

論文 深層学習を用いた RC 部材のひび割れ幅分布特性評価と分析

塚 大祐*1・千田 紘之*2・高橋 典之*3

要旨：地震による建物の損傷補修費用の積算を目的として、ひび割れ幅とひび割れ長さの組み合わせ量を表す「ひび割れ幅分布特性」についての研究が進められている。特に、設計時に修復性能評価の一環として補修費用を評価する際には、通常の構造解析にも適用可能な損傷量推定モデルの一部としての「ひび割れ幅分布特性」を把握することが重要である。本研究では、鉄筋コンクリート部材の「ひび割れ幅分布特性」の分析にあたり、ひび割れ量が多くなる鉄筋コンクリート壁部材を対象に深層学習を用いた損傷検出を実施し、形態学的画像演算処理による損傷量計測アルゴリズムを用いてひび割れ幅分布特性を評価・分析した。

キーワード：ひび割れ幅、壁部材、損傷量評価、深層学習

1. はじめに

地球環境保全および省資源化を目的として、建物を長期に維持管理する必要性が高まっている。建物の長期使用を促進するためには、供用期間中に発生する地震に対する修復性能を適切に評価し、維持管理を継続することのほうが解体・新設よりも建築主にとって経済合理性を有することを示す必要がある。この観点で修復性能評価を実施することを目的として、補修費用の積算に直結する地震損傷量推定に関する研究が進められてきた^{1),2)}。具体的には、鉄筋コンクリート（以下、RC）造建物の構造躯体を対象に、ひび割れ幅－ひび割れ長さ関係（特定のひび割れ幅を有するひび割れ長さがどれくらいの割合あるか）についての定量的な評価が検討されてきた。ひび割れ幅－ひび割れ長さ関係（以降、ひび割れ幅分布特性と呼ぶ）は、既往の研究^{3),4)}より一般に対数正規分布に従うことが分かっている。これを用いることで、対数正規分布を定める変数（具体的には中央値にあたる平均ひび割れ幅と、対数標準偏差）が分かれば、RC 部材のひび割れ幅分布特性、すなわち、ひび割れ幅とひび割れ長さの組み合わせ量を定めることができるようになる。ひび割れ幅分布特性を特定することができれば、これをもって簡易な損傷量推定モデルを展開し、修復性能評価を容易に実施できる基盤技術を提供できる。既往の研究⁴⁾で、構造部材種別（梁、柱、壁）および部材角によってひび割れ幅分布特性を定めるパラメータが変化することは示されているが、限られた試験体に対する分析であり、一般化したパラメータ特定モデルの確立には至っていない。その原因は、ひび割れ幅とひび割れ長さとの組み合わせ量として計測する作業および集計データ処理に膨大な労力と計算コストを要することが課題となっていたためである。そこで本研究では、損傷計測の省力化を目的として深層学習（セマンティック・セグメンテーション

技術⁵⁾）を用いた損傷検出手法によりひび割れ領域を検出するだけでなく、損傷量計測アルゴリズム⁶⁾をこれに併用することで、これまで計測作業面が広域で多大な労力を要した RC 壁部材に対しても容易にひび割れ幅と長さの組み合わせ量を算定できるようにした。そして、算定結果よりひび割れ幅分布特性を特定するパラメータについて分析を行った。

2. ひび割れ幅分布特性


特定のひび割れ幅を有するひび割れ長さが総ひび割れ長さに占める割合の確率密度分布を「ひび割れ幅分布特性」と呼ぶ。前述のとおり、既往の研究^{3),4)}において「ひび割れ幅分布特性」は対数正規分布に従うことが指摘されている。本研究では、ひび割れ幅分布特性を評価するための損傷量計測の省力化に、深層学習を用いた画像検出技術（セマンティック・セグメンテーション）を導入し、図-1 に示すフローに基づきひび割れ幅分布特性を求める。

