

植物の生体電位を用いた土のせん断応力予測モデル

九州大学 学○松田昂大 正 笠間清伸 古川全太郎 八尋裕一

1. はじめに

近年、豪雨や地震などによる山間部の表層崩壊が増加傾向にある。今後も予想される大きな被害を防止するため、そのメカニズムを定量化し、検知に役立てることが期待される。その一つの手法として、植物の生体電位に着目した。植物の生体電位とは、植物の生命維持に関わる情報伝達によって生じるものであり、温度、湿度、照度など様々な環境変化によって変動することが明らかになっている²⁾。本文では、深層学習の一種である LSTM (Long Short-Term Memory) を用いて、一面せん断試験中に計測した植物の生体電位反応からせん断応力の経時変化を予測する手法を検討した。

2. LSTM モデルの概要

LSTM は RNN (再帰型ニューラルネットワーク) における勾配消失問題を解決し、長期依存による学習を可能とした深層学習の一種である。³⁾ ゆえに、前後関係が重要な時系列データの予測によく使用される。

入力データには、植物を含む供試体を対象とした一面せん断試験中に計測した植物の生体電位反応を用いた。植物には、日本で最も広く分布しているスギを採用し、生体電位反応の計測箇所は、根系、茎、葉の3か所とした。計測データは、**図1**のように初期値が $0 \mu\text{V}$ になるように設定し、絶対値をとる処理を LSTM モデルに入力する前に行った。詳細な実験方法は、参考文献 4) に記す。

学習対象とする出力データは、一面せん断試験中に供試体に加わるせん断応力とした。なお、学習に用いるデータは全て 0.5 s ずつの間隔で計測した。

図2に本研究で構築した LSTM モデルの概略図を示す。植物の生体電位反応は、根系、茎、葉で計測したデータをそれぞれ i 番目から $i+2p-1$ 番目のデータで区切り、「3行×2列」の行列を形成し、せん断応力1点を予測するのに必要な入力データの

の長さを $2p$ (入力データに用いる計測時間 = p (s)) とした。その行列を1層とした隠れ層中の LSTM ブロックに入力する。LSTM ブロックは、過去の学習結果を記憶し、次の学習に与える影響を調整する仕組みとなっており、ブロック数は任意で設定する。活性化関数には \tanh 関数、勾配降下法の最適化アルゴリズムには adam を用いた。最後に、各 LSTM ブロックで得た結果より、 $i+p$ 番目 (0.5 s 後) のせん断応力を出力する。出力層の活性化関数は、linear を用いた。以上の学習を $i=1$ から繰り返し行うモデルを用いて、各供試体のデータの前半7割で訓練し、後半3割をテストデータとして予測値を求める。予測値と実測値を比較することで、LSTM モデルの予測精度を評価するが、より良い予測精度を求めるためには、LSTM モデルの構築において、いくつかのパラメータの調整が必須である。そのパラメータ調整の結果を次章で述べる。なお、パラメータ調整の際に用いる予測精度の評価指数は平均絶対誤差 MAE および決定係数 R^2 とした。




図1 植物の生体電位反応

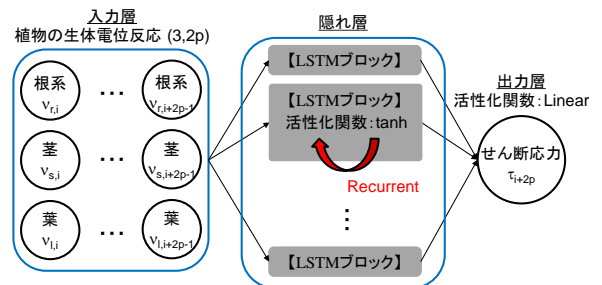


図2 構築した LSTM モデルの概略図

キーワード 表層崩壊、検知、植物、生体電位、機械学習、LSTM

連絡先 〒819-0395 福岡県福岡市西区元岡 744 番地ウエスト 2 号館 11 階 九州大学工学府土木工学専攻防災
地盤工学研究室 TEL 092-802-3384

