



도로교통소음과 도시구성요소 관계 분석을 위한 인공신경망 모형 Artificial Neural Network Model Development based on Road-traffic Noise and Urban Form Indicators

김 필 립* · 류 훈 재** · 전 종 준*** · 장 서 일†
Phillip Kim*, Hunjae Ryu**, Jong June Jeon*** and Seo Il Chang†

(Received May 9, 2019 ; Revised August 19, 2019 ; Accepted August 19, 2019)

Key Words : Artificial Neural Network(인공신경망), Ordinary Least Squares Model(통상최소자승 모형), Road-traffic Noise(도로교통소음), Urban Form Indicator(도시 구성 요소)

ABSTRACT

Road-traffic noise is a critical factor that affects the life and health environments of urban inhabitants. In Korea, noise maps of cities created by commercial noise mapping software are used to manage road-traffic noise. This makes the management of noisy environments easy, but in the case of metropolitan cities, the creation of noise maps is time-consuming and costly. In this study, the relationship between road-traffic noise and urban form indicators (i.e., population, roads, buildings, and land use), showing the characteristics of a city, were analyzed to predict the road-traffic noise level using a statistical model. The road-traffic noise level predicted by the artificial neural network method was compared to that using the ordinary least squares method: The adjusted coefficient of determination (R^2) of the former method was 0.5, while that of the latter model was 0.44. Furthermore, the floor space index was used as the urban form indicator, which has the largest effect on the road-traffic noise level.

1. 서 론

도시 지역의 도로교통은 소음 및 대기오염 물질의 주된 발생 원인이고, 도시 거주민의 주거 환경과 신체적 정신적 건강을 위협하고 있다. 도로는 도시가 유지되기 위해 필수적인 사회적 기반시설로, 이를 축소 또는 제거하여 소음 및 대기오염 물질을 저감 하는 것은 현실적으로 불가능하다. 따라서 도로에서 방출되는 소음과 전달경로 상의 흡음, 반사 및 회절 등

을 고려하는 도로교통소음 예측식을 이용하여 예측 모형을 구축, 도시의 현재 또는 미래 교통량을 적용하여 작성한 소음지도로 도로교통소음을 관리하고 있다. 이러한 도로교통소음 예측 과정은 상용 소음지도 작성 소프트웨어를 기반으로 수행된다. 이는 소음의 발생 및 전달 과정을 수학적으로 계산하는 것으로 규모가 큰 광역도시를 대상으로 수행하는 경우 많은 시간과 비용이 소요된다. 따라서 시간, 비용 등을 절약하여 간단하게 도심 지역의 도로교통소음을 예측하는 통계적 도로교통소음 예측 방법의 연구가 필요하다.

† Corresponding Author; Member, School of Environmental Engineering, University of Seoul
E-mail : schang@uos.ac.kr

* Member, Department of Energy and Environmental System Engineering, University of Seoul

** Member, Korean Educational Environments Protection Agency

*** Department of Statistics, University of Seoul

A part of this paper was presented at the KSNVE 2018 Annual Autumn Conference

‡ Recommended by Editor Jong Kwan Ryu

© The Korean Society for Noise and Vibration Engineering

다양한 통계 예측 방법 중 인공신경망 기법을 중심으로 연구를 수행하였다.

Kumar et al.(2014)는 도로변에서 1시간 단위로 측정된 도로교통소음, 교통량, 대형차량 혼입률 및 운행속도 자료를 기반으로 인공신경망 모형을 작성하였다⁽¹⁾. 예측 소음도는 일반회귀모형을 이용한 경우보다 인공신경망 모형을 이용할 때 측정 소음도와 근사하게 나타났다. Garg et al.(2015)는 8개의 설명 변수(이륜차, 삼륜차, 자동차, 중형 상용 자동차, 버스, 트럭의 교통량, 소형 및 대형차량의 평균 운행속도)를 통해 인공신경망 모형으로 도로교통소음(L_{eq} , L_{10})을 예측하였으며, 마찬가지로 다중회귀 분석에 비하여 우수한 설명력을 보였다⁽²⁾. 영국, 북유럽, 이탈리아 및 프랑스의 도로교통소음 예측식과 인공신경망 모형의 예측 소음도를 비교한 연구에서도 인공신경망 모형의 결과가 측정 소음도와 가장 근사하였다⁽³⁾. Hamad et al.(2017)는 도로 끝단으로부터의 거리, 소형 및 대형차량의 교통량, 대형차량 혼입률 및 평균 운행속도와 함께 중동지방의 높은 기온을 고려하기 위하여 도로 온도를 설명변수로 활용하여 인공신경망 모형을 작성하였다⁽⁴⁾. 인공신경망을 이용한 도로교통소음 예측 소음도는 일반적인 도로교통소음 예측식에 비해 측정 소음도와 유사하게 나타났다. 다만 이러한 예측은 측정된 소음도를 예측하여 비교하는 것으로 해당 지역의 지형적, 지리적 특성 등을 반영하므로 일반화하여 광역도시를 대상으로 소음을 예측하기에는 무리가 있다.

