

# 미세먼지 위험 단계 예측을 위한 1-D CRNN 모델 설계

이기혁<sup>1</sup>, 황우성<sup>2</sup>, 최명렬<sup>3\*</sup>

<sup>1</sup>한양대학교 전자공학과 석사, <sup>2</sup>한양대학교 전기전자제어계측공학과 박사과정,  
<sup>3</sup>한양대학교 전자공학부 교수

## Design of a 1-D CRNN Model for Prediction of Fine Dust Risk Level

Ki-Hyeok Lee<sup>1</sup>, Woo-Sung Hwang<sup>2</sup>, Myung-Ryul Choi<sup>3\*</sup>

<sup>1</sup>Master, Department of Electrical and Electronic Engineering, Hanyang University,

<sup>2</sup>The doctor's course, Department of Electronic, Electrical, Control & Instrumentation Engineering, Hanyang University,

<sup>3</sup>Professor, Division of Electronics Engineering, Hanyang University

요 약 최근 국내 미세먼지 발생의 증가에 따라 발생하는 인체에 유해한 영향을 줄이기 위하여, 미세먼지 수치를 예측하고 사전 조치를 취할 수 있도록 돕는 기술이 필요해지고 있다. 본 논문에서는 국내 미세먼지 위험 수준을 예측하기 위한 1D Convolutional to Recurrent Neural Network (1-D CRNN) 모델을 제안한다. 제안된 모델은 딥러닝 신경망의 CNN과 RNN을 결합한 구조이며, 다른 종류의 데이터로 구성된 시계열 데이터 세트에서 데이터 예측을 수행할 수 있다. 데이터 예측을 위해 국내·외 미세먼지, 풍향, 풍속 데이터를 사용한다. 제안된 모델은 약 76%(부분 최대 84%)의 정확도를 달성했으며, 일반 RNN 모델(53%)보다 정확한 예측 결과를 얻을 수 있었다. 제안된 모델은 향후 여러 개의 시계열 데이터 세트를 고려해야 하는 데이터 예측 모델 학습 및 실험을 목표로 한다.

주제어 : 미세먼지, 딥러닝, CNN, RNN, 데이터 예측

Abstract In order to reduce the harmful effects on the human body caused by the recent increase in the generation of fine dust in Korea, there is a need for technology to help predict the level of fine dust and take precautions. In this paper, we propose a 1D Convolutional-Recurrent Neural Network (1-D CRNN) model to predict the level of fine dust in Korea. The proposed model is a structure that combines the CNN and the RNN, and uses domestic and foreign fine dust, wind direction, and wind speed data for data prediction. The proposed model achieved an accuracy of about 76%(Partial up to 84%). The proposed model aims to data prediction model for time series data sets that need to consider various data in the future.

Key Words : Fine dust, Deep learning, CNN, RNN, Data prediction

### 1. 서론

미세먼지(Fine dust, PM: Particulate Matter)[1]는 최근 우리나라에서 큰 관심을 갖고 있는 환경 문제 중 하나

이다. 국내에서는 지름 10 $\mu$ m 이하의 부유 먼지를 미세먼지( $PM_{10}$ ), 거기서 지름 2.5 $\mu$ m 이하의 미세먼지를 초미세먼지( $PM_{2.5}$ )로 분류한다. 최근 발생하는 국내 미세먼지는 중금속 함량이 높아 1급 발암물질로

\*Corresponding Author : Myung-Ryul Choi(choimy@hanyang.ac.kr)

Received November 15, 2020

Accepted February 20, 2021

Revised December 16, 2020

Published February 28, 2021

분류되며 인체에 유해한 영향을 끼칠 수 있다. 국내에서는 미세먼지 발생원인 분석 및 기계학습 등을 사용한 미세먼지 예측을 위한 다양한 연구가 진행되고 있다[2-4]. 미세먼지로 인해 발생하는 질병 피해를 막고 국민 공공 보건을 향상시키기 위하여, 사전에 미세먼지가 발생할 수 있는 수치를 예측하고 예방 조치를 취할 수 있도록 알리는 것이 중요하다.

