

機械学習を用いた水利施設操作者の意思決定指標の可視化の検討 Investigation of Visualization of Decision-Making Indices for Drainage Pump Operation by using Machine Learning Model

○福重 雄大*・皆川 裕樹*・相原 星哉*

○FUKUSHIGE Yudai・MINAKAWA Hiroki・AIHARA Seiya

1. 背景と目的

農業従事者の減少や担い手の不足、さらには近年の豪雨の増加や流域の都市化等による流出特性の変化によって、農業水利施設管理者の負担は増加すると考えられる。実際、排水機場管理者を対象に実施したアンケート調査では、約7割の管理者が10年前と比較して年間のポンプ運転時間が増加したと回答している¹⁾。水利施設の管理・操作は土地改良区職員や委託された地域の操作者が担うことが多いが、特に、操作規定に明確な基準がない豪雨前の事前排水(例えば Fig.1)等の緊急時操作などは状況に応じたフレキシブルな対応が求められるため、過去の経験がものをいう。持続可能な営農活動のためには、培われてきた地区毎の特徴やベテラン操作者の貴重な経験「知」を、次世代にスムーズに継承していくことが重要である。そのためにベテラン操作者の判断基準を客観的に捉える必要があるが、操作者の主観を基準に落とし込むのは一般に困難である。そこで本研究では、排水機場の操作履歴と操作判断の指標になるであろう降水量や内水位等の情報の関係を機械学習モデルによって近似し、その機械学習モデルの挙動を解釈することで、機場操作者の判断基準を抽出できないかを検討する。

2. モデル概要と検討方法

(1) 対象地区 本研究では、千葉県印旛沼地区にある宗吾北排水機場(常用排水機1台、非常用排水機2台)を対象とした。本機場は干拓農地域にあり、排水路の水は循環灌漑にも用いられるが、地区外(印旛沼)への排水は全て機械排水に依っている。

(2) モデルの概要と問題設定 説明可能なAIの代表的手法であるランダムフォレストを選択した。操作者の判断に即したモデルの作成を目的とするため、時刻 $t+1$ のポンプ場の運転状況(目的変数)を、時刻 t までの水位・雨量の観測値(説明変数)から予測するように問題を設定した(Fig.2)。特に Fig.1 のような降雨前の事前排水といった警戒態勢時の操作の予測精度を向上させることが本研究の大きな目的である。

(3) 特徴量の概要 使用したデータは、2017年4月～2021年12月までの毎時のポンプ運転記録




Fig.1 対象地区の内水位変化とハイエトグラフ
Observed inner water level change and hyetograph




Fig.2 ランダムフォレストで解く問題の設定
Problem setting to solve with Random Forest

* (国研) 農研機構 農村工学研究部門 Institute for Rural Engineering, NARO

キーワード：施設操作支援, 事前排水, 機械学習, 説明可能なAI

および機場地点の内・外水位，同期間の近傍アメダス雨量（佐倉）である．さらに，排水路の水位管理に関係する灌漑期間（4月～8月）情報を加えた．これらのデータから，学習に用いる特徴量を作成した（Table 1）．さらに雨量データでは，操作員が現場で知りえる天気予報をイメージして，±1日，2日，3日の総降雨量も加えた．これらから，2017年～2020年の期間を教師データとし，2021年データを対象に学習モデルをテストするとともに，設定した特徴量の重要度（PFI）を評価した．

3. 結果と考察

学習済みモデルを2021年のデータに適用した結果である混同行列を Fig.3 に示す．全体の正答率は95.7%と非常に高いが，ポンプ稼働を正例とした場合の再現率は67.9%となり，本研究の目的からは十分な精度とはいえなかった．原因として，ポンプ未稼働の時間が全体の90%以上を占める不均衡なデータを用いたことが挙げられる．これにより，モデル全体の正答率を上げるために未稼働時間への適合が重視された可能性がある．この問題を解消するために，ある程度の降雨時や洪水時などの緊急時操作を含むイベントを抽出して学習に用いる必要があると考えており，現在正答率を上昇させるためのデータ抽出ルールを試行している．

また，作成したモデルの特徴量重要度を Fig.4 に示す．現時点では不十分な結果ではあるが，このように機械学習モデル内部の判断に影響する特徴量を評価することで，操作員の経験を再現するための指標を可視化できる．この結果は地区ごとに異なると考えられるが，機械学習を通じて施設操作の履歴を解釈し，重要な要素を可視化することができれば，操作経験の浅い者に対しても蓄積された経験をスムーズに継承できると考えられる．

4. まとめと今後の予定

排水機場の操作履歴から操作員の判断を解釈するための第一歩として，降水量と水位のデータを用いて，排水機場操作を予測するモデルの作成を試みた．今回の検討では，洪水時や事前排水時の予測精度が十分なモデルは得られなかったものの，今後はモデル自体の改善とともに，学習データの工夫を進める．さらに，構築した学習モデルをマイクロ・マクロに解釈する様々な評価手法を適用し，操作支援に資する情報を発信することを目指す．

参考文献：1) 農林水産省 農村振興局（2014）：ため池・排水機場における豪雨等に対する備えと対応（参考事例集）

Table 1 機械学習に用いた特徴量

Created feature values for machine learning

特徴量	n
n 時刻前との差	1, 3, 6, 12, 24
過去 n 時間の総和	3, 6, 12, 24
過去 n 時間の最大値	3, 6, 12, 24
過去 n 時間の最小値	3, 6, 12, 24
過去 n 時間の標準偏差	3, 6, 12, 24
過去 n 時間の線形トレンド	3, 6, 12, 24

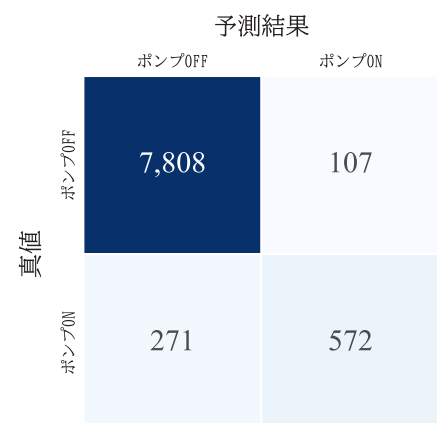


Fig.3 モデルをテストデータに適用した混同行列

Confusion Matrix from learned model




Fig.4 特徴量の重要度（上位5つ）

Permutation Feature Importance