

LDAPS 예측 및 AWS 관측 데이터를 이용한 CNN-BLSTM 기반의 단기 기온 예측

전지민, 김홍국

광주과학기술원

jiminbot20@gm.gist.ac.kr, hongkook@gist.ac.kr

Short-term Temperature Prediction Based on CNN-BLSTM Using LDAPS-Predicted and AWS-Observed Data

Jimin Jun, Hong Kook Kim

Gwangju Institute of Science and Technology

요 약

본 논문에서는 단기 기온 예측 성능을 향상하기 위해 AWS (Automatic Weather Station) 관측 데이터와 LDAPS (Local Data Assimilation and Prediction System) 수치예보모델의 고해상도 데이터를 사용한 CNN-BLSTM (Convolutional Neural Network - Bi-directional Long Short-Term Memory) 모델 기반 모델의 성능을 평가한다. 특히, LDAPS 이미지의 크기에 따른 기온 예측 오차의 성능을 평가한다. 그 결과, 수치예보모델의 이미지 크기가 20x20일 때, 1.78 RMSE (Root-Mean-Squared Error), 1.39 MAE (Mean Absolute Error)로 가장 좋은 성능을 보였다.

I. 서 론

최근 전 지구적 극단적인 기후 변화의 영향으로 국내외의 직간접적인 경제적 피해와 인명 피해가 증가하고 있다. 정밀한 기후 예측은 이러한 피해를 줄이고 예방하는데 필요한 가장 중요한 요소 중 하나이다. 기후변화의 가속화로 급변한 기상환경에 대한 정밀한 기후 예측의 필요성이 더욱 높아지고 있다[1]. 특히 극단적인 이상 기상 현상으로 급변하는 기상환경에 의해 증가하는 폭염, 국지성 집중호우, 태풍 등을 대비하기 위한 정확한 단기 기후예측은 매우 중요하다.

대표적인 기후 예측 방법으로는 수치예보모델이 있다. 수치예보모델은 해상도, 모델 지형, 동화 기법, 모수화 등에서 여러 가지 한계점을 가지고 있다[2]. 이를 보완하기 위해 딥러닝으로 접근하는 여러 연구가 진행되고 있다[3-5]. 특히 [3]에서는 관측 데이터와 수치예보모델 데이터를 각각의 신경망으로 특징을 추출하고, 각각의 특징을 주의집중 기법을 적용하여 기온을 예측하는 방법을 제안하였다. 여기서는, 중장기 기온 예측을 위해 수치예보모델로 RDAPS (Regional Data Assimilation and Prediction System) 예측 데이터를 사용하였다.

본 논문에서는 [3]의 신경망 모델을 활용하여 단기 기온 예측 성능을 높이고자 한다. 이를 위해 RDAPS 보다 해상도 높은 LDAPS (Local Data Assimilation and Prediction System) 예측 데이터를 활용한다. 특히, LDAPS 이미지 데이터의 크기에 따른 단기 기온 예측의 성능에 대해 논하기로 한다.

II. 본론

2.1 데이터 구성

사용한 데이터는 기상청에서 제공한 관측 데이터와 수치예보모델 데이터로 구성되었다. 기간은 LDAPS 제공 시작일인 2012년 9월 10일부터 2015년 12월 31일까지 약 3년 4개월이다. 이 데이터를 6:2:2 비율로 training, validation, 그리고 test 데이터로 각각 분할하였다.

관측 데이터란 지역 날씨를 지상, 해상 혹은 고층에서 직접 관측한 데이터이다. 본 연구에는 AWS (Automatic Weather Station) 관측 데이터를 사용하였다. AWS는 관측 공백 해소 및 국지적인 기상 현상을 파악하기 위해 실시하는 지상관측을 말하고 전국 약 510여 지점에서 관측한다. 본 연구에서는 도봉구(지역 번호 406) 지점의 기온, 1시간 누적 강수량, 10분 평균 풍향 및 풍속, 습도 등 5개 변수 데이터를 사용하였다. 따라서 AWS는 변수 개수에 따라 5차원 벡터가 한 시간 간격으로 모델에 입력된다. 하지만 AWS는 점검이나 고장 등 각종 이유에 따라 결측될 수가 있어 모델 학습에 바로 적용할 경우 문제가 된다. 구체적으로는, 수집한 데이터 중 389시간에 문제가 있었고, 544개 데이터가 결측되었다. 따라서 본 연구에서는 [6]에서 제안한 방법에 따라 전처리를 수행하였다.

