

## PM10 예보 정확도 향상을 위한 Deep Neural Network 기반 농도별 분리 예측 모델

조경우<sup>1</sup> · 정용진<sup>1</sup> · 이종성<sup>1</sup> · 오창현<sup>2\*</sup>

### Separation Prediction Model by Concentration based on Deep Neural Network for Improving PM10 Forecast Accuracy

Kyoung-woo Cho<sup>1</sup> · Yong-jin Jung<sup>1</sup> · Jong-sung Lee<sup>1</sup> · Chang-heon Oh<sup>2\*</sup>

<sup>1</sup>Ph.D. student, Department of Electrical, Electronics & Communication Engineering, Korea University of  
Technology and Education(KOREATECH), Cheonan 31253, Korea

<sup>2\*</sup>Professor, Department of Electrical, Electronics & Communication Engineering, Korea University of  
Technology and Education(KOREATECH), Cheonan 31253, Korea

#### 요 약

미세먼지의 인체 영향이 밝혀지며 예보정확도 개선에 대한 요구가 증가하고 있다. 이에 기계 학습 기법을 도입하여 예측 정확성을 높이려는 노력이 수행되고 있으나, 저농도 발생 비율이 매우 큰 미세먼지 데이터로 인해 전체 예측 성능이 떨어지는 문제가 있다. 본 논문에서는  $PM_{10}$  미세먼지 예보 정확도 향상을 위해 농도별 분리 예측 모델을 제안한다. 이를 위해 천안 지역의 기상 및 대기오염 인자를 활용하여 저, 고농도별 예측 모델을 설계하고 전 영역 예측 모델과의 성능 비교를 수행하였다. RMSE, MAPE, 상관계수 및 AQI 정확도를 통한 성능 비교 결과, 전체 기준에서 예측 성능이 향상됨을 확인하였으며, AQI 고농도 예측 성능의 경우 20.62%의 성능 향상이 나타났음을 확인하였다.

#### ABSTRACT

The human impact of particulate matter are revealed and demand for improved forecast accuracy is increasing. Recently, efforts is made to improve the accuracy of PM10 predictions by using machine learning, but prediction performance is decreasing due to the particulate matter data with a large rate of low concentration occurrence. In this paper, separation prediction model by concentration is proposed to improve the accuracy of PM10 particulate matter forecast. The low and high concentration prediction model was designed using the weather and air pollution factors in Cheonan, and the performance comparison with the prediction models was performed. As a result of experiments with RMSE, MAPE, correlation coefficient, and AQI accuracy, it was confirmed that the predictive performance was improved, and that 20.62% of the AQI high-concentration prediction performance was improved.

**키워드** : 미세먼지, 심층학습, 인공신경망, 심층신경망

**Keywords** : Particulate matters, Deep Learning, Artificial neural network, Deep neural network

Received 29 September 2019, Revised 30 September 2019, Accepted 14 October 2019

\* **Corresponding Author** Chang-Heon Oh(E-mail:choh@koreatech.ac.kr, Tel:+82-41-560-1215)

Professor, Department of Electrical, Electronics & Communication Engineering, Korea University of Technology and Education (KOREATECH), Cheonan 31253, Korea

Open Access <http://doi.org/10.6109/jkiice.2020.24.1.8>

print ISSN: 2234-4772 online ISSN: 2288-4165

©This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.  
Copyright © The Korea Institute of Information and Communication Engineering.

## I. 서론

인구, 차량 및 산업 활동의 증가로 인해 대기오염 문제가 국내의 주요 환경 문제로 대두되고 있다. 특히, 급속한 산업 발전에 따른 공장, 자동차, 일상생활 등에서 사용되는 화석연료의 사용량 증가로 인한 대기오염은 국경을 뛰어넘는 문제로 인식되고 있다. 이로 인해 유럽 및 북미, 동남아 지역은 국제 공조를 통해 대기오염 물질 배출 한도 및 감축량을 준수하는 협정을 체결하고 있으며, 우리나라 역시 2014년 한중일 환경장관회의를 통해 미세먼지를 포함한 대기질 개선의 목적으로 주요 현안별 국장급 정례협의체를 신설하여 연 2회 개최하기로 합의하였다[1-4].