Ryu et al.(2014)는 광역도시를 대상으로 통계적 방법으로 도로교통소음을 예측하기 위하여 대상 지역을 일정한 크기의 격자로 분할하고, 각 격자별로 도시구성요소 및 도로교통소음의 대표값을 선정하고, 그 관계를 공간통계모형을 통해 분석하였다⁽⁵⁾. 도로교통을 배출원으로 공유하는 대기오염물질을 예측하는 연구로 Chen et al.(2018)은 머신러닝 기법을 이용하여 중국 16개 도시의 대기질을 예측하였고⁽⁶⁾, Gao et al.(2017)는 교통량, 대형차량 혼입률, 기온, 풍속, 습도 및 일조량을 기반으로 고속도로 변의 높이 별 PM2.5 농도를 예측하는 인공신경망 모형을 작성하였다⁽⁷⁾. 공간통계모형 또는 인공신경망 모형과 같은 통계적 모형을 이용하여 도로교통에 의한 소음, 대기오염물질의 분포 선행연구를 참고하여 이 연구에서는 광역도시를 대상으로 도시구성요소와 도로교통소음

의 관계를 분석하는 인공신경망 모형을 작성하고 그 결과를 분석하였다.

2. 연구 방법

2.1 연구 대상 지역 선정 및 격자화

소음지도 작성 소프트웨어를 이용하여 도로교통소음 지도가 이미 작성되어있는 대한민국의 광주광역시 를 연구 대상 지역으로 선정하였다. 광주광역시는 소음지도가 작성된 2017년을 기준으로 501 km²의 면적에 146만 명이 거주하였다.

연구 대상 지역을 Ryu et al.(2017)의 연구를 참고하여 격자별 도시 구성 요소 특성을 가장 잘 반영할 수 있는 125 m × 125 m 크기의 격자로 분할하고, 격




Fig. 1 Mean squared prediction error of each node number




Fig. 2 Mean squared error by decay parameter (node number = 27)

자별 도로교통소음 및 도시 구성 요소의 대표값을 산정하였다⁽⁸⁾. 유효한 격자의 개수는 11 990개이다.

2.2 도로교통소음 및 도시구성요소 대표값

대상 지역의 격자별 도로교통소음 대표값을 산정하기 위하여 기존에 작성된 소음지도를 활용하였다.

Table 1 Explanation and unit of variable

Variable	Explanation	Unit
L_{cell}	Energy-averaged value of facade noise level	dB(A)
P_{cell}	Population density	persons/m ²
GSI_{cell}	Ground space index	m ² /m ²
FSI_{cell}	Floor space index	m ² /m ²
Q_{cell}	Traffic volume	vehicles/h
PH_{cell}	Percentage of heavy vehicles	%
V_{cell}	Traffic speed	km/h
D_t	Traffic density	vehicles/km
R_a	Road area density	m ² /m ²
W_a	Noise barrier area density	m ² /m ²
L_r	The fraction of residential area	-
L_c	The fraction of commercial area	-
L_i	The fraction of industrial area	-
L_g	The fraction of green area	-

소음지도는 SoundPLAN 7.4를 이용하여 작성되었으며, 독일의 도로교통소음 예측식 RLS-90이 활용되었다^(9,10). 격자별 대표소음도(L_{cell})는 격자에 포함되는 건물의 모든 외벽소음도의 에너지 평균으로 결정하였다.

