



서울글로벌챌린지 2021 수상작

자동측정망 자료를 활용한 도시철도 공기질 실/내외 영향 분석과 농도 변화 예측

Prediction of Concentration Change and Influence Analysis of Indoor/Outdoor in Subway Station using Indoor Air Quality Monitoring Data

김종범¹, 박세찬¹, 이용일², 이선엽³, 김정호⁴, 박덕신⁵.*

충남연구원 서해안기후환경연구소, ¹(주)나옴 개발팀,

²한강유역환경청 환경감시단, ³근로복지공단 직업환경연구원,

⁴(주)미세먼지연구소, ⁵한국철도기술연구원 교통환경연구팀

접수일 2021년 9월 30일
수정일 2021년 12월 27일
채택일 2022년 1월 11일

Received 30 September 2021
Revised 27 December 2021
Accepted 11 January 2022

*Corresponding author
Tel : +82-(0)31-460-5367
E-mail : dspark@krii.re.kr

Jong Bum Kim, Sechan Park¹, Yongil Lee², Seonyeop Lee³, Jeongho Kim⁴, Duckshin Park⁵.*

Seohaean Research Institute, ChungNam Institute, Hongseong, Republic of Korea

¹Department of Research & Development, NAOM Inc., Uiwang, Republic of Korea

²Environmental Inspection, Hanriver Basin Environmental Office, Hanam, Republic of Korea

³Institute of Occupation and Environment, Korea Workers' Compensation & Welfare Service, Incheon, Republic of Korea

⁴Fine Particle Lab. Co. Ltd., Incheon, Republic of Korea

⁵Transportation Environmental Research Team, Korea Railroad Research Institute, Uiwang, Republic of Korea

Abstract Concern and caution for the atmospheric environment has been increasing recently; the air quality in urban subways, a major means of transportation in large cities, is a major concern. To manage this situation, the Korean government has installed real-time monitoring devices at all subway stations and its data is made available to the public. In this study, we carried out an influence analysis between the indoor and outdoor environment, and future concentration prediction (1 hour later) using machine learning; real-time data was measured at Suyu station. PM₁₀ concentration on a platform at Suyu station was 146.0 µg/m³, exceeding the indoor air quality standards. The annual average concentration of CO₂ was 530 ppm, which was below the indoor air quality standards. The correlation analysis between pollutants and measurement points showed that PM₁₀ had a high correlation coefficient for train passing number (TPN), tunnel, concourse, and platform. NO showed high correlation for concourse, platform, and ambient air. The prediction results (R²) for big data obtained using machine learning was 0.69. We confirmed that it is possible to predict indoor air quality of subway stations by employing machine learning and real-time monitoring data. In future, the results of this study can be used as basic information for establishing an indoor air quality management plan for subway stations.

Key words: Subway station, PM₁₀, IAQ monitoring, Machine learning, Prediction

1. 서 론

도시철도는 사전에 계획한 규정 노선을 운행함으로써 교통사고의 위험이 적고, 공급전기를 직접 동력으로 사용하기 때문에 오염물질의 배출이 거의 없어 친환경

경적이고 안정적인 대중교통수단으로 인식되고 있다 (Xu and Hao, 2017). 국내 도시철도는 1974년 서울역부터 청량리역까지 운행하는 서울지하철 개통을 시작으로 인천~경기권까지 연계되는 수도권 광역노선이 운행되고 있으며, 부산, 대구, 대전, 광주와 같은 주요

광역시까지 확대되어 운영되고 있다. 도시철도 이용객 수는 2003년 1,982백만 명에서 2019년 2,645백만 명으로 1.33배나 증가하였고, 대중교통수단 수송분담률 또한 16.6%에서 18.7%로 지속적으로 증가하고 있다(MOLIT, 2020). 이처럼 이용객과 수송량 증가는 도시철도 시스템의 규모 확대를 가져왔으며, 그에 따라 이용객의 도시철도 이용 만족에 대한 욕구 또한 증가하고 있다. 도시철도는 일부 지상 노선을 제외하고 지하의 밀폐된 공간을 운행하기 때문에 오염문제에 대응하기 어려운 특성이 있다. 지하 역사 및 운행통로에 유입된 오염물질은 자연적인 환기를 통해 외부 배출이 어렵고, 지하 공간은 희석 및 확산 효과를 통한 정화가 제한적이기 때문에 이러한 문제를 해결하고자 효과적인 도시철도 공기질 관리에 대한 연구가 수행되어 왔다(Kim *et al.*, 2019; Lee *et al.*, 2016). 최근 연구에서는 도시철도 역사 내의 공기질이 승객과 근로자의 건강에 악영향을 줄 수 있다는 결과와 함께, 특히 승객의 안전과 건강보호를 위해 승강장에 스크린 도어(platform screen door, PSD)를 설치한 이후 터널 내 공기질은 더욱 안 좋아진 것으로 확인되면서 이에 대한 대책이 요구되고 있다(Han *et al.*, 2014; Son *et al.*, 2014, 2013; Kim *et al.*, 2012; Lee *et al.*, 2010).

정부는 1997년 지하생활공간 공기질 관리법을 제정하여 지하 역사와 지하도 상가에 대한 관리를 시작하였고, 미세먼지(particulate matter less than 10 μm , PM_{10})를 포함하여 총 7개의 오염물질을 관리대상으로 지정하였다(MOE, 1998). 2006년에는 대중교통수단 실내공기질 관리 가이드라인을 설정하여 열차, 버스과 더불어 도시철도 차량에 대한 공기질을 관리하기 시작하였다(MOE, 2006). 2021년 현재 승강장을 대상으로 실시간 초미세먼지(particulate matter less than 2.5 μm , $\text{PM}_{2.5}$)의 1시간 단위 농도를 확인할 수 있는 자동측정기와 미세먼지 저감장치를 설치하였으며 지하 역사, 지하도 상가, 철도 역사 및 대합실에 대하여 유지기준 6개, 권고기준 4개 등 총 10개 물질을 관리하고 있다(MOE, 2021a). 2018년에는 관계부처 합동으로 “실내공기질 관리 기본계획(2020~2024)”

을 수립하여 모든 지하 역사와 승강장에 공기정화 설비 설치, 노후 환기설비 교체, IoT 기반 공기질 모니터링($\text{PM}_{2.5}$) 확대, 신규제작 차량 미세먼지 저감장치 부착 등을 추진 중에 있다(MOE, 2020). 하지만 대부분의 사업들이 발생원에 대한 사후 모니터링이나 개선 대책에 머무르고 있다.

도시철도 내 오염원은 크게 내부 발생원과 외부 유입원으로 나뉜다. 내부발생의 주요 요인으로는 도시철도 차량 이동 시 브레이크 패드와 휠, 레일의 마모에 의해 발생하는 마모입자를 들 수 있고, 이외 차량운행 시 발생한 열차풍에 의한 재비산 입자와 팬토 그래프의 마모 등이 있다(Jung *et al.*, 2010; Kim *et al.*, 2010; Chillrud *et al.*, 2004; Birenzvice *et al.*, 2003). 외부 유입으로는 자연환기구를 통한 주변 오염물질의 유입을 들 수 있는데 특히 도로변 가까이 저상으로 설치된 자연환기구를 통한 실내 유입이 역사 내 문제로 보고되고 있다(Namgung *et al.*, 2016; Son *et al.*, 2000).

이와 같은 도시철도 환경문제를 예측, 진단하기 위해 최근 빅데이터 분석을 통한 머신러닝 기법(machine learning)이 다수 활용되고 있다(Nam *et al.*, 2020; Loy *et al.*, 2020; Liu *et al.*, 2019; Kim *et al.*, 2016). 머신러닝 기법은 인공지능을 활용하여 데이터 분석을 위한 모델 생성을 자동화하여 소프트웨어가 데이터를 바탕으로 학습하고, 패턴을 찾아내어 이를 다양한 분야에 활용하도록 지원하는 방식이다(Lee and Lee, 2020; Cho *et al.*, 2019a, 2019b). Chellali *et al.* (2016)은 인공신경망(artificial neural network, ANN)을 활용하여 PM_{10} 농도변화를 예측하였으며, Perez *et al.* (2000)은 고농도 사례에 대한 $\text{PM}_{2.5}$ 농도예측에 적용하였다. 더 나아가 Chaloulakou *et al.* (2003)은 ANN이 잘 학습된다면 미세입자 생성 메커니즘 예측 분야에도 적용 가능할 것으로 예상하였다. 그리고 Park (2021)은 다양한 빅데이터 분석 기법을 적용하여 지하 역사 내 최적 관리방안을 제시하였다. 이처럼 머신러닝 기법은 빅데이터 학습을 통해 다양한 분야 예측에 적용되고 있다.

