

BLDC 팬모터의 모터 DC 전압을 이용한 고장 진단

심준석, 조현진, 박정환, 김호원*

부산대학교, 부산대학교, 부산대학교, *부산대학교

sugo312@pusan.ac.kr, wh77r77@pusan.ac.kr,

gg2059@pusan.ac.kr, *Howonkim@gmail.com

Fault Diagnosis Using DC Voltage Of BLDC Fan Motor

Jun Seok Shim, Hyun Jin Jo, Sang Hyun Lee, Ho Won Kim*

Pusan National Univ., Pusan National Univ., Pusan National Univ., *Pusan National Univ.

요 약

본 논문은 BLDC 팬모터의 DC 전압을 사용하여 오랜 사용으로 인해 결상된 BLDC 팬모터 또는 BLDC 팬모터 불량 제품의 고장을 진단하는 방법을 제안한다. 기존에는 모터의 진동 특성에 FFT 등 신호 분석 방법들을 모터의 진동 특성에 적용하여 모터의 고장을 진단하는 방법들을 제안하였다. 그러나 가전제품들 내부에 설치되는 공간적 특성상 광학 인코더 또는 가속도 측정 센서들을 부착하여 진동 특성을 추출하고, 추출된 진동 특성을 기반으로 하여 고장을 진단을 수행하기 어렵다. 따라서 본 논문에서 제안된 방법은 시계열 데이터를 처리하기 위한 모델인 BiLSTM을 BLDC 팬모터의 접지단에서 출력되는 모터의 DC 전압에 적용하여 고장을 진단하는 방법을 제안한다.

I. 서 론


본 논문에서는 BLDC 팬모터의 DC 입력단 전압 정보만을 활용하여 모터의 고장 진단을 제안한다. 기존에는 모터에서 출력되는 펄스 기반의 고장 진단 로직 또는 모터의 진동 특성에 FFT와 같은 신호 분석 방법들[1]을 사용하여 모터의 고장 진단을 진행하였다. 그러나 기존의 펄스 기반의 모터 고장 진단의 경우 모터가 완전히 고장이 난 이후에야 모터의 고장을 진단할 수 있으며, 진동 특성 및 신호 분석 방법을 기반으로 한 모터의 고장 진단의 경우 가전제품 내에 광학 인코더 및 가속도 측정 센서를 부착하여야만 진동 특성을 추출할 수 있기 때문에 공간적인 제약이 있다.

따라서 본 논문은 BLDC 팬모터의 초기 고장 진단 및 가전제품 등에서 적용되는 공간적인 제약 등을 해결하기 위해 BLDC 팬모터의 접지단에서 출력되는 DC 전압을 사용하여 시계열 데이터를 처리하기 위한 모델인 BiLSTM 기반의 고장 진단 모델을 제안한다.

II. 본론

II-1. 데이터 전처리

본 논문에서 제안한 데이터 전처리 프로세스는 [그림 1]과 같다. BLDC 팬모터의 고장 진단을 위해 BLDC 팬모터의 접지단에서 출력되는 모터의 DC 전압을 증폭시키기 위해 비반전 증폭기가 사용된다. 비반전 증폭기는 입력 단자 간의 전위차(전압)보다 대개 백배에서 수 천배 큰 출력 전압을 생성하는 직류 연결형 고이득 전압 증폭기인 연산 증폭기(Op-amp)를 사용해 입력 전압의 부호와 일치하는 증폭된 출력 전압을 생성한다. 그 다음 데이터 전처리 단계로 생성된 전압의 노이즈를 제거하는 단계를 거친다. 본 논문에서 제안된 방식에는 노이즈를 제거하기 위해 저주파 통과 필터(Low Pass Filter, LPF)를 사용하였다.




[그림 1] 데이터 전처리 프로세스

II-2. 고장 진단 모델

BLDC 팬모터는 3상 인버터에 의해 구동되며 출력되는 DC 전압의 파형은 3상 전류가 합성된 파형이 그려진다. 따라서 본 논문은 BLDC 팬모터의 고장 진단을 위해 정현파의 고유한 특성인 주기성 및 시계열 데이터를 처리하기 위한 딥러닝 모델인 BiLSTM[3]을 활용하여 고장 진단을 진행하였다. BiLSTM은 시계열 데이터 처리를 위한 딥러닝 모델인 RNN의 문제점인 장기의존성을 개선한 모델이다. 해당 방법을 통하여 입력 시점인 (t) 시점에서 데이터의 기본 주기 (n)이후의 시점인 (t+n)시점에서의 예측 값과 실제 값 사이의 비교를 통해 고장 진단을 수행하였다.

