

3D 点群データと AI 技術による斜面崩壊リスクの把握手法の検討

Study of the prediction method of slope failure risk using 3D and AI technology

土田 孝¹⁾, 中井真司²⁾, 高山陶子³⁾, 中藪恭介⁴⁾, 吉富健一⁵⁾, 原田隆弘⁶⁾, 塚本峻一⁷⁾, 筒井駿吾⁸⁾

- 1) Takashi TSUCHIDA, 特任教授, 広島大学防災・減災研究センター, ttuchida@hiroshima-u.ac.jp
2) Shinji NAKAI, 部長, 復建調査設計(株)河川砂防部, nakai@fukken.co.jp
3) Touko TAKAYAMA, 副部長, アジア航測(株)社会インフラ技術部, tk.takayama@ajiko.co.jp
4) Kyosuke NAKAYABU, 係長, 復建調査設計(株)砂防技術課, k-nakayabu@fukken.co.jp
5) Kenichi YOSHIDOMI, 准教授, 広島大学大学院人間社会科学部研究科, shisho@hiroshima-u.ac.jp
6) Takahiro HARADA, 復建調査設計(株)地盤環境部 地盤技術課, takahiro.harada@fukken.co.jp
7) Ryoichi TSUKAMOTO, アジア航測(株)西日本インフラ技術部, ric.tsukamoto@ajiko.co.jp
8) Shungo TSUTSUI, アジア航測(株)先端技術研究所 AI 研究室, sng.tsutsui@ajiko.co.jp

道路防災点検のための効率的な 3D 点群データの取得・活用方法, 3D 点群データを利用した斜面の経年変化の把握手法について検討を行った。MMS, UAV, SLAM, 地上 SfM により道路斜面の 3D 点群データを計測し, 各技術の適用範囲を示した。複数時期の点群データから点群間の移動量を算出し, 変状の位置と量を把握する手法を検討した。安定度調査表の要因, 対策, 被災履歴に関するデータと総合評価の関係を AI に学習させ, 斜面の変化・変状の情報を含む危険度評価モデルを構築した。試作した GIS プラットフォームにより, これらの情報を空間的, 時間的に一元管理し, 豪雨時のリアルタイム危険度評価に活用できることを示した。

キーワード: 斜面崩壊, 3D 点群データ, AI 技術, 雨量指標 R' , リスク把握
(IGC: C-01, E-06, E-13)

1. はじめに

気候変動に伴う降雨量や豪雨発生頻度の増加により, 豪雨災害のリスクはますます増大しており, 毎年のように深刻な災害が発生している。中国地方においても平成 30 年 7 月豪雨による災害は記憶に新しく, 特に広島県では, 多数の土石流や斜面崩壊が同時多発的に発生し, 甚大な被害を及ぼした。

住宅への土砂災害リスクについては, 「土砂災害警戒区域等における土砂災害防止対策の推進に関する法律 (土砂災害防止法)」により危険な区域が抽出・開示されており, 道路斜面については斜面管理者による定期的な道路防災点検によりリスクが把握されている。道路防災点検は, 1968 年の飛騨川バス転落事故¹⁾ (104 名死亡) を切っ掛けに始められ, その後何度か見直しを経て, 1990 年度から安定度調査表が導入され, 点検箇所の状況, 対策工の施工状況, 災害履歴等をもとに点数を付けて, 定量的に斜面の安定度を評価する手法が確立された。1996 年度からは, 「道路防災総点検」として実施されるようになり, この時から, 点検箇所が「①対策が必要と判断される (要対策), ②防災カルテを作成し対応する (カルテ対応), ③特に新たな対応を必要としない (対応不要)」の 3 つに区分されるようになり, 以降, 定期的, 継続的に実

施されている。

2022 年 3 月に一般社団法人全国地質調査業協会連合会により改訂された新しい「道路防災点検の手引き (豪雨・豪雪等)」²⁾ では, 「DX 時代に向けたチャレンジ」とサブタイトルが付けられ, デジタルテクノロジーを活用した効率的できめ細かな点検による道路管理の変革に関する, 様々な技術が紹介されている。新しい手引きでは, 航空レーザ測量による三次元点群データ (以下 3D 点群データ) を活用した地形判読が推奨されているが, 現段階では道路管理者が路線沿いの詳細な 3D 点群データを所有していることは多くはない。また, 斜面災害は極めて複雑・多様であり, デジタル技術のみで一律に判断することは現状では困難であることにも言及されている。現行の道路防災点検では, 斜面の経験を有する技術者の目視により安定度調査がなされ, 総合評価 (対応区分の決定) が行われる。また, カルテ対応の箇所の定期点検では, 亀裂があるところに打設された鉋間隔の計測など限定的な定量指標と, 全体写真による状況の比較などにより, 経年変化やリスク要因の変化が把握されており, 技術者判断による部分も大きい。このように, 現状では一気に DX に移行することは困難であるといえる。

本研究では, デジタルテクノロジーを活用して道路防災点検を高度化かつ効率化することを目的として, 1) よ

り効率的な3D点群データの取得・活用方法、2)3D点群データを利用した斜面の経年変化の把握手法、さらに3)AIと計測データを用いた斜面の危険度評価手法について検討を行い、これらの技術の実用化に向けた方策を提案する。

2. 3D点群データ取得と斜面3D化への適用性

2.1 対象路線の地形的特徴と計測手法

3D点群データは、地形や物体の情報を立体的に捉えることが可能であり、道路防災点検におけるDXの検討にあたり、より詳細な斜面状況や経年変化の把握に効果的である。

本研究では、道路防災点検が実施されている路線を対象に、3D点群データを取得し、その活用方法を検討することとした。地形ごとに計測機器の適用性を確認するため、対象路線は以下の地形的特徴を有する2路線とした。

- ・谷地形や急峻な長大斜面が多く存在する。
- ・見通しの悪いカーブが多い。
- ・自然斜面（崖錐・岩盤）が多く存在する。
- ・擁壁、ロックネット等の対策施設が整備されている。

図-1は広島県の道路条件を対象にこれまでの現場調査の経験から作成した計測手法の適用の目安である。対象路線の延長が約10kmであったので、図-1を参考に比較的安価で簡易に計測が可能な、MMS、UAVレーザー計測（以下UAV-LP）、SLAM、地上写真によるSfM（以下地上SfM）の4種類の計測を実施した。各手法の特徴は以下のとおりである。

- ・MMS (Mobile Mapping System)：車両に搭載したレーザースキャナ等のセンサを組み合わせた技術である。自然斜面から走行経路周辺の広域な情報を取得できる。
- ・UAV-LP：UAV (Unmanned Aerial Vehicle) にレーザ計測器を搭載し、空中から対象物を計測する技術である。上空や斜め写真などの鳥瞰的な計測に優れている。
- ・SLAM：SLAM (Simultaneous Localization and Mapping) は、自己位置推定と環境地図作成を同時に行う技術で、コンパクトな機材で手軽に計測できる。起伏が激しい場所や支障物が多い場所でも計測が可能である。
- ・地上SfM：複数枚の写真から対象物の形状を復元するSfM (Structure from Motion) 技術により、地上からデジタルカメラで撮影した写真をもとに3Dモデルを作成するものである。地形特徴量を把握するため、撮影写真をラップさせる必要がある。

2.2 計測データの分析と検証

2.2.1 各計測手法と道路斜面の適用性

対象路線で4種類の計測・処理を行った結果を表-1にまとめた。

- ・MMS：計測範囲が広くデータ取得時間は短いものの、道路上を走行しながら計測するため、道路から死角と

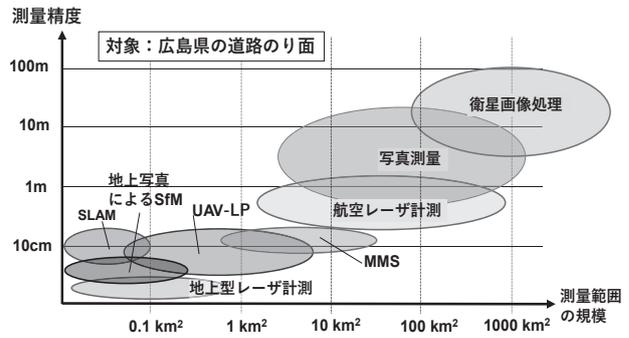


図-1 計測手法の適用目安

表-1 今回確認した各計測手法の適性

計測手法	面積あたり群密度*	面積あたり計測時間**	箇所ごとのデータ取得精度**				
			斜面頂部	斜面中腹	対策施設	対策施設背面	植生下部
MMS	小	小	△	○	△	×	△
UAV-LP	中	小	○	○	△	△	△
SLAM	中	中	△	○	○	○	○
地上SfM	大	大	×	△	○	○	×

*概ねの面積あたり点群密度の比 MMS：UAV-LP：SLAM：地上SfM=1：3：3：300、**概ねの面積あたり計測時間 MMS：UAV-LP：SLAM：地上SfM=1：3：20：100、***計測方法と計測範囲により判定（○:適する、△:条件により適用可能、×:困難）。

なる擁壁背面等のデータは取得できない。見通しの悪いカーブ等であっても、往路、復路の2方向で計測した結果を合成することにより、補完可能である。

- ・UAV-LP：計測範囲が広く上空からの視点で計測できるものの、植生等の遮蔽物の下方のデータ取得が弱く、擁壁等の対策施設は頂部を中心とした計測しかできない。
- ・SLAM：計測範囲は狭いものの、谷地形や擁壁背面等であっても人が踏査できる箇所であればデータの取得は可能である。
- ・地上SfM：計測範囲が幅広く点群密度が高いものの、計測範囲が大きくなるにつれて写真枚数やデータ処理時間が増加する。