도시구성요소는 소음지도 작성에 활용한 3차원 도시모형을 기반으로 ArcMap 10.3을 이용하여 추출되었다⁽¹¹⁾. 인구, 건물, 도로 및 토지이용도의 4가지 구분으로 도시구성요소를 분류하였다. 인구 관련 도시구성요소로 격자별 인구밀도(P_{cell})를 선정하였으며, 건물 관련 도시구성요소는 Ryu et al.(2014, 2017)의 연구를 참고하여 건폐율의 의미를 차용한 ground space index(GSI_{cell}), 용적률의 의미를 차용한 floor space index(FSI_{cell})를 선정하였다^(5,8). 도로 관련 도시구성요소는 교통량(Q_{cell}), 대형차량 혼입률(PH_{cell}), 운행 속도(V_{cell}), 교통 밀도(D_t), 도로 면적 비율(R_a) 및 방음벽 면적 비율(W_a)을 선정하였다^(5,8). 마지막으로 토지이용도 관련 도시구성요소로 각 격자의 주거(L_R), 상업(L_C), 공업(L_I) 및 녹지(L_G) 지역 면적 비율을 선정하였다^(5,8). 도로교통소음 및 도시구성요소의 정의 및 단위는 Table 1에 나타내었다^(5,8).

2.3 인공신경망 모형 구성

도로교통소음과 도시구성요소의 관계를 설명하기 위하여 기계학습 기법 중 지도학습의 일종인 인공신경망(artificial neural network) 모형을 작성하였다. 전체 도로교통소음과 도시구성요소 자료를 학습자료(training dataset)와 시험자료(test dataset)로 구분하였으며, 7993개의 학습자료를 이용하여 인공신경망 모형을 학습하고, 이를 3997개의 시험자료에 적용하

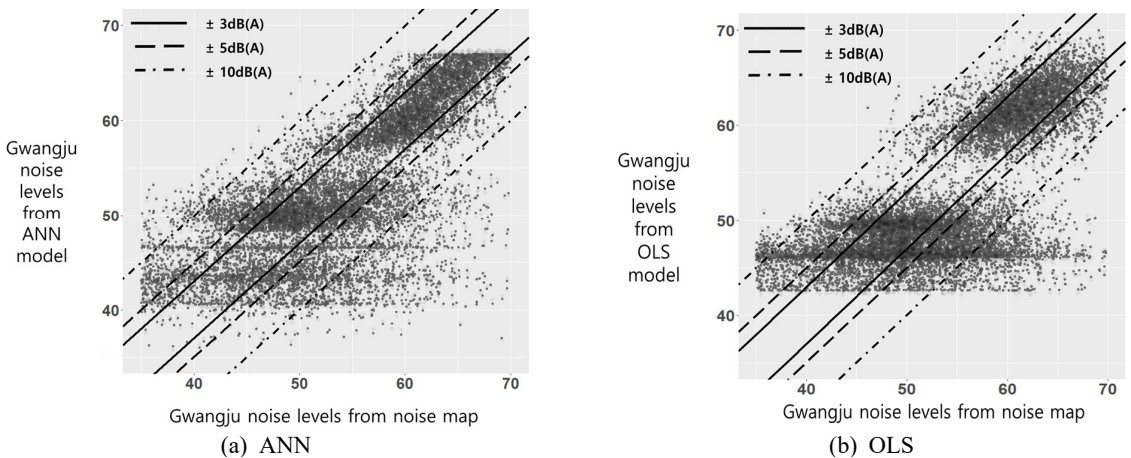


Fig. 3 Noise level comparison between noise map and statistical model

Table 2 Results of the ordinary least squares model

Variable	Estimate	Std. error	t-value	Pr(> t)
(Intercept)	5.69E+05	3.55E+06	0.16	0.872639
P _{cell}	-2.09E+01	1.11E+01	-1.885	0.059525
GSI _{cell}	1.45E+00	9.32E-01	1.559	0.119067
FSI _{cell}	2.54E+00	2.92E-01	8.706	< 2e-16 ***
Q _{cell}	-2.64E-03	7.61E-04	-3.474	0.000515 ***
PH _{cell}	2.92E-01	5.31E-02	5.501	3.88E-08 ***
V _{cell}	1.42E-01	8.56E-03	16.544	< 2e-16 ***
D _t	4.20E-01	5.55E-02	7.573	4.06E-14 ***
R _a	2.26E+01	2.19E+00	10.289	< 2e-16 ***
W _a	1.29E-04	6.19E-04	0.209	0.83444
L _R	-5.69E+05	3.55E+06	-0.16	0.872649
L _C	-5.69E+05	3.55E+06	-0.16	0.872649
L _I	-5.69E+05	3.55E+06	-0.16	0.87265
L _G	-5.69E+05	3.55E+06	-0.16	0.87265

Signif. codes : 0 '***' 0.1 '.'

