

卒業論文概要書

Summary of Bachelor's Thesis

Date of submission: 02/07/2020

学科名 Department	情報理工	氏名 Name	山野井 祐介	指導 教員 Advisor	渡辺 裕 ㊞
研究指導名 Research guidance	オーディオビジュアル 情報処理研究	学籍番号 Student ID number	1W163128-8 [㊞]		
研究題目 Title	曇み込みニューラルネットワークを用いた鋼構造物の腐食レベルの推定 Corrosion Level Estimation of Steel Structure Using Convolutional Neural Network				

1. まえがき

国土交通省によると、高度成長期以降に整備されたインフラについて、建設後 50 年以上経過する施設の割合が今後 20 年で急速に高くなる[1]. 老朽化したインフラは、コンクリートのひび割れ、鋼の腐食、ボルトの緩みなどの症状が現れやすい。したがって、点検及び補修が急務である。しかし、一斉に老朽化するインフラに対し、点検を行うための予算は不足している。特に、大規模な施設の点検を行うための足場の設置には多くの費用がかかる。そこで近年、ロボットやドローンに搭載したカメラでの足場を必要としない点検手法が注目されている。

本研究では、重要な点検項目の一つである鋼構造物の腐食に注目し、画像から鋼構造物の腐食レベルを推定する手法を検討する。将来的には、カメラのついたロボットやドローンと組み合わせることで、遠隔操作や自動での点検を目的とする。

2. 腐食に関する研究

国土技術政策総合研究所らは、さびの粒子の大きさや、さびの厚みが、さびの外観によって異なることを確認している[2]. さびの状態が良好であるほど、さびの粒子が細かく均一でさびの厚みが薄く、比較的明るい色調であり、さびの状態が不良であるほどさびの粒子が大きく粗くさびの厚みが厚いことを示している。

Ahuja らは、画像から腐食領域と、その腐食レベルを推定する手法を提案している[3]. 異なる濃度の塩酸による鋼の腐食を顕微鏡により撮影し、それらを腐食レベルごとに領域分割したものをデータセットとしている。作成したデータセットを、MS COCO データセットを事前学習済みの Mask R-CNN[4]で転移

学習している。四つの腐食レベルの分類に対し、約 94.3%の正解率である。

3. 提案手法

3.1 腐食面積推定

さびの粒子の大きさとさび外観に相関があることが確認されているため、その特徴を学習することで、画像からその腐食面積を推定可能であると考えられる。腐食面積とは、画像中の腐食領域を実測した面積である。腐食面積を推定するための特徴は腐食面積に対して比例関係にあると仮定し、データセットのおよそ中央値になる腐食面積を閾値としてラベルを付ける。腐食画像とその腐食面積に対応するラベルを Inception-v3[5]で学習し、腐食面積を推定する。

3.2 平均腐食深さ推定

さびの厚みとさび外観に相関があることが確認されているため、その特徴を学習することで、画像からその平均腐食深さを推定可能であると考えられる。平均腐食深さとは、画像中の腐食の深さの平均値である。平均腐食深さを推定するための特徴は平均腐食深さに対して比例関係にあると仮定し、データセットのおよそ中央値になる平均腐食深さを閾値としてラベルを付ける。腐食画像とその平均腐食深さに対応するラベルを Inception-v3 で学習し、平均腐食深さを推定する。

3.3 最大腐食深さ推定

さびの厚みとさび外観に相関があることが確認されているため、その特徴を学習することで、画像からその最大腐食深さを推定可能であると考えられる。最大腐食深さとは、画像中の腐食の深さの最大値で

ある。最大腐食深さを推定するための特徴は最大腐食深さに対して比例関係にあると仮定し、データセットのおおよそ中央値になる最大腐食深さを閾値としてラベルを付ける。腐食画像とその最大腐食深さに対応するラベルを Inception-v3 で学習し、最大腐食深さを推定する。

