

# 딥러닝 기반의 대기압을 활용한 옥내 층수 예측 모델의 제안

정태양\*, 김규석\*\*, 김주희\*\*\*

## A Proposal of An Indoor Floor Prediction Model using Deep Learning-based Atmospheric Pressure

Taeyang Jeong\*, Kyuseok Kim\*\*, and Juhee Kim\*\*\*

### 요약

GPS(Global Positioning System)의 평면 측위 오차는 지속적으로 감소하고 있다. 그러나 이 기술의 한계상 실내에서의 측위는 여전히 불가능하며, 고도 오차는 수십 미터 수준으로 크다. 고도에 따른 기압의 차이가 있다는 사실에 근거하여 본 연구에서는 스마트폰의 기압 센서를 활용하여 실내에서의 지상 및 지하 층수 예측 모형을 제안한다. 연구 방법론으로는 수집된 기압 정보를 기반으로 대기압에 기반한 고도 측정의 정확도를 높이기 위하여 DNN(Deep Neural Networks) 모형에 학습하여 결과를 예측한다. 기존의 대기압을 활용한 연구는 주로 실외에서 이루어진 것으로 본 연구는 실내에서도 대기압을 활용하여 고도 측정이 가능함을 제시하는 연구이다. 샘플 데이터를 기반으로 예측한 결과, 지하 층수 예측을 100% 성공하였다. 따라서 대기압 데이터를 활용하여 옥내 층수 예측의 가능성을 제시한다.

### Abstract

The plane positioning error of Global Positioning System(GPS) is continuously decreasing. However, due to the limitations of this technology, indoor positioning is still impossible, and altitude errors are as large as tens of meters. In order to measure altitude, based on the fact that there is a difference in air pressure according to altitude, we use a smartphone's air pressure sensor. In this study, we propose an indoor prediction model for the number of floors above and below ground using the barometric pressure sensor of a smartphone. Based on the collected air pressure information, the research methodology predicts the results by learning a Deep Neural Networks(DNN) model to increase the accuracy of altitude measurement based on atmospheric pressure. As a research methodology, the results are predicted by learning a DNN model based on the collected atmospheric pressure information. As a result of the prediction based on sample data, the prediction of the number of underground floors was 100% successful. Therefore, we suggest the possibility of predicting the number of indoor floors using atmospheric pressure data.

### Keywords

global positioning system, positioning error, deep neural network, atmospheric pressure, altitude error

\* 한국공학대학교 스마트팩토리융합학과 석사과정  
- ORCID: <https://orcid.org/0009-0004-6442-7836>  
\*\* 한국폴리텍대학 AI금융소프트웨어과 조교수  
- ORCID: <https://orcid.org/0000-0001-6613-5125>  
\*\*\* 한국폴리텍대학 스마트소프트웨어과 교수(교신저자)  
- ORCID: <https://orcid.org/0000-0002-6343-6587>

• Received: Mar. 20, 2024, Revised: May 02, 2024, Accepted: May 05, 2024  
• Corresponding Author: Juhee Kim  
Dept. of Smart Software, Korea Polytechnics  
Tel.: +82-42-670-0604, Email: [juhkim@kopo.ac.kr](mailto:juhkim@kopo.ac.kr)

## 1. 서 론

GPS는 수평 오차 10m 내외의 높은 정확도로 다양한 지도 서비스에 널리 활용되고 있다[1]. 그러나 수직 오차는 수평 오차의 1.5배 이상으로 측정되어 수직 위치 정보는 상대적으로 잘 활용되고 있지 않다[1][2].

이에 수직 위치 정보인 고도를 측정하는 데 있어 상대적으로 정확도가 높은 센서는 기압 고도계이다[3]. 기압 고도계는 일반적인 스마트폰에도 내장되어 있는 센서로서 디지털 센서가 내부와 외부의 압력 차이를 이용하여 고도를 산출한다. 기압 고도계는 GPS와는 다르게 실외가 아닌 실내에서도 측정을 할 수 있는 등 지형적, 환경적 영향을 거의 받지 않는다는 특징이 있다[3].

그러나 기압 고도계 센서는 날씨에 영향을 크게 받는다는 단점이 있어 같은 장소에서 측정하더라도 시간에 따라 그 변화가 클 수 있다[3]. 대기의 이동은 기압 변화에 의한 자연 현상으로 고정된 장소에 머물러 있지 않고 항상 움직이는 특성이 있기 때문이다.

