

削孔検層データを用いた切羽評価での 機械学習方法に関する考察

翟 思敏^{1*}・坂元 秀行¹・大森 禎敏¹・高橋 恒樹²・伊藤 直人²

¹五洋建設株式会社 土木部門 土木本部 土木技術部 (〒112-8576 東京都文京区後楽2-2-8)

²NSW株式会社 プロダクトソリューション事業本部 (〒150-0036 東京都渋谷区南平台町2-15)

*E-mail: shibin.taku@mail.penta-ocean.co.jp

さぐり削孔は、山岳トンネルにおいて古くから切羽前方の地山状況を予測する手段であったが、近年では鑿下がり（のみさがり）と呼ばれる穿孔速度だけでなく削岩機の油圧データを用いて定量的に地山性状を把握する削孔検層が適用されている。また、最近では削孔検層データに加えて切羽で得られる画像データを用いた人工知能などによる切羽評価方法の開発が進められている。

本稿では、削孔検層データを用いて切羽評価を行う際の機械学習方法について検証した。その際、従来の重回帰分析に加えて勾配ブースティングに基づく機械学習手法であるLightGBMを用いて、正答率だけでなく学習時に重みが置かれる説明変数についても考察した。

Key Words : mountain tunnel, face evaluation, drilling logging, machine learning, LightGBM

1. はじめに

山岳トンネルにおけるさぐり削孔は、古くから切羽前方の地山状況を予測するのに活用されてきた。今日では、さぐり削孔時に実施される鑿下がりの測定や排出されるスライムの観察だけでなく回転圧、打撃圧およびフィード圧といった削岩機の油圧データをもとに地山性状の定量的な評価を行う削孔検層が適用される例も多い¹⁾。加えて、最近では発破に用いる装薬孔やロックボルト孔でも削孔データを採取してトンネル周辺地山の性状を把握したり、得られたデータを人工知能で分析して切羽評価する取り組みもなされている^{例えば2),3)}。しかしながら、削孔検層で得られたデータを機械学習するに当たっての学習方法についての検討は限定的と考えられた。

本稿では、削孔検層で得られた回転圧、打撃圧、フィード圧といった削岩機の油圧データを用いて切羽観察における項目を評価するために用いる機械学習の手法について検証するものである。具体的にはトンネル切羽での装薬孔で得られた削孔検層データについて、重回帰分析に加えて勾配ブースティングに基づく機械学習手法であるLightGBM (Light Gradient Boosting Machine) を用いて予測値と技術者の評価値について比較検証するとともに、それぞれの機械学習方法で得られた結果の違いについて考察する⁴⁾。

2. 検証方法

(1) 対象トンネルの概要

本検証に用いる削孔検層データは、山口県で建設されたHトンネルで取得した。Hトンネルは延長619.5mの二車線道路トンネルで、完成内空断面積は88.8m²である。掘削対象地山の岩質は、中生代白亜紀後期の流紋岩質もしくはデイサイト質溶結凝灰岩であった。

(2) 削孔検層データと切羽評価

Hトンネルでは写真-1に示すように発破のための装薬孔ごとに削孔検層を実施した。また、鏡面を26区画の区間に区切って技術者が観察し、道路トンネル観察・計測指針に示されている圧縮強度、風化変質、割目間隔および割目状態の4項目を評価し教師データとした⁵⁾。

その際、評価値は区画ごとに判断するものとし、削孔地点が属している区画の評価値をその削孔地点の評価と




写真-1 削孔位置と切羽評価のための区画

し、検証に用いた切羽数は6断面とした。

(3) 検証方法

評価値は区画ごとに決められるため、削孔地点が属している区画の評価値をその削孔地点の評価として教師データとした。

また、取得した削孔検層データのうち回転圧、打撃圧、フィード圧および穿孔速度に対し、外れ値を除去する処理を行った。外れ値はIQR（四分位範囲）を用いて判断し、IQRは次式で表される。

$$IQR = \text{第3 四分位数} - \text{第1 四分位数} \quad (1)$$

これを用いて、 x をデータとすると次式の範囲のデータを外れ値として除去した。

$$x < \text{第1 四分位数} - 2 \times IQR \quad (2a)$$

$$\text{第3 四分位数} + 2 \times IQR < x \quad (2b)$$

IQR の係数は 1.5 が一般的だが、一部のデータが除去されすぎているものが確認されたため、外れ値の範囲が狭くなるよう係数は 2 とし、四分位数については切羽ごとに決定した。

