

딥러닝 기반 시추장비 이상 예측 및 진단 모델 개발 연구

한동권*, 김민수*, 권순일*, 최정호**

*동아대학교 환경에너지공학부 미래에너지공학전공

**동아대학교 조선해양플랜트공학과

dkhan@donga.ac.kr, minsoo0821@naver.com, sikwon@dau.ac.kr, tamuchoi@dau.ac.kr

A Study on the Development of Anomaly Detection Prediction Model for Deep Learning-Based Drilling Equipment

Dong-Kwon Han*, Min-Soo Kim*, Sun-Il Kwon*, Jung-Ho Choi**

*Dept. of Future and Energy Engineering, Dong-A University

**Dept. of Naval Architecture and Offshore Engineering, Dong-A University

요 약

석유개발 현장에서 시추장비의 고장으로 인한 장비교체 및 시추시간 증가는 막대한 비용소모를 발생시킨다. 본 논문은 딥러닝 기반의 시추장비 중 드릴비트의 동력을 구동시키는 디젤엔진의 고장 요소를 분류하고 이 요소에 따른 고장여부를 판별하는 딥러닝 기반의 이상 예측 및 진단 모델을 개발하였다. 또한 제안한 모델의 우수성을 확인하기 위해 로지스틱 회귀분석 분류모델과의 예측성능 비교분석도 수행하였다.

1. 서론

석유개발에서 탐사와 생산 분야에서 시추는 상당한 시간과 비용이 소요되는 필수작업요소 중 하나이다. 이러한 시간과 비용소모를 줄이기 위한 일환으로 석유개발 분야에 2010년대 초반부터 4차산업혁명 기술인 사물인터넷과 빅데이터를 포함한 종합적인 ICT를 접목해 현장 상황을 실시간으로 관찰하거나 탐사 및 생산 전 과정을 자동화 하여 온라인으로 관리하는 시스템인 디지털 오일필드 시스템을 적용하였다. 이에 따라 세부적으로 석유공학 각 분야에서 다양한 ICT 및 인공지능 기술을 적용한 연구들이 수행되었다 [1]-[4].

석유 시추분야에서도 다양한 인공지능 적용 연구들이 수행되어 왔는데 일반적으로 시추 시 발생하는 막대한 비용을 줄이기 위해 시추 효율성을 향상시키는데 도움을 주는 어플리케이션으로 활용하는 연구들이 주를 이루고 있다 [5-8]. 시추 효율을 높이기 위해서는 비트의 일정한 회전수와 굴진율도 중요하지만 고장 및 이상으로 인한 장비 교체 시간 소모를 줄이는 것도 상당히 중요한 부분이다. 이상 예측 및 고장은 시추드릴 비트, 이수 펌프 모터, 디젤 엔진에

서 발생할 수 있으며 이 중 디젤 엔진은 앞서 2가지의 구동력을 전달하는 역할을 담당하기 때문에 엔진의 부하나 관리가 필요하다. 엔진의 이상은 크게 진동과 점화상태 배기가스, 윤활유, 오일 등의 온도 및 유량과 같은 영향인자 파악을 통해 예측 및 진단이 가능하다.

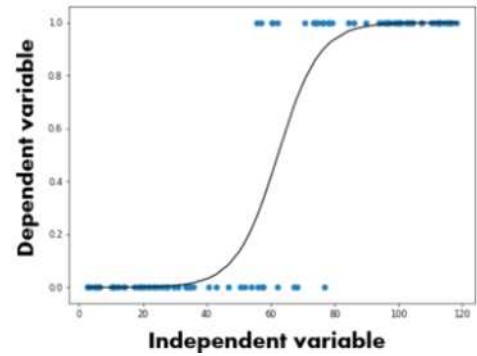
본 논문에서는 지도학습 분류기법 중 하나인 다층퍼셉트론 (Multi Layer Perceptron: MLP) 기반의 딥러닝 모델을 이용하여 시추장비의 고장여부를 진단하는 모델을 개발하는 연구를 진행하였다.