미세먼지(Particulate matter, PM)는 다양한 크기, 모양, 성분을 가진 입자 형태의 물질이며, 입경당 크기가  $10\mu g$  이하인 경우  $PM_{10}$ ,  $2.5\mu g$  이하인 경우  $PM_{2.5}$ 를 뜻한다. 미세먼지는 호흡기의 흉부 부위를 통과할 수 있을 만큼 작은 흡입 입자로, 오존과 같은 기타 대기오염 물질보다 인체 건강에 더 큰 위험을 초래한다. 이로 인해 미세먼지로 인한 심혈관, 호흡기, 뇌혈관 질환 등의 건강 영향에 관한 다수의 연구결과가 발표되었으며, 2013년 WHO는 미세먼지를 1군 발암물질로 분류하였다[5-9].

이처럼 미세먼지에 대한 인식 수준의 증대로 인해 대중들은 미세먼지에 따른 선제 대응을 위해 ‘ 좋음, 보통, 나쁨, 매우 나쁨 ’의 4단계로 구분된 예보 정보를 확인하는 것이 일상이 되었다. 그러나 2015년 기준 고농도 미세먼지 예보정확도는 약 60% 수준을 나타내어 기존 CMAQ와 같은 통계적 선형 방법과 더불어 기계 학습 예측 모델을 도입하여 예측 정확성을 높이려는 다양한 시도가 이루어지고 있다[10-14]. 하지만 불규칙하게 발생하는 고농도 미세먼지의 특징과 함께 저농도 발생 비율이 매우 큰 미세먼지 데이터의 비율 문제는 기계 학습 기반의 예측 모델 학습 시, 저농도로 과대 적합된 예측 결과를 발생시키는 문제가 있다. 이에 본 논문에서는 미세먼지 예측 정확도 향상을 위해 저, 고농도별 분리 예측 모델을 제안한다. 이를 위해 기상 인자 및 대기오염 인자를 수집하여 고농도 기준인  $81\mu g/m^3$ 의 PM10 농도를 기준으로 데이터를 분리하여 deep neural network 모델을 통해 미세먼지 예측을 수행한다[15].

## II. 미세먼지 발생 요인

미세먼지의 경우 자연적 발생과 인위적 발생으로 구분된다. 자연적 발생의 경우 흙먼지, 바닷물에서 생기는 소금, 식물의 꽃가루 등이 있으며, 인위적 발생은 보일러나 발전시설 등에서 석탄, 석유 등 화석연료의 연소 과정에서 생기는 매연, 건설현장의 날림먼지 등이 있다. 이중 인위적 발생은 1차적 발생과 2차적 발생으로 구분된다. 1차적 발생은 배출원에서 직접 배출되는 미세먼지를 뜻하며, 2차적 발생의 경우 발생원에서는 가스 형태로 배출되었으나, 해당 물질이 공기 중에서 화학반응을 통해 다른 대기오염 물질과 결합하는 경우를 뜻한다. 2차적 발생에 기여하는 대표적 대기오염 물질은  $SO_2$ ,  $NO_x$ ,  $VOC_s$ ,  $NH_3$  등이 있다[16-18].

또한, 미세먼지의 경우 기상 조건으로 인한 고농도 발생 현상도 존재한다. 일교차가 큰 계절이나 산간분지지역의 경우 고도가 높아질수록 기온이 올라가는 ‘기온역전’ 현상이 발생한다. 기온역전이 발생하면 고도가 낮은 쪽에 무거운 공기가, 높은 쪽에 가벼운 공기가 위치하여 대기 순환이 원활하지 않아 지상의 미세먼지가 계속해서 쌓이는 문제가 발생한다[16]. 또한, 풍속과 상대습도에 따른 미세먼지의 영향에 관한 연구도 발표되었다. Shin et. al.의 연구에서는 기상인자가 미세먼지 농도에 미치는 영향을 분석하기 위해 인천 지역의 기상인자와  $PM_{10}$  미세먼지 농도에 대한 분석을 수행하였다. 해당 연구에서는 풍속이 증가함에 따라 미세먼지 농도가 점차 감소하는 특성을 확인하였으며, 상대습도가 높아질수록  $PM_{10}$  농도가 상승하는 특성을 확인하였다. 특히, 상대습도 40%부터 10% 증가 시마다 평균 6.7%의 미세먼지 농도가 상승하는 모습을 보였는데 이는 높은 습도가 2차적 미세먼지 발생을 촉진하는 것으로 추정하였다[19]. X. Zhou의 연구에서는 서울의 기상인자와 미세먼지( $PM_{10}$ ,  $PM_{2.5}$ )에 대해 다중회귀 분석을 수행한 결과,  $PM_{10}$ 은 풍속에 의한 농도 변화 영향을 가장 많이 받는 것으로 나타났으며,  $PM_{2.5}$ 의 경우 풍속, 강우량, 일사량에 의해 농도가 저감되고, 기온의 상승에 따라 농도가 상승되는 특성을 보였다[20].

