

防災カルテを活用した教師あり学習による 国道沿い急崖斜面の総合評価手法の提案

伊藤友希^{1*}・三谷泰浩²・谷口寿俊²・本田博之²・川野浩平²・
Ibrahim DJAMALUDDIN²

¹九州大学大学院 工学府 土木工学専攻 (〒819-0935 福岡県福岡市西区元岡744)

²九州大学大学院 工学研究院 附属アジア防災研究センター (〒819-0935 福岡県福岡市西区元岡744)

*E-mail: ito.yuki.430@s.kyushu-u.ac.jp

国道で実施されている道路防災点検では、現地スケッチや専門技術者の所見などを記録した道路防災カルテが作成されている。専門技術者はその点検結果をもとに、斜面の総合評価を三段階で評価している。しかし、斜面の総合評価は定量的でなく、専門技術者によってばらつきがあることが指摘されている。そこで本研究では、点検時の専門技術者の意思決定支援となる斜面の総合評価モデルの開発を目的として、まず防災カルテに記載された情報を抽出してデータベースを作成する。そして、データベースの情報を数値化し、教師あり学習により総合評価を予測可能なモデルを提案した。その結果、Random Forestを用いた評価モデルによる総合評価は実際の総合評価と90%以上の精度で一致し、本モデルの有用性を示した。

Key Words : road disaster prevention, disaster prevention record, steep cliff, rockfall, supervised learning

1. 背景

昭和43年8月に発生した土砂災害により104名が亡くなった飛騨川バス転落事故¹を契機として、国道では安全管理のため道路防災総点検が実施され、道路防災点検が毎年行われている。道路防災点検の結果は道路防災カルテとしてまとめられ、点検箇所の位置情報や現地スケッチ、専門技術者の所見、変状の記録、被災履歴、現地写真など、多くの情報が記録されている²。防災カルテにおける斜面の総合評価は、危険性の高い順に「要対策」「カルテ対応」「対策不要」の三段階に分類される。しかし、これらの点検結果は紙もしくはそれをデジタル化した形式で記録・管理されているが、データの検索や抽出などができるものではなく、点検結果を再利用することが難しい。さらに、総合評価の判定に明確な基準はなく、最終的な評価は専門技術者により決定されるため、斜面の安定度の評価にばらつきが生じている。このことから、総合評価を判定する際に、専門技術者の意思決定を支援する斜面の定量的評価手法の開発が必要とされている。

これらの課題に対して、小山³による自己組織化マップを用いて崩壊要因によって斜面をクラスタリングする手法や、高木ら⁴によるロジスティック回帰分析を用いた落石リスクマネジメントなどが提案されている。これ

らの研究では、点検項目や総合評価が記載されている安定度調査表の情報を用いて、機械学習により斜面の危険度を予測する評価モデルを作成しているが、落石・崩壊の可能性が高いとして抽出された斜面が本当に危険であるかについては検証されていない。そこで、村岡ら⁵は安定度調査表だけでなく、平成20年度を除いた平成18～24年度までの防災カルテにおける現地スケッチや専門技術者の所見などから防災点検データベースを作成し、教師なし学習の1つであるK-means法を用いたクラスタリングによる斜面の総合評価モデルについて検討している。しかし、そのクラスタリング精度は約50%であり、実用的な評価モデルの構築には至っていない。

そこで本研究では、道路防災点検時の専門技術者の意思決定支援となる斜面の総合評価モデルの開発を目的として、防災カルテを活用した国道沿い急崖斜面の定量的評価手法について検討する。具体的には、まず大分県の国道210号における平成18年度から令和元年度までの落石・崩壊に関する防災カルテを整理し、過去の点検履歴を参照可能な防災点検データベースを作成する。そしてデータベースの情報を数値化し、その情報から教師あり学習により斜面の特徴と総合評価の関係を学習することで、専門技術者の意思決定支援となる総合評価モデルの作成や道路防災点検時の総合評価に大きく影響を与える点検項目の検証を行う。