2. 학습 데이터 및 모델 소개


일반적으로 육상 시추장비는 비트의 회전구동력을 가하는 Top-drive drilling 모터를 작동하기 위한 전기모터를 디젤엔진의 발전으로 가동시키며 이 전기를 이용하여 시추 시 공저의 압력 유지 및 공벽 보호의 목적으로 주입되는 이수의 순환을 위한 이수 펌핑 모터를 사용한다 (그림 1). 시추작업에서 고장은 크게 비트장비, 이수펌프, 디젤엔진의 문제로 나눌 수 있다. 디젤엔진의 전기모터는 시추작업 전반에 걸친 동력을 제공하기 때문에 매우 중요한 장비 중 하나이다. 그리하여 엔진장비의 고장진단에 영향

을 미치는 인자를 도출하고 고장을 예측하는 분류 모델 데이터를 학습자료로 활용하기 위한 자료를 수집하였다. 디젤엔진의 고장에 영향을 미치는 인자는 대개 베어링의 손상, 피스톤의 마모, 엔진 실화(Miss fire), 엔진 Underbalance 문제, 가스 누출 (Gas leakage) 등이 대표적이다. 본 연구에서 모델 학습에 활용한 자료는 OREDA Reliability Data Handbook으로, 이는 장비 수명을 예측하는 엔진 효율 저하와 관련된 다양한 원인과 인자들에 대한 범위와 고장률의 관계에 대하여 기술하고 있는 서적이다. 상기 데이터를 기반으로 하는 공정 동적 모델을 통해 고장이 발생하는 경우를 다양한 범위에서 산출하였다.

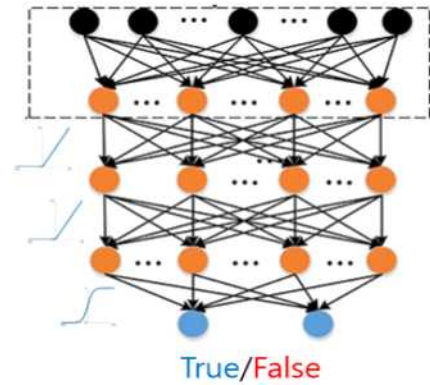
52055개 케이스로 각각 정상상태가 25055개, 고장상태 27000개이다. 학습자료 60%, 검증자료 20%,



(그림 2) 로지스틱 회귀분석.



(그림 1) 육상 시추장비 엔진 동력 전달 계통도.



(그림 3) MLP 기반의 딥러닝 알고리즘.

이 연구에서 개발한 이상 예측 진단 모델은 로지스틱 회귀분석 (그림 2)과 MLP 기반 딥러닝 모델 (그림 3)로 분류 모델에 적합한 지도학습 알고리즘이다. 학습데이터를 확보하기 위하여 OREDA Handbook의 데이터베이스를 이용하여 배기가스 온도, 외부 온도, 엔진출력, 연료 온도, 윤활유 온도, 오일 유량 등을 입력자료로 생성하였으며 베어링 손상, 피스톤 마모손실의 입력변수 범위를 0.1~0.5%로, Miss fire의 고장효율 범위를 0.35~0.5%로 하는 모델을 통해 정상상태 (True), 비정상상태 (고장, False)의 출력변수를 산출하였다 (그림 4, 5). 학습자료를 만들기 위해 시뮬레이션에 입력한 영향인자들은 <표 1>과 같다.

공정 동적 모델을 이용한 synthetic data 생성


| | | | |
|---------------------|--------------------|--|---|
| Exhaust gas T | - 60 ~ 120 °C | | 베어링 손상 |
| Air T | - 0 ~ 36 °C | | 피스톤 마모 |
| Power Heat Q | - 200 ~ 1800 kW | | Miss fire |
| Fuel T | - 60 ~ 120 °C | | |
| Oil in/outlet T | - 60 ~ 300 °C | | - 베어링 손상, 피스톤 마모 손실 입력변수 범위 0.1~0.5% - Miss fire의 고장 효율 범위 0.35~0.5% |
| Mass flow rate kg/h | - 40,000 ~ 390,000 | | |

(그림 4) 학습자료 생성을 위한 시뮬레이션 모델 범위.