本論文では RC 壁部材を対象として、RC 壁部材に発生するひび割れ損傷を適切に検出する深層学習モデルを構築する。深層学習を用いた画像認識では一般に、学習対象に応じた転移学習により精度の高い検出器を構築することが信頼性担保に寄与する。本研究においても、精度を確保した学習モデルを作成し、これを用いて損傷領域（すなわち「ひび割れ領域」で、「ひび割れ幅」と「ひび割れ長さ」双方が含まれる情報）を計測するとともに、形態学的画像演算処理を利用した損傷量計測アルゴリズム⁶⁾を用いて RC 壁部材のひび割れ幅分布特性を算定する。具体的には、ひび割れ分布特性を表す対数正規分布を特定するために、平均ひび割れ幅に相当する対数正規分布の中央値と、対数正規分布の分布のばらつきを示す対数標準偏差の値を評価する。

*1 東北大学 工学部 都市・社会環境工学科 （学生会員）

*2 東北大学大学院 工学研究科 都市・建築学専攻 （学生会員） 日本学術振興会特別研究員 DC

*3 東北大学大学院 工学研究科 都市・建築学専攻 准教授 博(工) （正会員）



3.1 学習データセットの構築

学習データ構築に用いた RC 壁部材の損傷画像として各試験体の最終変形状態 (1/100 rad.時) を用いた。その一例を図-3 に示す。背景・剥落・ひび割れの 3 つのクラスでラベリングを行い、損傷画像学習データにデータ増強⁹⁾ (図-4) を導入することで、トレーニングデータ 750 枚、バリデーションデータ 150 枚、検出精度検証データ 150 枚の計 1,050 枚の学習データセットを構築した。

学習データを転移学習させる事前学習モデルとして ResNet18¹⁰⁾を用い、転移学習に用いる学習モデルは Deeplabv3+¹¹⁾とした。これは、Spatial Pyramid Pooling¹¹⁾によって「ひび割れ」を対象とした領域検出において精緻に損傷領域が検出できることを確認¹²⁾しているモデルである。具体的には、学習対象の各種特徴を重みづけする過程において、エンコード（圧縮）された画像からの特徴と、より上層の（圧縮前の）特徴を、Skip connection により同時伝播することで、圧縮により欠落するひび割れ領域に特徴的なエッジ情報（ひび割れ領域境界部の細かいギザギザの形状情報）を保持できる。また、確率的に上層の特徴量を伝播させすぎない Stochastic dropout layer¹³⁾を追加することで細部の過剰な学習を防ぎ多様な特徴を学習可能としている。学習モデルの詳細については紙面の都合上、文献 12)を参照されたい。上層の特徴量を伝播させないための確率式は式(1)のように表される。

ここに、 P_l : 生存確率, P_L : 最終生存確率 (=0.5), 1 : 生存確率を決めるモジュール番号, L : Res Net モジュールの総数である。この式により、学習対象ごとに豊富な特徴量が学習可能な層の深さを可変にできる。なお、学習モデルで設定したハイパーパラメータを表-2 に記す。これは、文献 12) の学習器に対して RC 壁試験体のひび割れ抽出に適した値を予備検討により定めた結果である。

試験体	WM 試験体	WD2 試験体	WD1 試験体
内法高さ	780mm		
フランジ壁	B×D	700×150mm	
	主筋	16-D16($p_t=2.8\%$)	
	帯筋	2-D10@100($p_w=0.95\%$)	
ウェブ壁	壁厚	100mm	
	全長	1650mm	
	壁筋	D10@100 ダブル (縦横)	
M/QD	0.67		
N/BD σ_B	0 (軸力なし)		
養生方法	シールド	暴露 (ウェブ壁表面のみ)	
養生期間	3 ヶ月		8 ヶ月
σ_B (N/mm ²)	35.5	34.3	38.7







