

(25) 機械学習を用いたシールドマシンの自動操縦モデルの曲線区間への拡張

久保田 恭行¹・矢吹 信喜²・福田 知弘³

¹学生会員 大阪大学 大学院工学研究科 環境エネルギー工学専攻
(〒565-0871 大阪府吹田市山田丘 2-1)

E-mail: kubota@it.see.eng.osaka-u.ac.jp

²フェロー会員 大阪大学教授 大学院工学研究科 環境エネルギー工学専攻
(〒565-0871 大阪府吹田市山田丘 2-1)

E-mail: yabuki@see.eng.osaka-u.ac.jp

³正会員 大阪大学准教授 大学院工学研究科 環境エネルギー工学専攻

シールドトンネルの工事では、掘進中のシールドマシンの位置と計画線形の間に偏差が生じる。この際、偏差を緩やかに計画線形に戻すために目標線形を作成し、これに沿って掘進する操作を行う必要がある。しかし、シールドマシンを制御することは難しいことや、掘進管理者とオペレータは高齢化し、熟練した技術力が今後、失われることが懸念される。このため、AIを用いてシールドマシンの操作を自動化することが求められるが、筆者らの提案手法や関連研究の手法では計画線形が曲線である区間を対象に、目標線形に沿って掘進する操作パラメータを自動算出できなかった。そこで本研究では、筆者らの提案手法を基として、計画線形が直線・曲線である区間を対象に、シールドマシンの操作パラメータの最適値を自動算出する手法を開発することを目的とする。

Key Words: shield tunneling, shielded machine, automation, machine learning

1. はじめに

シールドトンネルの工事では、計画線形に沿ってシールドマシンを掘進することが基本であるが、実績線形との間に偏差が生じる。この際、生じた偏差を緩やかに計画線形に戻すために目標線形を作成し、これに沿って掘進する操作を行う必要がある。しかし、シールドマシンの姿勢や位置を制御することは難しく、時間もかかる。また、熟練した技術力を有する掘進管理者とオペレータは高齢化し、若年層が非常に少ないことから、そうした技術力は今後、失われてしまうことが懸念される。このため、熟練した技術者と同等以上の精度でシールドマシンの操作を自動化し、トンネル工事の掘進精度と生産性を向上することが求められる。

シールドマシンの操作の自動化に向け、岩下ら^①は計画線形が直線である区間を対象にシールドマシンの方向予測を行う手法を提案し、杉山ら^②はシールドジャッキの操作のタイミングを判定する手法を提案した。一方、これらの手法には、目標線形に沿って掘進するための操作パラメータを予測と評価を繰り返し、手動で決定して

いる課題がある。また、筆者ら^③は、計画線形が直線である区間を対象に、シールドマシンの操作パラメータの最適値を自動算出する手法を提案した。計画線形には直線である区間と曲線である区間があるが、筆者ら^③の提案手法には、計画線形が曲線である区間に適用できないという課題がある。そこで本研究では、筆者ら^③の提案手法を基として、計画線形が直線である区間と曲線である区間を対象に、シールドマシンの操作パラメータの最適値を自動算出する手法を開発することを目的とする。

2. シールドマシンの自動操縦モデル

(1) 従来の自動操縦モデルと課題

筆者ら^③は、計画線形が直線である区間を対象に、操作パラメータの最適値を自動算出し、その予測結果を掘進指示書の作成段階に反映する手法を提案した。提案手法である自動算出モデルの全体像を図-1に示す。自動操縦モデルに入力するデータとして、説明変数として選択されたセンシングデータと目標線形のデータがある。説




図-1 提案手法の全体像






図-2 偏差の変化量と予測区間

明変数として選択されたセンシングデータには、シールドマシンの操作パラメータ、ジャッキストロークやピッチングなどシールドマシンの姿勢を表す項目、推進力や中折圧力、カット電力など地盤の固さを表す項目など計47項目を用いている。次に、自動操縦モデルは、機械学習の手法を用いてシールドマシンの位置を予測する方向予測モデルと、最適化手法である粒子フィルタ⁴⁾を用いてシールドマシンの操作パラメータの最適値を算出する操作パラメータ最適化モデルから構成される。なお、機械学習モデルを用いて予測するシールドマシンの位置は水平偏差、垂直偏差、方位偏差である。ここで、水平偏差、垂直偏差、方位偏差とは、シールドマシンの先端の位置と計画線形との水平方向、垂直方向、方位方向の偏差である。自動操縦モデルから出力されるデータには、目標線形に沿って掘進すると予測される操作パラメータと、シールドマシンが到達する位置の予測値がある。この出力データを掘進指示書に記載する操作パラメータの指示値に活用する。