これらのことから、各手法を組み合わせることにより、長大斜面やオーバーハング地形などの複雑な地形でも3D点群データの取得が可能と考えられる。

2.2.2 重ね合わせ断面図

各計測手法を組み合わせることにより、各方法の特長を生かした3D点群データを作成することができる。図-2(a)は自然斜面におけるUAV-LPとSLAMの3D点群データを重ね合わせた断面図である。UAV-LPは、斜面頂部や路面等の見通しの良い箇所では有効なデータを取得できるものの、植生等の遮蔽物の下方ではデータ取得密度が小さく、地表面のデータ精度が減少する。このSLAM計測は道路沿いから計測したものであるが、植生下方の地形状況や急傾斜地の微地形も確認することができた。

図-2(b)は、擁壁の周辺におけるMMSとSLAMの3D点群データを重ね合わせた断面図である。MMSは、広域なデータを取得できるものの、道路から離れた斜面頂部付近や擁壁背面等の道路からの死角部分のデータは取得で

きない。この SLAM 計測は、路線のほかに擁壁背面を踏査したことにより、擁壁の構造物やその背面状況を鮮明に確認することができた。図-3 は、ロックネット部の地上 SfM 解析結果である。データを拡大や回転させることにより、防護網の網目や堆積土砂の微地形も詳細に確認することができた。

以上、道路斜面の 3D 計測のための 4 つの手法と、それらを組み合わせた 3D 点群データの取得について述べた。各計測機器の機能・特性と今回の結果から、計測手法の適性を表-2 のようにまとめた。ただし、急峻で人が到達困難な長大斜面の頂部は、UAV-LP である程度のデータの取得は可能であるが、MMS の点群密度は小さく SLAM、地上 SfM では計測ができないため、必要に応じて自走式の撮影ロボット等による補完技術の開発が課題であると考えられる。

3. 斜面の経年変化・崩壊前兆の把握手法の検討

1 章で述べたように、これまでの防災カルテ点検では、技術者の目視など定性的な指標で経年変化を把握することが多かった。一方で前章のように、近年は斜面の詳細な 3D 点群データを取得することが比較的容易になっている。そこで、複数時期の点群データを用いて、点群間の移動量を自動的に算出することにより、変化の生じている場所と変位量を面的・三次元的に把握し、危険斜面のモニタリングを効果的・効率的に行う手法について検討した。

3.1 検討手法の概要

複数時期の地形変化を把握する場合、点群からメッシュ等に変換し、標高変化を比較することが一般的である。しかしながらこの方法では、鉛直方向と水平方向の移動が同時に生じている場合、正しい変位をとらえることができない。そこで、点群をそのまま使用し比較することで、3 次元的な変化を精度よく把握することを考えた。

複数の点群間で位置合わせを行う一般的な手法として ICP (Iterative Closest Point) 手法³⁾がある。これは、2 つの点群間の最近傍点を対応点として求め、対応点の距離を縮小する幾何変換を推定する処理を繰り返すことで、自動的な位置合わせを可能とするものである。本検討では、さらに点群の構成する面と面の距離も最小化することも考慮した手法 (CCICP, Classification and Combined ICP)⁴⁾を採用した。この方法では、レーザ計測 (UAV レーザ、MMS、SLAM 等) による点群だけでなく、UAV や手持ちカメラで撮影した写真を用いた SfM 手法により作成した点群など、各種の 3D 点群が利用できる。その際、点群形状から自動的に位置合わせしたうえで比較するので、初期値の点群を正しい座標で取得しておけば、2 時期目以降のデータは位置精度を考慮しなくてもよい利点がある。ただし特に SfM 手法で点群にゆがみが生じていると正し

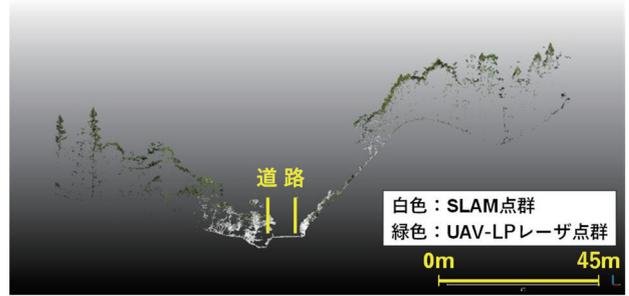


図-2(a) UAV-LP と SLAM の重ね合わせ断面図 (自然斜面)

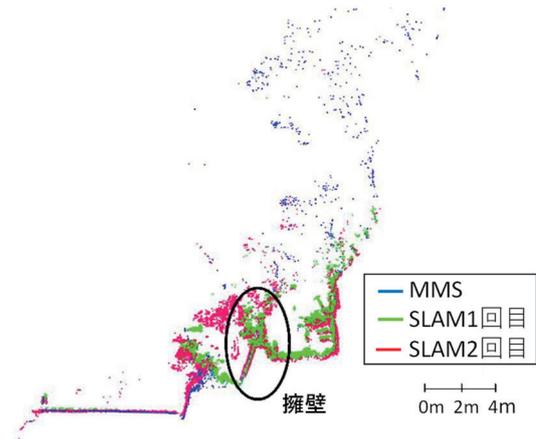


図-2(b) MMS と SLAM の重ね合わせ断面図 (擁壁)



図-3 ロックネット部の地上 SfM 計測結果

表-2 斜面における各計測手法の適性

計測箇所	各計測手法の適性*				組み合わせを含めた適性
	MMS	UAV-LP	SLAM	地上 SfM	
路線全体	○	×	×	×	MMS
谷地形	×	△	○	×	UAV-LP と SLAM
長大斜面	△	○	△	×	MMS と UAV-LP
斜面頂部	△	○	△	×	UAV-LP と SLAM
急峻な長大斜面頂部	×	△	×	×	左記の計測手法ではやや困難
見通しの良い箇所	○	○	△	×	MMS または UAV-LP
見通しの悪い箇所	△	△	○	△	SLAM
自然斜面(崖錐・岩盤)	○	△	○	×	MMS と UAV-LP または MMS と SLAM
対策施設(擁壁)	△	△	○	○	MMS と SLAM または地上 SfM
対策施設(擁壁)背面	×	×	○	△	SLAM
対策施設(ロックネット)	△	△	○	○	SLAM または地上 SfM
植生下部	△	△	○	×	SLAM
落石源等の微地形	△	×	○	○	SLAM または地上 SfM

*計測方法と計測範囲により判定 (○:適する, △:条件により適用可能, ×:困難).

い比較ができない。また解析の際は、密度や精度が同程度のもの同士で比較することが望ましい。

ここでは、転石がある状態と無い状態の2時期の手持ちカメラ画像をもとに、SfM/MVS手法により作成した点群データを用いて解析を行った事例について述べる。

3.2 CCICPによる解析結果

CCICPでは、指定した領域内で点群の分布形状から対応点を検索し、距離を縮小するための移動パラメータを算出する。移動パラメータが大きいほど、変化が大きい場所とみなすことができる。

複数の浮石が分布している斜面で石を取り除き（図-4上写真の赤丸で示す）、疑似的に転石とみなした箇所でCCICP解析を実施した結果を図-4下図に示す。三次元の移動方向をベクトルで、標高方向の変化量を色分け（暖色ほど変化大）で示している。CCICPは点群の分布形状を追跡しその距離を算出するものであるため、「石がなくなる」といった全く形状が異なる変化の場合は、追跡先が見つからず誤抽出値（大きな移動量）で返され、移動量はわからないが「変化があった」ことは把握できる。図-4を見ると、周辺ではほとんど変化がないが（5mm以下程度）、取り除いた石の位置においては変化があったベクトルの三成分合成平均値が5cm程度と周辺の約10倍の値となっており、変化を抽出することができた。

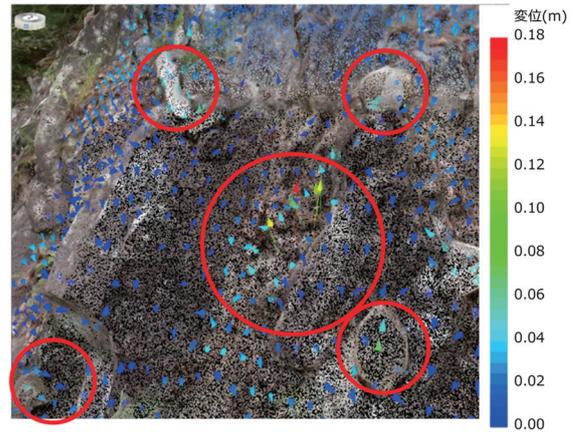
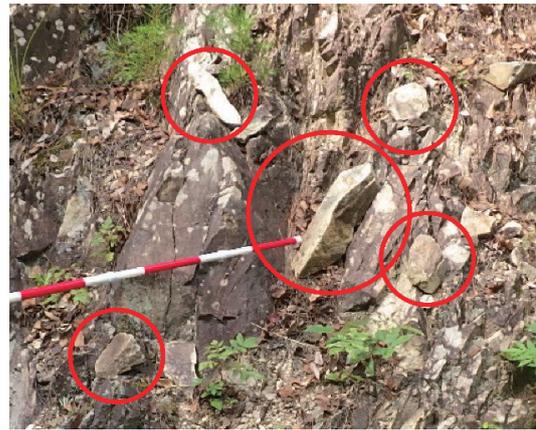


