

다중 시간 특징 추출 기반 CNN-LSTM 결합을 이용한 잔존수명 예측

마주이, 김태형

금오공과대학교

{iju298, taehyong}@kumoh.ac.kr

Remaining Useful Life Estimation with CNN-LSTM combination based on multiple temporal feature extraction

Ju-I Ma, Tae-Hyong Kim

Kumoh National Institute of Technology

요약

설비의 잔존수명을 예측하는 것은 설비의 운용 데이터를 분석하고 결함을 진단하거나 예측하는 예지보전에서 매우 중요한 기술로 최근 딥러닝 기반의 연구가 활발하다. 본 연구는 잔존수명 예측을 위해 데이터의 특징추출에 유리한 CNN과 순차 데이터처리에 유리한 LSTM을 결합한 네트워크를 제안한다. 특별히 다양한 시간 범위에 대해 특징을 추출하기 위해 커널 크기가 다른 복수의 병렬 CNN 모듈을 사용한다. 제안된 기법을 C-MAPSS 데이터셋에 적용한 결과 기존 CNN/RNN 결합 방식보다 성능이 크게 향상된 우수한 결과를 보였다.

I. 서론

진단 기술을 활용하여 설비에 대한 지속적인 모니터링을 통해 정상적이지 않은 시스템 동작을 예측하거나 인지하고 시스템 손상에 대한 예방 또는 경고 조치를 취하는 것을 예지보전(Predictive Maintenance)이라고 한다. 예지보전을 위해서는 사물인터넷(IoT) 및 통신기술(ICT)을 통해 설비에 설치된 센서로부터 데이터를 지속적으로 획득하고, 빅데이터 분석기술과 설비 결함을 진단 및 예측할 수 있는 인공지능 기술이 요구된다. 예지 기술의 중요한 분야는 과거 데이터 및 현재 동작 상태로부터 시스템 및 각 구성 요소의 잔존수명(RUL: Remaining Useful Life)을 예측하는 것이다. 잔존수명은 현재 시점부터 수명 끝까지의 시간으로 정의되며 설비 엔지니어는 잔존수명을 고려하여 정비 일정을 잡거나 가동을 최적화하고 갑작스러운 고장을 방지한다.

잔존수명 예측은 유사한 설비의 수명 데이터, 동작 상태에 따른 고장 데이터(run-to-failure data), 고장 조건의 한계치 데이터 등을 활용하며 일반적으로 전체 데이터가 존재할 경우에는 유사성 모델을, 고장 데이터가 주가 될 경우에는 생존 모델을, 정상 데이터가 주가 될 경우에는 성능저하 모델을 사용한다. 잔존수명 예측 기술로 HMM(Hidden Markov Model) 등의 통계적 모델링, SVM(Support Vector Machine)등의 기계학습 기술 등이 활용되어 왔으나 최근에는 딥러닝 기술의 발달과 함께, CNN(Convolution Neural Networks), RNN(Recurrent Neural Networks)과 같은 인공신경망 기술이 주를 이루고 있다.

NASA에서 공개한 터보엔진에 대한 가상 성능저하 데이터셋인 C-MAPSS(Commercial Modular Aero-Propulsion System Simulation) 데이터셋[1]은 동작 상태에 따른 고장 정보에 대해 다중 센서 기반 다변량 시간데이터 기반의 훈련 및 시험 셋을 가지고 있어 딥러닝 기반 잔존수명 예측 기술 평가에 널리 사용되고 있다. C-MAPSS 데이터셋을 사용한 최근 연구로는 성능향상을 위해

LSTM(Long Short-Term Memory) 네트워크에 어텐션 모듈을 결합한 연구[2], 타임 윈도우로 추출된 데이터를 CNN으로 분석하는 연구[3], Stacked LSTM 네트워크를 기반으로 유전알고리즘을 접목해 학습을 최적화하는 연구[4], CNN과 LSTM을 결합하고 데이터 증가를 사용한 연구[5] 등이 있다. 본 연구는 CNN과 LSTM을 모두 활용되 시계열 데이터의 특징을 효과적으로 추출하기 위해 CNN 모듈을 병렬로 구축한 네트워크를 제안한다.

