

論文 X線CT画像の教師なし深層学習によるコンクリート内部のひび割れ抽出

橋本 勝文^{*1}

要旨 : X線CT画像からのひび割れ抽出に関して、空気（空隙・気泡・ひび割れ）と固体の従来の二値化画像ではなく、教師なし学習によるニューラルネットワーク（NN）を持つ深層学習により、ひび割れの情報（位置や幅）を定量的に出力可能なAI（人工知能）を構築することを目的とした。特に、NNの一種であるオートエンコーダを適用し、X線CT画像内のひび割れを異常箇所・異常度として数値（定量）化する手法を適用した。その結果、学習および入力データの分解能を適切に設定することで、出力された異常度の可視化画像では、空隙や気泡との分離と同時に従来の画像処理に対して高い精度でひび割れの情報を抽出できた。

キーワード : X線CT, ひび割れ, 人工知能, 深層学習, オートエンコーダ, 異常検知

1. はじめに

対象とする材料の内部構造を3次元で可視化する非破壊イメージング技術として、X線コンピュータ断層撮影装置等を用いた放射線技術（以下、X線CT法）が一般に広く適用されている。X線撮影することで得られるX線吸収係数のデータを再構築することで、材料内部を構成する物質の密度に応じたX線の透過性を示すCT値に基づく画像を取得するものである。コンクリートを対象とした場合、空隙や気泡の分布、細孔構造の計測やひび割れの抽出を目的に、内部構造を把握できる手法として実験室内での試験方法として応用されるが、実構造物を対象とした適用事例も多い。特に、劣化や損傷によるコンクリート内部のひび割れの発生および進展の把握、ひび割れ内での物質移動の解明等を目的として、X線CT法をコンクリート中のひび割れの抽出のために高度利用した研究事例が多数報告されている^{1),2)}。

コンクリートを対象物とした場合の従来のX線CT法では、一般にX線吸収係数等で決定される画像ピクセルのCT値に閾値を設け、空隙・気泡やひび割れ（空気）と固体の二値化画像が作成される^{3),4)}。しかしながら、閾値の決定方法が曖昧なことが多く、ひび割れの抽出結果が正確に得られない場合がある。図-1にコンクリートのX線CT画像内におけるひび割れ抽出プロセスの一例を示す。X線吸収係数に基づく256階調（8ビット）のグレースケール画像では、密度が高い物質ほど白く、密度が低い物質ほど黒く表示されることになる。このとき、コンクリート中に硬化後に含まれる空隙・気泡と外力や劣化の作用により発生したひび割れは、同じ「空気」として黒い画素値を持つ。そのため、上述のCT値に閾値を設けて「空気」と「固体」の二値化処理を行った場合、ひび割れを空隙・気泡と分離することは原理上不可能である。ひび割れ以外の「空気」を微細なノイズとし




図-1 X線CT画像内のひび割れ抽出（従来）

て二値化画像から取り除くために、画像の補正処理や演算フィルタを適用することもできるが、この場合、二次処理を施した画像においては、抽出されたひび割れの形状に関する情報も同時に失われる（図-1参照）。

X線CT画像内のコンクリート中のひび割れを抽出するために、入力画像と解（ひび割れの情報）を学習データセットとしたAI（人工知能）を用いた深層学習（教師あり学習）による先行研究がある^{5),6)}。このとき、空隙や気泡の除去とひび割れの抽出が同時に高い精度で再現することを示しているが、未学習のデータに対する精度低下が懸念される。また、無数の教師データを用意することは実際には不可能である。

以上の背景より、出力結果が学習時のデータに依存しやすい教師あり学習（ひび割れ（位置・幅）の情報を学習）ではなく、教師なし学習（ひび割れの無いコンクリートの画像のみを学習）によるオートエンコーダを用いた異常検知手法^{7),8)}により、X線CT画像内の異常箇所・異常度をひび割れの位置・幅として数値（定量）化する手法を提案することを本研究の目的とした。

2. 材料と方法

2.1 模擬ひび割れコンクリート供試体の作製

普通ポルトランドセメント（密度：3.16 g/cm³，比表面

^{*1} 北海道大学大学院 工学研究院土木工学部門准教授 博士（工学）（正会員）

表-1 コンクリートの配合

Unit content (kg/m ³)			
C	W	S	G
426	213	853	853

C:セメント W:水 S:細骨材 G:粗骨材




図-2 供試体作製の概要

積: 3320 cm²/g) を使用してコンクリート供試体を作製した。W/C を 50%, s/a を 50%としたコンクリート供試体を作製した。粗骨材には静内産の砕石(表乾密度: 2.75g/cm³), 細骨材にはセメント強さ試験用標準砂(JIS R 5201)を使用した。表-1 に練混ぜ時のコンクリートの配合を示す。 α -グルコースを主成分とする可溶性の高分子膜材料(厚さ: 20 μ m および直径: 90mm)を図-2 に示す打設時の手順でコンクリート供試体の内部に配置した。これにより、ひび割れの模擬的な形成を試みた。なお、供試体内部に設置する膜材料の枚数を 2, 4, 8 枚とすることで形成する模擬ひび割れ空間の幅を制御した。10cm の高さまでの一層目の打込み後に高分子膜材料を所定の枚数設置し、直後に二層目の打込みを行った。


