

Research Article

식생지수를 활용한 LULUCF 정주지 온실가스 인벤토리 산정을 위한 수목탐지 방법 개발

이준우¹⁾ · 한유한¹⁾ · 이정택¹⁾ · 박진혁¹⁾ · 김근한^{ID 2)*}

Development of Tree Detection Methods for Estimating LULUCF Settlement Greenhouse Gas Inventories Using Vegetation Indices

Joon-Woo Lee¹⁾ · Yu-Han Han¹⁾ · Jeong-Taek Lee¹⁾ · Jin-Hyuk Park¹⁾ · Geun-Han Kim^{ID 2)*}

Abstract: As awareness of the problem of global warming emerges around the world, the role of carbon sinks in settlement is increasingly emphasized to achieve carbon neutrality in urban areas. In order to manage carbon sinks in settlement, it is necessary to identify the current status of carbon sinks. Identifying the status of carbon sinks requires a lot of manpower and time and a corresponding budget. Therefore, in this study, a map predicting the location of trees was created using already established tree location information and Sentinel-2 satellite images targeting Seoul. To this end, after constructing a tree presence/absence dataset, structured data was generated using 16 types of vegetation indices information constructed from satellite images. After learning this by applying the Extreme Gradient Boosting (XGBoost) model, a tree prediction map was created. Afterward, the correlation between independent and dependent variables was investigated in model learning using the Shapely value of Shapley Additive exPlanations (SHAP). A comparative analysis was performed between maps produced for local parts of Seoul and sub-categorized land cover maps. In the case of the tree prediction model produced in this study, it was confirmed that even hard-to-detect street trees around the main street were predicted as trees.

Keywords: Tree measurement, Vegetation index, Sentinel-2, XGBoost, SHAP

요약: 전 세계적으로 지구온난화와 관련된 문제인식이 대두되면서, 도시지역에서의 탄소중립을 위해 탄소흡수원의 역할이 더욱 강조되고 있다. 정주지 탄소흡수원의 관리를 위해서는 탄소흡수원의 현황 파악이 필요하며, 이를 위해서는 많은 인력과 시간과 이에 따른 예산이 소요되게 된다. 본 연구에서는 서울시를 대상으로 구축된 수목의 위치정보와 Sentinel-2 위성영상을 이용해 수목의 위치를 예측할 수 있는 지도를 제작했다. 이를

Received November 24, 2023; Revised December 4, 2023; Accepted December 11, 2023; Published online December 31, 2023

¹⁾ 서울시립대학교 공간정보공학과 학부생(Undergraduate Student, Department of Geoinformatics, University of Seoul, Seoul, Republic of Korea)

²⁾ 한국환경연구원 물국토연구본부 환경계획연구실 전문연구원(Research Specialist, Division for Environmental Planning, Water and Land Research Group, Korea Environmental Institute, Sejong, Republic of Korea)

* Corresponding author: Geun-Han Kim (ghkim@kei.re.kr)

Copyright © 2023 by The Korean Society of Remote Sensing. This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<https://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

위해 수목 유무 데이터셋을 구축한 뒤 위성영상으로부터 구축한 식생지수 16종 정보를 이용하여 분석에 활용할 정형데이터를 생성했다. 그리고 생성된 정형데이터에 Extreme Gradient Boosting (XGBoost) 모델을 적용하여 학습 후, 수목 예측 지도를 제작했다. 이후 Shapley Additive exPlanations (SHAP) 분석을 통해 모델 학습에서 독립변수와 종속변수 간의 관계를 조사하였다. 서울의 국소 부분에 대해 제작된 지도와 세분류 토지피복지도와의 비교분석을 수행했고, 본 연구에서 제작된 수목 예측 모델의 경우 대로변 주변의 탐지하기 어려운 가로수의 경우에도 수목의 위치로 예측이 된다는 것을 확인했다.

주요어: 수목 탐지, 식생지수, Sentinel-2, XGBoost, SHAP

1. 서론

지구온난화 문제에 대한 전 세계적인 관심이 고조되면서 과학적 근거의 제시가 절실해지고 있으며, 이에 Intergovernmental Panel on Climate Change (IPCC)는 인간 활동이 지구온난화에 미치는 영향에 대한 과학적 증거를 제공하였다(Seoul Development Institute, 2006). 더욱이 교토의정서와 파리 협정은 산림에 대해 탄소흡수원으로서 중요한 역할을 강조하며, 온실가스 배출 및 흡수량 통계의 투명성을 강조하고 있다(Kim et al., 2013). 지구온난화에 대응하려면 탄소흡수원의 기능을 강화해야 한다. 이에 전제되어야 하는 단계는 녹지 등 생태계 현황 파악이며, 나아가 도시지역의 녹지 개발을 통한 탄소저감능력 증대 효과를 기대할 수 있다(Kim et al., 2022).