최근 정부에서는 도시철도 역사의 공기질 관리를 위해 도시대기측정망(air quality monitoring station, AQMS)과 같은 준-실시간 측정장비를 지하 역사에 설치하여 관련 정보를 수집하고 있으며(KECO, 2021), 많은 양의 자료가 축적되면서 빅데이터를 형성하고 있다. 본 연구에서는 역사 내 자동측정망 자료를 통해 도시철도 역사 내 공기질 현황을 분석하여 그 실태를 파악하고, 많은 양의 측정자료를 효과적으로 해석하기 위한 빅데이터 분석방법을 적용하여 지하 역사 내의 공기질 예측기법을 제안하고자 한다. 추후 본 연구는 도시철도 역사 내 공기질 관리를 위한 개선방안으로 활용될 수 있을 것으로 기대된다.

2. 연구 방법

2.1 대상 역사 선정

도시철도 역사에 대한 실내외 영향분석을 위해 수도권 4호선의 수유역을 대상 역사로 선정하였다. 수유역은 서울 서북부지역에 위치하며, 역사 위로 왕복

6차선 도로와 버스중앙차선이 조성되어 있다. 또한 서울의 중심인 동대문과 연결된 대로로 동대문역부터 노원구청, 동부간선과 연계되어 평상시 교통량이 많고 출퇴근시간대 교통혼잡이 자주 야기되는 곳이다.

역사 내 환기는 역사 양쪽 끝에 위치한 환기실의 건조설비를 거쳐 진행되며, 수유역을 중심으로 쌍문과 미아역 방면으로 급기 4기, 배기 6기가 설치되어 운영되고 있다. 환기구는 모두 보도 쪽에 설치되어 있으며, 탑형으로 바닥으로부터 0.45~1.8m 높이에 있으나 교통량이 많은 도로변에 위치해 있어 주변 오염원에 의한 내부 유입이 많을 것으로 판단된다.

서울시에 설치된 도시철도는 1기 지하철인 1~4호선이 2기 지하철인 5~8호선에 비해 심도가 낮은 편인데, 1기 지하철의 경우 지면으로부터 선로까지의 깊이가 평균적으로 10~17m인 것에 반해 2기 지하철은 18~24m로 깊다. 이는 2기 지하철의 경우 1기 지하철과 전기나 수도배선을 피해 설계되다 보니 기존 설비들을 피해 더 깊은 곳에 설계되었기 때문이다. 대상 역사인 수유역 역시 지면으로부터 선로까지의 심도가 12.7m로 낮은 편에 속해 도로변에서 유입된 오염물

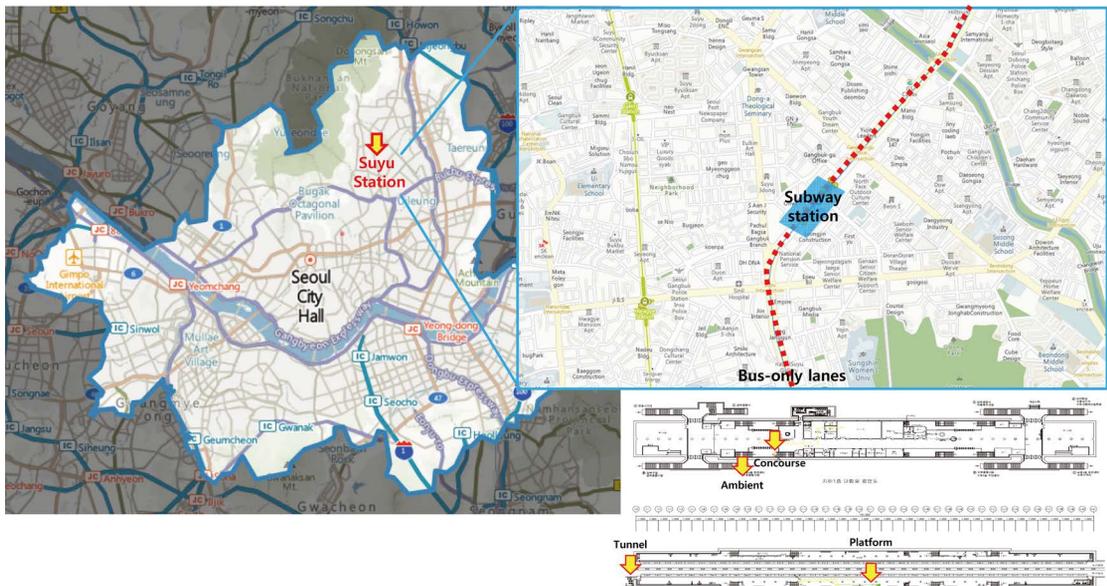


Fig. 1. Measurement points and position of air quality monitoring devices.

질에 의한 영향이 클 것으로 예상된다.

그림 1은 대상 역사와 측정 위치를 나타낸 것이다. 수유역은 타 역사와 다르게 외기와 승강장, 대합실, 터널 4개 지점의 공기질을 측정하고 있다. 외기는 수유역 7번 출구 상단에서 측정하며, 대합실은 수유역 1-2번과 7-8번 출입구 역무실 부근에, 승강장은 미아방면(하선) 승강장 5-4 출입구 부근에 설치되어 있다. 터널은 미아방면 PSD 바깥 첫 번째 기둥 옆에 설치되어 있다. 측정은 PM₁₀을 포함하여 이산화탄소(carbon dioxide, CO₂) 이산화질소(nitrate dioxide, NO₂), 일산화질소(nitrate monoxide, NO)의 4개 항목에 대해 이루어지고 있으나 터널의 경우 PM₁₀만을 측정하고 있어 터널과의 상관관계 분석 시에는 이를 고려하여 분석을 실시하였다.

2.2 자료수집 및 데이터 처리

실내외 영향분석을 위해 수유역에 설치된 실내공기질 관리 종합정보망 자료를 활용하였다. 수유역에 설치·운영 중인 측정장비는 환경부에서 고시하고 있는 대기오염공정시험기준 중 환경대기 중 미세먼지(PM₁₀)에 대한 공정시험 기준인 베타선흡수법 장비이다(MOE, 2021b). 본 장비는 16.7 LPM으로 등속흡인하도록 설계되어 있으며, 흡입부에 열선이 부착되어 흡입과정에서 간섭을 일으킬 수 있는 수분의 영향을 최소화하고, 장비 자체적으로 온습도를 측정하여 최종적으로 보정된 유량 정보를 제공한다. 질소산화물 또한 공정시험기준인 화학발광법에 준하는 장비를 사용하고 있다. 대상 역사에 대한 실내외 영향분석을 위해서는 동일 항목에 대해 장기적이고 안정적인 데이터 확보가 중요한데 대상 역사로 선정된 수유역은 터널, 승강장, 대합실, 외기 4개 지점에서 2018년부터 안정적으로 데이터를 확보하고 있다(표 1). 역사 실내외 영향분석을 위해 2019년 1월 1일 0시부터 2019년 12월 31일 23시까지 1시간 간격으로 오염물질 측정자료를 수집하였다. 오염물질 자료 외에 열차 운행횟수(Train Passing Number, TPN)와 환기가동률(Ventilation Rate, VR)을 추가로 수집하여 분석에 활용하였

Table 1. Measurement item of each location in Suyu station.

Location	PM ₁₀	NO	NO ₂	CO ₂
Ambient	○	○	○	
Concourse	○	○	○	○
Platform	○	○	○	○
Tunnel	○			

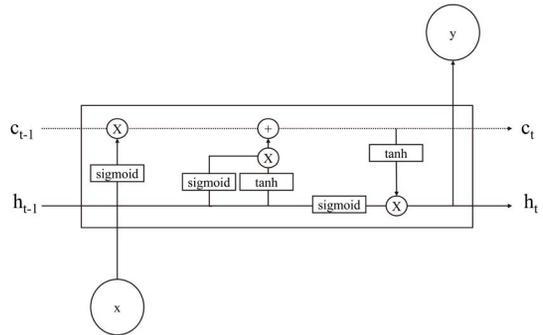


Fig. 2. Diagram of LSTM used in this study.

다. TPN은 시간당 상선과 하선의 열차 운행횟수의 합으로 활용하였으며, VR은 환기시스템이 가동되는 시간(7시~22시)에 따라 0~1 값으로 설정하였다. 확보된 자료를 대상으로 Sigmaplot 14.0 (Systat software Inc.)과 SPSS Statistics 24 (IBM Corp.)를 활용하여 통계분석과 자료처리를 하였다.

2.3 예측모델 구성

최근 다양한 분야에서 합성곱신경망(convolution neural network, CNN)과 순환신경망(recurrent neural network, RNN)에 기반한 시계열 예측 모델이 제안되었다. 이러한 심층 신경망 모델은 자연어 처리 및 음성 처리뿐만 아니라 의료 분야에서 인식하는 비디오 시퀀스 및 도구의 마모 상태를 예측하기 위한 기계적 상태 모니터링에도 사용되고 있다(Mahata et al., 2019; Wang et al., 2016; Sainath et al., 2015). 예측을 위하여 RNN 기법 중 하나인 LSTM(long short term memory) 기법을 적용하였으며, LSTM의 기본 구조를 그림 2에 나타내었다(Park, 2021).

Table 2. Input data of each case used for prediction.

