

グラフニューラルネットに基づく LP 点群データを用いた 危険斜面スクリーニング手法の高度化

石川 大智¹・貝戸 清之²

¹学生会員 大阪大学大学院工学研究科 地球総合工学専攻 (〒 565-0871 吹田市山田丘 2-1)
E-mail: t.ishikawa@civil.eng.osaka-u.ac.jp

²正会員 大阪大学准教授 大学院工学研究科 地球総合工学専攻 (〒 565-0871 吹田市山田丘 2-1)
E-mail: kaito@ga.eng.osaka-u.ac.jp

近年、局所的かつ突発的な集中豪雨の発生頻度の増加に伴って、斜面崩壊発生リスクが増大しており、斜面崩壊に対する防災対策のより一層の強化が求められている。斜面崩壊に対する適切なソフト対策を講じるためには、斜面に対する危険度予測が重要である。斜面に対する危険度予測に関する研究は盛んに行われているが、明確な手法が確立しているとはいえない。近年、i-Construction の推進に伴うレーザー計測技術の発展により、点群データの収集が容易化している。特に、航空レーザー測量による LP 点群データの活用が試みられている。しかしながら、点群データを活用した斜面に対する危険度予測に関する研究は十分な蓄積があるとはいえない。そこで本研究では、グラフニューラルネットを用いることにより、点群データの隣接関係を考慮した危険斜面スクリーニング手法を開発した。また、実際に溪流において取得された LP 点群データを用いて提案手法の実証分析を行った。

Key Words : *slope collapse, point cloud, aerial laser, graph neural network, risk*

1. はじめに

近年の局所的かつ突発的な豪雨や線状降水帯の発生といった異常的な集中豪雨の増加に伴って、斜面崩壊の発生リスクが高まっている。斜面崩壊に対する防災対策としては、ハード対策とソフト対策があげられるが、日本は国土の約 7 割が山地で構成されていることから、斜面に対するハード対策には限界がある。斜面崩壊に対する防災対策のより一層の強化のためには、ハード対策のみでなく、ソフト対策を含めた両面での対策の高度化が急務である。社会基盤施設の中でも、高速道路をはじめとしたネットワーク機能を有する構造物沿いの斜面においては、ひとたび斜面崩壊が発生した場合、利用者への安全性や使用性に与える影響が甚大であるため、防災対策の高度化がより一層要求されている。斜面崩壊に対するソフト対策の一つには、各地の斜面における危険度予測（以下、危険斜面スクリーニング）が考えられ、危険斜面スクリーニングに関する研究は古くから盛んに行われている^{1)–6)}。

このような中で、近年 i-Construction の推進に伴うレーザー計測技術の発展により、座標情報や色情報をもつ点の集合である点群データの収集が容易化している。とりわけ斜面においては、航空機を用いて取得される点群データである航空 LP (Laser Profiler) データ

の収集が広くなされており、様々な分野においてその活用が試みられている。しかしながら、斜面における危険度予測に関する航空 LP データの活用は十分な研究蓄積があるとはいえない。

以上の問題意識のもと、本研究では危険斜面スクリーニング手法の高度化を目的として、グラフニューラルネットに基づく航空 LP 点群データを用いたスクリーニング手法の方法論を構築する。具体的には、グラフニューラルネットワークの 1 つであるグラフ畳み込みニューラルネットワークを用いて、斜面における各点間の空間的相関関係を考慮した危険斜面抽出手法を構築する。以下、2. で本研究の基本的な考え方を説明する。3. では、グラフニューラルネットワークに関する基本的な前提知識を説明し、4. でグラフニューラルネットワークに基づく危険斜面スクリーニング手法を構築する。5. では、実際の高速道路路線に隣接する斜面において計測された航空 LP 点群データを用いて提案手法の実証分析を行う。

2. 本研究の基本的な考え方

(1) 危険斜面スクリーニング手法の必要性

近年、短時間での局所的かつ突発的な豪雨の頻発や線状降水帯の発生といった異常的な集中豪雨の増加が

問題視されている⁷⁾。これにより、台風による災害被害の少なかった地域を含め、毎年のように日本各地で大規模な災害が発生している。変容する斜面災害リスクに適応した対策を行うためには、社会基盤施設を維持管理する各主体においてハード対策・ソフト対策を含めた両面での対策の高度化が必要である。