하지만, 한국에서는 토지이용 및 임업(Land Use-Land Use Change and Forestry, LULUCF) 분야에 대한 탄소흡수량 인벤토리(Inventory) 산정이 어렵고, 정주지 부분의 정의 및 범위가 아직 정립되지 않아 정주지에 대한 탄소흡수량 계산 작업이 어려운 상황이다(Greenhouse Gas Inventory and Research Center of Korea, 2020; Yu et al., 2015). 산림자원에 의한 탄소흡수량은 통계적 계산이나 현장 센서 측측 등을 통한 방법들이 사용되어 왔으나, 이는 각각의 수목에 대한 위치데이터와 흉고직경 또는 수관면적 등의 데이터가 필요하므로 현장 조사가 요구됨에 따라 많은 예산과 시간이 소요된다(Cho et al., 2017). 따라서, 정주지 탄소흡수량을 산정하기 위해서는 정주지를 대상으로 일부 조사된 데이터, 즉 우리가 이미 알고 있는 일부 데이터를 활용하여 우리나라 정주지 전체 지역에 대한 탄소흡수량의 예측 및 산정이 필요하다. 특히 탄소흡수량의 예측을 위해서는 탄소흡수

원의 위치 추정과 해당 위치의 탄소흡수량 예측이 필요한데, 본 연구에서는 탄소흡수원의 위치를 추정할 수 있는 방법론을 제안하고자 했다.

탄소흡수원의 위치 예측을 위해서 기존의 수목 위치 데이터와 Sentinel-2 위성데이터를 활용하여 구축하고자 했다. 그리고 최근 활발히 활용되고 있는 eXplainable AI (XAI) 기법의 적용을 통해 분석된 머신러닝 중 정확도가 우수한 모델을 선정하고, 이를 이용하여 예측 지도를 도출하고, 인자들의 중요도 및 관계를 규명할 수 있는 방법론을 제공하고자 했다. 본 연구에서는 일부 조사된 데이터를 기반으로 약 15종의 머신러닝 모델과 XAI의 Shapley Additive exPlanations (SHAP) 분석을 이용해 탄소흡수원의 위치데이터를 예측하고, 탄소흡수원 위치데이터의 구축 가능성을 검토했다.

2. 연구자료 및 방법

2.1. 연구지역 및 자료

2.1.1. 연구지역

본 연구는 서울시를 중심으로 수행되며, 서울시 내의 주요 공공 녹지와 식재지를 대상으로 한다. 서울시는 대한민국의 수도로서 고밀도의 건축물과 도로 등이 복잡하게 얹혀 있는 대도시 지역이다. 이러한 도시 공간에서 탄소흡수원의 위치를 예측하고자 한다.

2.1.2. 연구자료

본 연구에서는 탄소 흡수원의 위치정보 예측을 위한 지도 구축을 목표로 하고 있다. 이를 위해, 수목의 유무를 종속변수로 설정하였으며, 여러 식생 지수들을 독립변수로 사용하여 분석하였다. 수목의 위치 데이터는

2002년부터 2003년 사이 서울시에 식재된 수목의 위치를 활용하여 구축하였다. 해당 위치는 서울 열린 데이터 광장의 서울시 가로수 위치정보(<http://data.seoul.go.kr/dataList/OA-1325/S/1/datasetView.do>)와 서울시 공원 및 사유지 수목 위치정보(<http://data.seoul.go.kr/dataList/OA-1324/S/1/datasetView.do>)에서 추출하여 사용하였다. 또한, 수목이 없는 지역의 위치 데이터는 2019년에 제작된 세분류 토지피복지도(2020; <https://egis.me.go.kr>)를 기반으로 서울시 내의 수목이 자랄 수 없는 환경에 해당하는 지역의 객체들을 포인트로 변환하여 위치 데이터를 수집하였다. 환경공간정보서비스의 토지피

복지도 작성지침에 따르면, 토지피복지도는 지구 표면의 지형과 지물의 형태를 과학적 기준에 따라 분류하며, 동질의 특성을 지닌 구역을 지도로 표현한 환경 기초 지도이다.