表-2 学習モデルのハイパーパラメータ

CNN	Res Net18 & DeepLabv3+
レイヤー	108 層
クラス数	3 (背景, ひび割れ, 剥落)
最適化手法	adam
初期学習率	0.0005
ミニバッチサイズ	10
入力画像サイズ	300×300



(a) 試験体撮影画像



(b) 損傷検出結果

図-5 損傷領域の検出例




図-6 ひび割れ領域におけるカラーノイズ




図-7 損傷量計測手法⁶⁾

3.3 RC 壁部材の損傷検出

学習対象試験体^{7),8)}の各部材角 (-1/500 Peak 時, -1/333 Peak 時, -1/200 Peak 時, -1/100 Peak 時) に対して損傷検出を行った。検出例を図-5 に示す。学習モデルを用いた検出は RGB 画素値を持つ画像データに対する結果として表現される。一般に RGB 画素としてのデジタルデータには、ひび割れ領域と非ひび割れ領域との境界のよ

うに輝度が急変する箇所カラーノイズ (図-6) が発生する。このカラーノイズを含むひび割れ領域検出において、ひび割れ部／非ひび割れ部に分類 (すなわち二値画像化することと同義の分類) をする場合、細いひび割れを漏らさず検出しようとするカラーノイズ等のためにひび割れ幅が総じて太くなる。一方、カラーノイズ等の影響を踏まえてひび割れ幅を正しく検出しようと二値画像上で閾値調整をすると、極めて細いひび割れ領域の検出漏れが生じる。本研究では、一般画像処理技術である細線化と外郭抽出をひび割れ領域に対して実施し、外郭と細線化線が重ならない領域では外郭を除いた領域をひび割れ領域とし、外郭と細線化線が重なる領域は外郭をひび割れ領域に残すことで、細いひび割れを検出漏れさせず、太めのひび割れのひび割れ幅がカラーノイズ分だけ太く評価される問題を解消することにした。

3.4 画像処理手法における計測限界に関する考察

前述したカラーノイズ (図-6) のように画像処理による損傷検出ではデジタル画像情報固有の誤差が生じる。あわせて光学機器センサーに依存する計測限界もある。例えば、本論文で検討した試験体損傷画像の画素分解能は 1pixel あたり 0.1667mm であり、原理的には、ひび割れ領域が画素の過半を占めるか否かでひび割れの存在を判断できるとしても 0.5pixel 以下 (本論文の場合は 0.08mm 以下) のひび割れは評価できない。この点については、実験時の試験体撮影を高解像度かつ適切な撮影環境下で実施する、あるいは、超解像技術を適用することでサブピクセルレベルの分解能を確保できるような画像処理技術の適用を検討するなどの工夫が必要になる。

4. RC 壁部材のひび割れ幅分布特性評価とその分析

4.1 ひび割れ幅-ひび割れ長さ組み合わせ量の計測

ひび割れ幅分布特性を計測する際に用いるひび割れ幅-ひび割れ長さ組み合わせ量の計測には、文献 6) の方法を採用した。その概要を図-7 に示す。ひび割れ領域と非ひび割れ領域に二値化された画像に対して細線化によるひび割れ領域中心線画素の抽出と、ひび割れ領域外郭画素の抽出を実施する。その後、ひび割れ中心線と垂直な直線について、中心線上の走査対象点を中心とした正方形のマスク内にある外郭画素に対する画素差分を式 (2) から求める。

$$difference = y - y_0 - k(x - x_0) \quad (2)$$

ここに、*difference* : 外郭画素と走査対象点との画素差分 (図-7 の *w1*, *w2*), (*x0*, *y0*) : 走査対象点の座標, (*x*, *y*) : 外郭画素の座標, *k* : ひび割れ中心線と垂直な線の傾きである。なお、*x* 軸は図-7 右向き、*y* 軸は図-7 上向きを