### III. Deep neural network 기반 농도별 분리 예측 모델

#### 3.1. 데이터 수집 및 데이터 셋 구성

본 논문에서는 2장에서 설명한 미세먼지 발생 요인을 고려하여 천안 지역의 시간별 기상 데이터와 대기오염 물질 데이터를 수집하였다. 기상 데이터의 경우 온도, 평균 풍속, 최대 풍향, 상대습도로 구성되며, 대기오염 물질 데이터의 경우 오존( $O_3$ ), 이산화질소( $NO_2$ ), 일산화탄소( $CO$ ), 이산화황( $SO_2$ ), 미세먼지( $PM_{10}$ )로 구성된다. 이 중, 대기오염 물질 데이터의 경우 측정소 장비 유지 보수와 같은 결측 데이터를 최소화하기 위해 백석동, 성성동, 성황동 세 측정소의 데이터를 평균하여 활용하였다. 데이터 수집기간은 2009년부터 10년간이며, 각 데이터는 기상자료개방포털과 에어코리아의 최종 확정 자료를 활용하였다. 이후 16방위로 표현된 범주형 변수인 최대 풍향의 경우, one-hot encoding을 통해 16개의 이진 벡터로 전처리하였으며, 서로 다른 scale을 가진 변수들을 모델 학습에 적합하도록 min max scaling을 통해 0~1 사이의 값으로 scaling 하였다.

모델에 사용되는 데이터 셋의 경우, 수집된 전체 데이터의 75%를 training set, 25%를 test set으로 분리하였다. 이때, 미세먼지 고농도 기준인  $81 \mu g/m^3$ 을 기준으로 각 데이터 셋을 분리하여 저농도, 고농도 예측 모델에 사용하였다. 표 1은 모델별 데이터 셋의 구성을 나타낸다.

Table. 1 Data set configuration of models

Model	Number of samples	
	Training	Test
Total	65,411	21,804
Low	56,665	19,713
High	8,746	2,091

#### 3.2. 모델 설계

인간의 뇌가 정보를 처리하는 구조를 모델링 한 인공신경망은 신경망의 최소 단위인 뉴런(node)들 사이의 연결 패턴, 연결의 가중치를 갱신하는 학습 과정, 뉴런의 가중 입력을 출력으로 바꿔주는 활성화 함수를 통해 정의된다. 그림 1은 신경망의 구조를 나타낸다.




Fig. 1 Structure of neural network

인공신경망의 layer 구조는 input, hidden, output layer로 구분된다. 이때, hidden layer의 수가 2개 이상일 경우 심층신경망(DNN)으로 구분한다. 각 node의 input은 synapse에 부여된 가중치(weight)와 곱해지며 다음 노드로 전달되고, 전달받은 node의 input은 활성화 함수를 거쳐 다음 노드의 input 값으로 사용된다. 활성화 함수는 일반적으로 sigmoid, hyperbolic tangent, ReLU 함수가 사용되며, 그 종류에 따라 input 값을 0과 1, -1과 1 사이의 출력으로 변환한다[21].

본 논문에서는 미세먼지 예측을 위해 DNN을 기반으로 예측 모델을 설계하였다. 데이터 전처리 작업을 통해 생성된 model의 input node는  $t-1$ 시점의 기상 및 대기오염 데이터,  $PM_{10}$  농도를 포함한 총 24개의 node로 구성되며,  $t-1$  시점의 특성을 통해  $t$ 시점의  $PM_{10}$  농도를 예측하도록 모델을 설계하였다. 또한, 모델 훈련 과정에서 과대 적합을 막기 위해 hidden layer마다 L2 규제와 dropout 층을 추가하였으며, 모델의 활성화 함수는 ReLU, 최적화 함수는 adam을 사용하였다.