한편, 수치예보모델이란 역학과 물리학적 원리에 대한 방정식들을 슈퍼컴퓨터를 활용하여 대기 상태를 분석하고 미래의 대기 상태를 정량적으로 예측하는 일련의 과정이다. 기상청에서 제공하는 대표적인 수치예보모델은 영국기상청의 통합수치예보모델(UM)을 기반으로 구축된 GDAPS (Global Data Assimilation and Prediction System), RDAPS, LDAPS 등이 있다. 각각 모델들은 서로 다른 예측시간, 수평 격자의 크기와 간격을 가진다. 본 연구에서는 국지적인 지역의 단기 예측을 위해 예측 시간이 짧고 해상도가 높은 LDAPS를 선택하였다.

LDAPS의 공간 해상도는 1.5km이며, 연직으로 70층으로 구성되며, 3시간 간격으로 GDAPS로부터 경계장을 제공받아 1일 8회 예측을 수행하고, 등압면, 모델면, 단일면 자료 3종류가 제공된다. 본 연구에서는 등압면의 변수 중 10,000Pa의 기온을 입력 데이터로 사용하였다.

LDAPS 또한 전처리 과정이 필요하다. 예를 들면, 그림 1의 우측 하단에 결측으로 인한 공백이 생긴 것을 볼 수 있다. 이를 3x3 필터로 결측치를 필터의 평균값으로 채우는 방식으로 이미지를 보간하였다. 앞서 언급한 바와 같이 1일 기준 3시간 간격으로 8회만 제공되므로 AWS와 일대일 대응시키기 위해 좌표를 고정하고 시간 축으로 선형 보간을 진행하였다. 이때 LDAPS를 입력 크기에 따른 성능을 평가하기 위하여 관측 지점을 중




그림 1. LDAPS의 전처리 전후 이미지 비교: 전처리 (a) 전 및 (b) 후

심으로 다양한 크기의 정사각형 모양으로 전처리를 수행하였다. 결과적으로, 각 이미지의 크기는 20x2, 40x40, 80x8, 320x320 등 4가지를 설정하였다. 이때, 320x320은 남한 전역으로 설정한 이미지의 크기에 해당한다.

2.2 단기 기온 예측 모델

2.2.1 주의 집중 기법을 적용한 CNN-BLSTM 기반 모델

본 논문에서의 단기 기온 예측 모델[3]은 크게 특징 추출, 정보 융합, 예측 등 3단계로 구성되어 있다. 특징 추출에서는 AWS와 LDAPS의 특징을 서로 다른 구조로 추출한다. AWS의 특징 추출은 BLSTM 모델을 사용한다. 이 모델은 256개의 은닉 노드를 갖는 두 개의 BLSTM 층과 repeat vector 층, dense 층으로 구성되었다. 시간마다 5차원 벡터가 있고, 현재 시간으로부터 이전 시간까지 예측 시간만큼의 데이터를 입력으로 한다. 즉, 예측 시간이 6시간인 경우 입력 데이터의 크기는 6x5이다. 다음으로 첫 BLSTM이 양방향성에 의해 512차 벡터 하나를 출력한다. BLSTM의 512차원 출력이 예측 시간만큼 repeat vector 층으로 입력되어 이 층을 거친 벡터의 크기는 예측 시간x512이다. 이후 두 번째 BLSTM 층을 거쳐 5개 AWS 변수에 대한 특징이 추출된다. 동시에 앞서 설명한 동일한 BLSTM 모델 구조에 기온 변수만 입력으로 하여 특징을 추출한다.

수치예보모델 데이터의 특징을 추출을 위해서는 CNN-BLSTM기반 모델을 사용한다. 이 모델은 여러 Conv(Convolution) 층을 거쳐 나온 벡터를 flatten 층을 거쳐 1차원 벡터로 전환해 AWS 특징 추출과 같은 구조의 BLSTM 층들을 거쳐 LDAPS 이미지 데이터에 대한 특징이 추출된다. 이후 정보 융합에서는 2번의 융합을 진행한다. 먼저 기온으로만 뽑은 특징과 LDAPS로부터 뽑힌 특징을 내적 연산을 통해 context vector를 만든다. 다음으로 AWS의 특징, LDAPS 이미지 데이터의 특징과 context vector를 연결해 concatenate 층을 만든다.