とりわけ、我が国の高速道路においては、供用延長の約 6 割が土工区間となっており⁸⁾、降雨に基づく斜面崩壊により安全性や使用性に与える影響が甚大である。危険斜面のスクリーニングは様々な主体によって従来より行われているが、現状では地質図等を用いた机上調査に基づき危険斜面の抽出が行われていることが多い。しかしながら、調査を必要とする斜面数が非常に多いのに対し、専門技術者の数が限られている上、地質図等を用いた抽出では様々な暗黙知が利用されることが多く、技術者への依存性が高い。以上のような背景から、客観的かつ効率的な危険斜面のスクリーニング手法の構築は高速道路をはじめとした多様な社会基盤施設の管理におけるソフト対策の高度化という点で重要であるといえる。

(2) 既往研究のレビュー

危険斜面スクリーニングは古くから研究がなされており、斜面崩壊の発生要因である斜面の素因（地形や地質の情報）や誘因（降雨や地下水の情報）などを考慮した手法が数多く提案されている。また手法としては、主に力学的手法によるものや統計学的手法・機械学習手法によるもの等があげられる。

力学的手法による危険斜面スクリーニング手法には、沖村等¹⁾や鳥居等²⁾があげられる。これらは主に表層崩壊の安定解析を対象としており、斜面を数値地形モデルによって表し、各地形の集水モデルを作成する。その上で各地形のメッシュ分割を行い、メッシュごとに無限長斜面安定解析を用いて当該地形に降雨を与えたときの安全率を算出する手法である。これにより、安全率が 1 をこえるまでの降雨継続時間などに基づき、危険斜面をスクリーニングすることが可能である。また、鳥居等²⁾は、沖村等の手法において降雨の浸透過程を考慮するための地下水位算定モデルを提案している。

統計学的手法・機械学習手法による危険斜面スクリーニング手法には、数量化理論Ⅱ類や自己組織化マップ (self-organizing map, SOM) を用いた手法等があり、これらを用いた研究として橋本等³⁾や日外等⁴⁾があげられる。自己組織化マップは、ニューラルネットワークの一種であり、データから学習を行うことで、類似した特徴をもつデータは近くに、そうでないデータは離れた位置に配置し人間が認識可能な 2 次元平面上にデータを可視化する教師なし学習手法である。また、数量

化理論Ⅱ類は質的データをダミー変数に変換したものを説明変数として、質的データである目的変数を予測する多変量解析の一手法である。橋本等³⁾は、北海道地域における岩盤斜面に対し数量化理論Ⅱ類を用いて斜面安定度に関する因子の抽出を行うとともに、レンジや偏相関係数を算出することで、斜面安定度への影響度を算出した。日外等⁴⁾は、数量化理論Ⅱ類のみを用いた手法では、収集した点検データが適切なものであるか（予測の妨げになる精度の悪いデータが含まれていないか等）に関する検討が不十分であることを指摘し、自己組織化マップを用いて 2 次元平面上にデータを可視化することで、不適切なデータを除去する前処理を行っている。類似した目的の研究として、荒木等⁵⁾や伊藤等⁶⁾はニューラルネットワーク等の機械学習手法を用いて、斜面崩壊の発生予測を行っている。

本研究では、近年計測が容易化している点群データを活用するとともに、素因情報のみに着目した危険斜面スクリーニング手法を構築する。これは、素因の時間的変化が小さいのに対して、誘因は時間的変化が大きいため、長期的な時間スケールで考えた場合には豪雨の発生時刻や場所を正確に予測することが困難であるためである。危険斜面を抽出した後、適切な防災対策を講じていくためには、ある程度長期的な時間スケールで豪雨時の崩壊危険性が高い斜面を抽出しておくことが重要であると考えられる。また、近年の局所的かつ突発的な豪雨の発生や線状降水帯の発生などは、過去の降雨履歴から予測することが困難なものも含まれており、そのような突発的な集中豪雨に対応するためにも、素因情報に重点を置くことが重要であるといえる。また、点群データを活用することにより、テーブルデータに基づく手法では考慮されていないことが多い空間的相関関係を考慮したスクリーニング手法の高度化を検討する。具体的には、点群データを距離に基づいたグラフとして表現したうえで、グラフにおける畳み込みを行うことにより周辺の点との関係を考慮した斜面崩壊予測モデルを構築し、予測における説明指標を算出することによって危険斜面スクリーニング手法を構築する。