본 논문에서는 시계열 데이터 분석에 사용되는 순환신경망(RNN: Recurrent Neural Network) [5]에 선형(1D) 합성곱 신경망(CNN: Convolutional Neural Network)[6]을 융합하여 복수의 시계열 데이터를 예측하는 1-D CRNN (1-Dimension Convolutional to Recurrent Neural Network) 신경망 구조를 제안하였다. 제안된 아키텍처를 실험을 위하여 기상청 및 해외 기상 사이트에서 10년간의 국내의 미세먼지 및 미세먼지에 영향을 줄 수 있는 환경 데이터를 확보하였다. 확보된 데이터 세트를 사용하여 제안된 신경망 및 성능 비교 모델에 대한 정확도를 평가하고 결과를 비교하였다.

## 2. 본론

연구의 목적은 딥러닝 신경망[7] 모델을 사용하여 미세먼지 수치를 예측하고, 국내 미세먼지 위험 단계를 기준으로 모델의 예측 정확도를 평가하여 정확한 미세먼지 예측 결과를 제공하는 것이다. 데이터 예측을 수행하는 미세먼지의 경우 예측 목표 데이터(Target data)인 미세먼지 데이터에 대하여 영향을 줄 수 있는 다양한 환경 데이터(Environment data)들을 고려해야 한다[8]. 딥러닝 모델을 이용한 데이터 예측은 주로 시계열 데이터와 RNN 모델 구조를 사용하며, 입력 데이터 다음에 발생할 결과를 예측할 수 있다. 하지만 기존의 RNN 모델은 한 종류의 시계열 데이터(문자열, 음성, 동영상 등)를 입력받으며, 서로 다른 종류의 시계열 데이터를 받고 관계를 확인하기 위해서는 별도의 구조가 필요하다. CNN 구조에서 사용되는 컨볼루션 연산은 Masking 범위의 데이터 사이의 특징 값을 얻을 수 있다. 일반적으로 사용되는 매트릭스 형태의 컨볼루션 연산 대신, 데이터를 1열로 나열하여 합성곱 연산을 수행하는 1-D 컨볼루션 연산을 사용하여 RNN 시계열 연산에 적합한 형태의 데이터 결과를 얻을 수 있을 것으로 예상하였다.

따라서 본 논문에서는 미세먼지 발생에 영향을 주는 여러 데이터를 사용한 시계열 데이터 세트의 확보 및 이

에 대한 데이터 예측에 적합한 1-D CRNN 구조를 제안하였다. 제안된 모델은 실험을 통해 단일 데이터를 사용한 일반 RNN 모델과 비교하고 성능을 분석하였다.

### 2.1 1-D CRNN 모델

본 논문에서 데이터 예측 정확도를 향상시키기 위해 제안된 방법은 여러 환경 데이터를 고려할 수 있는 구조를 갖는 신경망 모델을 설계하는 것이다. 제안된 1-D CRNN 모델은 입력 계층, CNN 계층, RNN 계층, 출력 계층으로 구성된 구조를 갖는다. Fig. 1.은 4개의 시계열 데이터 세트가 입력되는 1-D CRNN의 모델 구조도이다.

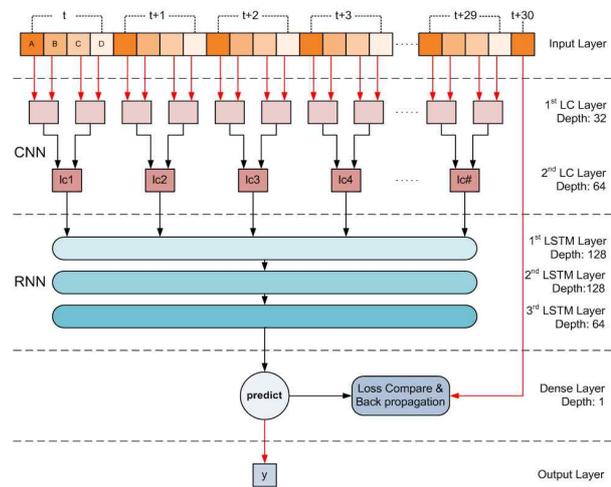


Fig. 1. 1-D CRNN Model architecture diagram

Fig. 1에서 사용되는 데이터는 목표 데이터인 서울 미세먼지 수치와 환경 데이터인 베이징 초미세먼지 수치, 서울 평균 풍향 및 풍속이다. 각 데이터의  $t$  번째 데이터를 각각  $a_t, b_t, c_t, d_t$  라고 할 때, 각각의 데이터 세트에 대한 집합  $A, B, C, D$  를 다음과 같이 표기할 수 있다.

