNet50	93.1	20
Xception	96.6	54
MobileNet V2	86.2	26

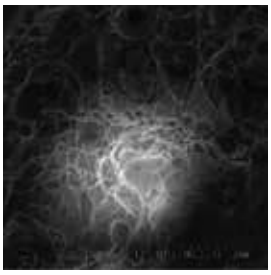

(a) ディンプル

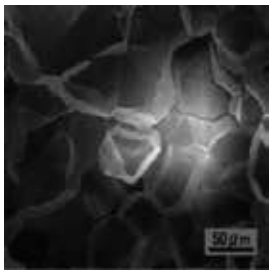

(b) 粒界破面

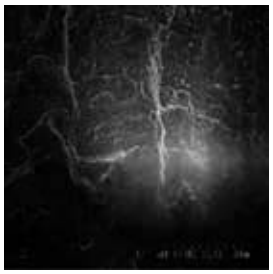

(c) ストライエーション

図 8　Grad-CAM による可視化

5.　Grad-CAM による可視化

CNN を用いて画像認識を行い，高い検証データの正解率を得られた場合でも，認識対象の特徴を正しくとらえて分類しているかがわかりづらい。そのため，分類結果が表示されても技術者は何を基に CNN が決定したのかを把握できないため，経験の蓄積はできない。

そうしたことから，近年，CNN が画像のどの部分を注視して分類を行ったのかを可視化するための手法が多く開発されている。今回は，Grad-CAM [3]という手法を用いた。Grad-CAM は，特徴量抽出層に勾配の変化を加え，その時に生じる出力の変化量を基に画像分類にとって重要な位置を特定する手法である。

図 6 の認識結果を得た CNN モデルを使用して可視化を行った結果を図 8 に示す。白色が強いほど，その部分を CNN が注視していることを示す。図に示すとおり，各破面観察画像に対して，その特徴部分をよく捉えられていることがわかる。

6. 結　　言

(1) 短時間で良好な結果を得る方法として転移学習がある。転移学習のみを適用したネットワークでも好結果が得られる。

(2) 一般的に用いられる 3 つの過学習対策の有用性を確認した。転移学習と合わせることで高い認識結果を得られた。

(3) 複数の学習済みモデルを用いて転移学習を行い，Xception が最も良い結果を示した。ただし，計算機の性能，学習時間などを考慮して学習済みモデルを選択するとよい。

(4) CNN がどの部分を注視して分類の決め手としたかを可視化する手法として Grad-CAM があり，破断面の分類でも有効であった。

参考文献

1) Y. LeCun et.al, “Gradient-based Learning Applied to Document Recongnition”, *Proceedings of the IEEE*, Vol.86, No.11, 1998, pp.2278-2324.

2) M. Lin et al, “Network In Network”, arXiv (2014), https://arxiv.org/pdf/1312.4400.pdf

3) Ramprasaath R. Selvaraju et al., “Grad-CAM: Visual Explanations from Deep Networks via Gradient-basedLocalization”, arXiv(2017), https://arxiv.org/pdf/1610.02391.pdf