◎ 논 문
◎ Original Paper

DOI: https://doi.org/10.5293/kfma.2020.23.3.005
ISSN (Print): 2287-9706

합성곱 신경망을 사용한 회전체 오일-휩 및 오일-휩 초기 상태 상태 진단 연구

공준상* · 하태웅** · 이용복†

Study of an Oil Whip and Oil Whip Initial State Detect in Rotating Machine Using by Convolution Neural Network

Junsang Kong*, Taewoong Ha**, Yongbok Lee†

Key Words : Rotating machine(회전기기), Machine Learning(기계 학습), Condition monitoring(상태 진단), Oil whip(오일-휩), Oil whip initial state(오일-휩 초기 상태), Convolution Neural Network(합성곱 신경망)

ABSTRACT

Failure of a rotating machine can lead to not only loss of system performance but massive losses. Therefore, Condition monitoring technologies of rotating machine for detecting a failure has been actively applied in many industries. Recently, as many techniques were developed to collect and analysis of data, condition monitoring which machine learning technology is applied has been studied. In this paper, the machine learning method is used to detect oil whip phenomenon and classify the normal state, oil whip initial state and oil whip. Oil whip which cand lead to large amplitude of vibration is the most common fault cause of sub-synchronous instability in hydrodynamic journal bearings. Convolution neural network which is widely used in image dimensionality reduction is used to detect oil whip phenomenon. As the input data of the neural network, an orbital image which can represent the feature of the normal state, the oil-whip initial state, and the oil-whip is used.

1. 서 론

회전기기는 여러 산업체에서 사용되고 있으며 특히 유체기기 회전체는 발전소에서 매우 많이 활용되고 있다. 유체기기 회전체에서 일어날 수 있는 오일-휩 현상은 유체기기에 고장을 유발할 수 있기 때문에 오일-휩 현상을 정비하고 현상을 규명하는 연구가 진행되었다. 구재량[1] 등은 350MW급 화력발전소 증기터빈의 오일-휩 현상을 축 정렬 불량을 통해 해결하는 방안을 제시하였다. 한승우[2] 등 대형 터빈 발전기에 나타나는 유체 불안정성에 의한 오일-선회와 오일-휩 현상에 대해 베어링에서 측정된 궤도 및 주파수 스펙트럼을 통해 분석하였다. 이인범[3] 등은 오일의 압력과 온도가 터보차저에 사용되는 풀-플로팅 링 베어링에서 일어나는 오일-휩 현상에 미치는 영향을 연구하였고 이동현[4] 등은 유체 동압 베어링의 불안정성으로 인해 나타나는 비동기 진동 성분을 예측하였다. 오일-휩 현상은 저널 베어링에서 생기는 유체역학적 힘으로 생겨나는 자려진동으로 오일-선회 주파수인 0.38x~0.48x의 주파수가 시스템의 위험속도를 만나 가진되면서 큰 진동을 일으키는 현상이다.[5]

회전기기의 고장은 큰 경제적 손실과 인명 피해를 일으킬 수 있기 때문에 회전기기를 효율적으로 운용하기 위한 회전기기 모니터링 기술과 상태 예측 기술이 매우 중요하다. 하지만 기존 진단 시스템인 진동 감시 시스템 등은 진동 데이터를 활용해 신호 처리 및 진단 전문가의 분석을 통해 이상을 판단하기 때문에 오랜 시간 지속 구동되는 회전기기를 지속해서 상태 진단해야 하는 경우 전문가의 부재로 지속적인 상태진단이 불가능하다. 또한 이미 일어난 현상에 대하여 이상 상태를 감지할 뿐 상태 예측 기술은 부족하다. 이러한 문제점을 해결하기 위해 기계학습 방법을 모니터링 기술에 융합하

* UST-KIST 스쿨 (Korea University of Science and Technology, KIST campus)
** 가천대학교 대학원 기계공학과 (Department of Mechanical Engineering, Gachon University)
† 교신저자, 한국과학기술연구원, UST-KIST 스쿨 교수, E-mail : lyb@kist.re.kr

The KSFM Journal of Fluid Machinery: Vol. 23, No. 3, June 2020, pp.05~12(Received 23 Mar. 2020; revised 13 Apr. 2020; accepted for publication 14 Apr. 2020)
한국유체기계학회 논문집: 제23권, 제3호, pp.05~12, 2020(논문접수일자: 2020.03.23, 논문수정일자: 2020.04.13, 심사완료일자: 2020.04.14)

여, 기기 상태를 진단하는 연구가 많이 이루어지고 있다[6].

기계학습, 딥러닝이 적용된 상태 진단의 연구로 Aditiya N[7] 등은 회전체 상태에서 나타나는 통계적 특성을 사용해 히든 마크로프 모델로 불평형 데이터 분류 모델을 사용한 분류 등이 연구되었다. 기계학습 중에서도 합성곱 신경망 알고리즘[8]은 합성곱을 통해 이미지의 특성을 추출하여 입력을 생성하는 방식으로 빠른 연산처리가 가능하다는 점에서 회전체 실시간 모니터링 부분에서 많은 연구가 진행되고 있으며 기존 연구들은 다음과 같이 진행되었다. 이승철 등[9]은 궤도 이미지를 사용해 축 정렬, 불평형 질량 등의 상태를 합성곱 신경망을 사용해 검출하고 Yongbo[10]는 회전체 주변의 열 감지 이미지를 사용해 베어링 상태와 회전체 상태를 분류하는 연구를 진행하였다. Van Hoecke[11]는 진동 이미지를 사용하여 베어링의 손상 진단을 하였다.

