

# 深層学習を用いた斜面崩壊予測による 高速道路通行規制施策の提案

橋詰遼太<sup>1</sup>・堤浩志<sup>2</sup>・小濱健吾<sup>3</sup>・貝戸清之<sup>4</sup>

<sup>1</sup>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: r.hashizume@civil.eng.osaka-u.ac.jp

<sup>2</sup>正会員 西日本高速道路株式会社 (〒 565-0871 大阪府吹田市山田丘 2-8)

E-mail: h.tsutsumi.aa@jrl.eng.osaka-u.ac.jp

<sup>3</sup>正会員 大阪大学准教授 大学院工学研究科 (〒 565-0871 大阪府吹田市山田丘 2-8)

E-mail: k-obama@civil.eng.osaka-u.ac.jp

<sup>4</sup>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

7割が土工区間を占める我が国の高速道路では、降雨に伴う斜面崩壊による通行車両の被災防止のために、事前通行規制が実施されている。道路利用者の安全性確保と利便性向上のため、斜面崩壊予測に基づく適切な通行規制基準の設定が求められている。本研究では、深層学習を用いた斜面崩壊予測モデルの予測結果に基づく通行規制施策を提案する。具体的には、過去の斜面崩壊発生履歴データ、解析雨量データを用いた誘因情報、地質情報を用いた素因情報を深層学習モデルに導入し、のり面の崩壊危険性を算出する。さらに、道路利用者の安全性と利便性の観点から考慮した定量的な判断指標に基づき、通行規制施策を立案する。最後に、実在の高速道路路線データを用いた実証分析を通じて、本研究で提案する方法論の有用性を検証する。

**Key Words** : *slope disaster prediction, highway, rainfall regulation, deep learning*

## 1. はじめに

近年の局所的豪雨や線状降水帯といった異常降雨の増加に伴い、高速道路上における斜面崩壊の危険性が高まっている。高速道路会社は、道路利用者の被災を防止するために雨量基準値を用いた事前通行規制を実施されている。雨量基準値はIC区間単位で設定され、各IC区間の降雨履歴データや災害履歴データ、道路構造データを活用している。しかしながら、近年の降雨特性の変化に伴い、雨量基準値に達する前に斜面崩壊が発生する「見逃し」や、通行規制実施中に斜面崩壊が発生しない「空振り」が増加している。高速道路利用者の安全性確保と利便性向上を両立できるような通行規制基準が求められている。

本研究では、降雨特性や地形・地質特性の地域差が大きい高速道路を対象として、広域で適用可能な汎用性の高い斜面崩壊予測モデルに基づいた通行規制手法を提案する。具体的には、降雨データ、地形データ、災害履歴データに基づいた深層学習モデルを作成し、深層学習モデルの推計結果に基づいた適切な通行規制基準値の設定を試みる。以下第2章では、本研究の基本的な考え方を述べる。第3章では、深層学習モデルについて詳述し、第4章で通行規制手法について示す。最後に第5章で実在の高速道路路線を対象とした実証分

析を行い、本研究で提案する手法の有用性を検証する。

## 2. 本研究の基本的な考え方

### (1) 現行基準値の設定方法

NEXCO 西日本では過去に観測された降雨データや災害記録、道路構造をもとに、時間雨量と連続雨量を用いた通行規制基準を定めている。連続雨量は降雨開始から降雨終了まで2mm/hを超える降雨が6時間以上の中断を伴わずに継続した場合の累積雨量と定義される。2mm/hを超える降雨で降雨開始とし、2mm/h未滿の状態が6時間継続した時点で降雨終了とする降雨の時系列を降雨イベントと定義し、降雨イベントを基に通行規制の実施を判断している。

通行規制基準値は、図-1のような降雨履歴図を用いて設定される。降雨履歴図は、横軸を連続雨量、縦軸を時間雨量として過去の降雨をプロットしたものである。1回の降雨イベントを1本の折れ線グラフとして記録し、過去20年間の降雨履歴を同一のグラフ上に描くことにより降雨特性を表す。降雨履歴図を基に連続雨量と組合せ雨量の2つの基準値を設定する。組合せ雨量とは連続雨量と時間雨量の組合せで定められる基準値のことである。雨量基準値は、岩井法<sup>1)</sup>による降雨確率年を基に決定される。岩井法は設計要領で降雨




