

특징기반 오토인코더를 이용한 고출력 스피indle 모터 진단

김종근*, 이현욱*
한국전기연구원*

High-performance Spindle Motor Fault Diagnosis using Feature Based Autoencoder

Jonggeun Kim*, Hyeonuk Lee*
Korean Electrotechnology Research Institute*

Abstract - 모터는 제조산업, 로봇 및 전기차에도 적용되면서 적용분야가 점점 늘어나고 있다. 모터 사용량이 늘어남에 따라 모터 상태모니터링에 대한 중요도 또한 증가하고 있다. 특히 고출력 모터의 경우 고위험 장비로 분류되기 때문에 모니터링 시스템이 더욱 중요하다. 본 논문에서는 고출력 스피indle 모터 진단을 위해 특징기반 오토인코더를 이용한 진단모델을 제안한다. 특징기반 오토인코더는 다변량 시계열데이터에서 특징을 추출하여 오토인코더의 입/출력 벡터로 사용하는 방법으로 오토인코더의 계산량을 줄일 수 있으며 더 좋은 성능을 낼 수 있다. 본 논문에서 사용된 스피indle 모터에 특징기반 오토인코더 진단모델을 적용한 결과, 스피indle 모터 고장을 정확하게 판단한 것을 확인할 수 있다.

1. 서 론

전동모터는 제조산업 및 다양한 분야에서 널리 이용되고 있으며 최근에는 전기차 및 다양한 로봇에도 모터가 적용되어 적용되는 분야가 점점 증가하고 있다[1]. 모터의 응용분야가 증가함에 따라 모터 상태모니터링에 대한 관심도 높아지고 있으며 관련 연구도 활발히 진행되고 있다. 특히, 제조공정에 많이 이용되는 스피indle 모터의 경우 높은 출력을 내기 위해 고압, 고전류를 사용하기 때문에 위험에 많이 노출되어 있으며 스피indle 모터의 이상은 생산품 품질에 영향을 줄 뿐만 아니라 관련 장치 또는 시스템에 영향을 줘 경제적 손실까지 유발한다. 따라서 안전한 작업환경 조성 및 생산품 품질 및 생산성 향상을 위해 모터 상태모니터링 시스템이 필요하다[2].

고장진단 방법으로는 크게 모델기반 방법과 데이터기반 방법으로 나눌 수 있다. 모델기반 고장진단은 대상시스템의 물리적 정보로부터 명확한 수학적 모델을 도출하는 것이며 파라미터 추정, 패리티 방정식 및 칼만필터와 같은 방법이 널리 사용되고 있다. 하지만 모델기반 고장진단은 물리적 정보가 충분하지 않거나 부정확한 경우 모델의 정확도가 매우 나빠질 수 있으며 이에 따른 진단성능 또한 영향을 받을 수 있다. 데이터기반 고장진단은 시스템 또는 장비에 설치된 센서데이터를 이용하여 진단을 수행하거나 진단모델을 학습하는 방법이다. 데이터기반 고장진단은 모델기반 고장진단과 달리 대상 시스템에 대한 사전지식이나 전문가 지식이 필요하지 않으며 양질의 데이터만 있다면 모델 구현이 가능하다[3]. 본 논문에서는 고장진단에 많이 적용되는 데이터기반 모델인 오토인코더를 이용한 스피indle 모터 진단 방법을 제안한다.

2. 특징기반 오토인코더

2.1 오토인코더

오토인코더(Autoencoder)는 기계학습 알고리즘 중 하나로 비지도학습 기반 모델 학습방법이다. 오토인코더의 구조는 일반적인 순방향 신경망(Feed forward neural network)과 유사한 형태를 가지며 그림 1과 같이 입력층과 출력층의 노드수가 같도록 구성한다. 인코더(Encoder)에서는 입력된 데이터의 차원을 축소

하여 잠재공간(Latent space)으로 보내고 축소된 데이터는 다시 디코더(Decoder)를 통해 원래의 차원으로 복원된다. 오토인코더의 목표벡터(Target vector)는 입력벡터와 동일한 데이터가 사용되며 데이터의 레이블(Label)이 필요없기 때문에 데이터 가공 시간을 줄일 수 있으며 다양한 분야 및 시스템에 폭넓게 사용할 수 있는 장점이 있다[4].