(3) 航空 LP 点群データ

航空レーザ測量とは、航空機から発射したレーザにより、3 次元形状を高密度かつ高精度に取得する測量技術である。航空機から測定対象物に照射したレーザの反射光が返ってくるまでの時間を計測することで、対象物の形状を計測する。航空機には航空機の位置を計測する GNSS (global navigation satellite systems) アンテナや航空機の姿勢と加速度を計測する慣性計測装置 (inertial measurement unit, IMU) が備えられてお

り、レーザ照射時の自己位置や姿勢を計測しながら点群データの取得を行う⁹⁾。航空レーザ測量の利点として、地形形状を含めた面的な把握が可能であることや反射強度により地物が判定可能であることなどがあげられる。

レーザパルスは地表面だけでなく、地物でも反射されてしまうため、航空レーザ測量で取得されたデータには建物や樹木の高さが記録された点も存在している。一般に、建物や樹木を含む地上の表面形状を表したデジタルデータを DSM (Digital Surface Model)、建物や樹木を除いた地表面形状を表したデジタルデータを DTM (Digital Terrain Model) や DEM (Digital Elevation Model) と呼んで区別する。すなわち、航空レーザ測量で取得された生の点群データは DSM データとなっているため、これにフィルタリング処理を行うことで DEM データを取得する必要がある。本研究でも、このような後処理を行った DEM データを用いるものとする。

また、獲得された DEM データは非常に多数の点で構成されていることから、計算コストを抑える工夫が必要である。一般には、得られた DEM データにおいて、各点間を接続することで作成した TIN (不規則三角形網) に対し、数 m 方眼のメッシュをかぶせ中心点の高さを補完する。これにより、各メッシュ内での代表点を作成してその他の点を除くことにより計算コストを抑制する。

3. グラフニューラルネットワークの基礎

(1) Graph Convolutional Network

グラフニューラルネットワークの代表的な手法として、Graph Convolutional Network (GCN)¹⁰⁾ について述べる。GCN はグラフ $G = (V, E)$ において、隣接行列 $A = (a_{ij}) \in \{0, 1\}^{n \times n}$ と特徴行列 $X = [x_1, \dots, x_n]^T \in \mathbb{R}^{n \times d}$ を入力とし、重みパラメータ W を持つ非線形関数と考えることができる。ここで、隣接行列 A の要素 a_{ij} は、ノード i とノード j がエッジで接続されている場合に 1 を、そうでない場合に 0 をとるものとする。また、 $x_i \in \mathbb{R}^d$ はノード i の有する特徴量を表す。GCN におけるグラフ畳み込みはスペクトルグラフ理論を用いて導出されている。一般的なグラフニューラルネットワークでは、第 l 層における特徴行列 $H^{(l)}$ に対して、

$$H^{(l+1)} = \sigma(AH^{(l)}W^{(l)}) \quad (1)$$

のように変換を行う。ここで、 $\sigma(\cdot)$ は活性化関数であり、 $W^{(l)}$ は第 l 層における重み行列である。また、 $H^{(0)} = X$ とする。このような変換では、自身のノードの特徴ベクトルが抽出されないことや行列積によって特徴ベクトルのスケールが変化してしまう問題点がある。そこで、Kipf 等¹⁰⁾ は A に単位行列を加算した $\tilde{A} = A + I$

を隣接行列として用いるとともに、これに対応した次数行列 $\tilde{D} = \text{diag}(\sum_k \tilde{a}_{ik})$ により正規化した $\tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}$ を用いて、

$$H^{(l+1)} = \sigma(\tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}H^{(l)}W^{(l)}) \quad (2)$$

