

LSTM-Autoencoder를 이용한 부유식 풍력터빈
블레이드 피치 시스템의 이상징후 감지조성필^{1,†}¹한국항공대학교 항공우주공학과Anomaly detection in blade pitch systems of floating wind turbines using
LSTM-AutoencoderSeongpil Cho^{1,†}¹Department of Aeronautical and Astronautical Engineering, Korea Aerospace University

Abstract

This paper presents an anomaly detection system that uses an LSTM-Autoencoder model to identify early-stage anomalies in the blade pitch system of floating wind turbines. The sensor data used in power plant monitoring systems is primarily composed of multivariate time-series data for each component. Comprising two unidirectional LSTM networks, the system skillfully uncovers long-term dependencies hidden within sequential time-series data. The autoencoder mechanism, learning solely from normal state data, effectively classifies abnormal states. Thus, by integrating these two networks, the system can proficiently detect anomalies. To confirm the effectiveness of the proposed framework, a real multivariate time-series dataset collected from a wind turbine model was employed. The LSTM-autoencoder model showed robust performance, achieving high classification accuracy.

초 록

본 논문은 부유식 풍력터빈의 블레이드 피치 시스템에서 발생하는 이상을 조기에 감지하기 위한 LSTM-Autoencoder 모델 기반의 이상징후 감지 시스템을 설명한다. 발전소 모니터링 시스템에 활용되는 센서 데이터는 주로 시계열 데이터로 구성되며, LSTM 네트워크는 이러한 시계열 데이터를 분석하기 위해 두 개의 단방향 LSTM 네트워크로 구성된다. 이를 통해 순차 데이터에 숨겨진 장기 의존성을 효과적으로 발견할 수 있다. 한편, 오토인코더 메커니즘은 정상상태 데이터로부터만 학습하여 이상상태를 분류될 수 있기 때문에 이 두 가지 네트워크를 결합하여 시스템에 발생하는 이상징후를 효과적으로 감지할 수 있다. 제안된 프레임워크의 효과를 입증하기 위해 풍력 터빈 모델에서 수집한 실제 다변량 시계열 데이터셋을 적용하였다. LSTM-AE 모델은 높은 이상징후 감지 정확도를 달성하여 우수한 성능을 보였다.

Key Words : Floating wind turbine(부유식 풍력터빈), Blade pitch system(블레이드 피치 시스템), Anomaly detection(이상징후 감지), Long short-term memory(장단기 메모리), Autoencoder(오토인코더)

1. 서 론

해상 풍력터빈은 강한 바람, 파도 및 해류가 있는 혹독한 해상환경에서 운영되고 있으며 이러한 환경은 풍

력터빈의 결함 및 고장의 발생 위험을 크게 증가시킨다. 해상 풍력 터빈의 결함과 고장발생은 유지 보수 비용과 큰 상관관계가 있다. 해상 풍력 터빈의 통계자료[1]에 따르면, 풍력 터빈의 유지 보수 비용이 풍력 터빈의 전체 비용의 약 25%-30%를 차지한다.

해상 풍력터빈의 주요 구성품으로는 타워, 부유체, 블레이드, 허브, 회전축, 증속기, 발전기, 요잉시스템, 피치시스템이 있다. 각 구성품의 고장은 풍력터빈의 수

Received: Jun. 03, 2024 Revised: Jul. 04, 2024 Accepted: Jul. 25, 2024

† Corresponding Author

Tel: +82-02-300-0177, E-mail: spcho@kau.ac.kr

© The Society for Aerospace System Engineering

명에 많은 영향을 끼치지만 블레이드 피치 시스템의 고장이 특히 치명적이다. 블레이드 피치 시스템의 고장은 블레이드에 작용하는 공기역학적 부하가 변화하며 이로 인해 지지 구조 및 타워의 응답에 영향을 준다[2-5]. 이는 터빈의 시스템 특성을 변경하여 구조적 안전성 및 발전 효율에 영향을 미칠 수 있다. 따라서 시스템의 이상을 조기에 감지하는 것은 심각한 시스템 고장을 방지하며 잠재적 위험, 사고 및 터빈에 장기적 손상을 완화하는 데 도움이 된다[6].

최근의 고장 감지 및 진단 기법은 데이터 기반 기법이 큰 비중을 차지하며, 이는 시스템에서 측정된 데이터만 있으면 감지/진단을 할 수 있는 장점이 있다[7, 8]. 데이터 기반 이상 감지 및 진단 알고리즘은 풍력 터빈 시스템의 발전기 및 다양한 부품에 위치한 센서에서 수집된 일련의 측정 데이터를 활용하며 통계적 기법 또는 딥러닝 이론을 적용했다. 이들 중에는 다중계층 퍼셉트론(multi layer perceptron, MLP) [9-13], 합성곱 신경망(convolutional neural network, CNN) [14, 15], 오토인코더(autoencoder, AE) [16, 17], 그리고 순환 신경망(recurrent neural network, RNN) [18-20]이 포함된다. 특히, 순환신경망 구조 중 하나인 장단기 메모리(long short-term memory, LSTM)는 현재와 과거 사건 간의 연결을 효과적으로 나타내고, 시계열 데이터셋의 장기 의존성을 학습할 수 있는 장점이 있다[21]. 순환신경망은 이전 시간 단계의 정보를 활용하여 순차 데이터를 모델링할 수 있지만, 장기 의존성을 포착하려 할 때 기울기 소실(vanishing gradient) 문제를 겪는다. 반면, LSTM은 정보의 포함 또는 제외를 선택할 수 있는 메모리 셀을 사용하여 이 문제를 해결하도록 만들어져, 장기 의존성을 관리하는 능력을 향상시킨다[22].

