

シールド工法における AI を用いた方向予測システムの開発

ー その1：方向予測AIモデルの構築 ー

株式会社 奥村組 ○正会員 木下 茂樹, 正会員 竹内 花奈

株式会社 コンポート 正会員 有賀 貴志

大阪大学大学院工学研究科 環境・エネルギー工学専攻 フェロー会員 矢吹 信喜

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、シールド掘進の難易度は高く、トンネル線形を含めて高度な掘進管理が求められる。一方で、熟練したシールド工法の経験者の高齢化などにより、シールド工法の担い手は年々少なくなっている。これら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った。本稿では、シールド掘進データの機械学習における処理方法および構築したAIモデルについて報告する。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。

2. シールド方向予測AIモデル構築に関する概念

一般的にシールドは、工事ごとにシールド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」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いる。大げさに言えば、シールド工法は、オペレータの暗黙知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ものである。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を開発することも目的とした。

3. 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）。

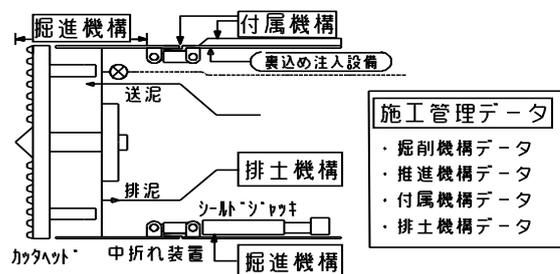


図1 泥水式シールドシステム概要

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、カッタビット加速度、テールクリアランスなど	23
合計		187

4. 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。

(1) 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。

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

(2) 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

キーワード シールドトンネル, 方向予測, AI, 機械学習

連絡先 〒108-8381 東京都港区芝5-6-1 (株) 奥村組 東日本支社 土木技術部 TEL03-5427-8456

行う処理である。採用した処理を表3に示す。

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

6. 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。モデルの基本仕様を表4に示す。

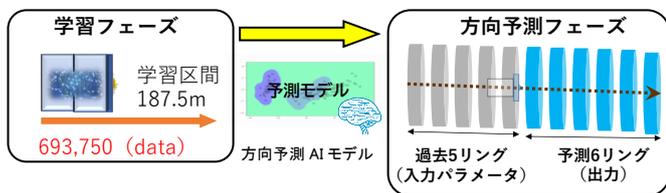


図2 方向予測 AI モデルの構成

表4 モデルの仕様

データ	学習区間	本掘進データを対象
	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

7. 方向予測 AI モデルの予測精度の検証

方向予測 AI の予測精度について、実現場の掘進データを用いて検証を実施した。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

$$\text{掘進線形誤差評価値(RMSE)} = \sqrt{\frac{\int_{x_0}^{x_1} (S(x) - F(x))^2 dx}{x_1 - x_0}} \quad \dots \text{式(1)}$$

ここに、S(x) : 実績掘進線形、F(x) : 予測掘進線形

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。

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

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。ModelV3は、必要な方向操作が実施されている直線部分166mを学習区間とした。結果はRMSEが5.1mmで、操作Sも正常に動作することを確認でき、目標を達成した。

図3に各モデルにおける0~5リング先のRMSEの変遷と平均値を示す。なお、ModelV3では、学習区間と検証区間を入替え予測させる交差検証を実施し、5リング先の予測結果が全区間で20mm以下となることも確認した。

8. まとめ

検証結果から以下の結論を得た。

- 掘進データをSVRに学習させることで、精度の良い方向予測ができる。その際、掘進データの事前処理、学習区間の選定が重要となる。
- 操作シミュレーションでは、学習区間における操作の実績が重要であるものの、極端な操作や過学習は、予測精度の低下につながる事が分かった。

本研究の成果をもとに、今後は急曲線部を含めたシールド全線の方向予測、操作シミュレーションの実現を目指す所存である。

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.

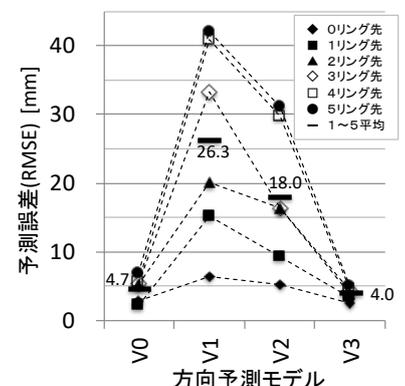


図3 RMSEの変遷