Prediction	Case	Input data
PM ₁₀ _Conc (in 1 hour)	Case 1	PM _{10_out} , PM _{10_plat}
	Case 2	PM _{10_out} , PM _{10_plat} , TPN, VR
	Case 3	PM _{10_out} , PM _{10_plat} , PM _{10_tunn} , TPN, VR
	Case 4	PM _{10_out} , NO _{2_out} , NO _{2_conc} , CO _{2_conc} , NO _{2_conc} , NO _{2_conc} , PM _{10_plat} , CO _{2_plat} , NO _{2_plat} , NO _{2_plat} , PM _{10_tunn} , TPN, VR
PM ₁₀ _plat (in 1 hour)	Case 5	PM _{10_out} , PM _{10_conc}
	Case 6	PM _{10_out} , PM _{10_conc} , TPN, VR
	Case 7	PM _{10_out} , PM _{10_conc} , PM _{10_tunn} , TPN, VR
	Case 8	PM _{10_out} , NO _{2_out} , NO _{2_conc} , PM _{10_conc} , CO _{2_conc} , NO _{2_conc} , NO _{2_conc} , CO _{2_plat} , NO _{2_plat} , NO _{2_plat} , PM _{10_tunn} , TPN, VR
PM ₁₀ _Tunn (in 1 hour)	Case 9	PM _{10_out} , PM _{10_plat}
	Case 10	PM _{10_out} , PM _{10_plat} , TPN, VR
	Case 11	PM _{10_out} , PM _{10_conc} , PM _{10_plat} , TPN, VR
	Case 12	PM _{10_out} , NO _{2_out} , NO _{2_conc} , CO _{2_conc} , NO _{2_conc} , NO _{2_conc} , PM _{10_plat} , CO _{2_plat} , NO _{2_plat} , NO _{2_plat} , PM _{10_tunn} , TPN, VR

LSTM은 기존 RNN의 오차문제 (gradient vanishing)를 해결하기 위해 적용되었다. RNN은 내부에 루프를 가진 네트워크로, 정보의 지속성을 보장한다. 하지만 레이어가 깊어질수록 초기의 가중치가 더는 학습에 영향을 주지 못하는 문제가 발생하며, 이것이 gradient vanishing 문제이다. LSTM은 메모리 셀을 통해 장기 메모리를 보존하는 특징을 가진다. RNN과는 차별되는 메모리 특성 때문에 장기 시퀀스의 시간 특성을 추출하는 데 유용하다. LSTM은 입력, 출력, 망각의 세 개의 게이트와 비선형성의 특징을 가지는 활성화 함수는 장기 의존성 문제를 해결하며 시계열 데이터나 자연어 처리에서 활발히 사용되고 있다. LSTM의 가장 중요한 특성은 sequence를 저장하고 이를 학습에 활용하기 때문에 예측을 위해서도 많이 활용되고 있다(Hong and Hur, 2021).

수집된 14가지 데이터를 입력변수로 활용하였으며, 변수 선정에 따른 예측성능 변화를 확인하고자 하였다. LSTM 모델에 입력변수를 적용하기 위해서 모든 입력변수는 정규화(normalization)를 수행한 후 데이터를 활용하였다. 입력변수 중 80% (1월~10월 초)는 모델 학습에 활용하였으며, 나머지 20% (10월 중순~12월)는 학습된 모델을 검증하는 데 활용하였다. LSTM에 모델구조는 Dense 2로 설정하였으며, learning rate는 0.01, epoch를 10000, batch size는 120을 적

용하였다.

예측모델은 각 위치별 1시간 후 PM₁₀ 농도 예측을 목적으로 구성하였으며, 입력변수의 조합을 12가지로 분류하여 각 Case별로 각각 예측을 수행하였다(표 2).

Case 1~4에서는 1시간 후 대합실 PM₁₀을 예측하였으며, Case 5~8은 승강장 PM₁₀, Case 9~12는 터널 PM₁₀을 예측하였다. 변수선정에는 인접해 있는 곳의 PM₁₀ 농도만을 수행하였으며 (Case 1, 5, 9), VR과 TPN을 추가하여 예측을 수행하였다(Case 2, 6, 10). Case 3, 7에서는 터널 데이터를 추가하여 예측성능을 확인하였으며, Case 11에서는 외기, 대합실, 승강장 PM₁₀과 TPN, VR을 변수로 활용하여 예측을 수행하였다. Case 4, 8, 12에서는 입력변수 전체를 적용하여 예측을 수행하였다.

예측성능 평가기준으로 결정계수(coefficient of determination, R²), 평균 제곱근 오차(root mean square error, RMSE)와 평균 절대 백분율 오차(mean absolute percentile error, MAPE)를 활용하였다. RMSE는 추정값 또는 모델이 예측한 값과 실제 환경에서 관찰되는 값의 차이를 다룰 때 흔히 사용하는 척도이며, 정밀도(precision)를 표현하는 데 적합하다. 각각의 차이값은 잔차라고도 하며, RMSE는 잔차들을 하나의 척도로 종합할 때 사용된다(Park, 2021).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}$$

결정계수(R²)는 모델의 예측값이 실측값과 얼마나 일치하는지를 나타내는 지표이다. R²는 0에서 1 사이의 값을 가지며 1에 가까울수록 예측력이 좋은 모델이다. 결정계수는 아래 식으로 정의되며, n은 데이터의 개수를 나타내고, y_i는 실측값을 의미하며, \hat{y}_i 는 예측값을 의미한다.

$$R^2 = \left(\frac{n \sum_{i=1}^n y_i \hat{y}_i - (\sum_{i=1}^n y_i)(\sum_{i=1}^n \hat{y}_i)}{\sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2} \sqrt{n \sum_{i=1}^n \hat{y}_i^2 - (\sum_{i=1}^n \hat{y}_i)^2}} \right)^2$$

MAPE는 측정값들의 단위가 다른 경우, 오차 평균의 크기가 크게 차이나게 되는데 오차 평균의 크기가 더 작은 모델을 좋은 모델로 평가된다. RMSE가 단순히 오차의 절대값 크기를 비교한다면, MAPE는 오차의 비율로 모델을 비교할 수 있는 지표로 활용되어진다. 오차 평균의 크기가 크게 차이나는 모델을 비교할 수 있다.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

3. 결과 및 고찰

3.1 도시철도 역사 실내외 오염특성

도시철도 역사는 지하공간을 이용하면서 지상공간의 활용도를 높인 반면, 지하구간에서 배출된 오염물질에 대한 자연적인 확산·희석효과를 기대하기 어려운 구조로 되어 있다. 이를 개선하기 위해 전통적으로 도시철도 운행에 따라 발생하는 열차풍을 이용한 자연환기와 공조설비를 이용한 기계환기가 활용되어 왔다. 최근에는 환기만으로는 터널 및 역사 내 오염물질 제거가 어렵다고 판단되어 공기정화장치가 추가로 설치되어 운영되고 있다(Kwon, 2018). 도시철도 역사는 외부에서 유입된 오염물질과 터널에서 발생된 오염물질들이 혼재되어 존재하며, 환기 및 공조설비 운영, 공기청정기 가동에 따라 오염상태가 변화한다. 그림 3

은 수유역에서 2019년 1월부터 12월까지 1년간 오염물질의 농도변화를 나타낸 것이다. 연간 측정데이터 중 약 1달 이상 데이터가 누락된 구간이 있는데 이는 장비관리(정도관리, 등가성평가 등)를 위한 기간으로 데이터 분석에서 제외하였다.

연평균 PM₁₀ 농도는 외기가 44.1 µg/m³으로 가장 낮게 나타났고, 대합실 61.9 µg/m³, 승강장 146.0 µg/m³, 터널 289.7 µg/m³로 나타났다. 외기는 44.1 µg/m³으로 국가 연평균 기준인 50 µg/m³보다 낮게 나타났으며, 2019년도 서울 평균농도인 42 µg/m³과 유사한 수준으로 확인되었다(NIER, 2020). 하지만 대합실로부터 승강장, 터널로 갈수록 농도가 증가하여 각각 1.4배, 3.3배, 6.6배로 농도 차가 급격히 증가하였고, 특히 승강장의 경우 실내공기질 관리법에서 제시하고 있는 환경기준인 100 µg/m³보다 높은 수준으로 확인되었다(MOE, 2021a).

