

グラウトを含む岩石コアの X 線 CT 画像 に対する機械学習による材料識別

田川 千尋^{1*}・中島 伸一郎¹・吉津 洋一²・井関 宏崇³・岸田 潔⁴

山口大学大学院 創成科学研究科建設環境系専攻 (〒755-8611 宇部市常盤台 2-16-1)

株式会社ニュージェック (〒531-0074 大阪市北区本庄東 2-3-20)

関西電力株式会社 (〒530-8270 大阪市北区中之島 3-6-16)

京都大学大学院 工学研究科都市社会工学専攻 (〒615-8510 京都府京都市西京区京都大学桂)

*E-mail:a008veu@yamaguchi-u.ac.jp

本研究では、き裂にグラウト材が充填された岩石コアの X 線 CT 画像から、母岩、グラウト、空隙の材料識別を機械学習によって自動識別を行う。X 線 CT は岩石試料内部の材質やき裂の分布を非破壊的に観察する有効な手段であるが、構成材料間の CT 値が似通っている場合には材料識別が難しい。自動識別で得られた識別結果は、識別の過程における教師データの与え方によって変化する。本論では、与えられた教師データから導かれた識別結果を比較して、最適な教師データの与え方について検討した。結果として、教師データに学習させる手動識別の範囲が、範囲の大きさではなく、材料の境界部分や CT 値が混合している箇所を与えるなど多様性を重視しなければならないことがわかった。

Key words : grouting, rock, X-ray CT, machine learning, automatic segmentation

1. はじめに

重力式コンクリートダムでは、基礎岩盤の遮水性の確保や弱部補強のために、岩盤を削孔してセメントミルクを圧入するカーテングラウチングやコンソリデーショングラウチングがよく行われる¹⁾。その改良効果は原位置での透水試験や載荷試験で確認されるが、グラウト材が実際に、どのようにき裂内部に侵入し、充填していくのかという詳細なプロセスについては、未解明の部分が多い。本研究では、グラウチング施工後のチェック孔から採取されたボーリングコアを用いて X 線 CT によりコア内部を非破壊的に可視化することで、割れ目内部のグラウト未充填箇所の幾何学的な形状や、グラウト材質分布などの物質的な情報を観察した。その第一段階として、画素値に基づいて、母岩・き裂・グラウトを材料分離(セグメンテーション)する方法を検討した。材料分離においては、手作業による識別も手段として考えられるが、本研究では、より効率的に行うため機械学習を用いた自動識別を試行した。

2. 供試体および X 線 CT 撮像

供試体を採取した A ダムサイトは重力式コンクリートダムである。カーテングラウチング後の基礎岩盤のチェック孔で採取された深度 10 m~20 m のボーリングコアから、き裂へのグラウト材充填が確認できるものを選び X 線 CT 撮像を行った。チェック孔における基礎岩盤は砂岩と泥岩の互層構造であり、境界層及び砂岩、泥岩に複数の割れ目を有するため非常に透水性が高い。グラウトは、水・セメント比 W/C=1.5 の注入で、圧力が規定値に満たなかった場合に W/C=0.8, 0.6 の順に濃度を上げて注入した。

X 線 CT スキャナは、医療用のヘリカル CT スキャナを使用した。X 線 CT 画像はコア軸に沿って輪切りにスライスするように撮像した。スライス方向(コア軸)を Z 軸とし、その直交断面を XY 平面とする。CT 画像の空間分解能は XY 面内が 0.053mm、スライス厚 Z は 0.058mm である。画像は符号付き 16bit で出力した。

画像解析は ImageJ により行った。図-1(a)は泥岩層から採取されたボーリングコアでき裂にグラウト材が充填されている。ImageJ によりボーリングコアを 3 次元的に可視化したものが図-1(b)である。ここから、分析対象と

するグラウト材が含まれる局所要素を切り出した。

局所要素から画素値に基づいて、母岩、グラウト、空隙を識別（セグメンテーション）した。識別には機械学習プラグイン Trainable Weka Segmentation (TWS) を使用した²⁾。局所要素のCT値ヒストグラムを示す。母岩のCT値ピークは約1700、グラウト材のCT値ピークは約2000と確認できるが、CT値を共有している部分も多く、両者のCT値の閾値を一意に定めることは難しい。TWSを用いた画像識別により母岩、グラウト、空隙を識別し、それぞれのCT値を図-2(a)に示す。図より、母岩とグラウト材とでCT値が重なり合っている部分も、それぞれの材料が明瞭に分離されている。機械学習による材料識別が成功しているといえる。以下では、その機械学習による材料識別の概要を説明する。

