

(41) 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

岩下 将也¹・木下 茂樹²・石丸 基之³・林 稔⁴

¹正会員 株式会社奥村組 技術研究所（〒10-0004 茨城県つくば市大砂 387）

²正会員 株式会社奥村組 東日本支社土木技術部（〒108-8381 東京都港区芝 5-6-1）

E-mail: shigeki.kinoshita@okumuragumi.jp

³非会員 伊藤忠テクノソリューションズ株式会社（〒141-8522 東京都品川区大崎 1-2-2）

⁴正会員 株式会社 演算工房（〒602-8268 京都市上京区智恵光院通中立売下る山里町 237 番地 3）

近年、シールドトンネルは大深度化、長距離化が進んでおり、これに伴うシールド掘進の難易度も高度化している。シールド掘進では、トンネル線形の管理を含めて高度な方向制御が求められるが、熟練したシールド工法の技術者の高齢化などにより、シールド工法を担う技術者減少が減少している。この課題を解決するため、AI（人工知能）を活用してシールド機の位置、方向を予測させることで、トンネルの線形管理を高度化するシステムの構築を行い、実掘進においてそのシステムの性能を評価した。その結果、平均平方根誤差(RMSE)で10mm以内の予測が実現できた。また仮想的な操作を入力してシミュレートすることで、オペレータの経験に頼らず最適操作が決定でき、トンネルの出来形精度が向上することが確認できた。

Key Words: Shield Tunnel, Support Vector Regression, Prediction and Controls, RMSE

1. はじめに

近年、シールドトンネルは大深度化、長距離化が進んでおり、これに伴うシールド掘進の難易度も高度化している。シールド掘進では、トンネル線形の管理を含めて高度な方向制御が求められるが、熟練したシールド工法の技術者の高齢化などにより、シールド工法を担う技術者減少が減少している。

この課題を解決するため、AI（人工知能）を活用してシールド機の位置、方向を予測させることで、トンネルの線形管理を高度化するシステムの構築を行い、実掘進においてそのシステムの性能を評価したので報告する。

なお、本試行は国土交通省の「建設現場の生産性を飛躍的に向上するための革新的技術の導入・活用に関するプロジェクト」の助成を受け実施されている。

シールドマシンの方向制御は、トンネル線形の品質を決める重要な施工要素であるが、シールドトンネルは、工事ごとに形状や施工条件が異なり、画一的な方向制御方法はない。シールド工法の技術者は、シールドの制御は各現場で特有の傾向を示し、従来はシールドの「くせ」




図-1 泥水式シールドシステム概要

表-1 187項目の主要な掘進データ

大分類	分類	点数
シールドマシンの位置の把握に関する掘進データ	前胴、中胴、後胴、ジャイロコンパス、座標、偏差、変位量など	44
方向制御に関わる掘進データ	シールドジャッキ、中折れジャッキ、コビーカッタなど	120
土質などその他の掘進データ	記録日時、カッタビット加速度、テールクリアランスなど	23
合計		187

2. シールド方向予測AIの概要

(1) シールドの方向制御

と捉えて、操作するオペレータが経験をもとに制御を行っており、オペレータの経験に頼った技術である。本研究におけるシールド方向予測AIモデルは、シールドの掘進過程で計測される多種多様なデータを各シールド固有の「くせ」も含め、人工知能に学習させることで、精度の高い方向予測を行う。また、シールドの操作（ジャッキ、中折れなど）を入力し、シミュレートすることで、熟練オペレータと同等以上の最適な方向制御を支援するシステムである。

(2) AIの学習対象とするシールド掘進データ

シールド工法では、多くのセンサを搭載し掘進時は秒単位で200～4000のデータ（以下、掘進データ）を取得しながら、情報化施工によってトンネルを構築している。掘進データは、PCにプログラムしたシステムを用いて一括で管理しており（以下、掘進管理システム）、図-1に示すように排土機構、付属機構、掘削機構と推進機構から収集している¹⁾。学習対象としたデータは、方向予測に寄与しない掘進データを除外しつつ、少しでも影響する可能性がある主要なデータを残し187項目を選択した。主要な掘進データは大別すると、3種類に分類できる（表-1）。