4. 実験

4.1 腐食面積推定

データセットのおおよそ中央値となる腐食面積の値は 16000mm² であった。そのため、腐食面積が 16001mm² 未満の画像をラベル 0, 16001mm² 以上の画像はラベル 1 とした。学習にはラベル 0 の腐食画像を 2733 枚, ラベル 1 の腐食画像を 2856 枚, 合計で 5589 枚使用し, 90, 180, 270 度の回転によって 22356 枚にデータ拡張した。拡張した腐食画像とその腐食面積に対応するラベルを Inception-v3 で学習した。学習用とは別の腐食画像を, 各ラベル 800 枚ずつ用いて学習したモデルを評価した。その結果を表 1 に示す。ランダムな推定より約 24 ポイント高い結果であった。

表 1 腐食面積推定の結果

正解率	適合率	再現率	F 値
0.7425	0.7059	0.8313	0.7635

4.2 平均腐食深さ推定

データセットのおおよそ中央値となる平均腐食深さの値は 2.2mm であった。そのため、平均腐食深さが 2.3 未満の画像をラベル 0, 2.3 以上の画像はラベル 1 とした。学習にはラベル 0 の腐食画像を 2831 枚, ラベル 1 の腐食画像を 2820 枚, 合計で 5651 枚使用し, 90, 180, 270 度の回転によって 22604 枚にデータ拡張した。拡張した腐食画像とその平均腐食深さに対応するラベルを Inception-v3 で学習した。学習用とは別の腐食画像を, 各ラベル 800 枚ずつ用いて学習したモデルを評価した。その結果を表 2 に示す。表 2 に示す正解率から, 学習に成功しているとはいえない。

表 2 平均腐食深さ推定の結果

正解率	適合率	再現率	F 値
0.5725	0.5775	0.5400	0.5581

4.3 最大腐食深さ推定

データセットのおおよそ中央値となる最大腐食深さの値は 3.0mm であった。そのため、最大腐食深さが 3.1 未満の画像をラベル 0, 3.1 以上の画像はラベル 1 とした。学習にはラベル 0 の腐食画像を 3524 枚, ラベル 1 の腐食画像を 2127 枚, 合計で 5651 枚使用し, 90, 180, 270 度の回転によって 22604 枚にデータ拡張した。拡張した腐食画像とその最大腐食深さに対応するラベルを Inception-v3 で学習した。学習用とは別の腐食画像を, 各ラベル 800 枚ずつ用いて学習したモデルを評価した。その結果を表 3 に示す。表 3 に示す正解率から, 学習に成功しているとはいえない。

表 3 最大腐食深さ推定の結果

正解率	適合率	再現率	F 値
0.5531	0.6557	0.2238	0.3336

5. むすび

本研究では、鋼構造物の腐食画像とその腐食面積、平均腐食深さ、最大腐食深さの三つをそれぞれ CNN で学習し、推定結果を評価した。その結果、腐食面積に相関する特徴を CNN で学習できる可能性を示し、画像からの平均腐食深さ及び最大腐食深さの推定は困難であることを示した。

参考文献

- [1] 国土交通省：“インフラ長寿命化とデータ利活用に向けた取組”，未来投資会議 産官協議会（次世代インフラ）【第 1 回】，資料 2，p.2，Nov. 2018.
- [2] 国土交通省 国土技術政策総合研究所，（一社）日本鉄鋼連盟，（一社）日本橋梁建設協会：“耐候性橋梁の適用環境評価手法の高度化に関する研究（II）—凍結防止剤散布の影響に関する検討—”，国土技術政策総合研究所資料，No.778，Jan. 2014.
- [3] S.K. Ahuja, M.K. Shukla, and K.K. Ravulakollu: “Surface corrosion grade classification using convolution neural network”, International Journal of Recent Technology and Engineering, Vol.6, Sep. 2019.
- [4] K. He, G. Gkioxari, P. Dollar, and R. Girshick: “Mask R-CNN”, International Conference on Computer Vision, pp.2961-2969, 2017.
- [5] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna: “Rethinking the Inception Architecture for Computer Vision”, Computer Vision and Pattern Recognition, pp.2818-2826, Jun. 2016.

