

(平成 30 年 2 月 2 日発表予定)

Keywords: 超大水深掘削, 再帰型ニューラルネットワーク, WOB, 時系列解析, グレーボックスモデル

Keywords: ultra-deep ocean drilling, recurrent neural network, WOB, time series analysis, gray-box model

1. 序論

資源開発や科学研究を目的とした海洋掘削が実施されているが、大水深化・大深度化が進行し、将来的には長さ 10,000m を超える掘削システムの実用化が視野に入ってきた。しかし、ドリルパイプ (以下, DP) の長大化により静的張力が増大するとともに、掘削船の動揺による DP の張力変動やビットの接地圧 (以下, WOB: Weight On Bit) の変動が増大する。特に DP の軸方向振動の固有周波数が掘削船の上下揺れ (以下, ヒープ) の周波数領域に近づくことで、それらの変動の増幅が懸念される。[1]

筆者らは先行研究[2]で、地球深部探査船「ちきゅう」の掘削システムの上方向挙動をモデル化し、DP 長さが約 4,000m と約 8,000m の 2 ケースにおいて船上で実測されたデータとシミュレーション結果との比較・考察を行った。その結果、8,000m のケースにおいて、WOB にヒープの周波数領域から離れた高周波数の変動が発生し、その原因がヒープコンペンセータ (以下, HC) の機構にある可能性を示した。さらに、現在「ちきゅう」では、実際の掘削性能の重要指標となる Downhole WOB をリアルタイムで計測することが困難であることから、DP 上端付近の張力から推定される Surface measured WOB で代用している (Fig. 1) が、8,000m のケースでは両者に乖離が生じることが示された。

今後益々大水深化が進む海洋掘削では WOB を正確にモニターできなければ適切な掘削作業が行えず、掘削性能の悪化に繋がるため、Downhole WOB をリアルタイムでモニターする必要がある。しかし、数千 m にも及ぶ DP 下端の挙動をリアルタイムで直接的に計測する技術の開発は現実的でないため、船上で計測可能なデータを用いて Downhole WOB を推定するモデルの開発が必要となる。

先行研究で扱ったような力学モデルは、現象理解には有効だが、パラメタを事後解析で調整するためにリアルタイム性が無かったり、顕在化していない現象のメカニズムを含むことが期待できなかったりなど、実務面で限界がある。本研究では、Downhole WOB を推定する手法において、力学モデルを補完する仕組みとしてブラックボックスモデルの活用方法を検討する。ブラックボックスモデルとして、再帰型ニューラルネットワーク (以下, RNN: Recurrent Neural Network) の適用性および汎化性の検証を行い、両者を用いたグレーボックスモデルの活用方法を検討する。

2. 手法

2.1 グレーボックスモデル

本研究では、力学現象をモデル化したホワイトボックスモデルと、力学現象を介さず入出力データのみから構築されたブラックボックスモデルの両者を用いたグレーボックスモデルの検討を行う。非線形系のブラックボックスによるモデル化は容易ではないとされているが[3]、本研究では、近年多分野で成果を挙げている深層学習の手法の一つである RNN を利用することにより超大水深掘削システムのモデル化を行う。

2.2 入出力データの作成

本研究で推定する Downhole WOB は実測データが殆ど無いため、これまでの研究で用いたシミュレ




Fig. 1 Schematic of Offshore Drilling System.

ーションモデルを用いて入出力データを作成する。具体的には、ブレットシュナイダー・光易型の波浪スペクトルと「ちきゅう」のRAOデータから不規則ヒープを作成し、シミュレーションモデルに強制ヒープを与え計算し、WOB等必要な入出力データを抽出した。なお、今回用いたシミュレーションモデルは、ランプトマス法による多質点・ばね・ダンパ系のモデルであり、DP部は線形ばね、HC部は、複雑な仕組みを精緻にモデル化した非線形ばねとなっている[2]。また、力学モデルに非線形性を加えることでより複雑な入出力データも作成できる。

