

# 気象ビッグデータを活用した土砂災害予測技術の開発

佐賀大学 農学部 生物資源科学科

宮本 英揮

# 気象ビッグデータを活用した土砂災害予測技術の開発

佐賀大学農学部 宮本 英揮

## 1. はじめに

集中豪雨の増加・激化により風水害が多発するなか、膨大な土砂災害危険箇所を抱える我が国では、ハード対策を主体とした防災対策に加え、情報通信技術(ICT)やビッグデータを活用した減災対策の確立と、その早期社会実装を求める気運が高まっている。

土砂災害の7割を占める突発的な斜面崩壊は、土中への雨水の浸透が引き金となって、斜面が崩落する事象である。ワイヤー式伸縮計に代表される既存の監視技術は、滑動が比較的ゆっくりとした地すべりや、崩壊の起点となる源頭部の位置が明らかな場合に有用な検知手法となるものの、測定原理上、突発的に生じる表層部の崩壊を検知することは難しい。斜面崩壊を効果的に予測するためには、その引き金をひく事象、すなわち、土壌中の水分の動態や量的な時空間変動を予測し、それに基づき危険度を評価する技術の確立する必要がある。

本研究では、斜面土壌内の水分の多点リアルタイム計測を可能とするIoT(モノのインターネット)技術と、気象庁が提供する膨大な降水量データとを組み合わせることで、新たな土砂災害予測技術を確立することを最終目標と定め、その前段として、研究代表者が調査・研究を推進中の熊本地震・土砂災害現場において、次の2点について検討した。すなわち、(1)既設の土壌水分センサーネットワークに雨量計を併設し、土壌雨量指数(SWI)のピンポイント予測のためのデータ収集に着手するとともに、(2)気象庁による降水量データを活用した土壌雨量指数および土壌水分量の予測アルゴリズムの構築とその予測値の妥当性を検討した。

## 2. 方法

### 2.1 研究対象斜面および斜面計測の概要

2016年4月に発生した熊本地震によって、大規模土砂災害が多発した熊本県阿蘇郡南阿蘇村のY山の南西側急斜面を、本研究の研究対象斜面とした。この急斜面には、熊本地震によって大規模な地割れが形成されており、その表層には黒ボク土と呼ばれる火山灰土が厚く堆積している。山裾の国道325号線沿いには、約1,200人の

居住区が存在するため、雨水の地下浸透に伴う土塊重量の増加と、それに起因する地割れの拡大による斜面崩壊の発生が危惧されている。

基盤地図情報ダウンロードサービス(国土地理院)より入手した 5 m メッシュ DEM データ(GML 形式)に基づいて行った地表流解析の結果を考慮して、斜面内の 5 地点に統合型 IoT システム(写真 1)、すなわち、ゲートウェイとなる親機 1 台、土壌水分・加速度・大気環境測定のための子機 4 台、降水量計測のための子機 1 台等を分散配置し、これらをクラウド型 IoT プラットフォーム上で制御することとした。そして、土壌水分・加速度センサー、大気圧センサー、温度・湿度センサー、雨量計、日射センサー、Web カメラ等を子機に接続したうえで、それらによる全測定データをクラウド上に集約した。



写真 1 統合型 IoT システム

## 2.2 気象ビッグデータを利用したデータ駆動型予測モデルの構築方法

土壌水分量の予測モデルを構築するためには、センサー埋設地点における数年分の測定データが必要であり、測定に着手して間もない本研究では、十分な測定データを入手することができない。そこで、本研究では、土壌水分量および SWI の予測モデル構築の前段として、両者と高い相関性を有する降水量の予測モデルを構築し、その値に基づき SWI を予測する 2 つのアプローチを検討することとした。




図 1 降水量観測点

熊本県阿蘇郡南阿蘇村の地域気象観測所の降水量および SWI を予測対象と定め、2016~2019 年の計 4 年分の 1 時間あたりの降水量のデータを入手した。2016~2018 年の 3 年分を学習用データ、2019 年の 1 年分を検証用データと定めた。現在を起点とし、それよりも過去の時間を  $I$ 、未来の時間を  $J$  とそれぞれ定義したうえで、 $I$ (= 0, 1, 2, 3, 4, 5, 11, 23, 35, 47)時間前の降水量を説明変数、予測対象となる  $J$ (=1, 2, 3)時間後の降水量を目的変数とし、教師あり機械学習により各  $J$  における  $I$  の異なる 10 種、すなわち、計 30 種の降水量予測モデル(以後、1 地点モデルと称す)を構築した。比較対象として、前述の地点を中心とした半径 100 km 以内の計 83 地点(図 1)の気象

序観測点の降水量データを統合し、それら全てを説明変数とした場合についても、 $I$  および  $J$  の異なる計 30 種の降水量予測モデル(以後、83 地点モデルと称す)を構築した。2019 年の降水量の観測値( $P_m$ )に対する 2 種のモデルによる降水量の予測値( $P_1$ ,  $P_{83}$ )の精度を  $R^2$  および RMSE に基づいて評価するとともに、最適な予測値が得られた  $I$  において、3 段タンクモデルに基づき 1~3 時間後( $J=1, 2, 3$ )の SWI を計算し、 $P_m$  に基づくそれと比較した。