[그림 2]는 데이터 전처리가 포함된 전체 고장 진단 모델을 나타낸다. 먼저 훈련부(Training Step)와 검증부(Test Step)으로 나뉘며 훈련부에서 정상 모터의 DC 전압에 대한 데이터만을 입력시켜 학습을 진행한다. 데이터 전처리부를 통해 노이즈 및 증폭 작업을 진행하고, 전처리된 데이터는 학습을 위해 BiLSTM에 입력된다. BiLSTM을 통해 정상 데이터에 대한

학습 가중치를 얻을 수 있으며, MSE 가우시안 분포 D_{train} 의 정확도 95%의 신뢰구간인 R_{train} 을 얻을 수 있다. D_{train} 의 분포는 [그림 3]과 같다.



[그림 2] BiLSTM을 사용한 전체 이상탐지 모델

그 다음 검증부에서 훈련부와 같이 전처리를 진행하며 전처리된 데이터는 훈련부에서 학습된 가중치를 기반으로 예측값들을 출력한다. 출력된 예측값과 실제값을 비교하여 MSE 가우시안 분포 D_{test} 의 정확도 95%의 신뢰구간인 R_{test} 을 얻을 수 있다.

최종적으로 위에서 얻은 신뢰구간인 R_{train} 과 R_{test} 를 비교하여 R_{test} 이 R_{train} 에 포함되면 정상인 모터로, 포함되지 않는다면 고장난 모터로써 분류한다.

II-3. 결과

본 논문에서는 검증을 위해 정상 데이터만 포함된 검증 데이터인 $Valid_{normal}$ 과 불량 모터의 데이터가 포함된 검증 데이터인 $Valid_{abnormal}$ 에서의 MSE 가우시안 분포인 D_{normal} , $D_{abnormal}$ 를 얻었다. 각 검증 데이터들의 분포인 D_{normal} , $D_{abnormal}$ 에서의 정확도 95% 신뢰 구간 R_{normal} , $R_{abnormal}$ 과 훈련부에서의 MSE 가우시안 분포 정확도 95% 신뢰구간인 R_{train} 안에서의 포함 여부를 통해 검증을 진행하였다.


[그림 4]는 D_{train} 과 D_{normal} 를 비교한 그림이다. R_{normal} 이 R_{train} 안에 포함되므로 $Valid_{normal}$ 은 정상적인 데이터임을 예측할 수 있으며, 실제 $Valid_{normal}$ 는 정상 모터의 데이터만이 포함된 데이터 셋이다.

[그림 5]는 D_{train} 과 $D_{abnormal}$ 를 비교한 그림이다. $R_{abnormal}$ 이 R_{train} 안에 포함되지 않으므로 $Valid_{abnormal}$ 은 모터가 불량임을 예측할 수 있으며 실제 $Valid_{abnormal}$ 또한 불량 모터의 데이터가 포함된 데이터이므로 정확하게 정상, 불량 모터로 분류해 낼 수 있었다.

III. 결론


본 논문에서는 BiLSTM을 사용해 BLDC 팬모터에서 나오는 DC 전압을 학습 및 테스트시킴으로써 시계열 데이터를 처리하기 위한 딥러닝 모델인 BiLSTM기반의 고장 진단 방식을 제안하였다.

또한 기존의 펄스 기반 혹은 진동 특성 기반의 방식과 달리 BLDC 팬모터의 접지단에서 쉽게 추출 가능한 DC 전압과 MSE 가우시안 분포도를 통해 쉽게 고장 진단이 가능함을 실험을 통해 검증하였다.




[그림 3] 훈련부에서의 가우시안 분포

D_{train}



[그림 4] D_{train} 과 D_{normal} 을 비교한 그림



[그림 5] D_{train} 과 $D_{abnormal}$ 을 비교한 그림

ACKNOWLEDGMENT

이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (2019-0-01343, 융합보안핵심인재양성사업)

참고 문헌

- [1] Zachar, Ryan, et al. "Utilizing spin-down transients for vibration-based diagnostics of resiliently mounted machines." IEEE Transactions on Instrumentation and Measurement 65.7 (2016): 1641-1650.
- [2] M. Schuster, K. K. Paliwal, "Bidirectional recurrent Neural Networks," IEEE Transactions on Signal Processing, vol.45, no. 11, pp. 2673-2681, 1997.
- [3] Flam, J. T., Chatterjee, S., Kansanen, K., & Ekman, T. (2011). Minimum mean square error estimation under gaussian mixture statistics. arXiv preprint arXiv:1108.3410.