3. 方向予測AIの構築

(1) データクレンジング、特徴量エンジニアリング

データの欠損やノイズはAIモデル性能に悪影響を与える。また、センサデータはそのまま使用すると特徴が捉え切れない場合があり、性質に応じた変換や統合を行う必要がある。以下に対応方法を示す。

a) データクレンジング

収集したデータから、ノイズ等を除去（クレンジング）する処理である。採用した処理を表-2に示す。

b) 特徴量エンジニアリング

センサデータを性質に応じて変換もしくは統合を行う処理である。採用した処理を表-3に示す。

(2) 方向予測AIモデルの構成

方向予測AIモデルは、一定区間で測定データを学習したうえで、直近の5リング分の測定データを入力し将来6リング分方向（水平偏差、垂直偏差、方位偏差）を予測値として出力する構成とした（図-2）。また、機械学習の方法としては、サポートベクトルマシンによる回帰手法（Support Vector Regression、以下SVR）を採用した。SVRはε不感と呼ばれる特性から、微小なノイズに対しての過学習が起きにくいモデルとなっている²⁾。モデルの基本仕様を表-4に示す。

表-6 試行現場の概要

工事名	千代田幹線工事	工事内容
発注者	東京都下水道局	・泥水式シールド工
施工者	奥村組・大豊建設JV	・仕上り内径φ4900mm
工期	H28.11.21～R02.3.24	・今回延長L=4300.5m （全延長L=8,701m）
工事場所	千代田区飯田橋三丁目 ～霞が関一丁目	・一次覆工：ハニカムセグメント他

表-2 データクレンジング処理過程

手順	内容	手順	内容
1	平均、分散、分布の算出、調査	5	移動平均
2	データ差分の算出、調査	6	DiffSum
3	リサンプリング	7	差分処理
4	斜交変換	8	分布の正規化

表-3 特徴量エンジニアリング処理方法

項目	処理方法
水平・垂直方向の面板の傾き	水平・垂直方向のジャッキストロークの差より算出
水平・垂直方向のモーメント	ジャッキのON/OFF検出により合成モーメントを生成、合成ベクトルを水平、垂直方向に分解
水平・垂直方向の余掘量	全体の余掘量の算出後、余掘り量ベクトルを計算、水平、垂直方向に分解し算出
方向付きトルク	面板の回転方向により、トルクのかかる方向を算出

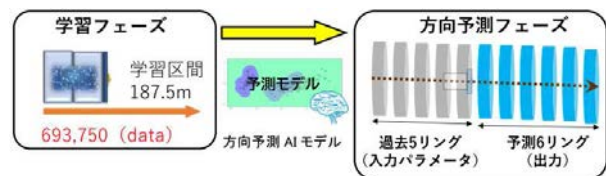


図-2 方向予測AIモデルの構成

表-4 モデルの仕様

データ	学習期間	本掘進データを対象 110リング(166m)
	使用データ	5sごとのデータを5cmごとにまとめて取得
AIモデル	目的変数	水平偏差、垂直偏差、方位偏差
	説明変数	187項目の説明変数を定義
	アルゴリズム	サポートベクトルマシンによる回帰手法
システム	予測頻度	1リング単位
	システム構成	PC(windows10)内で予測、画面表示を実施
	評価方法	評価用の画面を掘進管理室に表示




図-3 RMSEの変遷

表-5 方向予測AIモデルの検証結果

モデル	説明	5リング先水平RMSE評価	操作
Model V0	初期	○6.9mm	×動作せず
Model V1	操作シミュレーション/曲線	×42.2mm	○正常動作
Model V2	方向線形対応	×31.1mm	○正常動作
Model V3	操作シミュレーション/直線	○5.1mm	○正常動作

(3) 方向予測 AI モデルの予測精度の検証

方向予測 AI の方向予測について、実現場の掘進データを用い、精度検証を実施した。また、精度目標として以下の2項目を立案し、達成するまで、モデルの再学習および再構築を計4回実施した。なお、精度の評価は、実掘進線形と予測値を比較し、RMSE（二乗平均平方根誤差、式(1)）を評価値とした。