図-1 降雨履歴図

量や積雪の水分統計解析で用いられる確率手法である。供用年数、被害履歴、道路構造といった各区分における特性に応じて降雨確率年を設定する。次に、降雨履歴図上に災害記録をプロットし、降雨確率年を用いて設定された雨量基準値を調整する。すべての災害を捕捉できる基準値を設定するのではなく、災害の規模や災害発生後の対策状況、降雨経験を十分に考慮して検討を行う。基準値は降雨経験や斜面災害発生事例に応じて適宜見直されている。

しかしながら、現行基準にはいくつか課題がある。まず、降雨量を観測する雨量計の設置間隔が挙げられる。雨量計は約 10km 間隔で設置されているため、局所的豪雨の影響を十分に考慮できないことが懸念される。2つ目に、雨量指標の選定方法が挙げられる。現行基準では、時間雨量と連続雨量が用いられているが、適切な雨量指標を複数組み合わせることにより、災害捕捉率の向上が期待される。3つ目に、最終的な雨量基準の設定において道路管理上の経験に依存していることが挙げられる。降雨確率年や道路区分の特性、災害発生履歴といった定量的なデータを用いて雨量基準の検討が行われているが、最終的には定性的な判断に基づいて基準値が決定されている。近年の降雨特性の変化に対応するため、より定量的な手法を用いて基準値の精緻化を図る必要がある。

## (2) 既往研究のレビュー

斜面崩壊予測に基づいて通行規制基準値を決定するための研究は数多く行われている。荒木等<sup>2)</sup>は、ニューラルネットワークを用いて土砂流危険渓流における土砂崩壊のリアルタイム発生予測及び雨量基準の設定を行っている。倉本等<sup>3)</sup>は、RBF ネットワークによる機械学習を用いて、非線形がけ崩れ発生限界雨量線の設定を行い、災害捕捉率の向上を報告している。篠崎等<sup>4)</sup>

は、RBF ネットワークによる出力値をロジスティック回帰モデルを用いて確率値に変換することにより、災害の危険性の表現や雨量基準の超過予測を行っている。櫻谷等<sup>5)</sup>は、多重ロジスティック回帰分析の特性変数に降雨量を合成した混合確率モデルを用いて斜面災害発生確率を統計的にモデル化し、通行規制実施前に斜面災害が発生するリスクと通行規制実施後に斜面災害が発生しないリスクの双方を考慮した雨量基準値の設定方法を提案している。

斜面崩壊予測の研究では、同質な降雨特性や地形特性を持つ限定された地域のデータを用いてモデルの推計を行う場合が多い。しかしながら、高速道路路線上のり面を対象とした場合、雨量データや地形データに大きな地域差が生じる。限定された地域のデータを用いて推計されたモデルは、地域性に依存したモデルとなる可能性が高く、他地域に適用した場合、推定精度の低下が懸念される。また、高度な管理が実施されている高速道路路上では、斜面崩壊事例が少なく、降雨特性や地形特性が似通った地域毎に分けて推計を行うことが難しい。

## (3) 本研究の方法論

以上の問題意識から本研究においては、広域で適用可能な汎用性の高い斜面崩壊予測モデルの作成を試みる。斜面崩壊と関連付けられる最適な雨量指標は、地域の降雨特性や地形、地質によって異なる。一般に、雨量基準は短期雨量指標と長期雨量指標を組み合わせる場合が多いが、広域を対象とした斜面崩壊予測モデルでは、2つの雨量指標では十分とはいえない。そこで、時間雨量や半減期の異なる実効雨量といった複数の雨量指標をモデルに導入する。しかしながら、雨量指標同士では相関性が高い場合が多く、重判別分析やロジスティック回帰分析といった回帰モデルに複数の雨量指標を導入した場合、多重共線性の問題が生じる。そこで、本研究においては、多重共線性の影響を受けにくい深層学習モデルを用いる。深層学習モデルは、多重共線性によって説明力が低下する可能性があるが、推定精度には影響を及ぼさないとされる。

