

Research Paper

실측소음도 기반 통계적 환경 소음지도 작성 및 활용 방안

김경민 · 장서일

서울시립대학교 일반대학원 환경공학과*, 서울시립대학교 환경공학부**

Statistical Environmental Noise Mapping Based on Measured Noise Data

Kyoungmin Kim* · Seo Il Chang**

Department of Environmental Engineering, University of Seoul*
School of Environmental Engineering, University of Seoul**

요약: 본 연구는 소음 노출 분포의 공간적 변동성 예측 및 모니터링을 목적으로, 서울시 S-DoT 측정망에서 수집한 실측소음도와 주변 도시구성요소(교통, 건물, 토지, 식생, 인구)를 다양한 버퍼 반경으로 집계 및 활용하여 기계학습 기반 통계적 환경소음 예측모형을 작성하고, 이를 서울시 전역에 적용하여 통계적 환경 소음지도를 작성 및 활용 방향을 제안하고자 한다. 연구결과, S-DoT 973개 설치지점을 기준으로 40m 버퍼(buffer) 반경까지 도시구성요소를 데이터셋으로 활용하였을 때, Random Forest 비선형 회귀모델이 가장 우수한 예측성능을 보였다. 여기서, 예측성능은 교차검증(5-fold CV)을 통해 실측소음도 대비 ± 5 dB 오차범위 내 약 70%의 정확도로 나타났다. 한편, SHAP 분석을 통해, 건물 밀도(GSI)와 토지피복(주거, 도로)이 예측소음도에 가장 많은 영향을 미치는 도시구성요소로 확인되었다. 이 연구는 소음측정망 데이터를 활용한 통계적 환경 소음지도 작성 가능성을 제시하였으며, 도시 내 소음 모니터링이 필요한 지역을 식별하고, 소음저감 관리대책 우선순위 설정을 위한 기초자료로 활용될 수 있다.

주요어: 스마트서울 도시데이터 센서, 실측소음도, 통계적 소음지도, 랜덤 포레스트, 샐플리 가산 설명기법, 환경소음

Abstract: This study aims to develop a machine learning-based statistical environmental noise prediction model for predicting and monitoring the spatial variability of noise exposure. To this end, measured noise data collected from the S-DoT monitoring network in Seoul were combined with surrounding urban components, including traffic, buildings, land, vegetation, and population, aggregated across multiple buffer radius. The developed model was then applied to the entire area of Seoul to conduct statistical environmental noise mapping and to propose its potential applications. The results showed that the Random Forest nonlinear regression model achieved the best predictive performance when urban component variables within a 40m buffer radius were used for 973 S-DoT monitoring sites. Based on 5-fold cross-validation, approximately 70% of the predicted noise levels

were within ± 5 dB of the measured noise levels. In addition, SHAP analysis identified building density, represented by the Ground Space Index (GSI), and land cover variables, particularly residential and road land cover, as the most influential urban components affecting predicted noise levels. This study demonstrates the potential for developing statistical environmental noise maps using noise monitoring network data. The results can be used to identify areas requiring urban noise monitoring and to support the prioritization of noise reduction and management measures.

Keywords: S-DoT, Measured Noise Data, Statistical Noise Map, Random Forest, SHAP, Environmental Noise

I. 서론

도시에서 발생하는 환경소음은 교통, 건물, 토지이용, 식생, 인구활동 등 다양한 도시구성요소가 복합적으로 작용하여 형성되는 대표적인 환경공해이다. 특히, WHO는 환경소음을 수면장애, 심혈관계 영향, 삶의 질 저하 등과 관련되는 주요 환경보건 위험요인으로 제시한 바 있다(WHO, 2018).

이에 환경소음 노출을 관리하기 위한 수단 중의 하나로 소음지도를 활용하고 있다. 유럽연합은 주요 교통소음원과 도시지역을 대상으로 전략적 소음지도 작성을 제도화하였고(Directive 2002/49/EC, 2002), 국내에서도 「소음·진동관리법」 제4조의2(국가법령정보센터, 2025)에 근거하여 소음지도를 작성할 수 있는 법적근거가 마련되어 있다.

소음지도는 일반적으로 도로, 철도, 항공기 등 주요 교통소음원의 음향 방출 특성과 지형, 건물, 방음시설, 거리감쇠 등을 반영하는 물리적 음향전파 모델을 기반으로 작성된다. 이와 같은 소음지도는 특정 소음원을 대상으로 정밀한 소음 노출 평가와 규제 수단으로 활용하는 데 효과적이다. 그러나 정밀한 입력자료의 구축과 전문적인 모델링 등에 소요되는 높은 비용과 상당한 시간이 요구되기 때문에, 도시계획의 변화에 따라 필요한 경우 소음지도의 재작성 등을 주기적으로 갱신하기 어렵다는 한계가 있다. 특히, 교통체계나 토지이용계획, 인구밀도 및 생활패턴 등 주변 환경이 복합적으로 변화하는 도시에서는 소음 노출 분포 현황을 시기적절하게 지속적으로 모니터링하고 유연하게 관리할 수 있는 목적의 데이터 기반 소음지도가 보완적으로 요구된다.

이에 따라 소음도와 도시를 구성하는 공간정보 간의 통계적 관계를 이용하여, 소음 노출 분포를 추정하는 통계적 소음 예측 관련 연구가 수행되고 있다. 초기 연구에서는 환경소음을 주변 토지이용과 도로망, 교통특성 등의 독립변수로 설명 및 예측하는 토지이용 회귀 모형(Land Use Regression)을 중심으로 수행되었으며(Xie et al., 2011; Aguilera et al., 2015; Sieber et al., 2017), 이후에는 도시형태, 건물밀도, 도로구조, 녹지 등 다양한 도시구성요소가 소음 노출에 미치는 영향을 분석하는 연구로 확장되었다(Salomons & Berghauser Pont, 2012; Weber et al., 2014; Ryu et al., 2017). 또한, 최근에는 소음도와 도시구성요소 간의 관계가 선형적 구조만으로 충분히 설명되기 어렵다는 점에서, Random Forest(Breiman, 2001)와 같은 비선형의 기계학습 회귀모형을 적용하여 예측성능을 개선하려는 연구로 발전하고 있다(Singh et al., 2016; Liu et al., 2020; Kim et al., 2021; Gharehchahi et al., 2024; Zheng et al., 2025; Almatawah et al., 2025).