3. LSTM モデルの構築結果

調整するパラメータは、入力データに用いる計測時間 p (s)、LSTM ブロック数、学習回数、バッチサイズ、adam の初期学習率の5つとした。表1に LSTM ブロック数、学習回数、バッチサイズ、初期学習率の調整結果を示す。一方、入力データに用いる計測時間 p (s)は値が大きいくほど、精度が良くなった。しかし、 p (s)が大きくなるとともに予測点数が少なくなり、その影響で精度が良くなった可能性がある。そのため、一面せん断試験で得た他の結果との関係性も考察した。図3の青線で実測値の最大せん断応力と訓練データの学習精度の関係を示したところ、最大せん断応力が大きいほど、学習精度が悪くなる傾向があった。

図3と同様のことをテストデータにおいて入力データに用いる計測時間 p (s)を変えて行い、その決定係数と p (s)の関係を図4に示す。その結果、 $p=600$ s (試験時間全体の約67%)としたとき、訓練データと最も同じ傾向を示した(図3の赤線)。ゆえに、入力データに用いる計測時間 $p=600$ sとしたとき、最も良い精度で予測値を出力していることが示唆される。ゆえに、 $p=600$ sを最適なパラメータと評価することにした。

図5に上記で調整したパラメータを用いた LSTM モデルでの予測結果の一例を示す。各供試体で予測精度を評価したところ、全供試体で決定係数は0.99となったが、平均絶対誤差は0.066~0.29 (平均値=0.16)となり、精度にばらつきがみられた。そのため、精度にばらつきが生じないモデルの構築するための考察が今後の課題となる。

4. まとめ

本文において、LSTM を用いて、植物の生体電位反応からせん断応力を予測する手法を検討した結果、以下の知見を得た。

- 1) 学習精度は鉛直拘束圧が大きいほど悪くなり、テストデータの予測精度は入力データに用いる計測時間 $p=600$ sにしたとき、訓練精度と最も同じ傾向を示した。
- 2) 入力データに用いる計測時間 $p=600$ s、LSTM ブロック数=50、学習回数=400、バッチサイズ=4、初期学習率=0.001で LSTM モデルを構築すると、予測精度は $MAE=0.16$ 、 $R^2=0.99$ となった。

謝辞: 本研究は、JSPS 科研費 JP19K15089 の助成を受けたものです。ここに感謝の意を表します。

参考文献: 1) 大津宏康ら: 短期間集中豪雨に起因する斜面崩壊機構に関する研究、Journal of the Society of Materials Science, Japan, Vol.63, No.3, p.271~278, Mar.2014. 2) 新保達也ら: 風速変化に対する植物生体電位反応、電学論 E, 126-E, 7, 370-375, 2006. 3) 張曉齊ら: オープンデータと LSTM を用いた犯罪発生の予測及び時間的近接性における考察、情報学, 16 巻 1 号, 56-70, 2019. 4) 松田昂大ら: 原位置一面せん断試験によるスギ根系の地盤補強効果と生体電位の関係、環境地盤工学シンポジウム, 2021.

表1 パラメータの調整結果

パラメータ	値
LSTMブロック数	50
学習回数	400
バッチサイズ	4
初期学習率	0.001




図3 最大せん断応力(実測値)と学習精度、予測精度 ($p=600$ s) の関係




図4 入力データに用いる計測時間の長ささと図3のグラフの決定係数の関係

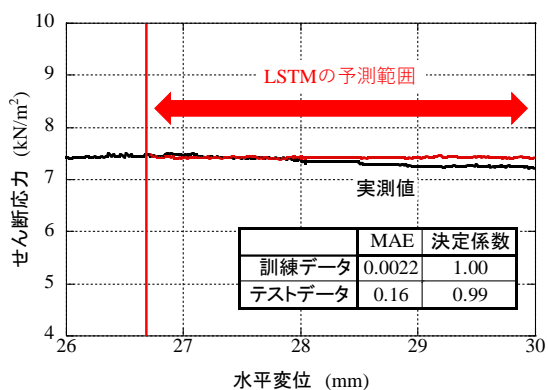


図5 パラメータ調整後の LSTM モデルにおけるせん断応力の予測結果の一例