のようにグラフにおける畳み込みを定義している。これにより、グラフ上のノード i における畳み込みの式を書き下せば、

$$h_i^{(l+1)} = \sigma \left(\sum_{j \in \mathcal{N}_i \cup \{i\}} \frac{1}{\sqrt{d_{ii}d_{jj}}} W^{(l)} h_j^{(l)} \right) \quad (3)$$

と表される。ここで、 \mathcal{N}_i はノード i の隣接ノード集合であり、 d_{ii}, d_{jj} はそれぞれ次数行列 $D = \text{diag}(\sum_k a_{ik})$ における (i, i) 、 (j, j) 成分である。 $\sqrt{d_{ii}d_{jj}}$ で割ることにより、ノードごとのエッジ数が異なる効果をなくすることができる。式 (3) は、自身のノードと隣接ノードの情報を集約した後、得られた情報を用いて自身のノードを更新する変換と解釈できる。GCN は Weisfeiler-Lehman のアルゴリズムにパラメータをもたせ、微分可能性を付加した特殊なケースであるとも指摘されている。以上のようなグラフニューラルネットワークを用いることで、近傍データの特徴を加味した学習が可能である。

(2) GNNExplainer

GNNExplainer¹¹⁾ はグラフニューラルネットワークに対する Explainable AI 技術 (以下、XAI 技術) の 1 つである。いま、ノード分類問題の枠組みを考え、あるノード i に対し、ノード i を表現するベクトル (ノード i の埋め込み) の計算に用いられるグラフを $G_c(i)$ とする。GNNExplainer では、ノード i のラベルの予測への重要度が高いと考えられるノード集合を、 G_c を剪定した部分グラフ G_s を特定することにより求める。この際、グラフニューラルネットワークの予測値と考える部分グラフに限定した場合のグラフニューラルネットワークの予測値との相互情報量を最大化するように部分グラフを選出する。すなわち、 G_s に付随する隣接行列を A_s 、特徴行列を X_s とするとき、

$$\begin{aligned} G_s &= \arg \max_{G_s} MI(Y, (G_s, X_s)) \\ &= \arg \max_{G_s} [H(Y) - H(Y|G = G_s, X = X_s)] \quad (4) \end{aligned}$$

によって部分グラフを選出する。 MI は相互情報量、 H はエントロピーを表す。ここで、訓練後のモデルにおいて第一項は不変なので、式 (4) は $H(Y|G = G_s, X = X_s) = -\mathbb{E}_{Y|G_s, X_s} [\log P(Y|G = G_s, X = X_s)]$ の最小化問題に帰着される。このような最小化問題は、 G_c が増加するほど部分グラフ G_s の数が指数的に増加するため困難となることが多い。そこで、部分グラフ G_s をある確率分布 \mathcal{G} に従う確率変数として考えれば、目的関数は $\mathbb{E}_{G_s \sim \mathcal{G}} [H(Y|G = G_s, X = X_s)]$ と変形され

表-1 2 値分類における混同行列

		正解値	
		正例 (Positive)	負例 (Negative)
予測結果	正例 (Positive)	TP	FP
	負例 (Negative)	FN	TN

る. さらに, 凸性を仮定すれば, イェンセンの不等式より, $H(Y|G = \mathbb{E}_G[G_s], X = X_s)$ によって上から抑えられる. また, \mathbb{E}_G に平均場近似, すなわち $P_G(G_s) = \prod_{(j,k) \in G_c} A_s(j,k)$ を用いれば, 期待値部分を A_s に置き換えることができる.

GNNExplainer では, 部分グラフの隣接行列 A_s を

$$A_s = A_c \odot \sigma(M) \quad (5)$$

のように算出する. ここで, $M \in \mathbb{R}^{n \times n}$ はマスク行列, $\sigma(\cdot)$ はシグモイド関数である. 実際には, 勾配降下法により最適化が可能であるように, 損失関数

$$L = - \sum_{c=1}^C \delta_{yc} \log P(y|G = A_c \odot \sigma(M), X = X_s) \quad (6)$$

を最小化することにより最適なマスク行列を獲得する. ここで, δ_{yc} は $y = c$ の場合のみ 1, その他の場合は 0 とする. これにより, 得られたマスク行列 M から, 式 (5) により A_s を算出しある閾値を超えた要素を 1, そうでない要素を 0 とすることによって部分グラフの隣接行列を推定することが可能である.