한편, 통계적 소음 예측 관련 연구는 목표변수의 성격에 따라 예측소음도와 실측소음도 기반 예측방식으로 구분할 수 있다.

예측소음도 기반 연구는 기존 소음지도 또는 물리 기반 소음예측식에서 도출한 격자 단위 소음도를 통계모형의 목표변수로 활용하고, 해당 격자에서의 도시구성요소를 설명변수로 추출 및 증첩하여 소음도를 예측하는 방식이다. 이와 같은 방식은 도시 전역에 대해 공간적으로 연속적이고 세밀한 데이터셋을 확보할 수 있어, 실측소음도 기반 연구에 비해 정확도가 높은 통계모형을 기대할 수 있다. 그러나, 통계모형의 예측결과가 공학적 소음예측식의 산출값을 재현하는 성격을 가

질 수 있다는 한계가 있다.

실측소음도 기반 연구는 소음측정망 등 현장 소음측정 자료를 목표변수로 활용하고, 주변 도시구성요소를 설명변수로 집계하여 소음도를 예측하는 방식이다. 이는 측정지점의 공간적 대표성, 대상소음원 이외 이벤트 소음 등으로 인해 예측 불확실성이 증가할 수 있지만, 실제 현장에서 발생하는 소음과 관련 교통 변동성 및 생활활동 특성 등을 동적으로 연계 반영할 수 있어, 실시간 소음 노출 분포 모니터링에 더 효과적인 통계적 소음지도를 작성할 수 있다.

따라서, 본 연구는 2023년 기준 서울특별시(이하 “서울시”라 한다)에 구축된 S-DoT 측정망의 실측소음도와 주변 도시구성요소 간의 통계적 관계를 학습하여 예측모델을 개발하고 관련 도시구성요소가 소음 예측결과에 미치는 영향의 기여도를 분석하며, 예측모델을

서울시 전역에 배포하여 주간 및 야간 시간대의 통계적 환경 소음지도를 작성하고, 작성된 소음지도의 정책적 활용 방안을 제시하는 것을 목적으로 한다.

II. 연구방법

1. 버퍼(buffer) 기반 데이터셋 구축

목표변수는 Figure 1과 같이 서울시 S-DoT 측정망 973개 지점의 시간 단위 실측소음도(Leq, dB)를 수집하여, 주간(06:00~ 22:00) 및 야간(22:00~06:00) 연평균 등가소음도로 대표화하여 산정하였다.

여기서, 973개 지점은 250일 이상 유효 데이터(1일 주간 4시간 이상, 야간 2시간 이상)를 확보한 지점의 미한다. 이외, 결측치와 일반적인 소음 노출 분포 범위 밖의 이상치는 제외하였다.

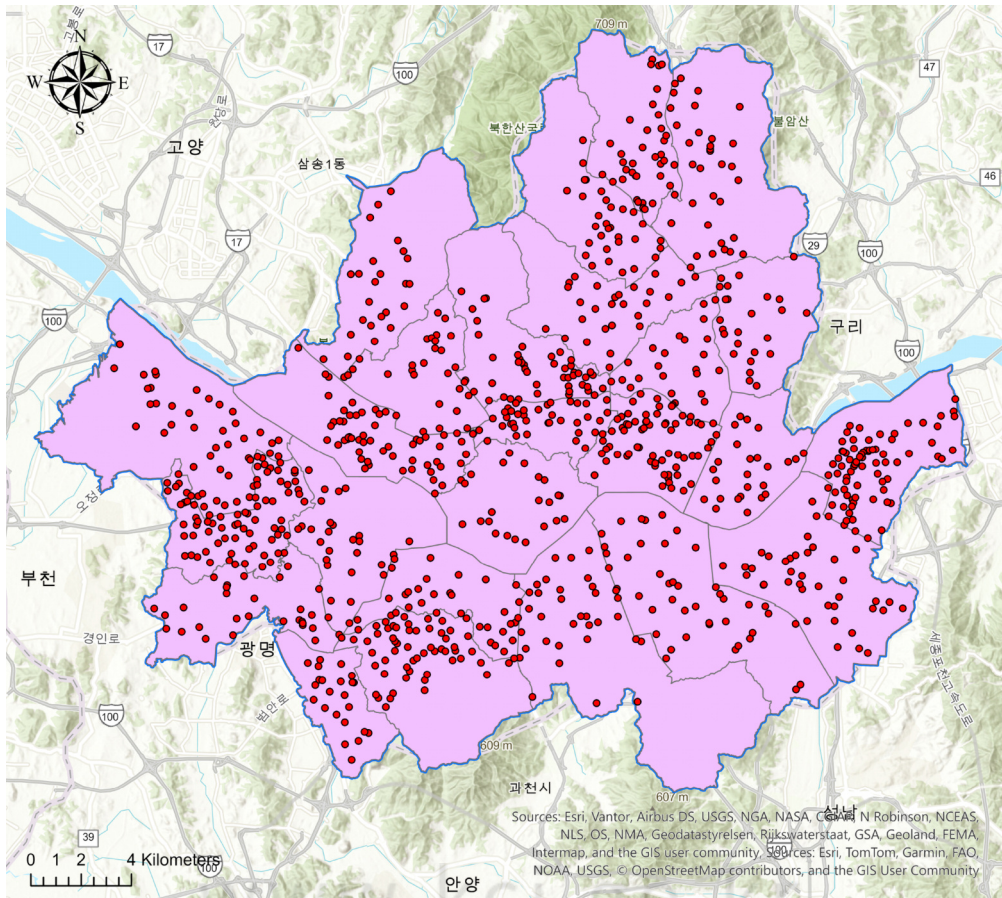


Figure 1. Location of S-DoT Sites

Table 1. Regional distribution and noise levels of S-DoT monitoring sites in 2023