최종적으로 dense 층에 입력해 기온을 예측한다. 예측된 기온은 AWS의 기온 간의 평균 제곱 오차(MSE, Mean-Squared Error)를 손실함수로 설정하여 Adam Optimizer로 역전파된다. 본 논문의 모든 실험에서는 64 batch, learning rate 0.001로 설정하였으며, 80 epoch을 최대로 하여 early stopping 기법을 적용하였다.

2.2.2 LDAPS 이미지 크기에 따른 특징 추출

단기 예측을 할 때 관측지점을 중심으로 얼마만큼 넓은 영역을 학습에 사용해야 최적의 결과를 얻을 수 있을지에 대한 답을 얻기 위해 2.2.1절의 LDAPS 특징 추출 모델을 여러 가지로 변경하며 실험을 진행하였다.

특징 추출을 위한 CNN모델의 구조는 기본적으로 2차원 Conv 층, ReLU 활성화함수, 2x2차원 max pooling 층이 한 블록으로 이뤄진 구조이다. 세부적인 파라미터와 블록의 수는 서로 다르다.

20x20 크기의 이미지 추출을 위해, 3x3 커널을 가진 Conv 층 2개, 5x5 커널을 가진 Conv 층과 한 개의 2x2차원 max pooling 층으로 구성되었

표 1. LDAPS 입력 이미지 크기에 따른 6시간 기온 예측 성능 비교

이미지 크기	20x20	40x40	80x80	320x320	기존모델[3]
평가 척도					
RMSE(°C)	1.78	1.88	1.88	3.89	1.94
MAE(°C)	1.39	1.48	1.47	3.52	1.52

다. 40x40 이미지에 대해서는 2개의 블록이 적용되었다. 첫 Conv 층은 5x5 커널과 8 채널, 두 번째는 7x7 커널과 32 채널을 가진다. 80x80은 3개의 블록이 적용되었다. 모든 Conv 층은 5x5 커널을 가지고 층이 깊어질수록 4, 8, 32 채널을 가진다. 마지막으로, 320x320 이미지를 위해서는 5개의 블록이 적용되었다. 모든 Conv 층은 5x5 커널을 가지고 층이 깊어질수록 4에서 64까지 2배씩 채널이 증가한다. 출력한 특징은 6x6x64 차원이다. 320x320 이미지 외의 나머지 이미지는 6x6x32 차원을 출력한다.

2.3 실험 및 결과

6시간 후 기온 예측에 대한 성능 평가를 위해 관측치와 예측치 간의 평균 제곱근 오차(RMSE, Root-Mean-Squared Error)와 평균 절대 오차(MAE, Mean Absolute Error)를 측정하였다. 표 1에서 보는 바와 같이, 이미지 크기가 320x320 일 때를 제외하면 [3]에서 제안된 기존 모델보다 좋은 성능을 보였다. 특히, 20x20 이미지를 입력으로 주었을 때 RMSE와 MAE가 각각 1.78과 1.39로 가장 작은 기온 예측 오차를 보였다. 단기 기온 예측에서 영상의 크기를 작게 볼수록 예측 오차가 적음을 알 수 있다.

III. 결론

본 연구에서는 AWS 관측 데이터와 LDAPS 예측 수치 데이터를 활용한 단기 기온 예측 모델의 성능을 평가하였다. 기존의 LDAPS 수치 데이터에 비해 LDAPS 수치 데이터를 사용한 경우, 단기 기온 예측 오차를 줄일 수 있었다. 특히, LDAPS의 이미지 크기를 조절할 경우 기온 예측 오차를 더욱 감소시킬 수 있었다.

ACKNOWLEDGMENT

이 논문은 2021년도 광주과학기술원의 재원으로 GRI(GIST연구원) 사업의 지원을 받아 수행된 연구임.

참 고 문 헌

- [1] 기상청, "2018 기상연감," 2018.
- [2] 기상청, "예보관 훈련용 기술서-수치예보."
- [3] S. Jeong, et al., "Temperature prediction based on bidirectional long short-term memory and convolutional neural network combining observed and numerical forecast data," Sensors, 21(3), 941, 2021.
- [4] Y.-G. Ham, et al., "Deep learning for multi-year ENSO forecasts," Nature 573, pp. 568 - 572, 2019.
- [5] C. K. Sønderby, et al., "MetNet: A neural weather model for precipitation forecasting," 2020.
- [6] I. Park, et al., "Temperature prediction using the missing data refinement model based on a long short-term memory neural network," Atmosphere, vol. 10(11), 718, 2019.