같은 고도의 장소에서 각각 다른 일시에 같은 압력 센서에 의해 기압을 측정한 실험에서 측정된 기압이 같은 수치를 나타내지 않는다는 것을 알 수 있다[4].

기압 고도계를 통해 지상, 지하의 위치를 측위했을 때 비교적 저렴하게 구입할 수 있으며 유지 보수 비용이 낮아서 대규모로 사용하여 넓은 지역의 위치를 측정하는 데 효과적이다. 또한 기압 고도계는 작고 가벼워서 이동성이 높아서 쉽게 운반하여 사용할 수 있다.

적절하게 보정된 기압 고도계는 대기압의 변화를 측정하여 지상과 지하의 상대적인 높이를 정확하게 측정할 수 있다. 또한 신속하게 측정할 수 있어서 실시간으로 위치를 확인하는 데 유용하다. 무선으로 데이터를 전송할 수 있으며, 이는 데이터 수집 및 분석을 효율적으로 할 수 있게 해준다.

따라서 기압 고도계를 사용하여 지상과 지하의 위치를 측정하는 것은 비용 효율적이고 정확성이 높으며 이동성이 있어서 매우 유용하다고 할 수 있다.

본 연구는 스마트폰으로 측정한 기압 실측값을 통해 지상과 지하의 실측값과 예측값에 대한 예측

오차율을 확인한다. 연구 방법론으로는 DNN을 활용하여 연구 데이터를 학습하고 예측하며, 연구 모형의 평가 방법은 MAPE(Mean Absolute Percentage Error)를 활용한다. MAPE는 예측 값과 실제 값 사이의 절대 백분율 오차를 평균한 값이다.

본 논문은 다음과 같이 구성된다. 1장에서는 본 연구의 배경 및 목적에 대하여 기술하고, 2장에서는 기존의 관련 연구들에 대한 고찰을 수행한다. 3장에서는 본 연구에서 활용하는 데이터와 방법론을 설명하며, 4장에서는 연구 결과에 대하여 기술한다. 마지막으로 5장에서는 결론과 추후 연구 방향에 대하여 설명한다.

## II. 관련 연구

### 2.1 기압과 고도의 특성에 관한 연구

기압은 해수면에서의 표준 대기압을 기준으로 표시되며, 해수면에서 높은 고도로 올라갈수록 기압이 감소한다. 이런 기압의 변화를 측정하여 식 (1), (2)와 같이 해당 지점의 고도를 계산할 수 있다.

수정 대기 모델은 대류권으로 알려진 약 고도 11km까지 적용할 수 있는 압력과 고도의 근사 관계로 표준 대기 상태 대신에 특정 시간과 지역의 대기 상태를 사용할 수 있다[5].

$$H_{BA} = H_{Ref} + \frac{T_{Ref}}{\beta} \left[ \left( \frac{p}{p_{Ref}} \right)^{\frac{-R\beta}{g}} - 1 \right], \quad (1)$$

여기서,  $H_{Ref} = \frac{1}{N} \sum_{i=1}^N H_i$ 는 기준고도를,  $p_{Ref} = \frac{1}{N} \sum_{i=1}^N p_i$ 와  $T_{Ref} = \frac{1}{N} \sum_{i=1}^N T_i$ 는 기준고도에서 대기압과 온도를  $\beta$ 는 기온감률을 각각 의미한다.

$$a^{-n} = \frac{1}{a^n}, \quad (2)$$

여기서,  $a$ 는  $H_{Ref} = \frac{1}{N} \sum_{i=1}^N H_i, p_{Ref} = \frac{1}{N} \sum_{i=1}^N p_i,$   
 $T_{Ref} = \frac{1}{N} \sum_{i=1}^N T_i$ 를 의미한다.

즉, 일정 시간 동안 측정된 고도와 압력, 온도 정보의 평균값들을 기압 고도계 설정에 사용한다.

주택 건설기준 등에 관한 규칙에 따르면, 지하주차장의 바닥면부터 천장까지의 높이는 2.7m 이상을 확보하도록 하였다[5]. 이는 기존에 2.3m로 승인받은 주택들이 화물 차량의 출입이 불가하여 40cm 높아진 기준이다[5]. 또한, 아파트 세대의 바닥면부터 천장까지의 높이는 2.3m 이상으로 규정하고 있는 것과 대비하여 지하주차장은 실내 층고가 최소 40cm 이상 높음을 알 수 있다[6].