NO와 NO₂는 연소과정에서 주로 발생되며, 도심지역의 경우 자동차 배기가스가 주요 배출원으로 알려져 있다(Yeo, 2017; Kwon et al., 2015; Chun and Song, 2004). 자동차에서 연소에 의해 직접적으로 배출된 NO는 대기 중에 배출되자마자 산화되어 NO₂로 전환된다. NO는 터널에서 측정을 하지않아 제외되었고, 외기와 대합실, 승강장의 농도가 각각 0.074 ppm, 0.043 ppm, 0.038 ppm으로 지상으로부터 지하 깊숙이 들어갈수록 낮아지는 경향을 보였다. 표준편차가 외기가 0.053으로 크게 나타난 반면, 대합실과 승강장은 둘다 0.016으로 적게 나타나 상대적으로 외기보다 역사 내부의 농도변화가 적은 것으로 확인되었다. NO₂는 국가 환경기준이 0.03 ppm으로 2019년 서울시의 연평균 농도는 0.028 ppm으로 확인되었고, 수유역 외기의 농도는 이보다 높은 0.039 ppm으로 나타나 환경기준을 초과한 것으로 나타났다. 일반적으로 도심지역에 위치한 지하 역사의 경우 차량운행에 의해 발생된 배출가스가 도로변 인근 환기구를 통해 역사로 유입되어 공기질을 악화시키는 것으로 알려져 있다(Gonzlez et al., 2014; Lee et al., 2014). 자동차로부터 직접 배출되는 NO가 지상으로부터 지하로 내려갈수

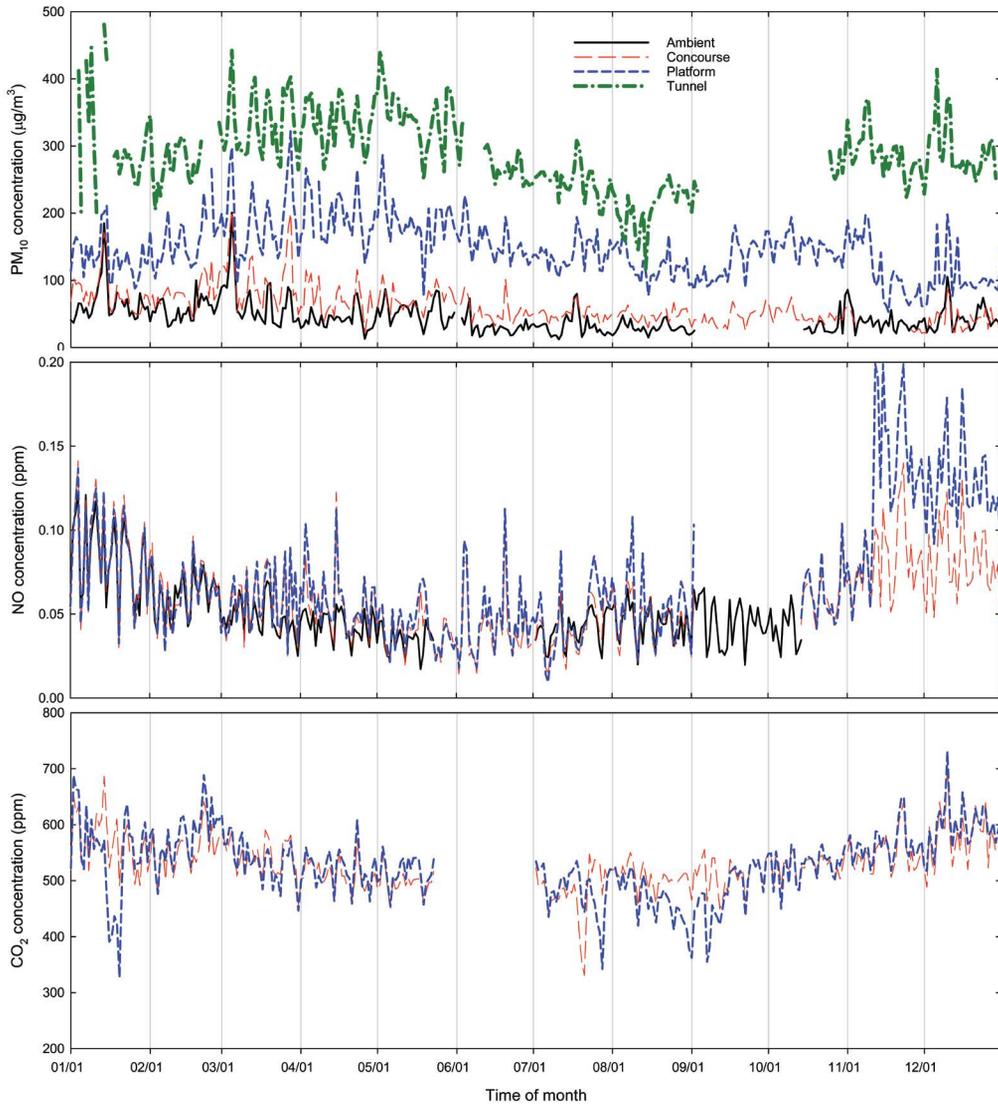


Fig. 3. Daily variation of PM_{10} , NO, and CO_2 concentration measured in Suyu station.

록 농도가 낮아진 반면, NO_2 의 농도가 증가한다는 것은 다른 내부 배출원이 있거나 NO와 반응하여 NO_2 를 생성하는 다른 물질이 있다는 것을 의미한다. 추후 역사 내부에 대한 세부적인 조사를 통해 이에 대한 원인 규명이 필요할 것으로 판단된다.

CO_2 는 화석연료의 연소과정이나 재실자의 호흡을 통해 배출되는데, 지하 역사의 경우 대부분 재실자의

영향으로 볼 수 있다. 대합실과 승강장에서 측정된 CO_2 농도는 각각 530 ppm과 529 ppm으로 유사한 수준을 보였고, 편차는 대합실보다 승강장이 크게 나타났다. 이는 승강장의 경우 다수의 인원이 몰려있다가 열차 유입시 순간적으로 탑승 후 떠나면서 배출원의 급격한 감소현상이 자주 발생함에 따른 영향으로 판단된다. 승강장과 대합실의 CO_2 농도는 모두 실내 환

Table 3. Summary of indoor air pollutants measured in Suyu station.

		Ambient	Concourse	Platform	Tunnel
PM ₁₀ ($\mu\text{g}/\text{m}^3$)	Mean	44.1	61.9	146.0	289.7
	S.D.	27.0	38.9	80.0	148.4
	Max	279.4	374.0	494.0	884.0
	Min	0.4	0.1	0.1	2.1
NO (ppm)	Mean	0.074	0.043	0.038	N/D
	S.D.	0.053	0.016	0.016	N/D
	Max	0.348	0.267	0.445	N/D
	Min	-	0.006	0.008	N/D
NO ₂ (ppm)	Mean	0.039	0.059	0.069	N/D
	S.D.	0.037	0.046	0.058	N/D
	Max	0.276	0.5	0.5	N/D
	Min	-	-	-	N/D
CO ₂ (ppm)	Mean	N/D	530	529	N/D
	S.D.	N/D	74	103	N/D
	Max	N/D	932	1,133	N/D
	Min	N/D	301	301	N/D

※ N/D: no data

경기준인 1,000 ppm 이내에서 유지되는 것으로 나타났다. 수유역에 대한 1년간 세부 농도자료를 표 3에 나타냈다.

그림 4는 수유역에서 측정된 자료를 활용하여 시간대에 따른 농도변화와 이때 차량운행량을 비교한 것이다. 수유역 차량운행량은 시간대별 양방향 운행 대수 모두를 합산한 값이다.

그림 4의 (a)에서 PM₁₀ 농도는 0시를 기점으로 감소하기 시작하여 5시경 최소농도를 보이고, 이후 차량운행이 시작하면서 8시에 최대 농도를 보인다. 이후 감소하여 10시부터 15시까지는 소폭 증가를 보이다가 퇴근시간때 다시 한번 증가하는 형태를 보인다. 농도의 편차가 있긴 하지만 대합실, 승강장, 터널 모두 유사한 경향을 보인다. 터널의 경우 새벽시간대 외기와 유사한 농도를 보이다가 차량운행과 동시에 급격하게 증가하는 것을 확인할 수 있었다. 터널에서 차량운행은 오염물질 발생의 주요 원인으로 알려져 있다. 선행 연구에서 PSD 설치 이후 터널과 승강장의 분리로 어느 정도 승강장의 공기질이 개선된 것으로 보고되고 있으나, 아직까지도 영향을 미치고 있는 것으로

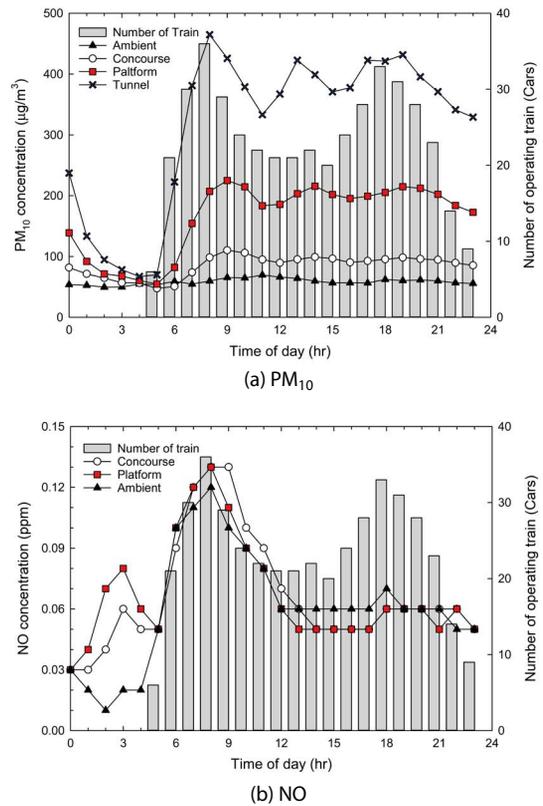


Fig. 4. Diurnal variation of PM₁₀ and NO concentration by train operating.

