

## Prediction Remaining Useful Life of Aircraft Turbofans Using Transfer Learning Based CNN-LSTM

Kim Jeong Min<sup>†</sup> · Kang Hyeon Woo<sup>††</sup> · Cho Young Ki<sup>†††</sup> · Kwon Gi Hyuk<sup>††††</sup> · An Seo Yeon<sup>†††††</sup> · Kim Hun Kee<sup>†††††</sup>

### ABSTRACT

The objective of research in the field of prognostics and health management is to predict the Remaining Useful Life of aircraft engines, a critical component of analysis within this domain. Nevertheless, there are difficulties in acquiring dependable failure information, and the limited availability of defect data hinders the development of predictive models. Current data augmentation techniques are utilized to enhance the insufficient defect data; however, the heuristic approaches might oversimplify the data characteristics, ultimately decreasing predictive accuracy. This study suggests a hybrid model that combines Transfer Learning, specifically integrating Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM). The hybrid CNN-LSTM model integrates the CNN's feature extraction capabilities with the LSTM's long-term time series learning capacity, facilitating the representation of intricate dynamic characteristics and temporal fluctuations in aircraft engine sensor data. The performance of predictive techniques is enhanced by applying data learned from various source domains to target domain data through transfer learning. The results obtained by applying this model to the C-MAPSS aircraft engine simulator dataset developed by the National Aeronautics and Space Administration (NASA) corroborate the idea that employing a pre-trained model through transfer learning improves predictive accuracy in comparison to the standard mixed model. Furthermore, the proposed model demonstrates improved predictive abilities when compared to various leading predictive models in the PHM field.

Keywords : Prognostics and Health Management, Remaining Useful Life Prediction, CNN-LSTM, Transfer Learning, C-MAPSS Dataset

## 전이학습 기반 CNN-LSTM을 통한 항공기 터보팬 잔여 유효 수명 예측

김 정 민<sup>†</sup> · 강 현 우<sup>††</sup> · 조 영 기<sup>†††</sup> · 권 기 혁<sup>††††</sup> · 안 서 연<sup>†††††</sup> · 김 훈 기<sup>†††††</sup>

### 요 약

항공기 엔진의 잔여 유효 수명(RUL) 예측은 고장 예지 및 건전성 관리(PHM)를 좌우하는 중요한 역할이며 관련 연구가 활발히 진행되고 있다. 하지만 실제 고장 데이터를 확보하는 데 어려움이 있으며 결함 데이터의 희소성으로 인해 예측 모델 구축에 한계가 존재한다. 기존의 데이터 증대 방법은 제한된 결함 데이터를 보완하기 위해 사용되지만, 휴리스틱한 접근법으로 인해 데이터 특성이 일반화되는 문제가 발생하며 예측 정확도가 저하될 수 있다. 이러한 문제를 해결하기 위해, 본 연구에서는 전이학습(Transfer Learning)에 기반한 CNN-LSTM 혼합모델을 제안한다. CNN-LSTM 혼합모델은 CNN의 특징 추출 능력과 LSTM의 장기 시계열 학습 능력을 결합하여, 항공기 엔진 센서 데이터의 복잡한 동적 특성과 시계열적 변화를 동시에 반영한다. 본 모델로 서로 다른 소스 도메인(Source Domain)에서 학습된 데이터를 전이학습을 통해 타겟 도메인(Target Domain) 데이터에 적용함으로써, 예측 기법의 성능을 향상시킨다. 미국항공우주국(NASA)에서 개발한 C-MAPSS 항공기 엔진 시뮬레이터 데이터 세트에 적용한 결과, 전이학습을 통한 사전 학습된 모델의 활용이 기본 혼합모델보다 예측 정확도 향상에 기여함을 확인하였다. 또한, 제안된 모델이 PHM 분야에서 주요한 여러 예측 모델들 대비 우수한 예측 성능을 보임을 확인하였다.

키워드 : 고장 예지 및 건전성 관리, 잔여 유효 수명 예측, CNN-LSTM, 전이학습, C-MAPSS 데이터세트

※ 본 논문은 2024년도 LIG Nex1과 국방과학연구소의 재원을 지원받아 수행된 연구임.

† 준 회 원 : 인하대학교 첨단소재공정공학과 석사과정

†† 비 회 원 : 인하대학교 첨단소재공정공학과 박사과정

††† 비 회 원 : LIG 넥스원 연구위원

†††† 비 회 원 : LIG 넥스원 수석연구원

††††† 비 회 원 : LIG 넥스원 연구위원

†††††† 정 회 원 : 인하대학교 첨단소재공정공학과 교수

Manuscript Received : November 20, 2024

Accepted : November 28, 2024

\* Corresponding Author : Kim Hun Kee(hunkeekim@inha.ac.kr)

## 1. 서론

잔여 유효 수명(RUL, Remaining Useful Life) 예측은 고장 예지 및 건전성 관리(PHM, Prognostics and Health Management)의 핵심 기술로, 장비의 상태를 모니터링하고 고장을 사전에 예측하며 유지보수 일정을 최적화하는 데 사용된다. 특히, 항공기 터보팬 엔진의 경우 RUL 예측은 비행 안전성과 비용 절감에 중요한 역할을 한다 [1].

PHM은 항공뿐만 아니라 다양한 산업 분야에서 장비의 신뢰성 확보 및 효율성 향상을 위한 필수적인 요소로 자리 잡고 있다. PHM 시스템은 상태 기반 유지보수를 가능하게 하며, 사전에 고장을 예측하여 비정상적인 장비 가동 중단을 방지한다. PHM의 도입은 해양 엔진, 발전소 터빈 및 철도와 같은 고비용 장비에서도 강조되며, 이러한 시스템을 통해 운영 효율성을 높이고, 유지보수 비용을 줄이는 효과를 얻을 수 있다 [2].

최근에는 데이터 기반 방법론을 중심으로 시스템 또는 구성품 수준에서의 RUL을 예측하는 다양한 AI 알고리즘 모델이 연구되고 있다 [3]. 그 중에서도 심층 학습 기법은 RUL 예측에서 중요한 역할을 하고 있으며, CNN(Convolutional Neural Networks)과 LSTM(Long Short-Term Memory) 네트워크는 데이터의 공간적 및 시간적 패턴을 포착하는 특징이 있다 [4].

하지만 항공기 터보팬 엔진과 같은 고비용, 고위험 장비에서는 다양한 환경 조건에서 데이터를 수집하기 어려우며, 이는 학습에 사용할 데이터의 부족으로 이어진다. 이러한 문제를 해결하기 위해 데이터 증강(Data Augmentation) 기법이 부족한 데이터셋을 늘리기 위해 널리 사용되지만, 몇 가지 한계점이 존재한다. 첫째로, 데이터 증강을 통해 인위적으로 데이터셋의 크기를 늘리면, 추가적인 메모리와 연산 비용이 발생할 수 있다. 또한, 일부 변형은 데이터의 레이블을 유지하지 못할 수 있어, 예측 모델이 잘못된 학습을 하게 만들 가능성도 있다 [5]. 특히, 부적절한 증강 방법을 사용할 경우, 편향된 합성 데이터가 생성되어 실제 데이터를 제대로 반영하지 못할 수 있으며, 이는 모델 성능에 부정적인 영향을 미칠 수 있다 [6].