해당 시스템의 이상 감지 및 고장진단을 하기 위해서는 각 시스템 개별 고장 데이터의 학습이 필요하다. 그러나 이러한 터빈 부품의 개별 고장 데이터는 수가 많지 않으며 더욱이 획득이 어렵다. 이에 대한 해결책으로, 위에 언급하였던 장기 의존성에 강한 LSTM과 오토인코더를 결합한 LSTM-AE 기법을 이용하면 시계열 데이터의 실시간 처리를 가능하게 하여 고장 데이터의 학습 없이 정상 데이터를 이용하여 학습을 하며 이상 감지를 효과적으로 수행할 수 있다.

본 논문에서는 부유식 풍력 터빈 블레이드 피치 시스템에서 이상을 감지하기 위한 LSTM-AE 시스템의 구현에 대해 설명한다. 2장에서는 풍력 터빈의 모델링 및 제어 기술에 대한 상세한 정보를 제공하며, 3장에서는 블레이드 피치 시스템의 고장 모드 및 데이터 획득방법을 설명하였다. 4장에서는 LSTM-AE를 이용한 이상징후 감지 시스템의 데이터 학습절차 및 결과를

나타낸다. 마지막으로, 결론에서는 향후 연구 방향에 대해 논의한다.

2. 풍력터빈 모델링 및 제어기법

2.1 풍력터빈 모델

스파형의 부유체로 지지되는 풍력 터빈은 로터, 타워, 나셀, 부유체 및 계류 라인으로 구성되어 모델링 되었으며 수치모델은 그림 1에서 보이는 것처럼 NREL 5-MW 해상 풍력 터빈, 스파형 부유체(OC3-Hywind) 및 3개의 현수선 계류 케이블 모델링을 기반으로 한다. 다음 표 1 및 2는 각각 NREL 5MW 풍력 터빈과 OC3-Hywind 부유체 모델의 특징을 나타낸다 [23, 24].




Fig. 1 Schematic view of a spar-type floating wind turbine [4]

Table 1 Properties for the National Renewable Energy Laboratory (NREL) 5-MW wind turbine [23]

Rated power, MW	5
Rotor orientation and configuration	Upwind, three blades, horizontal axis
Rotor diameter, m	126
Hub height from the mean water level, m	90
Cut-in, rated, cut-out wind speed, m/s	3, 11.4, 25
Cut-in, rated rotor speed, °/s	41.4, 72.6
Max pitch rate, °/s	8
Gearbox ratio	97

Table 2 Properties for the OC3-Hywind floater [24]

Water depth, m	320
Draft, m	120
Diameter above taper, m	6.5
Diameter below taper, m	9.4
Center of mass, m	(0, 0, -89.9115)
Mass, including ballast, kg	7.466×10^6
Mass moment of inertia (I_{xx} and I_{yy}), $\text{kg}\cdot\text{m}^2$	4.229×10^9
Mass moment of inertia (I_{zz}), $\text{kg}\cdot\text{m}^2$	1.642×10^8

2.2 유압 블레이드 피치 시스템

유압 피치 시스템은 그림 2에서 보이는 것처럼 유압 펌프, 어큐뮬레이터, 방향 제어 밸브, 유체 저장 탱크 및 유압 실린더로 구성된다. 터빈 허브에 위치한 유압 실린더는 블레이드 피치 각도를 제어한다. 펌프에 의해 공급되는 유압은 방향제어밸브로 유량 및 실린더로 유체 유입방향을 효과적으로 조절하여 피스톤의 위치를 제어하여 블레이드 피치각을 제어한다. 블레이드 피치 각은 인코더를 이용하여 측정하며 선형가변위 변환기(linear variable displacement transformer, LVDT)를 이용하여 밸브 스톱의 위치를 측정한다. 이러한 측정 값은 제어기의 입력변수에 사용된다[4].




Fig. 2 Schematic view of a hydraulic blade pitch system [4]

2.3 풍력터빈 제어 시스템

풍력터빈의 기저 제어 시스템(baseline control system)은 블레이드 피치와 발전기 토크 제어기로 구

성된다. 정격 이하의 풍속 영역에서, 토크 제어기는 발전기 토크를 조절하여 블레이드의 최적 팁 속도비를 유지함으로써 최대 전력발전을 수행한다. 정격 이상 풍속 영역에서 풍속이 증가할 때 블레이드 피치 제어기는 블레이드 피치 각도를 조절하여 정격전력을 유지하면서 블레이드에 작용하는 공기역학적 하중을 감소시킨다. 해상에서 강한 풍하중이 작용하는 부유식 풍력 터빈의 경우 블레이드 피치 제어기를 사용하여 시스템 응답을 개선하고 부유체의 운동을 감소시킬 수 있다.

2.3 다물리 해석 시뮬레이션

부유식 풍력 터빈 모델의 동적 응답해석은 시간 영역 수치 시뮬레이션을 위한 공력-파랑하중-제어-탄성의 코드의 일종인 Simo-Riflex를 이용하여 시뮬레이션이 수행되었다[25, 26]. Simo는 1차 포텐셜 유동 이론 및 모리슨 점성 항력에 따라 부유체에 가해지는 유체 역학적 힘과 모멘트를 계산한다. Riflex는 보 요소 기반의 유한 요소법을 사용하여 블레이드, 샤프트, 타워 및 계류 시스템의 탄성체 구조 해석을 수행한다. Riflex의 비선형 보 요소는 대변형을 고려하며, 블레이드와 타워는 길이에 따라 단면을 다르게 모델링할 수 있다. 시간 영역 해석에서는 질량, 감쇠, 강성 행렬을 포함하여 Simo와 연동된 해석을 수행한다. 외부 하중으로는 공기역학적 하중, 파랑 하중, 제어기로부터의 토크가 포함된다. 또한, Riflex는 타워 그림자 효과 및 동적 실속을 포함한 블레이드 요소 운동량 이론에 기초하여 블레이드에 작용하는 공기역학적 힘 및 모멘트를 계산한다. 따라서, Simo-Riflex의 구조 동역학, 유체역학 및 공기역학 모델은 토크 및 피치 제어기를 포함한 기저 제어 시스템과 연동되어 시뮬레이션을 수행한다. Fig. 4는 Simo-Riflex와 제어 알고리즘의 데이터 전송을 나타낸다.