이 논문에서는 합성곱 신경망을 사용하여 Bently nevada의 RK4-Rotor kit에서 일어나는 오일-휩 현상을 진단하고 오일-휩 시작 단계를 진단하여 심각한 오일-휩 현상을 방지할 수 있는 모델을 학습시키고 모델을 평가하였다. 기계학습으로 기기 상태를 판단하기 위해서는 정상 상태의 신호뿐만 아니라 고장 상태의 신호가 필요하므로 시스템에서 오일-휩 현상이 언제 나타나는지 해석을 통해 분석하고 실제 실험을 통해 데이터를 취득하였다. 기존의 회전체 진단 방식인 궤도 분석 방법[12]을 활용하여 각 특성에 따른 궤도 이미지를 사용해 합성곱 신경망 모델을 구축하였다. 마지막으로 생성된 모델에 훈련과 검증에 사용되지 않은 데이터 세트(테스트 세트)를 사용하여 모델의 신뢰성을 정확도, 손실 함수와 ROC 커브를 통하여 검증하였다.

2. 연구 방법

2.1 오일-휩 데이터 취득 장치

오일-휩 데이터를 추출하기 위해 테스트는 Bently nevada의 RK4-Rotor kit로 진행하였다. Fig. 1(a)은 실험 장치인 RK4-Rotor kit의 전체 구성도를 나타낸다. 구성 요소로는 ①모터, 모터와 축을 연결해주는 ②커플링, 축의 시작 단을 지지하는 ③슬리브 구리 베어링, 진동 측정 ④와전류 센서, 스프링을 사용해 프리로드를 주어 불량 축 정렬 현상을 만들어 주는 ⑤프리로드 조정기, 오일--선회/휩 현상이 발생되는 ⑥저널 베어링과 오일 공급 부로 구성되어 저널 쪽에 오일을 공급하여 저널을 지지도록 구성되어 있다. 와전류 센서의 경우 Bently Nevada사의 Eddy current 3300XL Probe를 사용하여 축의 X축과 Y축을 측정할 수 있도록 90도의 위상 차이를 가진 위치에 설치되어 있으며, 프리로드 조정기의 경우 오일-휩 현상이 축 정렬 상태에서 잘 나타나기 때문에 축 정렬 상태를 정확하게 만들어 주고자 설치되어 있다.

Table 1 Information of RK-rotor kit rotor

재료 : SUS 304		
구성 요소	크기	단위
축 전체 길이	455	mm
저널 폭	25.5	mm
Disk1 두께	25.4	mm
Disk2 두께		
축 지름	10	mm
저널 지름	25	mm
Disk1 지름	75	mm
Disk2 지름		
로터 무게	2.148	kg

Fig. 1(b)은 RK4-Rotor kit의 축의 정보를 나타낸다. 축의 전체 길이는 455 mm, 무게는 약 2.2 kg이며 지름은 10 mm이다. 축의 시작 단에 저널과 불평형 질량을 임의로 줄 수 있는 디스크 2개로 구성되어 있다. 저널 부분에 저널베어링이 설치되고, 디스크 뒤쪽 프리로드 조정기 내부에 볼베어링이 설치된다. 축의 끝단 쪽에는 구리 슬리브 베어링이 설치된다. 구성 요소에 대한 수치와 축에 대한 정보를 표 1에 명시해 두었다.

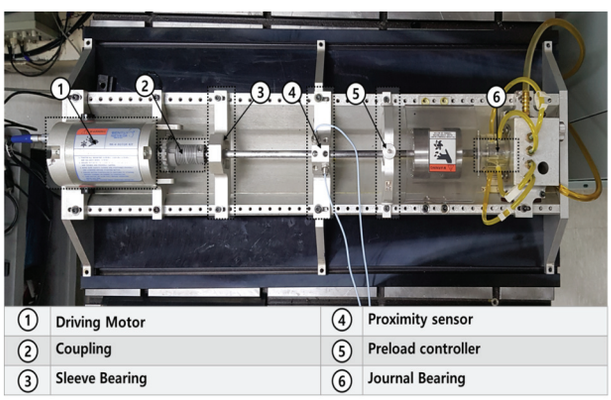

(a)

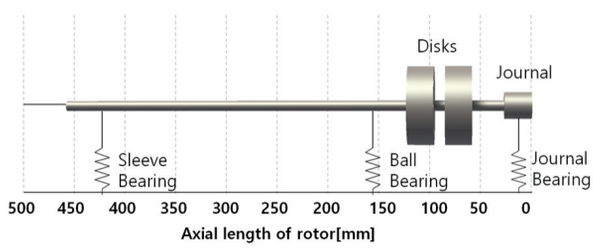

(b)

Fig. 1 (a) Experimental set up for oil whip and (b) Geometry of RK4-rotor kit rotor

2.1.1 오일-휩 이론적 접근

RK4-Rotor kit에서 오일-휩 현상이 언제 나타나는지를 알기 위해 회전축의 회전속도에 따른 구조물 특정 진동 모드와 고유 진동수를 나타내는 캠벨 선도[13]와 유량 균형 방정식(flow balance equation)[13]을 사용하였다.