이러한 문제들을 해결하기 위한 방법 중 하나로 전이학습(Transfer Learning)이 주목받고 있다. 전이학습은 소스 도메인의 데이터를 활용하여 타겟 도메인의 데이터 부족 문제를 해결하고, 더 높은 예측 성능을 달성할 수 있다. 특히, 항공기 터보팬 엔진의 RUL 예측에서, 데이터 수집의 어려움과 라벨링된 데이터 부족 문제를 해결하는 데 효과적이다. 소스 도메인의 데이터를 사용하여 타겟 도메인의 데이터 분포 차이에 대응하고, 새로운 환경에서도 예측 정확도를 유지할 수 있게 한다 [7]. 실제로 항공기 엔진과 해양 공기 압축기와 같은 서로 다른 장비에서 수집된 데이터를 기반으로 전이학습을 통해 성능이 향상된 사례들이 있다. 소스 도메인에서 학

습한 데이터를 타겟 도메인에 적용함으로써 PHM 성능을 크게 향상시킬 수 있음을 보여주었다. 또한, 항공기 터보팬 엔진 데이터와 유사한 엔진에 대한 PHM 적용 연구는 터보팬 엔진의 RUL 예측에서 전이학습이 가지는 가능성을 시사한다 [8].

본 논문은 이러한 해결에 기여하기 위해 전이학습(Transfer Learning) 기법을 활용한 예측 모델을 제안하고자 한다. 전이학습은 서로 다른 도메인에서 학습된 모델을 타겟 도메인에 적용함으로써 데이터 부족 문제를 완화하고, 예측 모델의 성능을 향상시키는 방법이다. 본 연구에서는 CNN-LSTM 모델을 사용하여 전이학습 기법을 적용하였고, NASA의 C-MAPSS 항공기 엔진 시뮬레이터 데이터셋을 이용해 실험을 수행한 결과, 기존의 예측 모델들에 비해 향상된 성능을 확인하고자 한다.

본 논문에서는 2절에서 시계열 데이터에서 주로 사용되는 CNN 모델과 LSTM 모델을 고찰하고, 3절에서는 C-MAPSS 데이터셋에 전이학습 기반의 CNN-LSTM 모델을 적용하기 위한 과정을 설명한다. 4절에서는 C-MAPSS 데이터셋을 활용한 실험 결과를 분석하고, 5절에서는 결론 고찰과 본 연구의 주요 기여와 향후 연구 방향에 대해 논의한다.

## 2. 도메인 적응 기술과 알고리즘

### 2.1 문제 정의

항공기 엔진의 잔여 유효 수명(RUL) 예측은 비행 안전과 유지보수 최적화에 있어 매우 중요한 요소로, 이를 위해 센서 데이터를 활용한 예측 모델이 광범위하게 사용되고 있다. 그러나 각기 다른 운용 조건, 고장 모드, 그리고 센서 환경에서 수집된 데이터는 그 특성이 상이하여, 개별적인 도메인에서 학습된 경우 새로운 환경에서는 성능 저하가 발생할 수 있다.

실제 운용 조건에서는 소스 도메인에서 학습된 모델이 타겟 도메인으로 적용될 때 성능이 저하될 위험이 있다. 이는 다양한 운영 조건에서 수집된 데이터 간 차이로 인해 발생하며, 이러한 차이를 보정하지 않으면 새로운 데이터에 대한 예측 성능이 크게 저하될 수 있다 [9].

도메인 적응(Domain Adaptation)은 이러한 문제를 해결하기 위해 제안된 기술로, 소스 도메인에서 학습된 모델을 타겟 도메인에 적용하기 위해 도메인 간 차이를 보정하는 기법이다. 이 기술은 서로 다른 환경에서 수집된 데이터 간의 차이를

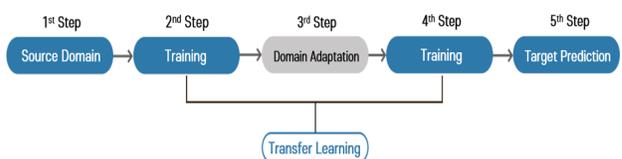


Fig. 1. Domain Adaptation

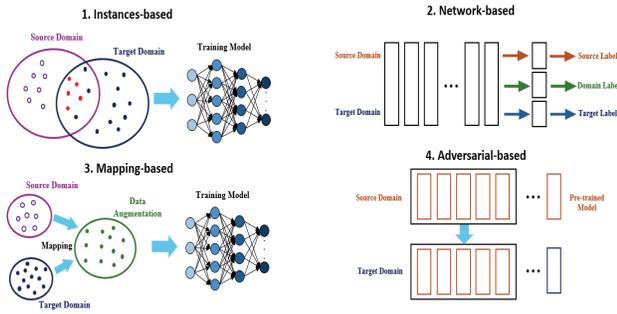


Fig. 2. Methods for Cross-Domain Learning

줄여 예측 모델의 성능 저하를 방지하고, 새로운 환경에서도 예측 정확도를 유지하는 데 효과적이다. 특히 복잡한 시스템에서의 도메인 간 차이를 보정하는 것은 매우 중요하며, 이를 통해 RUL 예측의 신뢰성을 높일 수 있다 [10].

또한, 기존 연구들은 소스 도메인에서 충분히 수집된 데이터를 바탕으로 타겟 도메인에 모델을 적용하여 성능을 개선하는 사례를 보여주었다. 전이학습 기법을 통해 두 도메인 간의 차이를 줄이고, 새로운 조건에서 모델이 예측 성능을 유지할 수 있도록 하는 방법론이 제안되었다 [11].

Fig. 2와 같이 도메인 적응 방법론은 Instances-based, Network-based, Mapping-based, Adversarial-based 접근법이 있다. 그중에서도 도메인 간 패턴 학습을 효과적으로 활용할 수 있는 Network-based 도메인 적응 기술을 통한 전이학습(Transfer Learning) 기법이 있다. 이 접근법은 소스 도메인에서 이미 학습된 패턴과 지식을 타겟 도메인에 적용하여, 데이터 부족 문제를 완화하고, 다양한 운용 조건에서 일관된 예측 성능을 유지하며, 도메인 간 차이를 극복할 수 있도록 한다. 전이학습을 통한 도메인 간 패턴 학습은 항공기 엔진 센서 데이터를 기반으로 한 RUL 예측 모델에서 발생할 수 있는 여러 문제를 효과적으로 해결할 수 있는 핵심 전략으로 활용될 수 있다 [12].

2.2 시계열 데이터의 이미지화 및 CNN 알고리즘

본 연구에서는 시계열 데이터를 CNN 모델에 적합한 2차원 이미지 형태로 변환하기 위해 Recurrence Plot (RP) 기법을 활용하였다. RP는 시계열 데이터를 2D 이미지로 변환하는 대표적인 방법 중 하나로, 시계열의 복잡한 행동을 시각적으로 분석할 수 있도록 자기 유사성을 2차원 매트릭스 형태로 표현한다. 이를 통해 숨겨진 주기성, 비선형성, 그리고 장기적 의존성을 시각화할 수 있다.

