

論文 電磁波による鉄筋腐食膨張に伴う内部ひび割れの推定に関する基礎的研究

藤原茜*1・新保弘*2・野嶋潤一郎*3・溝渕利明*4

要旨：本研究では、電磁波レーダ法により鉄筋腐食膨張に伴うコンクリート内部のひび割れをコンクリート構造物の劣化進行状況を画像処理や機械学習により正確に測定できる推定手法を提案することを目的とした。最初に画像処理による簡易推定法について検討し、色の閾値を用いた画像処理によって劣化が推定できる可能性のあることを示した。次に、電磁波レーダの出力画像はひび割れの有無による鉄筋のエコーの形状が異なることに着目し、機械学習によって劣化を推定する方法を検討した。その結果、機械学習による詳細評価によって鉄筋のエコーの形状から劣化を判定することができる可能性を見出した。

キーワード：非破壊検査, 劣化評価, 電磁波レーダ法, 機械学習, 画像処理, 転移学習, HOG 特徴量

1. はじめに

橋梁などのコンクリート構造物の点検の1次検査においては、表面をハンマーでたたいた時に発生する音の違いにより異常を判断する打音法が広く用いられている。打音法は、現在提案されている他の手法と比較すると、天候や周囲の環境の影響を受けにくく、低コストで実施でき、作業が容易である。しかし、判断が点検員の熟練度に依存することや、高齢化に伴う検査員の不足が課題である。そのため、構造物を破壊することなく早期にひび割れを判定することの可能な手法の確立が求められている。

本研究では、鉄筋コンクリート構造物の劣化進行状況を把握することが可能な電磁波レーダに着目し、鉄筋腐食による内部ひび割れの推定への適用性について検討を行った。電磁波レーダは、ハンドタイプの検査であることから面的調査を行うことができ、測定時間も短いことから、点検時間を短縮することができる。本検討では、鋼材腐食によるコンクリート構造物の劣化進行状況を電磁波レーダ法を用いて内部ひび割れを早期に推定できる

可能性について検討を行うとともに、機械学習を用いることで検査者の熟練度に関係なく正確な判定が可能な推定手法について検討することを目的とした。そこで、本研究では進展期における腐食ひび割れの早期発見およびひび割れ進展状況の推定に関する検討を行った。

本研究の流れを図-1に示す。

2. 検討概要

2.1 室内供試体

(1) 供試体 I

本検討では2017年度に作製した供試体Iのデータを用いた。供試体外観を図-2に示す。また、かぶり、ひび割れの有無、ひび割れ幅、取得データ数を表-1に示す。




図-2 供試体 I 外観

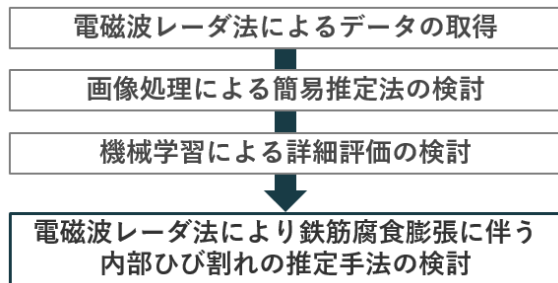


図-1 本研究の流れ

*1 法政大学 デザイン工学部都市環境デザイン工学科 修士課程 (学生会員)

*2 法政大学 デザイン工学部都市環境デザイン工学専攻 博士課程(工学)(学生会員)

*3 (株)開発設計コンサルタント 茅ヶ崎技術事業本部 設備保全技術部 課長 博士(工学)(正会員)

*4 法政大学 デザイン工学部都市環境デザイン工学専攻 教授 博士(工学)(正会員)

表-1 供試体 I による取得データの概要

かぶり(mm)	50					70					
ひび割れ幅(mm)	0	1	1.5	2	3	0	0.5	1	1.5	2	3
データ数	16	16	16	16	16	16	16	16	16	16	16