2019年度 卒業論文

畳み込みニューラルネットワークを用いた

鋼構造物の腐食レベルの推定

Corrosion Level Estimation of Steel Structure

Using Convolutional Neural Network

指導教員 渡辺 裕 教授

早稲田大学 基幹理工学部 情報理工学科

1W163128-8

山野井祐介

目次

第 1 章	序論	1
1.1	研究の背景	1
1.2	本研究の目的	1
1.3	関連研究	1
1.3.1	さびに関する調査	1
1.3.2	画像を用いた腐食レベルの推定手法	1
1.4	先行研究の問題点	2
1.5	本論文の構成	2
第 2 章	関連技術	3
2.1	まえがき	3
2.2	パーセプトロン	3
2.3	ニューラルネットワーク	3
2.4	畳み込みニューラルネットワーク	4
2.5	Inception-v3	4
2.6	むすび	4
第 3 章	CNN を用いた腐食レベルの推定手法	5
3.1	まえがき	5
3.2	腐食面積推定	5
3.3	平均腐食深さ推定	5
3.4	最大腐食深さ推定	5
3.5	むすび	6
第 4 章	実験結果と考察	7
4.1	まえがき	7
4.2	腐食面積推定	7
4.2.1	実験概要	7
4.2.2	CNN で学習	7
4.2.3	学習したモデルの評価	8
4.2.4	考察	8
4.3	平均腐食深さ推定	9
4.3.1	実験概要	9

4.3.2	CNN で学習	9
4.3.3	学習したモデルの評価	10
4.3.4	考察	10
4.4	最大腐食深さ推定	10
4.4.1	実験概要	10
4.4.2	CNN で学習	11
4.4.3	学習したモデルの評価	11
4.4.4	考察	11
4.5	むすび	12
第 5 章	結論と今後の課題	13
5.1	結論	13
5.2	今後の課題	13
	謝辞	14
	参考文献	15
	図一覧	16
	表一覧	17

第1章 序論

1.1 研究の背景

国土交通省によると、高度成長期以降に整備されたインフラについて、建設後 50 年以上経過する施設の割合が今後 20 年で急速に高くなる[1]。老朽化したインフラは、コンクリートのひび割れ、鋼の腐食、ボルトの緩みなどの症状が現れやすい。したがって、点検及び補修が急務である。しかし、一斉に老朽化するインフラに対し、点検を行うための予算は不足している。特に、大規模な施設の点検を行うための足場の設置には多くの費用がかかる。そこで近年、ロボットやドローンに搭載したカメラでの足場を必要としない点検手法が注目されている。

1.2 本研究の目的

本研究では、重要な点検項目の一つである鋼構造物の腐食に注目し、画像から鋼構造物の腐食レベルを推定する手法を検討する。将来的には、カメラのついたロボットやドローンと組み合わせることで、遠隔操作や自動での点検を目的とする。

1.3 関連研究

1.3.1 さびに関する調査

国土技術政策総合研究所らは、さびの粒子の大きさや、さびの厚みが、さびの外観によって異なることを確認している[2]。さびの状態が良好であるほど、さびの粒子が細かく均一でさびの厚みが薄く、比較的明るい色調であり、さびの状態が不良であるほどさびの粒子が大きく粗くさびの厚みが厚いことを示している。

1.3.2 画像を用いた腐食レベルの推定手法

後藤らは、画像処理とパターン認識を用いて耐候性鋼材のさび外観を評価する手法[3]を提案している。さびの厚みや外観による 5 段階の評価点がついた同一スケールのさび画像を用いた実験を行っている。まず、さび画像に対しウェーブレット変換による多重解像度解析を行い、さびの粗密さがさび画像の周波数エネルギー比の違いとして表現できることを示している。さらに、さび画像の周波数エネルギー特性を学習パターンとする外観評価の識別モデルを、サポートベクトルマシンにより構築し、さび画像からさび外観評価点を推定している。さび画像の再現率はクラスごとに約 72~94%である。

Ahuja らは、画像を用いて塩酸による鋼の腐食を分類している[4]。六つの濃度の塩酸によってそれぞれ違うレベルに腐食させた鋼を電子顕微鏡で撮影した画像を解析している。赤、緑、青、色相、彩度などのヒストグラムとグレーレベルの同時生起行列を学

習パターンとする外観評価の識別モデルを、サポートベクトルマシンにより構築し、鋼の腐食画像から腐食のレベルを推定している。平均正解率は約 92.4%である。

さらに Ahuja らは、画像から腐食領域と、その腐食レベルを推定する手法を提案している[5]。異なる濃度の塩酸による鋼の腐食を顕微鏡により撮影し、それらを腐食レベルごとに領域分割したものをデータセットとしている。作成したデータセットを、MS COCO データセットを事前学習済みの Mask R-CNN[6]で転移学習している。四つの腐食レベルの分類に対し、約 94.3%の正解率である。

