

터보팬의 잔여 유효 수명 예측을 위한 다수 소수 특징 추출 병렬연결 합성곱 신경망

ISSN 2671-4744(Print)
ISSN 2671-9673(Online)

Parallel-connected convolutional neural network with minority and majority feature extraction for the estimation of the remaining useful life of turbofans

김해영, Haeyoung Kim

금오공과대학교, 전자공학과, 석사
School of Electronic Engineering, Kumoh
National Institute of Technology

김도윤, Doyun Kim

금오공과대학교, 전자공학과, 석사
School of Electronic Engineering, Kumoh
National Institute of Technology

반재필, Jaepil Ban

금오공과대학교, 전자공학과, 교수
Professor, School of Electronic
Engineering, Kumoh National Institute of
Technology

구교권, Gyogwon Koo

대구경북과학기술원, 지능형로봇연구부,
선임연구원
Senior Researcher, Division of Intelligent
Robot, Daegu Gyeongbuk Institute of
Science and Technology

정재진[†], Jae Jin Jeong

금오공과대학교, 전자공학과, 교수
Professor, School of Electronic
Engineering, Kumoh National Institute of
Technology

Abstract

The prediction of remaining useful life (RUL) plays a crucial role in assessing the condition of a machine before it completely fails, ensuring performance by the execution of preventive maintenance beforehand. Recently, various deep learning models have been frequently used for RUL estimation, and they have shown good performance. However, these deep learning models face several challenges such as inefficiency owing to the selection of complex preprocessing methods, overfitting owing to model complexity, and other unresolved issues. Therefore, this study proposes a new deep-learning-based approach to address these issues by constructing a novel structure that includes a simple preprocessing step, minority feature extraction module, and majority feature extraction module. First, it explains the relatively simple preprocessing and assumptions regarding the target data of an undefined training set. Second, we describe the design of a convolution-based model using minority and majority feature extraction modules created through 2D convolutional layers. This model can learn the relationships between minority and majority sensors over time. By connecting the modules in parallel, it aggregates various types of information using multiple features from a single dataset. Finally, we present various experiments on the proposed algorithm and compare it with the latest existing methods using the NASA C-MAPSS dataset.

keywords : time series forecasting, RUL, deep learning, C-MAPSS, CNN

[†] Corresponding Author : Jae Jin Jeong

Tel : +82-54-478-7503, email : jeong@kumoh.ac.kr

Kumoh National Institute of Technology, 61, Daehak-ro, Gumi-si, Gyeongsangbuk-do, Republic of Korea

Received September 30th. 2024 Revised November 3rd. 2024 Accepted December 24th. 2024 Published December 30th. 2024

www.kci.go.kr

1. 서론

모든 기계는 꾸준한 정비를 통해 결함을 예방하고 수리해야 한다[1]. 특히, 군용기나 군용차, 군 잠수함과 같은 국방 이동 수단의 엔진은 중요한 순간에 한번의 결함 발생으로 엄청난 인명사고, 재산 손실, 심하게는 국가의 막대한 피해가 있을 수 있기 때문에 꾸준한 정비는 필수이다[2].

정비의 전략으로는 수리 정비(Corrective Maintenance, CM), 예방 정비(Preventive Maintenance, PM), 상태 기반 정비(Condition-based Maintenance, CBM/CBM⁺)가 있다. 가장 오래 사용된 정비 전략인 수리 정비[3]는 엔진에 결함이 발생한 후 기계를 정비하는 전략이다. 하지만, 이 정비 전략은 기계가 완전히 고장나기 전까지는 결함을 발견하기 힘들어 장비 전체에 치명적인 영향을 끼친다. 예방 정비는 정상 엔진을 일정한 주기에 정기적으로 점검하는 전략으로 기계의 작동을 정지하고 분해, 수리를 통해 정비해야 한다. 이 정비 전략은 정기적인 정비를 자주 하게 되면 과도한 정비로 인해 예산이 과하게 소요되고, 과잉 정비로 인한 결함, 돌발고장의 원인이 된다[4]. 상태 기반 정비[5]는 센서값을 이용해 기계의 성능 상태를 실시간 모니터링하여 미리 정해진 임계값을 기반으로 기계의 결함을 판단하는 정비 전략이다. 모니터링된 데이터를 사용하여 결함을 발견하고 정비시기를 결정하기 때문에 이전 전략들과 비교해 노동력 감소, 비용 절감의 장점이 있고, 실시간 데이터를 활용하여 잔여 수명 및 결함 시점을 예측하기 때문에 비교적 장비의 안정적인 운영이 가능하다[6].