(2) 供試体 II

本検討では 2011 年に作製した供試体 II についても実験を行った。供試体外観を図-3 に示す。コンクリート中に D16 異形鉄筋を埋設した供試体で、かぶりおよび取得データ数を表-2 に示す。




図-3 供試体 II

表-2 供試体 II による取得データの概要

かぶり(mm)	50	70
データ数	16	16

2. 2 現場試験

現場試験においては、A 火力発電所における現場測定の結果を用いた。A 火力発電所の現場測定においては、熟練者による打音検査により劣化部が推定されているため、それを元にデータを劣化部と健全部に分類した。



写真-1 A 火力発電所

3. 画像処理による簡易推定法

現場試験により取得した電磁波レーダ法のデータには、ひび割れ幅が大きく機械学習を用いなくても劣化していることが推定可能なものがあるのではないかと考え、本検討では、そのようなデータから画像処理による劣化の推定方法について考案し検討を行った。電磁波レーダ

の出力画像においては、鉄筋のエコーは図-4 のように凸型の形状となる。この画像は反射波の振幅の大きさを色によって表現している。色と反射波の振幅の大きさの関係を図-5 に示す。よって、出力画像において青色が最も反射波の振幅値が小さく、赤色が最も反射波の振幅値が大きいことが分かる。

図-6 の(A)の画像は A 火力発電所で得られた出力画像である。この画像の異常部と正常部についてそれぞれ画像処理を行うことにより、異常部の検出を行った。

図-6 の(A)において、異常部の画像のように明らかに劣化している部分は、鉄筋の存在により生じる凸型の影のうち、黄緑色の部分が隣の鉄筋の存在により生じる影と繋がっている。一方で、正常部の画像では赤色と黄緑色の鉄筋のエコーは独立していて他と繋がらない。ここで、図-6 の(A)の画像に色の閾値による画像処理を行い、反射の強い部分のみを検出すると(B)となる。このとき、色の閾値による画像処理では、図-5 の赤い枠線部分のみを表示させる処理を行った。図-6 の(B)を大きさで区分し、画像内のピクセル数が 1000 以上の面積の大きいものだけを表示させ、数値を画像の左上に示すと図-6 の(C)のようになる。(C)の異常部のように左上の数値が 0 でなければ劣化しており、右側の健全部の画像のように 0 であれば健全であるということがわかる。したがって、この処理を行った場合、繋がったデータが出てくれば、劣化しているということが推定可能である。ただし、ひび割れ幅が小さい場合はこのような画像とならないことから、推定することができなくなる可能性がある。そこで、ひび割れ幅の小さなひび割れの判定は機械学習による判定を行うこととした。この検討においては健全部分との比較により異常を発見するため、健全時のデータもしくは、同様の鉄筋および比誘電率のコンクリートによるデータが必要となってくる。また、4. 1 節から、異常部の画像において鉄筋の存在により生じる影が繋がる理由として、ひび割れによる屈折の影響があることが推察できる。