2.2 X線CT画像による模擬ひび割れの可視化

μ フォーカス X 線 CT を用いて模擬ひび割れ空間の観察および形成された模擬ひび割れの厚さを測定した。本研究で供試体の撮影に使用した X 線 CT スキャナは、マイクロフォーカス X 線 CT 装置 KYOTO-GEO μ XCT (TOSCANER-32250 μ HDK) ⁵⁾である。ここでは、視野サイズを約 100mm として 1024×1024 画素で出力を行った。そのため、最小ピクセルサイズは 98 μ m×98 μ m (スライス幅: 94 μ m) である。なお、供試体断面の目視外観上においては、上記の膜材料の使用により形成された模擬ひび割れはコンクリート表面に到達しておらず、内部のみ存置できていることを確認している。


2.3 教師なし深層学習によるひび割れ抽出

(1) オートエンコーダによる異常検知

オートエンコーダ(自己符号化器)とは、効果的な次元削減方式として提案されたニューラルネットワークの一つ(AIモデル)であり、学習パターンを入力データと



a) 学習データの入力画像と復元画像("4"と"9")



b) 学習に用いていないデータの異常検知("5"と"8")

図-3 オートエンコーダの構造

同じ出力データを目標とする教師なし学習を行うものである⁶⁾。入力データに対して、次元削減や特徴抽出を行うことでデータを圧縮(エンコード(符号化))し、エンコードしたパターンを復元(デコード(復号化))するオートエンコーダは、データの異常検知にもしばしば応用される。すなわち、異常な情報を含まないデータを入力値として正しく学習できた場合、入力値に異常がない場合には高い復元性で出力されるのに対し、入力値に異常がある場合には入力値と出力値の間に誤差が生じる。図-3 に示すように、入力データと同じ画像を復元する学習によれば、学習に用いたデータは正しく復元できているのに対し($X \approx X'$)、学習に用いられていないデータは正しく復元できていない($X \neq X'$)。このように、元画像(入力データ)と復元画像(出力データ)の誤差により入力データの異常度を定量化できる。本研究では、学習に用いるデータはひび割れを含まないコンクリートの X 線 CT 画像であり、ひび割れを含む X 線 CT 画像を入力した際に、入力画像と復元(再構成)画像との差分から得られる異常度(再構成誤差)の大きい箇所をひび割れとして抽出する。

(2) ニューラルネットワークの構造

ディープラーニングを試行するための GUI ツールとして、ソニーネットワークコミュニケーションズが提供している Neural Network Console⁶⁾を使用した。本研究で導入したニューラルネットワーク内のエンコーダおよび

デコーダは、それぞれ複数の畳み込み層と逆畳み込み層を有している。また、過学習を防止して学習を効率的かつ安定して進めるために Dropout 層と Batch Normalization 層を配置している。Neural Network Console は、ニューラルネットワーク構造の自動最適化機能を有している。本研究では、50 個のネットワークモデルをランダムに生成し、各モデルにおいて反復学習回数は 50 回と 100 回に設定した。このうち、学習過程において最も高い精度が得られたモデルを採用した。入力／出力層のユニットサイズ(画像データ)は、3×3, 5×5, 10×10, 30×30, 50×50 ピクセルの 5 ケースとした。入力画像に対する出力画像の差分を二乗して異常度(再構成誤差)として計算した。

(3) X 線 CT 画像と入力データ

図-4 に円柱コンクリート供試体内部に設置する膜材料の枚数を 2, 4, 8 枚とした場合の X 線 CT 法により得られた断面画像(供試体中心の縦断面)を示す。膜材料の枚数を 2 枚とした供試体(以下、C2)の場合には幅 1~4 ピクセル(0.1~0.4mm 程度)、膜材料の枚数を 4 枚とした供試体(以下、C4)の場合には幅 4~20 ピクセル(0.4~2.0mm 程度)、膜材料の枚数を 8 枚とした供試体(以下、C8)の場合には幅 14~20 ピクセル(1.4~2.0mm 程度)のひび割れを模擬した空間(以下、ひび割れ)が形成されていることを確認した。