해당 연구에서는 2019년 촬영된 Sentinel-2 위성 영상의 밴드를 활용하여 Plant Senescence Reflectance Index (PSRI), Ratio Vegetation Index (RVI), Normalized Differential Vegetation Index red-edge1 (NDVIre1), Normalized Differential Vegetation Index red-edge2 (NDVIre2), Normalized Differential Vegetation Index red-edge3 (NDVIre3), Normalized Differential Vegetation Index red-

Table 1. Information on vegetation indexes used in the study

Vegetation index	Name	Calculation formula	References
PSRI	Plant Senescence Reflectance Index	$PSRI = \frac{Band\ 8}{Band\ 4}$	Bagheri (2020)
RVI	Ratio Vegetation Index	$RVI = \frac{Band\ 8}{Band\ 4}$	Xue and Su (2017)
NDVIre1	Normalized Differential Vegetation Index red-edge1	$NDVIre\ 1 = \frac{Band\ 8 - Band\ 5}{Band\ 8 + Band\ 5}$	Zhou et al. (2022)
NDVIre2	Normalized Differential Vegetation Index red-edge2	$NDVIre\ 2 = \frac{Band\ 8A - Band\ 5}{Band\ 8A + Band\ 5}$	
NDVIre3	Normalized Differential Vegetation Index red-edge3	$NDVIre\ 3 = \frac{Band\ 8A - Band\ 6}{Band\ 8A + Band\ 6}$	
NDVIre4	Normalized Differential Vegetation Index red-edge4	$NDVIre\ 4 = \frac{Band\ 8A - Band\ 7}{Band\ 8A + Band\ 7}$	
NDVI	Normalized Difference Vegetation Index	$NDVI = \frac{Band\ 8 - Band\ 4}{Band\ 8 + Band\ 4}$	Tucker (1979)
NDRE	Normalized Difference Red Edge	$NDRE = \frac{Band\ 8 - Band\ 7}{Band\ 8 + Band\ 7}$	
EVI	Enhanced Vegetation Index	$EVI = \frac{2.5 \times (Band\ 8 - Band\ 4)}{(Band\ 8 + 6 \times Band\ 4 - 7.5 \times Band\ 2) + 1}$	Huete et al. (2002)
SAVI	Soil Adjusted Vegetation Index	$SAVI = \frac{Band\ 8 - Band\ 4}{(Band\ 8 + Band\ 4 + 0.428) \times 1.428}$	Huete (1988), Radočaj et al. (2023)
NDMI	Normalized Difference Moisture Index	$NDMI = \frac{Band\ 8 - Band\ 11}{Band\ 8 + Band\ 11}$	Klemas and Smart (1983), Taloor et al. (2021)
MSI	Moisture Stress Index	$MSI = \frac{Band\ 11}{Band\ 8}$	Kureel et al. (2022)
NDWI	Normalized Difference Water Index	$NDWI = \frac{Band\ 3 - Band\ 8}{Band\ 3 + Band\ 8}$	Gao (1996)
GCI	Green Chlorophyll Index	$GCI = \frac{Band\ 9}{Band\ 8} - 1$	Clevers and Gitelson (2013)
LCI	Leaf Chlorophyll Index	$LCI = \frac{Band\ 8 - Band\ 5}{Band\ 8 + Band\ 2}$	
SIPI	Structure Insensitive Pigment Index	$SIPI = \frac{Band\ 8 - Band\ 4}{Band\ 8 + Band\ 2}$	Peñuelas et al. (1995)

Table 2. Number of objects by level-3 land cover types used for extracting treeless locations

Level-3 land cover types	111	112	121	131	132	154	711
Number of points	16,185	20,276	902	17,371	77	902	285

edge4 (NDVIre4), Normalized Difference Vegetation Index (NDVI), Normalized Difference Red Edge (NDRE), Enhanced Vegetation Index (EVI), Soil Adjusted Vegetation Index (SAVI), Normalized Difference Moisture Index (NDMI), Moisture Stress Index (MSI), Normalized Difference Water Index (NDWI), Green Chlorophyll Index (GCI), Leaf Chlorophyll Index (LCI), Structure Insensitive Pigment Index (SIPI) 식생 지수를 사용했는데, 식생지수 계산식은 Table 1과 같다.