2.4 해상 환경조건

부유식 풍력터빈이 운영되는 해양 환경하중의 풍속 및 파랑하중 조건은 표 3에 기술되어 있다. 풍하중에 대한 난류 모델링은 IEC 61400-1 및 3[27, 28]의 지침에 따라 카이말(Kaimal) 난류 모델을 기반으로 TurbSim[29]을 사용하여 수행되었다. 불규칙한 파도 하중에 대해서는 북해의 Statfjord 해역의 풍속과 관련하여 JONSWAP 스펙트럼[30, 31]이 사용되었으며, 이를 통해 침두주기와 유의파고가 결정되었다. 본 환경조건을 적용하여 해상풍력터빈이 실제 운영환경과 유사하도록 모델링 하였다. Table 3은 풍속과 파랑하중의 관계를 각 load case 별로 나타내며 여기서 U_w 는 풍속, T_p 는 침두주기, H_s 는 유의파고를 의미한다.

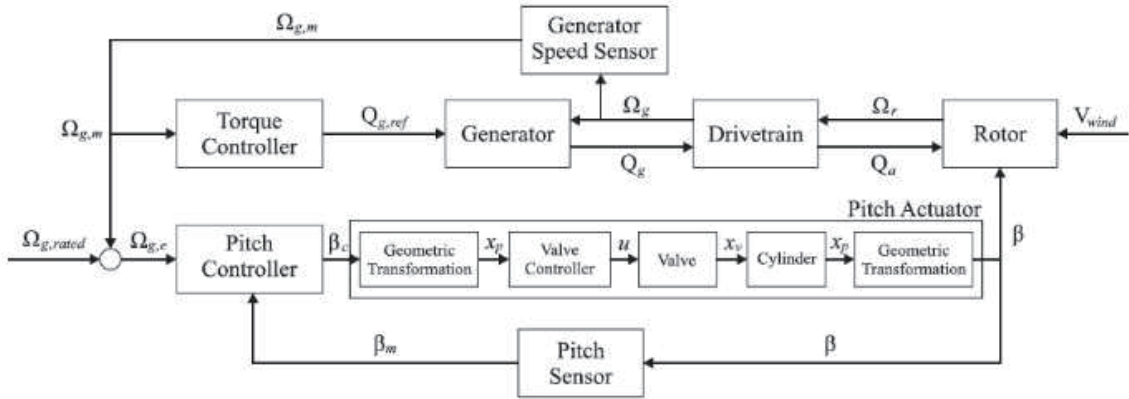


Fig. 3 Block diagram of the baseline controller [4]

Table 3 Load cases based on winds and waves [4, 29]

Load case	$U_w(m/s)$	$H_s(m)$	$T_p(s)$
1	14	3.58	10.27
2	16	3.97	10.44
3	17	4.17	10.53
4	19	4.58	10.72
5	20	4.8	10.82
6	22	5.23	11.02

* Turbulence model: IEC Class C

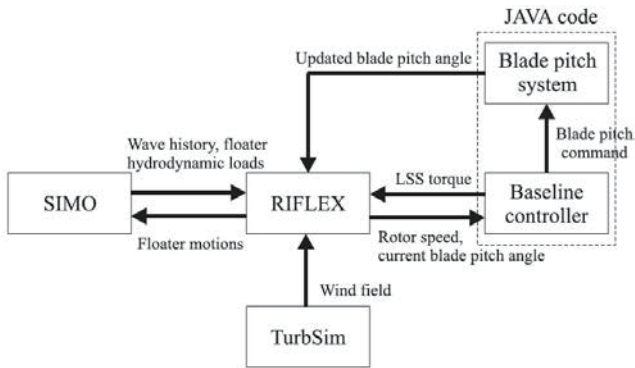


Fig. 4 Data transmission between Simo-Riflex and controller [4, 25, 26]

3. 블레이드 피치 시스템의 고장 모드 및 데이터 획득

3.1 블레이드 피치 시스템의 고장 모드

블레이드 피치 시스템에서의 액추에이터 고장은 로터의 회전 불균형과 블레이드의 비대칭 정렬로 이어질 수 있는 심각한 문제이다. 특히, 오일, 밸브, 그리고 슬

러지와 관련된 고장은 블레이드 피치 시스템의 고장종류 중에 큰 비율(37.3%)을 차지한다[3]. 게다가, 피치 액추에이터의 밸브 고장은 동적 시스템 특성을 변화시키며 풍력 터빈의 과도구간 또는 정상 상태 구간에서 발생하는 동적 응답에 영향을 줄 수 있다. 본 논문에서는 유압식 블레이드 피치 시스템의 피치 액추에이터의 유량 제어 밸브에서 발생하는 네 가지 종류의 고장을 고려하며 이는 표 4에서 자세히 기술되어 있다[4]. Cho et al.[4]은 블레이드 피치 시스템의 유압 액추에이터 고장 특성을 자세히 설명하였다.