저널 부에 공급되는 유막은 유량에 의해 결정되게 되며 유량은 로터의 속도와 압력 등에 의해 영향을 받게 된다. 압력은 유막의 하중 지지 능력을 조절하며 만약 압력이 너무 낮다면 하중 지지 능력이 낮고 압력이 없다면 베어링 역할을 하지 못하게 된다. 압력이 적용되지 않는 유막에 대해서는 속도가 유일하게 유막 형성에 영향을 미치게 된다. 속도가 증가하면서 저널의 압력이 낮은 위치에 오일 웨지를 발생하여 유체역학적 힘으로 저널이 부상하게 해준다. 저널은 저널 베어링 내부에서 동압이 형성될 때까지 부상되어 센터 부근으로 이동하게 된다. 이때 저널이 유막 센터 주위를 맴돌게 되면서 유막에 휘돌림 현상이 생기게 되는데 이러한 현상을 오일-선회 현상이라고 한다.

Fig. 2는 부하가 가해진 저널 베어링의 개략도를 나타내며 저널 베어링에 작용하는 오일 현상은 유량 균형 방정식을 통해 정의될 수 있으며 식 (1)과 같다.

$$F_i = F_o + F_w$$

$$\frac{1}{2}LR\omega(C+e) = \frac{1}{2}LR\omega(C-e) + 2LR(ev)$$

$$\therefore \quad Oil \quad Whirl \quad Frequency \quad v = \frac{1}{2}\omega \qquad (1)$$

L은 저널 베어링의 길이, R은 저널의 지름, C는 저널과 저널 베어링 사이의 간극, W는 저널의 무게중심, e는 저널의 편심, ω는 Synchronous Frequency, v는 오일-선회 주파수(oil whirl frequency)를 각각 나타낸다.

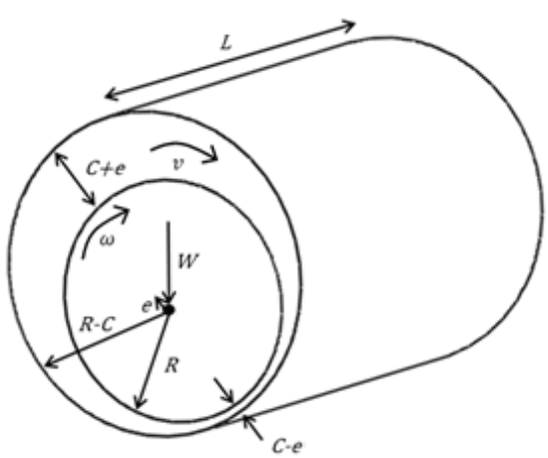

Fig. 2 Schematic view of loaded journal bearing and coordinate system

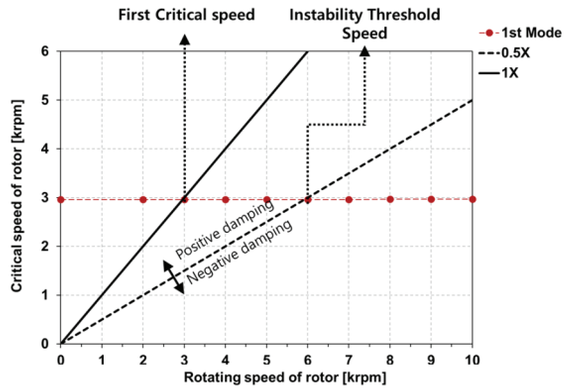

Fig. 3 Cambell diagram with half frequency whirl and negative damping effect over Instability threshold Speed

Fig. 3은 RK-4 rotor kit의 캠벨 선도를 나타낸다. 캠벨 선도에 나타나는 1X 성분의 동기 휘돌림(Synchronous whirl)은 로터의 불평형 질량에 의해 생기게 되며 1X 선과 1차 시스템 응답 주파수가 만나는 지점인 3,000 rpm에서 첫 번째 위험속도가 나타나게 된다.

0.5X 성분의 Half Frequency Whirl 회전속도의 절반의 주파수를 나타내며 이는 유막의 회전 주파수를 나타내고 이를 오일-선회 현상이라고 한다. 위험속도를 초과한 후 0.5X 선과 1차 시스템 응답 주파수가 만나는 지점인 6,000 rpm 부분을 불안정 문턱 속도(Instability Threshold Speed)라 하며 불안정 문턱 속도를 넘어가게 되면 더 이상 오일-선회 현상을 제어할 수 없게 된다. 이러한 현상을 오일-휩 현상이라 하며 저널 베어링의 감쇠 능력은 현저하게 감소하게 되어 시스템에 공급되는 에너지가 큰 진동을 야기하게 된다.

축에 대하여 회전체 동역학적 해석의 결과 오일-휩 실험 장치에서 오일-휩 현상을 나타내기 위해서는 1차 시스템 응답 주파수와 동기화 주파수가 만나는 3,000 rpm을 넘어가 오일-선회 주파수와 1차 시스템 응답 주파수가 만나는 6,000 rpm까지 구동해야 하는 것을 알 수 있다.

2.1.2 오일-휩 실험 데이터 취득

진동 데이터의 경우 와전류 센서를 활용해 X축과 Y축의 진동을 축의 센터 지점에서 측정하였으며, 측정된 데이터 수집 장치로는 B&K사의 Pulse 장비를 통해 진동 데이터가 수집되며 샘플링 주파수는 8,192 Hz이다.

시스템의 운전영역은 0 rpm에서 오일-휩 상태가 나타날 수 있는 약 6,000 rpm이며 회전속도는 타코미터를 사용하여 실시간으로 측정된다.