図-4 CCICPによる石の移動の解析（上は移動前の状況、下は移動後の解析結果。赤丸は移動した石。）

3.3 経年変化の把握手法

複数時期の3D点群データを用いて、変位の三次元的な経年変化を把握する手法のフローを図-5に示す。

初回データ取得時には、位置座標や縮尺の正しい3D点群データを取得する必要がある。また、把握したい変状が表現できる程度の点群密度のデータを用いることが重要である。そのため、事前に現地確認を行う等、状況を把握したうえで初回および二時期目以降のデータ取得計画（計測手法、範囲、密度等）を立案する。初回の3D点群データ取得時には現地基準点を設置して測量を行い、位置の補正・検証を行う。

2時期目以降の3D点群データ取得時には、初回データと比較可能な不動地点（構造物の角等の特徴点、あるいは基準点となる杭等）が3点以上程度、データに含まれるようにし、位置と尺度が整合できるようにする。

変化解析を行う際は、樹木など変化対象以外の点群やSfM/MVS手法で歪みが生じやすい縁辺部などのノイズ除去、点群密度が多すぎる場合の間引き等を前処理として行う。解析結果より変化の有無を判定するにあたって、将来的に事例が蓄積されれば、閾値を設定し自動化することも期待できる。現時点では、技術者が解析結果から変位の大きさや範囲などを読み取り、落石や崩壊などの斜面リスク事象による変化であるかを判断することが現実的と考えられる。

変化が確認された場合、技術者による現地確認が望ましい。将来的には、初回で安定度調査候補箇所の3D点

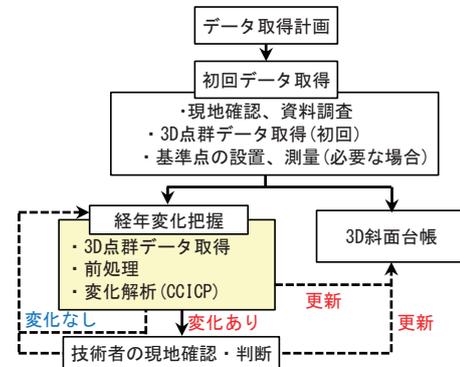


図-5 3D点群を用いた経年変化把握のフロー

群を取得し、防災カルテ点検箇所について経年的な変化を把握するなど、防災点検の枠組みの中に組み込むことで、定量化、高精度化が期待される。また各時期の3D点群、及び変化解析結果は、3D斜面台帳（5章で後述）に集約することで、道路管理に役立てることができる。

4. AIを用いた危険度評価手法

4.1 AIを用いた自然斜面の危険度評価に関する既往の研究と課題

自然斜面における崩壊、落石、土石流などの災害は、

地形、地質、地盤特性、降雨特性など様々な条件が複合して発生する災害であり、その危険度を評価する試みが世界中で行われてきた。近年は AI あるいは機械学習を活用した危険度評価が盛んに研究され、手法として、ロジスティック回帰分析⁵⁾、ランダムフォレスト (RF)^{6),9)}、サポートベクターマシン(SVM)^{7),8),9)}やファジー理論¹⁰⁾、ニューラルネットワーク¹¹⁾、CART (決定木学習)¹²⁾などが用いられている。

AI および機械学習の手法は、被災した自然斜面および無被災の自然斜面に関する情報を集めてこれらを教師データとして学習させ、これらの要因が複雑に関連すると考えられる斜面の危険度の評価を行うものである。既往の AI を用いた危険度評価の研究では、自然斜面の危険度を評価するためのパラメータとして以下が用いられている⁵⁾⁻¹²⁾。

- ・斜面勾配、斜面高さ、斜面の方角・形状、斜面の緯度などの地形的な要因
 - ・岩質、地質、土質、断層からの距離などの地質・土質的要因
 - ・降雨特性、植生指数、集水面積およびそれを用いた水文学的指標 (地形的湿潤指数、ストリームパワー指数等) などの水文学的要因
 - ・土地利用や道路・河川からの距離などの社会的要因
- これらの中で岩質・地質・土質、降雨を除くパラメータの多くは、近年急速に進展している GIS のデータと解析ツールから計算できる。また、地質・土質的要因、水文学的要因はそれぞれ地質図や降雨統計から求められて

いる。これらのパラメータは、経年的に変化するものではなく、既知の条件の下での潜在的な斜面の危険度を評価しているといえる。一方、定期的実施されている道路防災点検は、斜面の点検・観察によってその変状およびその兆候をとらえ、個別斜面の危険度を判定することを目的としている。これらの情報をパラメータとする AI 学習のためには、教師データとして「統一的な方法で定期的な点検あるいは観測を行った被災および無被災斜面のデータセット」が必要であり、現状ではこのようなデータセットは存在しない。今後防災点検の情報の 3D 化が進展すれば、これらのデータセットが順次形成され、点検・観測データをパラメータとする危険度評価が可能になるが、現状ではこれらのデータセットによらない AI 学習を考える必要がある。

4.2 道路防災点検の安定度評価表の総合判断における AI の適用

本研究は 3D 斜面台帳に定期的に記録される道路斜面の計測データを活用して危険度評価を行うことを目指しているが、前述したように現状では斜面の計測データを含む教師データは存在しない。しかし、現行の道路防災点検では、斜面の危険度評価に関する経験を有する技術者が点検を行ってその結果をまとめた安定度調査表を作成し、各要因の点検結果とともに点検した斜面について以下の 3 つのクラスのいずれに該当するかの総合評価を行っている。

- ・対策が必要と判断される (要対策, 本論文の記号 A)



図-6 道路防災点検による安定度調査表²⁾

- ・防災カルテを作成し対応する（カルテ対応，B）
- ・特に新たな対応を必要としない（対応不要，C）

図-6 に道路防災点検における自然斜面の落石・崩壊に対する安定度調査表の例を示す。図のように，安定度調査表には，斜面の危険度に関わる諸要因を全国一律に定められている配点で数値的に評価した評価点の計算結果が示されるが，技術者は評価点の値によらず総合評価を行うとされている¹⁵⁾。したがって，現行の安定度調査表の総合評価は，定性的な評価に基づくものではあるが，経験を有する技術者がどのように危険度を判定しているかを示す教師データであるといえる。この総合評価の判定をAIに学習させることにより，斜面の計測データを安定度調査表の評価に換算すれば，経験を有する技術者と同等の水準で自動的に3段階の危険度評価を行うことが可能になる。

図-7 は広島県内のある事務所が管轄する道路斜面 109 か所の安定度調査表における評価点と技術者の総合評価との関係である。図のように，評価点が大きいくほど要対策の評価，評価点が小さいほど対策不要となる傾向があるが，それぞれの判定の境界における評価点には幅があり，技術者は評価点だけでない総合判断をしていることがわかる。

そこで，広島県内の 322 か所の安定度調査表のデータを収集し，これを教師データとして斜面の点検・観測情報から経験を有する技術者による総合判断を AI に学習させることとした。この際に現行の安定度調査表に規定された各要因の重みは与えず，各要因のデータ（たとえば該当するかしないか）と総合評価結果のみを学習させる。これは経験のある技術者の判断を AI に代行させることを目標としたものである。

代表的な機械学習モデルであるランダムフォレスト（RF）とサポートベクターマシン（SVM）の2つの判定モデルを用い地形，土質・地質・構造，表層の状況，幾何学形状，変状，既設対策工の効果に関する情報を説明変数とし3段階の総合評価の予測を目的として，教師データの学習を行い危険度判定のモデルを作成した。なお，過去の被災箇所はすべて復旧し対策工が施されているので，被災履歴は説明変数として使用していない。

322 データの総合評価結果の割合を表-3 に示すが，判定する3クラス（要対策，カルテ対応，対応不要）ごとにそれぞれ 32.0%，44.7%，23.3%であった。評価の配分に配慮したうえで，教師データを AI 学習用と学習によって構築した AI モデルの検証用におよそ 7:3 の比率で区分した。解析では調査表の点数（現在設定されている重み）ではなく各項目のどの区分に該当するかのクラス分けとして入力を行った。図-6 の調査表にある[要因](Ai)の自然斜面の各項目と[対策工](Bi)を説明変数とし，総合評価を目的変数とした。

AI による機械学習に用いたプログラムは `skit-learn 0.22.2.post1` である¹⁶⁾。RF モデルと SVM モデルのパラメータを表-4，表-5 に示す。表-4 の `class-weight` は判定す

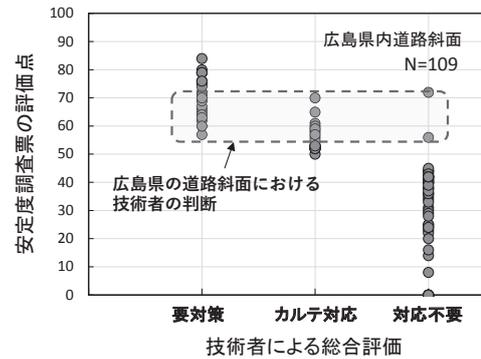


図-7 安定度調査表における評価点と技術者の総合評価との関係（ある建設事務所管内の道路斜面）

表-3 解析に用いた安定度調査表の総合評価の分類

要対策 (判定 A)	カルテ対応 (判定 B)	対応不要 (判定 C)
103	144	75
32.0%	44.7%	23.3%

表-4 RF モデルの解析に用いたパラメータ

パラメータ	設定値	説明
n estimators	2	樹*の数.
max depth	5	樹*の最大深度.
class weight	'balanced'	クラスの重み. Balanced はクラスの頻度に反比例するように自動計算. クラスバランスのため class_weight を使用.
random state	41	ランダム性を制御するパラメータ.