1.4 先行研究の問題点

1.3.2 項で示したように、画像を用いた腐食外観評価の推定は行われている。しかし、点検内容は外観の評価だけではなく、腐食面積や腐食深さなどを実測した上で、定量的に判断される。よって、腐食レベルの推定技術を実用化するためには、点検画像からより詳細なデータを取得する必要がある。そこで、実測の腐食面積や腐食深さに関連する特徴が、腐食を映した画像に存在するかを CNN で学習することで調査する。

1.5 本論文の構成

本論文の構成を以下に示す。

第 1 章は本章であり、本研究の背景、目的、関連研究について述べる。

第 2 章では本研究で用いる畳み込みニューラルネットワークについて述べる。

第 3 章では腐食レベルの推定手法について述べる。

第 4 章では実験結果及び考察について述べる。

第 5 章では本論文の結論と今後の課題について述べる。

第2章 関連技術

2.1 まえがき

本章では本研究で用いるパーセプトロン，ニューラルネットワーク，畳み込みニューラルネットワークの三つの技術[7]について述べる．また，腐食レベルの推定に用いたCNNモデルの Inception-v3[8]について述べる．

2.2 パーセプトロン

パーセプトロンは，複数の信号を入力として受け取り一つの信号を出力するニューラルネットワークの起源となるアルゴリズムである．入力信号のそれぞれが固有の重みを持ち，その重みは各信号の重要性を制御する要素として働く．

2.3 ニューラルネットワーク

ニューラルネットワークは，入力層，中間層，出力層から構成され，各層は複数のノードを持ち，それぞれのノード間には重みが存在する．ニューラルネットワークの構造例を図 2.1 に示す．ニューラルネットワークの信号の流れは，基本的にパーセプトロンと同じである．しかし，ニューラルネットワークはパーセプトロンと異なり，適切な重みパラメータをデータセットから自動で学習できる．なお，データセットとは，入力信号とそれに対応する正解ラベルである．




図 2.1 ニューラルネットワークの構造例

2.4 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (CNN) とはニューラルネットワークに畳み込み層とプーリング層を追加したものである。CNN の構造例を図 2.2 に示す。畳み込み層で行う処理は、畳み込み演算である。入力データに対し、フィルターを一定の間隔でスライドさせながら適応していき、フィルターの要素と対応する入力の要素を乗算し、和を求める。そして、その結果を対応する出力先に格納する。CNN の場合、フィルターのパラメータがパーセプトロンやニューラルネットワークでの重みと対応し、各要素の重要性を制御する要素として働く。次に、プーリング層では縦・横方向の空間を小さくする演算を行う。プーリングの演算方法には、対象領域から最大値をとる Max プーリングや、対象領域の平均を計算する平均プーリングなどが存在する。入力データの微小なズレに対して、プーリングは同じような結果を出力するため、入力データのズレに対して頑強となる。

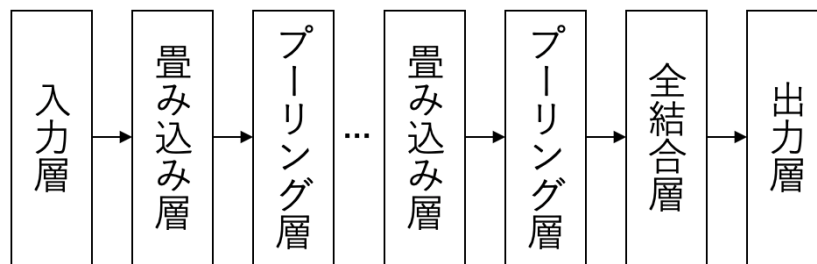


図 2.2 CNN の構造例

2.5 Inception-v3

Inception-v3 は Szegedy らによって提案されたネットワークの深さが 42 層の CNN モデルである。大きなフィルターによる畳み込みは計算コストが高いため、小さいフィルターによる畳み込みを複数重ねることで、特徴マップのサイズを変更せずにパラメータ数の削減をしている。さらにプーリングと畳み込みを並列に行うことで、ネットワークの表現力の低下を抑えながら計算コストを低減している。