### 3. 結果と考察

計 10 種の  $I$  における 1 地点モデルの予測値( $P_1$ )は、降水のたびに急増した後に、徐々に減少し、その変化は  $P_m$  と連動した(図は割愛)。 $J=1$  における  $P_1$  を  $P_m$  と比較した結果、いずれの  $I$  においても  $R^2$  および RMSE は概ね同等の水準にあったが、それらの中でも  $I=2$  における予測精度が最良であった。しかしながら、 $I=2$  においても  $R^2$  は 0.5 未満であり、予測精度は必ずしも高いとは言えなかった。同様の結果は、 $J=2$  および 3 においても認められた。

一方、83 地点モデルの予測値( $P_{83}$ )は、 $P_1$  と同様、 $P_m$  と連動した  $I$  条件が多く認められた(図は割愛)。ただし、 $I=47$ 、すなわち、全 83 地点の過去 48 時間分の計 3,984 個の降水量を説明変数とした場合、 $P_{83}$  と  $P_m$  との差が大きくなったように、 $I$  が大きいほど  $R^2$  は低下し、逆に RMSE は大きくなった。このことは、学習用データの点数を増やしたり、説明変数の数を増やしたりすることが、必ずしも予測精度の向上に繋がらないことを示す。同様の結果は、 $J=2$  および 3 においても認められた。

$P_m$  を最も良い精度で予測した  $I$  における  $P_1$  と  $P_{83}$  を比較した結果、83 地点モデルによる予測精度が高かった(図 2)。 $J=1$  では、 $I=2$  において  $P_1$  の精度が、また  $I=0$  において  $P_{83}$  の精度がそれぞれ最良となり、両者は共に  $P_m$  と連動した(図 2)。ただし、前者に比べ後者による  $R^2$  が大きく、また RMSE が小さかったことから、83 地点モデルの予測精度がより高いと判断された。同様の傾向は、 $J=2$  および 3 にも認められた。さらに、 $J$  が大きい、すなわち、より先の未来ほど低下することが判明した。

最適化した  $I$  における  $P_{83}$  に基づく SWI は、 $P_m$  に基づくそれと連動して増減したものの、全体的に過小評価される傾向が認められた(図 3)。比較的降水量が多かった期間(DOY175~203)に着目すると、各モデルにより予測された SWI は  $P_m$  に基づくそれと連動した変化を示したが、 $P_m$  に基づく SWI を過小評価する傾向が全期間に認められた。なかでも、土砂災害警戒基準値を超過した DOY180 において基準値未満

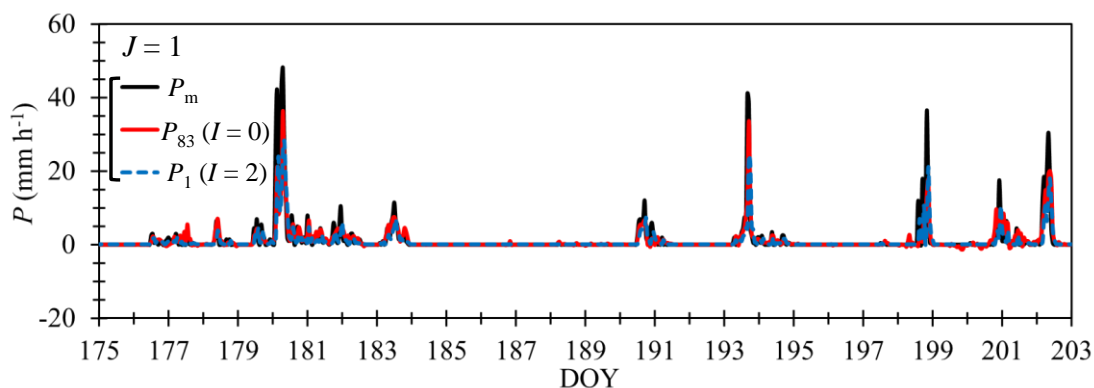


図2 降水量の観測値( $P_m$ )と83地点および1地点モデルによる1時間後( $J=1$ )の予測値( $P_{83}$ ,  $P_1$ )




図3 降水量の観測値( $P_m$ )と83地点モデルによる1~3時間後( $J=1\sim3$ )の予測値( $P_{83}$ )に基づく土壌雨量指数(SWI)の経日変化

の数値を示したことは、本研究における予測手法の更なる改良の必要性を示すものと考えられる。

#### 4. おわりに

本研究では、説明変数として与える降水量の組合せの異なる降水量予測モデルを構築したうえで、南阿蘇村の降水量および土壌雨量指数(SWI)を予測した。単一地点の降水量をもとに構築した予測モデルよりも、計83地点の降水量をもとに構築した予測モデルによる降水量の予測精度が高かった。ただし、予測された降水量をもとに、SWIを予測した結果、土砂災害警戒基準値を超過したDOY180において基準値未満となり、リスクを過小評価したことから、予測精度の更なる向上のためのモデルの改良が必要であると考えられる。今後は、蓄積した土壌水分量の測定データに基づき、急斜面の土壌水分量および土砂災害危険度のリアルタイム予測に取り組む予定である。