*機械学習に使用される決定木（木構造）

表-5 SVM モデルの解析に用いたパラメータ

パラメータ	設定値	説明
kernel	'poly'	使用するカーネルタイプを指定する. poly は多項式カーネル関数.
degree	2	多項式カーネル関数の次数.
probability	True	確率の推定を有効にするかどうかを指定.
class weight	'balanced'	クラスごとの出現頻度の違いを考慮するため class_weight を使用.

表-6 AI 解析の出力例（SVM モデル）

斜面の箇所名	[総合評価]						AIによる判定
	技術者の判断(真値)			AIによるA,B,Cの予測確率			
	要対策 A	カルテ対応 B	対応不要 C	要対策 A	カルテ対応 B	対応不要 C	
RXXX-01		B		0.644	0.332	0.024	A
RXXX-02			C	0.023	0.069	0.908	C
RXXX-03			C	0.078	0.800	0.122	B
RXXX-04			C	0.017	0.046	0.937	C
RXXX-05			C	0.106	0.276	0.618	C
RXXX-06			C	0.121	0.410	0.468	C
RXXX-07		B		0.683	0.312	0.005	A
RXXX-08		B		0.295	0.690	0.016	B
RXXX-10		A		0.880	0.120	0.000	A
RXXX-11		B		0.515	0.472	0.012	A
RXXX-12		B		0.292	0.672	0.036	B

る3クラスで出現頻度が異なる影響の考慮の有無を指定するものである。出現頻度の高いクラスへ最適化されないようにするため，学習時にクラス重みを出現頻度に反比例となるように設定した。

AI モデルの評価には，正解率(Accuracy)と F1score(F1)を用いた。それぞれの定義は式(1)，式(2)である。

$$Accuracy = (\text{判定が正のデータ数}) / (\text{全データ数}) \quad (1)$$

$$F_1 = 2 \text{ Precision} \cdot \text{Recall} / (\text{Precision} + \text{Recall}) \quad (2)$$

ここに、Precision は適合率（クラスごとに予測したデータのうち実際に正である割合）であり、Recall は再現率（クラスごとのデータ中の予測が正しいものの割合）である。各クラスごとに Accuracy と F₁ を計算し、その平均をモデルの正解率、F1score とした。

4.3 AI 解析の結果と考察

表-6 に SVM モデルを用いた AI 解析の出力を示す。出力される値は、検証データに学習モデルを当てはめた場合の、各総合評価の予測確率と AI による判定である。AI による判定は、予測確率が最も高くなるクラスとした。予測確率が同じ値の場合は、「要対策」→「カルテ対応」→「対応不要」の順に参照し、安全側の判定となるように最初に参照したクラスを AI の判定とした。たとえば予測確率の値が「要対策」0.5, 「カルテ対応」0.0, 「対策不要」0.5 の場合、判定は「要対策」とした。

表-7 は RF モデルと SVM モデルの予測結果の比較である。表中には正解率、F1score のほか、危険度過小評価割合と予測結果に対する重要度が高い順に 6 つの特徴量を示している。この中で下線を付したものは表土・浮石、当該斜面の変状など計測結果が反映される量である。

安定度調査表において経験を有する技術者が示した総合評価を真値として AI による予測結果と評価すると、RF モデルと SVM モデルで正解率はそれぞれ 0.835 と 0.814, F1score が 0.817 と 0.805 であった。この判断の妥当性を確認するため、予測結果について考察を行った。

図-8 は RF と SVM におけるクラスごとの予測確率の分布である。図のように、A (要対策) と B (カルテ対応) に関する予測確率の分布は AI のモデルによって大きく異なっている。RF では 31 か所が A と判定されたが (予測確率最大により判定)、クラス A の予測確率は 26 か所で 80-100%, 4 か所で 60-80% であった (31 か所中 30 か所が該当)。また、51 か所が B と判定されたが、クラス B の予測確率は 22 か所で 80-100%, 28 か所で 60-80% であった (51 か所中 50 か所が該当)。このように、特定のクラスの予測確率が明確に大きくなっており、確率の大

表-7 AI 解析におけるモデルごとの予測結果の比較

モデル	RF モデル	SVM モデル
予測結果		
正解率	0.835	0.814
F1score 平均	0.817	0.805
危険度過小評価割合*	4/16	5/18
重要度が高い特徴量**	1.表土・浮石 2.対策工 3.崩壊(流れ盤) 4.崩壊(土砂) 5.崩壊(岩質) 6.隣接斜面	1.表土・浮石 2.対策工 3.当該斜面 4.勾配 5.崩壊(岩質) 6.隣接斜面

* (危険度が過大な方向に誤判定した斜面の数) / (誤判定した斜面の数)

** 表土・浮石=表土及び浮石・転石の状態, 崩壊(流れ盤)=崩壊性の構造 (流れ盤), 崩壊(土砂)=崩壊性の構造 (土砂), 崩壊(岩質)=崩壊性の構造(岩質), 当該斜面=当該斜面の変状, 隣接斜面=隣接斜面の変状。

きさからも判定はきわめて明確といえる。これに対して SVM では、特定のクラスに予測確率が 60%以上となる箇所数は RF に比べ少なく、A と判定された 32 か所の A の予測確率は 80-100% が 9 か所、60-80% が 15 か所、40-60% が 8 か所となっている。これは、RF では個々の条件ごとにイエス・ノーの要領で分類していくため、分類されたクラスごとに予測確率の値が明確に異なっているのに対して、SVM では連続的に変化する予測確率の値をある境界で分類しているため、クラスごとの予測確率の違いが RF ほど大きくならないと考えられる。すなわち、これらの予測確率の分布の違いはモデルの特徴を反映している。

予測に寄与した程度を示す特徴量 (説明変数) の重要度をみると、RF モデルでは、「表土及び浮石・転石の状態」、「対策工」、「崩壊性の構造 (流れ盤)」、「崩壊性の構造 (土砂)」、「崩壊性の構造 (岩質)」の重要度が高かった。一方、SVM モデルでは、「表土及び浮石・転石の状態」、「対策工」、「当該斜面の変状」、「勾配」、「崩壊性の構造 (岩質)」が高かった。5.2 で検討するが、3D 斜面台帳の計測結果は、「当該斜面の変状」、「表土及び浮石・転石の状態」、「隣接斜面の変状」として、危険度評価に関わってくるので、この観点からは「当該斜面の変状」の

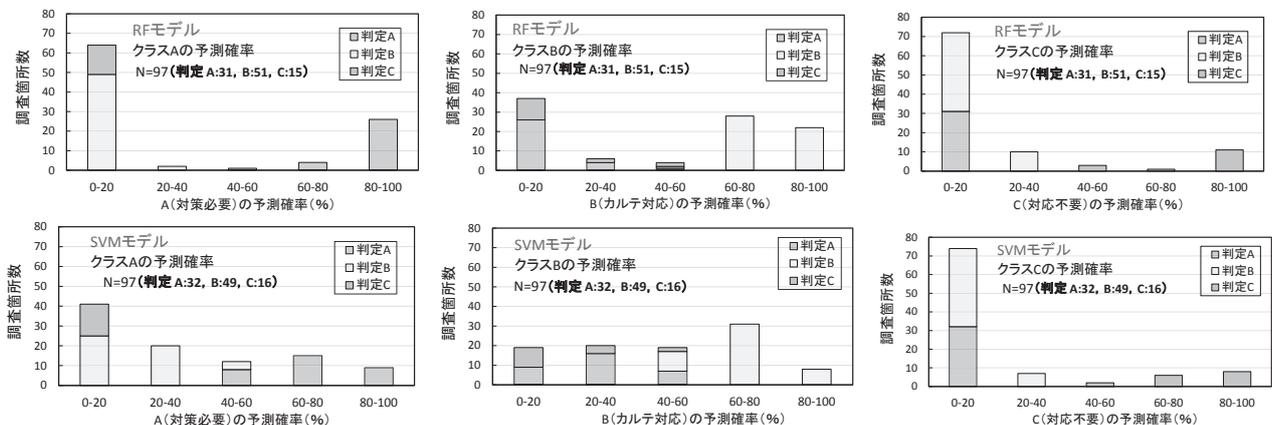


図-8 RF モデルと SVM モデルにおける判定クラスごとの予測確率の分布

表-8 AI 判定（予測確率最大のクラス）が真値(技術者の判定)と異なったケースの AI の予測確率の内訳

SVMモデル(18か所)

調査表の 評点	調査表の 総合 評価	AI判定	予測確率A (対策必要)	予測確率B (カルテ対応)	予測確率C (対策不要)
71	B	A	0.644	0.332	0.024
46	C	B	0.078	0.800	0.122
70	B	A	0.683	0.312	0.005
70	B	A	0.515	0.472	0.012
49	C	B	0.120	0.747	0.133
68	B	A	0.528	0.439	0.033
56	C	B	0.140	0.775	0.085
45	C	B	0.090	0.548	0.361
68	B	A	0.734	0.244	0.022
42	C	B	0.063	0.675	0.262
46	C	B	0.117	0.705	0.178
68	B	A	0.538	0.455	0.008
57	A	B	0.483	0.488	0.029
70	A	B	0.282	0.710	0.009
41	B	C	0.144	0.084	0.771
70	C	A	0.715	0.278	0.007
71	A	B	0.274	0.719	0.007
48	B	C	0.041	0.208	0.751

