

エコーチップ硬度計とX線コアスキャナーに基づいた岩級区分に関する基礎的研究

森 遥¹⁾, 珠玖 隆行²⁾, 木下 博久³⁾, 原口 強⁴⁾

- 1) 復建調査設計(株), yo.mori@fukken.co.jp
- 2) 教授, 東京都市大学, tshuku@tcu.ac.jp
- 3) 部長, 復建調査設計(株), h-kinoshita@fukken.co.jp
- 4) 特任教授, 東北大学, h@story-ujv.com

ボーリング調査では、一般的にコアの岩級区分は岩の硬軟や形状、風化・変質の程度、RQD (Rock Quality Designation) 等を指標とした目視観察により行われるため、技術者間で一部評価が異なることが課題となっている。本研究では、エコーチップ硬度計を用いて得られたコアの硬度（反発値）とX線コアスキャナーを用いて得られたX線画像のデータに対して、ロジスティック回帰を用いた岩級区分法を新たに提案した。学習データに基づいて構築したロジスティック回帰モデルの精度について、検証データを用いて評価した。その結果、経験ある技術者が行った岩級区分を6割程度の精度で再現できることを示した。

キーワード：ボーリングコア、岩級区分、X線、エコーチップ、機械学習（F-01, G-13）

1. はじめに

ボーリング調査では、ボーリングコアの岩級区分を岩の硬軟や形状、風化・変質の程度、RQD等の指標に基づいて行われている。これらの指標には、コアの色調やハンマー打撃による打撃音、触感など、人間の五感による判断が必要な項目が存在しており、定性的なものとなっている。そのため、これらの結果は技術者間で評価結果に差異が生じることが課題となっている。

定量的な岩級区分の試みとして、エコーチップ硬度計を用いた研究^{1,2)}が報告されており、エコーチップ硬度計は、コアの物理的性質や岩級の把握に有効であることが示されている。しかしながら、エコーチップ硬度計では、測定の原理上、局所的な反発値（以後、L値とする）を測定するため、材料の不均質性がそのまま反発値に反映され、ばらつきの大きなデータが取得されるという問題がある。岩級区分のように、ある程度「マクロ」にボーリングコアや岩石を評価したい場合には、ばらつきのある反発値データの適切な前処理や、他の補助情報も利用した判定が必要となる。

本研究では、エコーチップ硬度計の補助情報として、ボーリングコアに対するX線コアスキャナーから得られるX線透過量に着目し、L値とX線透過量から岩級区分を行う方法を新たに提案する。本研究で対象とする「データに基づいた岩級区分の問題」は、機械学習の文脈では識別問題に対応する。L値とX線透過量を説明変数(特徴量)、岩級区分を目的変数とした識別問題を解くためのアルゴリズムに基づく岩級区分方法を提案し、提案手法を実際のボーリングコアデータに適用し、従来の方法（技術者による定性的な岩級区分）と比較することで、提案

手法の有効性を検証した。

2. データの取得方法と計測データ

本研究では、2地点でサンプリングされたφ86mmオールコアボーリングのコア試料（試料A、試料Bとする）を対象に検討を行った。これらのコア試料に対しては、コア形状、割れ目の状態、風化の程度、変質の程度が評価され、それらの評価に基づいた岩級区分が技術者により実施されている。図-1に深度毎の岩級区分の一例を示す。本研究では岩級区分への適用性を検討することから、測定区間は岩盤出現深度以深とし、試料AはGL-9.8～20.0m、試料BはGL-19.8～85.0mで測定を行った。試料

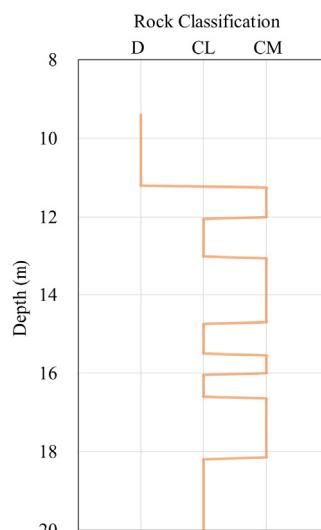


図-1 技術者判断による岩級区分の一例

Aは泥質片岩～緑色岩から構成されており、試料Bはチャート、泥質片岩、ドロマイト、塩基性凝灰岩から構成される。本試料は、付加作用に伴うメランジュの発達する地域から採取したものであり、全体的に破碎質な状態であった。