m개의 특징을 가지는 입력벡터를 $\mathbf{x} = [x_1, x_2, \dots, x_m]$ 로 두었을 때 인코더파트의 계산은 식 (1)과 같으며 결과 값으로 잠재벡터(Latent vector)를 출력한다.

$$\mathbf{h} = f(\mathbf{W}_e \mathbf{x} + \mathbf{b}_e) \quad (1)$$

여기서 f 는 인코딩 함수이고 \mathbf{h} 는 잠재벡터이며 \mathbf{W}_e 와 \mathbf{b}_e 는 각각 인코더의 가중치행렬과 바이어스 벡터이다. 디코더파트에서는 잠재벡터를 다시 원래의 차원으로 복원하는 계산이 수행되며 식 (2)와 같이 계산된다.

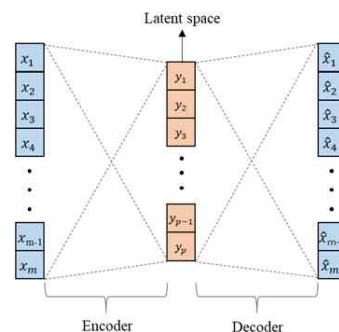
$$\hat{\mathbf{x}} = g(\mathbf{W}_d \mathbf{h} + \mathbf{b}_d) \quad (2)$$

여기서 g 는 디코딩 함수이고 $\hat{\mathbf{x}}$ 는 추론된 벡터로 잠재벡터에서 원래의 차원으로 복원된 벡터이며 \mathbf{W}_d 와 \mathbf{b}_d 는 각각 디코더의 가중치행렬과 바이어스 벡터를 나타낸다. 오토인코더는 입력벡터와 복원된 출력벡터간의 차이가 최소가 되도록 학습되기 때문에 식 (3)과 같이 학습된다.

$$\underset{\mathbf{W}_e, \mathbf{b}_e, \mathbf{W}_d, \mathbf{b}_d}{\text{Argmin}} [L(\mathbf{x}, \hat{\mathbf{x}})] \quad (3)$$

2.2 특징기반 오토인코더

시계열 데이터를 가공하지 않은 상태로 오토인코더에 적용할 경우 입력벡터와 출력벡터의 길이가 매우 길어질 수 있으며 다변량 데이터를 동시에 처리할 수 없다. 입력벡터가 길어질 경우 계산해야 할 노드가 많아지면서 계산량이 증가하고 잠재공간으로 데이터 벡터가 압축될 때 압축률이 높아지기 때문에 성능이 떨어질 수 있다.



<그림 1> Vanilla autoencoder 구조



〈그림 2〉 하중 부가장치가 설치된 스핀들모터

본 논문에서는 다변량 데이터 처리 및 입력벡터의 크기로 인한 문제점을 해결하기 위해 시계열 데이터에서 추출한 특징을 이용하는 특징기반 오토인코더를 제안한다. 본 논문에서 사용된 특징데이터는 스핀들모터의 진동센서 및 전류센서 데이터에서 추출된 평균값, 최대값, 최소값, 표준편차 및 제곱평균제곱근(Root mean square, RMS)으로 구성하였다.

3. 실험 및 결과



본 논문에서 사용된 스핀들모터는 60kW급 모터로 최대 30000RPM까지 회전 가능하며 그림 2와 같이 모터의 앞쪽 부분에 하중을 가할 수 있도록 하중 부가장치를 설치하여 실험을 진행하였다. 실험에 사용된 센서로는 스핀들모터 내부에 전방 진동센서와 후방 진동센서를 설치하였으며 스핀들모터 외부에 x축 y축 방향으로 각각 하나씩 부착하였다. 그리고 모터의 3상 전류를 계측할 수 있도록 전류센서 3개를 설치하여 스핀들모터 전류를 계측하였다.

특징기반 오토인코더에 사용된 특징 데이터는 스핀들모터 내부에 장착된 2개의 진동센서 데이터, 외부에 장착된 2개의 진동센서에서 각각 계측한 x축 y축 진동데이터 그리고 3상 전류중 u상 전류와 3상 전류의 RMS 값으로부터 평균값, 최대값, 최소값, 표준편차 및 RMS를 계산하여 구성한 것으로 총 40개의 특징을 가지는 입력벡터를 사용하였다.