## 2.2 GPS의 고도 오차를 줄이기 위한 연구

L. Kim et al.(2016)[1] GPS와 기압 고도계의 장점을 융합하여 수직 오차를 줄이는 방법을 제안하였다. 연구 방법으로는 기압 고도의 산출 및 보정방법을 제시하여 기압 고도를 GPS 고도로 환산하고, 칼만 필터를 이용하여 이 두 값을 융합하였다. 그 결과, RMSE의 값이 99% 이상 감소함을 알 수 있었다.

N. Kim and C. Park(2012)[7]는 GPS의 고도 값이 신뢰성을 잃는 경우, 기압형 고도계를 통해 보정하였다. 그 결과, 고도 오차는 10m 내외로 줄일 수 있었다.

J. Lee(2019)[8]는 기압 고도계의 고도 바이어스 및 환산 계수 오차 추정 및 보상을 적용한 INS/GNSS 복합 항법 설계와 항법 시스템 강인성을 향상시키기 위해 고장 검출 및 분리 로직을 포함한 연합형 필터 기반 INS/GNSS/TRN 통합 항법 설계를 제안하였다.

제안한 INS/GNSS 복합항법은 차량 탑재 시험을 통해 기압 고도계의 바이어스와 환산 계수 오차를 잘 추정하여 제안한 통합 항법 수평 위치오차는 6.183 m CEP, 기존의 설계는 7.426 m CEP로 약 1.243 m CEP로 성능이 크게 개선됨을 확인하였다.

S. P. Kim et al.(2008)[9]는 웨이블릿 해석을 이용한 GPS/INS/기압고도계의 융합 항법 알고리즘을 제안하였다. 관성센서와 기압고도계의 융합을 위해 수직 채널 댄핑 기법을 사용하고, 웨이블릿 해석을 이용하여 기압 및 관성 고도와 GPS 고도를 합성하였다. 그 결과, 기존의 기압 및 관성센서 고도 항법에서는 기압 고도 오차를 보상할 수 없는 문제를 해

결하고, 연속적이며 변화에 민감한 고도 정보를 얻을 수 있음을 확인하였다.

위 연구들은 모두 실외에서만 활용 가능한 GPS 기반의 기술이다. 그리고 추가적인 장비인 기압 고도계를 통해 측정값을 보정함에 있어 그 결과가 긍정적이지만 기압계가 있어야 한다는 한계점이 있다.

## 2.3 DNN 기반의 예측 모형

4차 산업혁명 시대에 들어와 DNN 기반의 예측 모형은 다양한 산업과 융합되어 활용되고 있다. 딥러닝은 여러 가지 비선형 변환 기법의 조합을 거쳐 높은 레벨의 추상화를 시도하는 알고리즘의 집합체로 정의된다.

그 중에서 DNN 모형의 layer는 input layer, hidden layer, output layer로 구성되며, hidden layer의 수에 따라 ANN과 DNN으로 구분된다. DNN은 2개 이상의 hidden layer를 포함하고 있으며, 각 layer의 뉴런에 해당하는 노드들을 연결하기 위한 연결선들은 각각의 가중치를 가지고 있다[10]-[12].

일반적으로 충분히 학습 가능한 데이터만 구비된다면 DNN 기반의 연구 모형은 전통적인 분석 방법론인 선형 회귀 분석 등에 비해 예측 결과의 정확도가 더 높다는 것이 일반적이다.

## 2.4 본 연구의 차별성

본 연구는 기존 연구 대비 다음과 같은 차별성이 있다. 첫째, 고도 측정을 하기 위하여 GPS가 아닌 스마트폰의 기압 센서를 활용한다. 이는 고도에 따라 대기압의 차이가 있으며 그 차이가 일정하다는 사실에 근거한다.

둘째, 대기압에 기반한 고도 측정의 정확도를 높이기 위하여 딥러닝 기반의 DNN 연구 모형을 활용한다. 이는 아파트, 상가 등 건축물의 형태 및 연식에 따라 지상과 지하 높이의 비율이 상이함에 근거한 것이다.

