

# 教師なし機械学習アルゴリズムによる異常予兆検知の基盤技術の研究開発

課題責任者

中川 友進 海洋研究開発機構 技術開発部 海洋ロボティクス開発実装グループ

著者

中川 友進\*<sup>1</sup>, 井上 朝哉\*<sup>1</sup>, 金子 達哉\*<sup>1</sup>, 竹本 樹央\*<sup>2</sup>

\*<sup>1</sup> 海洋研究開発機構 技術開発部 海洋ロボティクス開発実装グループ

\*<sup>2</sup> 東京大学 新領域創成科学研究科 海洋技術環境学専攻

キーワード：抑留，異常予兆検知，教師なし機械学習，掘削データ

## 1. 緒言

過去のデータから未来に起こる可能性がある異常を予測する「異常予兆検知」は、非生産的な時間、経済的な損失を回避する上で重要である。すでに起こった異常を検知する「異常検知」は様々な分野で実施されているが、「異常予兆検知」は確立されていない。本課題では、多変量時系列データに対して機械学習を適用した特徴抽出や異常状態識別を目的として、複数のアルゴリズムでの検討や整理、基盤技術構築を推進している。掘削作業中の抑留のデータを使用した、教師なし機械学習アルゴリズムの研究開発、および異常予兆検知の可否の調査を実施した。

掘削作業中の抑留の発生は、作業完了の遅延、坑井の放棄につながり、経済的損失や安全上の問題を引き起こす。そのため、抑留の被害軽減・回避は重要であり、抑留の発生後に出来るだけ早く検知（以下、抑留検知）、抑留の発生前に予兆を検知（以下、抑留予兆検知）するアプローチが有力である。特に後者は作業員に被害軽減・回避のための十分な時間を与えられるため、より適切な方法である。そのため坑井内の状況を反映した掘削データを用いた抑留予兆検知は、抑留の被害軽減・回避において重要である。

掘削データを用いた抑留検知は、大きく分けて三つのアイデアが提案されており、統計的モデルと解析的モデルのどちらか一方または両方を使用[1][2][3][4][5]、物理ベースモデルとデータ駆動型モデルの組み合わせ[6]、

教師あり機械学習に基づきニューラルネットワークとサポートベクターマシンの一方または両方を使用[7][8][9][10][11][12][13][14][15]というアイデアである。

抑留予兆検知は、教師なし機械学習に基づき、深度領域データを用いた 3 次元量み込みニューラルネットワーク[16]、全結合型ニューラルネットワークによる混合確率モデル[17][18]、長・短期記憶 (Long Short-Term Memory; LSTM) と自己符号化器 (AutoEncoder; AE) を組み合わせた LSTM-AE モデル[18][19][20]、機械学習に物理的な知見を取り入れた Torque モデル[21][22]が提案されている。

我々は、人工知能を用いたリアルタイムでの抑留予兆検知を行うため、産官学連携プロジェクトを推進しており[23]、3つの教師なし機械学習モデル (混合確率モデル、LSTM-AE モデル、Torque モデル) を開発した。教師なし機械学習モデルは、通常の掘削作業の時系列データのみで学習させることが特徴である。さらに、抑留が始まる前後は、通常の掘削作業と比べて、時系列データの実測値と予測値の乖離が大きくなるという仮説に基づいている。この仮説が正しければ、抑留が始まる前にリアルタイムでの抑留予兆検知が可能である。教師なし機械学習モデルは、様々な種類の坑井に適用可能であり、教師あり機械学習モデルでは実現できない高精度なリアルタイムの抑留予兆検知の可能性を持っていると考えている。

表 1 掘削パラメータの一覧を示す。

掘削パラメータの名称	説明	単位	最小値	最大値
TD_spd	Top drive rotation speed	rpm	-300	300
TD_trq	Top drive torque	kNm	-100	100
ROP_ave	Average rate of penetration	m/h	-9000	9000
Bitdepth	Bit depth	m	-50	9000
Totdepth	Total hole depth	m	-50	9000
Hookheight	Hook height	m	-10	100
Hookload	Hook load	ton	-20	500
WOB	Weight on bit (calculated from	kN	-	-
MRetFlow	Return flow rate of mud	%	-30	100
SPP_pressA	Pressure of stand-pipe manifold	MPa	-5	50
MPP_SPM1	Stroke of mud pump #1	spm	-1	160
MPP_SPM2	Stroke of mud pump #2	spm	-1	160
FlowIn	Flow from the mud pumps	L/min	-100	6000

## 2. 掘削データ

本研究において、混合確率モデルでは海洋研究開発機構によって計測された 7 個の異なる坑井における実際の掘削操作の時系列データ（1 秒のサンプリング周期）を使用した。また、Torque モデルでは協力企業によって計測された 34 個の異なる坑井における実際の掘削操作の時系列データ（4 秒のサンプリング周期）を使用した。表 1 に本研究で使用した掘削パラメータを示す。最も抑留の影響が現れると考えられる 13 個を使用した。海洋研究開発機構のデータについては ROP\_ave を除く 12 個を使用した。異常値を取り除くために、表 1 に示す最小値と最大値を 13 個の掘削パラメータが同時に満たすようにデータをフィルタリングした。