확인되었다. 일부 선행연구에서도 이와 유사한 결과를 보고한 바 있다(Kim *et al.*, 2020).

가스상 오염물질은 자동차 배기가스에서 1차적으로 분류되는 NO를 대상으로 분석하였다. NO는 0시를 기점으로 외기의 농도는 감소하기 시작하지만 대합실과 승강장의 농도는 증가하기 시작한다. 앞서 외기보다 승강장과 대합실의 NO₂ 농도가 높은 것으로 확인할 수 있었는데 시간 특성상 배출원이 없으므로 예상되는 새벽시간대 NO 농도가 증가하는 것은 역사 내부에 또 다른 반응을 일으키거나 영향을 미치는 인자가 존재한다는 것을 의미한다. 이에 대한 것은 추후 수유역 내부환경조사 및 추가분석을 통해 재해석이 필요할 것으로 판단되며, 본 연구에서는 세부 분석은 제외하였다. 차량운행이 시작되는 5시를 기점으로

Table 4. Pearson correlation coefficient between air pollutants (PM₁₀, NO) and the number of trains passing through Suyu station.

	PM ₁₀				NO			Number of train
	Ambient	Concourse	Platform	Tunnel	Ambient	Concourse	Platform	
PM ₁₀	1							
Concourse	.671**	1						
Platform	.683**	.966**	1					
Tunnel	.664**	.884**	.962**	1				
NO					1			
Concourse	.492*	.291	.320	.432*	.874**	1		
Platform	.221	.039	.060	.198	.733**	.931**	1	
Number of train	.311	.504*	.566*	.755**	.583**	.491*	.495*	1

※ **p<0.01, *p<0.05

로 PM₁₀과 마찬가지로 8시까지 급격한 증가를 보인 후 감소하기 시작한다. 이후 12시~17시경까지 유사한 농도수준을 보인 후 17시~19시경 소폭 증가 후 감소하였다. 차량운행에 따라 NO의 농도값이 증감하는 것으로 보일 수 있으나 도시철도 운행 과정에서 NO의 배출원이 없고, 수유역 내부 환기시설이 7시부터 22시까지 운행된다는 것을 감안했을 때 이는 터널이나 역사 내 요인보다는 외부로부터 유입된 오염원의 영향일 것으로 판단된다. 수유역의 경우 버스중앙차선을 포함한 왕복 6차선이 가운데 있고, 그 양옆으로 저상형 환기구가 위치해 있다. 도로 운행차량에서 배출된 오염물질은 차량운행에 따라 피스톤 효과로 도로 양옆으로 밀려나고 이때 바닥면에 위치한 환기구를 통해 역사 내부로 유입되어 영향을 미치고 있는 것으로 판단된다. 선행연구에서도 도로변에 위치한 환기구를 통해 외부 오염물질이 유입되어 역사 내 공기 질에 영향을 미친 사례가 다수 보고된 적이 있다 (Park et al., 2018; Lee et al., 2014; Kim et al., 2004).

3.2 변수 간 상관성 분석

표 4는 수유역에서 측정된 자료를 이용하여 터널과 역사 내부(승강장, 대합실)를 중심으로 오염물질간

상관성 분석을 실시한 결과이다. 대상공간은 외기와 승강장, 대합실, 터널 4개 지점을 선정하였고, 4개 공간에 대해 측정값 중 모두 해당되는 PM₁₀과 NO를 분석물질로 선정하였다. NO₂는 일부 구간 이상치가 발견되어 상관분석에서 제외하였다. 분석결과 PM₁₀ 기준 승강장과 대합실의 상관성이 가장 높게(0.966) 나타났고, 그 뒤를 이어 승강장과 터널(0.962), 대합실과 터널(0.884), 차량운행대수와 터널(0.755)로 나타났다. 앞서 차량 이동에 따른 역사 내 농도변화에서도(그림 4의 (a)) 차량운행 대수와 터널, 대합실, 승강장의 농도변화가 유사하게 나타났는데, 상관성 역시 매우 높은 수준인 것으로 확인되었다. NO 역시 PM₁₀과 동일하게 대합실과 승강장의 상관성이 가장 높은 것(0.931)으로 확인되었고, 그 뒤를 이어 외기와 대합실(0.874), 외기와 승강장(0.733)으로 확인되었다. 결과적으로 PM₁₀의 경우 차량운행에 따라 발생된 오염물질이 터널과 승강장, 대합실에 영향을 지배적으로 미치고 있으며, NO는 내부 발생보다는 외부에서 유입되어 미치는 영향이 더 큰 것으로 확인되었다.

3.3 예측모델 적용 및 평가

각 Case별로 예측한 결과를 표 5에 나타내었고, 그

림 5에 대합실, 터널, 승강장에서 측정된 PM₁₀과 예측된 PM₁₀의 산점도를 나타내었다.

1시간 후 대합실 PM₁₀ 예측한 결과를 Case 1~4에 나타내었다. Case 1에서 인접한 위치의 PM₁₀ 정보만을 활용하여 예측한 결과, R²가 0.36으로 낮게 나타났다. Case 2에서 대합실 PM₁₀ 예측 결과 중 가장 높은 R²을 보였으나 이 또한 0.42로 낮은 수준이었다. Case 2에 터널 PM₁₀ 농도 변수를 입력한 Case 3에서는 R²가 높아질 것으로 예상하였으나, 0.40으로 오히려 낮아진 것을 확인할 수 있었으며, 모든 입력변수를 활용한 Case 4에서는 가장 낮은 R²인 0.29를 확인할 수 있었다. 본 예측 결과에서 예측에 활용될 입력변수는 많은 정보가 아닌 유의미한 결과를 반영했을 때 높은 예측 결과가 도출되는 것을 확인할 수 있었다.

Case 5~8은 1시간 후 승강장 PM₁₀ 예측한 결과이다. Case 5에서는 미세먼지 농도 정보만을 활용하였을 경우 0.09로 모든 경우 중 가장 낮은 R²와 가장 높은 RMSE (50.59)를 보였다. Case 6은 Case 5에서 활용하였던 입력변수에 TPN과 VR을 추가하여 예측을 수행하였는데, 예측 결과 R²가 0.69로 가장 높게 나타났으며, 전체 예측 결과 중 가장 낮은 RMSE (28.28)를 보였다. Case 7과 Case 8의 예측 결과는 Case 6보다 예측 성능이 낮은 것으로 확인되어, 예측 변수 선정의 중요성을 다시 확인할 수 있었다.

Table 5. Result of prediction accuracy at each site.

Prediction	Case	R ²	RMSE	MAPE
PM ₁₀ Concourse (in 1 hour)	Case 1	0.36	28.39	37.65
	Case 2	0.42	26.81	36.62
	Case 3	0.40	27.98	36.95
	Case 4	0.29	25.21	41.57
PM ₁₀ Platform (in 1 hour)	Case 5	0.09	81.47	50.59
	Case 6	0.69	44.80	28.28
	Case 7	0.63	46.83	28.56
	Case 8	0.62	50.18	29.71
PM ₁₀ Tunnel (in 1 hour)	Case 9	0.31	136.04	58.96
	Case 10	0.64	92.70	31.94
	Case 11	0.64	93.41	32.82
	Case 12	0.66	92.70	31.30

Case 9~12는 1시간 후 터널 PM₁₀에 대한 예측 결과이다. Case 9에서는 가장 높은 RMSE (136.04)을 보였고, Case 10과 Case 11에서 R²가 0.64로 높은 수치를 보였으나, Case 6에 비해 낮은 R²와 높은 RMSE를 보여 정확도와 정밀도 부분에서 낮게 나타났다. Case 12 역시 0.66으로 R² 값은 높은 수준이었으나 앞선 Case 10 및 11과 같이 높은 RMSE (92.70)을 보여 예측모델로서의 적합성이 떨어지는 것을 확인할 수 있었다.

그림 6은 앞선 분석에서 높은 Case로 분류된 Case 2, 6, 10에 대해 PM₁₀을 대상으로 예측농도와 실측농도에 대한 변화패턴을 나타낸 것이다. 대합실을 대상으로 하는 Case 2의 경우 실측값과 예측값 간에 상당한 편차가 있는 것으로 나타났고, 터널을 대상으로 한 Case 10의 경우 역시 예측값이 실측값보다 낮은 수준에서 변화하는 것으로 나타났다. 하지만 승강장을 대상으로 한 Case 6의 경우 대합실과 터널을 대상으로 한 Case 2와 Case 10에 비해 측정값과 예측값의 변화패턴이 유사하게 변화하는 것을 확인할 수 있다.