CBM⁺은 실시간 모니터링을 기반으로 기계의 결함을 정비하는 상태 기반 정비 방식에 RUL(Remaining Useful Life) 예측 기술을 더한 정비 전략이다[7]. 여기서 RUL은 기계가 결함이 발생하기 전까지 남은 수명을 의미한다. CBM⁺과 같은 상태 기반 정비의 핵심은 PHM(Prognostics and Health Management) 기술로 RUL을 정확하게 예

측하는 것이 가장 중요한 목표이다[8]. 이 기술을 사용해 최근 인공지능, 기계학습 등 4차 산업혁명 기술을 병합한 RUL 예측 기술에 대한 관심이 높기 때문에[9-11] RUL 예측은 앞으로도 중요한 연구 과제가 될 수 있다.

최근 터보팬 잔여 수명 데이터인 C-MAPSS 데이터 세트를 사용해 RUL을 추정하는 딥러닝 연구가 활발하게 진행되고 있다. 이전 연구 중 RNN(Recurrent Neural Network) 모델로 RUL을 예측한 알고리즘이 많이 제안되었다[11-14]. Li *et al.*은 1차원 합성곱 층 5개를 이용해 터보팬 엔진의 RUL을 예측하는 알고리즘을 제안했다[11]. Lin *et al.*은 윈도우 슬라이딩 기법을 사용해 전처리 후 2개의 LSTM(Long Short-Term Memory)과 1개의 FC(Fully Connected) 층을 이용해 RUL을 예측했고[12], Asif *et al.*도 4개의 LSTM과 3개의 FC 층을 이용해 학습하지만, 전처리 기법으로 특징 선택과 Median Filter를 사용해서 RUL을 예측했다[13]. Wang *et al.*은 Bi-LSTM(Bidirectional Long Short-Term Memory)만을 사용해서 학습을 진행했다[14]. RNN 기반의 모델은 데이터의 시간적 특성을 잘 이해할 수 있어 시계열 데이터 학습에 적합한 모델이지만 RNN 기반 모델의 문제점은 이전 시간 단계들이 모두 계산되어야 현재 시간 단계를 계산할 수 있어 학습이 느린다는 문제점이 있다[15]. 최근 CNN(Convolution Neural Network)과 RNN을 결합한 알고리즘이 많이 제안되었다[16-20]. Shcherbakov and Sai은 2개의 1차원 CNN과 2개의 LSTM, 1개의 FC 층을 이용해 RUL을 추정하는 알고리즘을 제안했고[16], Hong *et al.*은 3개의 1차원 CNN과 2개의 Bi-LSTM과 3개의 LSTM을 이용해 RUL을 예측하는 알고리즘을 제안했으며, 특징 선택과 피어슨 상관계수를 이용한 전처리 기법을 사용해 학습의 성능을 높였다[17]. Kong *et al.*은 2개의 2차원 CNN과 2개의 LSTM을 사용한 모델을 이용하였고[18], Wang *et al.*은 2차원 CNN과 Bi-LSTM을 이용해 간단한 모델에 비해 좋은 결과를 보여준다[19]. Back *et al.*은 2개의 2차원 CNN과 2개의 LSTM, 2개의 Bi-LSTM, 2개의

FC를 사용해 학습을 진행했다[20]. 좋은 성능을 보여주지만, 여전히 RNN 계열 단점을 가지고 있다. 또한, Asif *et al.*과 Hong *et al.*의 경우 특징 선택과 여러 전처리를 사용해 학습을 진행하면 데이터의 유의미한 관계를 계산해서 효과적인 학습으로 성능이 향상될 수도 있지만 전처리에서 큰 비용을 소모해야 하고 다른 새로운 데이터에 적용하기 어렵다는 문제점이 있다.