外れ値を除去したのち、削孔検層で得られた回転圧、打撃圧、フィード圧および穿孔速度の平均値、標準偏差、最大値および最小値を算出した。その結果、説明変数としては削孔位置を表す x 座標と y 座標、回転圧の平均値、標準偏差、最大値および最小値、打撃圧の平均値、標準偏差、最大値および最小値、フィード圧の平均値、標準偏差、最大値および最小値、穿孔速度の平均値、標準偏差、最大値および最小値の計 18 とした。また、目的変数は切羽観察項目のうち圧縮強度、風化変質、割目間隔、割目状態の 4 項目とした。

上述した説明変数と目的変数について機械学習を行い技術者の評価値と機械学習での予測値を比較検討した。その際にはすべてのデータに対し推論を行うために、学習を行うごとに5分割交差検証を行った。

3. 検証に用いた機械学習方法

本検証に用いた機械学習方法は、重回帰分析に加えて LightGBM とした⁹⁾。このうち LightGBM については回帰タスクと分類タスクの 2 手法を用いるものとし、それぞれの概要を以下に示す。

(1) 重回帰分析

重回帰分析とは、複数の説明変数から以下のような回帰式を算出して結果を予測する手法である。

$$y = a_1 \cdot x_1 + a_2 \cdot x_2 + a_3 \cdot x_3 \cdots a_n \cdot x_n + b \quad (3)$$

ここで、 x_n は説明変数、 y は目的変数、 a_n は偏回帰係数、 b は切片である。係数および切片は教師データとの差が最も小さくなるように最小二乗法を用いて決定される。




図-1 決定木の模式図




図-2 説明変数1と2を用いたクラス分類

今回、各説明変数のデータは標準化を行ってから学習に使用した。また出力が連続値であるため、四捨五入した値を予測値とした。

(2) LightGBM

LightGBM(Light Gradient Boosting Machine)とは、決定木の一種のアルゴリズムである。決定木では、説明変数の値によって分岐が作成され、説明変数を予測する。図-1にその模式図を示す。

この手法では、図-1に示すように説明変数ごとにデータを分類しクラスに分けるものである。その結果を図-2に示すように説明変数1と2の平面を用いて分類するとクラス1～3の分類ができるというもので、分類タスクでは分類したクラス自体が出力となる。

回帰タスクでは、分類されたクラスに属する学習データの平均値が出力となる。すなわち本試行においては、分類タスクでは評価値の1, 2, 3, 4, 5のいずれか、回帰タスクでは小数点以下の値も含む1～5の範囲の値として出力される。

実際には、図-1, 2のような決定木を複数回作成し誤差が小さくなるよう学習して改善する。LightGBMでは分類作成の制御等により高速で学習することができるものとなっている。

今回の学習では、モデル改善回数を100回とし、10回モデルのスコアが改善されなければ演算を止めるものと

した。モデルのスコアは平均二乗誤差の平方根（RMSE）で判断した。回帰タスクにおいては出力値が実数であるため、小数点以下3桁目を四捨五入した値を予測値とした。

4. 検証結果

(1) 技術者の評価値

図-3のそれぞれ(a)～(d)に技術者が評価した1鏡面26区間ごとの圧縮強度、風化変質、割目間隔および割目状態の評価値を示す。これらの図からHトンネルでは、圧縮強度で10～25N/mm²とされる評価値4が最も多かった。風化変質については、岩芯まで風化変質している評価値3が多く、次に土砂状風化、未固結土砂とする評価値4が多かった。また、割れ目の間隔については、RQD値40～10%とする評価値4が最も多く、次にRQD値60～30%とする評価値3とRQD値20%以下とする評価値5が同数となっている。割目状態については、割れ目が開口していると評価される評価値4が最も多くなっており、次に割れ目の多くが開口しているとされる評価値3が多くなっている。

このような結果になった理由としては、削孔検層を実施し、技術者が評価した区間が到達側の坑口部に該当としており、土被りも小さかった。このため、トンネルの一般部よりも風化変質が進行していたものと考えられた。




図-3 Hトンネルにおける技術者の評価値

表-1 機械学習による予測値の正答率 (%)

