

다시기 Landsat TM 영상과 기계학습을 이용한 토지피복변화에 따른 산림탄소저장량 변화 분석*

이정희¹ · 임정호^{1*} · 김경민² · 허준³

Change Analysis of Aboveground Forest Carbon Stocks According to the Land Cover Change Using Multi-Temporal Landsat TM Images and Machine Learning Algorithms*

Jung-Hee LEE¹ · Jung-Ho IM^{1*} · Kyoung-Min KIM² · Joon HEO³

요 약

가속되는 지구온난화로 인해 한반도 주변의 탄소순환에 대한 명확한 이해의 필요성이 제기되고 있다. 산림은 이산화탄소의 주요 흡수원으로 지상 탄소량의 대부분을 저장하고 있어 이에 대한 추정치 필요하다. 우리나라에서는 국가산림자원조사의 표본점에서 측정되는 헥타르당 임목축적량을 활용하여 산림 탄소저장량을 추정한다. 하지만 탄소저장량은 요약된 수치 형태로 발표하고 있어 탄소저장량의 공간적 분포를 파악하는 것이 어렵다. 본 연구에서는 토지피복변화가 빠르고 국가산림자원조사 표본점 배치가 부족한 도시지역을 대상으로 UNFCCC의 Approach 3와 Tier 3를 충족하는 격자 기반 산림탄소저장량을 추정하였다. 토지피복변화 및 산림탄소저장량은 1991, 1992, 2010, 2011년에 취득된 Landsat 5 TM 영상과 고해상도 항공사진, 제 3차 및 제 5, 6차 국가산림자원조사 자료를 이용하여 추정하였다. 토지피복변화는 기계학습을 이용하여 변화된 토지피복과 변화되지 않은 토지피복 항목을 한 번에 분류하여 추정하였으며, 산림탄소저장량은 반사도, 밴드비율, 식생지수, 지형변수를 입력변수로 하여 기계학습을 통해 추정하였다. 연구 결과, 산림이 그대로 산림으로 유지되는 지역의 경우 33.23tonC/ha의 흡수를 하였으며 비산림이 산림으로 변한 지역의 경우 이보다 큰 36.83tonC/ha의 흡수가 진행된 것으로 추정되었다. 산림이 비산림으로 바뀐 경우에는 -7.35tonC/ha로, 배출이 일어난 것으로 추정되었다. 본 연구를 통하여 토지피복변화에 따른 산림탄소저장량 변화를 정량적으로 이해할 수 있었으며, 향후 효율적인 산림관리에 기여할 수 있을 것으로 판단된다.

2015년 9월 25일 접수 Received on September 25, 2015 / 2015년 12월 2일 수정 Revised on December 2, 2015 /
2015년 12월 21일 심사완료 Accepted on December 21, 2015

* 이 연구는 2012년도 국립산림과학원의 기후변화대응 산림정책 및 기술개발 사업 위탁과제로 수행되었음.

1 울산과학기술대학교 도시환경공학부 School of Urban and Environmental Engineering, Ulsan National Institute of Science and Technology

2 국립산림과학원 국제산림연구과 Global Forest Resources Division, Korea Forest Research Institute

3 연세대학교 사회환경시스템공학부 School of Civil and Environmental Engineering, Yonsei University

* Corresponding Author E-mail : ersgis@unist.ac.kr

주요어 : 토지피복변화분석, 탄소 저장량 추정, 불확실성 분석, 국가산림자원조사, Random Forest, Support Vector Machine/Regression