Hatami et al. (2017)은 RP를 사용하여 시계열 데이터를 2D 이미지로 변환한 후, 이를 CNN에 입력하여 시계열 데이터의 복잡한 특징을 추출하는 방법을 제안하였다. 이 연구에서는 CNN이 여러 층의 합성곱과 풀링을 통해 이미지의 국부적인 패턴을 자동으로 학습하고, 이를 통해 시계열 데이터를 효과적으로 분류할 수 있음을 실험적으로 입증하였다. 또한, CNN 모델은 2D 이미지 상의 패턴을 학습하여 다양한 수준의

특징을 추출함으로써, 기존의 1D 시계열 데이터 분석 방식에 비해 더 나은 성능을 보인다고 설명하였다 [13].

$$R_{i,j} = \theta(\epsilon - \|\vec{s}_i - \vec{s}_j\|), \vec{s}(\bullet) \in R^n, i, j = 1, 2, \dots, K \quad (1)$$

$\vec{s}_i$ 와  $\vec{s}_j$ 는 시계열 데이터의  $i$ 번째와  $j$ 번째 상태를 나타내며,  $\epsilon$ 은 미리 정의된 임계값이다. Heaviside 함수  $\theta$ 는 두 상태 간의 거리가 임계값  $\epsilon$ 이하일 때  $R_{i,j}$ 값을 1로 설정하고, 그렇지 않을 경우 0을 반환한다. 이를 통해 두 시점 간의 유사성을 평가할 수 있다.

Fig. 3과 같이, 각 센서의 시계열 데이터를 Recurrence Plot으로 변환하여 처리하였다. 시계열 데이터 내에서 반복되는 패턴이 존재하며, 이러한 패턴은 RP에서 밝은 점이나 블록으로 나타난다. 이는 해당 시점들이 서로 유사성을 공유한다는 것을 의미한다. RP는 시스템의 주기적 동작과 비주기적 동작을 모두 감지할 수 있는 기능을 제공하므로 이상 징후를 조기에 식별하는 역할을 한다. 데이터에 내재된 잠재 패턴과 구조적 특성을 추출하여 고장 진단의 정확성을 높인다. [14-15]

CNN 알고리즘은 주로 이미지나 시계열 데이터를 비롯한 고차원 데이터를 분석하는 데 주로 사용되는 딥러닝 아키텍처를 나타내며, 지역적 패턴을 식별하는 데 강점을 가진다 [16]. CNN은 입력 데이터 X에 대해 여러 개의 필터  $w$ 를 적용하여

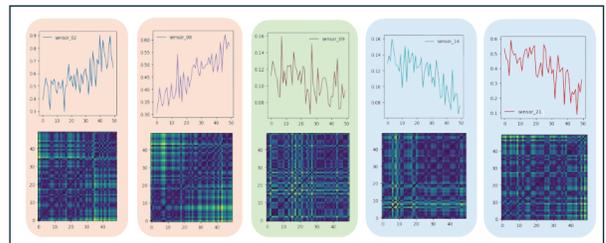


Fig. 3. Recurrence Plot of Sensor Data

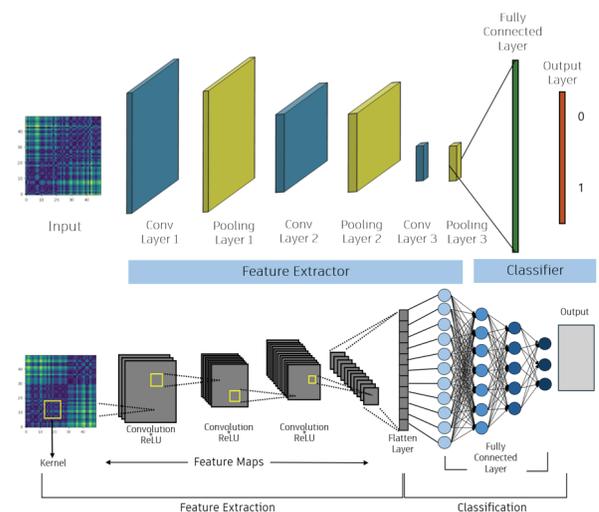


Fig. 4. The schematic layout of Convolution Neural Network (CNN)

특징 맵(Feature Map)을 생성한다. 이 과정은 수식으로 다음과 같이 표현된다.

$$Z_{i,j,k} = f\left(\sum_{m=1}^M \sum_{n=1}^N X_{i+m,j+n} \cdot W_{m,n,k} + b_k\right) \quad (2)$$

$Z_{i,j,k}$ 는 k번째 필터가 적용된 후의 i, j 위치에서의 출력값을 나타내며,  $W_{m,n,k}$ 는 k번째 필터의 가중치,  $b_k$ 는 바이어스, 그리고  $f$ 는 ReLU(Rectified Linear Unit)와 같은 활성화 함수를 나타낸다. CNN은 이러한 방법론으로 입력 데이터의 국소적인 패턴을 추출하며, 이는 항공기 엔진의 여러 센서에서 수집된 데이터의 특성을 탐지하는 데 중요한 역할을 한다. 센서 데이터는 각기 다른 시간대와 위치에서 수집된 광범위한 정보를 포함하고 있으며, CNN은 이러한 정보 간의 지역적 상관관계를 파악할 수 있으므로 특정 고장 모드 또는 엔진 상태의 특성을 효과적으로 학습한다.

### 2.3 LSTM 알고리즘

LSTM 알고리즘은 순환 신경망(RNN)의 일종으로, 시계열 데이터에서 시간적 의존성을 학습하는 데 특화된 구조를 가진다. RNN은 그래디언트 소실 및 폭발 문제에 취약하며, 장기 예측 문제를 해결하지 못하는 데 반해, LSTM은 특히 수명 예측에 있어서 장기 기억 정보를 저장하는 기억 유닛을 구축함으로써 더 나은 성과를 보였다 [16-18].

LSTM 셀은 입력 게이트, 망각 게이트, 출력 게이트의 세 가지 주요 게이트로 구성된다. Fig. 5에서 볼 수 있듯이, LSTM은 각 게이트를 통해 현재 셀 상태를 업데이트하고, 숨겨진 상태 벡터를 출력한다.

망각 게이트는 이전 출력값  $h_{t-1}$  과 현재 입력값  $x_t$  를 기반으로 시그모이드 함수  $\sigma$  를 사용하여 망각 벡터  $f_t$  를 생성한다. 이를 통해 셀이 이전 상태 정보를 유지할지 버릴지를 결정하며, 이 과정에서  $W_f$  는  $h_{t-1}$  과  $x_t$  에 곱해지는 가중치 행렬로, 입력 데이터를 선형 변환한다.  $b_f$  는 망각 게이트의 바이어스로, 활성화 값 계산 과정에서 추가되어 게이트의 출력을 조정한다. 망각 게이트는 수식 (3)과 같이 표현된다.

$$f_t = \sigma(W_f h_{t-1} + W_x x_t + b_f) \quad (3)$$

입력 게이트는 새로운 정보가 셀 상태에 얼마나 반영될지를 결정한다. 시그모이드 함수  $\sigma$  와  $\tanh$  함수를 사용한다. 입력 게이트  $i_t$  는 이전 출력값  $h_{t-1}$  과 현재 입력값  $x_t$  에 가중치  $W_i$  와 바이어스  $b_i$  를 적용하여 계산되며, 값은 0에서 1 사이로 출력되어 현재 상태에 추가될 정보량을 결정한다. 새로운 후보 셀 상태  $\tilde{C}_t$  도 가중치  $W_c$  와 바이어스  $b_c$  를 적용하여  $\tanh$  함수를 통해 계산된다. 이는 수식 (4)와 (5)로 표현된다.