3. 학습 및 예측 결과

개발한 시추장비 이상 예측 진단 모델은 MLP 기반 딥러닝, 로지스틱 회귀분석 2가지 지도학습 분류 기법을 통해 학습 및 예측을 해보고 비교를 수행하였다. 학습자료로 활용한 시뮬레이션 자료는 총

MLP 기반 딥러닝 디젤엔진 고장 진단 모델



(그림 5) 디젤엔진 고장진단 딥러닝 모델.

<표 1> 고장 진단 모델 생성을 위한 OREDA Handbook기반 동적 모델 synthetic data 생성

| | 계측값 | 정상 상태 모델 | | 비정상 상태 모델 | | |
|-------------------------|------|----------|--------|-----------|--------|-------------|
| | | new | old | Miss fire | 피스톤 마모 | Gas leakage |
| Power [kW] | 1800 | 1800 | 1800 | 1350 | 1800 | 1800 |
| Fuel Consumption [kg/h] | | 292.4 | 324.9 | 324.9 | 298.4 | 298.4 |
| Air Temperature [C] | | 25 | 25 | 25 | 25 | 25 |
| Oil flow [kg/h] | | 40,000 | 40,000 | 40,000 | 4,000 | 40,000 |
| Oil Temperature In [C] | | 70 | 70 | 70 | 70 | 70 |
| Oil Temperature Out [C] | 75.7 | 75.99 | 77.31 | 72.75 | 76.23 | 76.27 |
| Air Temperature Out [C] | 76.6 | 76.7 | 81.52 | 72.8 | 77.46 | 75.97 |

테스트 자료는 20%로 모델의 과대적합을 예방하기 위해 첫 번째로 k-fold validation 기법을 활용하였고 k의 개수는 10개로 설정하였으며 k당 학습자료의 개수는 275개로 10번의 학습자료 분류가 이루어졌다. 두 번째는 목적함수로 지정한 Loss값이 더 이상 개선되지 않으면 학습을 중단하는 텐서플로 케라스 모듈의 콜백함수 (Callback function)와 조기종료 (early stopping) 방법을 이용하였다. 딥러닝 모델의 손실함수는 0과 1의 이진법의 분류문제를 해결해주는 binary crossentropy를 적용하였다. 하이퍼파라미터를 최적화하는 민감도 분석 수행결과, 옵티마이저는 rmsprop, metrics는 정확도로 에포크 (epoch)이 100일 때 학습정확도가 0.97 검증정확도가 0.97인 것으로 나타났다. 테스트자료는 2750 개의 케이스로 검증하였다. 정상상태로 정확히 예측한 결과는 1083 케이스로 86.6%, 고장상태로 예측한 결과는 1179 케이스로 78.6% (총 예측결과 82.2%) 이다. 분류 모델을 평가하는 정밀도 (Precision) 지표는 86.6%, 재현율 (Recall)은 77.1%, 정확도 (Accuracy)는 82.3%이다. 개발 모델의 정상상태 예측성능이 더 우수한 것으로 확인되었다 <표 2>. 로지스틱 회귀모델의 경우 학습 결과 학습정확도가 0.89, 검증정확도가 0.80

으로 나타났다. 테스트자료의 정상상태로 예측한 결과는 1008 케이스로 80.7%, 고장상태로 예측한 결과는 912 케이스로 60.8%이다. 평가지표는 정밀도 (Precision)가 80.6%, 재현율 (Recall)은 63.2%, 정확도 (Accuracy)는 69.8%이다 <표 3>. 분석 결과 로지스틱 회귀모델이 정상 및 고장상태를 예측하는 정확도 및 분류 모델 평가지표에서도 전반적으로 딥러닝 모델에 비해 예측성능이 낮은 것으로 확인되었다.