$$A = \{a_t\}_{t \in Z}, \text{ A is target data} \quad (1)$$

$$B = \{b_t\}_{t \in Z}, \text{ B is 1}^{\text{st}} \text{ environment data} \quad (2)$$

$$C = \{c_t\}_{t \in Z}, \text{ C is 2}^{\text{nd}} \text{ environment data} \quad (3)$$

$$D = \{d_t\}_{t \in Z}, \text{ D is 3}^{\text{rd}} \text{ environment data} \quad (4)$$

확보한 데이터는 모두 일단위로 측정되었으며 한 달에 대한 시계열 특성을 얻기 위하여 한 번에 입력되는 시계열 길이(Sequential length)를 30으로 정하였다. 따라서 집합  $Z$ 는 시작 값부터 1씩 증가하는 총 30개의 자연수로

구성된다.  $t$ 는 입력되는 시계열 묶음에 따라 달라지므로  $Z = \{i, i+1, \dots, i+29\}$ 로 표현할 수 있다. 이때  $t$ 는 사용하는 데이터 세트에 따라 값이 정해지며, 본 논문에서 사용하는 데이터 세트의 최대 개수에 따라  $0 < i < 3897$  범위 내의 자연수로 정해진다. 또한 모델의 라벨(Label)으로써, 목표 데이터 집합  $A$ 의 마지막 원소( $a_{i+29}$ )의 다음 값  $a_{i+30}$ 을 입력 받는다.

데이터 집합  $A, B, C, D$ 는 각각 동일한 시간에 측정된 시계열 데이터이며, 각 집합에서  $t$ 번째 원소들을 묶어 새로운 시계열 데이터를 다시 구성할 수 있다. 다시 구성된 입력 시계열 데이터 세트의 원소를  $x_t$ 라고 할 때,  $x_t$ 는 시간  $t$ 에서  $x_t = (a_t, b_t, c_t, d_t)$ 로 표현할 수 있다. 다시 구성된 입력 데이터 세트  $X$ 는 다음과 같이 표현할 수 있다.

$$X = \{x_t | x_t = (a_t, b_t, c_t, d_t)\}_{t \in Z} \quad (5)$$

이때  $Z$ 는 수식 (1)-(4)에서  $t$ 의 집합  $Z$ 와 같다. 집합  $A, B, C, D$ 가 각각 30개의 원소를 가지므로,  $X$ 의 원소는 120개이다. 모델에 입력되는  $X$ 의 형태는  $(1 \times 120)$ 이다.

입력 계층에서 신경망 모델에 알맞은 형태로 재배열된 데이터 세트  $X$ 는 1차원 합성곱 계층(1D Convolutinal layer)[9]을 통과한다. 합성곱 필터는 필터의 크기(Filter size)에 따라서 여러 개의 입력을 받아 합성곱 연산을 통해 1개의 출력으로 반환하는 특징을 갖는다. 따라서 시간  $t$ 에서 원소  $x_t = (a_t, b_t, c_t, d_t)$ 에  $(1 \times 4)$  크기의 필터 혹은  $(1 \times 2)$  필터를 2계층 사용하면 크기  $(1 \times 1)$ 인 값  $cv_t$ 가 반환된다. 이때 동일한  $t$ 에서만 원소들이 하나의 값으로 묶일 수 있도록 필터 보폭(Stride)을 필터 크기와 동일하게 조정해주어야 한다. Fig. 1.에서는 첫 번째 1DC 계층은 필터 크기  $(1 \times 2)$ , 보폭 2, 깊이(depth) 32인 계층으로 출력은  $(1 \times 60 \times 32)$ 가 된다. 두 번째 1DC 계층은 동일한 필터 크기 및 보폭을 사용하며, 깊이 64인 계층으로  $(1 \times 30 \times 64)$ 의 출력을 갖는다.  $cv_t$ 의  $t$ 는  $t \in Z$ 이며, 이때  $Z$ 는 수식 (1)-(4)에서  $t$ 의 집합  $Z$ 와 같다. 합성곱 계층 출력 집합  $CV$ 는 다음과 같이 표현할 수 있다. 이때  $CV$ 는 1DC 계층의 출력이다.