主軸としている。画素差分をひび割れ幅として、近接するひび割れ幅が同じ階級にあれば、各ひび割れ幅算出線（外郭画素と走査対象点を結ぶ線分）の二等分線間の距離を計算しひび割れ長さとする。また、近接するひび割れ幅が異なる階級にある場合は、線形補間により各階級に近接区間分の長さを式 (3) によって配分計算することでひび割れ長さを算出する。これらの操作によって、ひび割れ幅とひび割れ長さの組み合わせ量を算定する。

$$li = \frac{w_i - w_{i-1}}{w_2 - w_1} \times l \quad (3)$$

ここに、 w_1, w_2 : ひび割れ幅 ($w_1 \leq w_2$)、 l : ひび割れ長さ、 w_i : ひび割れ幅階級 i の区間上限値 (ただし、 $w_{i-1} = \min(w_1, w_2)$ かつ $\max(w_i) \leq w_2$)、 li : 当該階級に対応

するひび割れ長さである。なお、ひび割れ外郭画素が複雑に入りくみ、外郭線の曲率が極端に大きくなる箇所では (文献 6) では「ひび割れコーナー部」と呼んでいる)、ガウス関数を乗じることで外郭線の局所的な凹凸を平滑化してからひび割れ幅を計測することで、ひび割れコーナー部で極端に大きなひび割れ幅を算出しないようにしている。また、本研究におけるひび割れ幅階級は 0.05mm 刻みとした。計測手順のさらなる詳細は文献 6) を参照されたい。

4.2 RC 壁部材のひび割れ幅分布特性の評価

前節で取得したひび割れ幅とひび割れ長さの組み合わせ量を、横軸にひび割れ幅 (0.05mm ごとの階級)、縦軸に当該階級のひび割れ幅を有するひび割れ長さが総ひび割れ長さに占める割合をとって図-8~19 にグラフ化し




図-8 WM 試験体 1/500 rad.




図-12 WD1 試験体 1/500 rad.




図-16 WD2 試験体 1/500 rad.




図-9 WM 試験体 1/333 rad.




図-13 WD1 試験体 1/333 rad.




図-17 WD2 試験体 1/333 rad.




図-10 WM 試験体 1/200 rad.




図-14 WD1 試験体 1/200 rad.




図-18 WD2 試験体 1/200 rad.




図-11 WM 試験体 1/100 rad.




図-15 WD1 試験体 1/100 rad.




図-19 WD2 試験体 1/100 rad.

た。具体的には、図-8～11に WM 試験体、図-12～15に WD1 試験体、図-16～19に WD2 試験体の、部材角 1/500, 1/333, 1/200, 1/100 rad.におけるひび割れ幅とひび割れ長さの組み合わせ量を示した。このひび割れ幅とひび割れ長さの組み合わせ量を「ひび割れ幅分布特性」として対数正規分布に従う確率密度関数化し、ひび割れ幅・長さの対数標準偏差と中央値にあたる平均ひび割れ幅を求め、対数標準偏差と平均ひび割れ幅（中央値）の試験体・部材角ごとの推移をそれぞれ図-20、図-21に示す。次の節で、ひび割れ分布特性を定める変数（対数標準偏差と中央値）が対象試験体および部材角ごとにどのような変化傾向にあったかを分析する。




図-20 対数標準偏差の推移




図-21 中央値（平均ひび割れ幅）の推移

4.3 RC 壁部材の試験体種別・部材角ごとのひび割れ幅分布特性に関する分析

図-20より、ひび割れ幅分布特性の対数標準偏差の部材角変化の養成条件ごとの差は比較的小さいが、大まかな傾向として、乾燥収縮の少ないシールド養生試験体である WM 試験体で対数標準偏差が大きめであり、乾燥収縮のある 3 ヶ月養生の WD2 試験体、乾燥収縮のある 8 ヶ月養生の WD1 試験体の順で、対数標準偏差が小さめの値であった。これは、WD1, 2 試験体では乾燥収縮によって生じた既発ひび割れにひび割れが集約されやすかった一方、WM 試験体では载荷によるひび割れが分散発生したものと考えられる。また図-20の概形から、微小変形時はひび割れ発生が壁面全体に広がる状態（対数標準偏差が比較的大きい値）となり、その後 0.005 rad.までは多くのひび割れで幅はそのままに一部のひび割れの幅のみが拡がり（対数標準偏差が小さくなり）、さらにその後の大変形時には各ひび割れが各々拡がる（対数標準偏