ABSTRACT

The acceleration of global warming has required better understanding of carbon cycles over local and regional areas such as the Korean peninsula. Since forests serve as a carbon sink, which stores a large amount of terrestrial carbon, there has been a demand to accurately estimate such forest carbon sequestration. In Korea, the National Forest Inventory(NFI) has been used to estimate the forest carbon stocks based on the amount of growing stocks per hectare measured at sampled location. However, as such data are based on point(i.e., plot) measurements, it is difficult to identify spatial distribution of forest carbon stocks. This study focuses on urban areas, which have limited number of NFI samples and have shown rapid land cover change, to estimate grid-based forest carbon stocks based on UNFCCC Approach 3 and Tier 3. Land cover change and forest carbon stocks were estimated using Landsat 5 TM data acquired in 1991, 1992, 2010, and 2011, high resolution airborne images, and the 3rd, 5th~6th NFI data. Machine learning techniques(i.e., random forest and support vector machines/regression) were used for land cover change classification and forest carbon stock estimation. Forest carbon stocks were estimated using reflectance, band ratios, vegetation indices, and topographical indices. Results showed that 33.23tonC/ha of carbon was sequestered on the unchanged forest areas between 1991 and 2010, while 36.83 tonC/ha of carbon was sequestered on the areas changed from other land-use types to forests. A total of 7.35 tonC/ha of carbon was released on the areas changed from forests to other land-use types. This study was a good chance to understand the quantitative forest carbon stock change according to the land cover change. Moreover the result of this study can contribute to the effective forest management.

KEYWORDS : *Land-Use Change Analysis, Carbon Stocks Estimation, Uncertainty Analysis, National Forest Inventory, Random Forest, Support Vector Machine/Regression*

서론

온실효과로 인한 지구온난화는 가속되고 있으며, 지구온난화에 의한 탄소순환의 변화가 미래 기후 예측에 있어 큰 불확실성 요인 중 하나로 이해되고 있다. 1997년 체결된 교토 의정서(Kyoto protocol)에 따르면 의무 당사국에 대해 법적 구속력이 있는 온실가스 감축을 요구하고 있다. 우리나라는 의무 당사국은 아니지

만 2010년을 기준으로 제 8위 이산화탄소 배출국임을 고려할 때, 가까운 시일 내에 의무 당사국의 위치에 오를 것으로 예상된다. 따라서 효율적인 탄소배출 규제를 수립하기 위해서는 한반도 주변의 탄소순환에 대한 명확한 이해가 요구되며, 우리나라의 이산화탄소 배출 및 흡수량을 체계적으로 정량화해야 한다. 산림 바이오매스와 탄소저장량은 이러한 이산화탄소의 주요 흡수원으로 지상 탄소량의 대부분을 저장하고 있고, 대기와 이산화탄소를 교환함으로써 전

지구적인 탄소 순환에 큰 영향을 미치고 있다 (Fuchs *et al.*, 2009).

우리나라에서는 국가산림자원조사(National Forest Inventory, NFI)의 표본점에서 측정되는 헥타르 당 임목축적량을 활용하여 산림 탄소저장량을 추정한다. 탄소저장량은 국가 전체 또는 시도별로 요약된 수치 형태로 발표하고 있기 때문에 국지적인 탄소저장량의 공간적 분포를 파악하는 것이 어렵다. 또한, 표본점이 없는 지역에 대해서는 추정이 쉽지 않아 산림 탄소저장량의 분포를 하나의 통계 값이 아닌 연속적인 표면으로 제공된다면 산림의 관리 측면에서 효율성이 증가할 것으로 예상된다. 우리나라의 경우 산림 탄소 추정 방법으로 IPCC 우수 실행지침의 기본 방법인 획득-손실법(gain-loss method)을 이용하고 있다. IPCC 가이드라인에 따르면 배출/흡수계수로 전 지구적 기본 값을 사용하면 Tier 1, 국가 고유계수를 사용하면 Tier 2, 그리고 상세한 국가산림조사나 모델에 근거하면 Tier 3로 구분하고 있다. 이와 더불어 토지피복 자료의 수집방법에 있어 국가 통계에서 구할 수 있는 토지피복 면적 자료를 이용하면 Approach 1, 공간적으로 분명하지는 않지만 면적별 토지피복 변화 매트릭스를 이용하면 Approach 2, 공간적으로 분명한 wall-to-wall 방식의 시계열 토지피복 변화자료를 이용하면 Approach 3에 해당한다(Kim *et al.*, 2008; Kim *et al.*, 2011).