여 설명력을 검토하였다. 또한 학습자료를 이용하여 인공신경망을 학습하는 과정에서 학습자료와 검증자료(validation dataset)로 구분, 각 격자의 기존 도로교통 소음도와 인공신경망 모형 기반 도로교통 예측 소음도의 오차를 mean squared prediction error(MSE)를 이용하여 분석하였다.

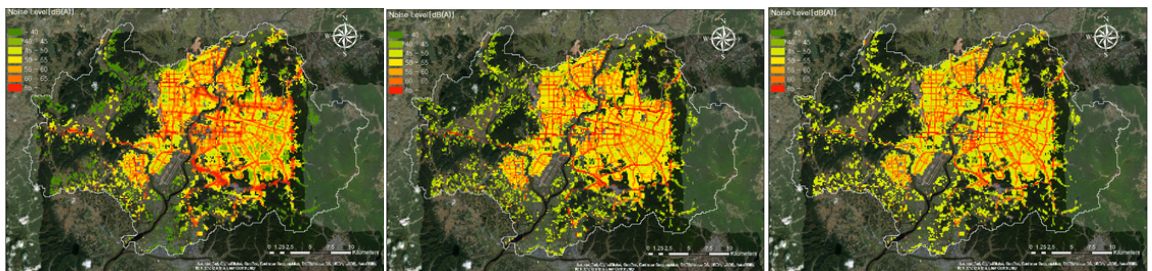
인공신경망 모형 작성은 수학적 계산을 기반으로 오차가 최소화되는 지점을 구하는 방법으로 복잡한 계산과정을 자동으로 수행할 수 있는 통계 분석 소프트웨어 R을 사용하였다⁽¹²⁾. R에는 인공신경망 모형을 작성할 수 있는 다양한 패키지가 있으며, 단층 은닉 레이어(hidden layer)로 구성된 모형을 작성하는 nnet 패키지를 사용하였다⁽¹³⁾.

인공신경망 모형 작성 과정에서 다양한 파라미터의 조정이 필요하다. 이 연구에서는 nnet 패키지의 다양한 파라미터 중 인공신경망의 은닉 노드(hidden node)의 수, 학습자료의 과적합을 방지하기 위한 decay를 조정하며 MSE를 분석하였으며, 학습자료를 반복하여 활용하는 횟수를 지정하는 maxit는 200회로 고정하였다. 그 외 파라미터는 기본값을 적용하였다. 각 파라미터를 조정하여 격자의 기존 도로교통 소음도와 도시구성요소 기반 예측 도로교통 소음도의 오차가 가장 작아지는 값을 선정하였다.

은닉 노드의 수는 1에서 50까지 조정하며 MSE를 탐색한 결과 수가 27일 때 가장 작았으며, decay는 e⁻²부터 e⁻⁷까지 10개와 0, 총 11개의 decay를 적용하여 MSE를 탐색하였으며, MSE가 가장 작게 나타나는 e⁻²을 최종 decay로 결정하였다. MSE 탐색 결과는 Figs. 1, 2에 나타내었다.

2.4 통상최소자승 모형 구성

인공신경망 모형에서 활용한 학습자료를 이용하여 통상최소자승 모형(ordinary least squares model, OLS)



(a) SoundPLAN (b) ANN (c) OLS

Fig. 4 Noise map developed by noise mapping software and statistical model

을 구성하였다. 설명변수에 의해 예측된 종속변수의 오차를 최소화하는 모형을 추정하는 통상최소자승법은 설명변수와 종속변수의 관계를 분석할 수 있는 기초 선형회귀 방법이다. 이 연구에서는 도시구성요소를 설명변수로 하여 종속변수인 도로교통소음 소음도를 추정하였으며, 추정 결과는 Table 2에 나타내었다.

3. 연구 결과

인공신경망 모형과 통상최소자승 모형을 시험자료에 적용하여 기존 도로교통 소음도와 통계적 모형 기반 도로교통 예측 소음도의 관계를 분석, 모형의 설명력을 분석한 결과는 Table 3과 같다.