2.3 再帰型ニューラルネットワークによる学習

深層学習は、多層のニューラルネットワークを用いた機械学習の手法であるが、実際には多層パーセプトロンや、畳み込みニューラルネットワーク等のいくつかの異なる方法論の集合であり、問題に応じてそれらが使い分けられている。本研究ではその中でも、時系列データを学習できる再帰型ニューラルネットワーク(以下、RNN: Recurrent Neural Network)を用いた学習を行い、ブラックボックスモデルを作成した。RNNは、出力が入力データの並びに強く依存するシステムのモデル化に適する手法であり[4]、本研究のようにヒープに対する応答を出力するモデルにも適していると考えられる。手順としては、①入出力データを訓練データとテストデータに分割し、②訓練データを用いて学習モデルの出力値と元データの出力値の平均二乗誤差を小さくするように学習を行い、③学習されたモデルにテストデータを入力し得られた出力を元の出力と比較することで精度の検証を行う。なお、RNNには学習できず予め与えるパラメタ(ハイパーパラメタ)があるが、十分な精度が得られるように調整した。また、モデルの全体像をFig. 2に示す。入力時刻(t-19)~t秒の1秒ごと、20秒間のCrown Block Position(DP上端の変位と等しく、以下、CBPとする。)やSurface measured WOB、出力は時刻t秒のDownhole WOBとする。また、ブラックボックスモデルの適用性の指標として回帰分析で一般的に用いられる決定係数(R^2)を採用する。決定係数は1が上限であり、大きい程モデルの適合度が高いことを示す。

3. 線形モデルへの適用性の検証

初めに、DP長約4,000mのケースと8,000mのケースの2種類のモデルについてそれぞれ入出力データを作成し、別々に学習を行った。なお入力・出力間には、線形ばね・ダンパのみが影響しているため、線形モデルの検証となる。なお、学習にはヒープを用いず、入力をCBPとして学習を行った。これは、CBPは船上で計測可能なデータであり、HCより下の要素であるため、HCの複雑な挙動を考慮しなくて良いためである。

3.1 DP長約4,000m ケース

4,000mのケースの場合、ヒープやCBPとWOBの周波数がほぼ等しく、逆位相となるような単純な

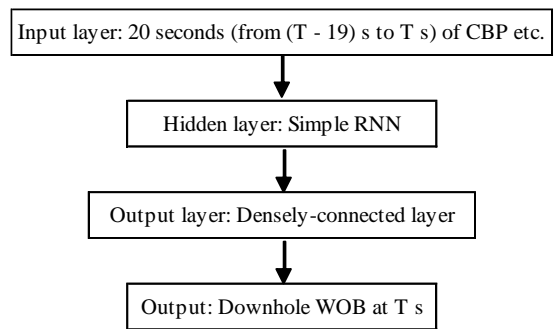


Fig. 2 Schematic of RNN model.







Fig. 3 RNN's output and original output (4,000 m case)



(a)



(b)



(c)

Fig. 4 RNN's output and original output (8,000 m case)

(a) input: CBP, (b) input: Surface measured WOB, (c) input: CBP and Surface measured WOB

挙動を示している。RNNによる学習を訓練データで行った後、テストデータのCBPをRNNモデルに入力することで出力されたDownhole WOBと力学現象をモデル化してシミュレーションしたDownhole WOBの比較をFig. 3に示す。4,000mのケースの場合、入力をCBPとするだけで十分に学習できている。

3.2 DP長約8,000m ケース

8,000mのケースでは、WOBにヒーブと異なる高周波数の振動が発生する。CBPには高周波数の振動が無いため、入力をCBPのみとした場合、Downhole WOBの高周波数成分を上手く表現できず、4,000mのケースと異なり十分に学習できない(Fig. 4 (a))。次に、入力をSurface measured WOBとして学習させた場合、Surface measured WOBにはDownhole WOBのように高周波数振動が発生しており、高周波数成分を学習することができるが、一方で、ヒーブに依存する周波数領域の精度が悪くなる Fig. 4 (b))。最後にCBPとSurface measured WOBの両方を入力として学習させた場合、非常に精度良く学習することができた(Fig. 4 (c))。