2.1 エコーチップ硬度計

エコーチップ硬度計は、バネの力を用いて試料表面に小さな球（チップ）を衝突させ、球の落下速度と反発速度の比率から反発強度（L値）を求める試験機である（図-2）。L値は0～1000の範囲の値を示し、値が高ければ試料が硬質である事を示している。エコーチップ硬度計には、打撃エネルギーやチップの移動距離の異なるインパクトデバイスが複数種類存在しているが、本研究では、標準タイプであるDタイプ（打撃エネルギー：11N·mm、チップ径： $\phi 3\text{ mm}$ ）を用いた。

測定は、岩盤出現深度を基準に、5cm間隔に行った。コア箱に収められたコアの表面の中央付近を、所定深度毎に、コア表面に対して垂直方向に打撃した。コアに亀裂や表面の欠けが生じていた場合は、測定位置を深度方向にずらして各深度3回ずつ測定を行った。礫打ちなどによる外れ値の影響を除くため、3回測定した値の中央値を特徴量（説明変数）として利用した。エコーチップ硬度計の計測データの一例を図-3に示す。縦軸が深度を表しており、横軸がL値を表している。図から明らかなように、エコーチップ硬度計の計測原理に起因して、L値はばらつきのあるデータであることが分かる。岩盤の性質をマクロに評価したい場合には、データのばらつきが問題となることが想像できる。

2.2 X線コアスキャナー

本研究では車載式のX線コアスキャナー（写真-1）を用い、X線の透過画像を取得した。写真-2はX線透過画像の例を示している。撮影出力は65kV、2mAで統一した。X線画像データの加工にはフリーウェアのImageJ³⁾を用い、画像からグレースケールを抽出し、X線透過量とした。X線画像は、16bitデータのため、65,536階調のグレースケールでX線の透過量を表現している。imageJを使用し、X線画像のピクセルごとの画素値を読み取り、その値をX線透過量として取り扱った。ただし、X線画像では、X線透過量が少ないほど画像上では白くなり、画素値は大きくなるため、それぞれの大小関係は反比例の関係にある。一般的に、X線が透過し難い（画素値が大きい）場合は、試料の密度が高く、岩石が硬質な場合が多い。グレースケールはボーリングコアの中心と両端に計3本の測線を配置し、測線部の画素値を深度方向に読み取った。局所的な亀裂や空隙による外れ値の影響を除くために3測線の中央値を特徴量（説明変数）として利用した。なお、X線透過量の値は1ピッチあたり7.5mmの解像度であるが、エコーチップ硬度計の解像度との整合性を考慮し、所定深度の上下2.5cmの範囲内における

中央値を採用した。グレースケールの読み取り方法の概念図を図-4に示す。X線コアスキャナーによる計測データの一例を図-5示す。縦軸が深度を表しており、横軸がX線透過量である。L値と同様に、データにばらつきがあることがわかる。なお、図-1、図-3、図-5は対応するデータである。