1024×1024 ピクセルで構成される 8bit (256 階調のグレースケール)の断面画像のうち、ひび割れを含まない 300×300 ピクセルの領域を学習データ(No.1, No.2 および No.3)の元画像とした。なお、一回の反復学習に用いるデータセットに含まれる画像数は、各ユニットサイズにより 300×300 ピクセルの元画像の構成数の半分(例えば、5×5 ピクセルの場合、 $60 \times 60 \div 2 = 1800$ 個)とした。すなわち、ユニットサイズが大きく(小さく)なるほど学習データ量が減少(増加)する。一方で、ユニットサイズが大きく(小さく)なるほどピクセル数が多い(少ない)ため、演算量は増加(減少)することになる。同様に、300×300 ピクセルのひび割れを含む領域を評価データ(領域 A および領域 B)の元画像とし、オートエンコーダによる異常検知に基づく教師なし深層学習によるひび割れ抽出を行う対象とした。

3. 結果と考察


3.1 X 線 CT 画像による内部可視化画像

図-5、図-6 および図-7 に C2, C4 および C8 の領域 A および領域 B の X 線 CT 画像を示す。同図中には、各領域内で認められるひび割れの法線方向に 6 箇所得られる輝度値のラインプロファイルを図-8 に示す。


C2 の場合には、輝度値の極小値に対して輝度値の低下



a) C2 (膜材料の枚数 : 2 枚)



b) C4 (膜材料の枚数 : 4 枚)




c) C8 (膜材料の枚数 : 8 枚)

図-4 X 線 CT 画像と入力データ画像の取得位置


を示している範囲も小さい。C4 の場合には、近接する骨材や空隙の影響で輝度値に変動が大きいものの、輝度値の極小値に対して輝度値の低下を示している範囲が広がっていることがわかる。一方、C8 の場合には、輝度値の低下を示している範囲は C4 と同程度でありながら、輝度値が極小値に近い値を示す範囲が広がっている。以上の結果は、上述した画像内で確認されたひび割れ幅と膜材料の数の関係と良く対応している。

3.2 異常検知手法によるひび割れ抽出

図-9 に学習に用いた入力画像のユニットサイズと学




a) 領域 A




b) 領域 B

図-5 X線 CT 画像 (C2)




a) 領域 A




b) 領域 B

図-6 X線 CT 画像 (C4)




a) 領域 A




c) 領域 B


図-7 X線 CT 画像 (C8)



a) C2 (膜材料の枚数: 2 枚)



b) C4 (膜材料の枚数: 4 枚)



c) C8 (膜材料の枚数: 8 枚)

図-8 ひび割れ部の輝度値 (ラインプロファイル)

習誤差の関係を示す。いずれの反復回数においても、画像サイズが小さくなるにつれて学習誤差は低下しているが、3×3 ピクセルとした場合には反復学習回数が 100 回とすることで学習誤差は大きくなっている。このとき、図中の数値に示すように、上記の場合に演算量（順伝播の乗加算回数）が著しく小さくなったことが原因と考えられる。そのため、ユニットサイズを 3×3 ピクセル ($d=3$) とし反復回数を 50 回 ($n=50$) とした場合（ケース A）と、ユニットサイズを 5×5 ピクセル ($d=5$) とし反復回数を 100 回 ($n=100$) とした場合（ケース B）について、評価データ（ひび割れを含む対象領域）に対して出力された異常度の可視化画像を作成した。

図-10、図-11 および図-12 にケース A、同様に、図-13、図-14 および図-15 にケース B について、異常度の可視化画像を C2、C4 および C8 の対象領域について示す。なお、各画像内での異常度の最大値と最小値






図-9 学習方法と学習誤差の関係

を 0~255 の輝度値として X 線 CT 画像と同様に 256 階調のグレースケールで画像を作成した。また、各図中の輝度値のラインプロファイルと X 線 CT 画像における輝度値のラインプロファイルの平均値を図-16 に示す。こ




a) 領域 A




b) 領域 B

図-10 異常度の可視化画像
C2 (d=3・n=50) ケース A




a) 領域 A




b) 領域 B

図-11 異常度の可視化画像
C4 (d=3・n=50) ケース A



a) 領域 A



b) 領域 B

図-12 異常度の可視化画像
C8 (d=3・n=50) ケース A

れより、画像上ではケース A の方がケース B よりもひび割れ部を鮮明に可視化できている。ケース A の場合、すべての場合にひび割れ部を可視化画像として抽出できおり、図-16 のラインプロファイルにおいても輝度値の変化量や輝度値の極小値に対して輝度値の低下を示している範囲は X 線 CT 画像の結果と概ね一致している。一方、ケース B の場合、C2 において可視化画像においてひび割れ部の抽出結果が鮮明ではなく、上述の輝度値のラインプロファイルに関する X 線 CT 画像との整合性も低いことがわかる（図-16a参照）。ケース A の場合、ユニットサイズは縦横 3 ピクセル（約 0.3mm）として学習データを入力していることから、C2 において幅 1～4 ピクセルのひび割れ検出に対応できたものの、ケース B の場合、学習データのユニットサイズ（縦横 5 ピクセル（約 0.5mm）の範囲）が検出対象とするひび割れ幅（幅 1～4 ピクセル）よりも大きいためであると考えられる。