図-4 鉄筋のエコー




図-5 振幅と色の関係

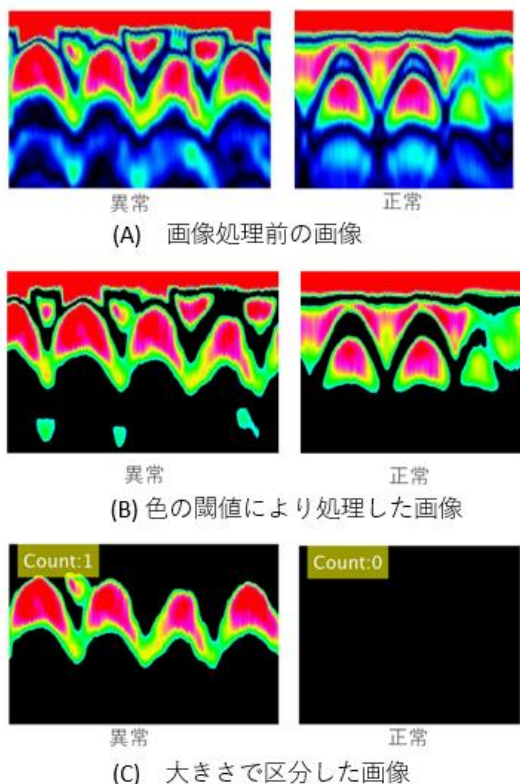


図-6 画像処理の流れ

4. 機械学習による出力画像のひび割れ判定

4.1 ひび割れの有無による出力画像の違いに関する検討

本検討では、ひび割れの有無による出力画像の変化について検討した。電磁波レーダ法の観測結果は専用ソフトであるレポートメーカーにより図-7 のように表示されることから、本研究では左側の画像に着目し、出力画像とした。出力画像においては、鉄筋からの反射波を受信するまでの時間から算定された長さを縦軸に、電磁波レーダの位置を横軸として表示される。この画像において、赤い凸型の形状は鉄筋の存在により生じるエコーであり、その下のエコーは多重反射の影響によって生じたものである。

鉄筋の存在により生じるエコーが凸状となる理由としては、電磁波レーダのアンテナから放射される電磁波がその進行方向(下向き)に対して広がりを持っているために、図-8 に示すように鉄筋直上通過前の位置 A においても前方の鉄筋からの反射波を受信する。よって、位置 A では装置から鉄筋までの斜めの距離を表示することになる。装置から鉄筋までの距離は、装置が鉄筋直上の位置 B になった時に最短となり、その後、再び装置は鉄筋までの斜めの距離を表示する。その結果、断面画像では、鉄筋直上をピークとする左右対称の凸形状として鉄筋が表現されることになる。

次に、ひび割れの有無による断面画像の鉄筋の存在に

より生じる影の形状の違いについて検討した。ひび割れがある(ひび割れ幅 2mm) 場合の画像とひび割れのない場合の画像を並べてさせると、図-9 のようになり、赤色の反射の強い部分のみに着目すると頂点から最下点までの長さが変わることが分かる。図-10 のイメージ図に示したように、①の部分ではひび割れありの画像がなしの画像の内側にあり、②の部分ではひび割れありの画像が有りの画像の外側にあるという特徴を推定した。

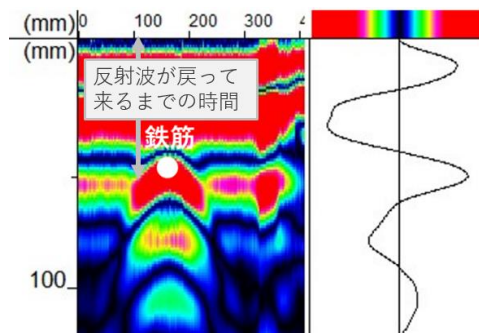


図-7 電磁波レーダ法の結果




図-8 鉄筋の存在により生じるエコーの形状




図-9 ひび割れなしとありの場合のエコー




図-10 ひび割れ有無による違い

次に、ひび割れの有無により断面画像が変化するメカニズムについて検討した。これは、ひび割れ部分の空気層とコンクリート層において電磁波が屈折することによ

って、ひび割れがあるとひび割れがない場合よりも電磁波を受信するまでの時間が長くなるためではないかと考えられる。その理由としては、図-11においてひび割れがない場合はaのように直進するが、ひび割れがある場合はbのように屈折するためではないかと推察される。このとき、屈折により往復距離が変わることで、図-7に示した反射波が戻ってくるまでの時間が変化することため、画像が図-10のように変化すると推測した。