본 논문에서는 터보팬의 잔여 유효 수명 추정을 위한 다수 소수 특징 추출 병렬연결 합성곱 신경망(Parallel-Connected Convolutional Neural Network with Minority and Majority feature extraction, PCNNwMM)을 제안한다. 논문에서 제안하는 PCNNwMM은 특징 선택을 위한 복잡한 전처리 과정 없이 원본의 데이터로 학습을 진행하기에 큰 비용 소모 없이 데이터를 학습할 수 있고 다른 새로운 데이터에 알고리즘을 쉽게 적용해 볼 수 있다는 장점이 존재한다. 그리고 성능 향상을 위해 각 센서 간의 복합적 특징을 추출하여 모델이 데이터에 대해 표현 학습을 잘하도록 구상하였다. 그래서 소수 센서 데이터 간의 특징을 추출하는 Minority FEM(Feature Extraction Module)과 다수의 센서 데이터 간의 특징을 추출하는 Majority FEM을 병렬로 연결하여 PCNNwMM을 구성했다. 또, RNN 계열을 사용하지 않아 학습 시간을 대폭 줄였다. 논문의 구성은 다음과 같다. 2절에서는 제안하는 RUL 추정 알고리즘에 대해서 설명하고, 3절에서는 실험 결과 및 분석을 보여주고, 마지막으로 4절은 결론이다. 논문에서 사용한 변수들의 정의는 Table 1에 나타났다.

2. 제안하는 RUL 추정 알고리즘

2.1. 제안 모델

2.1.1. 전처리 과정

데이터 전처리 전략으로 윈도우 슬라이딩 기법을 사용했다. 윈도우 슬라이딩 기법에 대해 Figure 1에

Table 1. Notation table

Variable	Definition
m	Number of engine data
n	Cycle number of engine data
$X_{m,n}$	n th input of m th engine data
N_s	Number of Sensor
N_m	Cycle of m th engine
l_w	Window length
s	Stride
H	Height of kernel
W	Width of kernel
C	Number of kernel
$N_{Minority}$	Kernel size of minority feature extraction module
$N_{Majority}$	Kernel size of majority feature extraction module




Figure 1. Window sliding technique

방법을 나타냈다. Window length는 1개의 윈도우에 들어갈 시점 길이, Stride는 이전 윈도우와 겹치지 않을 시점 길이를 의미한다. Window sliding을 수식으로 표현하면 식 (1)과 같다.

$$X_{m,n} = X_m[n \times s : n \times s + l_w, 1 : N_s, 1], \quad n = 1, \dots, \left\lfloor \frac{N_m - l_w}{s} \right\rfloor \quad (1)$$

식 (1)에서 $X_{m,n}$ 은 m 번째 엔진 데이터에 대한 n 번째 입력, l_w 는 Window length, s 는 Stride, N_s 은 센서 데이터의 개수, N_m 은 m 번째 엔진 데이

터의 측정된 총 사이클의 개수를 의미한다. Figure 1에서 l_w 값에 따라 데이터가 나뉘는 것을 볼 수 있고, s 값만큼 이전 Window가 갖고 있던 데이터를 공유하지 않는 것을 볼 수 있다. 본 논문에서 제안하는 알고리즘은 l_w 는 30, s 를 1로 지정해 전처리를 진행했다. l_w 가 30이기 때문에 데이터의 첫 시점에서는 Window sliding을 할 수 없게 된다. l_w 에 맞게 데이터를 맞춰주기 위해 첫 시점의 센서값들을 29개 복사해 시점 앞에 넣어주어 문제 상황을 방지했다.