2.6 むすび

本章では本研究で用いるパーセプトロン、ニューラルネットワーク、畳み込みニューラルネットワークの三つの技術について述べた。また、腐食レベルの推定に用いた CNN モデルの Inception-v3 について述べた。

第3章 CNN を用いた腐食レベルの推定手法

3.1 まえがき

本章では、鋼構造物の腐食画像からその腐食面積、平均腐食深さ、最大腐食深さの三つを CNN を用いて推定する手法を提案する。腐食画像は鋼構造物の腐食領域が映る画像とする。また、腐食画像の縮尺は未知である。

3.2 腐食面積推定

さびの粒子の大きさとさびの外観に相関があることが示されている[2]ため、その特徴を学習することで、画像からその腐食面積を推定可能であると考えられる。したがって、腐食画像とその腐食面積に対応するラベルを CNN で学習し、画像から腐食面積を推定する。腐食面積とは、画像中の腐食領域を実測した面積である。腐食面積を推定するための特徴は腐食面積に対して比例関係にあると仮定し、データセットのおおよそ中央値になる腐食面積を閾値としてラベル付けをする。また、画像を 90, 180, 270 度回転することでデータ拡張する。学習に用いる CNN モデルは Inception-v3 である。腐食画像とその腐食面積に対応するラベルを Inception-v3 で学習し、腐食面積を推定する。入力画像の形式は RGB、画像サイズは Inception-v3 のデフォルトの入力サイズである 299×299 画素である。

3.3 平均腐食深さ推定

さびの厚みとさびの外観に相関があることが示されている[2]ため、その特徴を学習することで、画像からその平均腐食深さを推定可能であると考えられる。腐食画像とその平均腐食深さに対応するラベルを CNN で学習し、画像から平均腐食深さを推定する。平均腐食深さとは、画像中の腐食の深さの平均値である。平均腐食深さを推定するための特徴は平均腐食深さに対して比例関係にあると仮定し、データセットのおおよそ中央値になる平均腐食深さを閾値としてラベル付けをする。また、画像を 90, 180, 270 度回転することでデータ拡張する。学習に用いる CNN モデルは Inception-v3 である。腐食画像とその平均腐食深さに対応するラベルを Inception-v3 で学習し、平均腐食深さを推定する。入力画像の形式は RGB、画像サイズは Inception-v3 のデフォルトの入力サイズである 299×299 画素である。

3.4 最大腐食深さ推定

さびの厚みとさびの外観に相関があることが示されている[2]ため、その特徴を学習することで、画像からその最大腐食深さを推定可能であると考えられる。腐食画像とそ

の最大腐食深さに対応するラベルを CNN で学習し, 画像から最大腐食深さを推定する. 最大腐食深さとは, 画像中の腐食の深さの最大値である. 最大腐食深さを推定するための特徴は最大腐食深さに対して比例関係にあると仮定し, データセットのおおよそ中央値になる最大腐食深さを閾値としてラベル付けをする. また, 画像を 90, 180, 270 度回転することでデータ拡張する. 学習に用いる CNN モデルは Inception-v3 である. 腐食画像とその最大腐食深さに対応するラベルを Inception-v3 で学習し, 最大腐食深さを推定する. 入力画像の形式は RGB, 画像サイズは Inception-v3 のデフォルトの入力サイズである 299×299 画素である.

3.5 むすび

本章では, 三つの手法を提案した. 一つ目は, 腐食画像とその腐食面積のラベルを CNN で学習することで, 腐食画像からその画像の腐食面積が任意の面積より大きいかわかる手法である. 二つ目は, 腐食画像とその平均腐食深さのラベルを CNN で学習することで, 腐食画像からその画像の平均腐食深さが任意の平均腐食深さより大きいかわかる手法である. 三つ目は, 腐食画像とその最大腐食深さのラベルを CNN で学習することで, 腐食画像からその画像の最大腐食深さが任意の最大腐食深さより大きいかわかる手法である.