4. 非線形モデルへの適用性の検証

非線形現象への適用性の検証として、以下2種類の非線形性を加えた力学モデルによって作成された入出力データについてRNNによる学習を行った。

4.1 速度二乗減衰

これまで線形ばね・ダンパでモデル化したDP部に速度二乗減衰を加えた。速度二乗減衰は、DPの表面積に比例する摩擦抗力と、ツールジョイント部とDPのメイン部の断面積の差に比例する圧力抗力を考慮して与えた。また、非線形影響を強くするため、抗力を10,000倍したケースについても検証を行った。両ケース共にRNNは速度二乗減衰を加えたモデルについても十分に学習することができた(Fig. 5)。

4.2 ドリルビットの浮き上がり

Downhole WOBが大きく減るとゼロ以下にはならずドリルビットが孔底から浮き上がるように、DP下端のばね定数の調整を行った。このように、Downhole WOBとドリルビット下端変位の関係が折れ線型になるような強い非線形性は、同じ学習方法では精度よく学習できない。そこで、これまでは1層のRNNを用いていたが、3層のRNNを用いたところ精度良く学習することができた。

5. RNNモデルの汎化性

ここまでの検証では、1ケース毎にそれぞれ別々に学習を行ってきたが、本章では、様々な条件において、同じRNNモデルで適用可能かの検証を行う。なお、本章で用いるシミュレーションモデルは、速度二乗減衰を加えた非線形モデルである。

5.1 波浪条件への汎化性

プレットシュナイダー・光易型の波浪スペクトルの有義波高と有義波周期を変化させることにより、様々な波浪条件の入出力データを作成した。まず、4ケースのデータを用いて学習を行い、それぞれの有義波高と有義波周期が共に異なるケースについて、テストデータとして検証した。テストデータの有義波高や、有義波周期が、学習に用いた有義波高や、有義波周期の範囲内にある場合(内挿)の検証を行うと、4,000mのケース、8,000mのケース共に良く学習できた。次に、テストデータの有義波高や、有義波周期が、学習に用いた有義波高や、有義波周期の範囲外にある場合(外挿)の検証を行うと、4,000mのケースの場合良く学習できたが、8,000mのケースの場合、少し精度が落ちた。

Downhole WOBの実測データが将来的に得られた場合に、少ないケースの学習のみでも汎化性を果たすことができるかを検証するため、1ケースのみのデータで学習を行い、他のケースをテストデータとして検証を行った。4,000mのケースの場合、1ケースのみを用いて学習を行った場合でも、全体




Fig. 5 RNN's output and original output (velocity-squared damping model case)

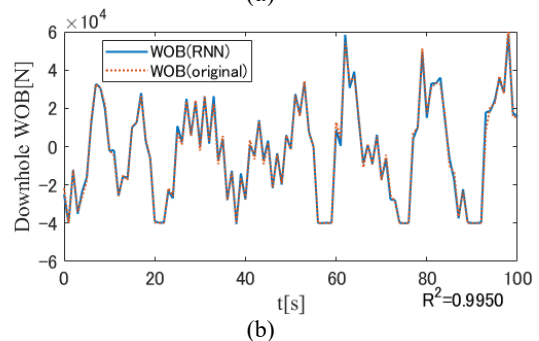
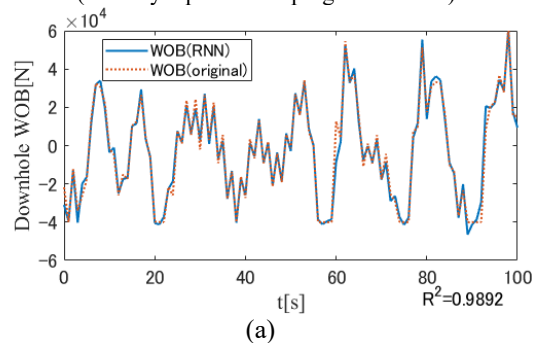


Fig. 6 RNN's output and original output (non-contact drill bit model case)

(a) single layer RNN, (b) triple layers RNN

としてそれほど精度が落ちなかったが、波浪条件が大きく異なる場合は精度が落ちるものも存在した。8,000m のケースの場合、4,000m のケースよりも全体として精度が悪く、特に有義波周期が大きく異なるケースにおいて精度が悪くなった。8,000m のケースの場合、DP の固有振動の周波数成分の大きさが有義波周期の違いにより大きく異なってくるため、学習精度が落ちたと考えられる。また、2 ケースを用いて学習を行った場合は、有義波周期が異なる 2 ケースを選択することで、広範囲で精度が高くなるケースが存在した。