특징기반 오토인코더를 이용한 스핀들모터 진단모델은 정상상태의 스핀들모터 특징데이터를 이용하여 학습을 진행한다. 학습이 완료된 진단모델은 질의 벡터가 들어왔을 때 추정벡터를 출력으로 내보내고 추정벡터(\hat{x})와 입력벡터(x) 사이의 오차값을 이용하여 스핀들모터를 진단한다. 본 논문에서는 제곱예측오차(Squared prediction error, SPE)를 복원 오차값 계산에 사용하였으며 SPE는 식 (4)와 같이 계산된다. 여기서 $e_q(k)$ 는 k 번째 질의벡터의 잔차값이다.

$$SPE(k) = \|e_q(k)\| = \|\hat{x} - x\| \quad (4)$$

그림 3은 특징기반 오토인코더를 이용한 스핀들모터 진단결과를 보여준다. 그림 3 (a)는 복원 오차값인 SPE 계산 결과를 보여주며 검은색 실선은 정상상태 스핀들모터의 결과를 나타내고 파란색 실선은 고장이 발생한 스핀들모터 진단결과를 나타내며 빨간색 실선은 진단모델의 문턱값을 나타낸다. 그림 3 (b)는 SPE 결과값을 알람신호로 나타낸 것이다. 정상상태 데이터를 이용한 진단모델 결과를 보면 대부분의 결과가 문턱값을 넘지 않고 정확한 진단을 하고 있지만 일부 결과에서 문턱값이 넘어서 정상상태를 고장으로 판단하는 Type1 오류가 발생하였다. 그러나 고장상태 데이터 진단의 경우 모두 고장으로 판단하여 Type2 오류는 0%로 정확하게 진단을 수행하였다.



〈그림 3〉 특징기반 오토인코더를 이용한 스핀들모터 진단 결과: (a) 복원 오차값; (b) 알람신호

4. 결론

본 논문에서는 특징기반 오토인코더를 이용한 고성능 스핀들모터 진단을 제안하였다. 오토인코더는 비지도학습 방법중 하나로 데이터의 레이블이 필요없기 때문에 데이터를 얻기 쉽고 다양한 데이터에 적용할 수 있는 장점이 있다. 그러나 시계열 데이터를 오토인코더에 적용할 경우 다변량 데이터를 사용할 수 없고 모델의 계산량이 기하급수적으로 늘어나는 단점이 있다. 이러한 문제를 해결하기 위해 본 논문에서는 다변량 시계열 데이터의 특징을 사용하여 모델을 학습하는 특징기반 오토인코더를 사용하였다. 특징기반 오토인코더를 이용한 스핀들모터 진단 결과를 보면 Type1 오류가 조금 발생하였지만 고장데이터는 정확히 분류하여 Type2 오류가 0%를 기록했다. 고성능 스핀들모터와 같이 고위험 장비의 경우 고장을 잘못 판단하게 되면 큰 사고로 이어질 수 있기 때문에 Type2 오류가 낮을수록 더 좋은 모델이라고 판단할 수 있다. 향후 연구로는 Type1 오류를 줄일 수 있도록 이동평균을 적용하거나 앙상블 모델을 적용해볼 예정이다. 스핀들모터의 상태를 여러 단계로 분류할 수 있는 진단모델을 연구할 예정이다.

감사의 글

이 연구는 2022년도 정부(과학기술정보통신부)의 재원으로 국가과학기술연구회의 지원을 받아 수행된 한국전기연구원 기본사업임(No. 22A01019)

[참고 문헌]

- [1] Glowacz, A. "Fault diagnosis of single-phase induction motor based on acoustic signal", *Mechanical Systems and signal processing*, 117, 65-80, 2019.
- [2] Peter, W. "Machine fault diagnosis through an effective exact wavelet analysis", *Journal of sound and vibration*, 277, 1005-1024, 2004
- [3] Yu, J. "bagged auto-associative kernel regression-based fault detection and identification approach for steam boilers in thermal power plant", *Journal of Electrical Engineering and Technology*, 12(4), 1406-1416, 2017
- [4] LeCun, Y. "Deep learning", *Nature*, 521, 436-444, 2015