2.1.2. PCNNwMM의 구조

본 논문에서 제안하는 PCNNwMM의 전반적인 구조는 Figure 2와 같다. 여기서 Conv는 각 2차원 합성곱 층을 의미하고 $(H \times W, C)$ 로 구성을 나타냈는데 H 는 Kernel의 높이, W 는 Kernel의 넓이, C 는 Kernel의 개수를 의미한다. 각 합성곱 층은 모두 BN(Batch Normalization layer), ReLU, Dropout 층을 차례로 연결해 모델을 구성했다. $\oplus$ 은 채널 방향의 Concatenation을 의미한다. PCNNwMM은 시간별로 추출된 센서 특징으로부터 시간 흐름에 따른 RUL을 추정하는 기존 방식과는 달리 본 모델은 주어진 총시간 데이터를 활용하여 추출된 센서별 특징으로부터 RUL을 추정한다. RUL에 대한 다양한 표현을 학습하기 위해 제안한 모델

은 소수 특징 추출 모듈과 다수 특징 추출 모듈, 회귀로 이루어져 있다. 소수 특징 추출 모듈(Minority FEM)에서 합성곱 층의 kernel 크기는 $l_w \times N_{Minority}$ 로 한 Window에 있는 모든 시점과 이웃한 $N_{Minority}$ 개의 센서들의 관계에 집중해서 Feature를 생성했고, 두 Majority FEM에서 합성곱 층의 Kernel 크기는 $l_w \times N_{Majority}$ 로 한 Window에 있는 모든 시점과 이웃한 $N_{Majority}$ 개의 센서들의 관계에 집중해서 Feature를 생성했다. 이후 각 Feature map을 입력의 넓이, 높이와 같은 값으로 Kernel 크기를 설정해서 입력으로 들어오는 Feature map을 1×1 로 압축시켜 중요한 Feature만 추출하는 마지막 합성곱 층에 입력된다. 이후 RUL 회귀 모듈에 입력되어 모든 연산이 끝나면 RUL의 추정값을 도출한다.

3. 실험 결과 및 분석

3.1. 데이터 세트

3.1.1. C-MAPSS

이 논문에서는 NASA에서 제공한 터보팬 엔진에 대한 정보를 담은 C-MAPSS[21] 데이터 세트를 사용하였다. C-MAPSS 데이터 세트는 네 개의 하위




Figure 2. Overall Structure of PCNNwMM

데이터 세트로 구성되고 이 논문에서는 FD001을 사용하여 터보팬 엔진의 RUL 추정 학습을 진행했다. 터보팬 엔진은 팬(Fan), 저압 압축기(Low pressure compressor), 고압 압축기(High pressure compressor), 저압 터빈(Low pressure turbine), 고압 터빈(High pressure turbine), 연소기(Combustor), 노즐(Nozzle) 등으로 구성되어 있고, Figure 3에 나타냈다. 각 구성 요소의 온도, 압력, 속도, 공기 비율 등이 센서로 측정되고 Table 2에 센서의 정보를 나타냈다. 각 하위 데이터 세트는 엔진의 수, 운영 조건, 고장 유형에 따라 다르게 구성된다. 데이터 세트는 Training 데이터, Test 데이터, RUL 데이터로 나누어 제공된다. C-MAPSS 데이터 세트는 엔진의 상태를 측정하는 21개의 센서로 구성되어 있다. Test 데이터는 데이터별 RUL 정보가 있지만 Training 데이터는 한 엔진이 결함이 발생할 때까지 즉, RUL이 0이 될 때까지의 센서값이 측정되어 있으며, Training 데이터의 RUL은 [23-24]에서 제안한 조각별 선형 열화 모델(Piece-Wise Linear Degradation, PWLD)을 사용하여 RUL을 임의로 지정했다. Heimes의 실험 결과를 통해 RUL이 125일 때 가장 좋은 결과를 보여 줌을 따라[23] 논문에서도 최대 RUL을 125로 두고 학습을 진행하였다. Figure 4는 FD001의 엔진 1번의 Training 데이터의 Target 값을 나타냈다. 논문에서 Training 데이터는 16,504개, Valid 데이터는 4,127개로 구성해서 학습을 진행했다.