인공신경망 모형의 결정계수는 0.50, 통상최소자승 모형의 결정계수는 0.44로 인공신경망 모형의 설명력이 보다 우수한 것으로 나타났다. 각 모형을 학습 및 시험자료 전체 11 990개의 격자에 적용하고, 기존 도

Table 3 Results of OLS and ANN model application

	ANN	OLS
Correlation coefficient(r)	0.70	0.66
Coefficient of determination(R ²)	0.50	0.44
Adjusted coefficient of determination(R ² _{adj})	0.50	0.44




Fig. 5 Result of Garson analysis of ANN model

로교통 소음도와 모형 기반 도로교통 예측 소음도를 비교하여 Fig. 3에 나타내었다.

인공신경망 모형 기반 예측 도로교통 예측 소음도와 기존 도로교통 소음도의 차이가 ±3 dB(A) 이내로는 전체 격자 중 44.5 %, ±5 dB(A) 이내로는 63.4 %, ±10 dB(A) 이내로는 85.2 %로 나타났으며, 이는 통상최소자승 모형의 41.1 %, 59.4 %, 83.4 %에 비해 설명력이 보다 우수하다는 것을 의미한다.

소음지도 기반 기존 도로교통소음과 인공신경망 모형 및 통상최소자승 모형 기반 예측 도로교통소음을 적용한 격자별 소음도를 Fig. 4에 나타내었다.

도시구성요소별 상대적 중요성을 검토하기 위하여 Garson 알고리즘을 이용하는 R패키지 neural nettools를 활용하고 그 결과를 Fig. 5에 나타내었다⁽¹⁴⁾.

FSI_{cell}이 도로교통소음 소음도 예측에 가장 큰 영향을 미치는 것으로 나타났으며, GSI_{cell}, L_i, L_r, L_c, L_g, Q_{cell}, PH_{cell}, W_a, V_{cell}, R_a, D_t, P_{cell}순으로 영향을 미치는 것으로 나타났다. 이는 격자 내 건물이 차지하는 면적의 비율이 높을수록 도로교통소음이 높게 나타나며 그 중에서도 고층건물이 위치하고 있는 격자의 소음도가 더 높다는 것을 의미한다. 또한 격자 내 토지이용도는 공업지역이 많을수록 도로교통소음이 높게 나타남을 의미한다.

4. 결 론

이 연구에서는 도로교통소음과 도시구성요소의 관계를 분석하기 위하여 인공신경망 모형을 작성하였다. 소음지도를 기반으로 계산된 기존 도로교통소음과 3차원 도시모형을 기반으로 계산된 도시구성요소의 관계를 인공신경망 모형과 통상최소자승 모형을 이용하여 분석하고, 각 모형을 이용하여 계산한 격자별 도로교통 예측 소음도와 기존 도로교통 소음도를 비교, 분석하였다.

인공신경망 모형의 도로교통소음 설명력은 50 %, 통상최소자승 모형은 44 %로 그 차이가 크지는 않지만 인공신경망 모형의 설명력이 약간 우세한 것을 확인하였다. 또한 인공신경망 모형 기반 도로교통 예측 소음도와 기존 도로교통 소음도의 차이가 ±3 dB(A) 이내로 나타나는 비율은 44.5 %, 통상최소자승 모형은 41.1 %로 인공신경망 모형이 통상최소자승 모형에 비해 기존 도로교통 소음도에 근사하게 예측하는

것을 확인하였다.

연구의 기초자료로 활용된 소음지도는 도로교통소음만을 대상으로 작성되었으며, 반사횟수가 3회, 소음 영향범위를 5 km로 설정하였기 때문에 도로를 포함하지 않고 있으나 반경 5 km 이내에 위치한 도로의 영향을 받는 경우 일부 격자에서 40 dB(A) 이하의 낮은 소음도를 확인할 수 있었다. 하지만 인공신경망 모형은 36.0 dB(A), 통상최소자승 모형은 42.6 dB(A) 이하의 소음도를 예측할 수 없었다.

기존 도시 내 소규모 계획 변경 또는 신규 도시 계획 시 기초 자료 부족으로 상용 소음지도 작성 소프트웨어 기반 도로교통소음 예측이 어렵거나, 예측 소요시간이 많이 소요될 수 있다. 인공신경망 모형 기반 도로교통소음 예측이 가능할 경우 비교적 적은 시간과 비용을 통해 변경 또는 신규 계획에 의한 도로교통소음 발생을 예측할 수 있고, 계획 단계에서 이를 반영한 저감 방안 마련이 가능하다.

