

深層学習と物理モデルの組み合わせによる土の繰返しせん断特性の表現

京都大学工学部 学生会員 ○ショーバック ジェイコブ英輔
 京都大学防災研究所 正会員 後藤 浩之
 京都大学大学院工学研究科 学生会員 栗間 淳
 基礎地盤コンサルタンツ株式会社 正会員 三上 武子
 関東学院大学 正会員 吉田 望
 京都大学防災研究所 正会員 澤田 純男

1. はじめに

耐震設計において地盤の非線形応答を正確に予測することは重要である。しかし、地盤の非線形応答は複雑であるため、任意の試料・状況における応答を完璧に再現することは難しい。このようにモデル化が困難とされてきた問題に対して、機械学習の一種である深層学習が大きな成果を上げつつある。そこで深層学習を用いて地盤の非線形応答をより正確に予測する手法を検討する。本研究では、深層学習を用いて土の繰返しせん断特性を再現したモデルを構築する。また、深層学習は未学習の入力に対する出力が不安定であるため、物理モデルを併用した組み合わせモデルを構築する。

2. データセット

主に粘土からなる49試料のデータを用いた¹⁾。1試料あたり、せん断ひずみの大きさが異なる12ステージ程度の繰返しせん断試験結果と土質特性および土の状態に関するデータが含まれている。繰返しせん断試験結果からせん断応力とせん断ひずみの時系列データを用い、土質特性等のデータは繰返しせん断試験時の拘束圧、試料の採取深度、N値、N1値、初期せん断剛性、湿潤密度、自然含水比、粒度組成（砂、シルト、粘土）、液性限界、塑性限界の12データを用いる。

3. LSTM (Long short-term memory) モデル

時系列データ予測に特化した深層学習の手法である Long short-term memory^{2),3)} (LSTM) を用いてせん断応力の時系列データと土質特性等のデータを入力としてせん断応力を出力とするモデルを構築する。モデルの全体構造を図1, LSTM部(NN_{mid})の構造を図2に示す。 γ_t, τ_t は時刻 t でのせん断ひずみとせん断応力、 d は土質特性等のデータである。 NN_{in} は2層の全結合構造であり、 NN_{out} も1層の全結合構造である。




図1. LSTM モデルの全体構造

全試料は学習に用いる訓練データ(39試料)と推定精度の検証に用いるテストデータ(10試料)にランダムに分割する。損失関数には平均二乗誤差、最適化アルゴリズムにはAdam法を用いる。

以降では、学習時に用いていないテストデータにより、モデルの精度を検証する。実験結果とLSTMモデル、既存モデル(Hardin-Drnevich⁴⁾モデル:HDモデル)とを比較した履歴曲線(応力-ひずみ関係)を図3に示す。3枚の図は上から小さいひずみ(0.001%程度)、中間(0.05%程度)、大きいひずみ(2%程度)の試験における最後の繰返し載荷の結果である。

図3から、LSTMモデルでは大ひずみ域の履歴形状に不自然な凹凸が見られるが、形状がよく再現できている一方、小～中ひずみ域における精度が低い。

4. 組み合わせモデル

4.1 モデルの構造

LSTMモデルと物理モデル

(HDモデル)を組み合わせたモデルを構築する。図4に組み合わせモデルの全体構造を示す。 $\gamma_{a,t} = \frac{1}{2}\{\max(\gamma_0, \dots, \gamma_t) - \min(\gamma_0, \dots, \gamma_t)\}$ は時刻 t までの最大のせん断ひずみ振幅である。 NN は3層の全結合構造であり、重み $p_{1,t}, p_{2,t}$ を出力する。重み $p_{1,t}, p_{2,t}$ を用いてLSTMモ