第4章 実験結果と考察

4.1 まえがき

本章では，第3章で示した提案手法についての実験を行い，その結果を考察する．

4.2 腐食面積推定

4.2.1 実験概要

縮尺が未知の腐食画像と，その腐食面積に対応するラベルを CNN で学習し，画像から腐食面積を推定し，その正解率を考察した．腐食画像の例を図 4.1 に示す．



図 4.1 腐食画像の例

データセットのおおよそ中央値である腐食面積の値は 16000mm^2 であった．そのため，腐食面積が 16001mm^2 未満の画像をラベル 0， 16001mm^2 以上の画像はラベル 1 とした．

4.2.2 CNN で学習

腐食画像とその腐食面積に対応するラベルを Inception-v3 で学習した．学習には，ラベル 0 の腐食画像を 2733 枚，ラベル 1 の腐食画像を 2856 枚，合計で 5589 枚を使用した．また，学習用画像を 90，180，270 度の回転によって，4 倍の 22356 枚にデータ拡張した．また，学習用とは別の腐食画像を，ラベル 0 を 800 枚，ラベル 1 を 800 枚，合計で 1600 枚検証に使用した．学習時の画像サイズは 299×299 画素，バッチサイズは 4，エポック数は 30 とした．エポックごとの損失と正解率の変化を図 4.2 に示す．




図 4.2 腐食面積学習時の損失と正解率の変化

4.2.3 学習したモデルの評価

図 4.2 に示すエポックごとの損失と正解率の変化より 10 エポック目以降に過学習の傾向が確認された。よって、過学習が起こる直前の 10 エポックまで学習したモデルを採用した。学習用と検証用とは別の腐食画像を、ラベル 0 を 800 枚、ラベル 1 を 800 枚、合計で 1600 枚用いて学習したモデルを評価した。その結果を表 4.1 に示す。

表 4.1 腐食面積推定の結果

正解率	適合率	再現率	F 値
0.7425	0.7059	0.8313	0.7635

4.2.4 考察

表 4.1 に示す実験結果より 2 クラス分類で正解率が約 74%であった。テストに用いた画像はラベル 0, 1 とともに同じ枚数であることから、ランダムに推定した場合の正解率は約 50%となる。したがって、ランダムよりも正解率が約 24 ポイント高い結果となった。しかし、実際の点検業務ではさらに細かい分類での高い正解率が求められるため、さらなる正解率の向上が必要である。以下で、正解率が約 74%となった理由を考察する。

最も大きな要因は、腐食面積の大きさに対して画像の画素数が足りず、さび粒子を表現できなかったためだと推察される。腐食画像からさび粒子を認識するためには、その特徴を表現できるだけの画素数が画像内に必要である。ここで、画像サイズが $m \times n$ 画素、画像全体に対する腐食画素の割合が $x\%$ 、腐食面積を s としたときの 1 画素あたりの距離 d を求める式を式(4.1)に示す。

$$d = \sqrt{\frac{s}{m \times n \times \frac{x}{100}}} \quad (4.1)$$

本実験で用いたデータセットの値から，1画素あたりの距離を算出する．画像サイズはCNNへの入力サイズである 299×299 画素である．ここで，画像全体にしめる腐食領域の割合を60%と仮定する．本実験で使用したデータセットの平均腐食面積は約 45487mm^2 であった．したがって，そのときの1画素あたりの距離は，式(4.1)より約 0.92mm である． 1mm 程度のさびの粒子も存在する[2]ため，1画素あたり約 0.92mm ではさび粒子を表現できない．よって，入力サイズが 299×299 画素のCNNで学習するには，本実験で使用した腐食画像の腐食面積は過大であった．

4.3 平均腐食深さ推定

4.3.1 実験概要

縮尺が未知の腐食画像と，その平均腐食深さに対応するラベルをCNNで学習し，画像から平均腐食深さを推定し，その正解率を考察した．データセットのおおよそ中央値である平均腐食深さの値は 2.2mm であった．そのため，平均腐食深さが 2.3mm 未満の画像をラベル0， 2.3 以上の画像はラベル1とした．

4.3.2 CNNで学習

腐食画像とその平均腐食深さに対応するラベルをInception-v3で学習した．学習には，ラベル0の腐食画像を2831枚，ラベル1の腐食画像を2820枚，合計で5651枚を使用した．また，学習用画像を 90° ， 180° ， 270° の回転によって，4倍の22604枚にデータ拡張した．また，学習用とは別の腐食画像を，ラベル0を800枚，ラベル1を800枚，合計で1600枚検証に使用した．学習時の画像サイズは 299×299 画素，バッチサイズは4，エポック数は30とした．エポックごとの損失と正解率の変化をに示す．



