

ディープラーニングによる全国を対象とした 土砂災害危険度判定方法

THE RISK ASSESSMENT METHOD OF SEDIMENT-RELATED DISASTERS
USING DEEP LEARNING AGAINST ALL THE DOMESTIC-WIDE REGION

野呂 智之¹・神山 嬢子²・鈴木 大和¹・谷田 佑太³

海原 荘一³・只熊 典子³・藤原 康正³・佐藤 丈晴⁴

Tomoyuki NORO, Joko KAMIYAMA, Yamato SUZUKI, Yuta TANIDA

Soichi KAIHARA, Noriko TADAKUMA, Yasumasa FUJIWARA and Takeharu SATO

¹国土交通省国土技術政策総合研究所 (〒305-0804 茨城県つくば市旭1番地)

²国立研究開発法人土木研究所 (〒305-8516 茨城県つくば市南原1-6)

³(株)エイト日本技術開発 (〒700-8617 岡山県岡山市北区津島京町3丁目1-21)

⁴岡山理科大学 (〒700-0005 岡山県岡山市北区理大町1-1)

Key Words: *debris flow, landslide, warning and evacuation, deep learning*

1. はじめに

土砂災害に対する危険度は、発生降雨データ及び非発生降雨データに基づいて、機械学習の1種であるRBFネットワーク^{1),2)}により、短期雨量指標である時間雨量と長期雨量指標である土壌雨量指数の2軸により設定された発生限界雨量線による判定が行われ、土砂災害警戒情報として運用されている。

土砂災害警戒情報は3次メッシュ単位で設定されており、地形や地質による災害の発生しやすさは各メッシュの経験降雨の大小でCLの大きさが決まるといった具合に、素因のデータはあくまで間接的に反映されていることが課題として挙げられる。その一方で、日本全国の地理情報が整備されており、日本全国の素因データを活用できる環境が整いつつある。

近年、画像解析等でディープラーニングが顕著な成果³⁾を上げており、今までもニューラルネットワークによる土砂災害に対する危険度判定方法⁴⁾も提案されているが、機械学習の精度が向上しており、

それを活用した危険度判定方法が有利となる可能性もある。

そこで、本研究では日本全国の3次メッシュを1つのモデルで評価可能、かつ、誘因や素因を考慮したディープラーニングによる土砂災害危険度評価方法について基礎的な研究を行った。

2. ディープラーニングによる土砂災害危険度判定方法の概要

(1) ディープラーニングによる土砂災害危険度判定

a) ニューラルネットワークの概要

ニューラルネットワークとは、人間の神経細胞(ニューロン)の仕組みを模したシステムの総称である。図-1に示すように、ニューラルネットワークには「入力層」、「隠れ層」、「出力層」と呼ばれる層がある⁴⁾。これらの層は、入力層⇒隠れ層⇒出力層の順番に並び、隠れ層は複数の層を備えることを可能にし、各層は複数個の「ノード」を配置する。また、ある層と次の層の間のノード同士は「エッジ」で結ばれ、

各エッジは、「重み」と呼ばれる値を持っている。これらの重みは教師データと呼ばれる入力データを基に最適化される。つまりモデルの予測精度は教師データによって影響を受けることとなる。

b) ディープラーニングの概要

ディープラーニングとは、階層の深いニューラルネットワークを用いたアルゴリズムの総称である⁴⁾。ニューラルネットワークの隠れ層を多層にして用いることで、データに含まれる特徴を段階的により深く学習することが可能になる。この構造と学習の手法がディープラーニングの特長であり、これにより今までのニューラルネットワークよりもディープラーニングのモデルの方が高精度で評価することが可能になったとされている。

c) 本研究における危険度評価モデルの概要

本研究では、日本全国の過去の降雨イベント毎に3次メッシュ単位の誘因・素因データ及び発生データ・非発生データにより学習データを作成し、それを基にディープラーニングにより全国の3次メッシュを判定する1つの危険度評価モデルを構築するこ