유량 제어밸브 고장은 주로 유압 액추에이터 내부 오일의 오염이나 필터 문제로 인해 발생한다. 이러한 문제로 인해 밸브 스펴에 과도한 슬러지가 축적되면 밸브와 스펴 간의 간격이 감소하여 마찰력이 증가하게 된다(fault 1). 본 이상징후에서 슬러지가 경화된다면 밸브의 마찰력이 크게 증가하여 밸브가 더 이상 움직이지 못하여 잠기는 현상이 발생할 수 있다(fault 2). 또한, 밸브 솔레노이드의 아마추어(armature)가 충격을 받거나 손상이 되면 과도한 전류가 유입되어 솔레노이드에 부정확한 전압이 인가되는 경우 발생한다(fault 3). 이러한, 과도한 전류로 인해 솔레노이드가 타버리면 더 이상 밸브 역할을 하지 못하는 현상이 발생한다(fault 4). 각 Load case 별로 표 4에 기술된 4 가지 고장 모드가 블레이드 피치 시스템에 발생했을 때, 한 번에 하나의 고장이 발생하도록 설정하였고, 각 고장이 해상 풍력터빈의 전역 동적 거동에 어떻게 영향을 미치는지에 대한 시뮬레이션을 수행하였다. 4 가지 고장 모델은 Simo-Riflex와 연동되는 Java 코드의 블레이드 피치 시스템 모델에 적용되어 시뮬레이션이 수행된다. 그림 5는 환경 하중이 load case 3인 경우에 과도한 마찰(fault 1), 부정확한 전압 인가(fault 3), 아마추어 소손(fault 4)이 발생할 때 풍력 터빈의 성능 변화를 나타낸다.

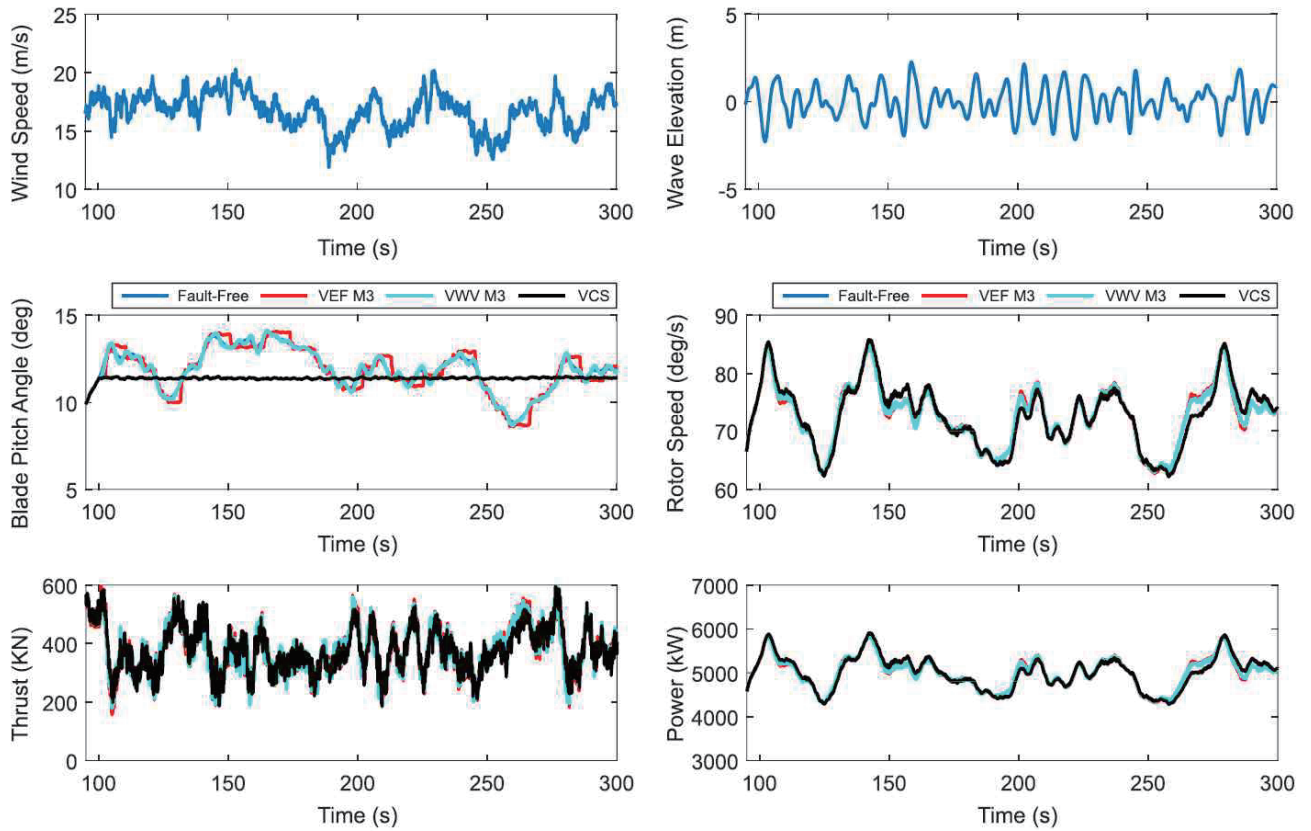


Fig. 5 Effects of excessive friction in the valve (fault 1), wrong voltage applied in the valve (fault3), and short circuit in the valve (fault4) faults on wind speed, wave elevation, the blade pitch angle, rotor speed, aerodynamic thrust, and power under load case 3 [4]