Fig. 4는 x축 방향의 와전류 센서로 수집된 데이터를 통해 나타낸 진동에 따른 주파수 응답 그래프이다. 주파수 응답 그래프를 통해 운전영역에 따른 회전체에 일어나는 특성을 알 수 있다. 약 50 Hz에서 1x 성분 진동이 커지며 이는 약 3,000 rpm에 첫 번째 위험속도가 있음을 알 수 있다. 첫 번

째 위험속도를 지나면 오일-선회 현상에 대한 0.48x 주파수 성분이 처음 나타나게 된다. 오일-선회 성분이 시스템의 고유진동 주파수 50 Hz에 가까워짐에 따라 오일-선회 주파수 성분은 커지게 된다. 로터의 속도가 첫 번째 위험속도의 약 2배가(약 6,000 rpm) 되었을 때 오일-휩 현상이 나타나게 되면서 시스템은 매우 큰 진폭으로 진동하게 된다. 오일-휩 현상은 회전체 속도가 올라가더라도 오일-선회 현상과 다르게 낮아지는 감쇠 값에 의해 위험속도 주파수에 존재하게 된다.

오일-휩에 대한 실험을 각 15번씩 2분간 실행하였으며, 회전체의 정상 상태, 오일-휩 초기 상태, 오일-휩에 대한 진동 데이터를 취득하였다. 진동 데이터를 궤도 이미지화 작업은 MATLAB을 사용하여 취득했고 각 궤도 이미지는 4,086개의 진동 데이터를 수반한 0.5초 동안의 궤도를 나타낸다. 실험 후 총 데이터의 수는 1,800개의 궤도 이미지이며, 정상 상태 1,000개 오일-휩 초기 상태 200개 오일-휩 상태 600개를 취득하였다.

모델을 구축할 때, 훈련 데이터와 테스트 데이터만으로도 훈련의 척도를 판단할 수 있으나 훈련 데이터에 대한 학습만을 바탕으로 모델의 설정을 구하게 되면 과적합 현상(overfitting)이 일어날 가능성이 매우 크다. 과적합 현상은 훈련 데이터를 통해 만들어진 모델에 같은 훈련 데이터와 중복된 데이터를 테스트 데이터로 주어 정확도가 매우 높은 현상을 말한다. 따라서 취득된 궤도 이미지를 훈련, 검증, 테스트 세트로 분류하였으며 훈련 데이터는 1,020개 검증 데이터는 180개 테스트 데이터는 400개로 분류하였다. 취득된 데이터에는 위험속도에 대한 데이터도 존재하나 이 논문에서는 오일-휩 예방과 검출을 중점적으로 다루기 위해 위험속도에 대한 데이터는 포함하지 않았다.

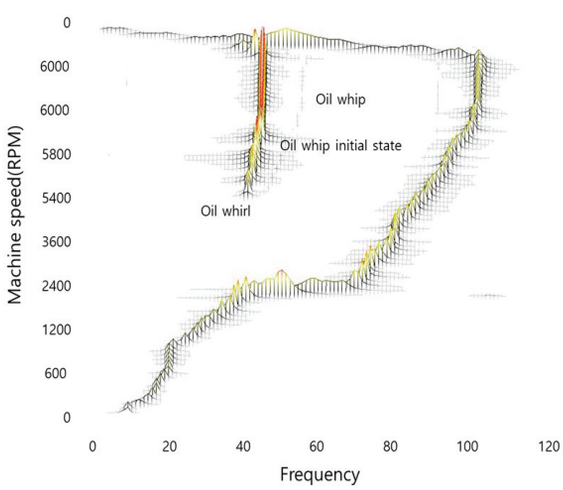

Fig. 4 Cascade spectrum of rotor run-up X-axis vibration response measured at the middle of rotor

2.2 합성곱 신경망을 사용한 오일-휩 검출

회전체의 오일-휩 상태와 정상 상태의 궤도 이미지를 분류하기 위하여 기계학습 기법 중 지도학습의 일종인 합성곱 신경망(Convolution Neural Network) 알고리즘을 사용하였다.

궤도 이미지는 가로, 세로, 채널을 가지는 3차원 데이터이다. 이러한 3차원 이미지 데이터를 기존 기계학습에 쓰이는 완전 연결 계층을 이용해 데이터 세트를 분류하는 모델 생성한다면 3차원 데이터를 1차원의 형태로 변환해야 한다. 이렇게 3차원의 데이터를 1차원으로 펼쳐주면 데이터의 형상이 무시되는 문제가 발생한다. 이러한 문제점을 해결하기 위해 합성곱 신경망은 합성곱층에서 3차원의 이미지를 그대로 입력층에 입력으로 받으며, 출력 또한 3차원 데이터를 통한 특성값을 출력하기 때문에 합성곱 신경망에서는 공간적 구조를 가진 데이터 형상을 유지 할 수 있다. 이처럼 합성곱 신경망은 이미지 콘텐츠에서 높은 수준의 표현을 점진적으로 추출할 수 있기 때문에 이미지 분류용 모델 개발에서 많이 쓰이고 있는 알고리즘이다.