(unit: dB)

Region	Site (n)	L_{day}				L_{night}			
		MEAN	STD	MIN	MAX	MEAN	STD	MIN	MAX
Commercial area	32	51.5	6.1	42.5	67.1	48.6	5.6	40.2	61.7
Industrial area	42	50.9	4.5	40.1	61.5	47.4	4.6	38.0	59.6
Main street	33	62.2	6.2	48.2	71.5	58.8	5.7	44.8	67.5
Parks	4	60.2	5.4	56.0	68.1	55.7	5.7	51.6	64.2
Public facilities	6	50.0	3.2	46.9	56.0	45.0	3.4	42.5	51.2
Residential area	709	50.1	5.2	35.2	71.7	46.7	4.7	35.1	68.9
Roads and parks	97	60.4	7.8	38.6	71.7	56.3	7.6	35.7	67.8
Traditional markets	50	49.4	6.0	35.2	66.3	45.8	5.8	35.2	59.3

Table 1과 같이 측정지점의 약 73%(709개)가 주거지 역에 편중된 표본 구조로 되어 있어 평균소음도가 낮은 데이터를 주로 학습할 가능성이 높아, 주의가 필요하다.

설명변수는 목표변수인 S-DoT 실측소음도 측정지점 기준으로 원형 버퍼를 생성하고, Table 2와 같이 버퍼 내부에 포함되는 도시구성요소를 집계하여 활용

하였다.

여기서, 교통 데이터는 도로 링크 단위의 교통량, 속력, 대형차의 혼입비율을 활용하였으며, 버퍼 내부에 포함되는 도로 링크의 길이와 차로(수)를 고려하여, 다음 산식과 같이 도로 점유 가중치를 적용한 대푯값으로 산정하였다.

Table 2. Feature variables and Seoul-wide data ranges used in 2023

Influence	Domain	Feature	Range	Geometry	Source	
Direct	Traffic	Traffic volume [vehicles/h]	Day	1~5,105	Vector (Line)	Korea Transport Data Base
			Night	0.5~2,858		
		Vehicle speed [km/h]	Day	1~79		
			Night	1~85		
		Heavy vehicles ratio [%]	Day	0~86		
			Night	0~90		
Indirect	Building	Building footprint area [m ²]	1~85,412	Vector (Polygon)	V-WORLD	
	Land Use and Land Cover	Land Cover area [%]	Residential	7.2	Vector (Polygon)	Environmental Geographic Information Service
			Industrial	0.3		
			Commercial	5.3		
			Green	39.7		
			Road	28.5		
			Others	19.0		
	Vegetation	NDVI (Normalized Difference Vegetation Index)	-0.9~0.9	Raster (Grid)	GBDOP	
Population	Residential population density [persons/km ²]		2~5,806	Vector (Polygon)	SGIS	
	Living population density [persons/km ²]	Day	0.2~3,186		Seoul Open Data Plaza	
		Night	0.2~2,154			

Note. GBDOP = Geo Big Data Open Platform; SGIS = Statistical Geographic Information Service.

$$Q_b = \frac{\sum_i (Q_i \times O_i)}{A_b} \quad (1)$$

$$V_b = \frac{\sum_i (V_i \times O_i)}{\sum_i O_i} \quad (2)$$

$$PH_b = \frac{\sum_i (PH_i \times O_i)}{\sum_i O_i} \quad (3)$$

여기서, Q_b, V_b, PH_b 는 각각 대상 버퍼 내부의 교통량 밀도, 속도, 대형차 혼입비율의 대푯값을 의미한다. Q_i, V_i, PH_i 는 도로 링크 i 의 교통량, 속도, 대형차 혼입비율이며, A_b 는 버퍼의 면적이다. O_i 는 도로 링크 i 의 버퍼 내 포함 길이와 차로(수)를 곱하여 산정한 도로 점유가 중치를 의미한다.

건물 데이터는 소음 전파에 영향을 미치는 건물의 수평적 밀도를 의미하는 GSI(Ground Space Index)를 활용하였다. 여기서, GSI는 버퍼 내부에 포함되는 건물 바닥 투영(footprint) 면적의 합을 버퍼 면적으로 나누어 산정하였다. 토지피복 변수는 지표면의 토지피복 특성이 주변 소음 노출에 미치는 영향인자를 의미하며, 각 토지피복 유형인 주거·상업·공업·녹지(산림, 초지)·도로·기타 지역이 버퍼 내에서 차지하는 면적비율로 변환하여 활용하였다. 식생 및 인구 관련 데이터는 버퍼 내부 포함되는 격자의 평균값으로 산정하였다. 여기서, 식생 데이터는 녹지 특성이 소음에 미치는 영향인자를 반영하기 위한 목적으로, 식생의 점유 정도와 활력도를 나타내는 정규식생지수(NDVI, Normalized Difference Vegetation Index)를 활용하였다. 인구 변수는 상주인구(수)와 서울시에서 자체적으로 운영하는 생활인구(수)를 수집하여, 인구밀도로 변환 활용하였다.

이후, 각 S-DoT 측정지점을 중심으로 다양한 후보 버퍼 반경(20, 40, 80, 100, 200, 400m)을 설정하고, 측정 지점별 주간 및 야간 대표소음도와 버퍼 기반 설명변수를 결합하여 데이터셋을 구축하였다.