셋째, 기존의 대기압을 활용한 연구는 주로 실외에서 이루어진 것으로 본 연구는 실내에서도 대기압을 활용하여 고도 측정이 가능함을 제시하는 연구이다.

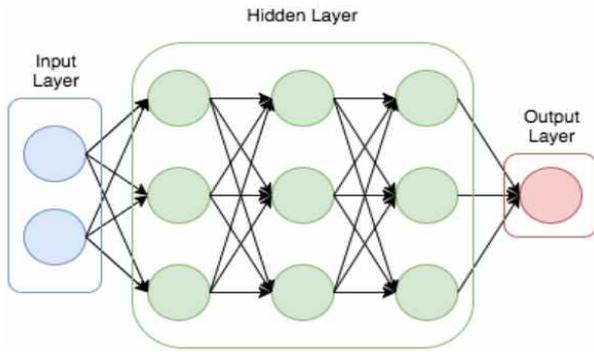


그림 1. 심층신경망  
Fig. 1. DNN

즉, 기존에는 GPS의 수직 오차 오류를 보정하기 위해 기압 고도계 등의 부가적인 장비가 활용되었고, 실외에서만 활용가능하다는 한계가 있었다. 그러나 본 연구에서는 기압 센서 하나만 사용하고 DNN 모델을 통한 예측을 수행함으로써 실내외 모두에서 활용 가능한 기술을 제안하는데 역점을 둔다.

### III. 연구 방법

#### 3.1 연구 데이터

제안한 옥내 층수 예측 모델의 성능 평가를 위해서 학습에 사용되는 학습 데이터는 서울특별시, 대전광역시, 경기도 안산시, 경기도 시흥시 등 4개 도시의 아파트 및 빌딩에서 수집한 128개의 데이터이다.

대기압의 측정은 자체 제작한 스마트폰 애플리케이션을 통해 진행된다. 지상층은 1층부터 N층까지에 대한 각 건물 최고 층수의 1/3 층마다 해당되는 기압 데이터를 수집한다. 그리고 지하층은 지하 1층부터 지하 M층까지의 모든 지하층에 대한 기압 데이터를 수집한다.

#### 3.2 연구 방법론 및 모형

본 논문에서는 옥내 층수 예측을 위해 완전 연결 신경망(FCNN, Fully Connected Neural Network) 구조를 사용하는 딥러닝 모델(DNN)을 활용한다.

제안하는 모델의 입력층은 N층의 기압, N층수, 1층의 기압, 지하 M층의 기압을 사용하며, 은닉층을

거쳐 계산된 예상 층수는 출력층에서 출력된다. 이때 coefficient  $\lambda$ 는 예측 모델의 등가적인 표현이며, 신경망의 학습을 통해 결정된다[13].

$$\hat{z}(x) = \lambda_1(x)z(x_1) + \dots + \lambda_n(x)z(x_n) \quad (3)$$

표 1에서는 본 연구에서 활용되는 DNN 모형의 변수들을 정리하였다. 종속변수는 AFU(A Floor Underground)로서 지하 A층 예측하는 값이다. 독립변수로는 예측을 위하여 7가지 변수가 활용된다.

첫째, BFA(B Floor Above the ground)와 APB(Atmospheric Pressure on the floor B)는 각 지상 B층에서의 층수와 실측 대기압 값이다.

둘째, APF(Atmospheric Pressure on the first Floor)는 1층에서의 실측 대기압 값이다.

셋째, HF(Height per Floor), HHD(Highest Height D), TFC(Top Floor C)는 각 건축 데이터 개방 사이트에서 추출한 해당 건물의 지상 층의 높이를 지상 층수로 나눈 값, 해당 건물의 높이, 해당 건물의 최고 층수이다[14].

마지막으로 APA(Atmospheric Pressure on the A floor)는 지하 A층에서 실측 대기압 값이다.