深層学習モデルの推計には、誘因の雨量データと素因の地形データに加えて災害履歴データを用いる。雨量データは局所的豪雨を考慮できるように、気象庁から提供されている解析雨量を使用する。解析雨量は、気象レーダーの観測データに加えて全国の雨量計のデータと組み合わせることで1時間の降水量分布を1km四方の細かさで解析したものである。広域に適用可能なモデルとなるように複数の雨量指標の中から適切な雨量指標の組合せを選定する。地形データ、災害履歴データは、り面別に集計されているため、り面単位で斜面崩

壊予測を行う。災害履歴データは、過去の災害からの経過時間と災害発生地点からの距離を考慮してモデルに導入する。のり面単位で得られる誘因情報、素因情報、災害履歴によって構成される入力ベクトルを深層学習モデルに入力すると、0~1 の値が出力値として得られる。これは斜面崩壊危険性と考えることができる。災害発生データの正解値を 1, 非発生データの正解値を 0 として与え、出力値と正解値の適合度が高くなるように深層学習を行う。なお、正確な崩壊時刻は記録されていないため、災害発見時刻を崩壊時刻として扱う。また、収集したデータは学習データとテストデータに分割し、学習データのみを用いてモデルの特徴量とハイパーパラメータを決定する。

通行規制の実施判断には、深層学習モデルの出力値を用いる。学習済みの深層学習モデルにテストデータを入力し、評価指標を用いて閾値の検討を行う。閾値を低く設定した場合、見逃し率を低減させることが可能となるが、空振り率が増加する。一方、閾値を高く設定した場合、空振り率を低減させることが可能となるが、見逃し率が増加する。このように両者はトレードオフの関係にあり、両者を同時に低減させることはできない。本研究においては、最適な閾値を求めるのではなく、現行手法よりも見逃し率と空振り率を改善できるような基準値の提案に留める。

### 3. 斜面災害予測モデル

#### (1) 深層学習モデル

##### a) ニューラルネットワークの構成

ニューラルネットワークは、神経細胞（ニューロン）の働きをコンピュータ上で再現したモデルである。個々のニューロンは簡単な演算能力しか持たないが、複数のニューロンが互いに結び付くことによって高度な認識能力を持つ。図-2 のようにニューロンを層状に接続し、ネットワーク化することによってニューラルネットワークが構築される。ニューラルネットワークは、入力層、中間層、出力層に分類される。入力層は入力を受け取って中間層に受け渡す機能のみであり、中間層と出力層で演算が行われる。中間層を複数接続することによって深層学習が可能となり、より複雑な認識能力が得られる<sup>6)</sup>。各ニューロンには複数の入力があるが、出力は一つだけである。通常のニューラルネットワークでは、1つのニューロンからの出力が次の層のすべてのニューロンの入力とつながっている。各入力には結合係数  $w$  を掛け合わせる。入力と重みを掛け合わせた値の総和にバイアス  $b$  を加えるた値を  $u$  とすると、

$$u = \sum_{k=1}^n x_k w_k + b \quad (1)$$




図-2 多層ニューラルネットワーク

と表される。活性化関数  $f$  を通じて処理された出力  $y$  は、

$$y = f(u) = f\left(\sum_{k=1}^n x_k w_k + b\right) \quad (2)$$

と表される。代表的な活性化関数として、シグモイド関数や  $\tanh$  関数、式-3 で表される ReLu 関数などが挙げられる。多層ニューラルネットワークにおいてシグモイド関数や  $\tanh$  関数を活性化関数として用いた場合、逆伝播において勾配が消失し、学習が進まなくなる。そこで、深層学習の活性化関数としては、Relu 関数が最適であるとされている<sup>7)</sup>。Relu 関数は、

$$y = \begin{cases} 0 & (u \leq 0) \\ u & (u > 0) \end{cases} \quad (3)$$

と定義される。Relu 関数は数学的には微分可能ではないが、

$$\frac{\partial y}{\partial u} = \begin{cases} 0 & (u \leq 0) \\ 1 & (u > 0) \end{cases} \quad (4)$$

と計算上定義する。

本研究で用いるニューラルネットワークでは、出力層のニューロンは 1つであり、活性化関数には、式-5 で示される恒等関数を用いる。

$$y = u \quad (5)$$

##### b) 誤差逆伝播法

ニューラルネットワークの学習には、誤差逆伝播法が用いられる。出力と正解の誤差がネットワークを逆伝播することにより結合係数  $w$  とバイアス  $b$  が最適化される。出力値  $y$  と正解値  $t$  の誤差を定義する損失関数を用いて、二乗和誤差  $E$  を最小化させることにより学習を行う。出力層の添字を  $k$ 、ニューロン数を  $n$ 、中間層の添字を  $j$ 、ニューロン数を  $m$ 、入力層の添字を