$$CV = \{cv_t\}_{t \in Z} \quad (6)$$

$cv_t$ 는 같은 시간에 측정된 데이터 묶음인  $x_t$ 가 합성곱 계산을 통해 하나의 값이 되었기 때문에 여전히 시계열 특성을 갖고 있다. 따라서 집합  $CV$ 는 시계열 특성을 분석할 수 있는 순환 계층(Recurrent layer)의 입력으로 사용될 수 있다. 순환 계층은 장기 의존성(Long-term dependency)을 해결하고 시계열 특성을 잘 얻을 수 있는 LSTM(Long Short Term Memory) 셀[10]을 사용하여 기울기 소실(Gradient vanishing)을 방지하였다. Fig. 1.에서는 3개 LSTM 계층을 사용하였다. 첫 번째와 두 번째 계층은 1DC와 같은 30개의 원소를 받아 30개의 원소를 출력하는 다대다(many to many) 방식의 LSTM 셀이다. 각 각의 층은  $(1 \times 30 \times 128)$ 의 출력을 반환한다. 세 번째 계층은 최종 출력  $y$ 를 얻기 위하여 다대일(many to one) 방식을 사용한다. 깊이는 64로  $(1 \times 1 \times 64)$ 의 출력을 완전 연결 계층으로 반환한다.

완전 연결 계층(dense layer)은 순환 계층에서 얻은  $(1 \times 1 \times 64)$  크기의 출력을 완전 연결을 통해  $(1 \times 1)$  크기의 하나의 출력으로 만들 수 있다. 완전 연결 계층의 출력은  $a_{i+1}$ 의 값의 예측값  $y$ 를 출력한다. 제안된 모델은 MSE(Mean Squared Error)[11] 손실 함수를 사용하여 라벨  $a_{i+30}$ 과 오차를 계산하였고, Adam 옵티마이저[12]를 사용하여 모델 최적화를 수행하였다.

## 2.2 국내 미세먼지 및 환경 데이터 세트

인공 신경망 학습을 위하여 국내 미세먼지 및 환경 데이터에 대한 데이터 세트를 준비한다. 본 논문에는 서울에서 측정된 미세먼지( $PM_{10}$ )를 목표 데이터로 지정하였으며, 국내 미세먼지 발생 요인으로[13] 중국 베이징에서 측정된 초미세먼지( $PM_{2.5}$ ), 서울시 평균 기온( $^{\circ}\text{C}$ ), 평균 습도(%), 평균 풍속(m/s), 최대 풍향(16방위), 서해 평균 풍속(m/s) 및 최대 풍향(16방위)을 환경 데이터로 사용하였다. 국내의 미세먼지 및 기상 관련 데이터는 기상청 자료 개방 포털[14]의 자료 조회를 통해 학술 목적으로 제공 받았다. 해외 기상 자료인 베이징의 초미세먼지 수치는 국제 대기질 모니터링 사이트에서 제공하는 베이징 초미세먼지 데이터베이스[15]에서 확보하였다. 준비된 데이터 세트는 일(Day) 단위를 기준으로 2009년 1월부터 2019년 10월까지 측정된 자료이며 모든 값은 일 평균치를 사용하였다. 전체 데이터 세트의 개수는 3926개이다. 학습 세트는 2009년부터 9년 기간의 데이터를 사용

하였으며 총 3256개이다. 실험 세트는 2019년도 10월까지 데이터를 사용하였으며 총 304개이다. 남은 데이터는 모델 학습 시 증명 세트로 사용하였으며, 총 366개의 증명 세트로 구성되었다.

### 2.3 모델 구현 및 학습

가중치 발산을 막기 위해 국내 미세먼지 기준으로 전체 미세먼지 수치를 정규화 하였으며 시계열 데이터 타임 스텝은 1달의 일수인 30으로 지정하였다. 또한 실험 결과에 대한 비교 모델을 지정하기 위하여 1개의 순환 계층을 사용한 Single RNN(RNN-1) 구조 및 3개의 LSTM 계층을 사용하여 신경망 깊이를 증가시킨 LSTM-3 구조를 설계하였다. 비교 모델은 목표 데이터만 사용하여 데이터 예측을 수행하며, 환경 데이터를 고려하여 데이터 예측을 수행할 때의 결과와 비교하는 비교 모델로 사용된다.