切羽の評価項目	圧縮強度	風化変質	割目間隔	割目状態	平均
ベースライン	80.43	61.47	62.69	74.62	69.81
重回帰分析	77.07	66.98	65.12	74.32	70.87
LightGBM (回帰)	81.66	74.93	71.86	81.95	77.60
LightGBM (分類)	84.40	73.70	75.54	81.03	78.67

(2) 機械学習による予測結果

表-1にHトンネルにおける技術者の評価値に対する機械学習による予測値の正答率を示す。表-1に示したベースラインは、機械学習手法によって全ての予測値が最多クラスと予測した場合の正答率である。この表から圧縮強度と割目状態で重回帰分析を用いた機械学習での予測結果がベースラインを下回ったことがわかる。一方で、LightGBMを用いた機械学習での予測結果はベースラインを上回るとともに重回帰分析を用いた機械学習で予測した結果よりも正答率が上回った。LightGBMで比較すると風化変質で回帰タスクが分類タスクより正答率が下回ったものの、その他の評価項目については回帰タスクよりも分類タスクの方が正答率の上回る結果となった。

ベースラインはすべてを最多クラスと予測したときの正解率である。すなわちデータの偏り具合を評価するものとも言えるため、予測精度がベースラインを上回ったことは、予測に偏りが無いモデルとしてうまく学習できていたことを示していると考えられる。

また、重回帰分析よりLightGBMの正解率が高かったことについては、機械学習手法の性能差が表れた結果であると考ええる。説明変数と定数を積和演算したシンプルな予測である重回帰分析よりも、決定木を利用したLightGBMの方がデータの分類や回帰に対応できたと考えられる。加えて、LightGBMの回帰タスクと分類タスクの差は、実際には1%程度の違いであり、もともと持っているアルゴリズムもほぼ同じため、有意なものではないと考えられた。

図-4、5のそれぞれ(a)～(d)にHトンネルにおける圧縮強度と風化変質について、技術者の評価値、重回帰分析を用いた機械学習での予測値、LightGBMの回帰タスクおよび分類タスクを用いた機械学習で予測した評価値をヒートマップで示す。

図-4の(a)～(d)に示した圧縮強度を見ると技術者の評価値と比較して重回帰分析を用いた機械学習の予測値は、鏡面の右肩、右脚部および切羽中央の下端の複数箇所では技術者の評価値とは異なる結果となっていることが分かる。また、LightGBMを用いた機械学習での予測値は、技術者の評価値と比較して回帰タスクでは、重回帰分析と同様に鏡面の右肩、右脚部および切羽中央部で技術者の評価値と若干ことなるものの、分類タスクでは天端部分の一部を除いては概ね技術者の評価値と一致する結果となった。

図-5の(a)～(d)に示した風化変質では、技術者の評価値と重回帰分析を用いた機械学習の予測値では、鏡面の左側および右側の下端で異なる結果となった。また、LightGBMを用いた機械学習での予測値は回帰タスク、分類タスクともに、鏡面の左脚部、右肩から下端で技術者の評価値と異なる結果となったが、重回帰分析を用い







図-4 H トンネルの切羽 509 の圧縮強度予測ヒートマップ







図-5 H トンネルの切羽 509 の風化変質予測ヒートマップ

た機械学習の評価値よりは技術者の評価値と一致していると考えられた。

残る切羽の評価項目である割目間隔と割目状態については、割目間隔で重回帰分析、LightGBMのいずれを用いた予測値は技術者の評価値と若干異なる結果となった。また割目状態については、重回帰分析よりはLightGBMのほうが技術者の評価値と類似することに加えてLightGBMでも分類タスクのほうがより詳細に至って一致する結果が得られた。

以上のことから圧縮強度、風化変質および割目状態については機械学習を用いた切羽評価項目の予測について重回帰分析よりもLightGBMの分類タスクが技術者の評

価に近いと考えられた。一方で割目間隔については、偏った学習データであったことからデータ数を増やすことで改善されると思われるものの、機械学習によらない評価方法についても検討する必要があると考えられた。

5. 機械学習での予測における重み付け

表-2に切羽評価項目ごとの機械学習で得られた手法ごとの重み付けが大きい説明変数をまとめて示す。この表では各切羽の評価項目、本検証で適用した機械学習方法ごとに重み付けが多い説明変数の上位3つを整理したものである。