2. 防災カルテのデータ化

(1) 研究対象区間

大分県の国道210号には、柱状節理の発達したAso-4などの溶結凝灰岩からなる急崖地が多数存在し、赤岩型⁸⁾と呼ばれる特殊な落石形態を示す。赤岩型の落石では、溶結凝灰岩の最下部に当たる非溶結部が河川の侵食作用などによって削られ、上部の溶結部が支えを失うことで、オーバーハング状となり不安定化し、岩塊が自由落下する。そのため、国道210号における災害は落石事故の占める割合が半数以上となっている⁹⁾。そこで本研究では、大分県の国道210号を対象として、落石の発生源となる急崖斜面の定量的評価手法について検討する。

(2) 防災点検データベースの作成

本研究では、過去の防災カルテから現地スケッチや専門技術者の所見などの定性的評価を含めて、道路防災点検で運用可能な防災点検データベースを作成する⁹⁾。まず、防災カルテに記載されている現地スケッチや専門技術者の所見、変状の記録、被災履歴、現地写真から、斜面の状態を表す用語をすべて抽出し、表-1に示すカテゴリおよび項目にしたがって点検箇所ごとに整理する。その際、専門技術者の所見や変状の記録など、分類したカテゴリの範疇外の記述については、その他や備考のカテゴリ欄に自由記述する。図-1は平成18年度のA001における現地スケッチと専門技術者の所見からの用語抽出の一例を示している。ここで、カルテ番号のAは落石・崩壊の災害形態を示し、001は点検箇所を示す数字である。図中の赤丸部分は用語として抽出し、下線部分は備考欄に記述する。防災点検データベースの作成にあたっては、点検が実施されなかった平成20年度を除いた平成18年度～令和元年度までの13年分の防災カルテを使用する。

3. 機械学習を用いた総合評価モデルの検討

(1) 防災カルテ情報のベクトル化

作成した防災点検データベースの情報は防災カルテ内

表-1 防災点検データベースのカテゴリと項目⁹⁾

カテゴリ	項目
斜面特徴	位置, 地形, 高さ, 傾斜角, 状態
遷急線	位置
基岩 (露岩)	位置, 高さ, 地質, 風化, 亀裂, 亀裂サイズ, 状態, 安定度
転石	安定度, サイズ
浮石	有無, サイズ
落石	有無, サイズ
湧水・流水	位置, 状態
植生	位置, 種類, 倒木, 根曲がり, サイズ
崩壊跡	位置, 現象, 形態, 大きさ, 古さ, 状態, サイズ
道路との距離	距離, 状態
その他	自由記述
対策工	位置, 種類, 高さ, 本数, 損傷種類, 損傷状態, 損傷サイズ, 安定度
被災履歴	有無, 詳細
備考	変状の記録等
点検結果	のり面評点, 自然斜面評点, 総合点, 総合評価
点検者	点検企業

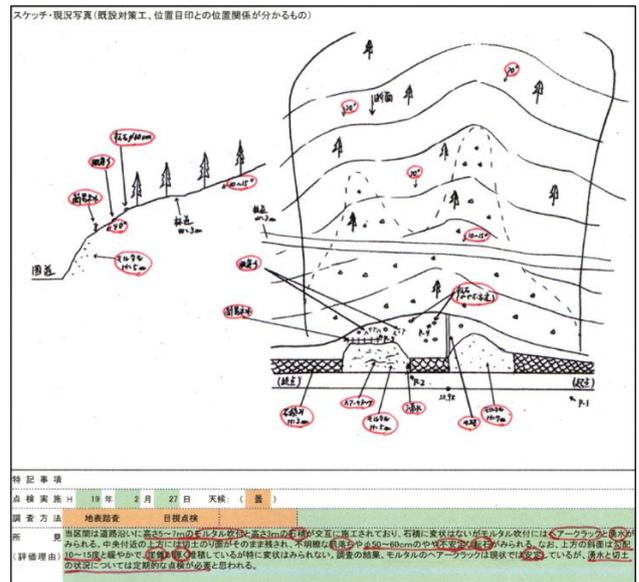


図-1 現地スケッチと専門技術者の所見からの用語抽出の一例

位置	斜面特徴		位置	斜面特徴		(例)	斜面特徴		
	地形	安定度		地形	安定度		位置	地形	安定度
下部	平坦地あり	安定	0	0	0	用語	下部	窪地	不安定
中部	尾根状地形	不安定	1	1	1		中部	滑落崖	
上部	集水地形	⇒	2	2	2		中部	崖錐斜面	
	窪地		3	3	3		上部	平坦地あり	
	地すべり地形		4	4	4	数値化	1	4	0
	流れ盤		5	5	5		2	10	2
	侵食地形		6	6	6		2	11	0
	(以下省略)		7	7	7		3	1	0
			(以下省略)			大きさ	4.24	15.43	2.00