이 연구에서는 단층의 은닉 레이어를 가진 인공신경망 모형을 작성하여 도로교통소음을 예측하였다. 인공신경망 모형은 일반적으로 은닉 레이어의 개수가 늘어날수록 모형의 설명력이 높아진다. 추후 연구에서 은닉 레이어의 개수를 추가하여 심층신경망(deep neural network) 모형을 작성하고, 도시 특성을 반영한 도시구성요소의 추가 선정을 통해 소음지도 기반 기존 도로교통소음과의 예측 오차를 줄이고, 일부 격자에서 나타나는 아주 낮은 수준의 도로교통소음을 예측하는 방안을 모색하고자 한다.

후 기

이 논문은 2019년도 서울시립대학교 연구년교수 연구비에 의하여 연구되었음.

References

(1) Kumar, P., Nigam, S. P. and Kumar, N., 2014, Vehicular Traffic Noise Modeling Using Artificial Neural Network Approach, *Transportation Research Part C: Emerging Technologies*, Vol. 40, pp. 111~122.

(2) Garg, N., Mangal, S. K., Saini, P. K., Dhiman, P. and Maji, S., 2015, Comparison of ANN and Analytical Models in Traffic Noise

Modeling and Predictions, *Acoustics Australia*, Vol. 43, No. 2, pp. 179~189.

(3) Nebojsa, B., Zlatan and Šoškić., 2018, Application of Artificial Neural Network to Prediction of Traffic Noise Levels in the City of Niš, Serbia, *Acoustics and Vibration of Mechanical Structures*, Vol. 198, pp. 91~98

(4) Hamad, K., Ali Khalil, M. and Shanableh, A., 2017, Modeling Roadway Traffic Noise in a Hot Climate Using Artificial Neural Networks, *Transportation Research Part D: Transport and Environment*, Vol. 53, pp. 161~177.

(5) Ryu, H. J., Park, I. K., Chun, B. S. and Chang, S. I., 2014, The Spatial Statistical Relationships between Road-traffic Noise and Urban Components Including Population, Building, Road-traffic and Land-use, *Transactions of the Korean Society for Noise and Vibration Engineering*, Vol. 24, No. 4, pp. 348~356.

(6) Chen, S., Kan, G., Li, J., Liang, K. and Hong, Y., 2018, Investigating China's Urban Air Quality Using Big Data, Information Theory, and Machine Learning, *Polish Journal of Environmental Studies*, Vol. 27, No. 2, pp. 565~578.

(7) Gao, Y., Wang, Z. Y., Lu, Q. C., Liu, C., Peng, Z. R. and Yu, Y., 2017, Prediction of Vertical PM2.5 Concentrations Alongside an Elevated Expressway by Using the Neural Network Hybrid Model and Generalized Additive Model, *Frontiers of Earth Science*, Vol. 11, No. 2, pp. 347~360.

(8) Ryu, H. J., Park, I. K., Chun, B. S. and 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*, Vol. 115, pp. 93~100.

(9) SoundPLAN, <http://www.soundplan.eu/english> (accessed November 5, 2015).

(10) Abteilung Straßenbau, 1990, Verkehrsblatt. RLS-90 Richtlinien für den Lärmschutz an Straßen des Bundesministers für Verkehr, <http://www.bv-elbtal.de/document/RLS90.pdf> (accessed November 5, 2015).

(11) ArcGIS, <https://www.esri.com/en-us/arcgis/a>

bout-arcgis/overview.

(12) The R Project for Statistical Computing, <http://www.r-project.org>.

(13) Ripley, B. and Venables, W., 2016, R Package 'nnet', <https://cran.r-project.org/web/packages/nnet>

(14) Marcus, A., Beck, W. and Beck, M. M. W., 2018, R Package 'NeuralNetTools', <https://cran.r-project.org/web/packages/NeuralNetTools>.



Seo Il Chang completed his Ph.D. studies in the Herrick laboratories, Dept. of Mechanical Engineering, Purdue University in 1993 on non-linear problems of mechanical systems including plates and shells. In 1997, he started his academic professional career in the Dept. of Environmental Engineering, the University of Seoul. His major research interest has been the environmental noise and vibration control and people in his lab have generated noise maps of cities. Recently, he collaborates with researchers from other fields including transportation, GIS, air quality and public health to make environmental pollution maps and to assess health impact. His long-term research plan is to study the relations between environmental noise and urban forms.