自動操縦モデルはシールドマシンの操作パラメータの指示値を示す掘進指示書の作成を補助するものである。また、現場では4-6リングの掘進ごとに人為測量を実施し、その結果をもとに掘進管理者が掘進指示書を作成することで、オペレータが指示に近づくようシールドマシンを操作している。よって、掘進指示書に示す、次の施工範囲である1-6リング先に対して、自動操縦モデルを適用することを想定している。

従来の方向予測モデルは、図-2に示すように、計画線



形が直線である区間を対象に、水平偏差、垂直偏差、方位偏差の変化量を予測する3つの機械学習モデルの予測結果を各々積算することで、1-6リング先のシールドマシンの位置を予測する。一方、計画線形が曲線である区間では、操作前後のシールドマシンの位置の変化量が同じであっても、曲率によって偏差の変化量が異なる。よって、偏差の変化量を目的変数とする従来の方向予測モデルでは、計画線形が曲線である区間で、精度良くシールドマシンの位置を予測できないという課題があった。

(2) 方向予測モデルの拡張

計画線形が曲線である区間にも適用できるように拡張するため、目的変数をシールドマシンの相対的な位置の変化量とした方向予測モデルを提案する。拡張した方向予測モデルでは、図-3、図-4に示すように、平面図での操作前のシールドマシンの進行方向を y 軸、面板の方向を x 軸、縦断面図での操作前のシールドマシンの進行方向を z 軸、面板の方向を r 軸と座標軸を作成し、シールドマシンの位置の変化量及び方位の変化量を機械学習する。よって、現在位置における説明変数として選択されたセンシングデータを機械学習モデルに入力することで、シ




図-5 訓練用データと検証用データ

ールドマシンの進行方向を基準とした座標系の軸である x 軸, y 軸, z 軸, r 軸の位置及び方位の変化量が予測される。ただし、予測される位置の変化量は、予測した地点における座標系での値であるため、シールドマシンの位置を求めるには、座標系を統一する必要がある。そこで、シールドマシンの位置の変化量を工事で用いた地図の座標系に統一し、積算することでシールドマシンの位置と計画線形との偏差を予測することとした。

3. 予測精度の評価

本章では、精度良くシールドマシンが到達する位置を予測するために、拡張した方向予測モデルの構築に用いる機械学習モデルを検討し、その予測精度を評価する。本検証では、中折装置のある単円形の泥水式シールドマシンで施工するA工事で計測したセンシングデータのうち、同一地質の掘進で計測したデータを対象とした。

本研究で扱う説明変数であるセンシングデータは、掘進中に計測した外乱の影響を受けやすいと想定される時系列データである。このため、機械学習モデルとして、説明変数にノイズが含まれるケースにも高い性能を発揮すると報告のあるSVR (Support Vector Regression) ⁹⁾と、再帰ニューラルネットワークのうち、時系列データの予測に高い性能を発揮すると報告のあるLSTM (Long Short-Term Memory) ⁹⁾を用いて、各々予測を行い、精度を比較した。検証の手順を以下に記す。

まず、対象としたセンシングデータを訓練用データと検証用データに分割し、方向予測モデルを構築する。次に、検証用データを方向予測モデルに入力し、算出した予測値と実績値を比較した。ただし、自動操縦モデルの運用時を想定し、検証用データとした区間のうち人為測量を行った区間から1-6リング先で到達するシールドマシンの位置を予測した。また、図-5に示すように、センシングデータの80%を訓練用データ、20%を検証用データとし、ともに計画線形が直線である区間と曲線である区間のデータが含まれるようデータに役割を与えた。

予測精度の評価基準として、二乗平均平方根誤差 (RMSE : Root Mean Squared Error) を用いた。RMSEとは予測値と実績値の差を2乗した後に集計する指標であり、小さいほど良い性能であることを示す。なお、RMSEは人為測量を行ったリングの番号と予測したリングの番号




図-6 水平偏差のRMSEの解析結果




図-7 垂直偏差のRMSEの解析結果




図-8 方位偏差のRMSEの解析結果

の差、偏差の種類、計画線形の線形ごとに算出した。また、シールドマシンはトンネルの外周に対して常時20mmの余掘りを行っており、予測精度へ影響を生じる要因となる。その余掘り量を考慮して、水平偏差、垂直偏差のRMSEを20mm以内の精度で予測することを目標値とした。