AI判定の予測確率(A,B,Cの中の最大) 真値(調査表の判定)の予測確率

RFモデル(16か所)

調査表の 評点	調査表の 総合 評価	AI判定	予測確率A (対策必要)	予測確率B (カルテ対応)	予測確率C (対策不要)
71	B	A	0.963	0.037	0.000
46	C	B	0.000	1.000	0.000
70	B	A	0.928	0.072	0.000
49	C	B	0.301	0.552	0.147
56	C	B	0.000	1.000	0.000
45	C	B	0.194	0.660	0.147
68	B	A	0.928	0.072	0.000
75	A	B	0.194	0.660	0.147
42	C	B	0.000	0.626	0.374
46	C	B	0.000	0.626	0.374
0	C	B	0.000	0.930	0.070
0	B	C	0.027	0.448	0.525
70	C	A	0.963	0.037	0.000
71	A	B	0.369	0.631	0.000
48	B	C	0.106	0.248	0.647
55	B	A	0.963	0.037	0.000

AI判定の予測確率(A,B,Cの中の最大) 真値(調査表の判定)の予測確率

重要度が高いSVMモデルの方が3D斜面台帳に適していると考えられる。

RFとSVMについて、AIの判定（予測確率最大のクラス）が真値（技術者の判定）と異なったケース（RF16か所、SVM18か所）の各クラスの予測確率の内訳を示したのが表-8である。表にはデータ番号、安定度調査表の評点と総合評価、AIによる判定、クラスA、B、Cの予測確率を示している。表ではSVMモデルとRFモデルで同じ調査箇所が12か所あり、モデルによらず予測が外れやすいデータに共通点があると考えられる。表中では真値のクラスに対するAIの予測確率を赤字で示し、さらに赤字の予測確率が0.1以下の場合、太字で表示した。RFの16か所をみると、赤字で示された確率が半分の8か所で0.1以下となっており、確率の値から判定結果が真値から大きく外れていることを示すが、これは分類されたクラスごとに予測確率が明確に異なってくるRFモデルの特徴と関連していると考えられる。

一方、SVMの場合は予測確率0.1以下が3か所しかなく、逆に0.3以上が7か所、うち4か所は0.4以上となっている。すなわちSVMの場合は、予測確率が最大にならず選択されない場合でも最大に準じる大きさの予測確率が計算されており、わずかの差で判定が外れていると解釈できるデータが多いことがわかる。斜面の危険度評価における技術者の場合も、明確に判断できる場合と判断基準の境界にある場合には判断に悩む場合もあり、SVMモデルの方がより技術者の判断との類似性が高いように思われる。

4.4 AIによる予測確率を用いた新総合評価値Eの提案

図-9はAIが予測した総合評価と安定度評価表の評点の関係である。図で真値とは安定度調査における技術者の判定である。AIによる結果は、評価点72点以上はA、52～71点の範囲ではAまたはB、38～51点の範囲ではBまたはC、38点以下はCという関係となっており、これらは検証用データの真値の傾向とよく一致している。図-9は今回のAIモデルによる総合評価が経験を有する

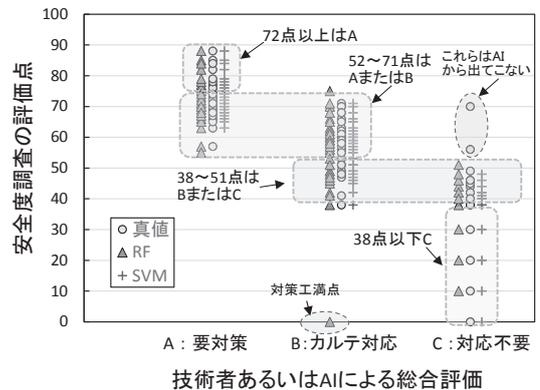


図-9 AIが予測した総合評価と安定度評価表の評点の関係

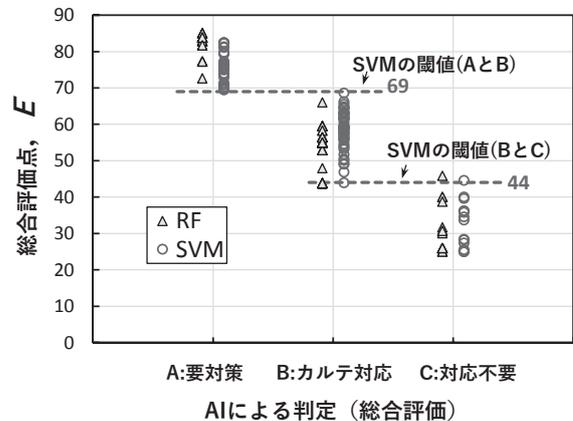


図-10 AIによる予測確率を用いた新総合評価値E値と総合評価との関係

技術者の判断をほぼ適切に学習していることを示していると考えられる。

AIによる予測確率の最大値により「要対策」と判定されても、必要度（危険度）の違いは予測確率に表現されている。予測確率を用いることにより、3段階の判定よりもきめ細かく危険度評価ができると考えられる。この観点から、AIによる予測確率を用いて、以下のように新総合評価値Eを定義した。

$$E=85P_A+55P_B+25P_C \quad (1)$$

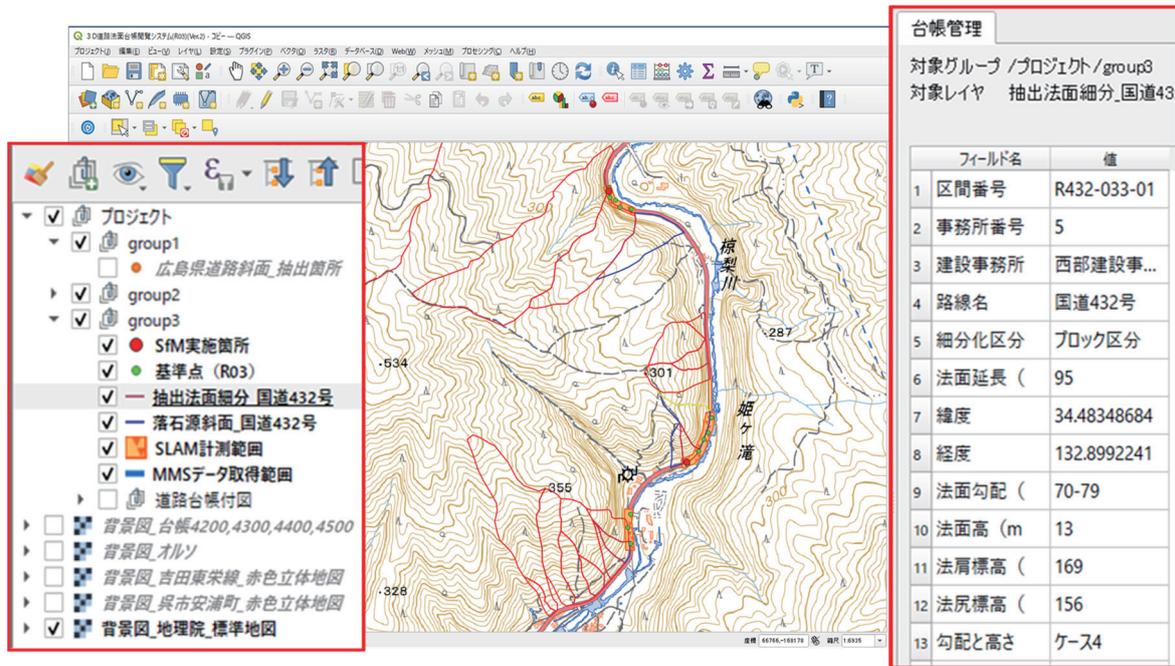


図-11 試作した 3D 斜面台帳 (オープン画面)

ここに P_A , P_B , P_C はそれぞれ AI モデルによる A, B, C の予測確率(%)である. なお, P_A , P_B , P_C に乗じる係数 85, 55, 25 は, A 判定, B 判定, C 判定におけるそれぞれの E の平均値が現行の安全度調査票の評価点の平均値とほぼ一致するように設定した.

図-10 は E と判定結果の関係である. 図をみると, RF モデルの場合, E 値 72 以上が A 判定と 66 以下が B 判定となっており 66~72 にギャップがある. 一方, E 値が 44~46 の場合に評価が B 判定と C 判定に分かれている. SVM モデルの場合は E 値がほぼ連続的に分布し, A 判定と B 判定, B 判定と C 判定がそれぞれ 69 と 44 を閾値として明確に分かれている. これらより, SVM を使用した場合, E 値によって当該斜面の安定度の変化をきめ細かく把握できると考えられる.

5. 3D 斜面台帳を活用した道路斜面のリアルタイム危険度予測の実用化に向けた検討

本研究では, DX 時代に向けたチャレンジとして, 道路防災点検の高度化・効率化を目指し, より効率的な 3D 点群データの取得・活用方法, 3D 点群データを利用した斜面の経年変化の把握手法, AI を用いた危険度評価手法を検討した. これらの技術の実用化するためには, データを一元化して管理し, それぞれの技術を融合させることが必要である. また, 現段階で点検方法や仕組みを一気に変更することは非現実的であるため, これまでの道路防災点検で蓄積されてきた, ノウハウやデータを活用しながら, 徐々に移行していくことが重要であると考えられる. このためには, 3D 点群データや道路防災点検結果などを一元的に管理できるよう, GIS プラットフォーム

による新たな斜面台帳 (以下, 「3D 斜面台帳」と呼ぶ) が必要であると考えられる.