以上までの議論とまったく同様に, GNNExplainer では予測に寄与した特徴量の選出を行うことが可能である. マスク行列 F を G_s に付随する特徴行列 X_s に作用させることで, 部分特徴量 X_s^F を獲得することを考える. ここで, $F \in \{0, 1\}^d$ とする. これにより, 最終的な最適化の式は $\max_{G_s, F} [H(Y) - H(Y|G = G_s, X = X_s^F)]$ となる.

(3) 2 値分類における評価指標

2 値分類においては, 正しい予測の数と誤った予測の数を定量的に表すために表-1 に示す混同行列を用いる. ここで, TP, TN, FP, FN はそれぞれ True Positive, True Negative, False Positive, False Negative の略であり, ある入力に対しモデルが Positive か Negative のどちらか一方を出力するものとしたとき, それが正解であるか誤りであるかを想定して定められている. また, 混同行列に基づいた評価指標として precision, recall とその調和平均である f1-score と呼ばれる指標を用いる




図-1 点群データのグラフ化

ことが多い. precision, recall, f1-score はそれぞれ

$$\text{precision} = \frac{TP}{TP + FP} \quad (7)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (8)$$

$$\text{f1-score} = \frac{2 \cdot \text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad (9)$$

と表される. ここで, precision, recall に関して, 分類の結果として得られる正例である確率に対し閾値を定め予測結果を算出する場合, 閾値を変化させるにつれ, 一方が減少し他方が増加するようなトレードオフの関係になっている. そのため, これらを統合的に評価した値として, 調和平均をとった f1-score が用いられる.

4. グラフニューラルネットに基づく危険斜面スクリーニング手法

(1) 点群データのグラフ化

本研究では, 斜面において観測された航空 LP 点群データをグラフとして取り扱うことを考える. グラフとして扱うことにより, 3.(1) で述べたようなグラフにおける畳み込みを用いることが可能となるため, グラフ上の近傍データの特徴を加味した学習が可能となる. 以下, 点群データからグラフを構成する方法を述べる.

ある斜面の点群 P を構成する点を $p_i \in \mathbb{R}^N (i = 1, \dots, n)$ とする. ここで, N は点群内の各点をもつ情報 (座標情報, 色情報, 反射強度など) の次元であり, 座標情報のみ用いる場合は $N = 3$ である. 斜面の点群からグラフを定義するには, ノード集合 V とエッジ集合 E を定義する必要がある. 本研究では, 図-1 に示すように, 斜面を構成する各点 p_i をノード (すなわち, $V = P$) とし, エッジについては各点 p_i に対する ϵ -近傍 $B(p_i; \epsilon) = \{p \in \mathbb{R}^3 \mid \|p - p_i\| < \epsilon\}$ を考え, その中に含まれる点をエッジで接続するものとする. なお, このようなグラフの構成において, 各点の ϵ -近傍を探索する操作は, 計算幾何学の分野で Fixed-radius near neighbors search problem としてよく知られており, 計算量 $O(cn)$ の効率的なアルゴリズム¹²⁾ が提案されている¹³⁾. ここで, c は ϵ -近傍内の最大の点数である.