표 1. 변수의 정의  
Table 1. Definition of variables

Category	Variable	
Dependent variable	AFU	A floor underground
	BFA	B floor above the ground
Independent variable	APB	Atmospheric pressure on the B floor[hPa]
	APF	Atmospheric pressure on the 1st floor[hPa]
	HF	Height per floor[m]
	HHD	Highest height D[m]
	TFC	Top floor C
	APA	Atmospheric pressure on the A floor[hPa]

위와 같이 대기압의 측정값과 건물의 높이, 최고 층수 등은 알고 있으나 지하 층수를 모른다고 가정하고, 해당 층수를 예측하는 방식으로 진행된다. 학습 초기에 신경망의 가중치는 무작위로 할당된 값이 사용되지만, 학습이 진행되면서 가중치는 측정값을 더 잘 예측하는 방향으로 조정되는 훈련 반복(Training loop)이 진행된다.

즉, 가중치는 예측값과 측정값의 차이가 최소화되는 방향으로 수정된다. 역전파(Backpropagation) 알고리즘은 학습 과정에서 가중치와 편향을 조정하기 위한 핵심 알고리즘이며, 이러한 과정은 옵티마이저(Optimizer)에 의해 수행된다.

본 논문에서 제안된 모델의 학습에 사용되는 총 128개의 학습 데이터 중 70%는 훈련 세트, 30%는 검증 세트로 매번 무작위로 구분된다. 훈련 세트를 이용하여 학습이 진행되고, 검증 세트를 이용하여 하이퍼 파라미터 튜닝을 통해 여러 구조의 모델을 실험하고, 최적의 성능을 보이는 모델이 선정된다.

학습 및 검증은 클라우드 기반의 Google colab 환경에서 수행되었다[15]. 연구 모델에 사용된 하이퍼 파라미터와 구조는 표 2와 같다. 레이어의 개수는 변수의 개수인 7개로 하며, 활성화 함수는 Linear를 활용한다.

또한, 예측 정확도에 초점을 맞추어 학습 단위인 Batch size는 1이며, 학습 횟수인 Epochs는 1,000으로 설정한다. 마지막으로, Optimizer는 'adam'으로 설정한다.

표 2. 연구 모델의 하이퍼 파라미터와 구조  
Table 2. Hyperparameters and structure for research model

Category	Value
Number of layers	7
Activation function	Linear x 7
Batch size	1
Epochs	1,000
Optimizer	adam

그리고 DNN 모형을 활용하여 예측된 AFU의 결과는 소수점형이 되어 예측이 된다. 따라서 그 값을 반올림한 결과를 기반으로 최종 층수를 확정한다.

또한 식 (4)와 같이 MAPE[16]를 활용하여 예측의 정확도를 평가한다.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100 [\%] \quad (4)$$

## IV. 연구 결과

### 4.1 기술 통계량

본 연구에서 활용하는 데이터의 기술 통계는 표 3과 같다. 여기서 중점적으로 봐야 할 것은 두 가지가 있다.

첫째, 1층의 대기압 값인 APF의 최솟값은 1,014.86, 최댓값은 1,030.12, 평균값은 1,023.97이라는 것이다. 즉, 같은 1층이어도 기압의 표준편차가 2.41로 크며, 이는 해당 지역의 고도나 날씨에 따라서 달라질 수 있는 부분이다.

둘째, 층별 높이인 HF의 최솟값은 2.78, 최댓값은 4.76, 평균값은 3.82이다. 이 역시도 표준편차가 크다는 것을 알 수 있다. 이는 건물의 형태가 아파트, 빌딩에 따라서 달라질 수 있고, 연식에 따라서도 그 기준이 달라질 수 있음을 의미하는 것이다.

표 3. 기술 통계량(n = 128)

Table 3. Descriptive statistics(n = 128)

Variable	Minimum	Maximum	Average	STD.DEV
AFU	1	5	2.05	1.05
BFA	2	21	7.22	4.99
APB	1,014.12	1,029.43	1,021.01	2.93
APF	1,014.86	1,030.12	1,023.97	2.41
HF	2.78	4.76	3.82	0.64
HHD	38.1	87.99	49.97	8.54
TFC	8	30	13.68	4.21
APA	1,015.54	1,031.32	1,024.87	2.48

### 4.2 DNN 기반의 예측 결과

표 4는 표 2를 기반으로 DNN 연구 모형을 구성하여 10회 반복 수행한 결과이다. 1회차부터 10회차까지의 MAPE의 최솟값은 0.22%, 최댓값은 0.97%,

평균값은 0.71%, 편차는 0.27%로 매우 낮았다. 또한, 예측된 값에서 반올림한 결과, 회차별 37개, 총 370개의 검증 데이터 중 1개도 예측 실패는 없었음을 알 수 있다.