$$i_t = \sigma(W_i h_{t-1} + W_x x_t + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c h_{t-1} + W_x x_t + b_c) \quad (5)$$

셀 상태 업데이트는 망각 게이트를 통해 이전 상태  $C_{t-1}$  의 일부를 유지하고, 입력 게이트를 통해 새로운 정보를 추가하여 현재 셀 상태  $C_t$  를 형성한다. 이는 수식 (6)으로 표현된다.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (6)$$

출력 게이트는 현재 셀 상태를 기반으로, 다음 단계로 전달될 출력 값을 결정한다. 출력 게이트  $O_t$  는  $h_{t-1}$  과  $x_t$  에 가중치  $W_o$  와 바이어스  $b_o$  를 적용하여 시그모이드 함수  $\sigma$  를 통해 계산된다. 이는  $C_t$  에  $\tanh$  함수를 적용한 결과와 곱해져 최종 출력  $h_t$  를 생성하며, 이는 수식 (7)과 (8)로 표현된다.

$$O_t = \sigma(W_o h_{t-1} + W_x x_t + b_o) \quad (7)$$

$$h_t = O_t * \tanh(C_t) \quad (8)$$

이와 같은 구조를 통해 LSTM은 장기 메모리를 효과적으로 관리하며, 시간에 따른 데이터의 종속성을 학습할 수 있는 능력을 제공한다. 망각 게이트는 불필요한 정보를 버리고, 입력 게이트는 중요한 정보를 셀 상태에 추가하며, 출력 게이트는 이 정보를 바탕으로 다음 레이어에 전달할 값을 결정한다.

### 3. CNN-LSTM 알고리즘

많은 연구에서 다변수 시계열 이상 탐지에서 CNN과 LSTM을 결합하여 유망한 결과를 보이고 있다 [19-22]. 이에 착안하여, 본 연구에서는 RUL 예측을 위해 2D CNN-LSTM 전이학습 모델을 제안한다. 모델의 아키텍처는 Fig. 6과 같다.

제안된 2D CNN-LSTM 전이 학습 모델은 공간적 및 시간적 특징을 추출하여 예측 성능을 향상시키기 위해 컨볼루션

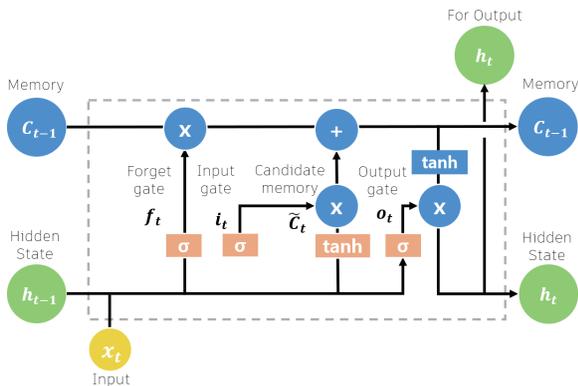


Fig. 5. The structure of an LSTM unit

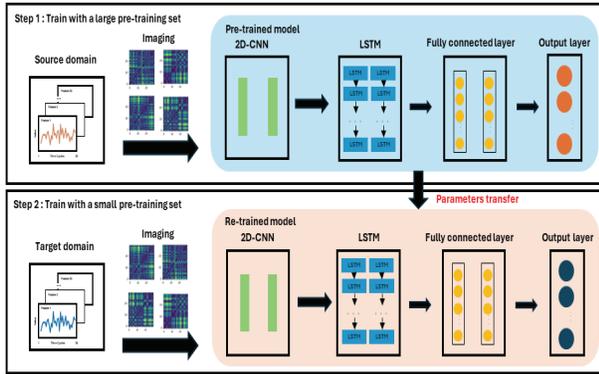


Fig. 6. Architecture of the proposed transfer learning based CNN-LSTM model

레이어와 LSTM 레이어의 조합으로 설계되었다.

이 모델은 3×3 필터 크기를 사용하는 두 개의 컨볼루션 레이어로 시작하여 입력 데이터에서 공간적 특징을 추출한다. 풀링 레이어는 2×2 필터와 두 개의 레이어로 구성되며, 공간 차원을 줄이고 계산 복잡도를 낮추면서도 중요한 특징을 유지하는 역할을 한다.

컨볼루션 레이어 이후에는 100개의 유닛을 가진 하나의 LSTM 레이어가 포함되어 시계열 데이터의 시간적 종속성을 포착한다. 이 LSTM 레이어는 입력 데이터의 순차적 정보를 처리하여 미래 값을 예측하는 모델의 능력을 향상시킨다. 학습 과정은 총 7개의 레이어로 구성된다. 모델 훈련 중 배치 크기는 100으로 설정되었으며, 50번의 에포크로 훈련을 진행하여 훈련 시간과 모델 수렴 사이의 균형을 맞춘다. 학습률은 0.001로 최적화되며, Adam 옵티마이저를 사용하여 손실 함수의 그래디언트를 기반으로 가중치를 조정한다. 모델 전반에 걸쳐 활성화 함수로는 ReLU가 사용되며, 이는 모델에 비선형성을 부여하면서도 계산 효율성을 유지한다. 성능 평가를 위해 손실 함수로는 평균 제곱 오차(MSE)를 사용하여 예측값과 실제 값 간의 차이를 최소화하는 것을 목표로 한다.

Table 1. Summary of CNN-LSTM Model Training

Parameters		Values
Convolutional layer	Filter size, Layers	3×3, 2
Pooling layer	Filter size, Layers	2×2, 2
LSTM layer	Units	100
Learning process	Layers	7
	Batch size	100
	Epochs	50
	Learning rate	0.001
	Optimizer	Adam
Activation function	Relu	
Loss function	Mean Squared Error	

## 4. 실험

### 4.1 C-MAPSS 데이터세트와 전처리

본 연구에서는 전이학습 기반의 CNN-LSTM 알고리즘을 C-MAPSS 데이터 세트에 적용하여 항공기 터보팬 엔진의 잔여 유효 수명(RUL) 예측 성능 개선을 검증하고자 하였다. 실험에 사용된 C-MAPSS 데이터 세트는 NASA에서 생성한 상업용 모듈형 항공 추진 시뮬레이션(Commercial Modular Aero-Propulsion System Simulation, CMAPSS) 데이터로, 터보팬 엔진의 실제 성능 저하를 시뮬레이션한 벤치마크 자료이다.

Fig. 7은 엔진 모델의 핵심 구성 요소들을 상세히 설명하며, 엔진의 전체적인 구조를 나타낸다. 또한, 시뮬레이션 맥락에서 다양한 서브루틴이 구성되고 통합되는 복잡한 과정을 종합적으로 보여준다 [23].