水平偏差、垂直偏差、方位偏差の解析結果を図-6、図-7、図-8に示す。同一の実験ケースでは、SVRモデルの方がLSTMモデルよりRMSEの値が小さく、精度良く予測できた。また、SVRモデルは1-6リング先まで水平偏差と垂直偏差のRMSEを20mm以内の精度で予測できた。

機械学習モデルによって、予測精度に差があったことを考察するため、図-9にSVRとLSTMの予測方法の概念図を示す。SVRでは直前のセンシングデータを基に偏差を予測し、LSTMではセンシングデータの前後関係の情報を保持して偏差を予測する。以上より、対象としたセンシングデータでは、直前の影響の方が、前後関係の




図-9 SVR と LSTM の予測方法の概念図




図-10 水平方向の目標線形との RMSE の解析結果




図-11 垂直方向の目標線形との RMSE の解析結果

影響より、シールドマシンの位置の予測に寄与したため、SVR モデルの予測精度が LSTM モデルの予測精度を上回ったと考えられる。よって、本研究では方向予測モデルの構築で用いる機械学習モデルとして SVR を採用した。

4. 既施工区間での検証実験

自動操縦モデルの有効性を示すため、自動算出した操作パラメータの最適値より予測したシールドマシンの位置と目標線形の偏差量が、実績値と比較して減少するか検証を行った結果を評価する。検証の手順を以下に記す。

まず、テスト用データとした区間（リング番号 868 - 1013）の目標線形の水平偏差と垂直偏差を自動操縦モデルに入力することで算出した操作パラメータの最適値を用いて、シールドマシンが到達する位置を予測した。開発したモデルの運用時を想定し、予測の対象とした区間のうち、人為測量を行った区間までを既施工区間と仮定し、切羽から 1-6 リング先を対象に自動操縦モデルを適用した。テスト用データとした区間では、計画線形のト

ンネル縦断勾配は一定の値であり、そのうち人為測量を行った区間は、計画線形が直線である区間で 15 箇所、曲線である区間で 11 箇所であるため、直線である区間では 90 リング分、曲線である区間では 66 リング分の予測を行った。なお、目標線形の偏差のうち、自動操縦モデルに入力するデータは、水平偏差と垂直偏差のデータである。よって、水平方向と垂直方向のシールドマシンの位置の予測値と目標線形との RMSE と、実績値と目標線形との RMSE を比較し、予測精度を評価した。

解析結果を図-10、図-11 に示す。同一の実験ケースでは、自動操縦モデルを用いて求めた予測値は実績値と比較して、RMSE は小さくなった。よって、自動操縦モデルにより、目標線形に近い掘進を行う操作パラメータを自動算出する可能性があると考えられる。

5. 結論

本研究では、計画線形が直線である区間と曲線である区間を対象に、目標線形に沿ってシールドマシンが掘進する操作パラメータを自動算出する手法を開発した。次に、既施工トンネルのセンシングデータを対象に、提案手法である自動操縦モデルの有効性を示した。

一方、さらなる区間で検証を行うことや、実トンネルの未掘削工区を対象に開発したモデルを適用する必要がある。今後、開発したモデルの改良を重ねることで解析精度の向上に努めていく次第である。

謝辞：本研究の遂行にご協力いただいた株式会社奥村組の関係者に深謝の意を表す。

参考文献

- 1) 岩下将也, 木下茂樹, 石丸基之, 林稔: シールド工法における AI を用いた方向予測モデル構築と評価, 土木情報学シンポジウム講演集, Vol.45, pp.161-164, 2020.
- 2) 杉山博一, 和田健介, 野澤剛二郎, 本多眞: シールドマシンの方向制御 AI モデルの評価, 土木学会第 74 回年次学術講演会, VI-813, 2019.
- 3) 久保田恭行, 矢吹信喜, 福田知弘: シールドマシンの自動操縦モデルに関する基礎的研究, 土木学会関西支部年次学術講演会, VI-3, 2021.
- 4) Gordon, N., Salmond, D. and Smith, S.: Novel Approach to Nonlinear/ Non-Gaussian Bayesian State Estimation, *IEE Proceedings F*, Vol.140, No.2, pp.107-113, 1993.
- 5) Vapnik, V.: *The Nature of Statistical Learning Theory*, Springer, 1995.
- 6) Hochreiter, D. and Schmidhuber, J.: Long short-term memory, *Neural Computation*, Vol.9, No.8, pp.1735-1780, 1997.