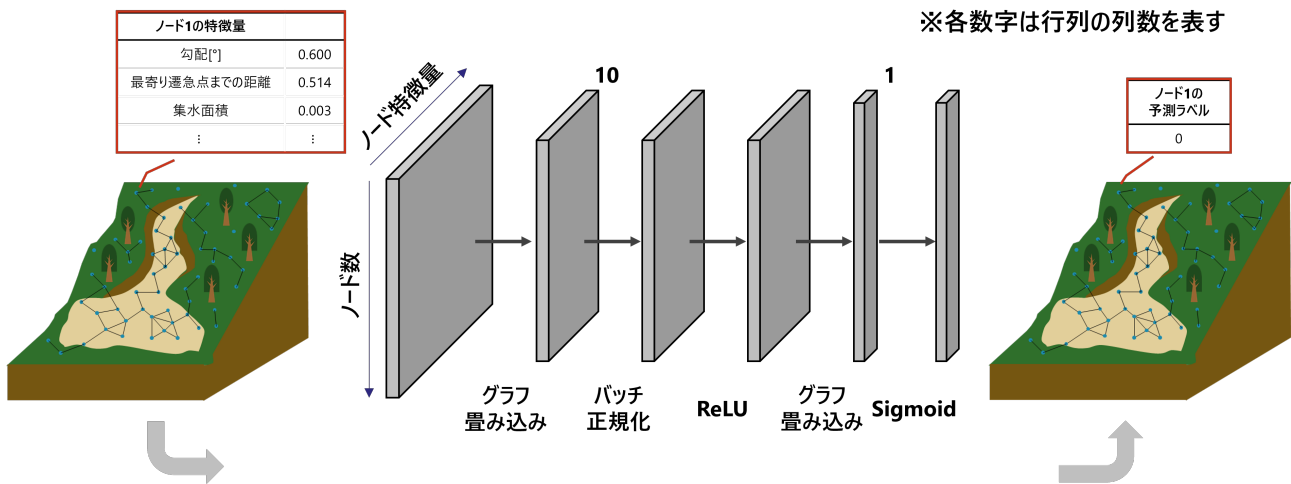


図-2 本研究で用いたモデル

以上のような手続きによって、各点の座標に依存したグラフを定義することにより、各点間の空間的相関関係をグラフにおける畳み込みにより考慮する。なお、本研究では以上のように近傍に基づいて点群データのグラフ化を行うが、その他にも様々なグラフ化の研究がなされている^{14),15)}。

(2) 危険斜面スクリーニングの考え方

本研究では、危険斜面スクリーニング手法として特徴量の重要度に基づく手法を考える。2.(2)で述べたように、危険斜面のスクリーニングには数量化理論Ⅱ類等を用いた研究がなされており、そこでは高精度が達成された斜面崩壊予測モデルに対してレンジや偏相関係数といった説明指標を算出することにより、斜面崩壊への影響度が推定されていた。本研究は以上の考え方を拡張し、点群データにおいて斜面崩壊の有無を予測する分類モデルを作成し、それに基づく説明指標の算出を行うことにより、斜面崩壊への影響度を推定する手法を提案する。具体的には、斜面崩壊の有無を予測する分類モデルとして、Graph Convolutional Networkに基づくニューラルネットワークを採用する。図-2に、本研究で用いたモデルの構造を示す。また、説明指標の算出においては、3.(2)で述べたGNNEExplainerを用いる。GNNEExplainerを用いることにより、予測に寄与したノードや特徴量を選出することができ、それにより獲得された情報に基づいた危険斜面スクリーニングが可能となる。

5. 実証分析

(1) データの概要

本研究で提案した手法の有用性を検証するため、実際の斜面で計測された航空LP点群データによる実証

分析を行う。斜面崩壊には表層崩壊、地すべり、崖崩れ、土石流など様々な種類があり、誘因や素因などの違いを含めると現象自体が複雑かつ多様なものである。本研究で対象とするデータは、平成30年の7月豪雨によって土石流が発生した山陽道・呉道沿いの81箇所の溪流における航空LP点群データである。これらはともに花崗岩の風化生成物である真砂土により構成された地域である。真砂土は中国・近畿地方を中心として広く分布しており、透水性が非常によく、飽和時にサクシオンに基づく見かけの粘着力が消失するという特性をもっていることから、真砂土地帯では豪雨時に斜面崩壊が発生しやすい¹⁶⁾。

はじめに、獲得されたLP点群データの前処理を行う。まず、地形図を用いて土石流が発生し移動した範囲を土砂移動範囲として設定する。また、区分された土砂移動範囲をさらに図-3のように、崩壊地、流下区間、堆積区間、流域の4つに再区分する。さらに、再区分した上で、2.(3)で述べた手法を用いて、1mメッシュごとの点群データを作成する。本研究では、以上のように再区分したデータのうち、流下区間、堆積区間、流域を非崩壊点として扱うこととし、崩壊・非崩壊の2値分類問題として問題を定式化する。