항공기 엔진의 작동 상태를 모니터링하려면 온도, 압력, 팬 속도, 코어 속도, 공기-연료 비율을 포함하나 이에 국한되지 않는 다양한 물리적 파라미터를 종합적으로 활용해야 한다. Table 2에 나와 있는 것처럼, 항공기 엔진의 다양한 복잡한 구성 요소 내부 또는 상단에 총 21개의 보정된 센서가 존재하며, 이는 일반적인 작동 조건을 감지하고 평가하는 중요한 정보를 제공한다 [24].

C-MAPSS 데이터 세트는 21개의 센서 데이터로 구성되어 있으며, 다양한 고장 모드와 작동 조건에 따라 FD001부터 FD004까지 4개의 하위 데이터 세트로 나뉜다. 각 데이터 세트는 다른 운용 조건과 고장 모드를 포함하고 있으며, 본 연구에서는 작동 조건이 하나이고 고장 유형이 하나인 FD001을 타겟 도메인으로 선택하였으며, 유사한 데이터 구성의 FD003을 소스 도메인으로 선정하였다.

RUL은 터보팬 엔진이 고장나기 전에 남은 수명을 의미하며, CMAPSS 데이터 세트에서는 RUL을 엔진의 최대 수명에서 현재까지의 사용 수명을 뺀 값으로 정의한다. 각 엔진의 RUL

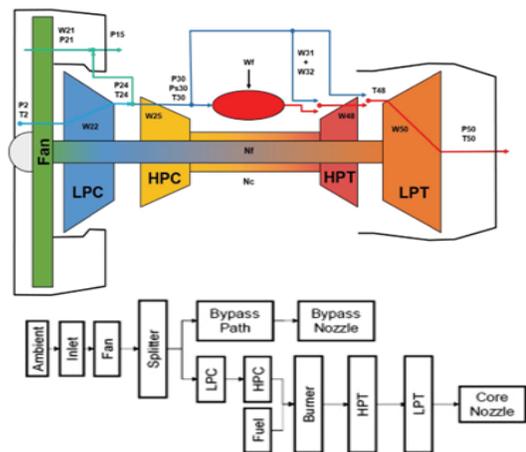


Fig. 7. Schematic diagram of the model used in C-MAPSS [23]

Table 2. C-MAPSS outputs to measure system response [24]

Symbol	Description	units
Parameters available to participants as sensor data		
T2	Total temperature at fan inlet	°R
T24	Total temperature at LPC outlet	°R
T30	Total temperature at HPC outlet	°R
T50	Total temperature at LPT outlet	°R
P1	Pressure at fan inlet	psia
P15	Total pressure in bypass-duct	psia
P30	Total pressure at HPC outlet	psia
Nf	Physical fan speed	rpm
Nc	Physical core speed	rpm
Epr	Engine pressure ratio (P50/P2)	--
Ps30	Static pressure at HPC outlet	psia
Phi	Ratio of fuel flow to Ps30	pps/psi
NRf	Corrected fan speed	rpm
NRc	Corrected core speed	rpm
BPR	Bypass Ratio	--
farB	Burner fuel-air ratio	--
htBleed	Bleed Enthalpy	--
Nf_dmd	Demanded fan speed	rpm
PCNfR_dmd	Demanded corrected fan speed	rpm
W31	HPT coolant bleed	lbm/s
W32	LPT coolant bleed	lbm /s

Table 3. Overview of C-MAPSS Dataset Characteristics for Different Fault Detection Scenarios

Dataset	FD001	FD002	FD003	FD004
Training set	100	260	100	249
Testing set	100	259	100	248
Maximum life span(Cycles)	362	378	525	543
Average life span(Cycles)	206	206	247	245
Minimum life span(Cycles)	128	128	145	128
Operating Conditions	1	6	1	6
Fault conditions	1 (HPC)	1 (HPC)	2 (HPC, Fan)	2 (HPC, Fan)

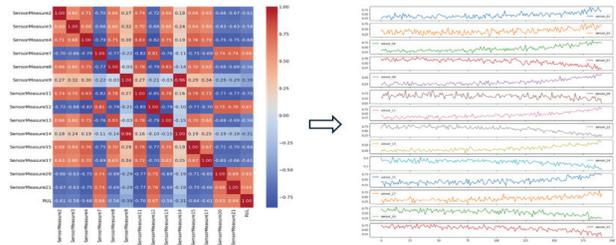


Fig. 8. Visualization of 21 sensors correlation of C-MAPSS dataset

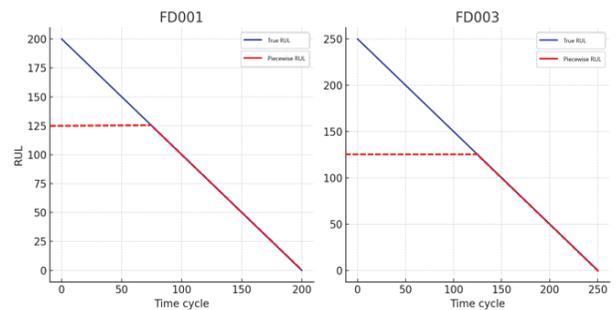


Fig. 9. True RUL and Piecewise RUL Predictions for FD001 and FD003

분포를 분석한 결과, 대부분의 엔진은 200사이클 이내에 고장이 발생하며, 일부 엔진은 300사이클 이상의 수명을 가지거나 150사이클 이하에서 고장이 발생하는 것을 확인하였다. 이를 바탕으로 RUL 예측의 정확도를 높이기 위해 총 21개의 센서 데이터가 RUL과 어떻게 상관관계를 가지는지 시각화를 통해 분석하였다.

분석 결과, 센서 1, 5, 10, 16, 18, 19는 RUL의 변화와 상관없이 센서 값이 거의 변동하지 않는 것으로 나타났으며, 센서 6의 경우에는 때때로 변동을 보였으나, 감소하는 RUL과 명확한 관계가 없는 것으로 판단되었다. 따라서 RUL 예측 모델의 학습 과정에서 이러한 센서들은 예측에 유의미한 영향을 미치지 않는다고 판단하여, 센서 1, 5, 6, 10, 16, 18, 19의 7개 센서를 제외하였다. 반면에, 센서 2, 3, 4, 8, 11, 13, 15, 17의 경우 RUL이 감소함에 따라 센서 값이 증가하는 경향을 보였으며, 이는 기계가 노화함에 따라 센서 값이 상승하는 패턴을 반영한 것이다. 또한, 센서 7, 12, 20, 21은 RUL이 감소함에 따라 센서 값이 감소하는 경향을 나타내어, 이들 센서 역시 다. 센서 9와 14는 유닛별로 다른 패턴을 보였지만, 이러한 변동성은 예측에 도움이 된다고 판단하여 학습에 포함하였다.

모델링에 앞서, 센서 데이터의 스케일 차이를 줄이고 모델의 학습 성능을 높이기 위해 Min-Max Scaler를 사용하여 모든 센서 데이터를 0과 1 사이의 값으로 정규화하였다. 모든 센서 측정치가 동일한 스케일로 변환되어 센서 간 비교가 용이해지고, 모델의 학습 과정에서 특정 센서 데이터가 과도하게 영향을 미치는 것을 방지할 수 있었다.