ととした。ディープラーニングには教師ありと教師なしモデルがあるが、土砂災害の発生・非発生データ等を教師データとできるため、本研究では精度の高い教師ありモデル³⁾を採用することとした。

このモデルは日本全国の3次メッシュの素因データや実況及び予測の誘因データを入力し、出力値であるメッシュ内の災害発生数により土砂災害の発生危険度を評価するものである。

なお、ここでいう発生・非発生とは、降り始めから24時間無降雨により区切られる一連降雨で土砂災害が発生した3次メッシュを1つの発生データ、土砂災害が発生していないものを非発生データとしている。

d) ディープラーニングの問題点

ディープラーニングの問題点として、教師データが少ないと、精度が向上しないことが挙げられる。本研究の対象は土砂災害であり、非発生データ数と比較して発生データ数が極端に少ない。また、識別結果の調整が難しいことが挙げられ、教師データの作成方法を工夫する必要がある。

e) 使用したソフトウェア

本研究ではオープンソフトウェア「H₂O」⁵⁾を使用した。H₂Oはインメモリプラットフォームで動作可能な機械学習フレームワークであり、オープンソースかつ商用可能なソフトである。

その特徴としてはWeb上のインターフェースから解析が可能で、ノンコーディングで動作確認ができる。本研究では中間層は3層、繰り返し計算回数は10回、活性化関数はRectifierWithDropout³⁾を使用した。

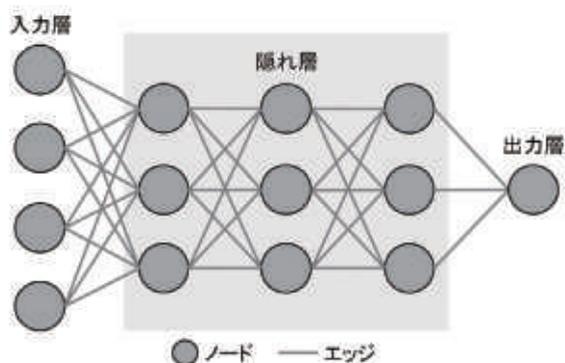


図-1 ニューラルネットワーク・ディープラーニングのイメージ

表-1 全17要因とそのデータ内容の概要

要因	概要	カテゴリ分類	
素因	地質	20万分の1日本シームレス地質図を使用し、8カテゴリに分類した。	○
	植生	5万分の1植生調査図を使用し、5カテゴリに分類した。	○
	土壌	20万分の1土壌図を使用し、11カテゴリに分類した。	○
	地形（谷密度）	50mメッシュより谷密度を求めた。	
	地形（接峰面差）	5次メッシュの標高値より接峰面差を求めた。	
	地形（傾斜方向）	5次メッシュの標高値より最大傾斜方向を求め、8カテゴリに分類した。	○
	地形（傾斜角度）	5次メッシュの標高値より最大傾斜角度を求めた。	
平均年間降水量	過去30年間の観測値から3次メッシュごとの平年値を推定・算出したデータを使用した。		
誘因	解析雨量（1h・24h・72h）	30分ごとに降水量分布を1km四方で解析したデータを使用し、1h・24h・72hの解析雨量を求めた。	
	超過確率率（1h・24h・72h）	1h・24h・72hの解析雨量の最大値に対する超過確率率を求めた。	
	降雨パターン	解析雨量（一連降雨）を3等分割でカテゴリ分類し、前方・中央・後方の中で最大雨量となるカテゴリを選定した。	○
	土壌雨量指数	5kmメッシュ単位の土壌雨量指数データを使用し、土壌雨量指数の最大値を求めた。	
	半減期の長い実効雨量	解析雨量を使用し、半減期1ヶ月（720h）の実効雨量の最大値を求めた。	

(2) 本研究で用いたデータ

a) 教師データの内容

表-1 に本研究のディープラーニングを用いた危険度評価モデルの構築における教師データの入力条件として用いた全 17 要因とその概要を示す。これらは土砂災害の発生に関連していると考えられる地形・地質等の素因と様々な降雨指標のうち、日本全国で統一したデータが取得または作成可能なもので構成した。