RMSE로 지하 역사 PM₁₀ 예측성능을 평가했을 경우, 대합실, 승강장, 터널 순으로 예측성능을 확인할 수 있다. RMSE 값은 실측값과 예측값의 scale에 영향을 많이 받기 때문에 상대적으로 외기 PM₁₀이나 대합실 PM₁₀보다 높은 농도를 나타내는 터널에서 더 높은 RMSE이 나올 수 밖에 없다. 이와 같은 문제점을 보완하기 위하여 MAPE로 모델을 평가하였고 예측 결과는 승강장, 터널, 대합실 순으로 확인되었으며, R²도 같이 고려한다고 했을 때 대합실보다 터널에서 더 좋은 예측성능이 확인되었다. 이를 통해 그동안 시도되지 않았던 터널 PM₁₀ 예측에 대한 가능성을 확인하였다. Park *et al.* (2018)은 서울시 주요 환승역사 6개를 대상으로 1시간 후 승강장 PM₁₀을 예측한 결과, 0.68~0.80의 R²와 30.54~59.78의 RMSE를 보고한 바 있다. 본 예측모델에서도 Case 6에서 R² 0.69, RMSE 44.80으로 유사한 것을 확인할 수 있었다. 이를 통하여 자동측정망 데이터만을 활용하여 승강장 PM₁₀ 농도를 확인할 수 있으며, 그동안 수행되지 않은 터널 미세먼지 예측 가능성을 확인하였다.

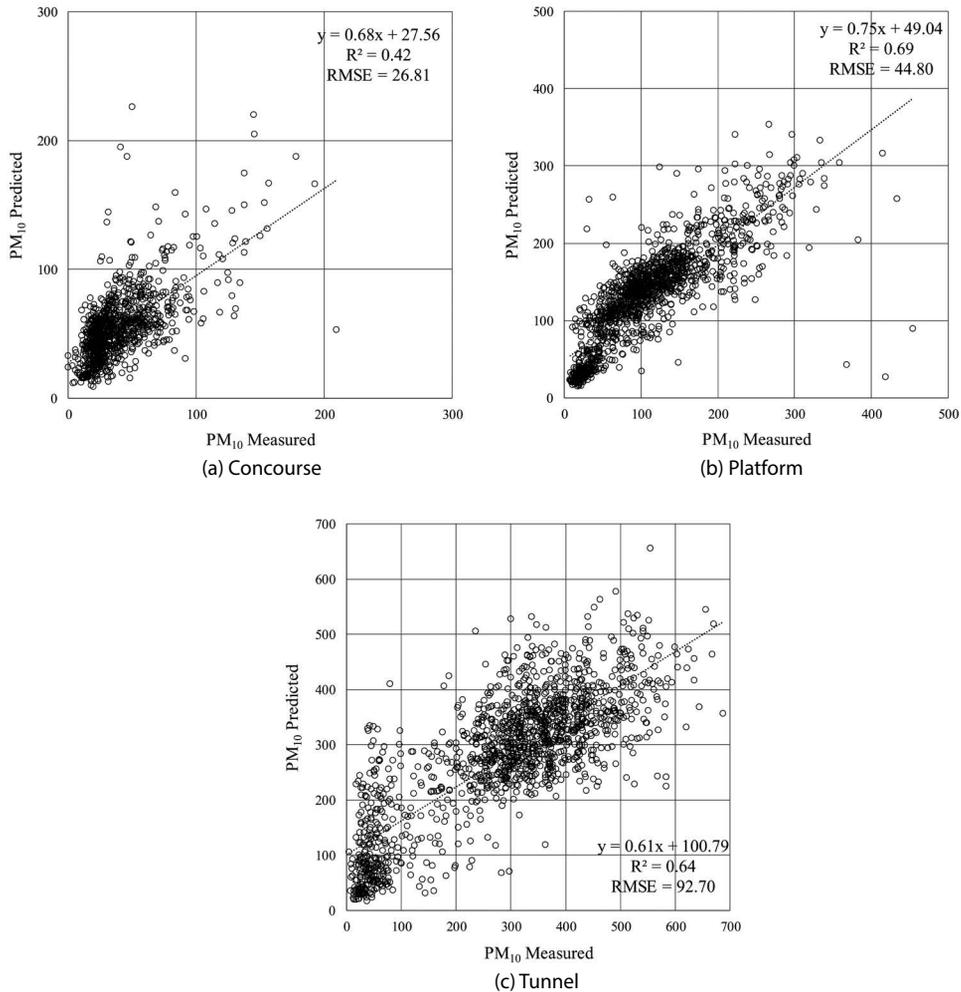


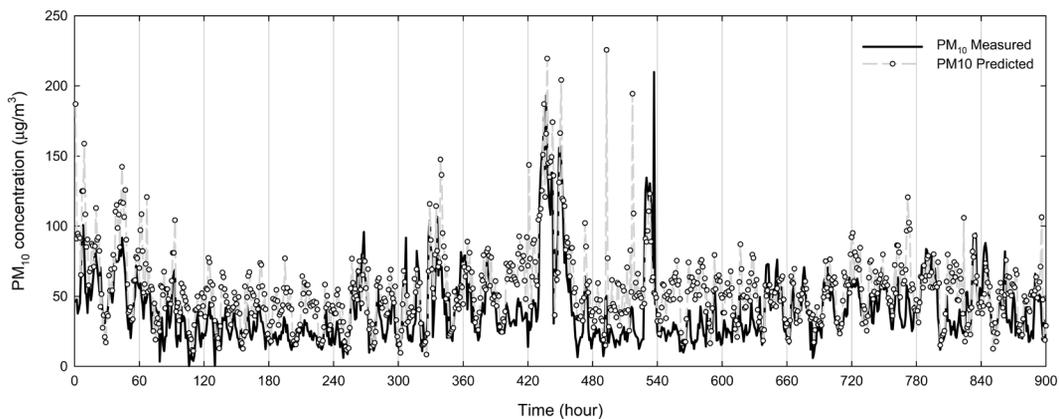
Fig. 5. Correlation of results between PM₁₀ measured and PM₁₀ predicted at each point using LSTM: (a) Case 2, (b) Case 6, (c) Case 10.

4. 결 론

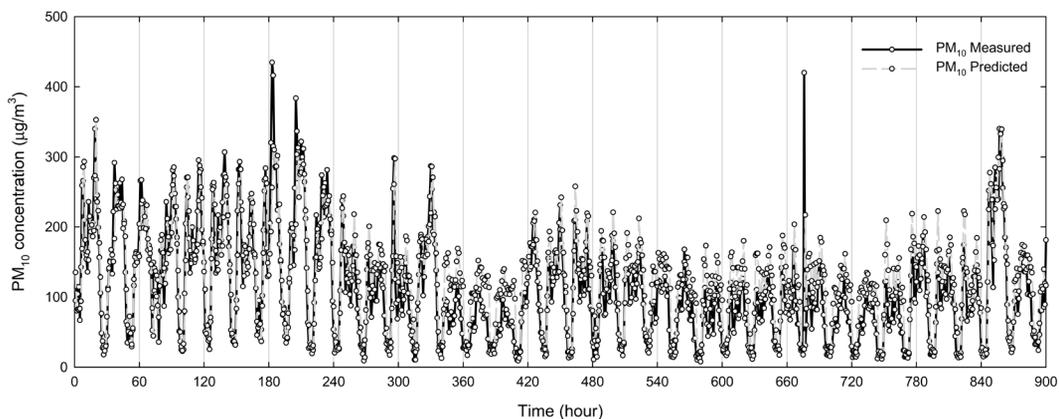
최근 고농도 미세먼지 발생사례 증가와 함께 대기 환경에 대한 국민적 관심이 증가하고 있으며 이와 더불어 대도시 주요 교통수단인 도시철도 역사 내 공기 질에 대한 관심과 우려 또한 증가하고 있다. 본 연구에서는 수도권에 위치한 수유역을 대상으로 2019년도 실시간 측정자료를 활용하여 지상과 역사(대합실, 승강장, 터널)의 상호 영향을 분석하고, 이를 활용한

공기질 변화를 예측하였다.

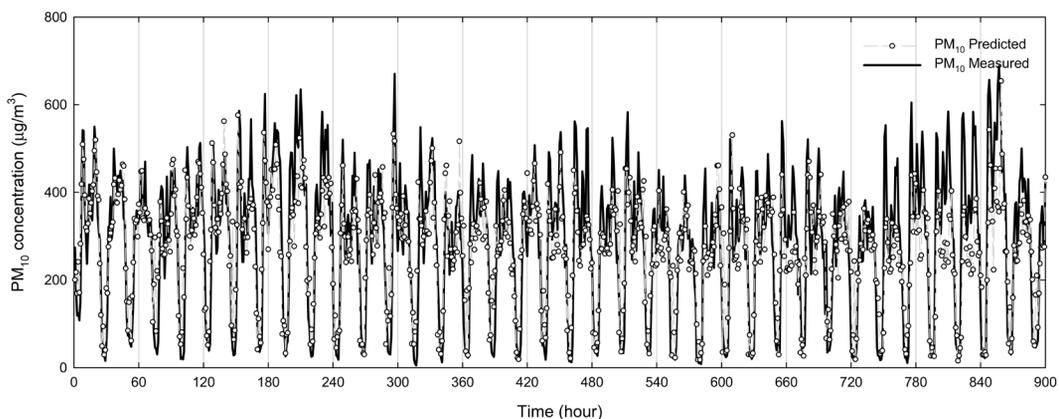
1. 수유역을 대상으로 PM₁₀ 농도는 외기가 44.1 µg/m³로 연평균 대기 환경기준을 만족하였으나 승강장의 경우 146.0 µg/m³으로 실내공기질 유지기준을 초과한 것으로 나타났다. 농도는 외기(44.1 µg/m³) < 대합실(61.9 µg/m³) < 승강장(146.0 µg/m³) < 터널(289.7 µg/m³)으로 나타나 외부로부터 지하 심도가 깊어질수록 농도가 높게 나타났다.
2. NO는 터널을 제외하고 외기(0.074 ppm)로부터 대



(a) Concourse



(b) Platform



(c) Tunnel

Fig. 6. Comparison between measured PM₁₀ and predicted PM₁₀ at each site; (a) Case 2, (b) Case 6, (c) Case 10.

