

福岡県筑後地方における土砂災害発生限界累加 雨量の算定と予測について

Estimate for Cumulative Rainfall of Critical Rainfall and Prediction of Landslides in
Chikugo District, Fukuoka Prefecture, Japan

森山 聡之¹・森下功啓²・外園慶明³・平野宗夫⁴

¹ 福岡工業大学社会環境学科 (〒 811-0295 福岡市東区和白東3丁目30番1号)

E-mail: sediment@civil.kyushu-u.ac.jp

² 熊本高等専門学校 (〒 866-0074 熊本県八代市平山新町2627)

E-mail: morishita@kumamoto-nct.ac.jp

³ ナカシャクリエイテブ(株) (〒 468-8533 名古屋市天白区野並二丁目213番地)

E-mail: y-hokazono@nakasha.co.jp

⁴ NPO 法人社会実装 (〒 811-0214 福岡市東区和白東3丁目11番6号)

E-mail: hirano_m@pop21.odn.ne.jp

Key Words: Critical Rainfall for landslide, Slope Element Accumulated Model, SVM, ANN

1. 平成29年7月九州北部豪雨の概要

平成29年7月九州北部豪雨は、5日の正午過ぎから、朝倉市、東峰村及び日田市において1時間に100mmを超える雨が頻発し、斜面崩壊と崩壊した土砂が樹木を巻き込み、下流まで流出する土石流となって多くの被害をもたらした。さらに日田市小野地区では、斜面崩壊により河道閉塞も発生した。ここで問題となるのは、土砂災害の発生限界降雨である。森山らは、既に同災害における3時間累加雨量最大値と崩壊面積率の関係を求めている¹⁾が、発生限界を規定する到達時間を3時間と仮定して計算を行なっている。これは、2003年の水俣市宝川内で発生した土石流の発生限界が3時間累加雨量で121mmであったことから3時間を採用している。また千木良雅弘²⁾も目視により3時間降雨量が200mm以上の領域に崩壊が多数発生したと報告している。しかし、朝倉市、東峰村及び日田市周辺で3時間累加雨量を用いることが適正であるかどうかは不明のため、本研究ではこれを詳細に検討するとともに、人工ニューラルネットワーク(以下ANN)とサポートベクタマシン(以下SVM)を用いて土砂災害発生予測を試みた。

2. 方法

(1) 斜面要素集合モデルによる土砂災害発生限界の検討

現在、気象庁で用いられている土壌雨量指数は、(1) タンクモデルのパラメータは全国一律であり、個々の地域における斜面長分布や地質、植生、風化等が考慮されていない。(2) このため気象庁は土壌雨量指数は絶対値でなく相対値であるとしている。(3) 今後1時間であと何mm降れば何%の確率で土砂災害が発生するかを求めることが容易ではない。といった課題が挙げられる。

それに比べ、平野らの斜面要素集合モデル³⁾(Slope Element Assemble Model:SEAM)は、地域毎に到達時間を求める必要があるが、単なる発生予測だけではなく、1時間であと何mmの降雨が続けば何%の確率で土砂災害が発生するかまで容易に計算可能である。

SEAMの概念図を図1に、以下にその式の展開を示す。

平野らは理論的考察と実験から、表面流発生つまり、斜面厚さ D が浸透水の水位 H_c に等しいことを土石流発生の条件として下式を導いた³⁾。

$$H_c = \frac{1}{\lambda} \int_{t-T_s}^t r \cos \theta dt \quad (1)$$

および

$$\ell \geq \frac{k \sin \theta}{\lambda} T_s \quad (2)$$

ここに、 r : 降雨強度, λ : 堆積物の空隙割合, T_s : 斜面の到達時間, θ : 斜面の傾斜角, ℓ : 斜面長, k : 透水係数である.

これより,

$$\int_{t-T_s}^t r \cos \theta dt \geq \frac{H_c k T_s}{\ell} \tan \theta = R_c \quad (3)$$

が発生限界の式となる.

上記の発生限界は室内実験³⁾で検証され, 現地への適用性⁴⁾も確認されている.

ここで累加雨量 $R(t, \tau)$ は下式で求めることが可能である.

$$R(t, \tau) = \int_{t-\tau}^t r dt \quad (4)$$

ここに時刻 t , 時間 τ である.

次にアメダスの降雨最大値

$$R_{\max}(\tau) = \max [R(t, \tau)] \quad (5)$$

を1日間(1440分)に区切って求め, 福岡県の土砂災害発生履歴データを元に, 土砂災害の発生及び不発生事例に分ける.