図2. LSTM部(NN_{mid})の構造

図3. LSTMモデルと既存モデルの履歴曲線

デルとHDモデルの出力の重み付き平均をとり、出力 τ_t を求める。

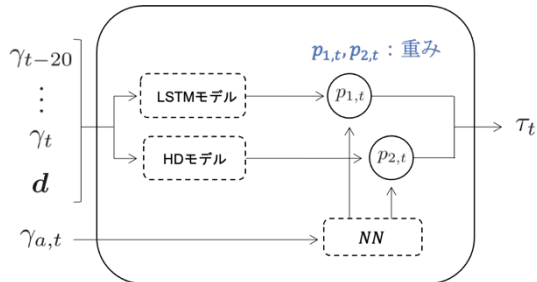


図4. 組み合わせモデルの全体構造

4.2 学習と検証

組み合わせモデルに用いる LSTM モデルは先に学習させたモデルを用い、モデルの学習時には重み $p_{1,t}, p_{2,t}$ のみを更新し、LSTM モデルは更新しない。

訓練データおよびテストデータ、損失関数、最適化アルゴリズムは LSTM モデルの学習と同様のものを用いる。

4.3 結果

テストデータを用いてモデルの精度を検証する。実験結果と組み合わせモデルと LSTMモデルを比較した履歴曲線を図5に示す。3枚の図は上から小さいひずみ (0.001%程度)、中間(0.05%程度)、大きいひずみ(2%程度)の試験における最後の繰り返し载荷の結果である。

図5から、組み合わせモデルは LSTMモデルと比べて小～中ひずみ域の精度が改善していることがわかる。また、大ひずみ域で高い精度を維持できていることがわかる。

図6は組み合わせモデル、LSTMモデル、既存モデル (HDモデル) の損失関数の結果を正規化して示したものである。S1～S5は各試料の繰返しせん断試験をひずみの大きさによって5つのグループに分けたものである。S1はひずみが最小の試験のグループ、S5はひずみが最大の試験のグループである。図6から、S1からS3の小中ひずみ域において、組み合わせモデルは LSTMモデルよりも大幅に精度が向上していることがわかる。また、S5では組み合わせモデルは LSTMモデルよりも精度が落ちるものの、既存モデルと比べて高い精度を維持できている。




図5. 組み合わせモデルと LSTM モデルの履歴曲線




図6. 組み合わせモデル、LSTM モデル、既存モデルにおける正規化した損失関数

以上より、組み合わせモデルは LSTMモデルのみを用いる場合よりも小～中ひずみ域における精度が改善し、モデルの表現力が向上したと考えられる。

図7に示すのは最大ひずみ振幅 γ_a に対する重み付き平均の重み p である。

図7から、LSTMモデルの精度が高い大ひずみ域は LSTMモデルの重みが大きく、小～中ひずみ域では HDモデルの重みが大きい。その結果、LSTMモデルより精度が向上したと考えられる。




図7. LSTM モデルと HD モデルの重み p

5 まとめ

深層学習を用いて土の繰返しせん断特性を表現するモデル (LSTM モデル) を構築した。LSTM モデルは大ひずみ域における精度がよい一方、小～中ひずみ域における精度が低い傾向が見られた。

次に、LSTM モデルと物理モデルを併用した組み合わせモデルを構築した。組み合わせモデルは LSTM モデルに比べ小～中ひずみ域における精度が改善し、モデルの表現力が向上した。

以上より、深層学習と物理モデルの組み合わせにより、高い精度で予測可能なモデルを構築できる可能性があることがわかった。今後はモデルの改良や、他の深層学習手法を検討して精度の向上をすること、繰返し特性以外への適用を考えている。

参考文献

- 1) Ichii, K & Mikami, T. :Cyclic threshold shear strain in pore water pressure generation in clay in situ samples, Soils and Foundations Vol.58, pp.756-765, 2018.
- 2) S. Hochreiter and J. Schmidhuber. Long short-term memory, Neural computation, 9(8):1735-1780, 1997.
- 3) F.A. Gers, J.A. Schmidhuber, and F.A. Cummins. Learning to forget: Continual prediction with lstm, Neural computation, 12(10):2451-2471, 2000.
- 4) B. Hardin and V.P. Drnevich. Shear modulus and damping in soils: design equations and curves, Journal of Soil Mechanics & Foundations Div, 98(sm7):667-692, 1972.