Figure 3. Tubofan structure [22]

Table 2. Information on the C-MAPSS sensors

#	Parameter	Description with units
1	T2	Total temperature in fan inlet (oR)
2	T24	Total temperature at LPC outlet (oR)
3	T30	Total temperature at HPC outlet (oR)
4	T50	Total temperature at LPT outlet (oR)
5	P2	Pressure at fan inlet (psia)
6	P15	Total pressure in bypass-duct (psia)
7	P30	Total pressure at HPC outlet (psia)
8	Nf	Physical fan speed (rpm)
9	Nc	Physical core speed (rpm)
10	Epr	Engine pressure ratio
11	Ps30	Static pressure at HPC outlet (psia)
12	Phi	Ratio of fuel flow to ps30 (psi)
13	NRf	Corrected fan speed (rpm)
14	Nrc	Corrected core speed (rpm)
15	BPR	Bypass ratio
16	farB	Burner fuel air
17	htBleed	Bleed enthalpy
18	NF-dmd	Demanded fan speed (rpm)
19	PCNR-dmd	Demanded corrected fan speed (rpm)
20	W31	HPT coolant bleed (lbm/s)
21	w32	LPT coolant bleed (lbm/s)




Figure 4. Labeled RUL data for engine No. 1

3.2. 실험 결과

3.2.1. 실험 설정

실험의 개발 환경은 Anaconda의 Jupyter notebook을 사용했고, 고정 하이퍼 파라미터는 Table 3과 같다. Loss function으로 MSE(Mean Square Error)를 사용했고, MSE의 수식은 식 (2)와 같다.

$$MSE = \frac{1}{J} \sum_{j=1}^J (y_j - y_{j,true})^2 \quad (2)$$

J 는 데이터의 총 엔진 수를 의미하고, 논문에서 $J=100$ 이다. y_j 는 j 번째 엔진의 RUL 예측값, $y_{j,true}$ 는 j 번째 엔진의 RUL 정답 값을 의미한다. 논문에서 평가지표로 RMSE(Root Mean Square Error)를 사용했고, RMSE는 수식은 식 (3)과 같다.

$$RMSE = \sqrt{\frac{1}{J} \sum_{j=1}^J (y_j - y_{j,true})^2} \quad (3)$$

Table 3. Fixed hyper-parameters for the experiment

Device	Environment
GPU	NVIDIA GeForce RTX 3090
Package	Version
Tensorflow-gpu	2.9.0
Cuda	11.2
cuDNN	8.1
Parameter	Value
Optimizer	Adam
epoch	200
Batch size	500
Loss Function	MSE
Training data rate	0.8
Validation data rate	0.2
regularization	L2 regularization

MSE는 제곱 값이기 때문에 이상치에 민감하게 반응하기 때문에 MSE와 비교했을 때 이상치에 둔감하게 반응하는 RMSE를 사용하여 C-MAPSS를 사용한 최근 알고리즘의 결과들과 비교할 것이다.

3.2.2. PCNNwMM 파라미터 최적화 실험

우리는 PCNNwMM의 최적 파라미터를 찾기 위해 소수, 다수 특징 추출 모듈의 Kernel 크기와 Dropout rate, Learning rate에 대한 실험을 수행하였다.

먼저, 제안한 PCNNwMM의 구조로 각 2차원 합성곱 층의 Kernel 크기를 여러 값으로 설정하여 진행한 실험 결과를 Table 4에 나타냈다. 여기서 Learning rate와 Dropout rate는 각각 0.01과 0.2로 설정하였으며, 최고 성능에는 볼드체로 표시하였다. 대부분 평균 RMSE가 10.4보다 큰 값을 가지는데 $N_{Minority}$ 이 3, $N_{Majority}$ 이 5일 때 평균 RMSE가 10.39로 가장 좋은 결과를 보여주었다.

다음으로, Learning rate를 변경하여 파라미터 최적화를 진행했고 결과는 Table 5에 나타냈다. 여기서 PCNNwMM kernel 크기는 Table 4의 최고

Table 4. Experiment on the conv filter size

Architecture		RMSE	
$N_{Minority}$	$N_{Majority}$	Average(10)	Standard deviation
1	5	10.47	0.34
	7	10.5	0.31
	8	10.85	0.44
	13	10.6	0.32
3	5	10.39	0.43
	7	10.66	0.52
	9	10.43	0.35
	13	10.53	0.46
5	7	10.56	0.44
	9	10.82	0.54
	13	10.75	0.35

성능의 3과 5로 설정하였다. 비교 결과로 Learning rate는 0.001일 때 평균 RMSE가 10.28로 비교군 중 가장 좋은 결과를 보여준다.