①方向予測性能の目標を5リング先までの水平偏差における実績と予測の誤差をRMSEで20mm以下

②入力した操作パラメータに応じ、操作シミュレーション結果（以下、操作S）が適切に変化する

$$RMSE = \frac{\int_{x_0}^{x_1} (S(x) - F(x))^2}{x_1 - x_0} \quad (1)$$

ここに、 $S(x)$: 実績掘進線形偏差,
 $F(x)$: 予測掘進線形偏差,
 x_0 : 初期位置, x_1 : 予測位置

検証結果を表-5と図-3に示す。ここでは5リング先の水平偏差の予測誤差と操作Sの評価を述べる。ModelV0はRMSEが6.9mmとなり予測結果としては目標を達成したが、学習区間が直線と左曲線(R300)のみであったため、操作Sが外挿予測となり結果が変化しなかった。ModelV1は操作Sの動作環境に着目し、直線、曲線左右で計452.8mを学習区間とした。結果は、操作Sは正常に動作したが、RMSEが42.2mmとなり著しく低下した。これは、曲線においてシールド方向の急激な変化を過学習したため、水平偏差に過敏な反応をしたことが原因と判断した。ModelV2はシールドの現時点の方位により、次に進む方向がある程度で制限されることを前提に再学習を実施した。結果は、RMSEが31.1mmまで改善し、操作Sも動作したが目標は達成できなかった。

4. 方向予測 AI の評価

表-6の現場において、方向予測 AI モデルの検証を実施した。大深度（土被り48～60m）、超長距離の泥水式シールドで施工する下水道築造工事である。試行に使用した方向予測 AI モデルは、ModelV3である。学習区間は直線部の166.5mとし、学習データには139変数（187項目）を使用した。また、データクレンジングを学習区間の全データに実施し、SVRで学習して方向予測 AI モデルを生成し、検証を行った。

(1) 掘進データの取得と方向予測

表-6 試行現場の概要

工事名	千代田幹線工事	工事内容
発注者	東京都下水道局	・泥水式シールド工
施工者	奥村組・大豊建設 JV	・仕上り内径φ4900mm
工期	H28.11.21～R02.3.24	・今回延長L=4300.5m (全延長L=8,701m)
工事場所	千代田区飯田橋三丁目 ～霞が関一丁目	・一次覆工:ハニカムセグメント他




図-4 全体システム

表-7 説明変数の内容

大分類	分類	点数
シールドマシンの位置の把握に関する掘進データ	前胴、中胴、後胴、ジャイロコンパス、座標、偏差、変位量など	44
方向制御に関わる掘進データ	シールドジャッキ、中折れジャッキ、コピーカッタなど	120
土質などその他の掘進データ	記録日時、カットビット加速度、テールクリアランスなど	23
合計(139変数+48項目)		187

実現場で利活用が可能な方向予測を行うためには、入力値となる掘進データをリアルタイムに方向予測 AI モデルに取り込む必要がある。掘進データは掘進管理システムが1回/5秒でロギングしているデータを、掘進5cmを1単位としてデータセットを生成し、クラウドサーバにアップロードを行うように設定した。また、このデータをクラウド環境内で自動的にデータクレンジング、特徴量エンジニアリングを行い、機械学習に適したデータに変換するプログラムを作成した。方向予測 AI はクラウド環境内に置き、作成されたデータを取得する仕様とした(図-4)。

シールドの方向制御は、おおむね1方（4～6リング）掘進ごとに人為的な測量を実施し、その結果をもとに掘進管理者が掘進指示書を作成して、オペレータが指示値に近づくように操作を行っている。このことを踏まえて、AIによる方向予測は、今から掘進する0～5リングでそれぞれ到達する位置（計画線形からの偏差量）を予測値として出力するシステムとした。また予測は、学習区間で生成した方向予測 AI モデルに、説明変数³⁾として直近5リング分のシールド掘進データ（139変数、187項目）を入力し、目的変数となる水平偏差、垂直偏差、方位偏差を出力させるようにした(表-7)。

(2) 方向予測 AI を応用した操作のシミュレーション

シールド掘進において方向制御に寄与する操作は、おもにカッター面板の回転、シールドジャッキ、中折れ装置およびコピーカッタ（余堀り装置）があり、これらの組み合わせだけでも数十～数百億通りの操作方法が選択で