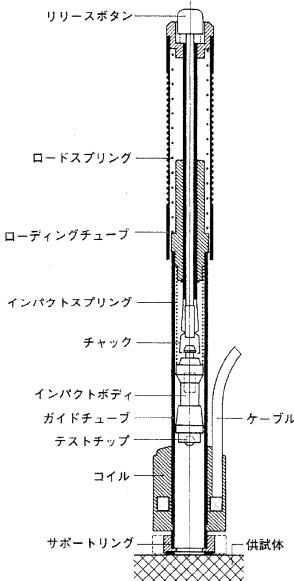


図-2 エコーチップ硬度計の概観¹⁾

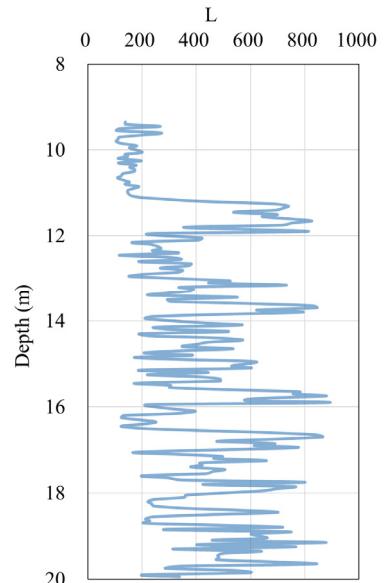


図-3 エコーチップ硬度計による計測データの一例

3. 岩級区分に用いる機械学習

3.1 識別モデル

本研究の目的は、エコーチップ硬度計とX線コアスキャナーのデータに基づいて岩級区分を決定する方法を提案することである。データに基づく岩級区分は、機械学習の文脈では、「ある入力ベクトル t を K 個の離散クラ



写真-1 X線コアスキャナー

ス C_k の一つに割り当てる」と、と解釈できる。このようなタスクに対しては識別モデルを用いることが一般的であり、本研究でも識別モデルを用いて岩級区分を試みる。なお、データの分類としてクラスタリングが一般的に利用されているが、クラスタリングではデータを解析する前にクラス C_k を直接指定しないため、今回の目的では用いることができない。

分類識別問題を解くための代表的な方法として、最小二乗法、フィッシャーの線形判別、ロジスティック回帰、サポートベクトルマシン (SVM)、ニューラルネットワークを挙げることができる（例えば、Bishop⁴⁾）。識別モデルには多くの選択肢があり、最近では複雑な問題に特化した高度なアルゴリズムも提案されているが、本研究では、基本的なロジスティック回帰を用いて岩級区分を試みる。本研究でロジスティック回帰を用いた理由は、1) 外れ値に対して頑健であること、2) 学習の計算コストが小さいこと、3) 結果の解釈が容易であり、実務者にも受け入れやすいこと、である。

3.2 ロジスティック回帰

本節では、本研究で用いるロジスティック回帰の基礎について説明する。ロジスティック回帰は汎用的に用いられている方法であり、一般的な機械学習の教科書にも解説されているため、ここでは基本的な内容を示すにとどめる。なお、本研究で対象とする岩級区分は2区分以上あるため、より一般的な $K > 2$ クラスの場合のロジスティック回帰を考える。

ロジスティック回帰は確率的にクラスを評価する方法であり、データ x が与えられたとき、そのデータがクラス C_k である確率 $p(C_k | x)$ を用いる。

$$p(C_k | x) = \frac{p(x|C_k)p(C_k)}{\sum_j p(x|C_j)p(C_j)} = \frac{\exp(a_k)}{\sum_j \exp(a_j)} \quad (1)$$