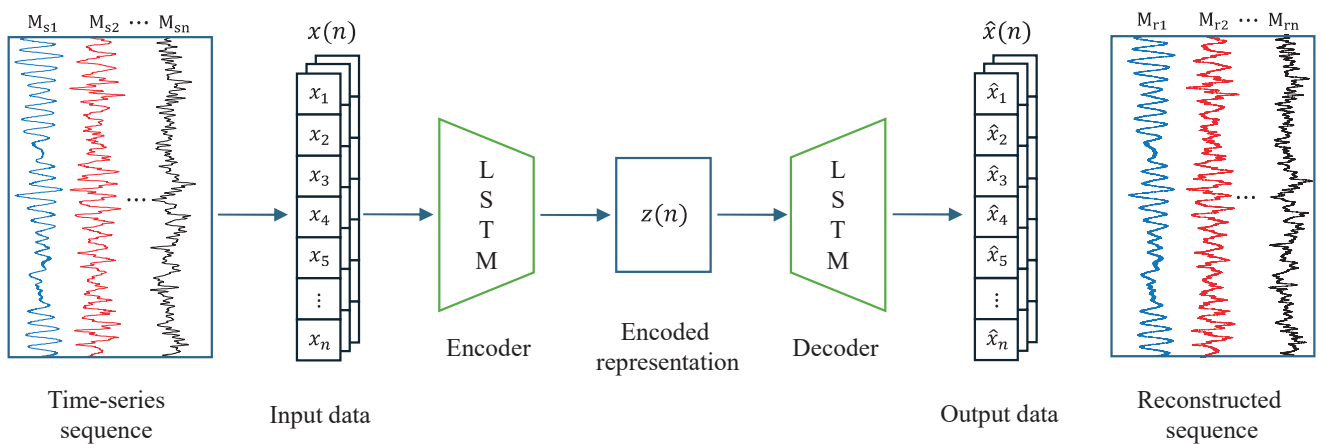


Fig. 6 The structure of the LSTM-AE

Table 4 Fault description in valves [4]

Fault number	Fault name	Consequence
1	Excessive friction (VEF)	Response delay
2	Slit lock on spool (VSL)	Blade pitch runaway
3	Wrong voltage (VWV)	Response delay
4	Short Circuit (VSC)	Actuator stuck

Table 5 Measurements for monitoring system [32]

Sensor Measurement	Unit
Power	W
Acceleration (Nacelle)	m/s ²
Displacement (Nacelle)	m
Rotor speed	rad/s
Thrust	N
Blade pitch angle (three blades)	rad

3.2 데이터 획득 및 처리방법

해상 풍력 터빈의 운영자는 풍력 터빈 운영의 모든 측면에 대한 광범위한 데이터를 지속적으로 모니터링하고 수집한다. 따라서 풍력 터빈의 모니터링 루틴을 갖추고, 데이터를 분석하여 미래의 발생가능한 고장을 예방하는 효율적인 방법을 사용하는 것이 필수적이다. 풍력 터빈 시스템은 주로 허브, 기어박스, 베어링, 스피들 및 발전기 세트로 구성되며 모니터링 시스템은 이러한 구성 요소들의 운영과 관련된 다양한 매개변수를 포함한다. GL 보고서[32]는 안전 및 모니터링 목적으로 풍력 터빈에서 회전 속도, 풍속, 전력 발생량, 블레이드 피치 각 및 나셀의 진동과 같은 특정 물리적 데이터의 측정이 필요함을 언급하였다. 따라서 나셀과 블레이드에 설치된 다양한 센서를 이용하여 물리량을 측정하는 상태 모니터링 시스템은 전력, 나셀의 변위/가속도, 로터 회전속도, 추력, 또는 블레이드 피치 각도와 같은 데이터를 수집한다. 이 연구에서 사용된 측정치는 표 5에 기술되어 있다.

4. LSTM-Autoencoder를 이용한 이상징후 감지 시스템

4.1 LSTM-Autoencoder

본 논문은 LSTM-Autoencoder를 이용한 센서 시계열 데이터 기반의 학습을 수행하여 시스템의 이상징후 탐지를 수행한다. LSTM과 autoencoder의 결합한 형태인 LSTM-AE는 시스템의 입력을 출력으로 복제함

으로써 시계열 데이터의 표현을 학습하도록 설계되었다. LSTM 인코더는 일반적으로 축소된 차원에서 입력 시계열의 압축된 벡터 표현을 학습하며, LSTM 디코더는 입력과 유사하게 시계열 데이터를 재구성한다. 데이터를 학습하는 동안 LSTM-autoencoder는 시계열 데이터의 인스턴스를 정확하게 재구성하는 방법을 학습한다. 그림 6는 LSTM-AE의 구조에 대해 나타낸다.

LSTM-AE 기반의 이상징후 감지 시스템은 센서 데이터로부터 학습하여 재구성 손실(reconstruction loss)을 생성하고, 이는 입력 데이터와 출력 데이터인 재구성된 데이터 사이의 차이를 나타내어 이상징후의 유무를 판단한다. 고장이 없는 정상 시스템으로부터 측정된 센서 데이터를 이용하여 학습된 LSTM-AE 모델이 다중 센서 시계열 데이터에서 이상을 효과적으로 탐지할 수 있음을 보여준다.

학습 중에 LSTM-AE가 정상 상태 데이터만 접하고 정확하게 재구성을 수행하면 결과적으로 정상적인 상황에서는 재구성 손실이 최소화된다. 그러나 입력 데이터가 학습 때 이용된 정상상태 데이터와 다른 특성을 보이는 경우, 재구성된 데이터는 입력과 크게 달라져 재구성 손실이 증가하게 된다. 따라서, 시스템이 이상징후가 발생하면 재구성 손실이 사전에 정의된 임계값을 초과하게 되고 본 상태는 이상상태로 분류하게 된다. 그림 7은 재구성 손실을 이용한 이상징후 감지 시스템의 알고리즘을 설명한다.

4.2 데이터 정규화 및 학습절차

센서 데이터 측정에 있어 전력, 가속도, 변위, 회전속도와 같은 물리량은 차원 및 크기가 매우 상이하다. 이러한 데이터가 하나의 학습 데이터셋으로 구성이 되면 각각의 수가 너무 달라 학습에 불리해진다. 따라서, 해당 데이터셋의 학습을 원활히 하기 위해 데이터 정규화가 요구된다. 이 논문에서는 학습을 위한 데이터셋은 최소값과 최대값을 기반으로 식 1에 설명된 대로 최소-최대 정규화가 수행되었다.