次に各地点の発生の下限と不発生の上限を求める. 平野⁵⁾によると, 場の定常性を仮定すると式(4)による不発生の上限と発生の下限が図3のようになり, 発生時は時間 T_s において発生限界点 R_c の上を通り, 不発生時は時間 T_s において発生限界点 R_c の下を通ることになる. しかし実際には降雨データに各種誤差に起因するばらつきが含まれるため, 図4のように交差せず開きが生じるため不発生の上限と発生の下限の差が極小になる点(くびれ)が斜面の到達時間と発生限界点 R_c , 即ち発生限界累加雨量を示すと考えられる.

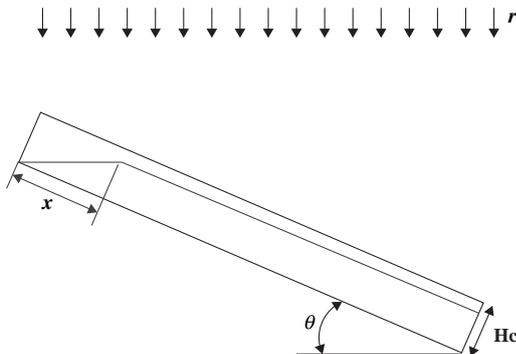


図2 斜面の概念図. 有限長を仮定.

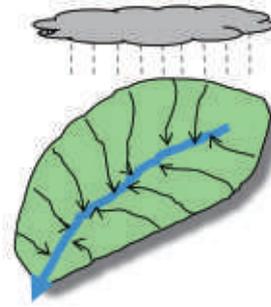


図1 斜面要素集合モデルのイメージ, 斜面長が分布している

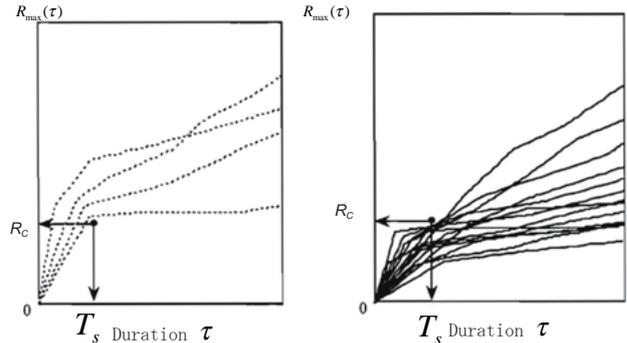


図3 発生下限(左)と不発生上限(右)⁵⁾

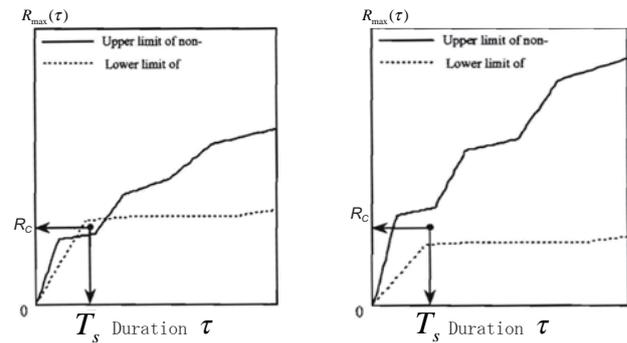


図4 到達時間, 発生限界降雨, 発生下限と不発生上限の関係 左は理想的な場合, 右は実際のデータ

(2) ANNを用いた土砂災害発生予測手法

明確な「くびれ」がない場合でも, ANNを用いる方法⁶⁾が有効であったことから, AMeDAS 朝倉と AMeDAS 黒木の累加雨量 ANN の適用を試みた.