図-2 斜面特徴カテゴリにおける各項目の数値化の一例⁹⁾

表-2 ベクトル化を行った項目

カテゴリ	項目
斜面特徴	位置, 地形, 安定度
遷急線	位置
基岩 (露岩)	位置, 地質, 風化, 亀裂, 状態, 安定度
転石	安定度
浮石	有無
落石	有無
湧水・流水	位置, 状態
植生	位置, 種類, 倒木, 根曲がり
崩壊跡	位置, 現象, 形態, 大きさ, 古さ, 状態
対策工	位置, 種類, 損傷種類, 損傷状態, 安定度
被災履歴	有無
点検者	点検企業

の用語を抽出・整理しただけであり、回帰や分類などの機械学習によって評価モデルを作成するためには、定性的評価を数値化する必要がある。そこで、図-2に示す通り、防災点検データベースの情報を項目ごとに数値化する。まず、用語に対して空欄を0とし、上から順に自然数を割り振って数値化する。そして、それらの数値を項目ごとにベクトルに変換する。なお、今回は点検技術者および専門技術者による定性的評価をもとに斜面を定量的に評価することに着目したため、データベース化された情報のうち表-2に示すカテゴリおよび項目に該当する用語のみをベクトル化しており、自由記述とした専門技術者の所見や変状の記録、転石や崩壊跡のサイズなどについてはベクトル化を行っていない。これらのベクトルの大きさが各項目の属性値となり、それらの各項目が機械学習の説明変数となる。

(2) 教師なし学習を用いた総合評価モデル

道路防災点検時の専門技術者の意思決定支援となる斜面の総合評価モデルの開発を目的として、村岡ら⁹⁾が採用した教師なし学習の1つである K-means 法により、平成 20 年度を除いた平成 18 年度～令和元年度までの 13 年分の防災カルテを用いて斜面をクラスタリングする手法について検討する。K-means 法は、クラスタの中心と各データとの距離が最小になるようなクラスタ中心を逐次的に求めることで、指定したクラスタ数で母集団をグループ分けする手法である⁷⁾。K-means 法では教師となるデータが存在しないため、どのクラスタがどの総合評価となるかを調べ、クラスタリング精度を検証する必要がある。そこで、ベクトル化したデータの母集団をクラスタ作成用データと結果検証用データに 3:1 の比で分割し、クラスタ作成用データで分類した結果をもとに結果

表-3 K-means 法による斜面のクラスタリング結果 (平成 18 年度～令和元年度の全データ)

	正解率 (%)	適合率 (%)	再現率 (%)	F 値 (%)
1 回目	52.8	35.4	37.9	36.6
2 回目	51.2	35.7	36.7	36.2
3 回目	36.6	33.2	26.7	29.6