일반적으로 산림탄소저장량 추정 연구는 NFI 자료와 원격탐사 자료를 연계하여 이용하는 방법이 사용되고 있다(Wulder *et al.*, 2008; Im *et al.*, 2009; Kim *et al.*, 2014). 원격탐사 자료로부터 산림 바이오매스 및 탄소저장량을 추정하는 기법은 기본적인 회귀분석에서부터 확률 모델, 기계학습, 그리고 수관추출 등을 융합하는 방향으로 확장되고 있다(Gleason *et al.*, 2011; Park *et al.*, 2012). 예를 들어 bagging, regression trees, random forest (RF), support vector regression (SVR)과 같은 기계학습 알고리즘이나 기존의 회귀모델보다 복잡한 확률 모델을 이용하여 바이오매스 및 탄소저장량을

포함한 산림 변수를 추정하는 연구가 활발해지고 있다(Jung *et al.*, 2010; Neumann *et al.*, 2012; Li *et al.*, 2014; Zhang *et al.*, 2014; Kattenborn *et al.*, 2015; Latifi *et al.*, 2015). Goetz *et al.*(2009)는 산림 바이오매스 및 탄소 저장량 추정에 사용되는 다양한 방법들을 비교분석하였으며, 기계학습에 의한 바이오매스와 탄소저장량의 추정 및 모니터링이 보다 일관성 있는 결과를 보여준다고 분석하였다. 산림탄소저장량을 추정하는 그 외의 방법들에는 개체목 수준에서 수관을 추출한 후 다양한 기법들을 적용하는 방법과 다중센서 자료통합 알고리즘을 통해 추정하는 방법이 있다 (Popescu *et al.*, 2004; Muukkonen *et al.*, 2007; Erdody *et al.*, 2010).

기존 연구에서 다양한 기법으로 산림탄소저장량을 추정한 것과 달리 본 연구에서는 토지피복변화에 따른 산림탄소저장량을 정량적으로 살펴보았다. 토지피복변화가 빠르고 국가 산림자원조사 표본점 배치가 부족한 도시지역을 대상으로 UNFCCC(United Nations Framework Convention on Climate Change)의 Approach 3과 Tier 3을 충족하는 격자 기반 산림탄소저장량 추정을 수행하고자 한다. 다중시기 LANDSAT 5 TM 자료와 현장 조사 자료를 이용하여 토지피복 분석 및 산림탄소저장량 추정을 수행하였으며, 추정결과들을 바탕으로 토지피복변화에 따른 산림탄소저장량을 분석하였다. 또한, 모델의 불확실성을 분석하여 모델에 대한 이해도를 높이고자 하였다.

연구대상지역 및 연구자료

1. 연구대상지역

본 연구에서는 토지피복변화에 따른 산림탄소저장량 변화를 분석하기 위해 도시 확장으로 토지피복변화가 크게 나타난 대전광역시, 세종특별자치시를 연구대상지역으로 선정하였다. 대전시는 1985년에 설립된 대규모 국책 계획도시로서 둔산 신도시 개발이 시작되면서 본격적

인 도시 확장이 시작되었다. 대전광역시의 지리적 특징으로 동부와 남부 지역에는 고지대로 식장산과 보문산이 자리하고 있으며, 서쪽 공주시와의 경계에 계룡산이 위치하고 있다. 또한 금강의 지류들이 합류하여 북쪽으로 흘러 들어가며 그 주변으로 넓은 평야가 발달되어 있다. 대전의 기후는 온대성 기후로 연평균 기온이 13도, 연평균 강수량 1459mm의 대륙성 기후를 나타내고 있다. 세종특별자치시는 서울특별시의 과밀화와 국토의 균형 잡힌 발전을 위해 2012년에 출범하였다. 앞으로 지속적으로 서울과 과전에 분산되어 있던 정부 기관들을 이전할 예정이며, 2000년대 중반 이후로 많은 토지피복의 변화를 보여주고 있는 지역이다. 세종시는 대전시와 인접해 있기 때문에 기후는 대전시와 비슷하다.