합실 (0.043 ppm), 승강장 (0.038 ppm)으로 심도가 깊어질수록 농도가 낮아졌고, NO₂는 반대로 외기 (0.039 ppm)로부터 대합실 (0.059 ppm), 승강장 (0.069 ppm)으로 갈수록 농도가 높아지는 경향을 보였다. CO₂는 대합실과 승강장에서 각각 530 ppm과 529 ppm으로 유사한 수준이고, 실내공기질 기준을 만족하였다.

3. 시간대별 오염도 분석결과 PM₁₀의 경우 4시경 외기와 대합실, 승강장, 터널 모두 유사한 수준으로 가장 낮은 농도를 보였고, 차량운행이 시작된 5시를 기점으로 증가하여 8시경 최대농도를 보였다. 상관관계 분석 결과 대합실과 승강장의 상관계수가 매우 높게 (0.966) 나타났고, 터널과 승강장 (0.962), 터널과 대합실 (0.884), 터널과 운행차량 대수 ((0.755)로 나와 역사 내 PM₁₀에 대해서는 운행차량에 의한 기여도가 매우 높은 것으로 확인되었다. 이는 기존 연구 논문 (Park, 2021; Kim *et al.*, 2020)에 제시된 결과와도 유사한 것으로 확인되었다.
4. NO의 경우 2시경 외기 농도가 가장 낮은 농도를 보인 후 4시를 기점으로 8시쯤 최대농도를 보이는 반면, 승강장과 대합실은 0시부터 3시까지 농도증가를 보였다. 외기의 경우 새벽시간대 차량운행이 감소하면서 농도가 떨어졌다가 차량운행이 증가하기 시작하는 5시를 시작으로 출퇴근시간대 최대농도를 보인다. 승강장과 대합실은 원인을 알 수 없는 새벽대 농도증가를 보이는데 이에 대해서는 추후 역사 내 배출원과 작업조건 등을 동반한 분석이 필요하다. 상관관계 분석 결과 승강장과 대합실의 상관계수가 가장 높게 (0.931) 나타났으며, 외기와 대합실 (0.874), 외기와 승강장 (0.733) 순으로 분석되어 역사 내 NO에 대한 영향은 외기의 영향이 큰 것으로 나타났다.
5. 실시간 측정자료를 기반으로 머신러닝 기법 중 하나인 LSTM 기법을 적용하여 1시간 뒤 미래농도에 측을 수행하였는데, 승강장 PM₁₀ 농도를 예측하기 위해 외기 PM₁₀, 대합실 PM₁₀, 환기 가동률, 열차 운행횟수를 입력변수로 선정하여 학습시킨 예측모

델 (Case 6)의 R²가 0.69로 가장 높은 예측 결과를 보였다. 이는 대상지점에 대한 직접적인 측정·분석 자료가 없어도 기존 자료를 입력자료로 활용하여 학습시킨 예측모형을 이용하여 미래예측 및 이를 활용한 관리방안 마련이 가능하다는 것을 의미한다.

본 연구를 통해 역사 PM₁₀은 열차 운행에, NO는 외부유입에 의한 영향이 크다는 것을 확인할 수 있었고, 향후 이들 오염물질에 대한 관리를 위해 환기대책과 공기청정기/공조설비 운영 계획 수립이 필요할 것으로 나타났다. 특히 최근 역사 내 공기질 측정을 위해 다수의 측정장비들이 설치·운영되고 있는데 이렇게 쌓인 정보들을 활용하여 미래 공기질을 예측하여 관리방안 마련을 위한 정보로 활용할 수 있다는 것도 알 수 있었다. 추후 지속적으로 축적될 지하 역사 내 측정 빅데이터에 머신러닝 기법을 잘 활용한다면 효과적인 관리방안 마련이 가능할 것으로 판단된다.

감사의 글

서울특별시 서울산업진흥원 <서울글로벌챌린지 2021> 사업을 통해 우수 논문으로 선정되어 작성된 논문입니다.

References

- Birenzvige, A., Eversole, J., Seaver, M., Francesconi, S., Valdes, E., Kulaga, H. (2003) Aerosol characteristics in a subway environment, *Aerosol Science and Technology*, 37(3), 210-220. <https://doi.org/10.1080/027868203000941>
- Chaloulakou, A., Grivas, G., Spyrellis, N. (2003) Neural network and multiple regression models for PM₁₀ prediction in Athens: A comparative assessment, *Journal of the Air & Waste Management Association*, 53, 1183-1190. <https://doi.org/10.1080/10473289.2003.10466276>
- Chillrud, S.N., Epstein, D., Ross, J.M., Sax, S.N., Pederson, D., Spengler, J.D., Kinney, P.L. (2004) Elevated airborne exposures of teenagers to manganese, chromium, and

- iron from steel dust and New York city's subway system, *Environmental Science and Technology*, 38(3), 732-737. <https://doi.org/10.1021/es034734y>
- Chellali, M.R., Abderrahim, H., Hamou, A., Nebatti, A., Janovec, J. (2016) Artificial neural network models for prediction of daily fine particulate matter concentrations in Algiers, *Environmental Science and Pollution Research*, 23(14), 14008-14017. <https://doi.org/10.1007/s11356-016-6565-9>
- Cho, K., Jung, Y., Kang, C., Oh, C. (2019a) Conformity assessment of machine learning algorithm for particulate matter prediction, *Journal of the Korea Institute of Information and Communication Engineering*, 23(1), 20-26, (in Korean with English abstract). <https://doi.org/10.6109/jkiice.2019.23.1.20>
- Cho, K., Lee, B.Y., Kwon, M., Kim, S. (2019b) Air quality prediction using a deep neural network model, *Journal of Korean Society for Atmospheric Environment*, 35(2), 214-225, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2019.35.2.214>
- Chun, Y.N., Song, H.O. (2004) Numerical modeling of vehicular exhaust dispersion around building in urban, *Journal of Korean Society Environmental Engineers*, 26(5), 619-622, (in Korean with English abstract).
- Han, H., Lee, J.Y., Jang, K.J. (2014) Effect of platform screen doors on the indoor air environment of an underground subway station, *Indoor and Built Environment*, 24(5), 672-681. <https://doi.org/10.1177/1420326X14528731>
- Hong, C.W., Hur, K. (2021) Electric Power Load Forecasting of DP Ships by Using CNN-RNN Based DNN, *The Korean Society for Naval Science and Technology*, 4(2), 121-126. <https://doi.org/10.31818/JKNST.2021.09.4.2.121>
- Jung, H.J., Kim, B.W., Ryu, J.Y., Maskey, S., Kim, J.C., Sohn, J., Ro, C.U. (2010) Source identification of particulate matter collected at underground subway stations in Seoul, Korea using quantitative single-particle analysis, *Atmospheric Environment*, 44(19), 2287-2293. <https://doi.org/10.1016/j.atmosenv.2010.04.003>
- Kim, B.W., Jung, H.J., Song, Y.C., Lee, M.J., Kim, H.K., Kim, J.C., Sohn, J.R., Ro, C.U. (2010) Characterization of summertime aerosol particles collected at subway stations in Seoul, Korea using low-Z particle electron probe X-ray microanalysis, *Asian Journal of Atmospheric Environment*, 4(2), 97-105. <https://doi.org/10.5572/ajae.2010.4.2.097>
- Kim, J.B., Lee, S.B., Bae, G.N. (2019) Status of particulate matter pollution in urban railway environments, *Journal of Odor and Indoor Environment*, 17(4), 303-314, (in Korean with English abstract). <https://doi.org/10.15250/joie.2018.17.4.303>
- Kim, J.B., Lee, S.B., Woo, S.H., Kim, C.H., Lee, S., Lee, J.I., Bae, G.N. (2020) Diurnal variation of PM₁₀ concentration in the subway concourse and tunnel, *Journal of Odor and Indoor Environment*, 19(3), 231-240, (in Korean with English abstract). <https://doi.org/10.15250/joie.2020.19.3.231>
- Kim, K.H., Ho, D.X., Jeon, J.S., Kim, J.C. (2012) A noticeable shift in particulate matter levels after platform screen door installation in a Korean subway station, *Atmospheric Environment*, 49, 219-223. <https://doi.org/10.1016/j.atmosenv.2011.11.058>
- Kim, M.H., Han, K.S., Kim, H.S., Gong, H.S., Kim, C.H., Jeong, J.C. (2016) A study on diffusion and distribution of PM₁₀ in metropolitan subway tunnel, *Journal of Society for Urban Railway*, 4(4), 577-582, (in Korean with English abstract).
- Kim, S.D., Song, J.H., Lee, H. (2004) Estimation of train-induced wind generated by train operation in subway tunnels, *Korean Journal of Air Conditioning and Refrigeration Engineering*, 16(7), 652-658, (in Korean with English abstract).
- Korea Environment Coporation (KECO) (2021) Portal information service for indoor air quality management. URL: <https://www.inair.or.kr/info>
- Kwon, S., Kwon, S., Lee, J., Oak, S., Seo, Y., Park, S., Chon, M.S. (2015) Data evaluation methods for real driving emissions using portable emissions measurement system, *Transactions of the Korean Society of Mechanical Engineers-B*, 39(12), 965-973, (in Korean with English abstract). <https://doi.org/10.3795/KSME-B.2015.39.12.965>
- Kwon, S.B. (2018) A case study on smart indoor air quality management in underground tunnel, *Air Cleaning Technology*, 31(3), 39-46.
- Kwon, S.B., Jeong, W.T., Park, D.S., Kim, K.T., Cho, K.H. (2015) A multivariate study for characterizing particulate matter (PM₁₀, PM_{2.5}, and PM₁) in Seoul metropolitan subway stations, *Korea Journal of Hazardous Materials*, 297, 295-303. <https://doi.org/10.1016/j.jhazmat.2015.05.015>
- Lee, K.B., Park, J.S., Oh, M.D., Bae, S.J., Kim, S.D. (2014) Field measurement and estimation of ventilation flow rates by using train-induced flow rate through subway vent shafts, *Journal of Mechanical Science and Technology*, 28(7), 2677-2686. <https://doi.org/10.1007/s12206-014-0624-2>
- Lee, K.H., Lee, K.T. (2020) Characteristics of Atmospheric Aerosols