我々の教師なし機械学習モデルは、通常の掘削操作の時系列データで学習するように設計されている。そこで、3.1 節に記述する混合確率モデルにおいては、通常の掘削操作は、抑留の開始時刻から 24 時間より前と、終了時刻から 24 時間より後の時間帯を学習に使用した。また、Torque モデルでは、予測対象時刻の 12.5 時間前から 30 分前の時間帯を学習に使用した。

学習済みモデルの性能を時系列で評価するために、テストデータとして、混合確率モデルでは海洋研究開発機構の 1 個の坑井に含まれる 6 個の抑留イベント、Torque モデルでは協力企業の 30 個の坑井に含まれる 34 個の抑留イベントを使用した。

## 3. 手法

### 3.1 機械学習モデル

本研究では、開発した 3 つの教師なし機械学習モデルのうち、混合確率モデルと Torque モデルを使用した。

混合確率モデルは、時系列データはニューラルネットワークの確率的な混合によって再現できるという考えに基づくモデルである[17][18]。確率を出力する 1 つのゲーティングモジュールと、予測値を出力する M 個の学習モジュールから構成される。最終的な予測値は、各々のニューラルネットワークからの出力の加重平均として計算される。混合確率モデルでは、予測値は TD\_trq と SPP\_pressA に着目した。

Torque モデルは、操業上の知見や物理的考察を加味したモデルである[21][22]。

通常の掘削操作の時系列データのみで学習した場合、通常の掘削操作では実測値と予測値の乖離は小さいと予想される。しかし、抑留の発生前後には、この乖離が大きくなることが予想される。そこで、抑留予兆検知および抑留検知の指標として、実測値と予測値の乖離度を用いることとし、予測対象時刻の直近 1 時間において、実測値がモデルから計算された閾値を超える割合（Score）を使用した。

### 3.2 学習

学習データを用いて、機械学習モデルのパラメータを反復して更新した。オーバーフィッティングを避けた

め、混合確率モデルでは MAE が一定回数の反復において改善されない場合に、学習を停止する機能を使用した。

図 1 は混合確率モデル（3 混合）における学習回数に対する MAE の変化を例示しており、学習 512 回ごとの平均値である。




図 1 混合確率モデルでの学習回数に対する MAE の変化。

### 3.3 予測

図 2 に、混合確率モデルにおける、抑留の開始時刻の前後における SPP\_pressA の Score の時系列変化を 1 つの抑留ケースについて例示する。Score は、1 混合（緑線）、2 混合（青線）、3 混合（赤線）を重ねて描画している。3 混合（赤線）に着目すると、抑留の開始直後に Score が増加しており、1 混合（緑線）や 2 混合（青線）と比べて、3 混合（赤線）の方がモデルの表現力が高いことが考えられる。



図 2 抑留の開始前後（24 分）での混合確率モデルの Score の時系列変化を例示する。灰色の網がけは抑留の時間帯を表す。

## 4. 結言

本課題の推進にあたり、掘削操作中の抑留のデータを使用し、教師なし機械学習アルゴリズムの研究開発を実施した。人工知能を用いたリアルタイムでの抑留予兆検知を行うため、産官学連携プロジェクトを推進しており[23]、3 つの教師なし機械学習モデルを開発した。これらのモデルは、通常の掘削操作時に比べて、抑留の発生前後で、実測値と予測値の乖離度が増加するという仮説のもと、通常の掘削操作の時刻タグ付き掘削データで学習された。学習済みモデルを用いて、抑留予兆検知および抑留検知の評価を 31 個の坑井に含まれる 40 個の抑留へ実施した。その結果、抑留の前に乖離度が増加するケースがあることが分かり、我々の仮説が一部確認された。したがって、本課題で開発した教師なし機械学習モデルは、作業員に被害軽減・回避のための十分な時間を与えることが可能となるリアルタイムでの抑留予兆検知において有望だが、より正確な予測のためには、ハイパーパラメータの最適化の改良が必要であると考えている。

多変量時系列データに対して機械学習を適用した特徴抽出や異常状態識別を目的として、掘削操作中の抑留のデータを使用した教師なし機械学習モデルの研究開発を実施し、複数のアルゴリズムでの検討や整理、および基盤技術構築を進めることができた。