教師データについては可能な限りカテゴリ分類せず、生データを使用した。地質、植生、土壌、地形（傾斜方向）、降雨パターンの 5 要因についてはカテゴリ分類した。また、降雨イベント毎の各メッシュの誘因データについては単純化するため発生時刻のものではなく、降雨イベント期間内の最大値を採用した。

発生数は、発生・非発生 (1, 0) のデータではなく、発生の集中度を評価するためメッシュ内の発生数を採用した。つまり、素因と誘因データからメッシュ内の発生箇所数を学習していることになる。

b) 教師データの作成方法

教師データは図-2 に示すように最左列に 3 次メッシュコード、右から 2 番目の列に発生数、中央に素因と誘因を合わせた全 17 要因、行数は 1 降雨イベ

ント分の約 38 万データ（日本全国のメッシュ数）を第 3 章で説明する 134 イベント分を結合させたデータ（約 5,092 万データ）である。

ディープラーニングで学習させるデータとしては、要因データは入力層に、発生データは出力層に対応している。

この 17 要因・134 イベントのデータベースを用いて別途実施した土石流・がけ崩れ・地すべりの 3 つの土砂災害種別ごとの重要要因の検討事例⁵⁾より、「土石流」と「がけ崩れ」では類似の要因が重要要因として選定されたものの、「地すべり」ではそれらと異なる要因が上位に選定された。このため、「土石流・がけ崩れ」と「地すべり」はそれぞれ分けて危険度評価モデル構築することとし、教師データも分けて作成した。

3. 教師データの作成方法の検討

(1) 教師データ作成における課題と対応策

ディープラーニングを用いた土砂災害発生モデルの構築における教師データの作成に関して、非発生メッシュ数と比較して発生メッシュ数が極端に少ないため、発生を当てにくいモデルとなる可能性があるという課題が挙げられる。

そこで、データベースから作成する教師データに

図-2 教師データの内容（イメージ）

表-2 教師データの検討対象ケース

case	データセット数（メッシュ数）及び内容		要因数	検証内容
	発生	非発生		
1 (基本データ)	全データ	発生数の10倍のデータ数	素因・誘因を合わせた全17要因	—
2	全データ	発生数の等倍のデータ数	素因・誘因を合わせた全17要因	非発生のデータ数による影響を検証
3	全データ	発生数の等倍のデータ数 (1/10年以下)	素因・誘因を合わせた全17要因	非発生のデータの内容による影響を検証

おける発生データ数と非発生データ数のバランスを調整した。具体的にはデータ数が少ない発生データは全データを教師データに用い、データ数が多い非発生データはその数を絞り込んで教師データを作成することとした。

教師データの作成方法の違いによって構築されるモデルの危険度評価手法としての精度の違いを確認した。その精度検証方法としては、まず、検証の対象とする降雨イベントを設定し、そのデータセットを除外して教師データを作成してモデルを構築する。

次に、その構築したモデルで、検証の対象とする降雨イベントの入力データ(誘因・素因データ)に対する出力結果(発生数)から、発生に対する適中率及び非発生に対する空振り率を把握することとした。

(2) 教師データ作成方法の検討における各検討ケースの教師データの内容

前述したモデルの構築と、発生に対する適中率及び非発生に対する空振り率の検討は表-2に示す非発生メッシュの絞り込み条件の異なる3ケースを検討した。なお、この教師データ作成方法の検討では、土石流とがけ崩れ災害を対象とした。

表-2における「全データ」とはメッシュ雨量データの存在期間である1998～2014年の間で、災害種別を問わず全国で1日当たり10箇所以上の災害が発生した降雨イベントを抽出し、抽出した134件の降雨イベント分のデータを結合したもののうち、発生データのみを抽出したものである。