신경망 모델은 layer별 node의 수, hidden layer의 수, 학습 횟수, 규제에 따라 각기 모델의 출력이 달라져 예측 모델에 맞는 적합한 hyperparameter 선정 작업이 중요하다. 따라서 본 논문에서는 미세먼지 예측을 위한 예측 모델의 최적 hyperparameter를 선정하기 위해 표 2와 같이 총 3,600개의 후보 파라미터를 설정하여 그리드 탐색 기법을 통한 모델별 hyperparameter 최적화를 수행하였다. 해당 과정에서 일반화 성능이 높은 hyperparameter 값을 선정하기 위해 교차 검증 방법의 하나인 k-fold의 fold 수를 3으로 설정하여 hyperparameter 탐색을 수행하였다. 또한, 제안한 농도별 분리 예측 모델과의 성능 비교를 위해 추가로 미세먼지 전 영역을 예측하는 DNN

모델의 hyperparameter 최적화를 수행하였다. 표 3은 해당 과정을 통해 선정된 모델별 hyperparameter를 나타낸다.

**Table. 2** Hyperparameter grid

Parameter	Values
Layer	1, 2, 3
Hidden node	20 ~ 200 (20 per interval)
L2 penalty	0, 0.001, 0.01, 0.1
Dropout rate	0, 0.1, 0.2, 0.3, 0.4, 0.5
Batch size	20, 40, 60, 80, 100

**Table. 3** Hyperparameter by models

Parameter	Low model	High model	All range model
Layer	3	3	2
Hidden node	20	20	60
L2 penalty	0.001	0.001	0.01
Dropout rate	0	0	0.1
Batch size	100	60	80

#### IV. 실험 및 평가


본 논문에서 설계된 미세먼지 예측 모델의 성능 평가를 위해 3장에서 선정된 hyperparameter를 사용하여 모델을 학습하였다. 모델의 구현은 keras library(ver. 2.2.4)를 사용하였으며, backend로는 tensorflow 1.14.0을 사용하였다. 표 4는 각 모델의 학습 환경을 나타낸다.

**Table. 4** Model learning environment


	Specifications
OS	Windows 10 pro
CPU	AMD Threadripper 2990wx (32 core, 64 thread)
Memory	DDR4 128GB
GPU	Geforce RTX 2080ti

모델 학습 과정에서 training set의 80%는 train data로, 나머지 20%는 모델의 학습 성능 검증을 위한 validation data로 활용하였다. 학습 과정에서 모델의 과다 학습으로 인한 과대 적합을 방지하기 위해 20회 이상 검증 손실이 향상되지 않을 때 학습을 조기 종료할 수 있도록 early stopping callback을 설정하여 각 모델을 학

습시켰다. 학습 결과, 전 영역 예측 모델의 경우 학습 횟수 35회, 저농도 모델의 경우 학습 횟수 72회, 고농도 모델의 경우 학습 횟수 95회에 학습이 종료되었다. 이후, test set을 통해 실제 미세먼지와 훈련된 모델별 예측치의 비교를 수행하였다[15]. 각 모델별 예측 성능의 평가 기준은 test set의 실제  $PM_{10}$  농도 값과 모델의 예측 농도 값을 사용하여 평균 제곱근 오차(RMSE), 평균 절대 백분율 오차(MAPE), 상관계수 값을 비교하였으며, 실제 농도와 예측 농도값을 미세먼지 예보에 활용되는 AQI로 변환하여 모델별 예측 정확도 역시 평가하였다. 그림 2와 3은 test set 중 2018년 10월 1일부터 3개월간의 예측 모델별 비교 그래프이다.