또한, C-MAPSS 데이터에서 RUL은 초기에는 일정하다가

시간이 지남에 따라 급격히 감소하는 패턴을 보이므로, 초반의 일정한 RUL 가정을 반영하기 위해 RUL 값을 125로 클리핑(clipping)하였다. RUL 값을 125로 제한함으로써, 초기에 일정한 RUL은 센서 신호와 더 높은 상관관계를 나타낼 수 있으며, RUL의 피크 값이 낮아져 목표 변수의 범위가 좁아짐에 따라 모델이 회귀를 수행하는 데 더 용이한 환경을 제공할 수 있었다. 이와 같은 설정을 통해, Clipping을 적용한 CNN-LSTM 모델이 RUL 예측에서 더 안정적이고 높은 성능을 발휘할 수 있는 기반을 마련하였다 [25].

4.2 모델 세팅

본 연구에서는 앞서 설명한 C-MAPSS 데이터 세트를 바탕으로 CNN-LSTM 모델을 적용하여 항공기 터보팬 엔진의 잔여 유효 수명(RUL)을 예측하였다. 이 모델은 공간적 특성과 시간적 특성을 동시에 학습하는 구조로, 두 부분으로 구성된다. 첫 번째 부분인 CNN 모델은 공간적 패턴을 학습하는 역할을 하며, 입력 데이터에서 중요한 특징을 추출하기 위해 여러 계층의 컨볼루션 레이어와 풀링 레이어를 포함한다. 이 과정에서 컨볼루션 레이어는 3x3 필터를 사용하여 데이터를 처리하고, 풀링 레이어는 2x2 필터를 사용해 데이터의 차원을 줄임으로써 핵심적인 패턴을 강조한다. 두 번째 부분인 LSTM 모델은 시간적 특성을 학습하여 시계열 데이터의 시간적 의존성을 모델링한다. CNN은 공간적 패턴을 잘 학습할 수 있으나 장기적인 데이터일수록 시간 의존성에 의해 경향성을 반영하는 능력이 떨어지는 단점이 있는데, LSTM 계층은 이러한 단점을 보완하여 데이터를 순차적으로 처리하면서 장기적인 의존성을 효과적으로 학습한다.

RUL 예측 모델의 성능 평가에는 RMSE(Root Mean Squared Error) 값을 사용하였다. 예측값과 실제값 간의 차이를 제공하여 평균한 후, 이를 제곱근으로 변환한 값으로, 모델의 예측 오류를 직접적으로 측정하는 지표이다. 시스템 구성 요소의 수가 N일 때 다음과 같이 표현한다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N E_i^2} \tag{9}$$

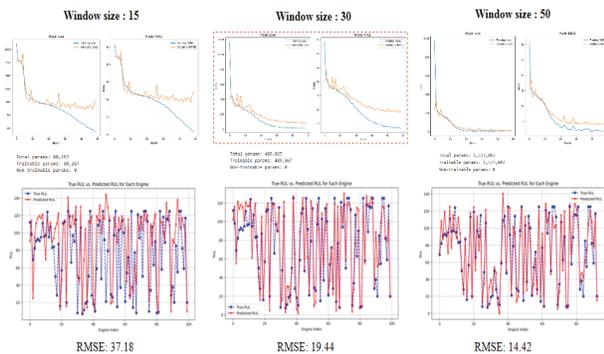


Fig. 10. Impact of Sliding Window Size on RUL Prediction Performance Using CNN-LSTM Model

RMSE 값이 낮을수록 모델의 예측 성능이 우수함을 나타내며, 이를 통해 모델이 잔여 유효 수명을 얼마나 정확하게 예측하는지를 평가하였다.

특히, 데이터와 시간 사이의 의존성이 높기 때문에 시계열 데이터를 처리할 때 적절한 Window size를 설정하는 것이 매우 중요하다. 이를 위해 15, 30, 50의 크기의 Window size를 각각 적용한 결과, RMSE 값이 37, 19, 14로 점차 감소하는 것을 확인하였다. 그러나 50 이상의 Window size에서는 학습이 제대로 이루어지지 않아 최종적으로 Window size를 50으로 설정하였다. 이와 같은 설정을 통해 CNN-LSTM 모델이 FD001 데이터 세트에서 RUL을 예측하는 데 성능이 개선되도록 하였다.

4.3 성능 비교 (기본 CNN-LSTM 모델과 전이학습 기반 CNN-LSTM 모델)

본 연구에서는 기본 2D CNN-LSTM 모델과 전이학습을 적용한 CNN-LSTM 모델 간의 성능을 비교하여, 전이학습이 잔여 유효 수명(RUL) 예측에 미치는 영향을 심도 있게 평가하였다. 먼저, 전이학습을 적용하지 않고 FD001 데이터 세트만을 사용하여 학습한 CNN-LSTM 모델의 경우, RMSE 값이 14.42로 나타났다.

이는 해당 데이터 세트에서 모델이 어느 정도의 예측 정확도를 달성했음을 의미하지만, 추가적인 성능 개선의 여지가 있음을 시사한다. 반면, FD003 데이터 세트로 사전 학습된 (pre-trained) 모델을 전이학습 기법을 통해 FD001 데이터 세트에 적용한 결과, RMSE 값이 13.91로 감소하였다. 이 결과는 전이학습이 모델의 초기 가중치를 더욱 유리한 상태로 설정함으로써, 모델이 적은 데이터와 더 짧은 학습 시간 내에 더 높은 예측 성능을 달성할 수 있음을 보여준다. 즉, 전이학습을 통해 FD003에서 학습된 패턴과 정보를 FD001 데이터에 효과적으로 전이함으로써 RUL 예측의 정확도가 향상되었음을 입증하였다.

더 나아가, 본 연구에서 제안한 전이학습 기반 CNN-LSTM 모델의 성능을 다른 알고리즘 모델들과 비교하였다. [26-34]

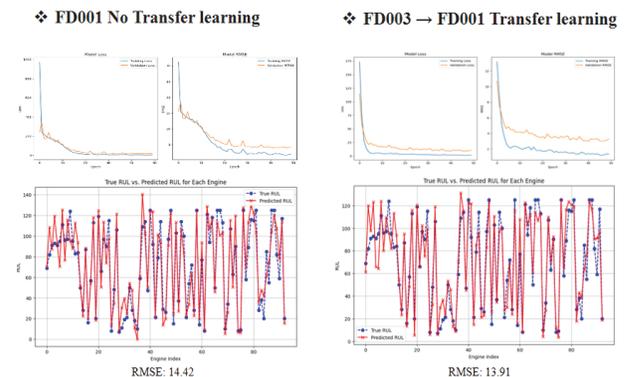


Fig. 11. Comparison of RUL Prediction Performance: FD001 Without Transfer Learning vs. FD003 With Transfer Learning

Table 4. Comparison of RUL Prediction Performance Across Models with and without Transfer Learning between FD001 and FD003 Datasets

Model	FD001	Transfer Model	FD003→FD001
MLP	37.56	TCA-NN	98.70
SVM	29.82	TCA-DNN	90.50
RVR	23.80	CORAL-NN	26.50
SVR	20.96	CORAL-DNN	26.50
CNN	18.45	FC-DANN	28.70
Random Forest	17.91	LSTM-DANN	31.70
CNN-GRU	16.29	CADA	19.54
LSTM	16.14	CORAL	40.33
Gradient boosting	15.67	ADDA	40.41
		Proposed Model	13.91

참고 문헌에서 보고된 바에 따르면, 전이학습이 적용되지 않은 다른 연구의 모델들은 RMSE 값이 37.56부터 최소 15.67까지의 범위를 보였다. 이는 전이학습 없이 RUL 예측 모델이 상당한 예측 오류를 가질 수 있음을 나타내며, 모델의 일반화 성능이 제한될 수 있음을 의미한다.