差が大きくなる）傾向が見られた。また図-21より、平均ひび割れ幅の部材角変化分も養成条件ごとの差は大きいものの、WM 試験体でひび割れ幅の平均ひび割れ幅はやや大きめで、全体の概形から部材角が大きくなるにつれ平均ひび割れ幅が大きくなる傾向が確認された。なお、対数正規分布を仮定しているひび割れ幅分布特性において、ひび割れが分散した WM 試験体では頻度（長さ）は小さくても（短くても）太いひび割れが局所的に存在したことで対数正規分布の中央値が引き上げられた一方、ひび割れが集約したと考えられる WD1 および WD2 試験体では、乾燥収縮による既発ひび割れに馴染むようにひび割れ拡幅が生じ、局所的な太いひび割れの発生が抑制され、対数正規分布の中央値が引き上げられなかったものと推察される。




図-22 RC 部材のひび割れ幅分布特性における対数標準偏差の比較

5. 他の RC 部材のひび割れ幅分布特性との比較・考察

既往の研究¹⁴⁾において、RC 柱部材、RC 梁部材の実大および約 1/3 スケール縮小試験体のひび割れ幅分布特性を計測し、その対数標準偏差を算定した結果が紹介されている。その対数標準偏差情報に、本研究で評価対象とした RC 壁部材のひび割れ幅分布特性の対数標準偏差を、それぞれ図-22に重ねて表示した。

部材角の増加に伴う RC 壁部材のひび割れ幅分布特性の対数標準偏差の変化は比較的小さめなのに対し、RC 柱・梁部材では対数標準偏差の増加分が RC 壁部材よりも大きくなる傾向にあった。ただし、同一変形角に着目すると、ひび割れ幅分布特性の対数標準偏差の値そのものが、約 1/3 スケール縮小試験体の部材種別（梁、壁）と実大試験体の部材種別（梁、柱）とで異なり、縮小試験体のほうが実大試験体より対数標準偏差が大きい傾向

にあり、梁部材のほうが壁部材および柱部材よりも対数標準偏差が大きくなる傾向が見られた。柱部材、梁部材、壁部材とでひび割れ分布特性の対数標準偏差が変わる原因については、今後より実験データを収集することで詳細な分析をする必要があるが、可能性のひとつとして、厚みのある柱部材や梁部材に比べて薄い壁部材では、3次元的な応力負担領域が部材表面に現れやすく、部材表面の損傷が広域に広がる傾向が対数標準偏差に反映されているのではないかと考えられる。

6. まとめ

深層学習技術を用いて RC 壁部材の損傷画像からひび割れ領域を検出し、形態学的演算処理を通してひび割れ幅－ひび割れ長さの組み合わせ量を計測することによって、RC 壁部材のひび割れ幅分布特性の評価・分析を行った。以下に得られた知見を示す。