Table 1. Data categories used for each model

Data category	Model2	Model4	Model6	Model8
Seoul Fine dust	0	0	0	0
Beijing Ultrafine dust	0	0	0	0
Seoul Temperatures				0
Seoul Humidity				0
Seoul Wind speed			0	0
Seoul Wind direction		0	0	0
West Sea Wind speed			0	0
West Sea Wind direction		0	0	0

제안된 모델은 파이썬(Python) 환경에서 딥러닝 설계 API인 케라스(Keras)를 사용하여 구현하였다. 구현에 필요한 신경망 구조는 케라스의 신경망 모델 함수 세트를 사용하였다. 1-D CRNN 모델 설계는 총 8 종류의 데이터에 대하여 사용되는 데이터에 따라 각각 설계하였다. 각 모델은 환경 데이터의 종류와 개수에 따른 예측 정확도 변화를 비교한다. Table 1은 각 모델 마다 사용한 환경 데이터의 종류를 표시하였다.

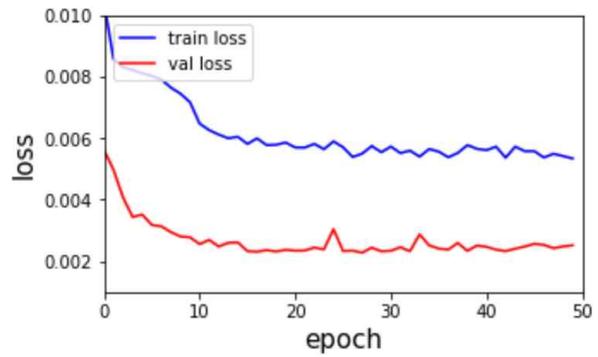


Fig. 2. Graph of loss function result

Fig. 2는 설계한 모델 별 학습에 따른 손실 함수의 변화를 그래프로 나타낸다. Fig. 2에서 파란 선은 학습, 빨간 선은 평가 세트에 대한 손실 값이다. 신경망 학습은 미니 배치 크기(Mini Batch Size)를 100으로 지정하고, 총 50 에폭(Epoch)을 수행하였다. 에폭 수를 더 많이 늘리더라도 예측 결과에 큰 변화를 주지 않기 때문에 동일 에폭에 대한 모델 구조 별 결과 차이를 비교하는 것에 집중 하였다.

### 2.3 실험 및 결과 비교

실험 세트를 사용하여 각 모델 별 데이터 예측을 실시하였다. 각 모델에 대한 미세먼지 예측 정확도를 평가하여 Table 2에 작성하였다. 미세먼지 예측 정확도 평가는 예측한 미세먼지 수치의 위험 단계가 실제 관측된 미세먼지 수치의 위험 단계와 일치할 때를 기준으로 정확도를 평가하였다.

Table 2. PM prediction accuracy for each model

Model	Accuracy				Total Acc.
	Good	Normal	Bad	Very Bad	
Model-2	0.7077	0.8693	0.2222	0.0	0.7533
Model-4	0.8000	0.7778	0.5000	0.0	0.7632
Model-6	0.7308	0.7974	0.3333	0.3333	0.7368
Model-8	0.7047	0.8431	0.3333	0.0	0.7467
RNN-1	0.0846	0.9804	0.1111	0.0	0.5362
LSTM-3	0.6154	0.7516	0.1666	0.0	0.6513

비교 모델 RNN-1은 대부분의 예측을 보통으로 수행하며 전체 정확도가 절반 정도인 53.62%로 저조한 정확도를 보였다. LSTM-3은 RNN-1에 비해 약 12% 개선된 65.13%의 정확도를 보이지만 더 높은 정확도를 얻기 위해서는 더 많은 계층을 추가해야 하며 그만큼 자원을 많

이 소모하게 된다.

제안된 1-D CRNN 구조를 사용한 모델은 선형 합성곱 계층을 추가함으로써 동일한 LSTM 셀의 개수를 사용한 LSTM 신경망에 비해 10% 이상 향상된 75% 이상의 정확도를 얻을 수 있었다. 또한 모델이 사용하는 환경 데이터를 여러 개 사용하면 예측 정확도의 향상을 기대할 수 있다. 6개의 환경 데이터를 사용하는 Model-6의 경우 전체 정확도는 다소 떨어졌지만 큰 폭의 변화 값을 감지하여 갑자기 발생하는 나쁨과 매우 나쁨 단계를 예측할 수 있었다. 하지만 Model-8처럼 너무 많은 환경 데이터를 사용하면 성능이 오히려 감소하는 문제가 발생하였다.