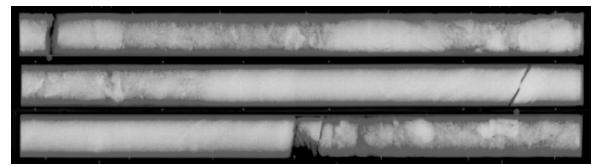


写真-2 コアに対するX線透過画像の例

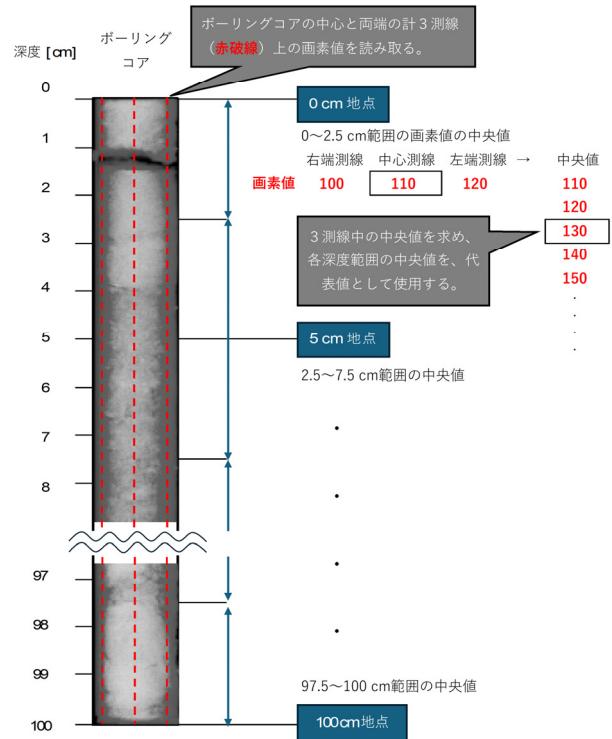


図-4 グレースケール読み取り方法（概念図）

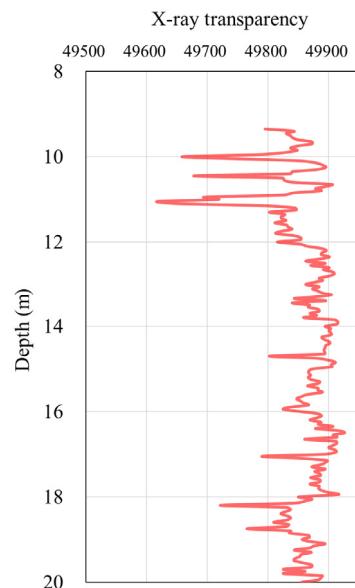


図-5 X線コアスキャナーによる計測データの一例

この式は条件付き確率そのものであり、解釈によってはベイズの定理とも捉えることができる。この確率的に評価するという特性が、不確実性の大きいデータ、ばらつきの大きなデータを扱う際に有用となる。式中の a_k は

表-1 各試料のデータセット情報

試料名		試料A				試料B			
岩級		D	CL	CM	全体	D	CL	CM	全体
データ数		35	81	86	202	877	382	144	1403
最大値	L値	435	879	887	887	889	931	903	931
	X線透過量	49905	49926	49915	49926	49913	49933	49919	49933
最小値	L値	104	115	183	104	96	94	110	94
	X線透過量	49617	49721	49790	49617	49230	45905	49550	45905
平均値	L値	166	378	521	401	242	405	566	321
	X線透過量	49819	49869	49871	49861	49809	49626	49833	49761
標準偏差	L値	65	183	201	217	175	229	192	222
	X線透過量	74	32	31	46	72	863	58	462

活性（識別関数）を表し、本研究では、以下の線形関数で与えることとした。

$$a_k = \mathbf{w}_k^T Q \quad (2)$$

ここで、 \mathbf{w}_k は重みベクトル、 Q は特徴ベクトルを表す。本研究では、特徴ベクトルとしてデータ x の多項式を用い、least absolute shrinkage and selection operator (lasso)⁵⁾によりモデル選択の問題を回避している。なお、lasso に必要なハイパーパラメータ λ は、ロジスティック回帰の推定結果を確認しつつ試行錯誤的に決定する。

ロジスティック回帰における「学習」とは、学習データ x から重みベクトル \mathbf{w}_k を求めることに対応し、本研究では最尤法によって重みベクトルを決定する。最尤法では次式で与えられる尤度関数を最大化して、重みベクトルを決定する。

$$p(T|\mathbf{w}_1, \dots, \mathbf{w}_K) = \prod_{n=1}^N \prod_{k=1}^K p(C_k|Q_n)^{t_{nk}} = \prod_{n=1}^N \prod_{k=1}^K y_{nk}^{t_{nk}} \quad (3)$$

ここで、 $y_{nk} = y_k(Q_n)$ であり、 T は t_{nk} を要素とする目的関数の $N \times K$ 行列である。なお、 N は学習データの数、 K はクラスの数を表す。尤度関数の負の対数をとると、

$$E(\mathbf{w}_1, \dots, \mathbf{w}_K) = -\ln p(T|\mathbf{w}_1, \dots, \mathbf{w}_K) = -\sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln(y_{nk}) \quad (4)$$