$i$ , ニューロン数を  $l$  とすると, 損失関数は,

$$E = \frac{1}{2} \sum_k (y_k - t_k)^2 \quad (6)$$

と表される. 二乗和誤差を起点に誤差を前層へ伝播させて結合係数とバイアスを修正する必要があるが, この際に勾配降下法を用いて修正量を決定する. まず, 出力層の結合係数の勾配は,

$$\frac{\partial E}{\partial w_{jk}} = \frac{\partial E}{\partial u_k} \frac{\partial u_k}{\partial w_{jk}} \quad (7)$$

と表される. ここで,

$$\frac{\partial u_k}{\partial w_{jk}} = \frac{\partial(\sum_{q=1}^m y_q w_{qk} + b_k)}{\partial w_{jk}} = y_j \quad (8)$$

と表される. また,

$$\delta_k = \frac{\partial E}{\partial u_k} \quad (9)$$

と設定する. 式-7 は, 式-8, 式-9 を用いて,

$$\frac{\partial E}{\partial w_{jk}} = y_j \delta_k \quad (10)$$

と表すことができる. バイアスの勾配は,

$$\frac{\partial E}{\partial b_k} = \frac{\partial E}{\partial u_k} \frac{\partial u_k}{\partial b_k} \quad (11)$$

と表される. ここで,

$$\frac{\partial u_k}{\partial b_k} = \frac{\partial(\sum_{q=1}^m y_q w_{qk} + b_k)}{\partial b_k} = 1 \quad (12)$$

より, 式-11 は, 式-9 を用いて,

$$\frac{\partial E}{\partial b_k} = \delta_k \quad (13)$$

と表すことができる. 次に, 出力層における入力勾配, すなわち中間層の出力の勾配は,

$$\frac{\partial E}{\partial y_j} = \sum_{r=1}^n \frac{\partial E}{\partial u_r} \frac{\partial u_r}{\partial y_j} \quad (14)$$

と表される. ここで,

$$\frac{\partial u_r}{\partial y_j} = \frac{\partial(\sum_{q=1}^m y_q w_{qr} + b_r)}{\partial y_j} = w_{jr} \quad (15)$$

と表される. また,

$$\delta_r = \frac{\partial E}{\partial u_r} \quad (16)$$

と設定する. 式-14 は, 式-15, 式-16 を用いて,

$$\frac{\partial E}{\partial y_j} = \sum_{r=1}^n \delta_r w_{jr} \quad (17)$$

と表すことができる. 続いて, 中間層の勾配は出力層の勾配と同様に,

$$\frac{\partial E}{\partial w_{ij}} = y_i \delta_j \quad (18)$$

と表される. バイアスの勾配も同様に,

$$\frac{\partial E}{\partial b_j} = \delta_j \quad (19)$$

と表される. さらに上層に中間層が存在する場合は,

$$\frac{\partial E}{\partial y_i} = \sum_{q=1}^m \delta_q w_{iq} \quad (20)$$

として伝播させる.

### c) AdaGrad

勾配降下法では, 勾配を基に結合係数とバイアスを少しずつ調整し, 誤差が最小になるようにニューラルネットワークを最適化する. 最適化アルゴリズムは, 効率的にかつ確実に大域最適解を得られるように用いられる. 代表的な最適化アルゴリズムに確率的勾配降下法や Momentum, AdaGrad などがある. 本研究においては, Duchi 等<sup>8)</sup> が 2011 年に提唱した AdaGrad を用いる. 更新量が自動的に調整され, 学習が進むと学習率が次第に小さくなるという特徴がある. また, 初期設定する必要があるパラメータが学習係数のみで, 調整を行いやすいという利点がある. 学習係数を  $\eta$  とすると, 結合係数の更新式は,

$$h \leftarrow h + \left(\frac{\partial E}{\partial w}\right)^2 \quad (21)$$

$$w \leftarrow w - \eta \frac{1}{\sqrt{h}} \frac{\partial E}{\partial w} \quad (22)$$

と表される. 式-21 は,  $h$  が必ず増加するように更新され,  $h$  は式-22 の分母にあるため, 更新量が減少していく.  $h$  は結合係数ごとに計算されるため, これまでの総更新量が少ない結合係数は, 新たな更新量が大きくなり, 総更新量が多い結合係数は新たな更新量が小さくなる. これにより, 最初は広い領域で探索し, 次第に探索範囲を絞ることにより効率良く探索することが可能となる.