합성곱 신경망은 각각 세 가지의 작업을 맡는 여러 개의 모듈로 구성되어 있다. 첫 번째로 합성곱층에서는 입력 이미지 데이터에 합성곱 필터를 적용하여 새로운 특성을 산출한다. 새로운 특성은 입력 이미지의 유의미한 특성을 포함하고 있으며 이를 특성 맵이라 한다. 유의미한 특성을 추출하기 위해 적용된 합성곱 필터 행렬값을 학습하게 된다. 두 번째로 활성화 함수 영역에서는 합성곱 신경망 모델에 비선형성을 주기 위해 합성곱층 작업이 끝날 때마다 합성곱된 특성에 활성화 함수 ReLU 함수를 적용하며 ReLU 함수는 식 (2)와 같이 정의된다. 세 번째로 풀링 과정에서는 합성곱 신경망의 처리 시간을 줄이기 위해 합성곱 된 특성 맵에서 가장 중요한 특성 정보는 남겨 두면서 특성 맵의 차원 수를 줄여 합성곱 신경망의 완전 연결형 층에서 연산 시간을 줄여 준다. 풀링 과정은 합성곱층과 비슷한 방식으로 진행되며, 가장 중요한 특성 정보를 남기기 위해서 일반적으로 최대 풀링 방법을 사용한다. 합성곱 신경망을 통해 만들어진 최종 특성 맵은 위의 3가지 모듈을 거치면서 이미지의 정보를 함축적으로 담을 수 있게 된다. 생성된 특성 맵은 분류를 위해 완전 연결 계층의 입력으로 사용되기 위해 1차원의 형태로 변환되고 소프트맥스 활성화 함수인 식 (3)을 거쳐 모델에서 예측하고자 하는 분류 라벨별로 0에서 1까지의 확률값을 출력하여 가장 높은 확률 값을 가지는 라벨로 분류하게 된다.

$$F(x) = \max(0, x) \tag{2}$$

$$p(x) = \frac{x_i}{\sum_{j=0}^{k} e^{x_j}} \tag{3}$$

Fig. 5는 합성곱 신경망을 사용해 정상 상태, 오일-휩 초기 상태, 오일-휩 상태 분류의 과정인 완전 연결형 계층과 전체적인 합성곱 신경망의 구조를 나타낸다.

본 논문에서 합성곱 신경망은 궤도 이미지를 150x150x3의 픽셀의 입력으로 받아 3x3 크기의 합성곱 필터를 사용하였으며 합성곱층은 3번 사용되었다. 필터의 개수는 각각 8개, 16개, 32개이며. 필터의 개수는 이미지의 공간적 특성 수반한 개수이다. 각각 합성곱층에서 활성화 함수로는 ReLU 함수를 사용하였다. 풀링은 일반적으로 사용되는 2x2픽셀에 최대 풀링 방법을 사용하였다. 마지막 완전 연결형 계층에서는 합성곱 연산을 마친 이미지를 평탄화하여 'softmax' 함수를 사용하여 정상 상태(클래스 0), 오일-휩 초기 상태(클래스 1), 오일-휩 상태(클래스 2)로 각각 클래스에 대한 예측 확률을 계산하여 가장 높은 예측 확률을 가진 클래스로 분류되도록 하였다. 훈련 과정은 에포크 30, 배치 사이즈는 8로 하였다.

에포크란 모든 훈련 데이터를 1회 학습하는 것을 1에포크라고 표현한다. 훈련 데이터는 여러 개로 묶여서 학습이 진행되는데 훈련 데이터의 묶음을 배치라고 한다. 1에포크에 이용되는 훈련 데이터는 여러 개의 배치로 분할된다. 즉, 1회 학습할 때 입력 데이터를 8개씩 묶은 225번의 학습이 이루어지며 학습을 30번 진행하여 합성곱 필터의 가중치를 구했다.