3.3 異常検知手法による空隙および気泡の除去

ひび割れを含まない領域から作成した画像を学習データとすることで、提案手法においては X 線 CT 画像内のひび割れ部に高い異常度を出力し、硬化後にコンクリートに含まれる空隙や気泡に低い異常度を出力することになる。その結果、細孔径が対象領域内に含まれるひび割れより幅も小さい場合には比較的低い異常度を示しており、可視化画像において除去できている場合もある。しかしながら、学習に用いた画像ユニットサイズに応じ

て空隙・気泡の濃淡が出ているものの、すべての空隙・気泡を除去するには至っていない。抽出対象とする除去対象とする空隙や気泡の大きさとひび割れ幅、学習および入力データの間係を適切に組み合わせることで、X 線 CT 画像からのひび割れ抽出と空隙・気泡の除去が同時に実行できる可能性がある。


4. まとめ

コンクリートの X 線 CT 画像内でひび割れ部の抽出を行うことを目的とし、教師なし深層学習による異常検知手法を適用した。その結果、以下の知見が得られた。


- ・オートエンコーダによる異常検知手法を X 線 CT 画像内のひび割れ抽出に適用することで、学習に用いた画像の分解能に応じた幅を持つひび割れを抽出できる。
- ・学習データの画像サイズを構成するピクセル数が検出対象とするひび割れ幅よりも大きい場合、ひび割れの抽出精度は低下する。
- ・抽出対象とするひび割れ幅と除去可能な気泡・空隙の大きさに対して、学習データの作成および画像データの入力を適切に組み合わせる必要がある。

謝辞

本研究で得たデータの一部は、公益財団法人日本コンクリート工学会 2021 年度研究助成（X 線 CT 画像の教師なし深層学習によるコンクリート内部のひび割れ抽出、




a) 領域 A




b) 領域 B

図-13 異常度の可視化画像
C2 ($d=5 \cdot n=100$) ケース B




a) 領域 A




b) 領域 B

図-14 異常度の可視化画像
C4 ($d=5 \cdot n=100$) ケース B




a) 領域 A




c) 領域 B


図-15 異常度の可視化画像
C8 ($d=5 \cdot n=100$) ケース B



a) C2 (膜材料の枚数: 2 枚)



b) C4 (膜材料の枚数: 4 枚)



c) C8 (膜材料の枚数: 8 枚)

図-16 X線 CT 画像の輝度値と異常度 (ラインプロファイル)

研究代表者：橋本勝文）により得られたものである。ここに記して、謝意を表す。

参考文献

- 1) Sugiyama, T. and Promentilla, M. A. B. : Advancing Concrete Durability Research through X-ray Computed Tomography, Journal of Advanced Concrete Technology Vol.19, pp.730-755, 2021
- 2) 人見尚, 竹田宣典, 入矢桂史郎: コンクリートの空隙構造を用いたカルシウム拡散に関する検討, コンクリート工学年次論文集, Vol.29, No.1, pp.915-920, 2007
- 3) 高木幹雄, 下田陽久: 画像解析ハンドブック, 東京大学出版会, pp.1520-1534, 2004
- 4) 村上伸一: 画像処理工学, 東京電機大学出版局, pp.28-33, 2004
- 5) 島本由麻, 鈴木哲也: 機械学習を用いた X 線 CT 画像におけるひび割れ損傷抽出, 農業農村工学会論文集, Vol.88, No.2, pp.IV_15-IV_16, 2020
- 6) Kim, Y., Ha, S. J. and Yun, T. S. : Deep learning for extracting micro-fracture: Pixel-level detection by convolutional neural network, E3S Web of Conferences, Vol.205, No.9, 03007, 2020
- 7) 一色正晴: 非破壊検査分野での ICT および AI の活用 AI フレームワークを用いた画像ベースの異常検知手法の紹介, 非破壊検査, Vol.70, No.2, pp.50-54, 2021
- 8) Chow, J. K., et al., Anomaly detection of defects on concrete structures with the convolutional autoencoder, Advanced Engineering Informatics, Vol.45, 101105, 2020