마지막으로, Dropout rate를 변경하여 파라미터 최적화 실험을 진행했고, Table 6에 나타났다. Table 5에서 최고 결과를 보였던 Learning rate를 0.001로 설정한 모델에서 Dropout rate만 변경해 학습을 진행했다. 결과 Dropout rate가 0.1일 때 평균 RMSE가 9.94로 가장 좋은 성능을 보여주었다.

Table 5. Experiment on method optimization

Hyper parameter		RMSE	
		Average(10)	Standard deviation
Learning rate	0.01	10.39	0.43
	0.001	10.28	0.20
	0.0001	11.37	2.60

Table 6. Experiment on dropout rate

Hyper parameter		RMSE	
		Average(10)	Standard deviation
Dropout rate	0.5	11.35	0.54
	0.4	10.96	0.39
	0.3	10.35	0.32
	0.2	10.28	0.20
	0.1	9.94	0.17
	0.0	10.49	0.33

결과로 Learning rate는 0.001, Dropout rate는 0.1일 때 제안한 Method는 가장 좋은 성능을 보였다.

제안한 PCNNwMM을 파라미터 최적화 후 C-MAPSS 데이터 세트에서 Valid 데이터 중 랜덤한 엔진 데이터의 RUL을 예측한 것과 모든 Test 데이터로 RUL을 예측한 결과를 Figure 5와 Figure 6에 나타났다. Figure 5는 3.1.2에서 임의로 정한 RUL값과 Validation set의 5번, 11번, 25번, 45번 엔진 데이터를 사용해 예측한 결과를 대조한 것이다. exp_num은 터보팬 엔진의 식별 번호, RUL은 엔진의 남은 수명을 의미한다. Figure 6은 Test 데이터를 이용해 RUL을 예측한 결과와 C-MAPSS 데이터 세트에서 제공한 실제 RUL값을 대조한 그래프이다. 조금씩의 오차가 있지만 대체로 좋은 성능을 보여준다.




Figure 5. Valid RUL predict result




Figure 6. Overall RUL predict of FD001

3.2.3. PCNNwMM ablation 실험

제안한 PCNNwMM의 구조가 효과적임을 증명하기 위해 2차원 합성곱 층을 잘라내는 실험을 진행했다. 실험 결과는 Table 7과 같다. 실험은 PCNNwMM 구조에서 Minority FEM, Majority FEM 구성 중 Minority FEM만 사용해서 학습을 진행했고, 구성 중 Majority FEM만 사용해서 학습을 진행했다.

마지막은 논문에서 제안한 PCNNwMM과 비교를 위해 Table 6의 최고 성능 결과를 한 번 더 나열했다. Minority FEM만 사용했을 때, Table 5, Table 6의 비교 대상들보다 좋은 성능을 보여주지만, 최고 성능과 비교하면 평균 RMSE가 0.05 높고, 표준편차가 커 실험의 결과가 안정하지 못함을 보인다. 따라서 제안한 PCNNwMM의 구조가 학습의 성능을 효과적으로 향상시키는 것을 증명했다.

Table 7. Experiment on ablation

Model architecture	RMSE	
	Average (10)	Standard deviation
Minority FEM	9.99	0.245
Majority FEM	10.38	0.272
PCNNwMM	9.94	0.17

Table 8. Comparison of the prognosis RMSE results with other algorithms.

Method	Time	RMSE
2 2D-CNN + 2 LSTM [18]	3.093	16.13
2 LSTM + 1 FC [12]	3.082	14.08
1 Bi-LSTM [14]	3.079	13.65
5 1D CNN [11]	0.008	13.32
1 2D-CNN + 1 Bi-LSTM [19]	1.015	13.22
2 1D-CNN + 2 LSTM + 1 FC [16]	9.257	12.76
PCNNwMM	0.007	9.94