5.2 DP の長さへの汎化性

DP の長さを変えて RNN モデルの汎化性の検証を行った。まず訓練データとして 1 ケースのみを用いた場合は、せいぜい ± 250 m ほどの汎化性しかもつことができず、500 m 以上長さが異なると精度が悪くなった。訓練データとして 2 ケースを用いた場合は、2 ケースの差が 1000 m の場合は、内挿の精度が非常に高いということが示された。一方、外挿の精度は ± 250 m ほどが限界であることが示された。

5.3 波浪条件と DP の長さ両方へ対しての汎化性

波浪条件について有義波周期が異なる 2 ケース、DP の長さについて 500 m 刻みの 9 ケースの計 18 ケースを用いて学習を行ったところ、内挿の精度が様々な波浪条件や DP の長さについて、内挿の精度が十分に高い RNN モデルを構築することができた。

6. グレーボックスモデルの活用法の考察

本研究では、Downhole WOB の実測データがほとんど得られない状況下で、力学モデルとブラックボックスモデルを組み合わせた推定手法の構築について検討している。特に船上で計測可能で DP 挙動の情報を含む Surface WOB を有効利用する方法が重要となる。まず、将来的に少ない Downhole WOB データだけでブラックボックスモデルを構築する場合は、海象条件や DP 長さ変化に対する汎化性が課題となることが示唆された。そこで本研究のようにブラックボックスモデルの学習にホワイトボックスモデルを活用する手法を提案する。このグレーボックスモデルは、力学モデルで表現される CBP, Surface WOB と Downhole WOB の関係性を持ち、また実測される CBP と Surface WOB を直接入力として扱える利点を持つ。

提案するグレーボックスモデルの有効性を模擬的な実測データにより検証した。模擬的な実測データは、学習に用いた力学モデルでは考慮されていない非線形性を含めて作成した。その CBP と Surface WOB を入力として推定される Downhole WOB が模擬的な実測データと良い精度で一致した(Fig. 6)。こうしたアプローチは、目的の実測データは得られないが、基本的な力学モデルと関連する実測データが得られるケースについて、両者のメリットを有効に組み合わせるモデルになっていると考えられる。

7. 結言

本研究では、超大水深掘削システムについて RNN による学習を行い、RNN によるブラックボックスモデルの適用性や汎化性を示すことができた。また、超大水深掘削における WOB の推定手法として、RNN と力学モデルを融合させたグレーボックスモデルについて、その有効性を示すことができた。本研究で構築したグレーボックスモデルは、超大水深掘削に限らず、様々なシステムに応用できる可能性があるため、今後更なる発展が期待できる。

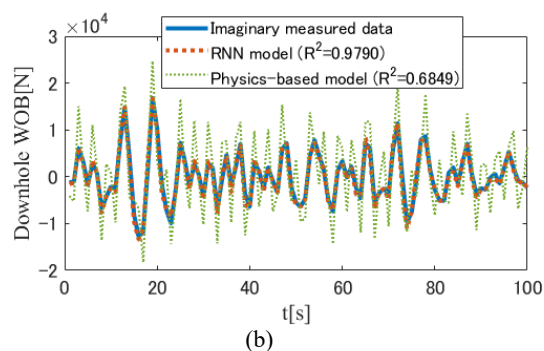
グレーボックスモデルの精度は、元となるホワイトボックスモデルとブラックボックスモデルの精度に影響されるため、両者共に今後益々検討される必要がある。

謝辞

「ちきゅう」の掘削データをご提供いただいた JAMSTEC / CDEX の関係各位に謝意を表します。

参考文献

- [1] 井上朝哉：日本船舶海洋工学会講演会論文集 10(2009)213-220.
- [2] 金子達哉, 和田良太, 尾崎雅彦, 他：日本船舶海洋工学会講演会論文集 23(2016)35-37.
- [3] J. Sjöberg, Q. Zhang, L. Ljung, et. al., *Automatica* 31(11) (1995)1691-1724.
- [4] J. J. Hopfield, *Proceedings of the National Academy of Sciences of the United States of America* 79(8) (1982) 2554-2558.



(b)
Fig. 6 RNNs' output and original output (non-contact drill bit model case)