その場合、屈折の程度としては以下のように考えることができる。なお、電磁波の屈折については若林ら⁵⁾の研究を参考にした。

$$n_1 \sin \theta_1 = n_2 \sin \theta_2 \quad (1)$$

ここで、 n_1 はコンクリート中の屈折率、 n_2 は空気中の屈折率である。空気中の屈折率は1であり、コンクリート中の屈折率は、比誘電率を ϵ としたときに以下の式より求められる。

$$n = \sqrt{\epsilon} \quad (2)$$

たとえば、入射角 θ_1 を 30° とし、比誘電率3とした場合について検討する。

式(2)より、 $n_1 = \sqrt{3}$ となる。また、式(1)より $\sqrt{3} \sin(30^\circ) = \sin \theta_2$ となり、 $\theta_2 = 60^\circ$ となる。したがって、ひび割れ幅を x としたときに図-11のaとbの距離について計算すると、式(3)、(4)のようになる。

$$a = \sqrt{\left(\frac{70}{\sqrt{3}} + \sqrt{3}x\right)^2 + (70+x)^2} \quad (3)$$

$$b = \frac{140}{\sqrt{3}} + 2x \quad (4)$$

これを基に、ひび割れ幅と往復の距離の差を求め、表-3に示した。この例では、比誘電率3の場合を求めたが、KEYTECのホームページ⁶⁾によると、コンクリートの比誘電率は4から20とされている。比誘電率が大きくなるほど、屈折の影響は大きくなるため、計算で求めた例よりもひび割れの影響が大きくなると考えられる。そこで、電磁波レーダ法の出力画像(図-9)において、かぶり50mmのひび割れなしの供試体とひび割れ幅2mmの供試体の結果画像で距離の差を比較したところ、差は2.3mm(計算上は2mm)となるため、実際に計算で求めたよりも屈折の影響は大きくなるのが推察される。




図-11 ひび割れによる電磁波の屈折

表-3 ひび割れ幅と往復の距離の差

x (mm)	0.0	1.0	2.0	3.0	4.0	5.0	10.0
2a-2b (mm)	0.0	0.5	1.0	1.5	2.0	2.4	4.3

4.2 機械学習を用いた詳細評価に関する検討

機械学習とは、コンピュータがデータから反復的に学習し、そこに潜むパターンを見つけ出すことである。学習した結果を新たなデータにあてはめることで、パターンにしたがって将来を予測することができるという仕組みである。

機械が学習するために、学習の元となるデータを入力値として用いる。この入力値を「機械学習アルゴリズム」と呼ばれる処理を通し、データの分類、認識などの処理(学習モデル)を見つけ出す。この処理を学習処理という。その後、学習モデルを用いることで、学習後に入力された未だ学習していないデータに対して、分類や識別をできるようにする判定処理を行う。

本検討では、この機械学習のうち転移学習とHOG特徴量による学習をもって電磁波の出力画像からひび割れの判定を行うこととした。

(1) 転移学習による学習

転移学習とは、ディープラーニング³⁾の一つである。事前学習済みのネットワークを利用して学習させることができ、ゼロからネットワークに学習させるよりもはるかに簡単である。少ない数の学習イメージでも学習可能であるという特徴がある。

本検討では、事前学習済みのAlexNet 畳み込みニューラルネットワーク⁴⁾を微調整して、電磁波レーダ画像を分類した。AlexNetは、100万枚を超えるイメージで学習しており、イメージを1000個のオブジェクトカテゴリに分類することができる。このネットワークは広範囲にわたるイメージについての豊富な特徴表現を学習している。機械学習の学習率は e^{-4} (e はネイピア数)、エポック数は12とした。1エポックは反復10回とし、反復3回ごとに検証データによる検証(学習に使用していないデータによる精度の確認)を行った。

AlexNetを用いた転移学習を効率よく行うためには、画像を前処理する必要がある。ここでは、前処理の方法の違いによる精度の違いについて検討した。図-7の画像に対して画像処理を行って図-12のように、3つのパターン化した画像で表すことができる。