2. 기계학습 모델링 및 성능평가

실측소음도와 도시구성요소 간의 비선형 관계를 학습 및 예측하기 위하여, 트리 기반 앙상블 계열인

Random Forest(RF), Extra Trees(ET), Gradient Boosting (GB) 모델과 커널 함수를 이용하여 비선형 회귀관계를 추정하는 Support Vector Regression with radial basis function kernel(SVR-RBF), 인공신경망 기반 Multi-Layer Perceptron(MLP)을 후보 회귀모형으로 설정하였다.

후보 모형의 예측성능은 버퍼 반경별 구축한 데이터셋을 5개 그룹으로 총 10회 교차 반복 분할하여 예측성능을 평가하는 교차검증(Repeated CV)을 수행하여 비교하였으며, 최종 선정된 예측모형은 최적의 하이퍼파라미터로 조정된 후에 random 5-fold CV 기반 OOF (Out of fold) 예측값을 이용하여 일반화 성능을 평가하였다. 여기서, OOF 예측값은 각 S-DoT 측정지점에서의 데이터가 검증 데이터셋에 포함되어 있을 때, 해당 지점의 데이터를 학습에 사용하지 않은 모형으로부터 산출한 예측값을 의미한다. 따라서, OOF 예측값은 전체 S-DoT 측정지점의 데이터셋에 대해 학습의 예측성능을 평가하는 데 효과적이다.

예측성능을 평가하기 위한 지표는 결정계수(R^2), 평균제곱근오차(RMSE), 평균절대오차(MAE)를 사용하였다. 여기서, R^2 는 예측모형의 설명력을, RMSE와 MAE는 예측오차의 크기를 나타내는 데 효과적이다. 최종 선정된 예측모형에 대해서 표준편차와 $\pm 3dB$ 및 $\pm 5dB$ 이내 예측비율을 추가로 제시하여, 예측소음도의 편향성과 오차 허용범위 내 정확도를 함께 평가하였다.

III. 결과 및 고찰

1. 회귀모형별 예측성능 비교

비선형 후보 회귀모형별 소음 예측성능(주간, Repeated CV) 비교 결과, 40m 버퍼 반경에서 RF 모형이 가장 우수한 성능을 보였다(Figure 2, Table 3). 여기서, RF 모형은 40m 버퍼 반경 기준 R^2 0.3, RMSE 약 5.6dB, MAE 약 4.2dB로 나타났으며, 이외 GB, ET, SVR, MLP 모형보다 낮은 RMSE 오차를 보였다. GB와 ET 역시 40m 버퍼 반경에서 비교적 유사한 성능을 보였으나, RF가 오차 기준에서 가장 안정적인 결과를 나타냈다.

버퍼 반경별 성능 변화를 살펴보면, Figure 2와 같이 대부분의 모형에서 40m 버퍼 반경까지 RMSE 오차값이 감소한 이후에 80m 이상 반경에서는 다시 오차값이




Figure 2. RMSE comparison of candidate nonlinear regression models by buffer radius for daytime noise prediction using repeated cross-validation

Table 3. Best Repeated cross-validation performance of each candidate nonlinear regression model for daytime noise prediction

Rank	Buffer (m)	Model	mean	mean	mean
1	40	RF	0.300	5.593	4.174
2	40	GB	0.284	5.654	4.212
3	40	ET	0.283	5.660	4.221
4	40	SVR	0.249	5.790	4.168
19	40	MLP	0.122	6.232	4.616

Note: RF, ET, GB, SVR, and MLP indicate Random Forest, Extra Trees, Gradient Boosting, Support Vector Regression, and Multi-Layer Perceptron Regressor, respectively.

증가하는 경향을 보였다. 이는 S-DoT 실측소음도가 측정지점 주변 국지적 범위에서의 도시구성요소에 민감하게 반응하며, 과도하게 넓은 버퍼 반경을 적용할 경우에는 주변 환경 특성이 평균화되어 예측능력이 저하될 수 있음을 시사한다. 따라서, 본 연구에서는 40m 버퍼 반경을 통계적 소음 예측 시 적정 공간 영향범위로 판단하고, RF 모델을 최종 예측모델로 선정하였다.

2. Random Forest 모델 일반화 성능평가

40m 버퍼 반경 기준으로 최종 선정한 Random Forest 모델에 대한 일반화 성능을 평가한 결과, Figure 3과 같이, 주간 예측성능은 R^2 0.318, RMSE 약 5.5dB, MAE 약

4.1dB로 나타났으며, 야간 소음도와 유사한 수준으로 전체 측정지점의 70.5%가 ± 5 dB 이내의 오차범위에 포함되었다. 다만, 산점도에서 예측소음도는 실측소음도보다 상대적으로 좁은 범위에 분포하여, 고소음 노출 구간에서는 과소추정, 저소음 노출 구간에서는 과대추정하는 경향을 보였다. 이는 Random Forest 모형 특성상, 다수 의사결정나무의 평균 예측값을 산출하는 앙상블 구조를 가지므로, 극단적인 소음도 노출 구간보다 전체 자료의 평균적 소음 변동 패턴에 수렴하는 회귀 특성이 반영된 결과로 해석된다.