きる。そこで構築したシステムには、方向予測 AI を活用して、シールドの操作を仮想的に入力すると、直近の掘進データと入力操作を用いて 1～5 リングの到達位置を予測するシミュレーター機能（以下、操作シミュレーション）を搭載した。操作シミュレーションに入力可能な操作を表-8 に示す。

(3) 方向予測 AI と操作シミュレーションの現場試行

システムの評価、検証を実施するため、2. で示した現場に本システムを導入し、試行を実施した。試行は、直線区間の 1942～1962 リング (30m) を対象とし、方向予測および操作シミュレーションの結果と人為的な測量結果（シールドが実際に掘進した軌跡）を比較することで検証した。

a) 方向予測 AI の評価

図-5 にシールドの 3 リング先の水平偏差、図-6 に垂直偏差のグラフを示す。グラフは縦軸を計画線形からの離れ（偏差）、横軸をリング No. で表している。また、赤線は方向予測 AI が予測した値、青線は測量結果である。実際の方向予測画面は、図-7 に示す。予測結果と測量結果との差は、試行区間の平均値で水平 5.08mm、垂直 6.01mm となった。また、グラフから判断できるように予測結果は、差分による精度のみならず、偏差傾向についても予測できている。なお、1～5 リング先までそれぞれの結果は表-9 に整理した。

b) 操作シミュレーションの評価

次に試行区間で実施した操作シミュレーションの結果について、表-10 に示す。ここでは、①オペレータが独自の判断で掘進した区間と②シミュレートに基づいて掘進した区間で、トンネルの線形品質を評価基準とし、各 10 リングの平均の出来形偏差を比較対象とした。なお、トンネル中心における出来形として、中心出来形偏差についても示している。10 リング当たりの平均で出来形は水平 6.0mm、垂直 2.5mm の偏差を低減できている。中心出来形で計算すると 5.9mm となり、偏差低減の向上率は 15.3%であった。

5. まとめ

現場に導入した方向予測 AI と操作シミュレーションについて、以下の結果を得た。方向予測については、0～5 リング先の予測精度がすべて 10mm 以内となり、シールド掘進に利活用が可能な精度を確保できた。また、仮想的な操作を入力してシミュレートすることで、オペレータの経験に頼らず最適操作が決定でき、トンネルの出来形精度が向上することが確認できた。今後は、本技術

を他現場へ普及展開を図るべく、システムの汎用性について開発を進める所存である。

なお、試行現場の提供をいただいた東京都下水道局第二基幹施設再構築事務所に、ここに感謝いたします。

表-8 操作シミュレーション操作値

操作種別	入力値
ジャッキパターン	ON, OFF 選択 (×18 本)
ジャッキ速度	mm/min (0～66.8mm)
コピーカッタ	ON, OFF 選択 (×360°)
コピーカッタストローク	mm (0～200mm)
中折れ上下角、左右角	deg (0～6°)
切羽カッター盤回転方向	右, 左




図-5 水平偏差 (3 リング先)




図-6 垂直偏差 (3 リング先)




図-7 方向予測 AI 表示画面

表-9 実掘進偏差と予測値の差

リング数[先]	1	2	3	4	5
水平偏差[mm]	3.56	5.25	5.08	5.53	4.67
垂直偏差[mm]	4.52	4.71	6.01	7.27	9.53

表-10 出来形に関する偏差の比較

偏差	中心出来形 偏差※(mm)		水平出来形 偏差(mm)		垂直出来形 偏差(mm)	
	①	②	①	②	①	②
① オペレータ	OP	操作	OP	操作	OP	操作
② 操作シミュレーション						
平均値 μ (mm)	38.5	32.6	26.5	20.5	27.7	25.2

※中心出来形偏差(mm)= $\sqrt{(\text{水平出来形偏差}^2 + \text{垂直出来形偏差}^2)}$

参考文献

- 1) 土木学会：シールド技術情報作成マニュアル，pp.28-37，2008.
- 2) Python 機械学習プログラミング: R. Sebastian, 2016
- 3) G. Aurelien.: Scikitlearn と TensorFlow による実践機械学習, 2018