各ノードがもつ特徴量としては、勾配、最寄り遷急点までの距離、集水面積、標高値(災害前)、縦断曲率、横断曲率を採用した。このうち、縦断曲率・横断曲率については窓領域を3, 5, 11, 31, 51[m]と変更した場合の5種類の値を用いた。これらの算出に当たっては、GISソフトウェアであるArcGISを用いた。また、各特徴量に関して、最大値を1、最小値を0とするように基準化を行った。

81溪流分の航空LP点群データに対して、訓練データ、検証データ、テストデータの比率を8:1:1となるよ




図-3 土石流が発生した溪流の区分

うに分割した。また、各点群データにおいて、崩壊点是非崩壊点に比べはるかに多いことが確認された。このような不均衡データに対しては、一般には損失関数を各クラスのサンプル数に応じて重みづけして調整することやオーバーサンプリング、アンダーサンプリングなどが行われることが多い。オーバーサンプリングはミニバッチを構成するサンプリングにおいて、マイナーなクラスのサンプルを復元抽出して選び出す手法であり、アンダーサンプリングはメジャーなクラスのサンプルを間引いて選び出す手法である。本研究では、各溪流に対し、あらかじめ崩壊点数（メジャーなクラスのサンプル数）にあわせて非崩壊点数（マイナーなクラスのサンプル数）をアンダーサンプリングすることにより対処するものとした。これは、本研究で扱う点群データでは相当に密な点で構成されているデータであるため、あらかじめ非崩壊の点数をランダムにサンプリングしても大きな問題は生じないと考えたためである。

学習の繰り返し回数であるエポック数は 20、バッチサイズは 1 とした。エポック数は、学習時の損失関数の推移を見つつ、実験的に求めた。損失関数には binary cross entropy を用いた。重みの最適化手法には学習率の適応的な調整と急激な振動への抑制を考慮した勾配降下法である Adam を用いた。Adam におけるハイパーパラメータの値は、Kingma and Ba¹⁷⁾ の推奨値である $\beta_1 = 0.9, \beta_2 = 0.999, \varepsilon = 10^{-8}, \eta = 0.001$ を用いた。

6. おわりに

本研究では、斜面を対象とする点群データを用いた危険斜面のスクリーニング手法を提案した。具体的には、グラフに対する深層学習モデルであるグラフニューラルネットワークを用いて、斜面の点群における崩壊予測モデルを作成し、XAI 技術を用いて予測に重要なノード・特徴量を算出する手法を提案した。

一方で、今後の課題として、算出されたスクリーニングの結果を現行のハザードマップ等と比較すること

により、検証を行うことがあげられる。また、真砂土以外の地質をもつ斜面や土石流以外の斜面崩壊が生じたデータに対し手法を適用することにより、得られる結果の差異を分析する必要があるといえる。

なお、本研究で提案した手法に基づいて、実際の斜面で計測された航空 LP 点群データにおける実証分析を行っており、その結果及び考察については研究発表会にて提示する。