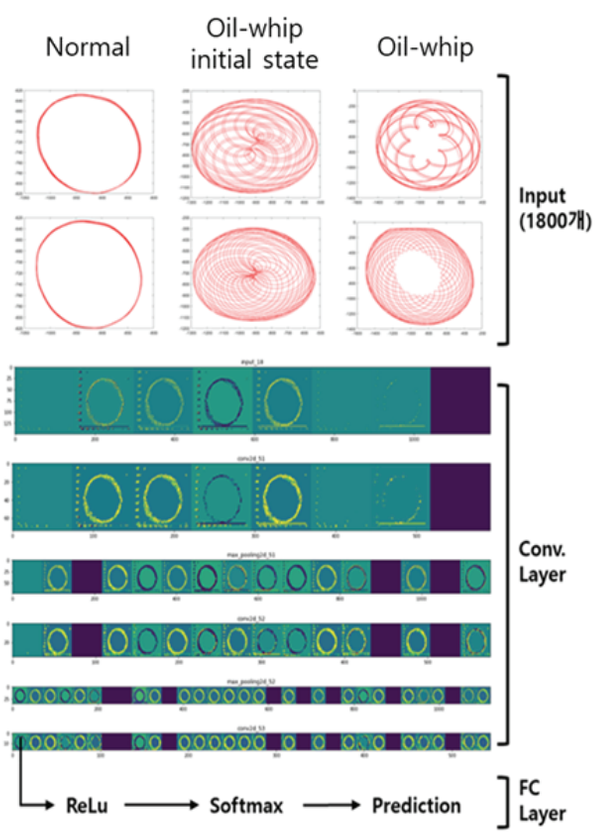

Fig. 5 Processing of Convolution Neural Network with Input data

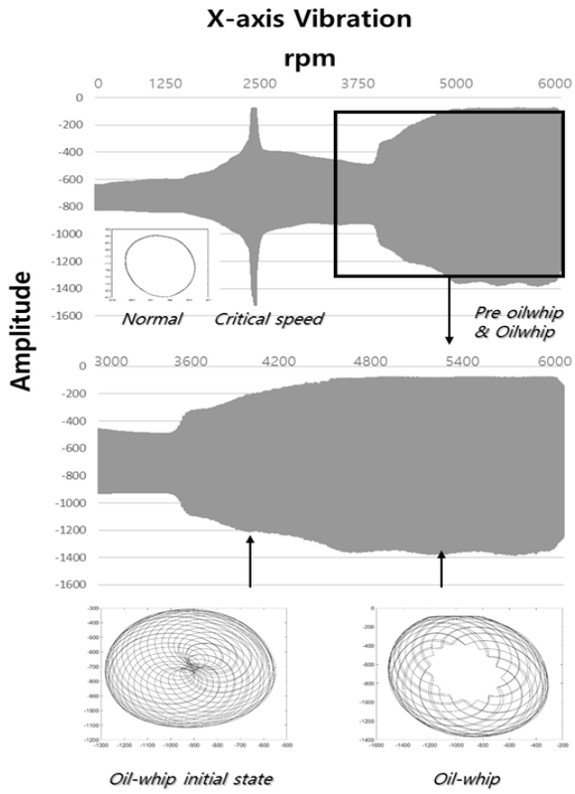

Fig. 6 X-Axis Vibration Amplitude and Orbit plot for Normal, Oil whip initial state, Oil whip

Fig. 6의 각 궤도에서 볼 수 있듯이 정상 상태에서는 원 모양의 궤도를 명확하게 가지며, 오일-휩 초기 상태의 경우는 원이 내부로 꼬이고 있으나 오일-휩 현상과는 다르게 내부에 원을 포함하고 있지 않다. 이러한 특성으로 보았을 때 충분히 각 궤도에 대한 특성을 나타내는 질 좋은 데이터이기 때문에 기계학습 시에 각각의 특성을 통해 상태 예측이 가능한 모델을 만들 수 있다.

3. 실험 결과

3.1 합성곱 신경망 모델 검증

Fig. 7은 모델의 성능을 나타내기 위한 손실 함수와 정확도 함수이다.

Fig. 7(a) 정확도 함수는 생성된 모델을 통해 전체 테스트 데이터에서 자신의 클래스를 정확하게 맞춘 개수의 비율이다. 정확도 함수의 경우 에포크가 늘어나면서 1에 수렴해 나가는 것을 볼 수 있으며, 이는 모델이 훈련되는 동안 샘플들이 잘 분류되었음을 의미한다. 모델 훈련 결과 정확도의 경우 에포크 30회를 수행하였을 때 98% 이상 정확하게 자신의 클래스로 분류했음을 알 수 있다.

Fig. 7(b) 손실 함수는 모델의 예측이 얼마나 잘못되었는

가를 나타낸다. 다중 클래스 분류 모델의 손실을 구하기 위해 일반적으로 이진 분류에 사용되는 Binary classification 손실 함수가 아닌 Categorical cross entropy 손실 함수를 사용하였다. Categorical cross entropy 손실 함수 식은 식 (3)에 나타내었다.

$$Loss(y,\hat{y}) = -\sum_{j=0}^{M}\sum_{i=0}^{N}(y_{ij} * \log(\widehat{y_{ij}})) \tag{3}$$

$\hat{y}$는 모델이 예측한 한 값이고 y는 정답인 값이며 클래스가 3개이므로 M과 N값은 2이다. 손실 함수는 예측값과 정답값의 차이를 나타내며 훈련을 통해 손실을 감소하게 된다.

Fig. 7(b)의 손실 함수를 보면 훈련을 에포크 수만큼 늘려가면 늘려 갈수록 점점 손실 값이 0에 가까워지는 것을 볼 수 있다. 이는 합성곱 신경망에 사용되는 합성곱 필터의 최적화 가중치 값을 찾았다는 것을 나타낸다.

모델 훈련 결과 에포크 30회를 수행하였을 때 98% 이상 정확하게 분류했음을 알 수 있으며 모델의 손실 또한 거의 0에 수렴함을 보아 다음 모델은 정확도가 높고 손실이 낮은 모델이라고 할 수 있다.

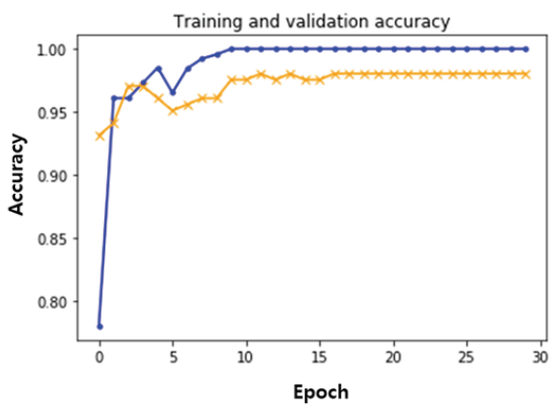

(a)

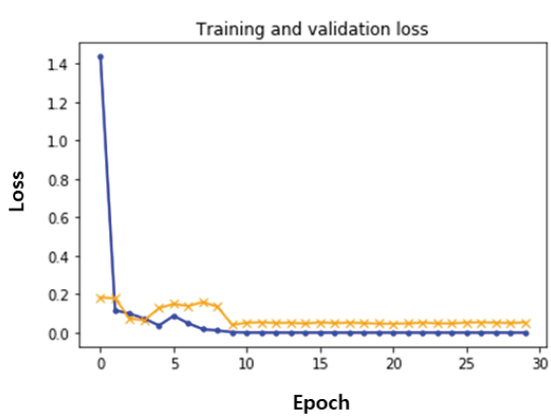

(b)