が得られる。上記の関数 $E(\mathbf{w}_1, \dots, \mathbf{w}_K)$ を最小化するために、本研究では最急降下法を用いる。係数ベクトルから構成される行列 $W = [\mathbf{w}_1, \dots, \mathbf{w}_K]$ の、最急降下法における更新は、次式で与えられる。

$$\mathbf{W}^{\text{new}} = \mathbf{W}^{\text{old}} - \eta \nabla E(\mathbf{w}) \quad (5)$$

ここで、 η は学習パラメータを表し、 $\nabla E(\mathbf{w})$ は次式で与えられるパラメータベクトル w_j に対するクロスエントロピーの勾配を表す。

$$\nabla_{\mathbf{w}_j} E(\mathbf{w}_1, \dots, \mathbf{w}_K) = \sum_{n=1}^N (y_{nj} - t_{nj}) Q_n \quad (6)$$

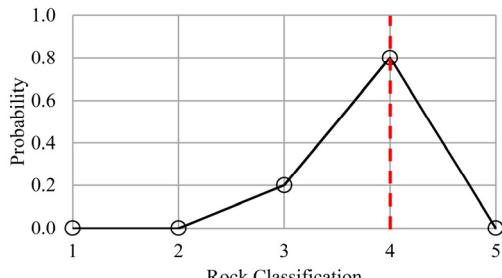
4. ロジスティック回帰による岩級区分

ここでは、2章で示した L 値と X 線透過量を説明変数として、3章で示したロジスティック回帰により、岩級区分を試みた結果を示す。

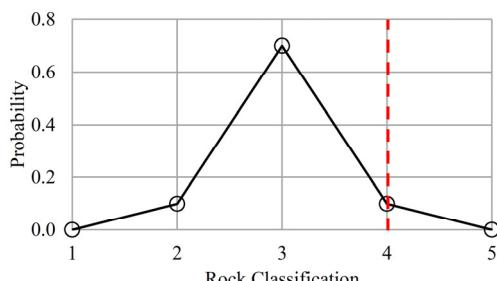
解析に用いるデータの詳細は表-1 に示す。解析に用いるデータに関して、各試料の全体の 20%を訓練用に、残りの 80%を検証用として利用した。ロジスティック回帰の精度は、訓練データと検証データの選び方に依存するため、訓練用・検証用データの選択パターンを 10通り用意し、それぞれの正答率を集計した。また、本研究の最終的な目標は、汎用的な岩級区分を実現する方法の提案であることから、試料 A のデータで訓練したモデルの試料 B への適用結果、および試料 B のデータで訓練したモデルの試料 A への適用結果も示す。

4.1 結果の整理方法

先述したように、ロジスティック回帰は、データ x が与えられた条件でのクラス C_k の確率 $p(C_k | x)$ が評価される。図-6 は、ロジスティック回帰から出力される結果の一例を表している。横軸の 1~5 までの数字は、岩級区分の B, CH, CM, CL, D にそれぞれ対応している。縦軸は確率であるため、意思決定のためには（ロジスティック回帰による推定値を決めるためには）何らかのルールが必要である。ここでは単純に確率が最も高い岩級区分を推定値とした。確率が等しい場合は推定値が決定できないことになるが、本研究で扱ったデータに関してはそのような例は生じなかったことを付記する。なお、図中の縦点線は、実際の岩級区分を表しており、図-6(a)は推定に成功した例であり、図-6(b)は失敗した例である。