謝辞：本研究を遂行するに際して、西日本高速道路株式会社から斜面における航空 LP 点群データを提供して頂いた。ここに記して感謝の意を表する。

参考文献

- 1) 沖村孝, 市川龍平: 数値地形モデルを用いた表層崩壊危険度の予測法, 土木学会論文集, Vol.358, No. III-3, pp.69-75, 1985. [Okimura, T. and Ichikawa, R.: A delineation method for probable mountain slope failures by a digital land form model, *Journal of JSCE*, Vol.358, No. III-3, pp.69-75, 1985.]
- 2) 鳥居宣之, 大西剛史: 斜面崩壊危険度評価のための表土層内の降雨浸透過程を簡略化した地下水位算定モデル, 土木学会論文集 C, Vol.67, No.4, pp.441-452, 2011. [Torii, N. and Onishi, T.: A ground water level estimation model with simplified rainfall infiltration and seepage process in surface soil layer, *Journal of JSCE C*, Vol.67, No.4, pp.441-452, 2011.]
- 3) 橋本祥司, 菊地宏吉, 水戸義忠: 数量化理論 II 類を用いた層雲峡地域の岩盤評価, 北海道開発土木研究所月報, No.588, pp.46-52, 2002. [Hashimoto, S., Kikuchi, K. and Mito, Y.: The rock evaluation analyzed by quantification theory II at Soukkyo Gorge area, *Monthly report of PWRI*, No.588, pp.46-52, 2002.]
- 4) 日外勝仁, 齋藤敏明, 伊東彦彦, 橋本祥司: 数量化理論 II 類および自己組織化マップによる岩盤斜面危険度評価法に関する研究, 土木学会論文集, No.771/III-68, pp.51-60, 2004. [Agi, K., Saito, T., Ito, Y. and Hashimoto, S.: A study on the stability evaluation method of rock slope failure by quantification and self-organizing maps, *Journal of JSCE*, No.771/III-68, pp.51-60, 2004.]
- 5) 荒木義則, 古川浩平, 松井範明, 大木戸孝也, 石川芳治, 水山高久: ニューラルネットワークを用いた土石流危険渓流における土砂崩壊のリアルタイム発生予測に関する研究, 土木学会論文集, No.581/VI-37, pp.107-121, 1997. [Araki, Y., Furukawa, K., Matsui, N., Ookido, T., Ishikawa, Y. and Mizuyama, T.: A study on the real-time judgement model of sediment stability of neural network for collapse and debris-flow in hazard torrent, *Journal of JSCE*, No.581/VI-37, pp.107-121, 1997.]
- 6) 伊藤真一, 小田和広, 小泉圭吾, 酒匂一成: 機械学習を用いた 1km メッシュごとの斜面崩壊に対する危険度評価, 地盤工学会誌 土と基礎 66(9), pp.8-11, 2018. [Ito, S., Oda, K., Koizumi, K. and Sakou, K.: Risk assessment for slope failures in 1 km mesh unit based on machine learning, *Geotechnical engineering magazine*, pp.8-11, 2018.]
- 7) 国土交通省砂防部: 令和 3 年度土砂災害, 2022. [MLIT: Sediment-related disasters in 2021, 2022.]
- 8) 国土交通省: これからの道路土工構造物等マネジメント, 2017. [MLIT: Future earthwork structure management, 2017.]
- 9) 国土交通省国土地理院: 航空レーザ測量入門, 2004.

- [Geospatial Information Authority of Japan : Introduction to aerial laser surveying, 2004.]
- 10) Kipf, T. N. and Welling, M. : Semi-supervised classification with graph convolutional networks, *ICML*, 2017.
 - 11) Ying, R., Bourgeois, D., You, J., Zitnik, M. and Leskovec, J. : GNNExplainer: Generating explanations for graph neural networks, *arXiv:1903.03894*, 2019.
 - 12) Bentley, J. L., Stanat, D. F. and Williams, E. H : The complexity of finding fixed-radius near neighbors, *Information Processing Letters*, Vol.6, No.6, pp.209-212, 1977.
 - 13) Shi, W. and Rajkumar, R. : Point-GNN: Graph Neural Network for 3D Object Detection in a Point Cloud, *arXiv:2003.0125*, 2020.
 - 14) Ma, Z., Mei, G., Prezioso, E., Zhang, Z. and Xu, N. : A deep learning approach using graph convolutional networks for slope deformation prediction based on time-series displacement data, *Neural Computing and Applications*, pp.14441-14457, 2021.
 - 15) Zhou, F., Li, R., Trajcevski, G. and Zhang, K. : Land Deformation Prediction via Slope-Aware Graph Neural Networks, *AAAI-21*, pp.15033-15040, 2020.
 - 16) 八木則男, 矢田部龍一 : 不攪乱まさ土のせん断特性と微視的考察, 土木学会論文集, Vol.364, No. III-4, pp.133-141, 1985. [Yagi, N. and Yatabe, R. : A microscopic consideration on shearing characteristic of decomposed granite soil, *Journal of JSCE*, Vol.364, No. III-4, pp.133-141, 1985.]
 - 17) Kingma, D. P. and Ba, J. : Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*, 2014.