**Fig. 2** Low concentration predict model result(3 month)



**Fig. 3** High concentration predict model result(3 month)

각 모델의 예측 그래프를 확인하였을 때, 모든 모델이 전반적으로 예측값과 실제 값의 비슷한 상상을, 하강 추세를 보였다. 그러나, 전 영역 예측 모델의 경우 저농도 예측 시에 저농도 경계값인  $80\mu g/m^3$  근방에서 미세먼지 농도를 과대 예측하는 경향이 보였으며, 고농도 예측 시에는 고농도 경계값인  $81\mu g/m^3$  근방에서 미세먼지 농도를 과소 예측하는 경향을 보였다. 따라서 그래프상으로 전 영역 모델과 제안 모델을 비교했을 때, 상대적으로 제안 모델의 예측 성능이 높은 것으로 판단된다. 표 5

는 성능 평가 기준에 따른 전체 test set의 예측 성능 평가 결과이다.

**Table. 5** Predictive performance evaluation by models

	All range model	Low model	High model
stop epoch	35	72	95
RMSE	7.12 (low) 15.7608 (high)	6.7276	13.8184
MAPE	14.4341 (low) 12.3409 (high)	14.1609	8.3481
Correlation coefficient	0.9173 (low) 0.8768(high)	0.9247	0.8800
Total AQI	88.71% (low) 74.84% (high)	89.63%	95.46%
AQI good (0-30 $\mu\text{g}/\text{m}^3$ )	79.9%	78.45%	-
AQI moderate (31-80 $\mu\text{g}/\text{m}^3$ )	93.14%	95.23%	-
AQI bad (81-150 $\mu\text{g}/\text{m}^3$ )	75.5%	-	96.83%
AQI very bad (151 $\mu\text{g}/\text{m}^3$ ~)	65.44%	-	75.74%

각 모델의 RMSE를 비교했을 때, 농도별 예측 모델이 전 영역 예측 모델보다 저농도, 고농도 모두 낮은 오차 값을 나타냈으며, MAPE 역시 농도별 예측 모델이 전 영역 예측 모델보다 낮은 백분율 오차를 나타내었다. 특히, 고농도의 경우 전 영역 예측 모델에 비해 3.9928% 낮은 MAPE 값을 보였다. 또한, 상관계수 값 역시 전 영역 예측 모델보다 제안하는 모델이 근소하게 높은 상관 관계를 보였다. 실제  $PM_{10}$  농도와 예측 농도값을 미세먼지 예보에 사용되는 AQI 구분으로 변환하여 정확도를 확인했을 때, 저농도의 경우 전 영역 예측 모델에 비해 근소한 성능 차이가 있었으나, 고농도의 경우 20.62%의 성능 향상이 관찰되었다.

## V. 결 론

급속한 산업 발전에 따른 화석연료의 사용량 증가는 대기오염 현상의 원인으로 제시되고 있다. 특히, 미세먼지의 경우 호흡기의 흉부 부위를 통과할 수 있을 만큼 작은 흡입 입자로서 심혈관, 호흡기, 뇌혈관 질환 등 인


체에 부정적인 영향을 끼치는 것으로 알려졌다. 이로 인해 대중들은 미세먼지 농도에 따른 선제 대응을 위해 예보 정보를 중요시하고 있으나, 저농도 발생 비율이 매우 큰 미세먼지 데이터의 비율 문제는 기계 학습 기반의 예측 모델 도입 시 저농도로 과대 적합 된 예측 결과를 발생시키는 문제가 있다. 이에 본 논문에서는 미세먼지 예측 정확도 향상을 위해 미세먼지 고농도 기준인 81  $\mu\text{g}/\text{m}^3$   $PM_{10}$  농도를 기준으로 DNN 기반의 저, 고농도 별 분리 예측 모델을 제안하였다. 이를 위해 10년간의 천안 지역 시간별 기상, 대기오염 데이터를 활용하여 모델별 최적 hyperparameter를 선정하여 농도별 예측 모델을 설계하였다. 또한, 제안하는 모델과 성능 비교를 위해 DNN 기반의 전 영역 농도 예측 모델의 최적 hyperparameter 탐색 및 모델 설계 역시 수행하였다. 이후 선정된 모델별 hyperparameter를 통해 모델을 학습하고, RMSE, MAPE, 상관계수 및 AQI 예측 정확도를 기준으로 모델별 예측 성능을 비교하였다. Test set 중 3개월 간의 예측 모델별 그래프를 비교한 결과, 모든 모델이 예측값과 실제 미세먼지 농도와의 근사한 상승 하강 추세를 보였으나, 전 영역 예측 모델의 경우 저농도 예측 시에 80 $\mu\text{g}/\text{m}^3$  근방에서 농도를 과대 예측하는 경향을 보였으며, 고농도 예측 시에는 81 $\mu\text{g}/\text{m}^3$  근방에서 농도를 과소 예측하는 모습을 보였다. 또한, 모델의 예측 성능 평가를 위해 전체 test set의 예측 결과를 사용하여 실제  $PM_{10}$  농도와 RMSE, MAPE, 상관 계수 및 AQI 예측 정확도 비교 결과 전체 기준에서 전 영역 예측 모델에 비해 제안하는 모델의 성능이 향상된 모습을 확인할 수 있었으며, 특히 고농도 예측 성능의 경우 AQI 예측 정확도를 기준으로 20.62% 향상된 모습을 보였다. 향후 딥러닝 알고리즘 변경을 통해 알고리즘별 예측 성능을 비교하고, 해당 모델의 활용을 위해 저, 고농도의 미세먼지 분류를 위한 분류 모델을 설계하여 전체 모델을 연결할 계획이다.