### d) ドロップアウト

ニューラルネットワークは, 特定の範囲のデータのみ最適化され, 未知のデータに対する推定精度が低下する過学習が発生することがある. 過学習は, 特定のパターンにのみ最適化された局所最適解に陥っている状態と考えられる. ドロップアウトは, 過学習の解消を目的として, 図-3 に示すように, 出力層以外のニューロンを一定の確率でランダムに消去する手法である<sup>9)</sup>. 消去されるニューロンは, 結合係数とバイアスの更新ごとに入れ替わる. ドロップアウトは, 実質的に小さなニューラルネットワークの組み合わせたとときと同様の効果が得られる. 規模の大きなニューラルネットワークは過学習を起こしやすいが, ドロップアウトを用いることにより, ネットワークの規模を下げつつ, 複数のネットワークの組み合わせによってネットワークの表現力は保たれる. また, ドロップアウトの正則化によって多重共線性を解消する効果が期待できる.

### (2) データの分割方法

予測モデルを作成する目的は, 未知のデータに対する予測であり, そのためには汎化能力が必要とされる. モデルの汎化能力を評価するために, データを訓練データと検証データに分割し, 検証データへの予測精度を定量化する必要がある. 最も基本的なデータの分割方




図-3 ドロップアウトの例

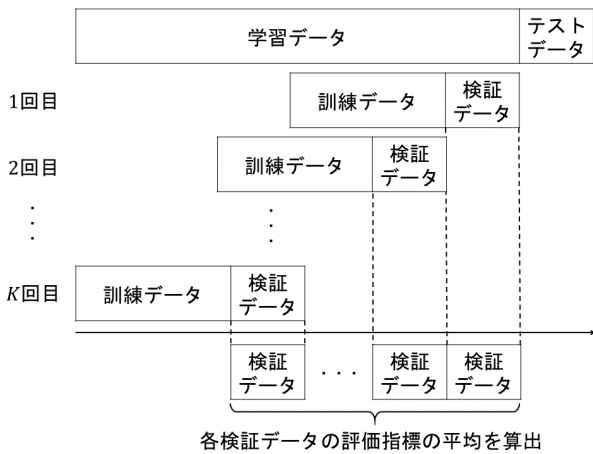


図-4 クロスバリデーション

法であるホールドアウト法では、収集したデータをまず学習データとテストデータに分割し、学習データをさらに訓練データと検証データに分割する。検証データの予測精度を評価し、特徴量とパラメータを決定する。しかしながら、検証データが一定期間に集中するため、他の期間に対する予測精度が低下する可能性がある。本研究においては、ホールドアウト法の欠点を解消したクロスバリデーション法<sup>10)</sup>を用いる。図-4に示すように時系列に沿って  $K$  個のデータセットに分割する。各データセットのデータ数が等しくなるように設定し、各データセットの検証データが連続的になるように分割する。訓練データと検証データの時間的な関係性を保ちながら評価を  $K$  回繰り返す。  $K$  個の検証データの評価指標の平均値を用いてモデルを比較する。

(3) モデルの評価指標

モデル性能の評価では、正しい予測の数と誤った予測の数を定量化に表-1に示すような混同行列が用いら

表-1 混同行列

		正解値	
		正例 (災害発生)	負例 (災害未発生)
予測結果	正例 (災害発生)	真陽性 TP (災害捕捉)	偽陽性 FP (空振り)
	負例 (災害未発生)	偽陰性 FN (見逃し)	真陰性 TN (未発生的中)