## 謝辞

本研究は、独立行政法人エネルギー・金属鉱物資源機構の委託研究の助成を受けたものである。

## 文献

- [1] Hess, J. "Pipe Sticking Prediction Using LWD Real-Time Measurements", Paper presented at the IADC/SPE Drilling Conference and Exhibition, SPE-178828-MS, 2016.
- [2] Magana-Mora, A., Gharbi, S., Alshaikh, A. et al., "AccuPipePred: A Framework for the Accurate and Early Detection of Stuck Pipe for Real-Time Drilling Operations", Paper presented at SPE MEOS, SPE-194980-MS, 2019.
- [3] Meor Hashim, M. M., Yusoff, H. M., Arriffin, F. M. et al., "Performance Improvement of Wells Augmented Stuck Pipe Indicator via Model Evaluations", Paper presented at IPTC, IPTC-21455-MS, 2021b.
- [4] Salminen, K., Cheatham, C., Smith, M. et al., "Stuck-Pipe Prediction by Use of Automated Real-Time Modeling and Data Analysis". SPE Drill & Compl, 32, 184-193, SPE-178888-PA, 2017.
- [5] Shoraka, S. A., Shadizadeh, S. R., and Pordel Shahri, M., "Prediction of Stuck Pipe in Iranian South Oil Fields Using Multivariate Statistical Analysis", Paper presented at NAICE, SPE-151076-MS, 2011.
- [6] Zhang, F., Islam, A., Zeng, H. et al., "Real Time Stuck Pipe Prediction by Using a Combination of Physics-Based Model and Data Analytics Approach", Paper presented at ADIPEC, SPE-197167-MS, 2019.
- [7] Abbas, A. K., Flori, R., Almubarak, H. et al., "Intelligent Prediction of Stuck Pipe Remediation Using Machine Learning Algorithms", Paper presented at the SPE ATCE, SPE-196229-MS, 2019.
- [8] Ahmed, O. S., Aman, B. M., Zahrani, M. A. et al., "Stuck Pipe Early Warning System Utilizing Moving Window Machine Learning Approach", Paper presented at ADIPEC, SPE-197674-MS, 2019.
- [9] Al-Baiyat, I., and Lloyd H., "Implementing Artificial Neural Networks and Support Vector Machines in Stuck Pipe Prediction", Paper presented at SPE KIPCE, SPE-163370-MS, 2012.
- [10] Alshaikh, A., Magana-Mora, A., Gharbi, S. A. et al., "Machine Learning for Detecting Stuck Pipe Incidents: Data Analytics and Models Evaluation", Paper presented at IPTC, IPTC-19394-MS, 2019.
- [11] Brankovic, A., Matteucci, M., Restelli, M. et al., "A Data-Based Approach for the Prediction of Stuck-Pipe Events in Oil Drilling Operations", Paper presented at ADIPEC, SPE-202625-MS, 2020.
- [12] Chamkalani, A., Pordel S. M., and Saeed P., "Support Vector Machine Model: A New Methodology for Stuck Pipe Prediction", Paper presented at SPE UGAS, SPE-164003-MS, 2013.
- [13] Meor Hashim, M. M., Yusoff, H. M., Arriffin, F. M. et al., "Utilizing Artificial Neural Network for Real-Time Prediction of Differential Sticking Symptoms", Paper presented at IPTC, IPTC-21221-MS, 2021a.
- [14] Siruvuri, C., Nagarakanti, S., and Samuel, R., "Stuck Pipe Prediction and Avoidance: A Convolutional Neural Network Approach", Paper presented at the IADC/SPE Drilling Conference, SPE-98378-MS, 2006.
- [15] Zhu, Q., Wang, Z., and Jian H., "Stuck Pipe Incidents Prediction Based On Data Analysis", Paper presented at SPE GOTECH, SPE-198672-MS, 2019.
- [16] Tsuchihashi, N., Wada, R., Ozaki, M. et al., "Early Stuck Pipe Sign Detection with Depth-Domain 3D Convolutional Neural Network Using Actual Drilling Data", SPE J., 26, 551-562, SPE-204462-PA, 2021.
- [17] Inoue, T., Nakagawa, Y., Wada, R. et al., "Attempt of Early Stuck Detection Using Unsupervised Deep Learning with Probability Mixture Model", Proceedings of the ASME 2021 40th International Conference on OMAE2021, Virtual, 2021.
- [18] Tomoya Inoue, Yujin Nakagawa, Ryota Wada et al., "Early stuck detection using supervised and unsupervised machine learning approaches", Paper presented by OTC Asia, OTC-31376-MS, 2022
- [19] Nakagawa, Y., Inoue, T., Bilien, H. et al., "An Unsupervised Learning Model For Pipe Stuck Predictions Using A Long Short-Term Memory Autoencoder Architecture", Paper presented by SPE/IATMI APOGCE, SPE-205677-MS, 2021a.
- [20] Nakagawa, Y., Inoue, T., Bilien, H. et al., "A Approach For Real-time Prediction Of Pipe Stuck Risk Using A Long Short-term Memory Autoencoder Architecture", Paper presented by ADIPEC, SPE-207805-MS, 2021b.
- [21] Tatsuya Kaneko, Tomoya Inoue, Nakagawa, Yujin et al., "Hybrid Approach Using Physical Insights and Data Science for Stuck-Pipe Prediction", SPE Journal pages 1-10, SPE-218013-PA, 2023
- [22] Kaneko, T., Inoue, T., Nakagawa, Y., et al., "Hybrid Approach Using Physical Insights And Data Science For Early Stuck Detection", Paper accepted by OTC, OTC-32532-MS, 2023
- [23] 井上朝哉, 和田良太, 三好啓介, ほか, "掘削を対象としたデジタル技術適用による安全性向上に関する調査プロジェクト", 日本船舶海洋工学会講演会論文集, ISSN: 2185-1840, 2020.