II. 본론

잔존시간 예측에는 다음과 같이 지도학습이 사용된다. R_T 가 실제 잔존시간이고 R_E 가 예측된 잔존시간이라고 할 때 오차 $E = R_E - R_T$ 가 최소가 되도록 학습을 진행한다. 성능지표로는 예측의 제공평균 제곱근오차(RMSE: Root Mean Square Error)와 S-스코어를 사용하며 설비 구성 요소의 수가 N 일 때 각각 아래와 같다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N E_i^2}, S = \begin{cases} \sum_{i=1}^N (e^{-\frac{E_i}{13}}) & E_i < 0 \\ \sum_{i=1}^N (e^{-\frac{E_i}{10}}) & E_i \geq 0 \end{cases}$$

잔존시간 모델로는 설비 가동 초기에는 성능저하가 거의 발생하지 않는다는 점에 착안한 조각(piece-wise) 잔존시간 모델을 사용한다[3,5].

C-MAPSS 데이터는 엔진 ID, 동작 사이클 수, 3개의 동작설정 및 21개의 센서값 등 총 26개의 열로 구성된다. 먼저 각 센서의 값은 센서 별 평균과 표준편차를 이용해 표준화한다. C-MAPSS 데이터는 FD001 ~ FD004까지 4개의 하위 데이터셋으로 구성되고 훈련 값은 각각 17,751, 48,819, 21,820, 57,522개이다. 딥러닝에서 성능은 훈련 데이터셋의 크기와 직결되므로 성능향상을 위해 데이터 증가를 활용할 수 있다. 본 연구에서는 [5]에서 사용된 것과 같

이 원본 데이터에서 잔존수명이 감소하는 부분을 따라 임의의 부분을 잘라내 더하는 방식의 데이터증가 기법을 사용하였다.

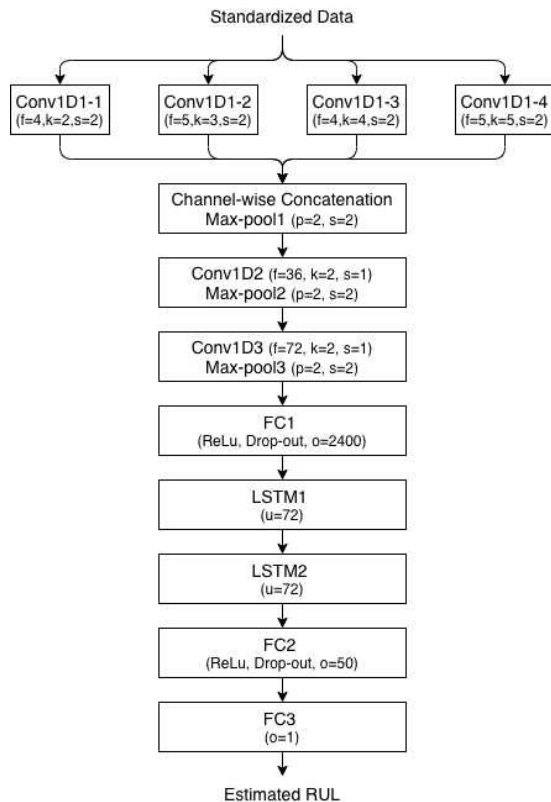


그림 1. 제안하는 잔존수명 예측 네트워크 구조

본 연구에서 제안하는 잔존수명 예측을 위한 네트워크 구조는 그림 1과 같다. 표준화된 데이터(21개의 센서 값 및 3개의 설정 값)는 100 크기의 시간 윈도우를 이용해 100개씩의 데이터로 나누어져 병렬로 구성된 서로 다른 4개의 1차원 합성곱(convolution) 모듈로 구성된 계층에 전달된다. 합성곱 연산은 2차원 이미지에 대해 이루어지는 것이 일반적이나 시계열 데이터의 처리를 위해 1차원 합성곱 연산을 사용하였다. 병렬 합성곱 연산은 시계열 정보에서 서로 다른 시간 범위의 특징을 추출하기 위한 목적으로 커널(k) 크기를 2~5로 다르게 설계하였다(f=필터 수). 스트라이드(s)는 보다 압축된 정보를 얻기 위해 2를 사용하였고 실제로 좋은 성능을 보여주었다. 각 합성곱 연산 결과는 서로 다른 채널로 결합되고 맥스풀링(p=풀링 크기) 연산을 거쳐 다음 합성곱 계층으로 입력된다. 두 개의 합성곱 계층을 통해 추출된 시계열 특징은 2400개의 출력노드(o)를 가진 완전연결계층(FC1)을 통과해 두 계층으로 구성된 Stacked LSTM 모듈(u=유닛 수)로 전달된다. Stacked LSTM 계층의 출력 값은 두 개의 완전연결계층을 통과해 잔존수명 예측 값을 생성하게 된다.