れる。予測値を正例としてその予測が正しい場合を  $TP$  (災害捕捉)、予測値を負例としてその予測が正しい場合を  $TN$  (災害未発生的中)、予測値を正例としてその予測値が誤りの場合を  $FP$  (空振り)、予測値を負例としてその予測が誤りの場合を  $FN$  (見逃し) とする。見逃し率  $r_1$  と空振り率  $r_2$  を次のように定義される。

$$r_1 = \frac{FN}{TP + FN} \tag{23}$$

$$r_2 = \frac{FP}{TP + FP} \tag{24}$$

閾値増加させると見逃し率  $r_1$  は増加し、空振り率  $r_2$  は減少する。一方で、閾値を減少させると見逃し率  $r_1$  は減少し、空振り率  $r_2$  は増加する。そこで、閾値を  $0 \sim 1$  まで走査し、見逃し率  $r_1$  と空振り率  $r_2$  の調和平均  $f$  を求め、調和平均の最大値をモデルの評価指標として用いる。

$$f = \frac{2r_1r_2}{r_1 + r_2} \tag{25}$$

(4) 学習データ

a) 誘因情報

誘因情報の候補として、時間雨量と実効雨量が挙げられる。実効雨量は土砂災害発生指標の1つであり、雨量を以下のように重み付き積算し、土壤中の水分量を近似的に表現する<sup>11)12)</sup>。

$$R_e(t) = \sum_i 0.5^{i/T} r(t-i) \tag{26}$$

$T$  は半減期を表す。時間が経つほど係数  $0.5^{i/T}$  が小さくなることによって、流出や蒸発散によって地表面から水が失われる影響を考慮する。つまり過去に降った雨量の影響を時間とともに減少させて計算した雨量の目安といえる。半減期が長くなるほど過去の降雨の影響が考慮される。半減期が長い実効雨量は長期雨量指標として用いられ、半減期の短い実効雨量は短期雨量指標として用いられる。

b) 素因情報

素因情報には、のり面単位で集計されている地形データを用いる。地形データの項目として、のり面延長、直高、面積、段数、平均のり面斜長、平均のり面勾配、の

り面保護工事種別、保護工事実施面積、湧水の有無が記録されている。地質、地盤に関するデータも記録されているが、データ欠損が多いため推計には使用しない。

### c) 災害履歴データ

多くの斜面災害は局所的豪雨や長期にわたる連続降雨によって引き起こされるが、比較的少ない雨量で発生する災害や降雨終了後長時間経過してから発生する斜面災害が一部存在する。雨量データや地形データのみを用いたモデルでは、そのような斜面災害を捕捉することは難しい。一方で、斜面災害は一定の期間に集中して発生し、かつ発生地点が密集する傾向が見られる。そこで、周辺地域で直近に発生した災害履歴データをモデルに導入することにより、災害捕捉精度の向上を試みる。ある地点で災害が発生したとき、周辺地域で災害が発生する危険性が高くなる。また、災害発生直後は特に次の災害が発生する可能性が高くなり、時間が経過するにつれて次の災害が発生する可能性が下がると仮定する。直近の災害が発生した地点までの距離と直近の災害からの経過時間を変数として導入する。

## 4. 斜面崩壊危険性に基づく通行規制手法

### (1) 通行規制の実施判断

通行規制の実施判断には、斜面崩壊予測モデルの出力値である斜面崩壊危険性を用いる。時刻毎に得られる雨量データ、各のり面の素因情報、周辺地域で直近に発生した災害発生情報を学習済みの斜面崩壊予測モデルに入力すると、各のり面の崩壊危険性が算出される。IC 区間中のいずれかののり面の斜面崩壊危険性が基準値以上となった時点で当該区間の通行規制を開始し、IC 区間のすべてののり面の斜面崩壊危険性が基準値未満となった時点で通行規制を終了する。

### (2) 通行規制基準値の設定

まず、訓練データを用いて学習を行った斜面崩壊予測モデルにテストデータを入力する。テストデータは、すべてののり面を対象とする。また、災害発生件数が十分確保できるような期間を設定する。テストデータを学習済みの斜面崩壊モデルに入力すると、各のり面に対して対象期間中の斜面崩壊危険性が算出される。次に、通行規制基準値としてすべてののり面に対して統一の施策変数  $u$  を設定する。施策変数  $u$  は、見逃し率と空振り率を指標として設定する。

施策変数  $u$  を低く設定した場合、見逃し率を低減させることが可能となるが、空振り率が増加する。一方、施策変数  $u$  を高く設定した場合、空振り率を低減させることが可能となるが、見逃し率が増加する。本研究においては、最適な閾値を求めるのではなく、現行手