非発生データについては、全データの中からCase1ではランダムに発生データ数の10倍、Case2及びCase3では等倍のデータを抽出した。Case3は全データから、誘因のデータが10年超過確率以下のデータのみを抽出し、その中からランダムに発生データ数と等倍の非発生データを抽出した。

上記の発生・非発生データセットを教師データとしてモデルを構築した。また、検証データは、全災害イベントの中で発生数が最も多い台風災害の平成16年台風23号を採用した。

(3) 教師データ作成方法の検討結果

土石流とがけ崩れを対象にしたCase1～3の各教

表-3 教師データの作成方法の検討結果

case	発生に対する適中率 (%)		非発生に対する空振り率 (%)
	発生数以上	1.0以上	1.0以上
1	1.09	1.09	0.05
2	29.35	36.41	3.50
3	44.02	52.99	8.46

師データで構築したモデルに対し、検証データである平成16年台風23号の発生及び非発生データの適中率と空振り率を求めた結果を表-3に示す。

なお、発生に対する適中率、非発生に対する空振り率は式(1)～式(3)のように定義し、「発生数以上」は、例えば1つの3次メッシュ内に2箇所土砂災害が発生していれば、出力値が2.0以上となる場合だけを適中と定義したものである。

$$\begin{aligned} & \text{発生数 1.0 以上を対象とした適中率 (\%)} \\ & = \frac{\text{1.0 以上の発生メッシュ数}}{\text{全発生メッシュ数}} \times 100 \quad (1) \end{aligned}$$

$$\begin{aligned} & \text{発生数以上を対象とした適中率 (\%)} \\ & = \frac{\text{発生数以上の発生メッシュ数}}{\text{全発生メッシュ数}} \times 100 \quad (2) \end{aligned}$$

$$\begin{aligned} & \text{非発生を対象とした空振り率 (\%)} \\ & = \frac{\text{1.0 以上の非発生メッシュ数}}{\text{全非発生メッシュ数}} \times 100 \quad (3) \end{aligned}$$

10年超過確率以下の非発生データを使用し、発生数と非発生数を揃えたcase3が最も適中率が高くなった。

非発生データを小規模の降雨データのみを反映させたcase3で推定精度が高くなった理由は、非発生データの中に大きな降雨指標を示すデータが多く存在することが挙げられる。

4. 異なる災害種別や降雨イベントにおける精度検証

(1) 検討目的及び検証データの作成方法

異なる降雨パターンや地すべり災害における適性を把握するため、第3章の教師データの作成方法の検討の際に検証データの対象とした「平成16年台風23号」以外の3つの災害を含む表-4に示す4つの災害について、第3章と同じ検証方法で発生率の適中率及び非発生データの空振り率を算定した。

別途実施した過去の災害イベントを対象にした土砂災害種別ごとの重要要因の解析結果⁶⁾を踏まえ、災害の重要要因が類似であった土石流とがけ崩れは土砂災害種別が異なるが、1つのモデルとして構築した。

降雨パターンは短期降雨災害・長期降雨災害・台風災害の3つの種別に分類し、それぞれの災害種別において発生数が最も多いものを検証用災害データ

として1イベントを選定した。

地すべりにおいては、前述した災害種別ごとの重要要因の解析では、土石流やがけ崩れと異なる傾向を示したため、土石流・がけ崩れとは別の危険度評価モデルを構築するとともに、地すべりは発生に地下水の上昇に伴うケースが多く、短期雨量よりも長期降雨指標が支配的と考えられるため、上記のよう

な短期降雨災害などの災害種別に分けず、地すべりの発生数が最も多いイベントを検証用災害データとして1つ選定し、発生の適中率及び非発生データの空振り率を求めた。

土石流・がけ崩れについて、短期降雨災害は「平成26年8月広島・丹波豪雨」、長期降雨災害は「平成11年6月広島・福岡豪雨」、台風災害は教師デー

表-4 検証データに使用した対象イベント

イベント	災害種別	災害名	災害原因	発生期間	災害発生数	連続雨量 (mm)
1	土石流・がけ崩れ	短期降雨災害	集中豪雨	2014/8/17-8/24	258	247 (高瀬観測所: 8/19~20)
2		長期降雨災害	梅雨前線	1999/6/27-7/3	401	271 (戸山観測所: 6/28~29)
3		台風災害	台風23号	2004/10/20-10/21	451	235 (玉野観測所: 10/18~20)
4	地すべり	長期降雨災害	梅雨前線	2004/7/13-7/18	70	563 (栲尾観測所: 7/12~18)