また, 前章の AI による危険度判定により, 斜面の持つ素因としての危険度を評価することができたが, 実用的な斜面崩壊予測のためには, 素因である斜面危険度の経年的な更新とともに, 誘因である降雨の情報とを合わせたリアルタイムの危険度評価が必要であると考えられる. ここでは, 3D 斜面台帳による経年的な危険度評価のための課題および雨量指標 R' との併用によるリアルタイムの斜面崩壊発生予測の方法について検討する.

5.1 GIS プラットフォームによる 3D 斜面台帳の試作

オープンソースの QGIS を利用して, GIS プラットフォームによる 3D 斜面台帳を試作した. 図-11 にオープン画面を示すが, GIS と情報をリンクさせ, 編集およびレイヤ管理には FGEX プラグイン¹³⁾を, 3D 点群データの表示と地図情報の計測機能には Laser Map Viewer¹⁴⁾を用いた.

図-12 は Laser Map Viewer による 3D 点群データの表示例であり, 洞門, 法枠工, ロックネットの支柱の状況等が把握できる. 3D 斜面台帳では, Web から得た最新の国土地理院の地図をベースとして, 随時入力されるオル

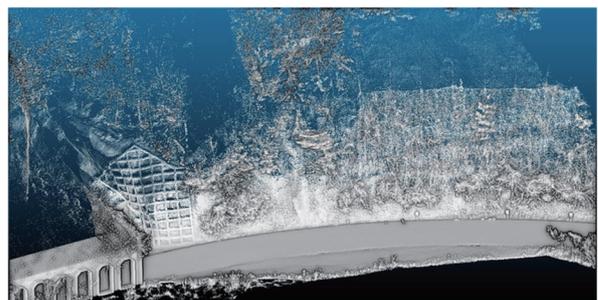


図-12 Laser Map Viewer による 3D 点群データの表示

ソ写真, 3D 点群データを取得した範囲の赤色立体図, 既往の道路防災点検の位置図に加え, 別事業による LP 測量結果などの情報も共有できる. さらにレイヤの表示/非表示を切替えることにより容易にこれらの情報の重ね合わせが可能である.

3D 点群データを GIS 上で管理することで, 任意の視点や倍率で鳥瞰的に地形を確認することができ, 2 次元の写真では確認できなかった現地の状況を詳細に把握することができる. 図-13 に斜面を鳥瞰した例を示すが, 全体をみながら任意の位置で勾配や距離の読み取りと断面図の作成が容易に行えるため, 現行の道路防災点検において目視あるいは簡易な計測手法で確認している情報を正確かつ詳細に把握できる. さらに, 3D 点群データの蓄積によって, 過去と最新の点群データに 3 章で述べた CCICP 処理を行って点群間の移動量を自動的に算出し, 経年変化を定量的に表示することが可能になる.

このように GIS プラットフォームによって, 道路防災点検結果や対策工等の施工および維持管理等のあらゆる情報を共有し, 空間的・時間的に一元管理することが可能となる. GIS プラットフォームは DX 時代のインフラの整備と管理に欠かせない基盤になると考えられる.



図-13 3D 斜面台帳による斜面の鳥瞰

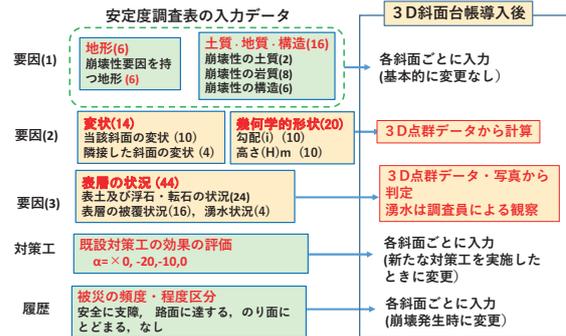


図-14 3D 斜面台帳を導入したときのデータと安定度調査表の入力データとの関係

5.2 3D 斜面台帳による変状の把握・蓄積と AI による道路斜面の危険度評価への反映のための課題

3D 斜面台帳が導入され, 道路防災点検時の斜面の計測データが入力される仕組みができると, 最新のデータによる AI 判定から, 経年変化の危険度評価を随時更新することが可能となる.

3D 斜面台帳を導入した場合に計測により更新される斜面データと安定度調査表の入力データとの関係を図-14 に示す. 図のように, 斜面崩壊の要因のうち地形, 土質・地質・構造は計測を行っても基本的には変更がないデータである. 一方, 要因の中で変状, 形状, 表層の状況は 3D 点群データや写真により, 計測ごとに変化する可能性がある. また, 対策工と被災履歴はそれぞれ対策工を実施したときと被災が起こったときに記録される. 前章で開発したモデルを用いれば 3D 斜面台帳のデータが更新されるごとに, AI により斜面の危険度の判断を最新の判断に反映することができる.

図-15 は 3D 斜面台帳を用いた経年変化の把握と斜面のリスク評価への反映の過程を図示したものである. まず 3D 計測で得られる点群データを CCICP 解析することにより変状等のデータとして蓄積する. 現段階では CCICP 処理において技術者が個別の斜面ごとに位置を指定して解析し, 必要な場合は現地確認を行って解析結果を解釈する必要がある. 次に, 3D 斜面台帳のデータが蓄積された段階で, 斜面の変状等の履歴を AI 解析の説明変数として反映させるが, この過程でも現段階では技術者が判断する必要があると考えられる. 図に示すように, 技術者の判断が必要な変状の把握と蓄積の過程, AI 解析の説明変数に反映させる過程の自動化は, 今後の課題で

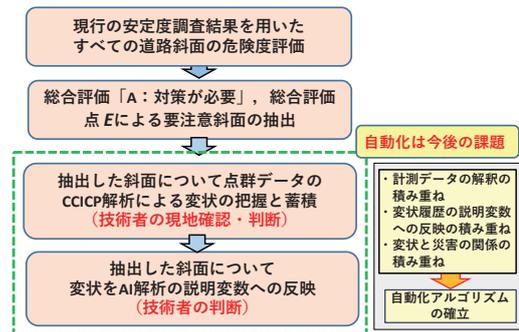


図-15 3D 斜面台帳を用いた経年変化の把握と斜面のリスク評価への反映

ある. 計測データの解釈および変状履歴の積み重ね, 説明変数への反映に関する技術者の判断の積み重ねにより, 自動化に必要なアルゴリズムが確立されると考えられる. なお, 今回の AI 解析の判断は従来の安定度調査表の項目に基づいて構築されているが, これは AI 学習には一定の教師データが必要であり, 現状では道路斜面の計測データを活かした斜面リスクに関する教師データが存在しないためであった. 3D 道路台帳を構築した後に, 3D 道路台帳で得られる高精度で精密な変状のデータと構築後の災害発生の有無を新たな教師データとして, AI モデルをより精度の高いものに更新することが今後の課題であると考えられる.

5.3 3D 斜面台帳の情報と雨量指標 R を組み合わせた道路斜面のリアルタイム危険度評価手法の検討

4 章では既往道路防災点検の安定度調査データをもと

に AI による危険度判定を行い、「要対策」、「カルテ対応」、「対応不要」の 3 つのランクを決定する手法を検討し、斜面の持つ素因としての危険度を評価することができた。一方、広島県における斜面崩壊の多くは、梅雨前線や台風による豪雨を誘因としている。ここでは誘因のリスク評価に雨量指標 R' を用い、 R' と素因である斜面崩壊危険度を組み合わせた道路斜面のリアルタイム危険度評価手法を検討した。

雨量指標 R' は、土砂災害発生の危険度を予測する指標として、長期実効雨量と短期実効雨量をパラメータとして式(4)で計算される値である。

$$R' = \sqrt{R_1^2 + a^2 r_1^2} - \sqrt{(R_1 - R_w)^2 + a^2 (r_1 - r_w)^2} \quad (4)$$

ここに、 R_w は半減期 72 時間の長期実効雨量 (mm)、 r_w は半減期 1.5 時間の短期実効雨量 (mm) である。また、 R_1 、 r_1 は地域ごとに決まる定数で、 a は長期実行雨量と短期実行雨量を合成するための重み係数である。

これまでの研究^{17)~19)}により、 R' が発生した土砂災害の特徴や規模と降雨との関係を良好に説明できることがわかっており、広島県周辺の事例では、 $R_i = 600\text{mm}$ 、 $r_i = 200\text{mm}$ 、 $a = 3$ とした場合、 $R' > 125\text{mm}$ でがけ崩れ、 $R' > 175\text{mm}$ で山地崩壊、 $R' > 250\text{mm}$ で土石流が発生し始めること¹⁸⁾、さらに $R' > 400\text{mm}$ になると甚大な被害が発生していることがわかっている¹⁹⁾。