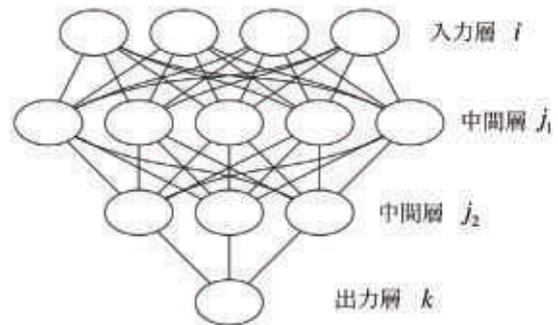


図5 多層型ニューラルネットワークの例

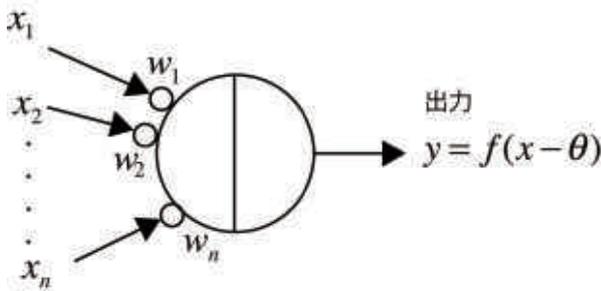


図6 ユニットモデル f は応答関数

図5のような入力層 i ・中間層 $j_1, j_2 \dots$ ・出力層 k からなる階層型の構造をした ANN を使用し、教師付き学習法であるバックプロパケーション（誤差逆伝播法）を使用した。バックプロパケーションは出力層の各ユニットが実際に出力した値と教師信号との誤差を規則にしたがって出力層へ向かって伝播させるものである。ネットワークを構成する最小単位であるユニットは図6のようになっており、このユニットの性質をあらわす応答関数（活性化関数）は、従来はシグモイド関数が用いられてきたが、最近では図7に示すような ReLU 関数（Rectified Linear Unit, 正規化線形関数）を中間層に使うことが多い。

x は 0 ~ 1 に正規化されて入力層に入力される。入力層の各ユニットは中間層の全ユニットに対して正規化された x を出力する。入力層から出力された値は全ユニット間毎に異なる重み w を乗じられる。中間層のユニットでは、入力層の全ユニットからの入力の和を応答関数 f により変換した値を出力層に対して出力する。中間層から出力層に向かう出力にも、ユニット間毎に異なる重み w が乗じられ、出力層でも中間層と同様の処理が行われる。最終的に出力層から出力されたものに教師信号を与え、ネットワーク間の重みを変えていく。ネットワークはこれをいくつかのパターンについて繰り返し学習することにより重み w を決定し、理想的なネットワークを形成する。出力層のユニット k のパターン p が入力された時の出力 O_{kp} と教師信号 T_{kp} のずれの程度を出力層での誤差とすると、パターン p に対する誤差関数及び全パターンでの誤差はそれぞれ次式で表される。

$$E_p = \frac{(T_{kp} - O_{kp})^2}{2} \quad (6)$$

$$E_T = \sum_p E_p \quad (7)$$

この E_T が最小となったものを最適なネットワークとしてこの E_T を極小化するように重みを変化させる。これを学習と呼ぶ。一般的には、バックプロパケーションを用いて最適化を行う。この逆誤差伝

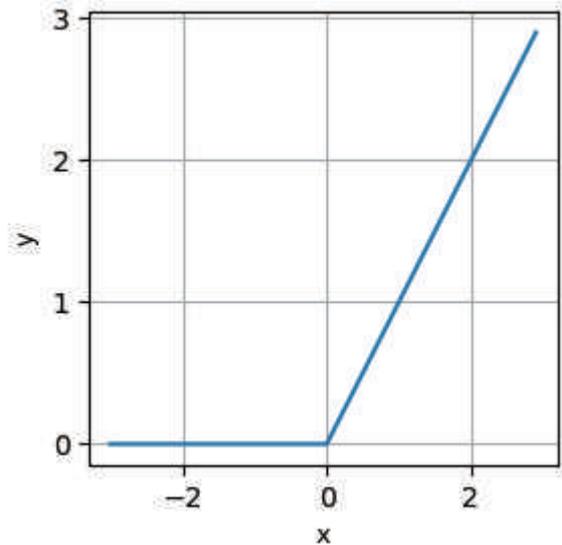


図7 ReLU 関数の例

搬法で用いられる誤差を最小にする最適化手法は、従来最急降下法が多用されていたが、準 Newton 法や確率的勾配降下法もよく使われる。

今回、ANN は Python の scikit-learn ライブラリを用いて、学習検証及びテストを行った。多層 ANN を用いて入力層の各ユニットに 10 分から 720 分までの累加雨量最大値 $R_{\max}(\tau)$ を与え、出力層に土砂災害の発生に 1、不発生に -1 の教師信号を与えた。最適化の過程で、応答関数は ReLU 関数に固定とし、最急降下法、準 Newton 法や確率的勾配降下法を適合の良好性（正答率）から選択することとした。中間層の構成も 2 層だけでなく 1 ~ 4 層までの選択肢を与えた。