한편, 전이학습을 적용한 다른 연구의 모델들은 Table 4와 같이 RMSE 값이 19.54로 가장 낮은 수치를 기록하였으나, 여전히 개선의 여지가 존재했다. 이러한 비교를 통해, 본 연구에서 제안한 전이학습 기반 CNN-LSTM 모델의 RMSE 값이 13.91로 가장 낮은 수치를 기록하였다.

### 5. 결론

본 연구에서는 항공기 터보팬 엔진의 잔여 유효 수명(RUL) 예측에 있어서, 충분한 수의 샘플을 확보하기 어려운 문제를 해결하기 위해 전이학습 기반의 딥러닝 모델을 제안하였다. 제안된 모델은 CNN 알고리즘과 LSTM 알고리즘을 결합하여, 시계열 데이터의 공간적 및 시간적 특성을 동시에 학습할 수 있도록 설계하였다. 실험 결과, 전이학습을 적용하지 않은 기본 CNN-LSTM 모델에 비해 전이학습을 적용한 모델이 RMSE 지표 측면에서 더 낮은 값을 기록하였다. 이는 전이학습이 RUL 예측 성능을 향상시키는 데 있어 효과적임을 입증한다. 특히, FD003 데이터 세트에서 학습된 모델을 FD001 데이터 세트에 전이함으로써, 타겟 도메인에서의 예측 정확도가 개선된 것을 확인할 수 있었다. 또한, 본 연구에서 제안한 전이학습 기반 모델은 다른 참고문헌에서 보고된 유사한 모델들과 비교하였을 때, 가장 낮은 RMSE를 기록하였다. 이러한 결과는 전이학습 기법이 서로 다른 도메인 간의 패턴을 효과적으로 학습하고, 이를 활용하여 예측 성능을 극대화할 수 있음을 시사한다. 본 연구의 결과는, 특히 데이터 수집이 제한된 상황

에서도 전이학습 기반 접근법이 RUL 예측의 신뢰성을 높이는 데 중요한 도구로 활용될 수 있음을 확인시켜준다. 이로써, 전이학습이 RUL 예측 모델링에 있어 필수적인 전략임을 제시하며, 향후 연구와 실제 적용에 있어 중요한 토대를 제공한다.

### References

- [1] O. Asif, S. A. Haider, S. R. Naqvi, J. F. W. Zaki, K. S. Kwak, and S. M. R. Islam, "A Deep Learning Model for Remaining Useful Life Prediction of Aircraft Turbofan Engine on C-MAPSS Dataset," *IEEE Access*, Vol.10, pp.95425-59440, 2022. <https://doi.org/10.1109/ACCESS.2022.3203406>
- [2] H. Gharib and G. Kovács, "A Review of Prognostic and Health Management (PHM) Methods and Limitations for Marine Diesel Engines: New Research Directions," *Machines*, Vol.11, No.7, pp.695, 2023
- [3] J. W. Baek, "Prognostics and Health Management using Artificial Intelligence," *Journal of Reliability Society of Korea*, Vol.23, No.3, pp.283-296, 2023
- [4] X. Li, Q. Ding, and J.-Q. Sun, "Remaining Useful Life Estimation in Prognostics Using Deep Convolution Neural Networks," *Reliability Engineering & System Safety*, Vol.172, pp.1-11, 2018.
- [5] C. Shorten and T. M. Khoshgoftaar, "A Survey on Image Data Augmentation for Deep Learning," *Journal of Big Data*, Vol.6, No.1, p.60, 2019.
- [6] E. Eldele, M. Ragab, Z. Chen, M. Wu, C. K. Kwok, and X. Li, "Label-Efficient Time Series Representation Learning: A Review," *IEEE Transactions on Artificial Intelligence*, Vol.5, No.1, pp.1-16, 2024.
- [7] A. Zhang et al., "Transfer Learning with Deep Recurrent Neural Networks for Remaining Useful Life Estimation," *Applied Sciences*, Vol.8, No.12, pp.2416, 2018.
- [8] M. Gribbestad, M. U. Hassan, and I. A. Hameed, "Transfer Learning for Prognostics and Health Management (PHM) of Marine Air Compressors," *Journal of Marine Science and Engineering*, Vol.9, No.1, p.47, 2021.
- [9] Y. Duan, J. Xiao, H. Li, and J. Zhang, "Cross-Domain Remaining Useful Life Prediction Based on Adversarial Training," *Machines*, Vol.10, No.6, pp.438, 2022.
- [10] Y. Ding, P. Ding, X. Zhao, Y. Cao, and M. Jia, "Transfer Learning for Remaining Useful Life Prediction Across Operating Conditions Based on Multisource Domain Adaptation," *IEEE/ASME Transactions on Mechatronics*, Vol.27, No.5, pp.4143-4152, 2022.
- [11] Y. Hu, Y. Bai, E. Fu, and P. Liu, "A Novel Remaining Useful Life Probability Prediction Approach for Aero-Engine with