(a) 推定に成功した例



(b) 推定に失敗した例

図-6 ロジスティック回帰から得られる推定結果の例

4.2 推定結果

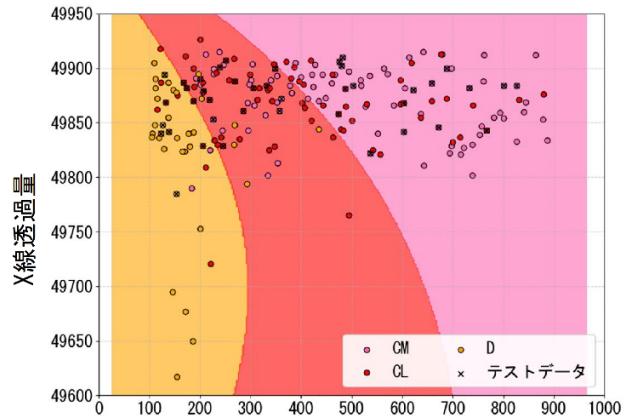
試料A, Bの正解率を表-2に示す。正解率は、全体に占める正解の割合であり、正解数を全データ数で除して求める。先述したように、学習用・検証用データを10セット準備し、その結果をまとめている。データセットにより多少のばらつきはあるものの、おおむね6割の正解率を得ることができた。

表-2 ロジスティック回帰の正解率

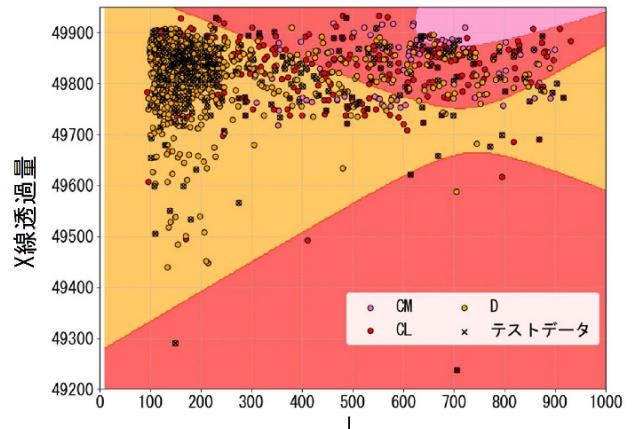
Dataset	正解率	
	試料A	試料B
1	0.51	0.67
2	0.76	0.67
3	0.54	0.66
4	0.63	0.66
5	0.61	0.67
6	0.71	0.65
7	0.56	0.64
8	0.59	0.57
9	0.59	0.64
10	0.63	0.68
Average	0.61	0.65

図-7はロジスティック回帰における決定境界の一例を示している。識別関数として多項式を用いているため、非線形の決定境界が得られていることが分かる。なお、より高次の多項式を用いることで、より複雑なデータにも対応できることを付記する。

各試料を訓練データとして、もう一方の試料の岩級区分を行った結果を表-3, 4に示す。ここで、適合率は推定結果のうち、どれだけ「本当に正しいもの」が含まれているかの割合を意味し、再現率は、推定対象や真に存在



(a) 試料A



(b) 試料B

図-7 決定境界の一例

表-3 試料Aのモデルで試料Bを評価した結果

岩級区分	適合率	再現率	F1スコア	データ数
CM	0.29	0.68	0.41	139
CL	0.38	0.40	0.39	339
D	0.87	0.65	0.74	833
正解率	0.59			

表-4 試料Bのモデルで試料Aを評価した結果

岩級区分	適合率	再現率	F1スコア	データ数
CM	0.72	0.15	0.25	86
CL	0.42	0.51	0.46	81
D	0.39	0.97	0.56	35
正解率	0.44			

るべきデータのうち、どれだけ「正しく推定できたか」の割合を意味する。また、F1スコアとは、適合率と再現率の調和平均で定義される。

試料Aのデータを訓練データとして使用したモデルを試料Bに適用した際の正答率は59%であった。適合率の岩級ごとの内訳は、CM級が29%，CL級が38%，D級

が 87%となり、D 級が最も高い値となった。試料 B は D 級のデータ数が 833 と他の岩級よりも 2 倍以上多いため、正答率も高く見積もられると考えられる。しかし、D 級の F-1 スコアは 0.74 と高い値が得られていることから、モデルとしての精度は十分であると考えられる。