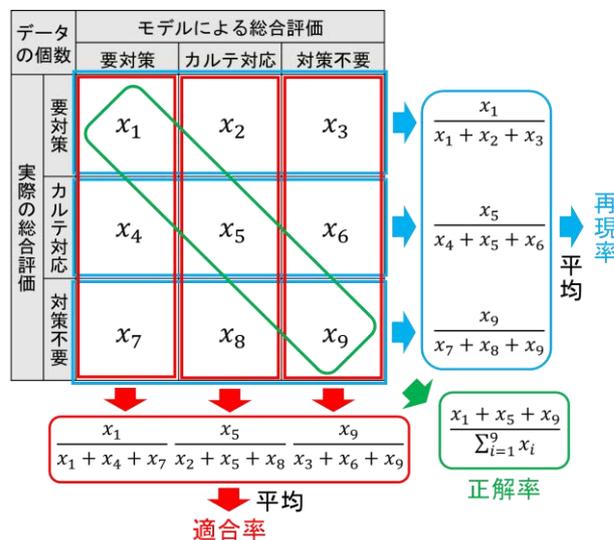


図-3 正解率・適合率・再現率の概念図

検証用データの精度を検証する。この操作を 3 回繰り返して、K-means 法により斜面をクラスタリングした結果を表-3 に示す。ここで、正解率とはモデルによる総合評価と実際の総合評価が一致した割合、適合率とはモデルによってある評価と分類されたデータのうち、その分類が実際の総合評価と一致していたデータの割合、再現率とはある実際の総合評価に対して、モデルの分類した評価が合っていた割合、F 値とは適合率と再現率の調和平均であり、図-3 に正解率と適合率、再現率の概念を示す。この結果、1 回目と 2 回目の正解率はかろうじて 50 % を超えるものの、それ以外の評価指標は 50 % 以下となり、総合評価結果を十分に再現することはできなかった。これは斜面ごとに点検技術者が異なるため、防災カルテに記載される情報も点検技術者によって様々であり、その結果データベースの情報が多様化した。K-means 法は教師となるデータが存在しないため、専門技術者が総合評価を判定する際に重視していると考えられる項目、つまり各説明変数に付けられた「重み」を総合評価予測に反映することはできず、単純に説明変数とその属性値のみに基づいてクラスタリングを行った結果、複雑なデータベースの情報から斜面を 3 つに分けることができなかったと考えられる。

(3) 使用する教師あり学習について

前述の通り、ベクトル化されたデータのみからデー

データをグループ分けする教師なし学習では、総合評価の予測が十分ではないことから、既存の防災点検結果を予測のための学習データとして用いる教師あり学習により斜面を分類する手法について検討する。本研究で使用する教師あり機械学習アルゴリズムは、防災点検データベース内の多くの項目を説明変数にすることができ、さらに総合評価の予測における各項目の重要度を算出できるという理由から、教師あり学習の1つである Random Forest を使用する。Random Forest は、複数の決定木を並列に用いるバギングと呼ばれる手法を使用しており、それらの決定木の多数決によって結果を算出するアンサンブル学習の一種である^{8),9)}。アンサンブル学習は、弱学習器と呼ばれる性能の低い複数の学習モデルから構成される機械学習であり、Random Forest は複数の決定木と呼ばれる弱学習器によって構成されている^{10),11)}。Random Forest による分類では、複数の決定木が出力する予測結果に対して多数決を適用することで、モデル全体の予測結果を出力する。その際、同一の学習データでは決定木をいくつ学習させても同じ予測結果しか返さないため、決定木を構築するにあたってはバギングと呼ばれる手法を採用し、学習データに対してランダムな変数選択とブートストラップサンプリング（重複を許したリサンプリング）を行っている。これにより、複数の決定木の学習結果に対してバリエーション（予測値のばらつき）を小さくすることができ、複雑なデータセットの特徴を反映しつつ、多数決によるモデル全体としての分類精度を向上させている。本研究では、以上の特徴を有する Random Forest を用いて、教師あり学習が総合評価の予測に適しているかを検討する。

(4) 教師あり学習を用いた総合評価モデル

教師あり学習が斜面の総合評価の予測に適しているかを検証することを目的として、まず、平成18年度～令和元年度の全データから教師データをランダムに選択し、教師あり学習による総合評価の予測精度を算出し、教師なし学習の結果と比較する。

図-4のa)に示すように、平成18年度～令和元年度の全データに対して、教師データとテストデータとの比率をランダムに7:3に分割する。ここでいう全データとは、各年度のカルテ番号ごとの防災点検データベース情報のことであり、年度もしくはカルテ番号が異なれば別の斜面とみなしている。例えば、H19年度のA001およびH18年度のA006のカルテデータは、H18年度のA001のカルテデータとは異なるデータであるとみなしている。全データの7割にあたる教師データをRandom Forestにより学習した上でテストデータを分類し、専門技術者による実際の総合評価と一致するかを検証する。この操作を3回繰り返して、Random Forestによる評価モデルを用いた