2.2. 연구방법

2.2.1. 수목 유무 데이터셋

본 연구에서는 Fig. 1과 같이 수목의 위치정보와 식생 지수를 이용해 탄소흡수원 위치예측을 하고자, 2002년부터 2003년 사이에 서울시에 식재된 수목 위치데이터를 활용하여 수목의 위치정보를 수집하였다. 그리고 수목이 없는 위치에 대한 샘플데이터는 세분류 토지피복 지도의 분류 중 단독주거시설, 공동주거시설, 공업시설, 상업업무시설, 혼합지역, 도로, 하천에 해당하는 지역

을 추출하여 샘플데이터를 추출하였다. 수목이 존재하는 지점의 데이터 총 52,942개의 샘플 포인트를 생성하였다. 수목이 없는 지점에서의 샘플데이터를 추출하기 위해, 세분류 토지피복지도 내에서 알맞은 유형의 객체로부터 무작위로 포인트를 추출했다. 균형 잡힌 데이터 학습을 위해 55,998개의 수목이 없는 지점의 샘플포인트를 추출해 수목이 존재하는 지점과 수목이 존재하지 않은 포인트 간의 비율을 약 1대 1로 만들어 총 108,940개의 샘플 포인트를 확보하였다. Table 2는 수목이 없는 지점 추출에 사용된 세분류 토지피복 분류에 대해서 각각 포인트 개수가 얼마나 있는지에 대한 표이다. 그리고 Fig. 2는 수목 유무에 대한 샘플데이터의 예시이며, 초록색 부분은 수목이 있는 지점, 빨간색 부분은 수목이 없는 지점이다.

이렇게 추출된 총 108,940개의 샘플 포인트를 사용하여 기계학습모델을 훈련시켰다. 식생 지수 값들을 독립 변수로, 수목의 유무를 종속변수로 설정하여 모델을 학습시켰다.

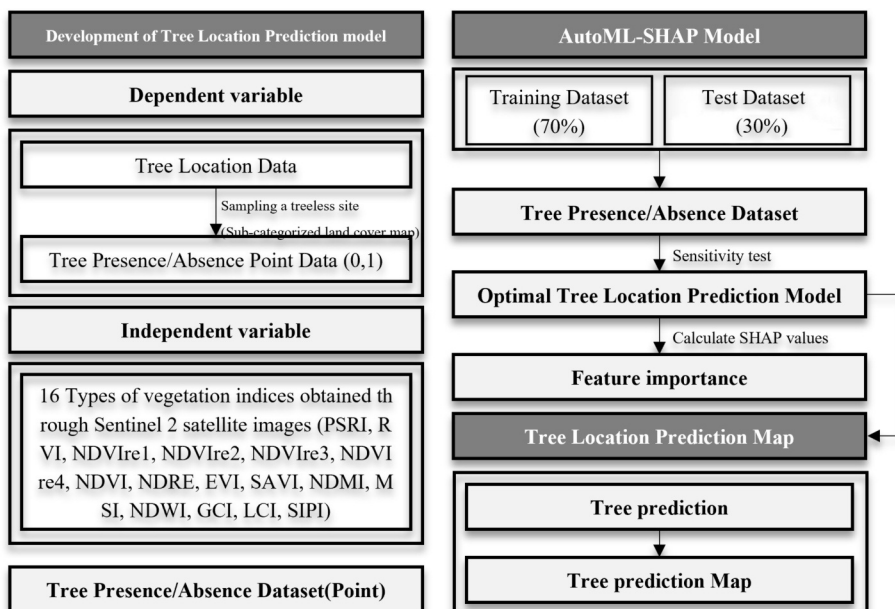
**Fig. 1.** Total process of the study.



Fig. 2. Sample data example (green: tree location, red: treeless locations).

2.2.2. AutoML-SHAP

본 연구에서는 수목 판별 예측에 대한 기계학습 모델을 선정하기 위해 automated machine learning (AutoML)을 이용한 기계학습 모델 선정 방식을 사용하였다. AutoML이란 머신러닝 모델 개발을 자동화하는 방식이다. 이는 많은 머신러닝 모델 개발 과정에서 데이터분할, 정제, 특징 선택 및 추출, 모델 선택, 하이퍼파라미터(Hyperparameter)

튜닝 등을 함수화하여 자동화할 수 있게 한다(IBM, 2023). AutoML 기술을 사용하게 된다면, 하나의 정형데이터를 가지고 학습된 다양한 기법의 머신러닝 모델 간 성능 비교를 수행할 수 있다. Table 3는 본 연구에서 수행된 AutoML을 이용한 기계학습 기법간 성능 비교 결과이다.