표 4. DNN 결과

Table 4. Results from DNN

No.	MAPE	Number of failure
1	0.22	0
2	0.79	0
3	0.62	0
4	0.93	0
5	0.95	0
6	0.71	0
7	0.63	0
8	0.32	0
9	0.97	0
10	0.95	0

## V. 결론 및 향후 과제

본 논문에서는 이전에 시도된 바 없던 DNN 모델을 활용해 옥내 층수 예측 모델을 제안하였다는 점에서 연구에 의의를 찾을 수 있다. 연구 데이터는 4개 도시의 층별 기압값이다. 그리고 제안된 딥러닝 기반의 대기압을 활용한 옥내 층수 예측 모델은 스마트폰의 기압 센서를 활용하여 고도 측정을 수행하고, DNN 모형을 통해 고도 측정의 정확도를 높일 수 있는 효과적인 방법임을 입증하였다.

그러나 더 다양한 데이터 셋을 활용하여 모델의 일반화 성능을 향상시키는 것이 필요하다. 특히 다양한 지역에서의 데이터 수집과 모델의 적용을 통해 일반화 능력을 검증해야 한다. 추가적인 센서 데이터나 외부 요인을 고려하여 모델을 보다 강건하게 만드는 연구가 필요하다. 예를 들어, 온도, 습도, 고도 등의 다른 환경 변수를 고려하여 모델을 개선할 수 있다.

추후 연구에서는 더 넓은 응용 범위를 고려하여 모델을 확장하는 연구가 필요하다. 예를 들어, 건물 내부 구조나 지형 변화 등에 대한 예측 모델을 개발하는 것이 가능할 것이다. 또한 대기압에 직접적인 영향을 주는 날씨와의 편차를 모델링하여 시차

가 길더라도 활용할 수 있는 모형이 될 수 있도록 할 것이다. 이러한 부분을 주제로하여 향후 본 연구로 나아갈 수 있을 것이다.

## References

- [1] L. Kim, K. Choi, J. Lim, W. Yoo, and H. Lee, "Improving GPS Vertical Error Using Barometric Altimeter", *Journal of Advanced Navigation Technology*, Vol. 20, No. 1, pp. 29-36, Feb. 2016. <https://doi.org/10.12673/jant.2016.20.1.29>.
- [2] N. H. Kim and C. H. Park, "A barometric altitude sensor and GPS altitude system fusion by using Kalman filter", *Proc. of the 36th Institute of Electronics Engineers of Korea(IEEK)*, Jeju, Korea, pp. 547-551, Jul. 2013.
- [3] H. Yu, Y.-J. Lee, G.-I. Ji, S.-B. Cheon, C.-B. Gwon, H.-S. Jeon, and J.-M. Ju, "Altitude Estimation Improvement in DGPS using Barometric Altitude Sensors", *Journal of the Korean Society for Aeronautical & Sciences*, Vol. 34, No. 1, pp. 89-94, Jan. 2006. <https://doi.org/10.5139/JKSAS.2006.34.1.089>.
- [4] J.-J. Choi, H.-Y. Choi, S.-B. Do, and H.-S. Kim, "Absolute Altitude Determination for 3-D Indoor and Outdoor Positioning Using Reference Station", *The Journal of Korean Institute of Communications and Information Sciences*, Vol. 40, No. 1, pp. 165-170, Jan. 2015. <https://doi.org/10.7840/kics.2015.40.1.165>.
- [5] S.-Y. Jung, "Procedure of Barometer Setting in Flight with On-board Navigation Data alone", *Journal of the Korean Society Aeronautical and Space Science*, Vol. 40, No. 4, pp. 300-308, Apr. 2012. <https://doi.org/10.5139/JKSAS.2012.40.4.300>.
- [6] Ministry of Land, Infrastructure and Transport, "Regulations on Housing Construction Standards, etc.", <https://www.law.go.kr> [accessed: Jan. 01, 2024]
- [7] N. Kim and C. Park, "A Study on The Advanced