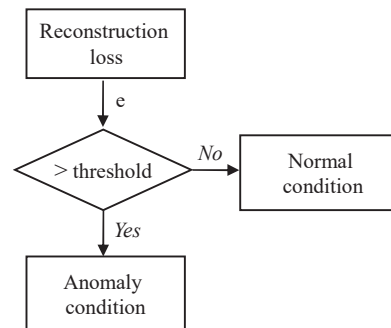


Fig. 7 Anomaly detection algorithm based on the reconstruction error

$$x_{i,normalized} = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (1)$$

또한, 모델은 시스템의 정상상태에 측정된 데이터를 사용하였으며 라벨이 지정되지 않은 샘플만으로 훈련되었다. 테스트 데이터셋의 경우, 데이터에서 정상상태 및 이상징후상태를 시뮬레이션 한 데이터가 모두 포함되어 있다.

학습을 위한 데이터셋은 훈련(training) 데이터, 검증(validation) 데이터, 시험(test) 데이터의 세 데이터셋으로 나누었으며, 각 데이터셋은 3시간 동안 기록된 약 10만 개의 값을 포함하고 있다. 각 LSTM-AE의 훈련 및 검증 데이터를 지정하기 위해 분할을 수행하였다. 구체적으로, 데이터셋의 초기 부분의 80%가 훈련 데이터로, 나머지 20%는 검증 데이터로 구성된다. 훈련 및 검증 데이터는 정상 시퀀스만을 포함하며 LSTM-AE 모델 훈련 및 검증에 사용된다. 각 Fault1, 2, 3, 및 4의 데이터는 모두 시험 데이터셋으로 구성되며 각 고장 별 테스트 절차를 거치며 LSTM-AE 모델의 성능을 결정한다.

네트워크의 인코더 부분은 두 개의 LSTM층으로 구성되어 있다. 첫 번째 층은 256개의 LSTM층을 갖고 있고, 두 번째 층은 128개의 LSTM층을 갖고 있다. 디코더 부분은 첫 번째 LSTM층이 128개의 유닛을, 두 번째 LSTM층이 256개의 LSTM 유닛을 가지고 있다. 모델은 학습률이 0.001이고 배치 크기가 256인 상태로 훈련되었다.

여기서, 훈련 데이터셋을 사용한 훈련 과정에서 LSTM-AE의 가중치는 미니 배치를 사용한 확률적 경사 하강법을 통해 업데이트되며, 훈련 과정을 가속화하기 위해 Adam 기반의 최적화 기법[33]을 사용한다. 훈련 절차에서 사용되는 손실 함수는 일반적으로 네트워크의 입력과 출력 사이의 평균 제곱 오차(mean square error, MSE)를 사용한다. MSE 값을 최소화하기 위해, 네트워크는 입력 데이터를 가능한 정확하게 재구성 한다. LSTM-AE 모델에서는 출력과 입력의 차이를 최소화하기 위해 재구성 손실을 계산한다. 여기서 x 는 입력 데이터를 나타내고, \hat{x} 는 출력/예측 데이터를 나타내며, n 는 학습 데이터셋의 샘플 수를 나타낸다. 식 2는 평균 제곱 오차를 이용한 재구성 손실에 대한 계산식을 나타낸다.

$$L(x_i - \hat{x}_i) = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (2)$$

훈련 과정 동안, 모델은 지정된 훈련 데이터 세트에서 일반적으로 훈련되며, 별도의 검증 데이터 세트에

서 성능이 평가된다. 그림 8은 LSTM-AE 모델의 훈련 및 검증 손실을 보여주며, 파랑색 선과 빨강색 실선은 각각 훈련 및 검증 손실을 나타낸다.

모델을 훈련하고 이상을 감지하기 위한 임계값을 설정한 후, 이제 테스트 데이터셋이 훈련된 모델에 전달된다. 훈련 데이터는 식 2에서 보이듯이 재구성 손실을 계산하는 데에도 사용된다. 시스템의 정상상태의 데이터를 이용하여 구성된 훈련 데이터셋의 재구성 손실 분포가 그림 9에 나타나 있다. 데이터 포인트를 이상으로 정의할 수 있는 임계값은 도메인 지식과 이 분포를 사용하여 0.001로 설정할 수 있다.




Fig. 8 Convergence of the training and validation losses during the learning procedure

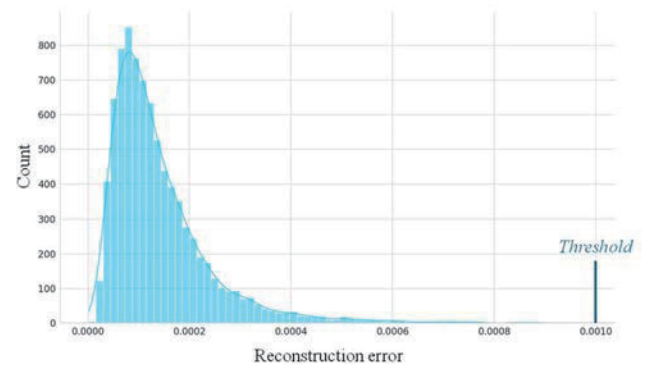


Fig. 9 Distribution of the reconstruction loss of the training data

4.3 결과

우리는 제안된 LSTM-AE 모델의 성능을 평가하기 위해 흔히 사용되는 몇 가지 성능 지표를 사용하였다. 이러한 지표는 정확도(accuracy), 정밀도(precision), 재현율(recall) 및 F1 score이다. 이들은 다음과 같은 식을 사용하여 표현된다.

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (4)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (5)$$

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

여기서 TP(True Positive)는 정확하게 식별된 이상징후 현상의 개수를 나타내며, TN(True Negative)은 정확하게 식별된 정상 이벤트의 개수를 나타낸다. FP(False Positive)는 정상 이벤트 중 잘못된 이상으로 진단된 이벤트의 개수를 나타내며, FN(False Negative)은 실제로는 이상징후를 나타내지만 정상 이벤트로 식별된 개수를 나타낸다. 테스트 데이터셋에 대한 혼동 행렬(confusion matrix)은 그림 10에 설명되어 있다. 각 고장별로 대각성분인 TP값과 TN값이 FP 및 FN 값보다 훨씬 높음을 확인할 수 있다. 해당 값은 전반적인 정확도, 정밀도, 재현율, F1 score에 영향을 끼친다.