ここで行った検証は、本来のモデルの推定範囲を超えた外挿的なものであるが、外挿的な推定であってもある程度推定ができる事を確認した。本研究の最終ゴールは、岩盤の種類や状態によらず、岩級区分を実現できる方法を構築することであるため、外挿的なデータに対する性能評価は重要である。今回、限られたデータに対して岩級区分を実施したが、より精度の高い、汎用的な方法を構築するためには、地道なデータの収集が必要不可欠である。

本研究課題として、推定精度が 6 割程度になった原因について、詳細な検証ができなかった。具体的には、データ数が限られているため、提案手法の性能が機械学習のアルゴリズムに大きく依存しているのか、そもそもデータのばらつきによる影響を大きく受けているのか、などを詳細に検討することができなかった。今後はデータを収集するとともに、データのばらつきによる推定精度への影響や、複数の機械学習による推定精度の違いについて検討する必要がある。

5.まとめ

本研究では、エコーチップ硬度計を用いて得られたコアの硬度（反発値）と X 線コアスキャナーを用いて得られた X 線画像のデータに対して、ロジスティック回帰を用いた岩級区分法を新たに提案した。学習データに基づいて構築したロジスティック回帰モデルの精度について、検証データを用いて評価した。解析の結果、本研究で提

案した方法では、経験ある技術者が行った岩級区分を 6 ~7 割程度の精度で再現できることが明らかとなった。また、試料 A (B) のデータで学習したモデルを試料 B (A) の岩級区分に適用した結果、5 割程度の推定精度を示した。実務に適用できる推定精度ではないものの、本研究で提案した方法が岩級区分に適用できる可能性は示すことができた。

汎用的な方法を構築するためには、より多くのデータが必要であり、今後もデータを収集していく予定である。その中で、別の岩種に対する適用性や、データ量の違いが推定結果に及ぼす影響について検討したいと考えている。

参考文献

- 1) 川崎了, 吉田昌登, 谷本親伯, 外屋直 : 簡易反発硬度試験による岩質材料の物性評価手法の開発-試験条件の影響と基本特性に関する調査-, 応用地質, 第 41 卷, 第 4 号, pp.230-241, 2000.
- 2) 木下篤彦, 田上弘樹, 山村充, 芝崎達也, 古谷綱崇, 宮本卓也 : 四国結晶片岩地すべりの高品質コアを用いたすべり面の特性評価, 日本地すべり学会, 第 50 卷, 第 4 号, pp.151-159, 2013.
- 3) Abramoff, M.D., Magelhaes, P.J., Ram, S.J.: Image Processing with ImageJ, Biophotonics International, Vol. 11, No. 7, pp. 36-42, 2004.
- 4) Bishop, C.M.: Pattern recognition and machine learning, Springer, 2004.
- 5) Tibshirani, R.: Regression Shrinkage and Selection via the lasso, Journal of the Royal Statistical Society. Series B (methodological). Vol. 58, No. 1, pp. 267-88, 1996.

(2025 年 6 月 23 日 受付)

A Fundamental Study on Rock Classification based on Equotip Hardness Tester and X-ray Core Scanning

Yo MORI¹, Takayuki SHUKU², Hirohisa KINOSHITA¹, and Tsuyoshi HARAGUCHI⁴

1 Fukken Co., Ltd

2 Professor, Tokyo City University

3 Specially Appointed Professor, Tohoku University

Abstract

In boring investigations, rock core classification is generally conducted through visual observation based on indicators such as rock hardness/softness, shape, degree of weathering/alteration, and RQD, which creates inconsistencies in evaluations between engineers. In this research, we propose a new rock classification method using logistic regression applied to core hardness data (rebound values) obtained from an Equotip hardness tester and X-ray image data acquired using an X-ray core scanner. We evaluated the accuracy of the logistic regression model constructed from training data using validation data. The results showed that our proposed logistic regression-based method can reproduce rock classifications performed by experienced engineers with approximately 60% accuracy.

Key words: Boring core, Rock classification, X-ray, Equotip, Machine learning