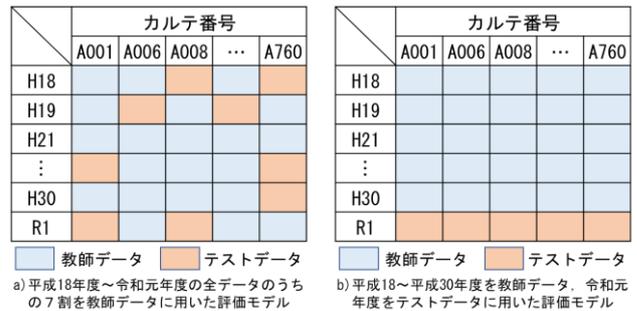


図-4 教師データとテストデータへの分割方法の概念図

表-4 Random Forestによる総合評価の予測結果（平成18年度～令和元年度の全データ）

	正解率 (%)	適合率 (%)	再現率 (%)	F値 (%)
1回目	92.5	83.6	70.4	75.6
2回目	93.2	83.0	65.4	71.5
3回目	92.2	81.4	64.9	71.0

表-5 各教師あり学習による総合評価の予測結果（平成18～30年度を教師データ、令和元年度をテストデータ）

	正解率 (%)	適合率 (%)	再現率 (%)	F値 (%)
予測結果	97.9	99.2	94.4	96.6

ときの正解率、適合率、再現率、F値を算出した結果を表-4に示す。表-4より、Random Forestでは正解率が90%を超え、適合率、再現率、F値は平均するとそれぞれ82.7%、66.9%、72.7%という結果となった。このことから、4つの評価指標すべてにおいて、教師あり学習による予測精度が、前述した教師なし学習であるK-means法より向上したことから、斜面の総合評価の予測においては過去の点検結果を学習した上で予測を行う教師あり学習が有用であることがわかる。これは、K-means法が説明変数とその属性値のみに基づいてクラスタリングする手法であるため、各専門技術者が総合評価を判定する際に付けている項目ごとの「重み」を総合評価予測に反映できないのに対し、Random Forestは教師となるデータが存在するため、複雑なデータセットに対しても、各説明変数に含まれている「重み」を学習した上で総合評価を予測することができる。その結果、教師あり学習であるRandom Forestを用いたときに総合評価の予測精度が向上したと考えられる。

次に、実際の道路防災点検を想定し、過去（平成18～30年度）のすべての点検結果を教師データとして学習した上で、令和元年度の総合評価を予測したときのRandom Forestの予測精度を調べる。

図-4のb)に示すように、平成18～30年度のデータを教師データとして学習した上で、令和元年度の総合評価を予測する。Random Forestを用いたときの評価モデルの予測精度を表-5に示す。Random Forestでは正解率が97.9%、適合率が99.2%、再現率が94.4%、F値が96.6%

- 9) 秋山仁志, フォンヤオカイ, 櫻井幸一: 異なるAIアルゴリズムと4つの特徴選択法によるDDoS攻撃検出のパフォーマンス比較, 情報処理学会研究報告, pp.1-5, 2020.
- 10) 渡部斉: ランダムフォレスト, 情報処理学会研究報告, 研究報告コンピュータビジョンとイメージメディア, Vol.2012-CVIM-182, No.31, pp.1-8, 2012.
- 11) 渡部斉: ランダムフォレストの基礎と最近の動向, 映像情報メディア学会誌, Vol.70, No.9, pp.788-791, 2016.

A COMPREHENSIVE SLOPE STABILITY EVALUATION: A NEW METHOD FOR STEEP CLIFF SLOPES BY SUPERVISED LEARNING THROUGH DATABASING DISASTER PREVENTION RECORDS

Yuki ITO, Yasuhiro MITANI, Hisatoshi TANIGUCHI,
Hiroyuki HONDA, Kohei KAWANO and Ibrahim DJAMALUDDIN

This paper addresses that the practice of experienced engineers, who conduct road disaster prevention inspections and make the official disaster prevention records, requires a non-biased slope stability evaluation model. We have established a comprehensive steep cliff slopes evaluation method to help engineers make quantitative and sharable decisions for inspections by databasing the existing disaster prevention records and employing supervised learning that predicts an encompassing stability evaluation. The model using Random Forest has provided a greater than 90% prediction accuracy ratio compared with an original evaluation result.