表-5 検証データの検討結果

イベント	災害種別	発生に対する適中率 (%)		非発生に対する空振り率 (%)	
		発生数以上	1.0以上	1.0以上	
1	土石流・がけ崩れ	短期降雨災害	50.99	84.77	2.77
2		長期降雨災害	31.11	45.19	5.39
3	台風災害	44.02	52.99	8.46	
4	地すべり	長期降雨災害	0.00	0.00	0.00

表-6 検証データの検討結果(適中率の閾値を変更)

イベント	災害種別	発生に対する適中率 (%)							
		発生数以上	1.0以上	0.9以上	0.8以上	0.7以上	0.6以上	0.5以上	
1	土石流・がけ崩れ	短期降雨災害	50.99	84.77	90.73	94.04	95.36	98.01	98.01
2		長期降雨災害	31.11	45.19	74.07	89.63	94.07	97.41	99.63
3	台風災害	44.02	52.99	67.12	79.08	86.41	92.93	96.47	
4	地すべり	長期降雨災害	0.00	0.00	43.40	75.47	83.02	90.57	94.34

表-7 検証データの検討結果(空振り率の閾値を変更)

イベント	災害種別	非発生に対する空振り率 (%)						
		1.0以上	0.9以上	0.8以上	0.7以上	0.6以上	0.5以上	
1	土石流・がけ崩れ	短期降雨災害	2.77	6.26	10.01	14.06	18.25	24.49
2		長期降雨災害	5.39	13.38	24.39	36.59	49.27	63.53
3	台風災害	8.46	14.01	20.60	27.87	36.33	46.06	
4	地すべり	長期降雨災害	0.00	0.20	1.82	4.02	6.19	9.34