(2) SVM を用いた土砂災害発生予測手法

今回使用した SVM は、1995 年に AT&T の V. Vapnik が発表した教師ありの機械学習方法⁷⁾ をベースにしている。ANN 同様 Python の scikit-learn ライブラリを用いて学習及びテストを行った。教師信号も ANN と同様である。

3. 解析対象データと解析処理

(1) 降雨データと前処理

1994 年から 2014 年の約 20 年間の筑後地方の AMeDAS の 10 分間雨量データから、降雨が続いているデータを取り出し、朝倉、久留米、黒木、耳納山、大牟田、柳川の 6 地点（図 8）について、土砂災害の発生限界図の作成を試みた。なお土砂災害の発生データは福岡県砂防課より提供いただいた「福岡県土砂災害事例一覧表（1992-2017.7）」より福岡県の土砂災害の発生地点と発生時刻の履歴データより、筑後地方の AMeDAS 周囲 10km 地点で 1994 年

4月から2017年7月までに発生した土砂災害56件を抽出した。この期間に各地点の周囲10km圏内で土砂災害を引き起こした降雨の件数は、朝倉で11件、黒木で17件、久留米で1件、大牟田で10件、耳納山で15件、柳川で2件であった。図8において円形黒塗りが今回検証に用いたAMeDAS地点、円形で示している範囲がAMeDASから10km圏内であり、三角形黒塗りで表示されているのが対象としたAMeDASより10km圏内に発生した土砂災害を表している。今回の解析ではこのうち朝倉と、比較のために降雨の件数が多い黒木を解析対象とした。

(2) 累加雨量の計算

式(5)から求めたデータに「福岡県土砂災害事例一覧表(1992-2017.7)」から2017年6月までの履歴データを元に、土砂災害の発生事例及び不発生事例に分けた。さらに不発生データの数が多くなる事で極端な偏りが生じ、学習結果が不発生になってしまう可能性が高いため、累加雨量が60mm以下の降雨については不採用とした。これにより本論で用いた不発生データは朝倉で82件、黒木で85件となった。

(3) ANNによる予測

ANNによる予測にも前項で求めた累加雨量と発生不発生の関係を適用した。さらに学習データには1994年から2009年まで、検証には2010年から2014年まで、テストには2015年から2017年までの発生不発生と $R_{max}(\tau)$ からなるデータを入力層に与え学習検証及びテストを行った。

(3) SVMによる予測

ANNによる予測と同様のデータを用いて学習検証及びテストを行った。

4. 結果と考察

(1) 土砂災害発生限界降雨

図9にAMeDASの朝倉の発生上限と不発生時の下限、発生時の下限と不発生の上限の差を、図10に黒木の発生上限と不発生時の下限、発生時の下限と不発生の上限の差を示す。図9のAMeDAS朝倉には100分、240分、320分の3箇所極値らしきものが見られたが、明確な「くびれ」とは言い難い。