図 4.3 平均腐食深さ学習時の損失と正解率の変化

4.3.3 学習したモデルの評価

に示すエポックごとの損失と正解率の変化から、30 エポックまで学習したモデルを採用した。学習用と検証用とは別の腐食画像を、ラベル 0 を 800 枚、ラベル 1 を 800 枚、合計で 1600 枚用いて学習したモデルを評価した。その結果を表 4.2 に示す。

表 4.2 平均腐食深さ推定の結果

正解率	適合率	再現率	F 値
0.5725	0.5775	0.5400	0.5581

4.3.4 考察

表 4.2 に示す実験結果から 2 クラス分類での正解率は約 57%であった。テストに用いた画像は、ラベル 0, 1 とともに同じ枚数であることから、ランダムに推定した場合正解率は約 50%となる。したがって、学習により正解率が約 7 ポイント向上した。しかし、この正解率では学習に成功しているとはいえない。その原因を考察する。

国土技術政策総合研究所らは、厚みが $800\ \mu\text{mm}$ 以下のさびは、その外観と厚みに相関があることを示した[2]。しかし、厚みが $800\ \mu\text{mm}$ 以上のさびの、その外観と厚みに相関があることは示していない。本実験で使用したデータセットの平均腐食深さの最小値は 1.5mm であったため、腐食深さとさびの外観に相関がなかったと推察される。

4.4 最大腐食深さ推定

4.4.1 実験概要

縮尺が未知の腐食画像と、その最大腐食深さに対応するラベルを CNN で学習し、画像から最大腐食深さを推定し、その正解率を考察した。データセットのおおよそ中央値

である最大腐食深さの値は 3.0mm であった。そのため、最大腐食深さが 3.1mm 未満の画像をラベル 0、3.1 以上の画像はラベル 1 とした。

4.4.2 CNN で学習

腐食画像とその最大腐食深さに対応するラベルを Inception-v3 で学習した。学習には、ラベル 0 の腐食画像を 3524 枚、ラベル 1 の腐食画像を 2127 枚、合計で 5651 枚を使用した。また、学習用画像を 90、180、270 度の回転によって、4 倍の 22604 枚にデータ拡張した。また、学習用とは別の腐食画像を、ラベル 0 を 800 枚、ラベル 1 を 800 枚、合計で 1600 枚検証に使用した。学習時の画像サイズは 299×299 画素、バッチサイズは 4、エポック数は 30 とした。エポックごとの損失と正解率の変化を示す。




図 4.4 最大腐食深さ学習時の損失と正解率の変化

4.4.3 学習したモデルの評価

に示すエポックごとの損失と正解率の変化から、30 エポックまで学習したモデルを採用した。学習用と検証用とは別の腐食画像を、ラベル 0 を 800 枚、ラベル 1 を 800 枚、合計で 1600 枚用いて学習したモデルを評価した。その結果を表 4.3 に示す。

表 4.3 最大腐食深さ推定の結果

正解率	適合率	再現率	F 値
0.5531	0.6557	0.2238	0.3336

4.4.4 考察

表 4.3 に示す実験結果から 2 クラス分類での正解率は約 55%であった。テストに用

いた画像は、ラベル 0, 1 とともに同じ枚数であることから、ランダムに推定した場合正解率は約 50%となる。したがって、学習により正解率が約 5 ポイント向上した。しかし、この正解率では学習に成功しているとはいえない。その原因を考察する。

国土技術政策総合研究所らは、厚みが $800\mu\text{mm}$ 以下のさびは、その外観と厚みに相関があることを示した[2]。しかし、厚みが $800\mu\text{mm}$ 以上のさびの、その外観と厚みに相関があることは示していない。本実験で使用したデータセットの最大腐食深さの最小値は 2.0mm であったため、腐食深さとさびの外観に相関がなかったと推察される。