본 연구에서는 종속변수와 독립변수에 대해 약 15개

Table 3. Performance comparison between machine learning models using AutoML

Model	Accuracy	Precision	F1 score
Extra Trees Classifier	0.8357	0.8218	0.8327
Random Forest Classifier	0.8351	0.8155	0.8337
Category Boosting Classifier	0.8236	0.8048	0.8218
Extreme Gradient Boosting	0.8198	0.8012	0.8179
Light Gradient Boosting Machine	0.8171	0.7943	0.8166
Gradient Boosting Classifier	0.8046	0.7828	0.8038
K Neighbors Classifier	0.7917	0.7791	0.7873
Adaptive Boosting Classifier	0.7913	0.7801	0.7863
Logistic Regression	0.782	0.7979	0.7666
Linear Discriminant Analysis	0.7813	0.7996	0.7644
Ridge Classifier	0.7811	0.7994	0.7642
Decision Tree Classifier	0.7711	0.7558	0.7674
Naive Bayes	0.7504	0.8226	0.7059
Quadratic Discriminant Analysis	0.7358	0.8275	0.6781
Support Vector Machine	0.7218	0.6969	0.7295


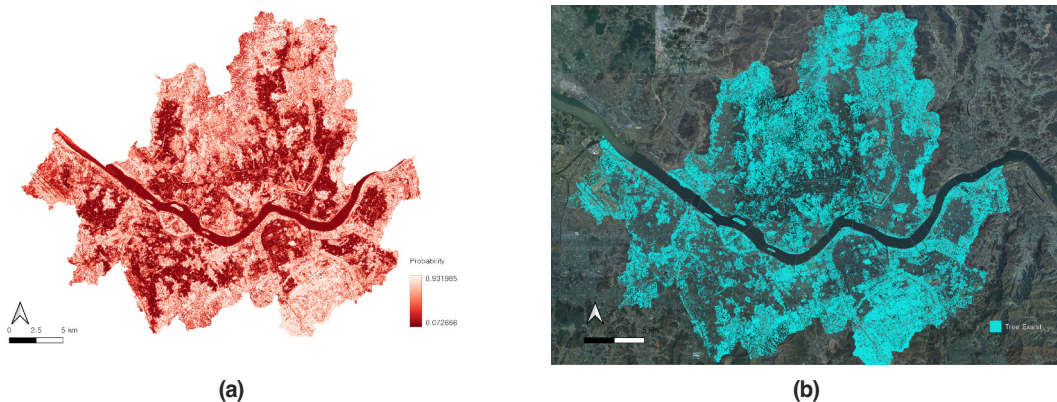
Table 4. Hyperparameter of tuned Extreme Gradient Boosting Classifier (XGBoost Classifier) model

Model	Hyperparameter
XGBoost Classifier	colsample_bytree: 0.8, gamma: 0.1, learning_rate: 0.1, max_depth: 7, n_estimators: 1000, reg_alpha: 0.1, reg_lambda: 0.1, subsample: 0.8

의 머신러닝 모델을 자동으로 학습하고, 정확성(Accuracy)이 높은 5가지 머신러닝 모델을 선정 후 하이퍼파라미터 튜닝을 진행했다. 선정된 5가지 상위 머신러닝 모델들은 트리 기반 앙상블 모델로, Random Forest Classifier, Extra Trees Classifier, Category Boosting Classifier (CatBoost Classifier), Extreme Gradient Boosting Classifier (XGBoost Classifier), Light Gradient Boosting Machine Classifier (LGBM Classifier)다. 이후, 해당 모델들에 대한 하이퍼파라미터 튜닝을 실행했을 시, XGBoost Classifier가 Accuracy: 0.8383, Precision: 0.8226, F1 score: 0.8378로 제일 우수한 성능을 보였다. 따라서 본 연구에서는 수목 판단 모델에 제일 적합한 모델을 XGBoost로 선정했다. Table 4는 본 연구에서 최종적으로 사용된 XGBoost 모델의 하이퍼파라미터이다. XGBoost는 의사결정트리 모델에 부스팅 기법을 통해 모델들을 합치는데, 모델별 결과 중 중요도가 높은 트리에 가중치를 제공한다(Oh et al., 2019). 이후, 생성된 모델을 이용하여 수목 예측 모델을 구축하였으며, 이를 바탕으로 서울시의 수목 위치 예측 지도를 작성하였다. Fig. 3은 이렇게 제작된 수목 위치 확률 지도와 수

목 위치 예측 지도이다.