- 1) 損傷領域検出において、一般画像処理技術である細線化と外郭抽出をひび割れ領域に対して実施し、外郭と細線化線が重ならない領域では外郭を除いた領域をひび割れ領域とし、外郭と細線化線が重なる領域は外郭をひび割れ領域に残すことで、細いひび割れを検出漏れさせず、また、太めのひび割れのひび割れ幅がカラーノイズ等の分だけ太く評価される問題を解消した。
- 2) 検討対象とした RC 壁部材では、乾燥収縮の少ないシールド養生試験体である WM 試験体でひび割れ幅分布特性における対数標準偏差の値がやや大きく、乾燥収縮のある 3 ヶ月養生の WD2 試験体、乾燥収縮のある 8 ヶ月養生の WD1 試験体の順で、対数標準偏差の値が小さくなった。これは、WD1、2 試験体では乾燥収縮によって生じた既発ひび割れにひび割れが集約されやすかった一方、WM 試験体では載荷によるひび割れが分散発生したものと考えられる。
- 3) ひび割れ幅分布特性の対数標準偏差は、縮小試験体のほうが実大試験体より大きく、梁部材のほうが壁部材、柱部材よりも大きくなる傾向が見られた。

参考文献

- 1) 高橋典之, 中埜良昭: 複数回地震動を受ける鉄筋コンクリート構造物の損傷量推定手法に関する考察, コンクリート工学年次論文集, Vol.30, No.3, pp.1027-1032, 2008.7
- 2) Takahashi, N. and Nakano, Y.: Seismic Repair Cost of R/C Structures Using a Geometrical Damage Estimation Model, Proc. of the First International Conference on Computational Design in Engineering, pp.515-518, Nov. 2009
- 3) 滝本和志, 長澤保紀, 石井清: ひび割れデータを用

いた RC 部材の損傷度評価に関する実験的研究, 土木学会論文集, No.760/V-63, pp.135-145, 2004.5

- 4) Takahashi, N., Takahashi, E. and Nakano, Y.: Experimental Study on Damage Quantification of R/C Members Under Earthquakes, Proc. of the Ninth U.S. National and Tenth Canadian Conference on Earthquake Engineering, Paper No.237, Jul. 2010
- 5) Long Jonathan, Evan Shelhamer, and Trevor Darrell: Fully convolutional networks for semantic segmentation, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition 2015, pp.3431-3440, 2015. 6
- 6) 王一哲, 耳塚友貴, 千田紘之, 高橋典之: 画像解析による RC 部材のひび割れ幅分布特性の計測に関する研究, コンクリート工学年次論文集, Vol.42, No.2, pp.673-678, 2020.7
- 7) 千葉幸大ほか: 微小変形領域における RC 造耐震壁の非線形性に関する検討(その 19) 乾燥収縮ひび割れを変数とした耐震壁の静的載荷試験, 日本建築学会大会学術講演会梗概集, 構造 II, pp.1157-1158, 2018.9
- 8) 佐藤真俊ほか: 微小変形領域における RC 造耐震壁の非線形性に関する検討(その 23) 養生期間の異なる試験体の静的載荷実験結果, 日本建築学会大会学術講演会梗概集, 構造 II, pp.1259-1260, 2019.9
- 9) Miao Z., Ji X., Okazaki T., Takahashi N.: Pixel-level multcategory detection of visible seismic damage of reinforced concrete components, Computer Aided Civil and Infrastructure, Vol.36, Issue 5, pp.620-637, Feb. 2021
- 10) Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun: Deep Residual Learning for Image Recognition, Proc. of 2016 IEEE Conference on Computer Vision and Pattern Recognition, pp.770-778, Jun. 2016
- 11) Liang-Chieh Chen, Yukun Zhu, George Papandreou, Florian Schroff, Hartwig Adam: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, Proc. of 15th European Conference on Computer Vision, pp.833-851, 2018
- 12) 千田紘之, 高橋典之, 山田朋幸: 2021 年福島県沖の地震による被害調査への深層学習活用型画像診断システムの適用および画像診断用撮影マニュアル策定のための基礎的検討, 構造工学論文集, Vol.68B, pp.1-8, 2022.4
- 13) Lei Jimmy Ba and Brendan Frey: Adaptive dropout for training deep neural networks, Advances in Neural Information Processing Systems, Dec. 2013
- 14) 日本コンクリート工学会: コンクリート構造物のひび割れ進展評価手法に関する研究委員会報告書, 2013.7