3. 自動識別において手動識別が与える影響

画像識別には機械学習プラグインである TWS を用いた。TWS における画像識別の流れを以下で説明する。TWS では一枚の画像に対して、Gaussian blur などのフィルタによりノイズ除去などの画像処理をあらかじめ行う。また、同時並行で手動による識別を各材料（母岩・グラウト・空隙）に説明変数として一定範囲与える。この2つの工程で得られた結果をもとに識別器（ランダムフォレスト）により画像識別を行う。本研究ではこの手動識別が自動識別の結果に与える影響について実験的に考察した。画像識別に用いた供試体画像を図-3に示す。図-3(a)には、図に示す様に母岩、グラウト、空隙の3つの材料が含まれている。この画像内のグラウトと空隙にはそれぞれの特徴がある。グラウトは密度が均一ではなく部分的に母岩と同じCT値を持つ。空隙は連続した空隙とグラウト中に含まれる円状の空隙の2種類がある。本研究では画像識別に用いる画像を8bitに変換して行った。画素値はCT値に基づき0~255の値で示される。図-3(b)には図-3(a)に適当に引いた黄色の直線上の画素値を示す。グラフを見ると、空隙部分で下落していることは確認できるがグラウト部から母岩部と思われる画素値が漸移しているために、その境界は画素値においては曖昧である。本研究で用いた特徴検出フィルタはデフォルト設定の Gaussian blur, Sobel filter, Difference of gaussian, Hessian, Membrane projections の5つである。第一段階として図-4(a)の黄色の枠線内で示す様に母岩、グラウト、空隙にそれぞれ適当な範囲の手動識別を与える。ここで与えた手動識別は先ほど述べた説明変数として与えられる。手動識別を母岩は赤、グラウトは緑、空隙は紫の50ピクセル分の直線範囲とした。空隙に対する手動識別は図のように、画像を横断し連続している空隙に対して与えた。図-4(b)には自動識別の結果を示す。






図-1 グラウト充填コア (a) グラウト充填コアの実際の写真 (b) グラウト充填コアのX線CT撮像写真 (3次元表示) (c) グラウト充填コアから解析用に抜き出した局所要素




(a) 識別前の局所要素のCT値分布




(d) 識別後の局所要素のCT値分布

図-2 局所要素のCT値分布




(a) グラウトを含むひび割れのX線CT画像例




(b) a-b 測線上の画素値プロファイル (符号付16bitの画像を8bit画像に変換している)

図-3 識別に用いた供試体元画像




(a) 手動識別箇所




(b) 識別結果

図-4 母岩, 空隙, グラウトにそれぞれ1箇所の手動識別を与えた場合の識別結果画像




(a) 手動識別箇所




(b) 識別結果

図-5 空隙と母岩の境界部分に1箇所の手動識別を与えた場合の識別結果画像




(a) 手動識別箇所




(b) 識別結果

図-6 誤識別されたグラウト部分に1箇所の手動識別を与えた場合の識別結果画像




(a) 手動識別箇所




(b) 識別結果

図-7 母岩とグラウトの境界部分に1箇所の手動識別を与えた場合の識別結果画像



(a) 手動識別箇所



(b) 識別結果

図-8 手動識別を与える範囲を縦方向にした場合の識別結果画像

識別結果の色は手動識別の色と同様に、赤色は母岩、緑色はグラウト、紫色は空隙を示す。図から円状の空隙も正しく空隙として識別がされていることから連続した空隙に与えた手動識別が正しい識別結果を導いたことがわかる。しかし、図内の黄色の点線で囲まれた部分の連続した空隙の上端に接している母岩部分がグラウトと誤識別されていた。

続いて、グラウトの手動識別を増やすために与える手動識別を同じ範囲で2倍を増やした。TWSは同じ範囲でも学習させる数を自由に設定することができる。結果をグラウト材に与える手動識別を2倍にする前の図-4と比較すると、識別の結果はほぼ変化せず、誤識別された黄色の点線内の部分にも改善は見られなかった。したがって、同じ場所で与える説明変数を増やしても結果には影響が出ないことが確認できる。