3.2.4. 최근 논문들과 성능 비교

제안한 알고리즘과 최근 4년간 C-MAPSS 데이터 세트를 사용해 RUL을 추정한 여러 알고리즘과 Table 8에 나타내 비교해 보았다. Table 8에서 제안한 PCNNwMM은 다양한 센서 간의 관계를 특징으로 추출할 수 있는 Minority FEM과 Majority FEM을 이용해 비교 알고리즘들보다 센서 간의 특징 추출을 좀 더 효과적으로 진행했기 때문에 모델이 데이터를 잘 이해할 수 있고, 가장 낮은 RMSE 값이 이를 입증할 수 있다. 또, 최신 알고리즘들과 학습 시간을 비교했을 때, 7ms/epoch으로 가장 짧은 학습 시간을 소비하는 것을 증명했다. 따라서 PCNNwMM은 가장 좋은 RMSE 성능과 가장 짧은 학습 시간을 가진 모델임을 나타낸다.

4. 결론

본 연구에서 터보팬의 잔여 유효 수명 추정을 위한 다수 소수 특징 추출 병렬연결 합성곱 신경망 (Parallel-Connected Convolutional Neural Network with Minority and Majority feature extraction, PCNNwMM)은 소수 크기의 센서 관계 학습에 용이한 Minority Feature Extraction Module(FEM)과 다수 크기의 센서 관계 학습에 용이한 Majority FEM을 병렬연결로 학습하여 C-MAPSS 데이터 세트의 다양한 관계의 Feature를 추출하고, 여러 관계의 Feature를 취합하여 학습함으로써 데이터에서 여러 Feature를 고려하여 학습을 진행할 수 있었다. 또, 간단한 전처리만을 사용해 RUL과 입력 센서 데이터 간의 유사도 평가 없이 모든 센서 데이터를 학습하여 좋은 성능을 보여주었고, 이는 다른 새로운 데이터에도 적용 시, 높은 용이성을 보인다. 마지막으로, PCNNwMM은 여러 최적화 실험을 통해 C-MAPSS 데이터 세트에 최적화된 모델임을 증명했으며, 최신 알고리즘들과 비교해 좋은 성능을 보여줌을 증명했다. 향후 연구로 충분하지 않은 산업 및 국방 데이터에 강인한 퓨샷 또는 제로샷

리닝을 이용해 모델 적용성을 증가시킬 계획이다.

Acknowledgement

본 연구는 과학기술정보통신부에서 지원하는 DGIST 기관고유사업에 의해 수행되었습니다 (24-IT-02).