		Predictions	
		Anomaly	Normal
Actuals	Anomaly	1865	136
	Normal	2	1997

(a)

		Predictions	
		Anomaly	Normal
Actuals	Anomaly	1996	5
	Normal	2	1997

(b)

		Predictions	
		Anomaly	Normal
Actuals	Anomaly	1878	123
	Normal	2	1997

(c)

		Predictions	
		Anomaly	Normal
Actuals	Anomaly	1995	5
	Normal	3	1997

(d)

Fig. 10 Confusion matrix of the test data: (a) Fault 1, (b) Fault2, (c) Fault3, and (d) Fault4 cases

식 (3)에서 (6)까지의 식을 사용하여 우리의 제안된 모델에 대한 성능 지표를 계산하였다. 또한 유사한 아키텍처와 매개변수를 갖는 LSTM-AE의 성능 비교 결과를 표 6에 요약되어 있다.

Table 6 Performance of LSTM-AE

Fault number	Accuracy	Precision	Recall	F1 Score	AUC-ROC
1	0.965	0.998	0.932	0.964	0.955
2	0.998	0.998	0.997	0.998	0.997
3	0.968	0.998	0.938	0.967	0.961
4	0.998	0.998	0.997	0.997	0.998

그림 11의 AUC-ROC 그래프는 LSTM-AE 모델의 실제 양성 비율과 거짓 양성 비율 간의 균형에 대한 효과를 보여준다. 이 모델은 각 fault 별로 AUC-ROC 점수가 각각 0.955, 0.997, 0.961, 0.998로 본 연구에서 제시하는 LSTM-AE 방법이 시스템의 이상징후를 올바르게 식별하는 데 효과적임을 보여준다.

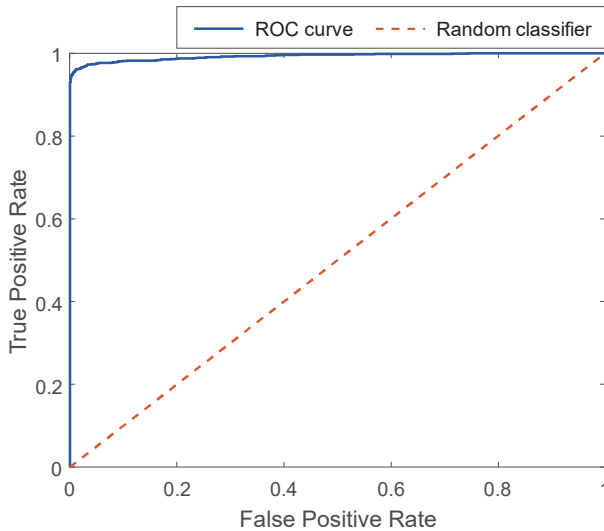


Fig. 11 AUC-ROC curve of the proposed model in the Fault 1 case

5. 결 론

본 연구에서는 LSTM-Autoencoder 기반 이상징후 감지 시스템을 개발하고, 풍력터빈의 모니터링으로부터 출력되는 데이터셋을 사용하여 성능을 검증하였다. 이 시스템은 시계열 데이터를 효과적으로 분석하고 정상상태 데이터를 이용한 학습을 위해 네 개의 LSTM 층을 사용하여 인코더 및 디코더를 구성하여 LSTM-AE를 구현하였다. LSTM-AE는 시퀀스 데이터를 특정 공간에서 데이터를 재구성하여 정상 데이터 학습만으로 풍력터빈에 발생할 수 있는 이상 징후를 빠른 시간 내에 감지한다. 이상 감지를 위한 임계값은 훈련과정에서 구해지는 재구성 손실의 분포도를 이용하여 선택한다. LSTM-AE의 성능 검증절차에서 제안한 모델이 종합적으로 우수한 성능을 보였다. 추후에는 Transformer를 이용하여 모델의 성능을 더 개선된 알고리즘을 개발할 예정이다.

후 기

본 논문의 기초연구 단계에서 소중한 의견을 주신 NTNU의 Torgeir Moan 및 Zhen Gao 교수님께 감사드립니다. 이 논문은 Equinor의 재원으로 MIT-NTNU-Statoil Wind Turbine Program의 지원을 받아 수행된 기초연구사업임. 이 논문은 2024년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(과제번호: 2022R1A6A1A03056784).

References

- [1] I. Dinwoodie, D. McMillan, M. Revie, I. Lazakis, Y. Dalgic, "Development of a combined operational and strategic decision support model for offshore wind," *Energy Procedia*, vol. 35, pp. 157-166, 2013.
- [2] J.B. Gayo, Reliability-focused Research on Optimizing Wind Energy System Design, Operation and Maintenance: Tools, Proof of Concepts, Guidelines & Methodologies for a New Generation, Final Publishable Summary of Results of Project ReliaWind, 2011.
- [3] J. Carroll, A. McDonald, D. McMillan, "Failure rate, repair time and unscheduled O&M cost analysis of offshore wind turbines," *Wind Energy*, vol. 19, pp. 1107-1119, 2016.
- [4] Cho S, Bachynski E, Rasekhi Nejad A, Gao Z, Moan T. "Numerical modeling of hydraulic blade pitch actuator in a spar-type floating wind turbine considering fault conditions and their effects on global dynamic responses," *Wind Energy*, vol. 23, no. 2, pp. 370-390, 2020.
- [5] S. Cho, Z. Gao, T. Moan, "Model-based fault detection, fault isolation and fault tolerant control of a blade pitch system in floating wind turbines," *Renewable Energy*, vol. 120, pp. 306-321, 2018.
- [6] R. Isermann, Fault-diagnosis Systems: an Introduction from Fault Detection to Fault Tolerance, Springer Science & Business Media, 2006.
- [7] A. Kusiak, A. Verma, "A data-driven approach for monitoring blade pitch faults in wind turbines," *IEEE Transactions on Sustainable Energy*, vol. 2, pp. 87-96, 2011.
- [8] J. H. Choi, "A review on prognostics and health management and its applications," *Journal of Aerospace System Engineering*, vol. 8, no. 4, pp. 7-17, 2014.
- [9] A. Kusiak, W. Li, "The prediction and diagnosis of wind turbine faults," *Renewable Energy*, vol. 36, no. 1, pp. 16-23, 2011.
- [10] L. Wang, Z. Zhang, H. Long, J. Xu, R. Liu, "Wind turbine gearbox failure identification with deep neural networks," *IEEE Transactions on Industrial Informatics*, vol. 13, no. 3 pp. 1360-1368, 2016.
- [11] A.S. Zaher, S.D. McArthur, D.G. Infield, Y. Patel, "Online wind turbine fault detection through automated SCADA data analysis," *Wind Energy: An International Journal for*