法よりも見逃し率と空振り率を改善できるような基準値の提案に留める。「現行基準と同程度の見逃し率まで許容し、空振り率の削減を図る」、「現行基準と同程度の空振り率は許容するが、空振り率をできる限り低減させる」といった複数の施策が考えられ、施策の選択は管理主体のリスク許容度に委ねられるためである。

## 5. 実証分析

### (1) データ概要

本研究で提案したモデルの有用性を検証するために、実際の高速道路を対象として実証分析を行う。対象路線において 2006 年 4 月から 2018 年 9 月の間に発生した斜面災害を対象に推計を行う。雨量データは、気象庁により提供されている 1km メッシュ解析雨量である。地形データはのり面単位で集計されている。地形データの項目として、のり面延長、直高、面積、段数、平均のり面斜長、平均のり面勾配、植生保護面積、コンクリート保護面積、湧水の有無が記録され、各項目の最大値が 1 となるように基準化した。雨量に関しては、最大雨量の地域差が大きい。地域によっては比較的少ない雨量で災害が発生することがあり、絶対的な雨量値だけでは、崩壊斜面と非崩壊斜面の差を説明することは難しい。多雨地域は、非多雨地域と比較して斜面崩壊の限界雨量が大きく、同程度の豪雨が発生した場合には、斜面崩壊の発生数が少ないとされる。これは降雨に対する斜面崩壊の慣れと呼ばれる<sup>13)</sup>。同じ雨量でも多雨地域と非多雨地域では、斜面崩壊に対する危険性に差が生じると考えられるため、各メッシュの最大雨量が 1 となるように基準化した。

## 6. おわりに

本研究では、高速道路の通行規制基準に着目し、雨量データ、地形データ、災害履歴データを用いた深層学習モデルにより推計し、見逃し率と空振り率の低減を図る通行規制手法を提案した。具体的には、誘因として複数の雨量指標、素因としてののり面の諸元データ、直近に発生した斜面災害の影響度を深層学習モデルに導入し、未知のデータに対する斜面災害発生予測を行った。また、現行通行基準との比較によって閾値の検討方法について述べた。なお、本研究で提案した方法論に実際の路線データを適用した実証分析を行っている。その結果および考察に関しては研究発表会にて提示する。

### 参考文献

- 1) 岩井重久, 石黒政儀: 応用水文統計学, 森北出版, 1970.
- 2) 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度

- 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.
- 3) 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, No.672, p.117-132, 2001.
  - 4) 篠崎 嗣浩, 福田 賢司, 大石 博之, 杉原 成満, 古川 浩平: ロジスティック回帰分析を用いた土砂災害発生危険基準線の確率的評価, 土木学会論文集 F, Vol.66, No.1, p.122-131, 2010.
  - 5) 櫻谷慶治, 水谷大二郎, 小濱健吾, 貝戸清之, 音地拓: 高速道路斜面災害に対する降雨時通行規制基準値の設定方法, 土木学会論文集 F6, Vol.75, p.12-30, 2019.
  - 6) 我妻幸長: はじめてのディープラーニング, SB クリエイティブ, 2018.
  - 7) Yann LeCun, Yoshua Bengio, Geoffrey Hinton : Deep learning, Nature 521(7553), p.436-444, 2015-05-28.
  - 8) John Duchi, Elad Hazan, Yoram Singer : Adaptive Subgradient Methods for Online Learning and Stochastic Optimization, Journal of Machine Learning Research 12, p.2121-2159, 2011.
  - 9) Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov: Dropout: A Simple Way to Prevent Neural Networks from Overfitting, Journal of Machine Learning Research, pp.1929-1958, Vol.15, 2014.
  - 10) 門脇大輔, 阪田隆司, 保坂桂佑, 平松雄司: Kaggle で勝つデータ分析の技術, 技術評論社, 2019
  - 11) 防災科学研究所: 実効雨量について (<https://sip4dkit-web.bosai.go.jp/rain/effectiverainfall/> 最終閲覧日: 2020 年 2 月 12 日)
  - 12) 矢野勝太郎: 前期降雨の改良による土石流の警戒・避難基準雨量設定手法の研究, 砂防学会誌, Vol.43, No.4, pp.3-13, 1990.
  - 13) 飯田智之: 技術者に必要な斜面崩壊の知識, 鹿島出版, 2012.