참고문헌

- [1] O. Merkt., "On the Use of Predictive Models for Improving the Quality of Industrial Maintenance: an Analytical Literature Review of Maintenance Strategies". *2019 Federated Conference on Computer Science and Information Systems (FedCSIS)*, pp. 693-704, 2019.
- [2] Kim, K., "A Study on the Improvement of the Safety Quality of Defence in Korea through the Survey · Analysis of the Safety Quality System of the UK MOD", *Proceedings of the 2020 spring conference of the Korean Society for Quality Management*, pp. 106-106, 2020.
- [3] Sakib, N., & Wuest, T., "Challenges and Opportunities of Condition-based Predictive Maintenance: A Review", *Procedia CIRP*, 78, pp. 267-272, 2018.
- [4] Pintelon, L., & Parodi-Herz, A., Maintenance: An Evolutionary Perspective in Complex System Maintenance Handbook edited by Kobbacy, K. A. H., & Murthy, D. P., Springer Science & Business Media, pp. 21-48, 2008.
- [5] S. J. Engel, B. J. Gilmartin, K. Bongort, & A. Hess, "Prognostics, The Real Issues Involved With Predicting Life Remaining", *2000 IEEE Aerospace Conference. Proceedings*, 6, pp. 457-469, 2000.
- [6] Ahmad, R., & Kamaruddin, S., "An overview of time-based and condition-based maintenance in industrial application", *Computers & Industrial Engineering*, 63(1), pp. 135-149, 2012.
- [7] Son, M., & Kim, Y. G., "A Study on the Reflection of Condition-Based Maintenance Requirement in the Defense Specification", *Journal of Korean Society for Quality Management*, 49(3), pp. 269-279, 2021.
- [8] Lee, J., Jin, C., Liu, Z., & Davari Ardakani, H., Introduction to Data-Driven Methodologies for Prognostics and Health Management in Probabilistic Prognostics and Health Management of Energy Systems edited by Ekwaro-Osire, S., Gonçalves, A. C., & Alemayehu, F. M., pp. 9-32, Springer, 2017.
- [9] Serradilla, O., Zugasti, E., Cernuda, C., Aranburu, A., de Okariz, J. R., Zurutuza, U., "Interpreting Remaining Useful Life estimations combining Explainable Artificial Intelligence and domain knowledge in industrial machinery", *2020 IEEE International Conference on Fuzzy Systems*, 2020.
- [10] Wang, Y., Zhao, Y., & Addepalli, S., "Remaining Useful Life Prediction using Deep Learning Approaches: A Review", *Procedia manufacturing*, 49, pp. 81-88, 2020.
- [11] Li, X., Ding, Q., & Sun, J. Q., "Remaining useful life estimation in prognostics using deep convolution neural networks", *Reliability Engineering & System Safety*, 172, pp. 1-11, 2018.
- [12] Lin, R., Yu, Y., Wang, H., Che, C., & Ni, X., "Remaining useful life prediction in prognostics using multi-scale sequence and Long Short-Term Memory network", *Journal of computational science*, 57, pp. 1-11, 2022.
- [13] Asif, O., Haider, S. A., Naqvi, S. R., Zaki, J. F., Kwak, K. S., & Islam, S. R., "A Deep Learning Model for Remaining Useful Life Prediction of Aircraft Turbofan Engine on C-MAPSS Dataset". *IEEE Access*, 10, pp. 95425-95440, 2022.
- [14] Wang, J., Wen, G., Yang, S., & Liu, Y., "Remaining Useful Life Estimation in Prognostics Using Deep Bidirectional LSTM Neural Network", *2018 Prognostics and System Health Management Conference*, pp. 1037-1042, 2019.
- [15] Shiri, F. M., Perumal, T., Mustapha, N., & Mohamed, R., "A Comprehensive Overview and Comparative Analysis on Deep Learning Models: CNN, RNN, LSTM, GRU", *arXiv*, pp. 1-61, 2023.
- [16] Shcherbakov, M., & Sai, C., "A Hybrid Deep Learning Framework for Intelligent Predictive Maintenance of Cyber-physical Systems", *ACM Transactions on*

Cyber-Physical Systems, 6(2), pp. 1–22, 2022.

- 17 Hong, C. W., Lee, C., Lee, K., Ko, M. S., Kim, D. E., & Hur, K., "Remaining Useful Life Prognosis for Turbofan Engine Using Explainable Deep Neural Networks with Dimensionality Reduction", *Sensors*, 20(22), pp. 1–19, 2020.
- 18 Kong, Z., Cui, Y., Xia, Z., & Lv, H., "Convolution and Long Short-Term Memory Hybrid Deep Neural Networks for Remaining Useful Life Prognostics", *Applied Sciences*, 9(19), pp. 1–18, 2019.
- 19 Wang, L., Zhu, Z., & Zhao, X., "Dynamic predictive maintenance strategy for system remaining useful life prediction via deep learning ensemble method", *Reliability Engineering & System Safety*, 245, pp. 1–12, 2024.
- 20 Back, M., Kim, H., Ban, J., & Koo, G., "Development of 2D CNN-based Model for Remaining Useful Life of Turbofan Engine", Proceedings of the autumn annual conference of IEIE, pp. 261–263, 2023.
- 21 Frederick, D. K., DeCastro, J., & Litt, J.S., User's guide for the commercial modular aero-propulsion system simulation (C-MAPSS), National Aeronautics and Space Administration, 2007.
- 22 Saxena, A., Goebel, K., Simon, D., & Eklund, N., "Damage Propagation Modeling for Aircraft Engine Run-to-Failure Simulation", *2008 international conference on prognostics and health management*, pp. 1–9, 2008.
- 23 Heimes, F. O., "Recurrent neural networks for remaining useful life estimation", *2008 international conference on prognostics and health management*, pp. 1–6, 2008.
- 24 Sateesh Babu, G., Zhao, P., & Li, X. L., "Deep convolutional neural network based regression approach for estimation of remaining useful life", *Database Systems for Advanced Applications: 21st International Conference*, pp. 214–228, 2016.