道路斜面の災害に限定した場合の適用性を確認するため、2020 年と 2021 年に広島県で発生した 94 件 (2020 年 12 件、2021 年 82 件) の道路災害について発生時の雨量指標 R' を算定した。収集した災害事例については、災害報告時の資料や写真などを参考に「土石流」、「崩壊」、「土砂流出」、「落石」、「その他」に分類した。災害の発生日は特定されているが、発生時刻が不明のものも多かったため、前日の夜間に発生したものも含まれる可能性も考慮して、前日の 18 時～当日 24 時の R' の最大値を発生雨量指標として検討した。2021 年 7 月豪雨と 8 月豪雨の災害については、広島県災害対策本部の報告資料²¹⁾に合わせ、前者は 7 月 7 日 5 時～7 月 13 日 9 時、後者は 8 月 11 日 21 時～8 月 25 日 15 時までの雨量を対象とした。

被災箇所の雨量指標 R' は、本研究で作成した「広島県内 R' リアルタイム表示システム」により算出したメッシュごとの値を用いた。本システムは、広島県防災 Web²⁰⁾ にリアルタイムで公開されている県内 405 箇所の雨量観測局の「半減期 1.5 時間実効雨量」と「半減期 72 時間実効雨量」の値を随時読み取り、休止中の観測局を除いた値を用いて雨量指標 R' を求め、内挿により $2\text{km} \times 2\text{km}$ メッシュの R' を算定し、これをもとにしたコンター図を描くものである。

図-16 は本システムによる R' 分布の例である。図に示す緑色のマーカーは広島県内の雨量観測局の位置を示している。マーカーの色は常時は緑であるが、60 分雨量が 0.5mm 以上の観測局は水色、 R' が崩壊発生限界 (暫定的

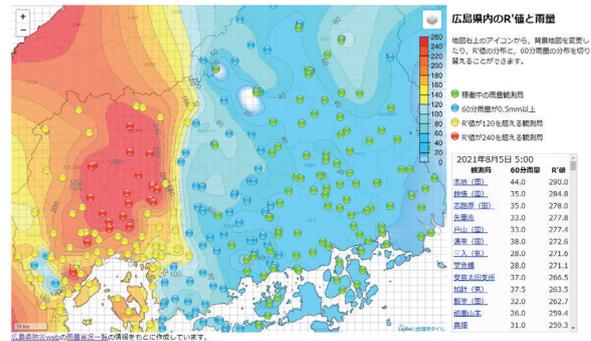


図-16 広島県 R' リアルタイム表示システム

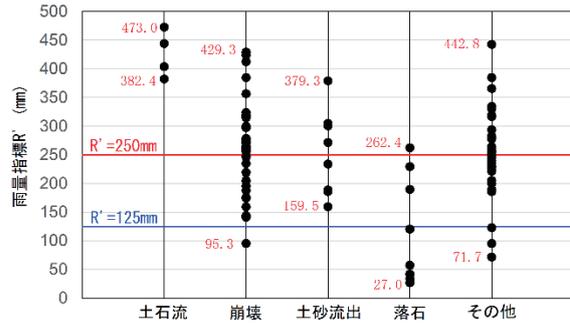


図-17 2020 年と 2021 年に広島県で発生した道路災害における形態別の雨量指標 R' の分布

に 120mm に設定) を超えると黄色、 R' が土石流発生限界 (暫定的に 240mm に設定) を超えると赤で表示される。 R' 分布は 10 分ごとに計測される観測局の雨量情報により、10 分ごとに更新される。本システムを利用すると道路斜面の緯度と経度を与えれば、最新の R' を知ることができる。

図-17 は、災害形態別に雨量指標 R' の分布を示したものである。発生時刻が特定されていないものも多いため、雨量指標 R' は一連の降雨の最大値を採用している。また、図中の「その他」は、道路陥没や浸水、河川による洗堀、倒木などで、いずれも豪雨を起因とすることもある現象であるが、本研究で取り扱う土砂移動現象とメカニズムが異なるため、一括してその他とした。図のように、土石流は $R' = 382.4 \sim 473.0\text{mm}$ 、崩壊は $R' = 95.3 \sim 429.3\text{mm}$ 、土砂流出は $R' = 159.5 \sim 379.3\text{mm}$ 、落石は $R' = 27.0 \sim 262.4\text{mm}$ 、その他は $R' = 71.7 \sim 442.8\text{mm}$ の範囲に分布している。このように、最近 2 年間の災害でも「土石流」は全て $R' > 250\text{mm}$ で発生し、「崩壊」(がけ崩れ) は 1 例を除いて $R' > 125\text{mm}$ で発生した。なお、今回 $R' = 95.3\text{mm}$ で崩壊した 1 例は既往の崩壊地の肩部が小規模に崩れたものであり、例外として取り扱うと考えられる。また、山地崩壊による土砂が谷筋から流れ出たと考えられる土砂流出は、1 例 (この事例の詳細は不明) を除いて $R' > 175\text{mm}$ で発生していた。

以上の結果より、道路災害においても既往研究^{17)~19)}から求められた上述の閾値を用いることができると判断される。なお、落石は $R' < 100\text{mm}$ の小規模な降雨での発生も多い。落石は、地震、強風、凍結・融解、動物の接

触などの事象が引き金となることもあり、岩塊や転石の不安定化はいったん進行すると降雨が停止してもリセットされることなく蓄積される傾向があることによると考えられる。したがって、落石は降雨のみで完全に予測することは困難であるが、一方で豪雨によると考えられるケースも相当数あり、図-17 は改めて豪雨時に注意を要する現象の1つであることを示している。

なお、既往の研究¹⁸⁾により、広島県内の $R^*=250\text{mm}$ に相当する雨量の生起確率は地域差があり、県内では北西ほど限界値が高く、南東ほど低い。 $R^*=159.5\text{mm}$ で土砂流出が発生した箇所は県東部に位置するため、付近の土砂移動現象の発生限界降雨がやや低めである可能性もある。

AIによる道路斜面の危険度評価と広島県 R^* リアルタイム表示システムを組み合わせることにより、現在の雨量を考慮したリアルタイムの危険度評価が可能になる。

ある地域内において経験的に求めたがけ崩れ、山地崩壊、土石流に関する R^* の閾値をそれぞれ $R^{*}_{(がけ)}$ 、 $R^{*}_{(山地崩壊)}$ 、 $R^{*}_{(土石流)}$ と表すことにする。 R^* リアルタイム表示システムの R^* 分布から任意の道路斜面におけるリアルタイムの R^* を読み取り、 R^* と閾値との比を雨量による危険度指数 I_R と定義すると、降雨によるがけ崩れの危険度指数 $I_{R(がけ)}$ は次式で表される。

$$I_{R(がけ)} = R^*/R^{*}_{(がけ)} \quad (5)$$

$I_{R(がけ)}$ は R^* が閾値の何倍となっているかを示しており、災害の誘因としての雨量の大きさを意味する。 $R^{*}_{(がけ)}$ は地域内ではがけ崩れが発生する閾値であり、がけ崩れの素因が高い箇所から被災が始まると考えられる。4章で提案したAIによる新総合評価値 E を I_R と組み合わせることにより、リアルタイムでの誘因と素因を組み合わせた危険度評価が可能となる。

図-18は、ある道路斜面において3D台帳による斜面の最新の E 値とリアルタイムの $I_{R(がけ)}$ を画面上に表示するイメージを示している。 E 値による斜面の危険度をマーカーの色で表示しているが、リアルタイムの $I_{R(がけ)}$ を警戒すべき箇所として以下の基準で示した。

赤色で表示：「要対策」($E \geq 69$)で $I_{R(がけ)} \geq 1$

橙色で表示：「要対策」($E \geq 69$)で $0.8 \leq I_{R(がけ)} < 1$

「カルテ対応 ($44 \leq E < 69$)」で $I_{R(がけ)} \geq 1$

図-18のように斜面ごとに、素因としての危険度 E と誘因の危険度である I_R を同時に表示して道路防災の判断に用いる効果として、以下が考えられる。

- 道路斜面単位での予測なので、豪雨が継続している状況で、「道路のどこでどのような災害が起こりうるか」を予測でき、発災時の迅速できめ細かい対応に役立つ。
- 発災時に当該箇所の道路斜面に関する基本情報、点検時の計測データ、発災前の危険度の推移を直ちに参照できる。これらは、迅速な復旧に資するとともに災害発生メカニズムの解明に役立つ。
- リアルタイムの危険度が高かったが災害に至らなかった道路斜面は、豪雨終了後の規制解除の判断において、



図-18 3D 斜面台帳による斜面の危険度評価値 E と雨量による危険度 I_R のリアルタイム表示のイメージ図

最優先の点検箇所となる。また、次の豪雨に備えた防災対策の優先度の判断にも使用することができる。

- 道路防災点検に基づく素因としての危険度と誘因の危険度である I_R および実際の被害発生状況の関係を積み重ね、危険度評価の精度を向上させることができる。このことは、道路防災点検の高度化・効率化に資する。

6. まとめ

道路防災点検の安定度調査は、現状ではその時点の斜面の素因としての状況を記録したもので時系列の確認はカルテ点検による着眼点の変化により把握されている。本研究は、デジタルテクノロジーを活用して道路防災点検を高度化かつ効率化することを目的として、より効率的な3D点群データの取得・活用方法、3D点群データを利用した斜面の経年変化の把握手法、さらにAIと計測データを用いた斜面の危険度評価手法について検討を行った。主な結論をまとめると以下ようになる。

