

シールドマシンの操作特性を考慮した自動操縦 AI モデル

清水建設(株) 正会員 ○和田健介, 杉山博一

清水建設(株) 正会員 野澤剛二郎, 本多眞

1. はじめに

著者らは、シールドマシンの自動運転を目指した AI モデルを開発している。今回、よりオペレータに近い操作を再現するために、シールドマシンの操作特性を考慮した AI モデルを開発した。

シールドマシンのジャッキ操作を例に挙げると、操作変更の頻度は数十秒から数百秒に一回程度であり、施工データの大半は操作変更がないものとなる。このデータを教師データとした場合、常に操作しないことを良しとする AI モデルが作成される傾向がある。仮にこの問題が解決できたとしても、シールドマシンから得られる特徴量が時々刻々変化するのに伴って、AI モデルの予測値も変動する。AI モデルは常に操作変更を要求することとなり、現実的ではない。

考案した AI モデルは、操作のタイミングを判定する AI モデル（以下、操作判定モデル）と設定値を判定する AI モデル（以下、操作予測モデル）の二つから成る。操作タイミングを考慮できるため、上記の課題を解決することができる。本稿では、二つの AI モデルの作成方法と組み合わせ方法について述べる。また実際の施工データに対して、操作判定モデルを適用した結果を示す。

2. 操作判定モデルの構築

操作判定モデルの作成手順を図-1 に示す。①では、オペレータが操作変更していないレコード（以下、操作無レコード）を 0、操作変更したレコード（以下、操作有レコード）を 1 として判定する。②では、操作無レコードの総数 n_0 と操作有レコードの総数 n_1 のバランスをとるためにデータの重みづけを行う。ここでは、操作無レコードの重みを 1 とし、操作有レコードの重みを n_0/n_1 とすることで、両者が均等となるように設定した。③では、操作有無判定値を目的変数とする教師あり学習により操作判定モデルを作成する。この際、②で定めた重みを考慮した学習を行う。本稿では、勾配ブースティングによって操作判定モデルを学習した。④では、操作の有無を判定するための閾値を決定する。学習済みの操作判定モデルより出力された予測値から確率分布を求め、TN、FN、TP、FP のデータ数が適切になるような閾値を設定する。ここでは、下記の式で示す BER (Balanced Error Rate) が最小となるように設定した。

$$BER = 0.5 \times \left(\frac{FP}{TN+FP} + \frac{FN}{FN+TP} \right) \quad (1)$$

3. 操作予測モデルの構築

操作予測モデルは、対象とする操作の設定値を目的変数とする教師あり学習によって作成する。教師データは図-1 の④における TP と FN とする。操作変更が必要であると判断されたデータのみを用いることによって、常に操作しないことを良しとする AI モデルになることを避けることができる。本稿では、勾配ブースティングによって操作予測モデルを学習した。

① 操作有無の判定

② データの重みづけ

操作無レコード			操作有レコード		
レコード番号	操作判定値	重み	レコード番号	操作判定値	重み
1	0	1	1	1	n_0/n_1
2	0	1	2	1	n_0/n_1
⋮	⋮	⋮	⋮	⋮	⋮
n_0	0	1	n_1	1	n_0/n_1

③ 操作判定モデルの作成



④ 閾値の決定




図-1 操作判定モデルの作成手順

キーワード シールドトンネル, 人工知能, 自動操縦

連絡先 〒135-8530 東京都江東区越中島 3-4-17 清水建設株式会社 技術研究所 TEL:03-3820-6891

4. 操作判定モデルと操作予測モデルの予測手順

操作判定モデルと操作予測モデルを用いた予測手順を図-2に示す。特徴量を操作判定モデルに入力し、出力値と閾値を比較する。閾値未満であれば、操作は必要がないと判定し、操作変更の指示は出さない。閾値以上であれば、操作予測モデルにて設定値を予測し、操作変更の指示を出す。

5. 実測データへの操作判定モデルの適用

シールドジャッキ操作を対象として、実際のシールド現場のデータを操作判定モデルに適用した。1～237リングのデータを用いて操作判定モデルを作成し、238～294リングのデータに対して予測値を出力した。

予測結果を図-3に示す。238～294リングのデータ分布を棒グラフで、オペレータの操作回数と操作判定モデルが出力した操作指示の回数（以下、AIの操作回数）を折れ線グラフで描いた。(a)と(b)はマシン先端の計画線形からの水平偏差と鉛直偏差に関するグラフであり、管理値までの近接割合(%)で表示した。(c)と(d)はマシンの方位角およびピッチング角と計画値との誤差に関するグラフである。オペレータとAIの操作回数は、データを10分毎に区切り、10分の間に操作があった場合を1回としてカウントした。水平偏差、鉛直偏差、方位角誤差、ピッチング角誤差は10分毎の最大値を用いてプロットした。

(a)～(d)のグラフより、オペレータとAIの操作回数の分布が同様の傾向を示していることがわかる。作成した操作判定モデルがオペレータの操作を模擬できており、シールドジャッキ操作を行うタイミングを適切に判定できているといえる。

6. まとめ

操作判定モデルと操作予測モデルの作成方法について述べた。施工データを操作判定モデルに適用した結果、オペレータの操作を模擬し、操作タイミングを適切に判断できていることを確認した。操作判定モデルと操作予測モデルを組み合わせた場合の評価については、別稿²⁾にて行った。

参考文献

- 1) 和田健介他：AIによるシールドマシンの自動方向制御，土木学会第73回年次学術講演会，VI-143，2018。
- 2) 杉山博一他：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，2019。




図-2 操作判定モデルと操作予測モデルの予測手順




図-3 オペレータの操作回数とAIによる操作指示回数