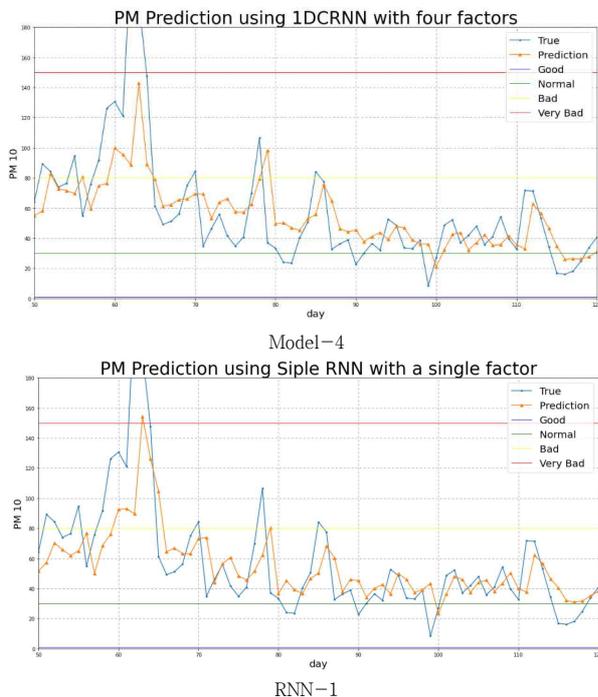


Fig. 3. Graph of PM prediction for each model

Fig. 3은 가장 좋은 성능을 보인 Model-4와 비교 모델 RNN-1의 예측 데이터에 대한 결과 그래프이다. 그래프의 수평선은 국내 미세먼지 위험 단계로, 아래에서부터 순서대로 좋음(0~30), 보통(31~80), 나쁨(81~150), 매우 나쁨(151~)이다. 파란색 그래프는 실제 미세먼지 수치(True data)를 나타내며 주황색 그래프는 예측한 미세먼지의 수치를 나타낸다. x축은 일자, y축은 0~180 사이의 미세먼지 수치( $PM_{10}$ )이다. RNN-1의 경우 미세먼지 수치 변화 경향성을 잘 따라가지 못하는 반면, 1-D CRNN 모델은 수치 변화를 유사하게 따라가는 것을 볼 수 있다.

2017년도 전기 신문[16] 기사에 따르면 현재 사용되

는 미세먼지 예측 모델은 10년 이상 관측 자료를 반영하지 않은 상태이며, 예보관의 판단을 통해 정확도를 상승시키고 있다. 제안된 미세먼지 예측 모델은 최근 10년간 확보한 기상청 자료를 기반으로 학습되었으며, 예보관의 판단을 반영하면 더 높은 미세먼지 예측 정확도를 보일 것으로 예상된다.

### 3. 결론

본 논문에서는 제안된 1-D CRNN 모델을 사용하여 미세먼지 수치를 예측하는 딥러닝 모델을 제안하였다. 제안된 모델은 10년간 국내 및 해외 기상 데이터를 학습하여 높은 미세먼지 예측 정확도를 보였다. 본 논문에서 제안한 1-D CRNN 구조는 기존의 RNN, LSTM 적층 방식의 신경망 구조에서 1D Convolution 계층을 추가하여 시스템 복잡도는 상승하지만, 약 10% 이상의 성능 향상에 비해 학습 및 예측 시간의 증가가 크지 않다. 또한 일별 데이터 예측을 수행한다고 가정하였을 때, 빠른 예측 시간 보다는 더 정확한 수치 예측이 모델의 성능을 더 높인다고 볼 수 있다. 또한, 1-D CRNN 모델은 동일한 신경망 구조를 사용하더라도 학습하는 데이터에 따라 예측 정확도에 차이가 발생할 수 있으며, 모델 설계 시, 데이터 예측에 가장 효과적인 환경 데이터의 종류 및 개수를 찾는 것이 중요하다. 본 모델은 이후 기존 미세먼지 예측 기술과 융합하여 더 정확한 미세먼지 수치 예측을 기대할 수 있다.

또한, 제안된 복합 신경망 구조는 미세먼지 수치 예측과 같이 여러 시계열 데이터를 함께 사용하는 데이터 예측에 대하여 응용 가능성을 보이며, 향후 비슷한 형태의 다양한 데이터를 사용해야 하는 시계열 데이터 분석 및 예측 모델을 학습 및 실험하는 것을 목표로 한다.