지역유형별 예측오차 분석결과, Table 4와 같이 주거 지역에서는 평균 예측오차가 0.8dB로 비교적 안정적

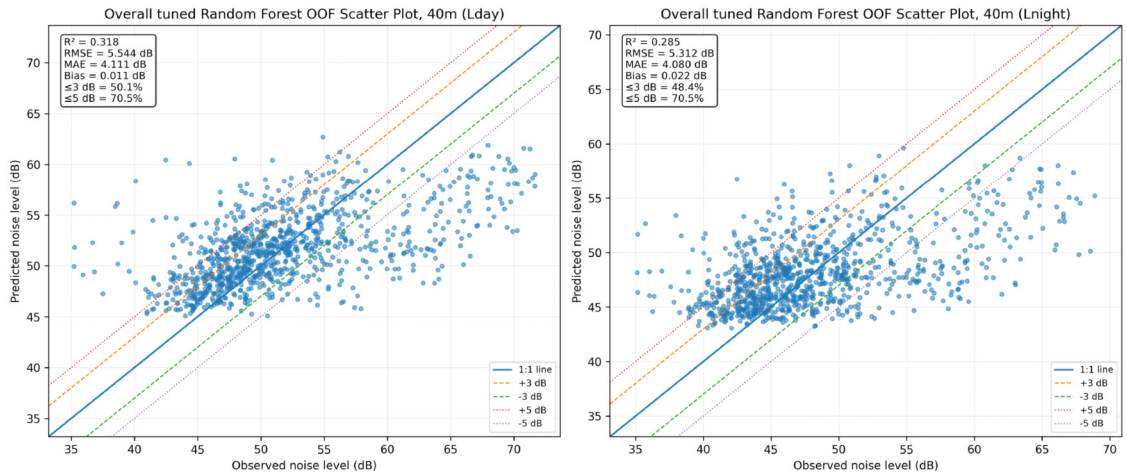


Figure 3. Observed versus OOF-predicted noise levels of the optimized Random Forest model using a 40m buffer

Table 4. Regional-type-based prediction error analysis of the optimized Random Forest model for daytime noise

(unit: dB)

Region	Sites (n)	Mean noise level		Mean prediction error (Pred. - Obs.)	Standard deviation of prediction error	Error exceedance rate	
		Obs.	Pred.			> ±5	>±3
Commercial area	32	51.5	52.7	1.2	5.6	0.25	0.50
Industrial area	42	50.9	53.2	2.3	4.8	0.31	0.48
Main street	33	62.2	54.4	-7.8	4.9	0.85	0.88
Parks	4	60.2	55.5	-4.7	6.3	0.25	0.25
Public facilities	6	50.0	51.9	1.9	2.7	0.00	0.33
Residential area	709	50.1	50.9	0.8	4.7	0.23	0.45
Roads and parks	97	60.4	55.4	-5.0	6.9	0.63	0.77
Traditional markets	50	49.4	50.4	0.9	5.1	0.24	0.48

인 반면, 주요 거리와 도로 및 공원 지역에서는 각각 -7.8dB, -5.0dB의 과소추정이 나타났다. 이는 S-DoT 측정지점이 주거지역에 집중적으로 편중되어 있어, 해당 주거지역의 평균적 소음 특성을 강하게 학습한 영향이 함께 작용한 것으로 판단된다.

3. SHAP 기반 소음 영향인자 기여도 분석

주간 시간대 기준 SHAP 분석 결과, 건물 밀도(GSI), 주거지역(LULC_res) 및 도로교통(LULC_road) 토지피복 비율이 주요 영향인자로 나타났다(Figure 4a). 즉, GSI와 주거지역 토지피복 비율은 예측소음도를 감소시키고, 도로 토지피복 비율은 증가시키는 방향으로 기여도가 높게 나타났다.

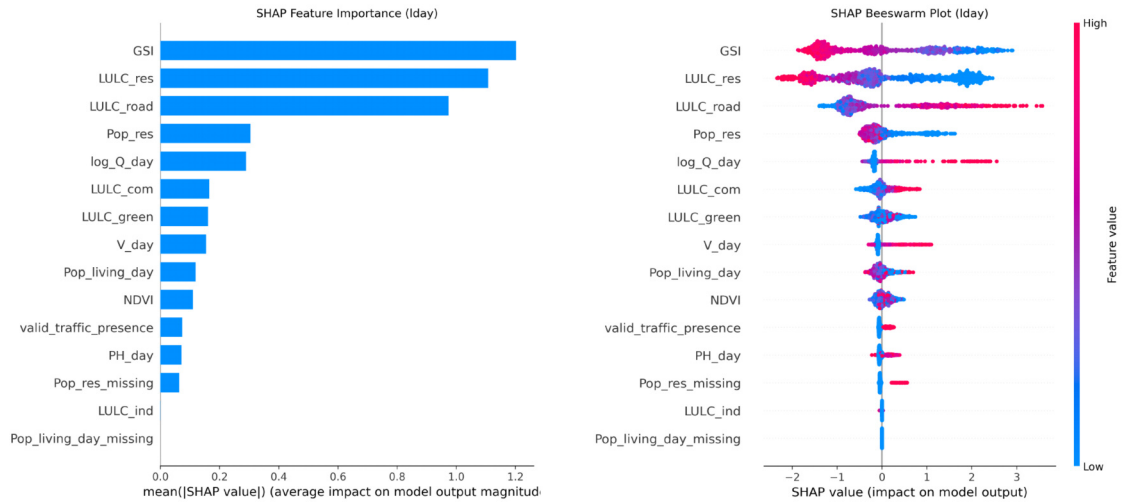
주요 설명변수의 비선형 특성 분석 결과(Figure 4b),

GSI는 관련 건물 피복이 약 0.25~0.35 구간 이후 예측소음도를 급격하게 감소시켰지만, 도로 토지피복 비율은 약 0.55~0.60 구간 이상에서 예측소음도를 급격히 증가시켰다. 이는 건물 피복과 도로 피복이 주간 소음도 예측에서 임계값을 갖는 비선형적 영향요인으로 작용함을 보여준다.