- 谷地形、急峻な長大斜面、見通しの悪いカーブ、崖錐・岩盤が多く存在し、擁壁やロックネット等の対策施設が整備されている、という特徴を有する広島県の道路の斜面において、MMS, UAV-LP, SLAM, 地上SfMを用いた計測を行い、各技術が適用できる道路の箇所・条件を明らかにした。
- 複数時期の点群データを用いて、点群間の移動量を自動的に算出し、変状の位置と量を面的・三次元的に把握して危険斜面のモニタリングを行う手法について検討した。複数の点群間で位置合わせを行うICP手法は、2つの点群間の最近傍点を対応点として求め、対応点の距離を縮小する幾何変換を推定する処理を繰り返す方法であるが、さらに点群の構成する面と面の距離の最小化を考慮した手法であるCCICPを採用し、実際の道路斜面の計測データに適用した。その

結果、三次元の移動量を計算し、図示することができた。

- (3) 道路防災点検における安定度調査表は、経験を有する技術者が観察した表層の状況、斜面の変状、形状などの観察が情報に含まれ、これらに基づいて 3 段階の総合評価（要対策、カルテ対応、対応不要）を行っている。そこで、安定度調査表の要因、対策、被災履歴に関するデータと総合評価の関係を AI に学習させ、道路斜面の変化・変状に関する情報を含む危険度評価モデルを構築した。AI 解析のモデルとしてランダムフォレスト (RF) とサポートベクターマシン (SVM) を適用した結果、正解率には大きな差がなかった。しかし、SVM モデルの方が、3D 斜面台帳の計測結果がより重要度の高い説明変数となったこと、予測確率の分布が現行の技術者の判断と類似性が高かったことより、SVM モデルが本研究の目的に適しているといえる。
- (4) SVM モデルによる各クラス (A:要対策, B:カルテ対応, C:対応不要) の予測確率を用いて、新たな総合評価点 E を定義した。 E を使用することにより、当該斜面の安定度の変化をよりきめ細かく把握できる。
- (5) GIS プラットフォームによる 3D 斜面台帳を試作した。GIS と情報をリンクさせ、編集およびレイヤ管理には FGEX プラグインを、3D 点群データの表示と地図情報の計測機能には Laser Map Viewer を用いた。これによって、地図上の任意の箇所における 3D 点群データの表示、任意の視点や倍率での斜面の鳥瞰図の作成、計測時期が異なる 3D 点群データを用いた変状・変形量の計算ができることを明らかにした。GIS プラットフォームによって、道路防災点検結果や対策工等の施工および維持管理等のあらゆる情報を共有し、空間的・時間的に一元管理することが可能となる。
- (6) 今回開発した AI モデルによって計測データを斜面危険度評価に反映させるには、まず 3D 計測で得られる点群データを CCICP 解析によって変状等のデータとして蓄積する。現段階では技術者が個別の斜面ごとに位置を指定し、必要な場合は現地確認により解析結果を解釈する必要がある。
- (7) 3D 計測で得られる点群データを CCICP 処理して斜面の経年変化を把握し、安定度調査表の説明変数に変換して更新する必要があるが、現段階ではこれらの作業に技術者の解釈と判断が必要である。次に、3D 斜面台帳のデータが蓄積された段階で、斜面の変状等の履歴を AI 解析の説明変数として反映させるが、この過程でも現段階では技術者が判断する必要がある。変状の把握と蓄積の過程、AI 解析の説明変数に反映させる過程の自動化は、計測データの解釈と変状履歴の積み重ね、説明変数への反映の積み重ねにより、自動化に必要なアルゴリズムが確立されていくと考えられる。なお、3D 道路台帳を稼働した後の

災害発生・変状等の発生の有無を新たな教師データとして AI モデルを更新することも今後の課題である。

- (8) 広島県における斜面崩壊の多くは、梅雨前線や台風による豪雨を誘因としている。ここでは誘因のリスク評価に雨量指標 R' を用い、 R' と素因である斜面崩壊危険度をくみあわせた道路斜面のリアルタイム危険度評価手法を検討した。最近の道路斜面災害の事例解析から R' が道路斜面の崩壊発生の指標となることを示し、 R' と AI による新総合評価値 E を組み合わせた豪雨時のリアルタイム危険度評価を提案した。

このように、3D 斜面台帳のプラットフォーム上で従来の道路防災点検を高精度化し CCICP によって経年変化を一元管理すること、その結果を AI 判定し、雨量情報を利用したリアルタイム危険度予測結果に活用することは、道路防災点検の高度化・効率化であるとともに、その利用用途を大きく拡大するものであると考えられる。

謝 辞

本研究に用いた道路防災点検の安定度調査表は広島県土木建築局道路整備課より提供いただいたものである。ここに記して深く感謝の意を表します。

参考文献

- 1) 岐阜県: 災害アーカイブ_飛騨川バス転落事故 (昭和 43 年), <https://www.pref.gifu.lg.jp/page/6951.html>, (参照 2022.6.2).
- 2) 一般社団法人全国地質調査業協会連合会: 道路防災点検の手引き (豪雨・豪雪等) [改訂版] — DX 時代に向けたチャレンジ —, 145p. 2022., <https://www.zenchiren.or.jp/geocenter/lec-road/docs/guidance-rain-snow.pdf>, (参照 2022.6.2).
- 3) Besl, P. J. and McKay, H. D.: A method for registration of 3-D shapes, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.14, Issue 2, pp.239-256, 1992.
- 4) Takai, S., Date, H., Kanai, S., Niina, Y., Oda, K. and Ikeda, T.: Accurate registration of MMS point clouds of urban areas using trajectory, ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, II-5/W2, pp.277-282, 2013.
- 5) Ayalew, L. and Yamagishi, H.: The application of GIS-based logistic regression for landslide susceptibility mapping in the Kakuda-Yahiko Mountains, Central Japan, Geomorphology, Vol.65, Issues 1-2, pp.15-31, 2005.
- 6) Phama, B. T., Prakash, I. and Bui, D. T.: Spatial prediction of landslides using a hybrid machine learning approach based on Random Subspace and Classification and Regression Trees, Geomorphology Vol.303, No.15, pp.256-270, 2018.
- 7) Ballabio, C. and Sterlacchini, S.: Support vector

- machines for landslide susceptibility mapping: the Staffora River Basin case study, Italy, *Mathematical Geosciences*, Vol.44, No.1, pp.47-70, 2012.
- 8) Marjanović, M., Kovačević, M., Bajat, B. and Voženilek, V.: Landslide susceptibility assessment using SVM machine learning algorithm. *Engineering Geology*, Vol.123, No.3, pp.225-234, 2011.
 - 9) Goetz, J., Brenning, A., Petschko, H. and Leopold, P.: Evaluating machine learning and statistical prediction techniques for landslide susceptibility modeling. *Computers & Geosciences*, Vol.81, pp.1-11, 2015.
 - 10) Hong, H., Iliia, I., Tsangaratos, P., Chend, W. and Xua, C.: A hybrid fuzzy weight of evidence method in landslide susceptibility analysis on the Wuyuan area, China, *Geomorphology*, Vol.290, pp.1-17, 2017.
 - 11) Tsangaratos, P. and Benardos, A.: Estimating landslide susceptibility through a artificial neural network classifier. *Nat. Hazards*, Vol.74, No.3, pp.1489-1516, 2014.
 - 12) Bui, D. T., Ho, T.-C., Pradhan, B., Pham, B.-T., Nhu, V.-H. and Revhaug, I.: GIS-based modeling of rainfall-induced landslides using data mining-based functional trees classifier with AdaBoost, Bagging, and MultiBoost ensemble frameworks. *Environmental Earth Sciences*, Vol.75, No.14, pp.1-22, 2016.
 - 13) 復建調査設計株式会社: FGEX プラグイン <https://www.fukken.co.jp/pdf/3-10-8.pdf>. (参照 2022.6.2).
 - 14) アジア航測株式会社: Laser Map Viewer <https://www.ajiko.co.jp/products/detail/33>, (参照 2022.6.2).
 - 15) 国土交通省道路局, 2006. (参考資料)点検要領, 「道路における災害危険箇所の再確認について」, <https://www.zenchiren.or.jp/geocenter/lec-road/docs/guideline.pdf>, (参照 2022.6.2).
 - 16) Sebastian Raschka, Vahid Mirjalili 著, 福島真太郎訳, 2018. 第2版 Python 機械学習プログラミング, 株式会社インプレス.
 - 17) 中井真司, 佐々木康, 海堀正博, 森脇武夫: 警戒・避難のための雨量指標の改良(危険雨量指標 R_f の再吟味と R' 提案), 広島大学大学院工学研究科報告, 第53巻, 第1号, pp.53-62, 2004.
 - 18) 中井真司, 海堀正博, 佐々木康, 森脇武夫: 雨量指標 R' による土砂災害発生基準の設定と監視雨量強度 R_R の提案—地域ごとの降雨履歴特性を反映した適用の可能性—, 砂防学会誌, Vol.60, No.6, pp.4-10, 2008.
 - 19) 中井真司: 地域ごとの降雨特性に着目した土砂移動現象の発生予測に関する研究, 広島大学博士論文, 172p., 2009.
 - 20) 広島県: 広島県防災 web(観測情報_雨量実況一覧), <http://www.bousai.pref.hiroshima.jp/?p=observation%2Frainfal>, (参照 2022.2.10).
 - 21) 広島県災害対策本部: 令和3年7月及び8月の大雨による被災状況について, 21p., 2021, <https://www.pref.hiroshima.lg.jp/uploaded/attachment/452953.pdf>, (参照 2022.2.10).

(2022年6月13日 受付)