

機械学習を用いた地すべりの地下水解析の事例紹介と今後の課題

(株)藤井基礎設計事務所 ○斉藤龍太、藤井俊逸、新宮敦弘
システムアトリエブルーオメガ 木村忍

1. はじめに

地すべり地の地下水位の挙動はタンクモデルで解析する場合が多い。タンクモデルはシンプルで有用であるが、係数設定等に困惑することが多い。現場ではモデルに反映しにくい複雑な要素が含まれるためと推測される。

そこで、事象を単純化しようとするのではなく、複雑なまま取扱うことができるのであれば、逆に解析そのものは単純化できないかと考えた。その一つの試みとして、昨今の技術革新により、比較的容易になった機械学習による地下水解析を試みたため、今回その事例を紹介する。

2. 現地状況と孔内水位解析実施の背景

島根県松江市の造成地において、谷埋め盛土を主体とする地すべりが発生した。地すべりの中心付近には旧谷地形があり、この旧谷地形に沿って地すべり地内に流れ込む地下水が、地すべりの誘因となっていた。

住宅地が隣接している地すべりであり、観測期間中の降雨により、伸縮計で2.9mm/日の確定変動レベルの変位が観測されたことから、緊急的に排水ボーリング工事を実施した。

排水ボーリング後も観測を継続したため、工事前後の孔内水位の変化を観測できた。そこで、排水機能効果なるべく定量的に示すため、工事前の孔内水位を解析により再現した。工事をしなかった場合の孔内水位について解析結果からシミュレーションし、実測の孔内水位と比較し、排水機能の評価を試みた。

3. 解析手法の概略と結果

(1) 機械学習の概略

孔内水位の解析には、機械学習の一手法であるニューラルネットワークモデルと呼ばれる学習アルゴリズムを用いた。ニューラルネットワークモデルは、脳の神経ネットワークを模して考案されたアルゴリズムであり、




図7.5：2層フィードフォワードニューラルネットワークモデル

図-1 ニューラルネットワークモデルの模式図¹⁾

脳の神経細胞からヒントを得て考案されたニューロンモデルを素子として、それらを幾重にも組み合わせた集合体のモデルである（図-1）。

ニューラルネットワークモデルに、入力データを与えると初期パラメータにより計算された値が出力される。この出力値がお手本となる教師データに近づくように、モデル内の重み付け係数を自動的に調整することから、大量のデータを用いて重み付け係数の値を収束させる。

係数の調整が終了したモデルに、同一の入力データを与えると、同一の出力データが得られる。そのため、タンクモデル等と同様に、学習済みのニューラルネットワークモデルを用いることで、現地特性を反映させた地下水解析モデルが作成できると考えた。

(2) 解析方法

孔内水位の解析は下記の手順により実施した。

- 1) 解析に用いる孔内水位として、地すべり中央付近にあるボーリング孔を選定。
- 2) 入力データ、教師データの選定および機械学習。
- 3) 解析モデルによる出力データ（解析水位）の確認。
- 4) 排水ボーリング工事後の入力データを用いて、工事をしなかった場合の水位を推定（推定水位）。
- 5) 推定水位と観測した孔内水位を比較。

(3) 解析条件

解析モデル作成に使用した入力データを下記に示す。

- 1) 1時間雨量（松江）：気象庁データ
- 2) 1時間雨量（鹿島）：気象庁データ
- 3) 1時間雨量（現場周辺）：弊社で別途観測中のもの
- 4) すべり面付近の歪計変位量

教師データは、孔内水位の観測値を用いた。

4. 解析結果と考察

図-2に、今回の現場で作成した地下水解析モデルによる解析水位と観測水位を示す。解析水位は観測水位に比べるとやや高い水位を示す傾向にあるが、豪雨後のピーク水位や、その後の低下傾向は比較的に似ている。定性的ではあるが、シミュレーションとして一定の信頼性があると判断した。定量的な評価の試みとして、解析水位をランダムに200点を抽出し、同時刻の観測値と比較したところ、学習時の精度は96.13%となった。

図-3に、推定水位と観測水位を示す。推定水位と比較すると、観測水位は降雨直後にピーク水位を観測した後、低下速度が向上している。推定水位と観測水位を、同グラフに併記することで、発注者にも排水ボーリングの効果を分かりやすく提示することが出来た。




図-2 排水ボーリング工事前の機械学習により作成した解析水位と観測水位




図-3 排水ボーリング後の学習済みのニューラルネットワークモデルによる推定水位と観測水位

推定水位の評価には下記の課題も残った。まず、教師データとして採用した期間中の雨量は、台風など豪雨によるものであり、推定水位をシミュレーション時の雨量は、降雪期によるため、降水条件と地下水位の関連付けが異なる可能性がある。図-3内の2018年2月16日付近の観測水位が推定水位を上回ったのは、降雪の影響を解析に反映出来なかったためと推測される。

次に、入力データの選定である。今回のケースでは、地すべりが運動中に孔内水位が低下しにくい傾向が見られたため、すべり面付近にあたる歪計の変位量を入力データに加えた。その結果、降雨量だけの場合に比べて、歪計の変位量を加えた方が、孔内水位の低下速度の解析精度が向上した。ただし、推定水位のシミュレーション時には、入力データである歪計の変位量は、排水ボーリングが機能した「運動していない」状態のパラメータであり、厳密な意味では、前提条件が変わってしまっている。地すべり運動量を入力データに選定した場合には、そのパラメータの影響も事前に評価する必要がある。

5. おわりに

歪計の変位量を入力データに加えることで解析精度が向上したことは、地すべり運動と孔内水位には、一定の関係があることを示唆する結果と思われる。このような過程から、孔内水位と地すべり運動を関連させる新モデルを立案し、新発見のきっかけとなる可能性がある。

今回、機械学習による解析を実施して痛感したことは、人間がわからないことは機械でも再現できないということである。特に自然現象は非定型な現象であり、非定型であることは AI 技術が発展したとしてもカバーできない分野だと言われている。最終的に判断するのは人間である。その意味で、技術のブラックボックス化を避けるためにも生身の人間の技術力向上が望まれる。

《引用・参考文献》

- 1) 伊藤真著:Python で動かして学ぶ! あたらしい機械学習の教科書, p256, 2018.1.