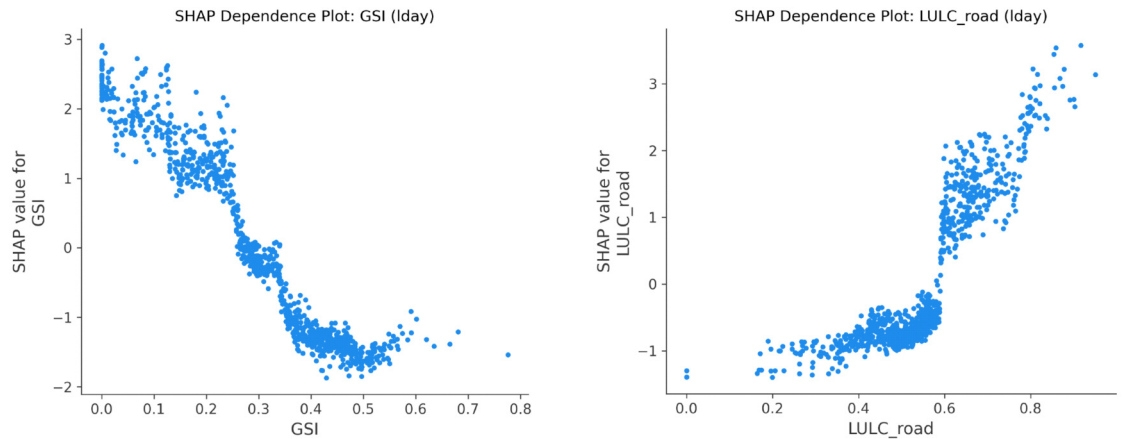
4. 통계적 환경 소음지도 작성 및 활용

최종 개발한 40m 버퍼 반경의 Random Forest 모델을 서울시 전역에 배포하여, Figure 5와 같이 10m 격자 단위의 통계적 환경 소음지도를 작성하였다.

소음지도 작성결과, 주요 도로망 및 고밀도 도시화 동 지역을 중심으로 소음도가 높게 분포하는 공간적 패턴을 보였다. 시간대별로 주간에는 주요 간선도로와



(a) SHAP feature importance and beeswarm plot



(b) SHAP dependence plots for GSI and road land-cover fraction

Note: SHAP denotes SHapley Additive exPlanations. Positive SHAP values increase the predicted daytime noise level, while negative values decrease it. Feature importance was calculated as the mean absolute SHAP value. GSI denotes Ground Space Index; LULC denotes land use and land cover; Pop_res and Pop_living_day indicate residential and daytime living population density, respectively.

Figure 4. SHAP-based interpretation of the optimized Random Forest model for daytime noise prediction

도시 중심부 주변에서 57dB 이상의 고소음 노출 구간이 분포하였으며, 이는 주간 시간대 교통량과 도시활동 증가가 반영된 결과로 해석된다. 반면, 야간에는 주간보다 낮은 45~54dB 이하의 저소음 노출 구간이 더 넓게 분포하였다. 이는 야간 시간대 교통량 및 생활활동 감소에 따른 소음 노출 수준 저하를 보여준다.

공간적으로는 주거지 내부 및 녹지와 인접한 지역에서 낮은 소음도가 분포하지만, 도로 토지피복 비율이 높거나 교통축과 인접한 지역에서는 높은 소음도로 추

정되는 경향을 보였다. 이는 SHAP 분석결과와 같이 도로 토지피복이 예측소음도를 증가시키고, GSI 및 주거지역 토지피복이 예측소음도를 감소시키는 방향으로 작용한 결과와도 일관된다.

다만, 본 연구의 예측모델은 주거지역의 소음도에 집중한 S-DoT 실측소음도를 기반으로 하고 있어, 일부 지역에서는 실제 소음 노출 특성과 차이가 발생할 수 있다. 예를 들어, 도로변과 같이 고소음 노출 가능성이 높은 지역에서는 실제 소음도보다 과소추정될 수 있

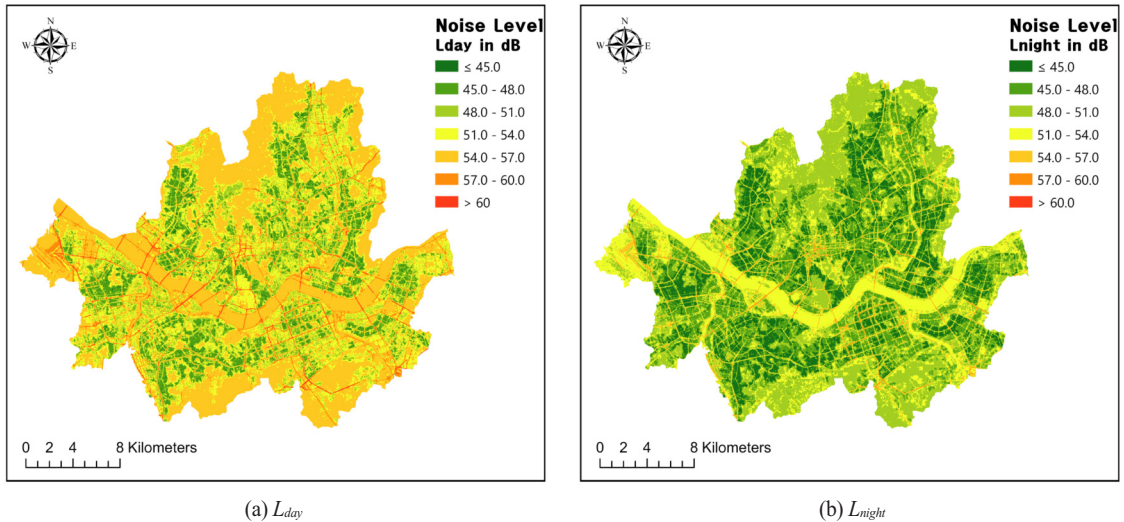


Figure 5. Observed versus OOF-predicted noise levels of the optimized Random Forest model using a 40m buffer

며, 국립공원과 같이 저소음 노출 특성이 강한 지역에서는 상대적으로 과대추정될 가능성이 있다. 또한, 한강과 같은 수계지역은 예측결과 해석 시 제외하거나 별도로 처리할 필요가 있다.