- Improved Bayesian Uncertainty Estimation Based on Degradation Data,” *Applied Sciences*, Vol.13, No.16, pp.9194, 2023.
- [12] T. Tang, Z. Liu, C. Qiu, B. Wu, M. Chen, and Y. Yu, “Transfer Learning for Bearing Fault Diagnosis Based on Graph Neural Network with Dilated KNN and Adversarial Discriminative Domain Adaptation,” *Measurement Science and Technology*, Vol.35, No.6, p.065106, 2024.
- [13] N. Hatami, Y. Gavet, and J. Debayle, “Classification of Time-Series Images Using Deep Convolutional Neural Networks,” *arXiv preprint arXiv:1710.00886*, 2017.
- [14] Y. Hsueh, V. R. Ittangihala, W.-B. Wu, H.-C. Chang, and C.-C. Kuo, “Condition Monitor System for Rotation Machine by CNN with Recurrence Plot,” *Energies*, Vol.12, No.17, pp.3221, 2019.
- [15] Y. J. Seo, “An Input Transformation with MFCCs and CNN Learning Based Robust Bearing Fault Diagnosis Method for Various Working Conditions,” *KIPS Transactions on Software and Data Engineering*, Vol.11, No.4, pp.179-188, 2022.
- [16] J. H. Baek, D. Y. Yoo, and J. W. Lee, “Gear Fault Diagnosis Based on Residual Patterns of Current and Vibration Data by Collaborative Robot’s Motions Using LSTM,” *The Transactions of the Korea Information Processing Society*, Vol.12, No.10, pp.445-454, 2023.
- [17] H. Lu et al., “A Multi-Source Transfer Learning Model Based on LSTM and Domain Adaptation for Building Energy Prediction,” *International Journal of Electrical Power & Energy Systems*, Vol.149, pp.109024, 2023.
- [18] Z. Liu, C. Tan, Y. Liu, H. Li, B. Cui, and X. Zhang, “A Study of a Domain-Adaptive LSTM-DNN-Based Method for Remaining Useful Life Prediction of Planetary Gearbox,” *Processes*, Vol.11, No.7, p.2002, 2023.
- [19] S. Seo, J. Hwang, and M. Chung, “Supervised Domain Adaptation for Remaining Useful Life Prediction Based on AdaBoost With Long Short-Term Memory,” *IEEE Access*, Vol.12, pp.96757-96768, 2024.
- [20] P. Khumprom, A. Davila-Frias, D. Grewell, and D. Buakum, “A Hybrid Evolutionary CNN-LSTM Model for Prognostics of C-MAPSS Aircraft Dataset,” *2023 Annual Reliability and Maintainability Symposium (RAMS)*, pp.1-8, 2023.
- [21] N. Borst and W. J. C. Verhagen, “Introducing CNN-LSTM Network Adaptations to Improve Remaining Useful Life Prediction of Complex Systems,” *The Aeronautical Journal*, Vol.127, No.1318, pp.2143-2153, 2023.
- [22] H. Mo, F. Lucca, J. Malacarne, and G. Iacca, “Multi-Head CNN-LSTM with Prediction Error Analysis for Remaining Useful Life Prediction,” in *Proceedings of the 27th Conference of Open Innovations Association (FRUCT)*, pp.164-171, 2020.
- [23] S. Deng and J. Zhou, “Prediction of Remaining Useful Life of Aero-Engines Based on CNN-LSTM-Attention,” *International Journal of Computational Intelligence Systems*, Vol.17, No.1, pp.232, 2024.
- [24] D. K. Frederick, J. A. DeCastro, and J. S. Litt, “User’s Guide for the Commercial Modular Aero-Propulsion System Simulation (C-MAPSS),” NASA Technical Report, NASA Glenn Research Center, Cleveland, OH, 2007.
- [25] L. Liu, S. Wang, D. Liu, Y. Zhang, and Y. Peng, “Entropy-based sensor selection for condition monitoring and prognostics of aircraft engine,” *Microelectronics Reliability*, Vol.55, No.9-10, pp.2092-2096, 2015.
- [26] T. Berghout and M. Benbouzid, “A Systematic Guide for Predicting Remaining Useful Life with Machine Learning,” *Electronics*, Vol.11, No.7, pp.1125, 2022.
- [27] M. T. Furqon, M. Pratama, L. Liu, Habibullah, and K. Dogancay, “Mixup Domain Adaptations for Dynamic Remaining Useful Life Predictions,” *Knowledge-Based Systems*, Vol.295, p.111783, 2024.
- [28] C. Zhao, X. Huang, Y. Li, and M. Y. Iqbal, “A Double-Channel Hybrid Deep Neural Network Based on CNN and BiLSTM for Remaining Useful Life Prediction,” *Sensors*, Vol.20, No.24, p.7109, 2020.
- [29] F. Li et al., “A Light Gradient Boosting Machine for Remaining Useful Life Estimation of Aircraft Engines,” in *Proceedings of the 21st International Conference on Intelligent Transportation Systems (ITSC)*, pp.3562-3567, 2018.
- [30] A. F. Azyus, S. Kusuma, and M. Naved, “Prediction of Remaining Useful Life Using the CNN-GRU Network: A Study on Maintenance Management,” *Software Impacts*, Vol.17, pp.100535, 2023.
- [31] G. S. Babu, P. Zhao, and X. Li, “Deep Convolutional Neural Network-Based Regression Approach for Estimation of Remaining Useful Life,” in *Proceedings of the 21st International Conference on Database Systems for Advanced Applications (DASFAA 2016)*, Vol.9642, Lecture Notes in Computer Science, pp.214-228, 2016.
- [32] X. Li, Y. Xu, N. Li, B. Yang, and Y. Lei, “Remaining Useful Life Prediction with Partial Sensor Malfunctions Using Deep Adversarial Networks,” *IEEE/CAA Journal of Automatica Sinica*, Vol.10, No.1, pp.121-134, 2023.
- [33] C. Louen, S. X. Ding, and C. Kandler, “A New Framework for Remaining Useful Life Estimation Using Support Vector Machine Classifier,” in *Proceedings of IEEE Conference*

on Control and Fault-Tolerant Systems, pp.228-233, 2013.

[34] P. R. de O. da Costa, A. Akçay, Y. Zhang, and U. Kaymak, "Remaining Useful Lifetime Prediction via Deep Domain Adaptation," *Reliability Engineering & System Safety*, Vol.195, p.106682, 2020.

[35] M. Ragab et al., "Contrastive Adversarial Domain Adaptation for Machine Remaining Useful Life Prediction," *IEEE Transactions on Industrial Informatics*, Vol.17, No.8, pp.5239-5249, 2021.



**권 기 혁**

<https://orcid.org/0009-0003-3212-6927>  
 e-mail : khkwon80@lignex1.com  
 2007년 인하대학교 컴퓨터공학과(학사)  
 2009년 인하대학교 정보통신공학과(석사)  
 2009년~현 재 LIG 넥스원 수석연구원  
 관심분야 : Deep Learning & Engine  
 Control Unit & Mini Missile  
 & Inertial Navigation System  
 & Weapon Data Link



**김 정 민**

<https://orcid.org/0009-0001-2079-1917>  
 e-mail : kjm82801004@gmail.com  
 2021년 인하대학교 신소재공학과(학사)  
 2024년~현 재 인하대학교  
 첨단소재공정공학과(석사)  
 관심분야 : Deep Learning & Transfer Learning



**안 서 연**

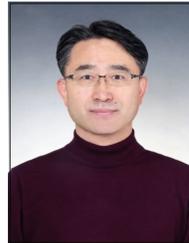
<https://orcid.org/0009-0007-9243-3530>  
 e-mail : seoyeon.an@lignex1.com  
 2023년 금오공과대학교 전자공학부(학사)  
 2023년~현 재 LIG 넥스원 연구원  
 관심분야 : Deep Learning & Engine  
 Control Unit & Guidance  
 Control Unit



**강 현 우**

<https://orcid.org/0009-0005-4275-4518>  
 e-mail : wk7008@naver.com  
 2020년 한서대학교 신소재공학과(학사)  
 2022년 인하대학교  
 첨단소재공정공학과(석사)  
 2022년~현 재 인하대학교 대학원  
 첨단소재공정공학과(박사)

관심분야 : Deep Learning & Remaining Useful Life Prediction



**김 현 기**

<https://orcid.org/0009-0009-9267-7556>  
 e-mail : hunkeekim@inha.ac.kr  
 1991년 인하대학교 전기공학과(학사)  
 1993년 인하대학교 전기공학과(석사)  
 2000년 뉴욕주립대학교 전기공학과(박사)  
 2000년~2016년 삼성전자 통신 연구소  
 2016년~2021년 인하대학교 정보전자공동연구소 연구교수  
 2021년~현 재 인하대학교 첨단소재공정공학과 교수  
 관심분야 : Deep Learning & Prognostics and Health Management



**조 영 기**

<https://orcid.org/0009-0009-3608-2531>  
 e-mail : sykcho@naver.com  
 2000년 인하대학교 자동화공학과(학사)  
 2002년 인하대학교 자동화공학과(석사)  
 2002년~현 재 LIG넥스원 연구위원  
 관심분야 : Deep Learning & Embedded System & Defense Industry