この表から圧縮強度を予測するためには、重回帰分析、LightGBMの回帰タスク、分類タスクともにフィード圧の統計量に大きな重み付けがなされていた。風化変質では各機械学習方法ともに打撃圧の統計量に重み付けされていた。とくに重回帰分析では穿孔速度の統計量に重み付けされているのに対してLightGBMの回帰タスクと分類タスクでは、x座標とフィード圧の最大値に重み付けがなされていた。割目間隔については、各機械学習方法ともにフィード圧の統計量に重み付けされていて、重回帰分析では圧縮強度と穿孔速度の統計量、回転圧の統計量が重けられている一方でLightGBMの回帰タスクと分類タスクでは、x座標とフィード圧の最大値に重み付けがなされていた。割目間隔については、各機械学習方法ともにフィード圧の統計量に重み付けされていて、重回帰分析については圧縮強度と同様に回転圧の統計量が重み付けされていた。一方、LightGBMの回帰タスクと分類タスクでは穿孔位置の位置情報であるx座標に重み付けされていた。割目状態を見ると各機械学習ともに打撃圧の平均値に重み付けがされていた。加えて、重回帰分析では穿孔速度の統計量に重み付けされている一方で、LightGBMの回帰タスクと分類タスクでは位置情報であるx座標とフィード圧の平均値が重み付けされていた。

表-2を作成するにあたって分析した機械学習の予測値における重要度の1例を図-6の(a)~(c)に示す。この図はHトンネルにおける圧縮強度で、それぞれの図の横軸は予測うえでの重要度を表し、縦軸は説明変数である。


この図から、圧縮強度の予測において重回帰分析では回転圧の平均値と回転圧の最大値の係数が大きい値であった。一方、LightGBMの回帰タスクおよび分類タスクでは、x座標、フィード圧の標準偏差、フィード圧の最大値のが共通して大きな値を示した。また、風化変質の予測では、重回帰分析で打撃圧の最大値、穿孔速度の標準偏差および穿孔速度の最大値の係数が大きな値であった。加えて、LightGBMの回帰タスクおよび分類タスクについては、フィード圧の最大値、打撃圧の平均値、x座標の係数が共通して大きい値を示す結果が得られた。

図-6に加えて割目間隔の予測では、重回帰分析で回転圧の平均値、回転圧の最小値およびフィード圧の最小値の重み付けが大きかった。一方、LightGBMの回帰タスク、分類タスクではフィード圧の最大値、x座標が共通して大きい値を示し、分類タスクでは打撃圧の平均値も大きい値であった。また、割目状態の予測では重回帰分析、LightGBMの回帰タスク、分類タスクの全てで打撃圧の平均値が高い値を示した。個別にみると、重回帰分析では穿孔速度の最大値が、LightGBMでは回帰タスク、分類タスクともにx座標が大きな値を示していることが確認できた。


以上のことから、圧縮強度と割目間隔では、削岩機の

表-2 各機械学習方法の評価項目ごとの重み付け結果


切羽評価項目	重み付け	機械学習方法		
		重回帰分析	LightGBMの回帰タスク	LightGBMの分類タスク
圧縮強度	1	回転圧の平均値	フィード圧の標準偏差	x座標
	2	回転圧の最大値	x座標	フィード圧の標準偏差
	3	フィード圧の平均値	打撃圧の標準偏差	フィード圧の最大値
風化変質	1	打撃圧の最大値	x座標	打撃圧の平均値
	2	穿孔速度の標準偏差	フィード圧の最大値	x座標
	3	穿孔速度の最大値	打撃圧の平均値	フィード圧の最大値
割目状態	1	回転圧の平均値	フィード圧の最大値	フィード圧の最大値
	2	回転圧の最小値	x座標	x座標
	3	フィード圧の最小値	回転圧の最大値	打撃圧の平均値
割目間隔	1	打撃圧の平均値	x座標	x座標
	2	穿孔速度の最大値	打撃圧の平均値	打撃圧の平均値
	3	穿孔速度の標準偏差	フィード圧の平均値	フィード圧の平均値