- Based on Column Measurements by Using Machine Learning Clustering, *Journal of Korean Society for Atmospheric Environment*, 36(5), 608-619, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2020.36.5.608>
- Lee, T.J., Jeon, J.S., Kim, S.D., Kim, D.S. (2010) A comparative study on PM₁₀ source contributions in a Seoul metropolitan subway station before/after installing platform screen doors, *Journal of Korean Society for Atmospheric Environment*, 26(5), 543-553, (in Korean with English abstract). <https://doi.org/10.5572/KOSAE.2010.26.5.543>
- Lee, Y.I., Jeong, W.S., Choi, K.M., Kim, T.S., Park, D.S. (2016) Estimation of particulate matters in subway tunnels using a kriging method, *Journal of Odor and Indoor Environment*, 15(2), 126-133, (in Korean with English abstract). <https://doi.org/10.15250/joie.2016.15.2.126>
- Liu, M., Zhu, C., Zhang, H., Zheng, W., You, S., Campana, P.E., Yan, J. (2019) The environment and energy consumption of a subway tunnel by the influence of piston wind, *Applied Energy*, 246, 11-23. <https://doi.org/10.1016/j.apenergy.2019.04.026>
- Loy, J., Heo, S., Yoo, C. (2020) Imputing missing indoor air quality data via variational convolutional autoencoders: Implications for ventilation management of subway metro systems, *Building and Environment*, 182, 107-135. <https://doi.org/10.1016/j.buildenv.2020.107135>
- Mahata, S., Das, D., Bandyopadhyay, S. (2019) Machine Translation Using Recurrent Neural Network on Statistical Machine Translation, *Journal of Intelligent Systems*, 28, 447-453. <https://doi.org/10.1515/jisys-2018-0016>
- Ministry of Environment (MOE) (1998) Air quality control in underground locations act.
- Ministry of Environment (MOE) (2006) Guideline for indoor air quality control in public transit.
- Ministry of Environment (MOE) (2020) Basic plan for management of indoor air quality.
- Ministry of Environment (MOE) (2021a) Indoor air quality control act.
- Ministry of Environment (MOE) (2021b) Standard methods for air quality monitoring.
- Ministry of Land, Infrastructure and Transport (MOLIT) (2020) Annual transport records of urban transit.
- Nam, K., He, S., Li, Q., Loy, J., Kim, M., Park, D., Yoo, C. (2020) A proactive energy-efficient optimal ventilation system using artificial intelligent techniques under outdoor air quality conditions, *Applied Energy*, 266, 1-17. <https://doi.org/10.1016/j.apenergy.2020.114893>
- Namgung, H.K., Song, J.H., Kim, S.Y., Kim, H.M., Kwon, S.B. (2016) Characteristics of indoor air quality in the over-ground and underground railway stations, *Journal of the Korean Academia-Industrial*, 17(5), 17-25, (in Korean with English abstract). <https://doi.org/10.5762/KAIS.2016.17.5.17>
- Nataional Institute of Environmental research (NIER) (2020) Atmospheric environmental annual report 2019.
- Park, S.C. (2021) A study on the prediction of concourse PM₁₀ by types of underground station in the metropolitan subway station, Doctor of philosophy thesis, University of Science and Technology, (in Korean with English abstract).
- Park, S.C., Kim, M., Kim, M., Namgung, H.G., Kim, K.T., Cho, K.H., Kwon, S.B. (2018) Predicting PM₁₀ concentration in Seoul metropolitan subway stations using artificial neural network (ANN), *Journal of Hazardous Materials*, 341, 75-82. <https://doi.org/10.1016/j.jhazmat.2017.07.050>
- Perez, P., Trier, A., Reyes, J. (2000) Prediction of PM_{2.5} concentrations several hours in advance using neural networks in Satiago, Chile, *Atmospheric Environment*, 34(8), 1189-1196. [https://doi.org/10.1016/S1352-2310\(99\)00316-7](https://doi.org/10.1016/S1352-2310(99)00316-7)
- Sainath, T.N., Vinyals, O., Senior, A., Sak, H. (2015) Convolutional, Long Short-term Memory, Fully Connected Deep Neural networks. In 2015 IEEE International Conference on Acoustics, Speech and Signal Processing, 4580-4584.
- Son, B.S., Jang, B.K., Park, J.A., Kim, Y.S. (2000) Indoor and outdoor NO₂ concentrations at subway station and personal NO₂ exposure of subway station workers, *Korean Society for Environmental Sanitary Engineers*, 15(4), 134-141, (in Korean with English abstract).
- Son, Y.S., Jeong, J.S., Lee, H.J., Ryu, I.C., Kim, J.C. (2014) Installation of platform screen doors and their impact on indoor air quality: Seoul subway trains, *Journal of the Air & Waste Management Association*, 64(9), 1054-1061. <https://doi.org/10.1080/10962247.2014.923350>
- Son, Y.S., Salama, A., Jeong, H.S., Kim, S., Jeong, J.H., Lee, H., Sunwoo, Y., Kim, J.C. (2013) The effect of platform screen doors on PM₁₀ levels in a subway station and a trial to reduce PM₁₀ in tunnels, *Asian Journal of Atmospheric Environment*, 7(1), 38-47. <https://doi.org/10.5572/ajae.2013.7.1.038>
- Wang, Q., Lin, J., Yuan, Y. (2016) Salient Band Selection for Hyperspectral Image Classification via Manifold Ranking, *IEEE Transactions on Neural Networks and Learning Systems*, 27(6), 1279-1289. <https://doi.org/10.1109/TNNLS.2015.2477537>

- Xayasouk, T., Lee, H., Lee, G. (2020) Air Pollution Prediction Using Long Short-Term Memory (LSTM) and Deep Autoencoder (DAE) Models, *Sustainability*, 12, 2570. <https://doi.org/10.3390/su12062570>
- Xu, B., Hao, J. (2017) Air quality inside subway metro indoor environment worldwide: A review, *Environment International*, 107, 33-46. <https://doi.org/10.1016/j.envint.2017.06.016>
- Yeo, G.K. (2017) Automotive after treatment systems for the future emission regulations, *Journal of the Korean Society of Automotive Engineers*, 39(4), 18-26, (in Korean with English abstract).

Authors Information

- 김종범 (충남연구원 서해안기후환경연구소 책임연구원)
(kjb0810@cni.re.kr)
- 박세찬 (주)나옴 개발팀 과장 (sechani3871@naver.com)
- 이용일 (한강유역환경청 환경감시단 환경연구사)
(freego83@korea.kr)
- 이선엽 (근로복지공단 직업환경연구원 전임연구원)
(lsy0298@comwel.or.kr)
- 김정호 (주)미세먼지연구소 소장 (jeonghoflux@naver.com)
- 박택신 (한국철도기술연구원 교통환경연구팀 수석연구원)
(dspark@krri.re.kr)