Fig. 7 (a) Training and Validation accuracy
(b) Training and Validation loss

Table 2 TP(True Positive), FP(False Positive), FN(False Negative) of each class

	예측 클래스0	예측 클래스1	예측 클래스2
정답 클래스0	TP	FP/FN	FP/FN
정답 클래스1	FP/FN	TP	FP/FN
정답 클래스2	FP/FN	FP/FN	TP

하지만 다음 모델 학습 시에 정상 상태에 데이터가 많기 때문에 정상 상태를 잘 예측하여 정확도가 높을 수 있음으로 모델을 평가에는 테스트 셋을 사용해 이상 상태에 대한 특이도와 민감도를 수반한 ROC 커브와 AUC[14]를 통해 모델을 검증해 볼 필요가 있다. ROC 커브는 다양한 임계값에 따른 True Positive Rate(TPR)와 False Positive Rate(FPR)를 나타낸다. 여기서 임계값(threshold)이란 각 클래스를 나누어 주는 기준이다. 즉, 클래스 예측값이 임계값 이상의 값을 가지면 TP라고 가정한다. 보통의 임계값은 AUC값이 0.5일 때를 나타내어 예측값이 0.5 이상일 때를 기준으로 클래스를 구분한다. AUC는 ROC 커브의 면적을 나타내며 값의 범위는 0~1로 예측이 100% 잘못된 모델의 AUC는 0이고 예측이 100% 정확한 모델의 AUC는 1.0이다. 즉, AUC의 값이 0.5 이상이 된다면 어느 정도 잘 분류를 하고있는 모델이라고 볼 수 있다.

ROC curve에서 나타내는 TPR은 각 클래스 입력에 대해 각 클래스로 잘 예측한 비율이며 FPR은 각 클래스에 대하여 다른 클래스로 잘못 예측한 비율을 나타낸다. 분류 기준이 이진 분류법이 아닌 다중 라벨 분류법을 사용하였기 때문에 각 클래스에 대한 TPR과 FPR을 평균화한 전체 값의 평균(micro-average) ROC 커브에 추가하였다.

표 2는 각 클래스당 참 양성률(TP), 거짓 양성률(FP), 거짓 음성률(FN)을 나타내며 표 2에서 클래스 0은 정상 상태 클래스 1은 오일-휩 초기 상태, 클래스 2에서는 오일-휩 상태를 나타낸다.

식 (4)와 (5)는 각각 TPR과 FPR을 나타낸다. TPR과 FPR 클래스 수로 나누어 평균화하여 TPR micro-average와 FPR micro-average를 구했으며 수식은 (6), (7)과 같다.

$$TPR = \frac{TP}{TP + FN} \tag{4}$$

$$FPR = \frac{FP}{FP + FN} \tag{5}$$

$$TPR_{micro} = \frac{TPR_{class0} + TPR_{class1} + TPR_{class2}}{3} \tag{6}$$

$$FPR_{micro} = \frac{FPR_{class0} + FPR_{class1} + FPR_{class2}}{3} \tag{7}$$

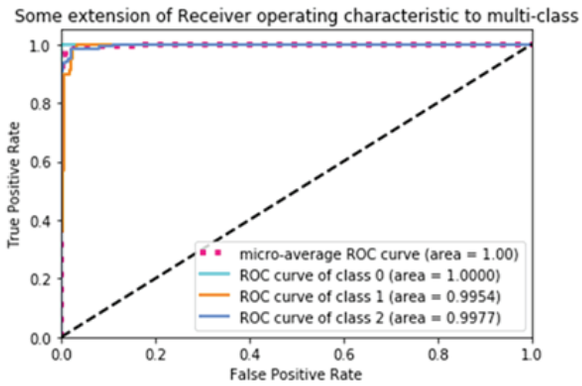

(a)

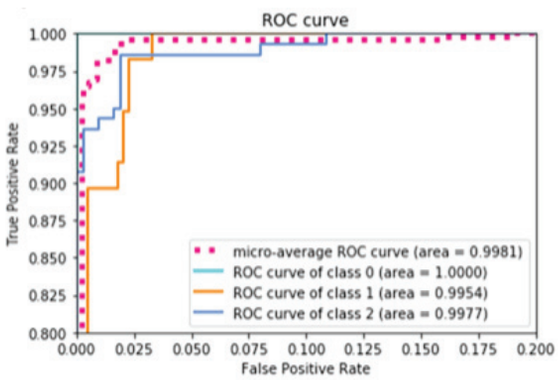

(b)

Fig. 8 ROC Curve of each class and micro-average; (a) ROC Curve (b) ROC Curve Zoom in

Fig. 8(a)은 테스트 세트 400개에 대하여 연산을 통해 얻은 값으로 ROC curve를 그린 결과이며 Fig. 8(b)는 변화하는 부분을 확대한 ROC curve이다. 가운데 검은 선은 임계값 0.5를 기준으로 TPR과 FPR의 비율을 나타낸 선이다. Fig. 8(a)의 검은선의 AUC 값은 0.5이며 모델의 성능을 나타낼 수 있는 비교 지표이며 모델의 성능이 좋으면 좋을수록 AUC 값은 1에 가깝게 된다.