パターンIは色の閾値により、鉄筋の存在により生じる影の形状のみを切り出したものである。パターンIIは、パターンIと同様に色の閾値により、鉄筋の存在により生じる影の形状を切り出したうえで、切り出した部分を

塗りつぶしたものである。パターンⅢは、鉄筋部周辺を正方形に切り取ったものである。画像の情報量は、パターンⅢが一番多く、パターンⅡが一番少ない。なお切り出し時には、かぶりが必要であるが、出力時に鉄筋位置の自動検出および平均かぶりの算出を行っており、現場データのかぶりはその値を用いた。

機械学習は、供試体Ⅰおよび供試体Ⅱによる供試体データにより行い、データ数は

表-4に示す。精度は、パターンⅠが92%、パターンⅡが79%、パターンⅢが71%となり、パターンⅠが最も精度が良い結果となった。このとき、精度は学習に用いていない検証データにおけるの正解率としている。これは、パターンⅠの画像はパターンⅡと比較すると、鉄筋の存在により生じる影の形状の情報量が多く、パターンⅢと比較して、鉄筋の存在により生じる影の形状以外の情報がないためであると考えられる。



図-12 画像処理のパターン

表-4 学習データ数

	ひび割れあり	ひび割れなし
全データ	144	32
学習データ	72	16
検証データ	72	16

次に、供試体データにおける機械学習と、A火力発電所の現場データによる学習を行った。データは、表-5および表-6に示すとおりである。推定結果は、精度が供試体データで92%、現場データで96%であり、現場データの方が供試体データよりも精度が良い結果が得られた。これは、現場データは明らかに劣化が分かるものを使用したのに比較し、供試体データは、ひび割れ幅が最大で3mmであり、ひび割れありとひび割れなしの出力画像が近い形状であったためと思われる。

表-5 供試体データのデータ数

	ひび割れあり	ひび割れなし
全データ	108	48
学習データ	72	32
検証データ	36	16

表-6 現場データのデータ数

	ひび割れあり	ひび割れなし
全データ	111	111
学習データ	67	67
検証データ	34	34

(2)HOG 特徴量による機械学習

電磁波レーダの出力画像のひび割れの有無を機械学習により推定することを目的とし、ここでは、学習の方法としてHOG特徴量⁷⁾を用いた。検討ではHOG特徴量とマルチクラスのSVM(Support Vector Machine)分類器を使用して分類する方法を用いた。

HOGとは、Histograms of Oriented Gradientsの略であり、日本語では勾配方向ヒストグラムと訳される。特徴ベクトルの一種であり、輝度の勾配をヒストグラム化することが可能な手法である。画像認識における特徴量の1つで、2005年に発表されてから、文字認識や人や車両などを検出することに一定の精度が認められている。方法としては図-13のように、画像のピクセルを、いくつか(8×8程度)まとめて「セル」を作る。また、セルをいくつか(2×2~4×4程度)まとめて「ブロック」を作成し、セルとブロックを作成するとピクセル毎の輝度の変化の方向と強さをセル単位でヒストグラム化した後にブロック単位で正規化し、特徴ベクトルを求めることができる手法である。

SVMとは、分類アルゴリズムの一種で、分類アルゴリズムの中ではよく使われるものの一つである。本検討では、線形SVMにより特徴ベクトルを線で区切ることで、分類を行った。図-14に分類したイメージを示す。

HOG特徴量を用いた学習においては、輝度の勾配をヒストグラム化し学習を行うことが可能であるため、鉄筋の存在により生じるエコーの形状の違いを推定することに適している。なお、HOG特徴量による学習の画像の前処理はパターンⅠを用いて行った。この画像における特徴量を図-15に示す。




図-13 セルとブロック




図-14 SVM




図-15 HOG 特徴量

本検討では、供試体データと現場データの精度の比較を行った。データは転移学習による学習と同様のデータを使用し、データ数を表-5 および表-6 に示す。

結果は、精度が供試体データで95%、現場データで87%であり、現場データの方よりも供試体データの方が精度の良い結果が得られた。供試体データのように画像に差が少ない場合に精度が高くなることが確かめられた。