한편, 본 연구의 통계적 환경 소음지도는 소음도의 공간적 변동성 추정과 함께 도시구성요소와 소음 노출 분포 간의 공간적 관계를 해석하는 데 활용될 수 있다. 다만, 통계적 환경 소음지도는 법적 기준 초과 여부를 정밀하게 판정하기 위한 규제평가 도구가 아닌 실제 현장에서의 소음도를 기반으로 도시 내 소음 노출 분포를 파악하기 위한 데이터 기반 모니터링 도구로 해석하는 것이 효과적이다. 특히, S-DoT 실측소음도는 도로변 교통소음뿐만 아니라 주거지역에서의 생활소음 등 측정지점 주변 다양한 환경에 영향을 받을 수 있기 때문에, 예측결과는 특정 소음원의 물리적 전파량보다는 실제 도시환경에서 관측되는 복합적 환경소음의 공간적 패턴을 반영한다. 이와 같은 특성에 따라 통계적 환경 소음지도는 도시 환경소음 관리 측면에서 다음과 같이 활용될 수 있다.

1) 환경영향평가 연계 활용

개발사업 또는 도시계획 수립 단계에서 주변 소음 노출 수준이 높을 것으로 예상되는 지역을 신속하게 파악하여, 평가대상지역 설정, 소음저감대책이 필요한

지역 선별, 사후환경영향조사 후보지점 선정 등을 사전에 검토하는 기초자료로 활용할 수 있다. 다만, 본 연구의 통계적 소음지도는 법적 기준 초과 여부를 판단하는 물리 기반의 공학적 소음지도를 대체하는 것이 아니라, 사전 스크리닝 및 소음 노출 현황을 모니터링하는 보조 도구로 활용범위를 제한할 필요가 있다.

2) 소음측정망 연계 검토

소음측정망이 설치되지 않은 지역의 상대적 소음 노출 수준을 추정함으로써, 추가 모니터링이 필요한 지역을 선별하는 등 측정지점의 적정성 검토 및 개선에 활용할 수 있다.

3) 소음저감대책 추진 우선순위 설정

주·야간 소음지도의 공간적 소음 노출 특성을 비교함으로써 주요 시간대별 소음관리 필요지역을 구분하고, 교통소음·진동 관리지역 지정, 생활소음 집중관리, 정온시설 주변 방음시설 설치 등의 소음저감대책 추진 우선순위 설정 시 기초자료로 활용할 수 있다.

4) 실시간 소음 노출 분포 모니터링

향후, 소음측정망 자료와 교통·유동인구 등 동적 도시 빅데이터 자료가 지속적으로 연계 갱신될 경우, 실시간 환경소음 모니터링 체계로 확장될 수 있다.

IV. 결론

본 연구는 서울시 S-DoT 측정망에서 수집한 실측소음도와 주변 도시구성요소를 활용하여 기계학습 기반 통계적 환경소음 예측모델을 개발 및 주·야간 통계적 소음지도 작성에 적용하였으며, 주요 결론은 다음과 같다.

첫째, 973개 S-DoT 유효 측정지점을 대상으로 주간 및 야간 연평균 등가소음도를 산정하고, 교통, 건물, 토지피복, 식생, 인구 관련 도시구성요소를 설명변수로 구축하였다. 후보 버퍼 반경별 예측성능을 비교한 결과, 주간 및 야간 모두 40m 버퍼 반경에서 가장 우수한 성능을 보여, 실측소음도 기반 예측에서는 소음 측정 지점 주변의 국지적 도시환경 특성이 중요하게 작용함을 확인하였다.

둘째, 후보 예측모형(RF, ET, GB, SVR-RBF, MLP)의 예측성능을 비교한 결과, 트리 기반 앙상블 모형인 RF와 ET, GB가 전반적으로 우수한 성능을 보였으며, 실측소음도와의 오차 허용범위(40m 버퍼 반경 기준 ± 5 dB 이내 약 70%)가 가장 우수한 RF 모델을 최종 예측모델로 선정하였다.

셋째, SHAP 분석을 통한 설명변수의 기여도 분석 결과, 건물 밀도를 의미하는 GSI, 주거지역 및 도로 토지피복 비율이 소음에 가장 영향을 많이 미치는 주요 인자로 확인되었다. 여기서, GSI와 주거지역 토지피복 비율은 예측소음도를 감소시키고, 도로 토지피복비율과 교통량은 예측소음도를 증가시키는 방향으로 기여하였다. 이는 도시 환경소음이 도로교통소음원뿐만 아니라 주변 도시형태와 토지피복 특성 등 간접적 영향인자에 의해 복합적으로 발생됨을 보여준다.

넷째, 최적의 RF 모델을 서울시 전역에 적용하여 10m 격자 단위의 통계적 환경 소음지도를 작성하였다. 작성된 지도는 실측소음도 기반의 상대적 소음 노출 분포를 시각화함으로써 고소음 노출지역 식별, 소음관리 우선순위 설정, 도시계획 및 환경영향평가 과정에서의 기초자료로 활용될 수 있다. 다만, 이 연구의 모델은 주거지역에 특화되어 있어 소음 노출수준에 따라 과소추정 또는 과대추정하는 경향이 있어 정량적 불확실성을 내포하고 있으며, 예측결과를 제한적으로 활용해

야 한다. 향후, 통계적 소음지도의 정확도를 높이기 위하여 실측값과의 상호 비교를 통한 보정 등 관련 검토 체계를 구축할 필요가 있다.