4.5 むすび

本章では、提案手法についての実験を行った。腐食面積推定の正解率は約 74%、平均腐食深さ推定の正解率は約 57%、最大腐食深さ推定の正解率は 55%であった。したがって、腐食面積に相関する特徴を腐食外観から CNN で学習できる可能性はあり、平均腐食深さ及び最大腐食深さに相関する特徴は腐食外観に現れないと考えられる。

第5章 結論と今後の課題

5.1 結論

本研究では、鋼構造物の腐食画像とその腐食面積、平均腐食深さ、最大腐食深さの三つをそれぞれ CNN で学習し、推定結果を評価した。腐食面積に相関する特徴を CNN で学習できる可能性を示し、平均腐食深さ及び最大腐食深さに相関する特徴は腐食の外観に現れないことを示した。

5.2 今後の課題

本研究では、腐食面積に相関する特徴を CNN で学習できる可能性を示した。しかし、その正解率は十分ではなく、過学習が生じていた。よって、さらに多くのデータセットを用いて学習を行うべきである。また、本研究で用いた腐食画像には背景や腐食していない構造物が映っていた。背景は腐食の学習を妨げるため、Mask R-CNN[6]などにより腐食領域のみを学習する必要がある。

また、腐食画像から腐食面積を推定する場合は処理を分ける必要がある。まず、さびの外観からさびの粒子の大きさを推定する。次にさび画像からさびの粒子を見つけ画像の縮尺を推定する。最後に、画像からさび領域を抽出し、画像の縮尺から腐食面積を推定することで正解率の向上につながると考えられる。

謝辞

本研究に用いたコンピュータの準備や環境を整えてくださり、研究の方向性や手法について適切なお指導くださった渡辺裕教授と早稲田大学情報通信研究センター招聘研究員の原潤一博士に深く感謝申し上げます。

また、日頃から問題点解決の相談に乗っていただき、快適な研究環境を作ってくださいました研究室の皆様に熱く御礼申し上げます。

最後に、常に支えてくれた家族に心より感謝致します。

参考文献

- [1]. 国土交通省：“インフラ長寿命化とデータ利活用に向けた取組”，未来投資会議 産官協議会（次世代インフラ）【第1回】，資料2，p.2，Nov. 2018.
- [2]. 国土交通省 国土技術政策総合研究所，（一社）日本鉄鋼連盟，（一社）日本橋梁建設協会：“耐候性橋梁の適用環境評価手法の高度化に関する研究（II）—凍結防止剤散布の影響に関する検討—”，国土技術政策総合研究所資料，No.778，Jan. 2014.
- [3]. 後藤悟史，麻生稔彦，宮本文穂：“画像処理とパターン認識手法を利用した耐候性鋼材のさび外観評価”，土木学会論文集 F，Vol.62，No.4，pp.674-683，Dec. 2006.
- [4]. S.K. Ahuja, M.K. Shukla, and K.K. Ravulakollu: “Surface corrosion detection and classification for steel alloy using image processing and machine learning”, Helix, Vol.8(5), pp.3822-3827, Aug. 2018.
- [5]. S.K. Ahuja, M.K. Shukla, and K.K. Ravulakollu: “Surface corrosion grade classification using convolution neural network”, International Journal of Recent Technology and Engineering, Vol.6, Sep. 2019.
- [6]. K. He, G. Gkioxari, P. Dollar, and R. Girshick: “Mask R-CNN”, International Conference on Computer Vision, pp.2961-2969, 2017.
- [7]. 斎藤康毅：“ゼロから作る Deep Learning—Python で学ぶディープラーニングの理論と実装”，株式会社オライリー・ジャパン，2016.
- [8]. C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna: “Rethinking the Inception Architecture for Computer Vision”, Computer Vision and Pattern Recognition, pp.2818-2826, Jun. 2016.

図一覧

図 2.1	ニューラルネットワークの構造例	3
図 2.2	CNN の構造例	4
図 4.1	腐食画像の例	7
図 4.2	腐食面積学習時の損失と正解率の変化	8
図 4.3	平均腐食深さ学習時の損失と正解率の変化	10
図 4.4	最大腐食深さ学習時の損失と正解率の変化	11

表一覧

表 4.1	腐食面積推定の結果	8
表 4.2	平均腐食深さ推定の結果	10
表 4.3	最大腐食深さ推定の結果	11