- Progress and Applications in Wind Power Conversion Technology*, vol. 12, no. 6, pp. 574-593, 2009.
- [12] A. Kusiak, A. Verma, "Analyzing bearing faults in wind turbines: a data-mining approach," *Renewable Energy*, vol. 48, pp. 110-116, 2012.
- [13] S. Cho, M. Choi, Z. Gao, T. Moan, "Fault detection and diagnosis of a blade pitch system in a floating wind turbine based on Kalman filters and artificial neural networks," *Renewable Energy*, vol. 169, pp. 1-13, 2021.
- [14] M. Bach-Andersen, B. Rømer-Odgaard, O. Winther, "Deep learning for automated drivetrain fault detection," *Wind Energy*, vol. 21, no. 1, pp. 29-41, 2018.
- [15] R. Rahimilarki, Z. Gao, N. Jin, A. Zhang, "Convolutional neural network fault classification based on time-series analysis for benchmark wind turbine machine," *Renewable Energy*, vol. 185, pp. 916-931, 2022.
- [16] N. Dervilis, M. Choi, S.G. Taylor, R.J. Barthorpe, G. Park, C.R. Farrar, K. Worden, "On damage diagnosis for a wind turbine blade using pattern recognition," *Journal of Sound and Vibration*, vol. 333, no. 6, pp. 1833-1850, 2014.
- [17] G. Jiang, P. Xie, H. He, J. Yan, "Wind turbine fault detection using a denoising autoencoder with temporal information," *IEEE/ASME Transactions on Mechatronics*, vol. 23, no. 1, pp. 89-100, 2017.
- [18] S. Cho, J. Park, M. Choi, "Fault classification of a blade pitch system in a floating wind turbine based on a recurrent neural network," *Journal of Ocean Engineering and Technology*, vol. 35, no. 4, pp. 287-295, 2021.
- [19] Y. Cui, P. Bangalore, L. B. Tjernberg, "A fault detection framework using recurrent neural networks for condition monitoring of wind turbines," *Wind Energy*, vol. 24, no. 11, pp. 1249-1262, 2021.
- [20] K. Dhibi, M. Mansouri, K. Bouzrara, H. Nounou, M. Nounou, "Enhanced Recurrent Neural Network for Fault Diagnosis of Uncertain Wind Energy Conversion Systems," *Proc. of International Conference on Control, Decision and Information Technologies (CoDIT)*, Vol. 1, pp. 1330-1335, May 2022.
- [21] H. D. Nguyen, K. P. Tran, S. Thomassey, M. Hamad, "Forecasting and Anomaly Detection approaches using LSTM and LSTM Autoencoder techniques with the applications in supply chain management," *International Journal of Information Management*, vol. 57, no. 102282, 2021.
- [22] P. Malhotra, L. Vig, G. Shroff, P. Agarwal, "Long short term memory networks for anomaly detection in time series," *Proc. of European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN)*, pp. 89-94, 2015.
- [23] J. Jonkman, S. Butterfield, W. Musial, G. Scott, Definition of a 5-MW Reference Wind Turbine for Offshore System Development Technical Report NREL/TP- 500-38060 USA, 2009.
- [24] J. Jonkman, Definition of the Floating System for Phase IV of OC3 Technical Report NREL/TP-500-47535 USA, 2010.
- [25] SINTEF Ocean, SIMO 4.15.0 User Guide, 2018.
- [26] SINTEF Ocean, RIFLEX 4.15.0 User Guide, 2018.
- [27] IEC 61400-1: Wind Turbines e Part 1: Design Requirements, International Electrotechnical Commission, 2005.
- [28] IEC 61400-3: wind turbines e Part 3: design requirements for offshore wind turbines, International Electrotechnical Commission, 2005.
- [29] J. Jonkman, L. Kilcher, TurbSim User's Guide Technical Report NREL USA, 2012.
- [30] K. Hasselmann, T.P. Barnett, E. Bouws, H. Carlson, D.E. Cartwright, K. Enke, J.A. Ewing, H. Gienapp, D.E. Hasselmann, P. Kruseman, A. Meerburg, Measurements of wind-wave growth and swell decay during the Joint North Sea Wave Project (JONSWAP), *Ergänzungsheft 8e12* (1973).
- [31] K. Johannessen, T. Meling, S. Haver, "Joint distribution for wind and waves in the northern North Sea," *International Journal of Offshore and Polar Engineering*, vol. 12, no. 1, pp.1-8, 2001.
- [32] G. Lloyd, G. Hamburg, "Guideline for the certification of wind turbines," *GL Report*, July 2010.
- [33] D. P. Kingma, B. Jimmy "Adam: A method for stochastic optimization," *arXiv*, 1412.6980v9, 2014.