## ACKNOWLEDGEMENT

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education(NRF-2019R111A3A01059038)

## REFERENCES

- [ 1 ] K. Kuklinska, L. Wolska, and J. Namiesnik, "Air quality policy in US and the EU-A review," *Atmospheric Pollution Research*, vol. 6, no. 1, pp.129-137, Jan. 2015.
- [ 2 ] J. Y. Ye, "Global environment institution and middle power : The case of the convention on long-range transboundary air pollution (CLTAP)," *Journal of International Politics*, vol. 14, no. 1, pp.33-57, Mar. 2009.
- [ 3 ] J. Y. Choi, "The convention on long-range transboundary air pollution (CLRTAP) and international cooperation for the resolution of particulate matters," *National Assembly Research Service, Issues and Perspectives*, vol. 1296, Apr. 2017.
- [ 4 ] J. Y. Moon, E. M. Kim, and E. H. Choi, "International responses to transboundary air pollution and there implications," *Korea Institute for International Economic Policy*, Research paper 17-11, Dec. 2017.
- [ 5 ] A. Valavanidis, K. Fiotakis, and T. Vlachogianni, "Airborne particulate matter and human health: Toxicological assessment and importance of size and composition of particles for oxidative damage and carcinogenic mechanisms," *Journal of Environmental Science and Health, Part C*, vol. 26, no. 4, pp. 339-362, 2008.
- [ 6 ] J. O. Anderson, J. G. Thundiyil, and A. Stolbach, "Clearing the air: A review of the effects of particulate matter air pollution on human health," *Journal of Medical Toxicology*, vol. 8, no. 2, pp. 166-175, 2012.
- [ 7 ] K. H. Kim, E. Kabir, and S. Kabir, "A review on the human health impact of airborne particulate matter," *Environment international*, vol. 74, pp. 136-143, 2015.
- [ 8 ] N. J. Hime, G. B. Marks, and C. T. Cowie, "A comparison of the health effects of ambient particulate matter air pollution from five emission sources," *International Journal of Environmental Research and Public Health*, vol. 15, no. 6, 2018.
- [ 9 ] World Health Organization (WHO), "Health effects of particulate matter: Policy implications for countries in eastern europe, caucasus and central asia," Regional Office for Europe, 2013.
- [10] National Institute of Environmental Research, "A study of data accuracy improvement for national air quality forecasting(III)," Research paper 11-1480523-002809-01, 2016.
- [11] A. Chaloulakou, G. Grivas, and N. Spyrellis, "Neural network and multiple regression models for PM10 prediction in Athens: A comparative assessment," *Journal of the Air & Waste Management Association*, vol. 53, no. 10, pp. 1183-1190, 2003.
- [12] M. M. Dedovic, S. Avadakovic, I. Turkovic, N. Dautbasic, and T. Konjic, "Forecasting PM10 concentrations using neural networks and system for improving air quality," in *proceeding of 2016 XI International Symposium on Telecommunications (BIHTEL)*, Sarajevo, pp. 1-6, 2016.
- [13] J. W. Cha, and J. Y. Kim, "Development of data mining algorithm for implementation of fine dust numerical prediction model," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 22, no. 4, pp. 595-601, 2018.
- [14] K. W. Cho, J. S. Lee, and C. H. Oh, "Particulate matter AQI index prediction using multi-layer perceptron network," in *Proceeding Conference on Korea Information and Communication Engineering*, Daejeon, vol. 23, no. 1, pp. 540-541, May. 2019.
- [15] K. W. Cho, Y. J. Jung, J. S. Lee, and C. H. Oh, "Separation prediction model by concentration based on multi-layer perceptron for improving particulate matters accuracy," in *Proceeding Conference on Korea Information and Communication Engineering*, Daejeon, vol. 23, no. 2, pp. 658-660, Oct. 2019.
- [16] Ministry of Environment, *If you know right away. Fine dust, what is it?*, Apr. 2016.
- [17] G. N. Bae, "Scientific understanding and reasonable judgment of particulate matter pollution," *The Board of Audit and Inspection of Korea, Inspection*, vol. 131, pp.20-27, Jul. 2016.
- [18] J. M. Han, J. G. Kim, and K. H. Cho, "Verify a causal relationship between fine dust and air condition-weather data in selected area by contamination factors," *The Korea Journal of BigData*, vol. 2, no. 1, pp.17-26, Feb. 2017.
- [19] M. K. Shin, C. D. Lee, H. S. Ha, C. S. Choe, and Y. H. Kim, "The influence of meteorological factors on PM10 concentration in Incheon," *Journal of Korean Society for Atmospheric Environment*, vol. 23, no. 3, pp.322-331, Jun. 2007.
- [20] X. Zhou, "Statistical characteristics of meteorological factors and particulate matters(PM10, PM2.5) in Seoul," M.S. dissertation, Seoul National University of Science and Technology, 2014.
- [21] K. W. Cho, Y. J. Jung, C. G. Kang, and C. H. Oh, "Conformity assessment of machine learning algorithm for particulate matter prediction," *Journal of the Korea Institute of Information and Communication Engineering*, vol. 23, no. 1, pp. 20-26, Jan. 2019.