誤識別の改善のため、誤識別されていた母岩部分(連続した空隙の上端付近の母岩)に手動識別を図-5(a)の様に与えた。識別結果の図-5(b)を見ると連続した空隙に接する母岩は正しく識別されたがグラウト中の高CT部(明るい部分)が母岩と誤識別される結果となった。

続いて、先ほどの結果で母岩と判断されたグラウト部にも手動識別を図-6(a)に示す様に与えた。結果(図-6(b))より、連続した空隙の上端に接している母岩部も高密度グラウト部も正しく識別が行われた。このことから、誤識別されている部分に直接、手動識別を与えることで細かな修正は可能であることがわかる。ここまでの結果から、より多くの多様性を兼ねた説明変数を元画像に与えることが正しい識別を導き出すことがわかったため、下部のグラウトと母岩の境界と円状の空隙に手動識別を図-7(a)の様に与えた。識別結果は図-7(b)のとおりグラウトと母岩の境界部分、円状の空隙もより正しく識別がなされた。以上より、1枚の365×183の全66795ピクセル画像に対して与えた手動識別の範囲は、360ピクセルであった。与える範囲や形状によって、より少ない手動識別範囲でも正しい識別が行えると考えられる。

この結果を基に、図-8(a)に示すように手動識別を与えた。図のように母岩とグラウトには縦方向に手動識別を与えた。これは、グラウト材の手動識別に多様性を与える意味で図-3(b)に示す様に、母岩とグラウトの境界部分はCT値が混合しやすく境界部分よりき裂直交方向にCT

値が低くなっていくためである。図-8(b)の結果より、図-7(b)と比較しても高い精度で識別が行われており、図-7(a)より少ない手動識別範囲で結果を出すことができた。

4. まとめ

本研究では、TWSにおいて手動識別が識別結果にどのような影響するのかを実験的に考察した。特徴検出フィルタはデフォルトの Gaussian blur, Sobel filter, Hessian, Difference of gaussian, Membrane projections の計5つとし、母岩、グラウト、空隙が含まれる供試体断面に段階的に手動の識別を与えTWSに反復学習させ、その結果から自動識別の精度を目視によって判断した。

結果より、説明変数を与えた範囲と連続した材料には比較的正しい識別が行われる。また、連続していない部分の範囲でも、空隙の様にグラウト、母岩よりCT値が明らかに低い材料は正しく識別される場合が多い。手動識別を与える範囲として手動識別を単純に増加させるために同じ範囲で手動識別を増加させても結果には影響は出ず、手動識別を与える範囲には多様性が必要であることがわかった。また、TWSでは繰り返し手動識別を行うことができるため、結果と照らし合わせて誤識別された部分に正しく手動で識別を与えることでより精度の高い識別を行うことができる。

今後の課題として、本研究では画像に対する特徴検出フィルタの選択をデフォルトのままで行った。課題として、特徴検出が自動識別に与える結果も考察すべきである。また、精度比較を目視によって判断しているため、あらかじめ材料の面積がわかっている供試体を識別するなどの精度の判断の検討も行わなければならない。

<参考文献>

- 1) グラウティング技術改定指針の概要,
<http://www.nilim.go.jp/lab/fdg/kijyun/2003grouting.pdf>
(2020/02/05 参照)
- 2) Ignacio Arganda-Carreras, Verena Kaynig, Johannes Schindelin, Albert Cardona, HS Seung : *Trainable Weka segmentation: a machine learning tool for microscopy image segmentation*, Neuroscience, 73-80, 2014

EFFECT OF MANUAL SEGMENTATION ON RESULT IN AUTOMATIC SEGMENTATION OF TWS

Chihiro TAGAWA, Shinichiro NAKASHIMA, Yoichi YOSHIZU, Hirotaka ISEKI,
Kiyoshi KISHIDA

X-ray CT is an effective means of nondestructively observing the segmentation of material and cracks inside a rock sample, but it is difficult to segment materials in case that the CT values of constituent materials are similar.

In this research, the material segmentation of the base rock, grout, and voids is automatically segmented by machine learning from the X-ray CT image of the rock core in which cracks are filled with grout. The segmentation result changes depending on how the teacher data is given during the classification process. In this paper, we compared the segmentation results derived from the given teacher data and examined how to give the optimum teacher data. As a result, diversity is important in the range of manual discrimination that the teacher data learns.