본 연구는 XAI 중 하나인 SHAP 분석을 통하여 모델의 output에 대해 독립변수의 영향력을 분석하였다(Fig. 4). SHAP 분석은 모델에서 각 입력 변수가 결과에 미치는 영향을 이해하는데 도움을 주며, 종속 변수의 예측을 결정하는 방법에 대한 해석을 제공한다. 즉, SHAP 분석은 Shapely 값을 사용하여 모델 학습에서 독립변수와 종속변수 간의 상관관계를 조사하는 도구이다. 이를 통해 수목과 선택된 식생 지수들 사이의 복잡한 관계성을 파악하였다.

**Fig. 4.** Analyzed SHAP values of independent variables.**Fig. 3.** Result of tree prediction model. (a) Tree existence probability map. (b) Tree location prediction map.

3. 연구결과

본 연구에서는 수목의 유무와 총 16종의 식생지수를 이용하여 서울시 내 수목의 식재 유무를 분류하는 XG Boost 머신러닝 모델을 생성했다. 해당 모델은 정확도 (Accuracy)가 0.816, 정밀도(Precision)가 0.7991, F1 score가 0.8135로 AutoML을 이용해 여러 머신러닝 모델에 대한 학습을 진행했을 때 타 기법의 머신러닝 모델보다 더 적합하다고 판단하였다. 본 연구에서는 선정된 XGBoost 머신러닝 모델에 XAI 학문의 SHAP 분석을 통해 16종의 식생지수와 수목의 유무에 대한 관계성을 확인했다. 결과에 의하면 수목이 어느 지점에 존재하는지에 대한 예측을 할 때 RVI가 제일 높은 기여도를 보였고, RVI 값이 높을수록 수목이 존재할 확률이 높아지는 양의 상관성을 가진 것을 확인했다. GCI와 NDVI 또한 수목이 존재하는지 판단을 할 때 높은 기여도를 가지면서 양의 상관성을 가지는 것으로 나타났다. 반대로 NDMI의 경우 수목 존재 판단에 기여를 안 하고, 상관성 또한 존재하지 않는 것으로 나타났다.

앞서 XGBoost 모델의 학습 결과를 이용하여 0과 1

Table 5. Accuracy comparison between tree prediction criteria

Tree prediction criteria	Accuracy
0.5	0.8850
0.6	0.8131
0.7	0.6957
0.8	0.4870
0.9	0.1282

사이의 확률로 표현되는 서울시의 수목 위치 예측 확률 지도를 제작하였다. 또한, 예측 확률 지도를 이용한 수목 예측 지도 또한 제작하였다. 예측 지도에 대한 검증을 위해, 모델 학습에 사용된 샘플 수목 데이터 중 모델이 찾아낸 수목의 수를 세어 예측 지도의 정확도를 확인했다. 일정한 확률 기준을 수목이 존재한다고 판단하는 기준으로 한 각 예측 지도의 정확도를 비교해보았다. Table 5는 그 결과이다. 수목의 존재 확률 기준을 0.5 이상으로 했을 때, 모델 학습에 사용된 샘플 수목 데이터 중 약 89%가 수목으로 예측되었으나, 위성사진과의 비교를 했을 때 수목이 아닌 지역을 잘못 판단하는 경우가 많았다. 또한, 수목의 존재를 판단하는 확률 기준을 각




Fig. 5. This is an image for prediction performance review. (a) Aerial Image. (b) Level-3 landcover map. (c) Tree location prediction map of Yeouido area.




Fig. 6. This is an image for prediction performance review. (a) Aerial Image. (b) Level-3 landcover map. (c) Tree location prediction map near Seoul Station.

각 0.7, 0.8, 0.9 이상으로 했을 때는 위성사진에 비해 수목인 지역을 잘 탐지하지 못하는 것을 확인했다. 반면, 확률 기준 0.6으로 설정했을 때, 샘플 수목 데이터 중 약 81%를 수목이라 판단했다. 따라서, 확률 기준 0.6을 수목이 존재한다고 판단하는 적합한 기준으로 설정했다.