それに対し図10のAMeDAS黒木には180分に明確な「くびれ」が見られた。

以上のようにAMeDAS朝倉は明確な到達時間 T_s が見出されなかったが、AMeDAS黒木では180分であった。

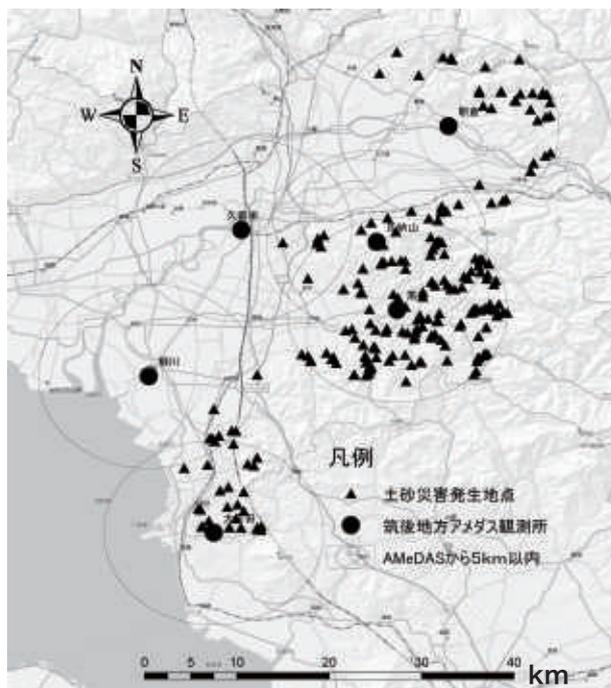


図8 筑後地方に設置されたAMeDASの観測所とその近傍で発生した土砂災害

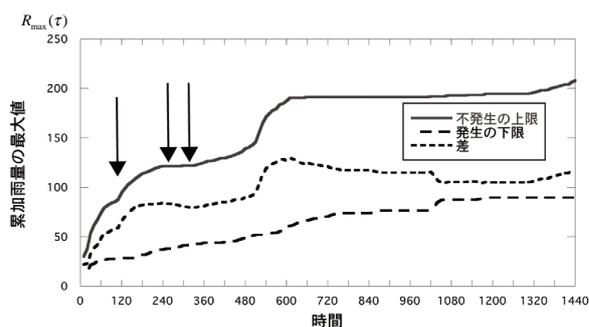


図9 AMeDAS朝倉における発生の下限と不発生の上限、及びその差

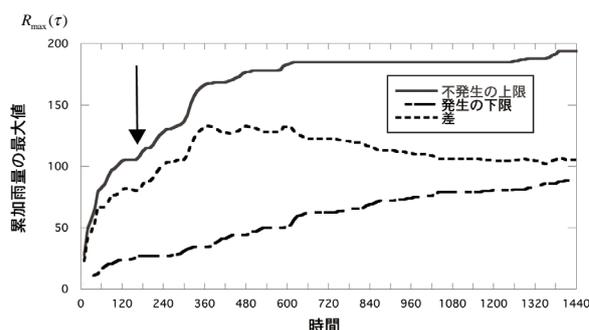


図10 AMeDAS黒木における発生の下限と不発生の上限、及びその差

(2) ANNを用いた土砂災害発生予測

学習、検証及びテストを行った結果得られたAMeDAS朝倉の混同行列と混同率を表1~3に示す。ここで学習の的中率0.95%, CSI=0.667かつ見逃し率50%であり、検証では的中率80%, CSI=0かつ見逃し率100%, テストでは的中率100%, CSI=1.0かつ見逃し

表 1 ANN(学習)による AMeDAS 朝倉の混同行列.

実測↓	不発生	発生	←予測
不発生	52	0	
発生	3	6	

表 2 ANN(検証)による AMeDAS 朝倉の混同行列.

実測↓	不発生	発生	←予測
不発生	16	3	
発生	1	0	

表 3 ANN(テスト)による AMeDAS 朝倉の混同行列.

実測↓	不発生	発生	←予測
不発生	11	0	
発生	0	1	

表 4 ANN(学習)による AMeDAS 黒木の混同行列.

実測↓	不発生	発生	←予測
不発生	43	0	
発生	0	15	

表 5 ANN(検証)による AMeDAS 黒木の混同行列.

実測↓	不発生	発生	←予測
不発生	25	3	
発生	0	2	

表 6 ANN(テスト)による AMeDAS 黒木の混同行列.

実測↓	不発生	発生	←予測
不発生	12	2	
発生	0	0	

し率 0%であった. なおテストに含まれた平成 29 年 7 月九州北部豪雨での土砂災害発生は正しく予測していた.

なお, 上記の CSI は Circulation Success Index (スレットスコア) であり, 全体事象の数から不発生と予測して不発生だった事象の数を引いたものを分母とし, 発生と予測して発生だった事象の数を分子としている.

見逃しは, 発生しないと予測して発生した事象を表し, 見逃し率は, 見逃した数を実際に発生した事象の数で除したものである.

また, 空振りとは, 発生と予測した場合に実際には不発生であった事象であり, 空振りとなった事象の数を発生した事象の数で除したものである.

scikit-learn ライブラリの最適化では, 中間層は 2 層で, 1 段目 100 個, 2 段目 10 個, 最適化手法は準 Newton 法が最も良好と判断された.

表 7 SVM(学習)による AMeDAS 朝倉の混同行列.

実測↓	不発生	発生	←予測
不発生	52	0	
発生	0	9	

表 8 SVM(検証)による AMeDAS 朝倉の混同行列.

実測↓	不発生	発生	←予測
不発生	15	4	
発生	0	1	

表 9 SVM(テスト)による AMeDAS 朝倉の混同行列.

実測↓	不発生	発生	←予測
不発生	10	1	
発生	0	1	

表 10 SVM(学習)による AMeDAS 黒木の混同行列.

実測↓	不発生	発生	←予測
不発生	43	0	
発生	0	15	

表 11 SVM(検証)による AMeDAS 黒木の混同行列.

実測↓	不発生	発生	←予測
不発生	20	8	
発生	1	1	

表 12 SVM(テスト)による AMeDAS 黒木の混同行列.