(a) 重回帰分析



(b) LightGBMの回帰タスク



(c) LightGBMの分類タスク

図-6 Hトンネルの圧縮強度予測における重要度

穿孔力との相関が強いと考えられた。すなわち、地山の硬さを表す強度は穿孔力が小さいと軟質と評価され、穿孔力が大きいと硬質と評価されると考えられた。また、割目間隔については、フィード圧の最大値や最小値に重み付けがなされていることから、割れ目ごとに生じるフィード圧の変化量を評価していると考えられた。一方で風化変質と割目状態については、打撃圧の統計量に重み付けされていた。このことから、硬軟を評価するような風化状況や割目の状態については、削孔検層時に地山を打ち砕く力が反映され、風化による硬軟の変化や割れ目の開口度、粘土化の程度などについては打撃力が反映されているものと推察された。

6. 結論

本検証では、実施した技術者による切羽評価と削孔検層データによる重回帰分析、LightGBMの回帰タスクと分類タスクを用いた機械学習による予測結果について検証した。その結果、以下のことが分かった。

- 1) 重回帰分析を用いた機械学習の予測値よりも、LightGBMを用いた機械学習での予測値のほうが技術者の評価値を正とした場合の正答率が大きくなった。
- 2) 技術者の評価値を正とした場合の正答率は、LightGBMを用いた機械学習でも回帰タスクよりも分類タスクのほうが大きくなった。
- 3) 機械学習を用いて評価値を予測する場合、圧縮強度と割目間隔については重回帰分析とLightGBMの回帰タスク、分類タスクともにフィード圧の統計量に重み付けがなされていた。
- 4) 機械学習を用いて評価値を予測する場合、風化変質と割目状態については重回帰分析とLightGBMの回帰タスク、分類タスクともに打撃圧の統計量に重み付けがなされていた。
- 5) LightGBMを用いた機械学習では、削孔検層で得られ

たデータだけでなく、位置情報であるx座標についても重み付けられることが分かった。

7. おわりに

本検証では、1トンネルだけのデータを学習させたが、様々なトンネルで得られた削孔検層データを混在させて学習すれば機械学習モデルの汎化性能が向上すると考えている。また、機械学習で予測する地山性状については、RGBなどの画像データを利用した場合と比較して、圧縮強度と割目間隔については削孔時に得られるフィード圧などの削孔検層データを用いることから地山特性を直接反映させた機械学習ができると考えられた。今後は多種多様な地山条件で検証を進める予定ある。

参考文献

- 1) 木村 哲, 大西有三, 西山 哲, 石山宏二: 穿孔データを指標としたトンネル切羽前方の地山評価システムの研究, 情報地質, 第16巻, 第3号, pp.191-198, 2005.
- 2) 例えば, 松下智昭, 宮嶋保幸, 犬塚隆明, 手塚康成: トンネル切羽の定量評価による掘削の合理化, 土木学会, 第44回岩盤力学に関するシンポジウム講演集, pp.217-221, 2016.
- 3) 例えば, 宮中美玖, 河邊信之, 森本真吾, 信士正人: 短尺削孔データを用いた前方切羽面の予測, 土木学会中国支部第69回研究発表会 概要集, pp.391-392, 2017.
- 4) Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, Tie-Yan Liu: A Highly Efficient Gradient Boosting Decision Tree, 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA.
- 5) 日本道路協会: 道路トンネル観察・計測指針, pp.112-114, 2007.
- 6) 野村総合研究所: 用語解説, “LightGBM”, https://www.nri.com/jp/knowledge/glossary/1st/alphabet/light_gbm, 2023-09-03.

CONSIDERATION ON MACHINE LEARNING METHOD FOR FACE EVALUTION USING DRILLING LOGGING DATA

Simin ZHAI, Hideyuki SAKAMOTO, Sadatoshi OHMORI,
Kouki TAKAHASHI and Takanori NOMURA

Exploration drilling has long been used to predict ground conditions in front of the face of tunnels in mountain tunnels, but in recent years, not only the drilling speed, but also the oil pressure data of the rock drill, has been used to quantitatively predict the ground conditions. Recently, the development of a face evaluation method using artificial intelligence that uses image data and drilling logging data obtained at the face is progressing. This paper presents a machine learning method for face evaluation using drill-ing logging data. Hence LightGBM, a machine learning method based on gradient boosting, was used in addition to conventional multiple regression analysis, while considering not only the percentage of correct responses but also the explanatory variables on which weights are placed during machine learning.