본 연구에서는 수목 위치 예측 지도를 이용해 서울시 내에 위치한 여의도와 서울역 인근에 대해 수목 위치 예측의 성과를 파악했다. Fig. 5는 서울시 여의도 상공을 촬영한 위성영상과, 세분류 토지피복지도 그리고 수목 위치 예측지도를 비교한 것이다. 예측된 수목의 위치를 보면 세분류 토지피복지도에서 기타 초지로 분류가 안된 가로수들이 위치해 있는 것을 확인하였다. Fig. 6은 서울역 인근의 상공을 촬영한 위성영상과 해당 지역의 세분류 토지피복지도, 수목 위치 예측지도를 비교한 것이다. 여의도와 마찬가지로 세분류 토지피복지도에서 파악되지 않은 가로수들이 수목의 위치로 예측된 것을 확인하였다.

4. 결론

본 연구에서는 2019년에 촬영된 Sentinel-2 위성영상을 활용하여 만들어진 총 16종의 식생지수들을 가지고 수목의 존재 유무를 판단하는 머신러닝 모델을 제작하고, 수목의 위치를 통해 탄소흡수원의 위치를 예측했다. 또한, 본 연구에서 사용된 식생지수들과 수목의 존재 사이의 관계성을 XAI를 통해 확인해 탄소흡수원에 영향을 끼치는 식생지수들에 대해 파악했다.

수목 위치 예측모델을 학습시키기 위해 서울 열린 데이터 광장의 서울시 가로수 위치정보와 서울시 공원 및 사유지 수목 위치정보에서 추출한 수목 데이터와 세분류 토지피복지도(2020)에서 추출한 수목이 존재하지 않는 데이터를 약 1대1 비율로 합쳐 만든 샘플데이터를 제작해 사용했다. 머신러닝 학습 기법의 경우, AutoML을 사용해 다양한 기계학습 기법을 통해 수목의 존재를 예측했을 때의 성능을 파악 및 비교를 했고, 이를 통해 XGBoost가 본 연구에 제일 적합한 기계학습모델인 것을 확인했다. 만들어진 XGBoost 모델에 대하여 SHAP 기법을 통해 수목의 존재와 식생지수 간의 관계성을 확인했다. 식생지수 중 RVI, GVI, NDVI의 경우 수목의 존

재를 확인하는데 있어 큰 기여도를 가지고 있고, 세 식생지수 모두 수목의 존재 경향과 양의 상관성을 가지는 것을 확인했다. 이렇게 제작된 XGBoost 모델을 이용하여 서울시 내에 수목이 존재할 수 있는 확률을 지도로 표현을 한 뒤, 0.5부터 0.9까지 0.1 단위씩 수목의 존재 판단의 기준이 되는 확률을 바꿔가며 예측지도를 제작했다. 결과적으로 0.6을 수목 판단의 기준이 되는 확률로 설정하여 수목 위치 예측 지도를 제작했다. 해당 지도를 가지고 서울시 여의도와 서울역 인근 지역에 대해 세분류 토지피복지도와 비교분석을 수행했고, 이를 통해 본 연구에서 제작된 수목 예측 모델의 경우 대로변 주변의 탐지되기 어려운 가로수의 경우에도 수목의 위치로 예측이 된다는 것을 확인했다.

해당 연구에서 사용한 독립변수 식생지수 중 수목의 위치와 상관성이 없다고 판단되는 식생지수를 제거 후 모델을 학습시킨다면 더 나은 결과가 나올 것이라고 판단한다. 더 나아가 해당 연구의 결과인 수목에 대한 위치 데이터와 함께 수목의 흉고직경 또는 수관면적 데이터 현장 조사 데이터가 구축된다면, 탄소흡수원의 탄소흡수량에 대한 통계적 계산을 할 수 있을 것이라고 기대한다.

사사

본 논문은 국토교통부/국토교통과학기술진흥원의 지원(과제번호 RS-2023-00242291)으로 한국환경연구원이 수행한 '탄소공간지도기반 계획지원 기술개발(2023-072(R))'의 연구 보고서를 기반으로 하였습니다.

Conflict of Interest

No potential conflict of interest relevant to this article was reported.