### REFERENCES

- [1] H. S. Kim, Kim, D. S., Kim, H., & Yi, S. M. (2012). Relationship between mortality and fine particles during Asian dust, smog-Asian dust, and smog days in Korea. *International journal of environmental health research*, 22(6), 518-530.
- [2] Y. P. Kim. (2006). (Invited paper) Air Pollution in Seoul Caused by Aerosols KOSAE, 22(5), 535-553.
- [3] Jeon, S., & Son, Y. S. (2018). Prediction of fine dust PM 10 using a deep neural network model. *The*

*Korean Journal of Applied Statistics*, 31(2), 265-28

- [4] Kim, H. S., Kim, D. S., Kim, H., & Yi, S. M. (2012). Relationship between mortality and fine particles during Asian dust, smog-Asian dust, and smog days in Korea. *International journal of environmental health research*, 22(6), 518-530.
- [5] Graves, A., & Schmidhuber, J. (2009). Offline handwriting recognition with multidimensional recurrent neural networks. *In Advances in neural information processing systems*, 545-552.
- [6] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [7] Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- [8] Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). *Introduction to linear regression analysis (Vol. 821)*. Hoboken : John Wiley & Sons.
- [9] T. Y. Kim. (2019). *Python Deep Learning Keras with Blocks*. Seoul : Digital books.
- [10] Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 28(10), 2222-2232.
- [11] Christoffersen, P., & Jacobs, K. (2004). The importance of the loss function in option valuation. *Journal of Financial Economics*, 72(2), 291-318.
- [12] Kingma, D. P., & Ba, J. (2014). *Adam: A method for stochastic optimization*. arXiv preprint arXiv, 1412.6980.
- [13] S. A. Park, & H. J. Shin. (2017). Analysis of the Factors Influencing PM2.5 in Korea : Focusing on Seasonal Factors. *Journal of Environmental Policy and Administration*, 25(1), 227-248.
- [14] Korea Meteorological Office. (2019). *Yellow dust observation*. Korea Meteorological Agency, Weather Data Opening Portal. <https://data.kma.go.kr/data/climate/selectDustRltmList.do?pgmNo=68>
- [15] young-0. *Beijing Air Quality: pm2.5*. monthly comparison. <http://www.young-0.com/airquality/>
- [16] D. Y. Wi. (2017.11.2.) Fine dust prediction accuracy, actually only 50%. *Electimes*, No. 3345, p. 12.



황 우 성(Woo-Sung Hwang)

[정회원]

- 2004년 2월 : 한양대학교 전자컴퓨터 공학과 (학사)
- 2006년 2월 : 한양대학교 전기전자 제어계측공학과 (석사)
- 2006년 1월 ~ 2007년 7월 : 하이텍 반도체부문 연구원
- 2007년 9월 ~ 현재 : 한양대학교 전기 전자제어계측공학과 박사과정
- 관심분야 : Image Processing, SoC/ASIC 설계, 2D/3D 및 VR/AR 영상처리, IoT/ICT 응용



· E-Mail : jokersir@gmail.com

최 명 렬(Choi, Myung Ryul)

[정회원]

- 1983년 2월 : 한양대학교 전자공학과 (학사)
- 1985년 12월 : 미시간주립대학교 컴퓨터 공학(M.S.)
- 1991년 2월 : 미시간주립대학교 컴퓨터공학(Ph..D.)
- 1991년 3월 ~ 1992년 8월 : 생산기술연구원 전자정보실용화센터 조교수 및 생산기술연구원 산하 전자부품종합기술연구소 선임연구원
- 1992년 9월 ~ 현재 : 한양대학교 전자공학부 교수
- 관심분야 : ASIC/SoC 설계, XR/AR/VR/3D/FPD 컨트롤러, RFID/IoT/ITS 응용, 스마트카드/보안 장비
- E-Mail : choimy@hanyang.ac.kr



이 기 혁(Lee, Ki Hyeok)

[정회원]

- 2018년 2월 : 한양대학교 ERICA 전자통신공학과(학사)
- 2020년 2월 : 한양대학교 전자공학과(석사)
- 2020년 7월 : KETI 연구원 근무
- 관심분야 : 영상처리, 딥러닝, FPGA
- E-Mail : enin20101@gmail.com