**조경우(Kyoung-Woo Cho)**

2015년 3월 ~ 현재 한국기술교육대학교 전기전자통신공학과 박사과정  
2015년 2월 한국기술교육대학교 전기전자통신공학과 공학석사  
2013년 2월 공주대학교 전기전자제어공학부 전자공학나노정보공학전공 전자공학트랙 공학사  
※관심분야: 미세먼지 예측, 기계 학습, Deep learning, Industrial IoT, LPWA



**정용진(Yong-Jin Jung)**

2018년 3월 ~ 현재 한국기술교육대학교 전기전자통신공학과 박사과정  
2016년 2월 한국기술교육대학교 전기전자통신공학과 공학석사  
2014년 2월 공주대학교 전기전자제어공학부 전자공학나노정보공학전공 전자공학트랙 공학사  
※관심분야: 미세먼지 예측, 기계 학습, 인공지능경망, 심층신경망,



**이종성(Jong-Sung Lee)**

2017년 3월 ~ 현재 한국기술교육대학교 전기전자통신공학과 박사과정  
2014년 8월 한국기술교육대학교 전기전자통신공학과 공학석사  
2011년 8월 나사렛대학교 정보통신학부 이학사  
※관심분야: 기계 학습, Deep learning, 데이터 분석, 5G network



**오창헌(Chang-Heon Oh)**

1999년 2월 ~ 현재 한국기술교육대학교 전기전자통신공학부 교수  
2006년 8월 ~ 2007년 7월 방문교수(University of Wisconsin-Madison)  
1993년 10월 ~ 1999년 2월 삼성전자(주) CDMA 개발팀 선임연구원  
1990년 2월 ~ 1993년 8월 한진전자(주) 기술연구소 선임연구원  
1996년 2월 한국항공대학교 항공전자공학과 공학박사  
1990년 2월 한국항공대학교 항공통신정보공학과 공학석사  
1988년 2월 한국항공대학교 항공통신공학과 공학사  
※관심분야: 무선/이동통신, IoT, 기계학습 기반 통신시스템