References

- Bagheri, N., 2020. Application of aerial remote sensing technology for detection of fire blight infected pear

- trees. *Computers and Electronics in Agriculture*, 168, 105147. <https://doi.org/10.1016/j.compag.2019.105147>
- Cho, S. W., Kim, Y. K., and Park, J. W., 2017. Development of forest volume estimation model using airborne LiDAR data - A case study of mixed forest in Aedang-ri, Chunyang-myeon, Bonghwa-gun -. *Journal of the Korean Association of Geographic Information Studies*, 20(3), 181–194. <https://doi.org/10.11108/KAGIS.2017.20.3.181>
- Clevers, J. G., and Gitelson, A. A., 2013. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. *International Journal of Applied Earth Observation and Geoinformation*, 23, 344–351. <https://doi.org/10.1016/j.jag.2012.10.008>
- Gao, B. C., 1996. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Greenhouse Gas Inventory and Research Center of Korea, 2020. *2020 National greenhouse gas inventory report of Korea*. Korean Ministry of Environment, Greenhouse Gas Inventory and Research Center of Korea.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., and Ferreira, L. G., 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1–2), 195–213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Huete, A. R., 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- IBM, 2023. What is AutoML?. Available online: <https://www.ibm.com/kr-ko/topics/automl> (accessed on Sept. 11, 2023).
- Kim, H., Kang, H., Kim, R. H., Kim, C. M., Koh, K. C., and Lee, K. H., 2013. Estimation of forest management ratio under article 3.4 of the Kyoto Protocol: A case study on the Chungcheongbuk-do. *Journal of Korean Forest Society of Forest Science*, 102(4), 608–616. <https://doi.org/10.14578/JKFS.2013.102.4.608>
- Kim, I. H., Yang, A., Kim, S. U., Han, D. H., Shin, G. S., Park, S. J., Kim, H. Y., and Kim, Y. M., 2022. Study on carbon storage calculation and green roof simulation modules to understand the current status and potential of urban ecosystem services: In case of Suwon-si in Korea. *Journal of Korea Planning Association*, 57(1), 128–144. <http://doi.org/10.17208/jkpa.2022.02.57.1.128>
- Klema, V., and Smart, R., 1983. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. *Photogrammetric Engineering and Remote Sensing*, 49(1), 77–83. https://www.asprs.org/wp-content/uploads/pers/1983journal/jan/1983_jan_77-83.pdf
- Kureel, N., Sarup, J., Matin, S., Goswami, S., and Kureel, K., 2022. Modeling vegetation health and stress using hyperspectral remote sensing data. *Modeling Earth Systems and Environment*, 8, 733–748. <https://doi.org/10.1007/s40808-021-01113-8>
- Oh, J. Y., Ham, D. H., Lee, Y. G., and Kim, G., 2019. Short-term load forecasting using XGBoost and the analysis of hyperparameters. *The Transactions of the Korean Institute of Electrical Engineers*, 68(9), 1073–1078. <https://doi.org/10.5370/KIEE.2019.68.9.1073>
- Peñuelas, J., Baret, F., and Filella, I., 1995. Semi-empirical indices to assess carotenoids/chlorophyll *a* ratio from leaf spectral reflectance. *Photosynthetica*, 31(2), 221–230. https://www.researchgate.net/profile/Josep-Penuelas/publication/235645504_Photosyn1995/links/02bfe512443728f376000000/Photosyn1995.pdf

- Radočaj, D., Šiljeg, A., Marinović, R., and Jurišić, M., 2023. State of major vegetation indices in precision agriculture studies indexed in Web of Science: A review. *Agriculture*, 13(3), 707. <https://doi.org/10.3390/agriculture13030707>
- Seoul Development Institute, 2006. *A preliminary goal-setting and implementing strategies for reducing greenhouse gas emissions in Seoul* (Publication No. 2006-R-17). Seoul Development Institute. https://www.si.re.kr/sites/default/files/2006-R-17_0.pdf
- Taloor, A. K., Manhas, D. S., and Kothiyari, G. C., 2021. Retrieval of land surface temperature, normalized difference moisture index, normalized difference water index of the Ravi basin using Landsat data. *Applied Computing and Geosciences*, 9, 100051. <https://doi.org/10.1016/j.acags.2020.100051>
- Tucker, C. J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- Xue, J., and Su, B., 2017. Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 2017, Article ID 1353691. <https://doi.org/10.1155/2017/1353691>
- Yu, S. C., Ahn, W., and Ok, J. A., 2015. A study on construction plan of the statistics for national greenhouse gas inventories (LULUCF Sector). *Spatial Information Research*, 23(3), 67–77. <https://doi.org/10.12672/ksis.2015.23.3.067>
- Zhou, X. X., Li, Y. Y., Luo, Y. K., Sun, Y. W., Su, Y. J., Tan, C. W. et al., 2022. Research on remote sensing classification of fruit trees based on Sentinel-2 multi-temporal imageries. *Scientific Reports*, 12, 11549. <https://doi.org/10.1038/s41598-022-15414-0>