- Altitude Accuracy of GPS with Barometric Altitude Sensor", Journal of the Institute of Electronics and Information Engineers, Vol. 49, No. 10, pp. 18-22, Oct. 2012. <https://doi.org/10.5573/ieek.2012.49.10.018>.
- [8] J. Lee, C. Sung, B. Park, and H. Lee, "Design of INS/GNSS/TRN Integrated Navigation Considering Compensation of Barometer Error", Journal of the KIMST, Vol. 22, No. 2, pp. 197-206, Apr. 2019. <https://doi.org/10.9766/KIMST.2019.22.2.197>.
- [9] S.-P. Kim, E.-T. Kim, and K.-J. Seong, "Sensor Fusion of GPS/INS/Baroaltimeter Using Wavelet Analysis", Journal of Institute of Control, Robotics and Systems, Vol. 14, No. 12, pp. 1232-1237, Dec. 2008. <https://doi.org/10.5302/J.ICROS.2008.14.12.1232>.
- [10] M. M. Dedovic, S. Avdakovic, I. Turkovic, N. Dautbasic, and T. Konjic, "Forecasting PM10 concentrations using neural networks and system for improving air quality", 2016 Telecommunications(BIHTEL), Sarajevo, Bosnia and Herzegovina, pp. 1-6, Oct. 2016. <https://doi.org/10.1109/BIHTEL.2016.7775721>.
- [11] J. B. Ahn and Y. M. Cha, "A Comparison Study of Corrections using Artificial Neural Network and Multiple Linear Regression for Dynamically Downscaled Winter Temperature over South Korea", Asia-Pacific Journal of Atmospheric Sciences, Vol. 41, No. 3, pp. 401-413, Jun. 2005.
- [12] J. W. Oh, J. H. Song, K. H. Kim, and S. H. Jung, "Automatic Composition Using Training Capability of Artificial Neural Networks and Chord Progression", Journal of Korea Multimedia Society, Vol. 18, No. 11, pp. 1358-1366, Nov. 2015. <https://doi.org/10.9717/kmms.2015.18.11.1358>.
- [13] J. Yang, J. Heo, J. H. Kim, Y. J. Park, H. Choo, and Y. B. Park, "Predicting Atmospheric Refractivity over the Korean Peninsula Using Deep Learning Techniques", The Journal of Korean Institute of Electromagnetic Engineering and Science, pp. 493-496, Jun. 2023. <https://doi.org/10.5515/KJKIEES.2023.34.6.493>.
- [14] EAIS, <https://open.eais.go.kr> [accessed: Jan. 02, 2024]
- [15] Google colab, <https://colab.research.google.com>, [accessed: Jan. 02, 2024]
- [16] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation", PeerJ. Computer Science, Vol. 7, pp. 1-24, Jul. 2021 <https://doi.org/10.7717/peerj-cs.623>.

## 저자소개

### 정 태 양 (Taeyang Jeong)



2014년 : (주)매트론 RF 통신  
개발연구원

2016년 : (주)에이텍 서울/경기  
지하철 S/W연구원

2022년 : ICT이노베이션  
AI융합교육 강사

2023년 ~ 현재 : 한국공학대학교

스마트팩토리융합학과 석사과정

2024년 현재 : 만들다.co SW 개발 회사 대표

관심분야 : 인공지능, 증권 및 암호화폐 데이터 활용

### 김 규 석 (Kyuseok Kim)



2011년 : 한국항공대학교  
정보통신공학(학사)

2019년 : 아주대학교 정보통신공학  
(석사)

2019년 : LG전자(주) 선임연구원  
2019년 9월 ~ 현재 : 서울대학교

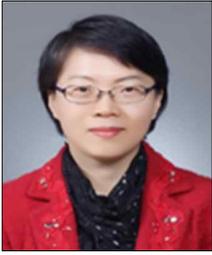
도시계획학과 박사수료

2020년 : (주)LG유플러스 책임 연구원

2024년 현재 : 한국폴리텍대학 AI금융소프트웨어과  
조교수

관심분야 : 도시계획, 데이터 분석, 인공지능, 근거리  
무선통신

김 주 희 (Juhee Kim)



1990년 : 계명대학교

컴퓨터공학과(공학사)

1992년 : 계명대학교

컴퓨터공학과(공학석사)

1997년 : 계명대학교 컴퓨터공학과  
(박사 수료)

2024년 현재 : 한국폴리텍대학

대전캠퍼스 스마트소프트웨어과 교수

관심분야 : 데이터베이스, 데이터 분석, 머신러닝, 딥러닝