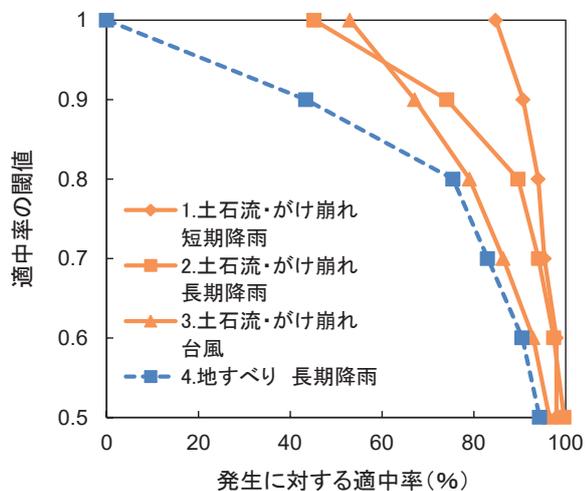


図-3 適中率の閾値と発生に対する適中率の関係

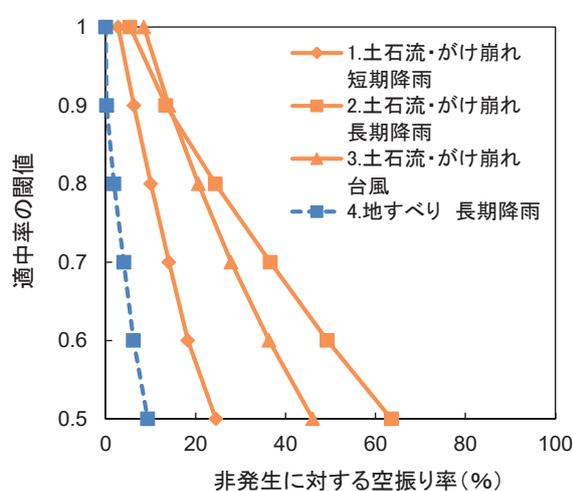


図-4 適中率の閾値と非発生に対する空振り率の関係

タの検証で用いた「平成 16 年台風 23 号」をそれぞれ選定した。地すべりについては「平成 16 年 7 月新潟・福島豪雨」を選定した。

教師データは適中率が最も高い case3 を使用することとした。適中率の閾値(予測の災害発生箇所数)について、1.0 以外に 0.9~0.5 についても適中率や空振り率を求めた。

(2) 災害種別の異なる降雨イベントにおける精度 検証結果

土石流・がけ崩れに関して、イベント 1 の短期降雨災害が他のイベントと比較して適中率(1.0 以上)が約 85%と高い値になり、また、空振り率についても 2.7%と低い値となった(表-5)。

イベント 4 の地すべりに関しては土石流・がけ崩れと比べて発生数が少ないため、うまく学習できず適中率が 0%になったと考えられる(表-5)。

しかし、表-6 に示すように適中率の閾値を下げると発生に対する適中率は上がり、閾値 0.8 の場合、すべてのイベントにおいて適中率は約 75%以上となった。

非発生に対する空振り率は適中率の閾値を下げると上がり、閾値 0.8 の場合、表-7 に示すように土石流・がけ崩れでは空振り率は約 10~25%、地すべりでは約 1.8%になる。地すべりについては適中率の閾値を下げて非発生に対する空振り率はそれほど増加しないことから、適中率の閾値を調整して運用すべきである。

5. おわりに

本研究では、現在の 3 次メッシュ単位の RBFN による警戒避難基準雨量の発展型ではなく、ディープラーニングを用い、日本全国で 1 つの土砂災害危険度評価モデルを試行した。

土砂災害は発生頻度の低い現象であり、非発生データの割合が極めて大きい現象であるが、学習データにおける発生メッシュ数、非発生メッシュ数の構成割合が結果に大きく影響し、モデルの構築にはその調整が必要であることが明らかとなった。

災害種別や降雨イベントタイプへの適用性については、地すべりに対するモデル及び土石流とがけ崩れを対象としたモデルのうち長期降雨災害や台風災害では、それほど高い適中率ではなかったものの短期雨量で高い適中率となった。また、長期降雨災害や台風災害においても適用できることを確認した。

本研究で試行したディープラーニングによる危険度評価方法は、災害実績の蓄積により精度向上が期

待できるモデルである。今後はパラメータの設定や現在運用されている RBFN を用いた警戒避難基準雨量の結果と比較検討などを行っていきたい。

参考文献

- 1) 倉本 和正, 鉄賀 博己, 東 寛和, 荒川 雅生, 中山 弘隆, 古川 浩平: RBF ネットワークを用いた非線形がけ崩れ発生限界雨量線の設定に関する研究, 土木学会論文集, 2001 巻, 672 号, pp.117-132, 2001.
- 2) 国土交通省河川局砂防部, 気象庁予報部, 国土交通省国土技術政策総合研究所: 国土交通省河川局砂防部と気象庁予報部の連携による土砂災害警戒避難基準雨量の設定手法(案), p.13, 2005.
- 3) 武井 宏将: 初めてのディープラーニング, リックテレコム, p.15, 2016.
- 4) 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, 1997 巻, 581 号, pp.107-121, 1997.
- 5) H2O. ai, <https://www.h2o.ai/>, 2018. 5. 18
- 6) 野呂 智之, 神山 嬢子, 鈴木 大和, 戸舘 光, 谷田 佑太, 海原 荘一, 只熊 典子, 竹本 大昭, 藤原 康正, 佐藤 文晴: 全国の 3 次メッシュを対象としたラフ集合による土砂災害発生の重要要因の抽出, 平成 30 年度砂防学会概要集, pp.677-678, 2018.

(2018. 5. 18 受付)