이 연구에서 목표변수 데이터로 활용한 S-DoT 실측소음도의 단위가 환경소음에서 일반적으로 사용하는 dB(A)가 아닌 dB 단위이며, 데이터셋의 공간적 분포가 주거지역에 집중되어 있어 예측결과를 제한적으로 활용해야 하는 한계를 가진다. 즉, 이 연구의 S-DoT 실측소음도(dB 단위) 기반 작성된 통계적 소음지도는 법적 규제평가 도구가 아닌 소음 노출분포를 모니터링할 수 있는 보조 도구로 활용범위를 제한할 필요가 있다. 또한, S-DoT 설치지점의 공간적 특성에 따라 실측소음도에는 도로교통소음뿐만 아니라, 생활소음과 공사장 소음 등 일시적으로 발생하는 이벤트 소음이 포함될 수 있기 때문에, 향후 연구에서는 소음측정망의 공간적 대표성 보완, 동적변수인 교통 데이터의 시간해상도 개선, 도로변 고소음 노출 예상지점의 추가 학습 등이 요구된다.

사사

이 논문은 정서 교란소음의 성가심 영향분석 연구사업의 지원을 받아 수행하였습니다(No. 202505142001).

References

- Aguilera, I., Foraster, M., Basagaña, X., Corradi, E., Deltell, A., Morelli, X., Phuleria, H. C., Ragetti, M. S., Rivera, M., Thomasson, A., Slama, R., & Künzli, N. (2015). Application of land use regression modelling to assess the spatial distribution of road traffic noise in three European cities. *Journal of Exposure Science and Environmental Epidemiology*, 25, 97-105. <https://doi.org/10.1038/jes.2014.61>
- Almatawah, J., Alrumaidhi, M., Matar, H., Altemeemi, A., & Alhubail, J. (2025). An Interpretable Machine Learning Framework for Urban Traffic Noise Prediction in Kuwait: A Data-Driven Approach to Environmental Management. *Sustainability*,

- 17(19), 8881. <https://doi.org/10.3390/su17198881>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>
- Directive 2002/49/EC of the European Parliament and of the Council of 25 June 2002 relating to the assessment and management of environmental noise. (2002). *Official Journal of the European Communities*, L 189, 12-25. <http://data.europa.eu/eli/dir/2002/49/oj>
- Gharehchahi, E., Hashemi, H., Yunesian, M., Samaei, M., Azhdarpoor, A., Oliyai, M., & Hoseini, M. (2024). Geospatial analysis for environmental noise mapping: A land use regression approach in a metropolitan city. *Environmental Research*, 257, 119375. <https://doi.org/10.1016/j.envres.2024.119375>
- Kim, P., Ryu, H., Jeon, J.-J., & Chang, S. I. (2021). Statistical Road-Traffic Noise Mapping Based on Elementary Urban Forms in Two Cities of South Korea. *Sustainability*, 13(4), 2365. <https://doi.org/10.3390/su13042365>
- 국가법령정보센터. (2025). 소음·진동관리법 (법률 제 21065호, 2025. 10. 1., 제4조의2)
- Korea Law Information Center. (2025). *Noise and Vibration Control Act* (Act No. 21065, October 1, 2025, Arts. 4-2) [https://www.law.go.kr/법령/소음·진동관리법/\(21065,20251001\)](https://www.law.go.kr/법령/소음·진동관리법/(21065,20251001))
- Liu, Y., Goudreau, S., Oiamo, T., Rainham, D., Hatzopoulou, M., Chen, H., Davies, H., Tremblay, M., Johnson, J., Bockstael, A., Leroux, T., & Smargiassi, A. (2020). Comparison of land use regression and random forests models on estimating noise levels in five Canadian cities. *Environmental Pollution*, 256, 113367. <https://doi.org/10.1016/j.envpol.2019.113367>
- Ryu, H., Park, I. K., Chun, B. S., & Chang, S. I. (2017). Spatial statistical analysis of the effects of urban form indicators on road-traffic noise exposure of a city in South Korea. *Applied Acoustics*, 115, 93-100. <https://doi.org/10.1016/j.apacoust.2016.08.025>
- Salomons, E. M., & Berghauser Pont, M. (2012). Urban traffic noise and the relation to urban density, form, and traffic elasticity. *Landscape and Urban Planning*, 108(1), 2-16. <https://doi.org/10.1016/j.landurbplan.2012.06.017>
- Sieber, C., Ragetti, M. S., Brink, M., Toyib, O., Baatjies, R., Saucy, A., Probst-Hensch, N., Dalvie, M. A., & Rössli, M. (2017). Land use regression modeling of outdoor noise exposure in informal settlements in Western Cape, South Africa. *International Journal of Environmental Research and Public Health*, 14(10), 1262. <https://doi.org/10.3390/ijerph14101262>
- Singh, D., Nigam, S. P., Agrawal, V. P., & Kumar, M. (2016). Vehicular traffic noise prediction using soft computing approach. *Journal of Environmental Management*, 183(1), 59-66. <https://doi.org/10.1016/j.jenvman.2016.08.053>
- Weber, N., Haase, D., & Franck, U. (2014). Assessing modelled outdoor traffic-induced noise and air pollution around urban structures using the concept of landscape metrics. *Landscape and Urban Planning*, 125, 105-116. <https://doi.org/10.1016/j.landurbplan.2014.02.018>
- World Health Organization (WHO). (2018). *Environmental noise guidelines for the European region*. WHO Regional Office for Europe. <https://www.who.int/europe/publications/i/item/9789289053563>
- Xie, D., Liu, Y., & Chen, J. (2011). Mapping urban environmental noise: A land use regression method. *Environmental Science and Technology*, 45(17), 7358-7364. <https://doi.org/10.1021/es200785x>
- Zheng, G., Chen, X., Huang, K., Mölter, A., Liu, M., Zhou, B., Fang, Z., Zhang, H., He, F., Chen, H., Jing, C., Xu, W., & Hao, G. (2025). Mapping environmental noise of Guangzhou based on land use regression models. *Journal of Environmental Management*, 373, 123931. <https://doi.org/10.1016/j.jenvman.2024.123931>