정상 상태(class 0)에 대해서는 훈련 세트에 오일-휩 초기 상태와 오일-휩 상태보다 정상 상태의 데이터가 많기 때문에 다소 과적합되어 AUC 값이 1이 되었다. 하지만 오일-휩 초기 상태의 AUC 값이 0.9954 오일-휩 상태의 AUC 값이 0.9977로 1과 가까운 값을 가지며 이를 평균화한 micro-average ROC curve의 경우 또한 0.9981로 학습이 잘 된 모델이라고 할 수 있다.

4. 결론 및 고찰

이 논문에서는 Bently nevada RK-4 rotorkit을 사용해 유체가 회전체 저널을 지지했을 시 일어날 수 있는 오일-휩과 오일-휩 초기 상태 대한 데이터를 추출하고 추출된 진동 데이터를 기반으로 합성곱 신경망을 사용해 모델을 구축하고 정상 상태, 오일-휩 초기 상태, 오일-휩 상태를 구분하는 연구를 진행하였다. 모델에 대한 평가는 정확도, 손실 함수와 ROC curve를 사용하였으며, ROC curve 결과 정상 상태의 데이터가 다소 과적합되어 있는 것을 확인하였다. 하지만 오일-휩 초기 상태나 오일-휩 상태 또한 높은 AUC 값을 가지고 있어 충분히 의미 있는 모델이라는 것을 검증하였다, 하지만 현 모델에서는 궤도 이미지만을 사용하여 모델을 생성하였기 때문에 Bently nevada RK-4 rotorkit 시스템에서는 오일-휩 현상을 잘 검출해낼 수 있으나, 실제 시스템에서 모델이 잘 동작할 수 있을지는 확인이 필요하다.

이러한 문제점을 해결하기 위해 본 논문을 바탕으로 하여 유체역학적 불안정성에 의해 생기는 오일 선회와 오일-휩 현상의 근본적인 발생 원인인 오일의 점도, 베어링 하중, 간극 등 여러 가지 변수들 통해 오일-휩 현상을 평가하여 실제 시스템에서도 동작할 수 있는 모델을 만들 필요가 있다.

후 기

이 논문은 2020년도 극한 환경용 볼 베어링의 신뢰성 및 스마트 볼 베어링 코어 기술 개발(도약연구지원사업, 프로젝트 No. NRF2017R1A2A1A17069515)와 IoT 기반의 미활용 열원을 활용한 터보발전시스템 기술 개발(미래원천국가기반기술개발사업, No. 2E30690)에 사용된 회전체 모니터링 기초연구의 지원을 받아 수행되었습니다. 이러한 기회를 주신 도약연구지원 사업단과 미래원천국가기술개발단에 특별한 감사를 표합니다.

References

(1) 구재량. 350MW 급 화력 발전소 증기터빈의 오일 휩 현상 및 대책. 한국소음진동공학회 학술대회논문집, 2001, 1015-1019.

(2) Han, S. W. and Roh, C. W., 2008, “A case study on the vibration by fluid induced instability at large steam turbine-generator,” Transactions of the Korean Society for Noise and Vibration Engineering, Vol. 18, No. 2, pp. 238-246.

(3) Lee, In-Beom and Hong, Seong-Ki., 2017, “Effects of Oil Inlet Pressure and Temperature on the Dynamic Behaviors of a Full-Floating Ring Bearing Supported Turbocharger Rotor,” The KSFM Journal of Fluid Machinery, Vol. 20, No. 2, pp. 53-62.

(4) D. H. Lee, Y. C. Kim, B. O. Kim, K. Y. Ahn, and Y. D. Lee, 2017, “Subsynchronous Vibration Behavior of Turbocharger Supported by Semi Floating Ring Bearing,” The KSFM Journal

of Fluid Machinery, Vol. 20, No. 1, pp. 15-20.

(5) Muszynska and Agnieszka., 1986, "Whirl and whip—rotor/bearing stability problems," Journal of Sound and Vibration, Vol. 110, No. 3, pp. 443-462.

(6) Liu, Ruonan,. 2018, "Artificial intelligence for fault diagnosis of rotating machinery: A review," Mechanical Systems and Signal Processing, Vol. 108, pp. 33-47.

(7) Aditiya, N. A and Dharmawan, M. R,. 2017, "Fault diagnosis system of rotating machines using Hidden Markov Model (HMM)," International Electronics Symposium on Knowledge Creation and Intelligent Computing.

(8) Krizhevsky and Alex,. 2012, "Geoffrey E. Imagenet classification with deep convolutional neural networks." Advances in neural information processing systems, pp. 1097-1105.

(9) Jeong Haedong,. 2016, "Rotating machinery diagnostics using deep learning on orbit plot images," Procedia Manufacturing, No. 5, pp. 1107-1118.

(10) Yongbo, L. I., 2019, "Rotating machinery fault diagnosis based on convolutional neural network and infrared thermal imaging." Chinese Journal of Aeronautics.

(11) Janssens Olivier,. 2016, "Convolutional neural network based fault detection for rotating machinery," Journal of Sound and Vibration, Vol. 377, pp. 331-345.

(12) Yunusa-Kaltungo and Akilu,. 2015, "Experimental observations of rotor orbit analysis in rotating machines," Proceedings of the 9th IFToMM International Conference on Rotor Dynamics. Springer, Cham, pp. 1551-1560.

(13) J. S. Rao,. 2011, "History of Rotating Machinery Dynamics," Springer-Verlag, Berlin.

(14) Bradley, Andrew P,. 1997, "The use of the area under the ROC curve in the evaluation of machine learning algorithms," Pattern Recognition, Vol. 30, No. 7, pp. 1145-1159.