実測↓	不発生	発生	←予測
不発生	13	1	
発生	0	0	

次に AMeDAS 黒木の混同行列と混同率を表 4~6 に示す. 学習の的中率 100%, CSI=1.0 かつ見逃し率 0%であり, 検証では的中率 90%, CSI=0.4 かつ見逃し率 0%, テストでは的中率 85.7%, CSI=0 かつ見逃し率は発生した事象の数がゼロであったため算定不能であった. また, 中間層は 3 層となり, 1 段目 100 個, 2 段目 100 個, 3 段目 10 個, 最適化手法は準 Newton 法が最適と判断された.

これらの結果から, 見逃しや空振りが存在し予測精度が十分に確保されていないため, 今後は学習データと検証用データを入れ替え, 目的変数を見逃し率最小として, さらに最適化を行う必要がある.

(3) SVM による予測

ANN による予測と全く同様のデータを入力とした. SVM のカーネルは, 特徴空間に写像するための膨大な内積計算を回避するために考案されたカーネル

トリックと呼ばれる方法のために用いられ、カーネルを適切に選ぶことにより汎化能力が向上するとされている⁸⁾。

今回はカーネル関数に汎用的なカーネルである非線形対応のラジアル基底関数 (RBF) を用い、コストパラメータ C のみを動かして学習し、検証用データを見逃し率が最小になるように手動で最適化した。ここで、コストパラメータ C は、誤分類をどの程度許容するかを決めるパラメータである。

その結果、朝倉では表 7～9、黒木では表 10～12 のように、混同行列が得られ、これから朝倉の学習の的中率 100%, CSI=1.0 かつ見逃し率 0%, 検証の的中率 80%, CSI=0.2 かつ見逃し率 0%, テストの的中率 90.9%, CSI=0.5 かつ見逃し率 0% となった。

さらに黒木においては学習の的中率 100%, CSI=1.0 かつ見逃し率 0%, 検証の的中率 70%, CSI=0.1 かつ見逃し率 50%, テストの的中率 92.9%, CSI=0 かつ見逃し率は評価できない結果となった。

以上により朝倉における予測は ANN の学習と検証で見逃しが多かったことにより SVM の方がアドバンテージがあるが、黒木においては、SVM の検証では見逃しと空振りが多かったため、ANN の方がアドバンテージがあると考えられる。

5. 結論

朝倉における土砂災害の発生限界降雨を規定する累加雨量の累加時間を、SEAM から図解法で求めることは困難であった。しかし、ANN では土砂災害の発生に関してはある程度の予測精度が得られ、SVM ではほぼ実用的な精度が得られた。今後は、データを増やし、また検証方法を工夫することにより、さらに予測精度の向上をはかりたい。

謝辞：土砂災害の発生データ（福岡県土砂災害事例一覧表（1992-2017.7））は福岡県砂防課より提供頂いた。記して謝意を表す。

参考文献

- 1) Moriyama, T. and Hirano, M., ESTIMATE FOR CUMULATIVE RAINFALL OF CRITICAL RAINFALL AND PREDICTION OF LANDSLIDES IN CHIKUGO DISTRICT, FUKUOKA PREFECTURE, JAPAN: Proceedings of the 21st IAHR-APD Congress 2018, Yogyakarta, Indonesia, 2018, 掲載予定。
- 2) 千木良雅弘：2017年九州北部豪雨災害調査報告書，京都大学防災研究所，pp. 26-27, 2018.
- 3) 平野宗夫，疋田誠，森山聡之：活火山流域における土

石流の発生限界と流出規模の予測，第30回水理講演会論文集，pp. 181-186, 1986.

- 4) 平野宗夫，岩本賢，原田民四郎：人工降雨による土砂災害の発生機構に関する研究，1977年第31回土木学会年次学術講演会概要集，pp. 181-186, 1977.
- 5) 平野宗夫：土石流の発生とその予測：1994年土木学会論文集 pp. 1-7, 1994.
- 6) 森山聡之，平野宗夫，上松泰介，川原恵一郎，白川朋道：ニューラルネットワークを用いた土石流発生予測について，：水工学論文集，第36巻，pp. 705-708, 1992.
- 7) Corinna Cortes, Vladimir Vapnik: Support-Vector Networks, Machine Learning, 20, pp. 273-297, 1995.
- 8) 阿部重夫：パターン認識のためのサポートベクトルマシン入門，森北出版，2011.

(2018.5.18 受付)