(3) 転移学習と HOG 特徴量による機械学習の比較

転移学習の結果は、現場データの方が精度よく判定されたが、HOG 特徴量による学習では、供試体データの方が精度よく判定された。これは、転移学習と HOG 特徴量では、学習の特徴が異なるからであると考えられる。転移学習は、一般的に一枚の画像全体を学習することから、現場データの画像のような多くの不確定な要因がある画像においても学習することができるため、現場データの方が精度良く判定されたと考えられる。このことから、電磁波レーダの画像においても、転移学習は HOG 特徴量による学習よりも適用範囲が広くなると推察される。一方、HOG 特徴量による学習では、画像をセルで分割し、セルごとに輝度の勾配ベクトルを求めるため、供試体データのような理想に近いデータの学習が適しており、供試体データの方が精度よく判定されたと考えられる。このことから HOG 特徴量による学習は、転移学習による学習よりも、よりひび割れ幅の小さな、潜伏期のひび割れを発見することができる可能性がある。

5. まとめ

本研究では、機械学習を用いて腐食ひび割れを推定することを目的として、ひび割れの判定手法を提案し、検証を行った。その結果として、以下のことが推定された。

- ・画像処理による簡易推定法では、数値解析ソフトウェア (MATLAB) の画像処理を用いて、鉄筋のエコーが隣のエコーと連続して繋がっているものを検出し、劣化を推定することができる可能性を示した。
- ・ひび割れがある場合とひび割れない場合の電磁波レーダによる断面画像の違いを比較した結果、鉄筋部の形状に違いがあるということが分かった。ひび割れがある場合は電磁波が屈折することにより、電磁波を送信してから受信するまでの時間が長くなるため、鉄筋部の形状が変化するというのを推測した。
- ・機械学習を用いた詳細評価に関する検討を行い転移学習と HOG 特徴量を用いることにより、機械学習によるひび割れの判定ができる可能性を示した。転移学習では、HOG 特徴量による学習よりも適用範囲が広くなり、HOG 特徴量による学習では転移学習による学習よりも、よりひび割れ幅の小さなひび割れを発見することができる可能性がある。

今後の課題としては、現在はデータのばらつきが大きいため、ほかの構造物での精度が下がる可能性があることが挙げられる。質の高いデータの収集により様々なコンクリート構造物に適用可能な学習を行う予定である。よって、今後の展望としては、新たな供試体の作成と GAN (敵対的生成ネットワーク)³⁾等によるシミュレーションを行っていく予定である。

参考文献

- 1) 溝淵利明：コンクリート構造物のメンテナンス長寿命化のための調査・診断と対策，日刊工業新聞，2019年9月
- 2) 遠藤雅守：電磁波の物理その発生・伝播・吸収・増幅・狂信を電磁気学で理解する，森北出版，2014年12月
- 3) 園田潤，木本智幸：畳み込みニューラルネットワークと敵対的生成ネットワークによる地中レーダ画像の物体識別，信学技報，vol. 118, no. 441SANE2018-123, p71-76, 2019年2月
- 4) 平山一希，陸慧敏，タンジュークイ，金亨燮，橋理恵，平野靖，木戸尚治：DCNN による LIDC データからのすりガラス状陰影の検出，医用画像情報学会雑誌，34 巻 2 号，p70-74, 2017年6月
- 5) 若林正樹，田中正吾：電磁波レーダを用いた鉄筋の深度及び径の計測に関する一考察，日本非破壊検査協会，59 巻 4 号，p183-188, 2010年4月
- 6) KEYTEC かぶり深さの測定原理：<https://www.keytec.co.jp/resources/rader-tecinfo/rader02/> (閲覧日 2020年1月2日)