C-MAPSS 데이터셋에 대한 제안 기법의 평가 결과는 표 1~2와 같다. 표 1과 2는 각각 RMSE 값과 S-스코어 값을 다른 잔존수명 예측 기법과 비교한 것이다. 표 1에서 제안된 기법은 각 하위 데이터셋에 대해 다른 최근 기법에 비해 매우 우수한 오차 값을 나타냈고, 특히 동일한 CNN/LSTM 기반의 RUL-Net[5]과 비교할 때 성능이 현저히 향상되었다. 단, S-스코어(표 2)는 평균적인 수치를 나타내어 추가 개선의 필요성을 보여주었다.

표 1. 성능 비교: RMSE

네트워크	오차(RMSE)			
	FD001	FD002	FD003	FD004
LSTM+attention [2]	21.83	14.00	19.62	22.65
DCNN+rectified labels [3]	12.61	22.36	12.64	23.31
Stacked LSTM [4]	12.56	22.73	12.10	22.66
RUL-NET [5]	23.57	20.45	21.17	21.03
Proposed	12.73	13.91	13.62	18.70

표 2. 성능 비교: S-스코어

네트워크	S-스코어			
	FD001	FD002	FD003	FD004
LSTM+attention [2]	905	752	521	2696
DCNN+rectified labels [3]	274	10412	284	12466
Stacked LSTM [4]	231	3366	251	2840
RUL-NET [5]	1220	3100	1300	4000
Proposed	1387	4286	1438	5344

III. 결론

본 논문은 설비 예지 보전을 위한 핵심 기술 중 하나인 잔존수명 예측을 위해 시계열 데이터의 특징추출에 유리한 CNN과 순차 데이터 처리에 유리한 LSTM을 결합한 네트워크를 제안하였다. 특히 시계열 데이터에서 다양한 시간 범위의 특징을 추출하기 위해 커널 크기가 다른 4개의 병렬 합성곱 모듈을 사용하였다. 제안된 기법을 C-MAPSS 데이터셋에 적용한 결과 기존 CNN/RNN 결합 방식보다 성능이 크게 향상된 우수한 결과를 얻었다.

향후 다중 시간 범위에 대한 특징 추출 방법의 최적화를 위해 다양한 병렬 및 앙상블 구조를 대상으로 성능을 시험하고 잔존시간 예측과 연관성을 가지는 부분을 잘 포착하기 위한 시간 및 채널 어텐션 구조 등을 설계할 예정이다.

참 고 문 헌

- [1] National Aeronautics and Space Administration, C-MAPSS Aircraft Engine Simulator Data, NASA's Open Data Portal, 2010.9
- [2] 백양, 이현동, 강유, "어텐션 메커니즘과 LSTM 모델을 이용한 잔존 수명 예측". 2019 한국소프트웨어종합학술대회 논문집, 한국정보과학회, 2019.12, pp.458-460.
- [3] Xiang Li, Qian Ding, Jian-Qiao Sun, "Remaining useful life estimation in prognostics using deep convolution neural networks", Reliability Engineering & System Safety, Vol. 172, April 2018, pp.1-11.
- [4] André Listou Ellefsen, Emil Bjørlykhaug, Vilmar Aesøy, Sergey Ushakov, Houxiang Zhang, "Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture", Reliability Engineering & System Safety, Vol. 183, March 2019, pp.240-251.
- [5] Jayasinghe, Lahiru, et al., "Temporal convolutional memory networks for remaining useful life estimation of industrial machinery." arXiv:1810.05644 (2018).