<표 2> MLP 기반 딥러닝 분류모델을 이용한 각 케이스별 예측 결과

| | 정상 (True) | 고장 (False) |
|------------|-----------|------------|
| 정상 (True) | 1083 | 167 |
| 고장 (False) | 321 | 1179 |

<표 3> 로지스틱 회귀분석 분류모델을 이용한 각 케이스별 예측 결과

| | 정상 (True) | 고장 (False) |
|------------|-----------|------------|
| 정상 (True) | 1008 | 242 |
| 고장 (False) | 588 | 912 |

4. 결론

본 논문에서는 시추장비인 비트의 구동력을 전달하는 디젤엔진의 고장 진단 여부를 확인할 수 있는 딥러닝기반 분류 모델을 제안하였다. 제안한 모델은 엔진 실화, 가스누출, 피스톤 마모의 원인으로 발생하는 고장 여부를 진단가능한 분류 모델이다. OREDA Reliability Data Handbook 기반의 장비수명 기준으로 엔진 효율을 저하시키는 다양한 범위의 데이터셋을 학습자료로 활용하였다. 학습에 사용하지 않은 테스트자료를 이용하여 로지스틱 회귀 모델과 MLP 기반 딥러닝 모델을 분류 기법 정확도 평가기법을 이용하여 비교한 결과 딥러닝 모델이 82%로 로지스틱 회귀 모델 70%에 비해 약 12% 이상 예측성능이 우수한 것으로 확인되었다. 향후 연구에서는 시추장비의 예지보전 관점에서 디젤엔진의 노후화에 따른 수명이나 고장 예측을 시계열자료를 통해 RNN을 이용한 딥러닝 모델을 개발하고자 한다.

사사

본 연구는 2021년도 산업통상부의 재원으로 한국에너지기술평가원(KETEP)의 지원을 받아 수행한 연구 과제입니다(No. 20182510102500).

참고문헌

- [1] 김성수, 손지연, 박준희, “디지털 오일필드에서 빅데이터 분석기반 IT 융합 기술 동향”, 전자통신동향분석, Vol. 28, No. 4, 2013.
- [2] 김현태, “4차산업혁명 시대 자원개발 산업의 디지털 전환 기술개발 동향”, 한국자원공학회지, Vol. 56, No. 5, pp. 514-528, 2019.
- [3] 정지현, 한동권, 김상호, 유인항, 권순일, “인공지능을 적용한 시추 굴진을 최적화 기술 동향 분석”, 한국가스학회지, Vol. 24(1), pp. 66-75, 2020.
- [4] 한동권, 권순일, “오일 생산정에서 초크사이즈와 가스주입량에 따른 생산성 예측 인공지능경망 모델 개발”, 한국가스학회지, Vol. 22(6), pp. 90-103, 2018.
- [5] Li Zhiyong, Zhao Hongdong, Zeng Ruili, Xia Kewen, Guo Qiang, and Li Yuhai, “Fault Identification Method of Diesel Engine in Light of Pearson Correlation Coefficient Diagram and Orthogonal Vibration Signals”, Mathematical Problems in Engineering Vol. 2019, Article ID 2837580, 10 pages, 2019.
- [6] Ezzeddine Ftoutou, and Mnaouar Chouchane “Diesel Engine injection faults’ detection and classification utilizing unsupervised fuzzy clustering techniques”, J. Mechanical Engineering Science, Vol. 233(16), pp, 5622-5636, 2019
- [7] Yuxing Ben Chris James, Dingzhou Cao, “Development and Application of a Real-Time Drilling State Classification Algorithm with Machine Learning”, at the Unconventional Resources Technology Conference (URTec) held in Dever, Colorado, USA, 2019, URTeC: 253.
- [8] Rayan Kanfar, Obai Shaikh, Mehrdad Yousefzadeh, Tapan Mukerji, “Real-Time Well Log Prediction From Drilling Data Using Deep Learning”, at the International Petroleum Technology Conference held in Dhahran, Saudi Arabia, 2020, IPTC-19693-MS.