2. 연구자료

1) 위성영상자료

본 연구에 사용된 위성영상자료는 Landsat 5 TM으로 1991년~1992년에 취득된 두 영상과 2010년~2011년에 취득된 두 영상을 사용하였으며, 정확한 취득날짜는 표 1과 같다. 이상적으로는 계절의 차이를 최소화해야 하나 광학 센서 자료의 특성상 구름이 없어야 하므로 부득이하게 영상 취득 시기에 계절의 차이가 존재하였다. 각 TM 자료의 총 7개 밴드 중 열외선 밴드를 제외한 6개 밴드를 사용하였다. 일반적으로 한 시기의 영상을 사용하여 우리나라 지역의 토지피복분류를 수행할 때에는 식생의 분포가 가장 쉽게 구별되는 여름 영상이 이상적인데, 1991년에는 8월 영상이 이용 가능하였지만 2010년~2011년에는 이용 가능한 여름 영상이 없어 봄, 가을 영상을 모두 이용하여 토지피복분류의 정확도를 높이고자 하였다. 2010년~2011년 영상과 비슷한 조건을 맞추기 위해 1992년 5월에 취득된 영상도 이용하였다.

위성자료를 수집한 날짜가 다르거나 서로 다른 센서로부터 취득된 위성자료를 동시에 사용하기 위해서는 각 밴드의 밝기 값을 위성의 반

사도로 변환하는 방사보정 및 대기에 의한 왜곡을 보정하는 대기보정이 필요하며, 위성자료를 지도상에 정확한 위치에 나타내기 위한 기하보정이 필요하다. 하지만 본 연구에서는 사전 테스트를 통해 ENVI FLAASH를 이용한 대기보정의 여부가 토지피복 분류와 산림탄소저장량 추정의 정확도 향상을 가지오지 않았기 때문에 대기보정 없이 진행한 결과를 가지고 분석하였다. 방사보정은 NASA의 Markhan and Barker(1987)가 제시한 식 (1)과 식 (2)을 통해 변환하였으며, 기하보정은 반사도로 변환된 영상을 고해상도 항공사진을 참고자료로 하여 GCP(Ground Control Points)와 최근린(Nearest Neighbor) 리샘플링 방법을 이용하여 수행하였다.

$$L_{\lambda} = LMIN_{\lambda} + \frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{calmax_{\lambda}} - Q_{calmin}} \cdot (Q_{CAL} - Q_{calmin}) \quad (1)$$

$$\rho_{\lambda} = \frac{\pi \cdot L_{\lambda} \cdot d^2}{ESUN_{\lambda} \cdot \cos(\theta_s)} \quad (2)$$

L_{λ} : 센서의 분광 방사량 ($Watt/(m^2 \mu m)$), λ : 밴드,

Q_{calmin} : $LMIN_{\lambda}$ 에 대응하는 정량화된 최소 영상소 값 (DN=0),

Q_{calmax} : $LMAX_{\lambda}$ 에 대응하는 정량화된 최대 영상소 값 (DN=255),

$LMIN_{\lambda}$: Q_{calmin} 의 범위로 변환된 분광 방사량 ($Q_{calmin} [W/(m^2 sr \mu m)]$),

$LMAX_{\lambda}$: Q_{calmax} 의 범위로 변환된 분광 방사량 ($Q_{calmax} [W/(m^2 sr \mu m)]$),

Q_{CAL} : 정량화된 영상소 값 [DN], ρ_{λ} : 위성의 반사도,

$ESUN_{\lambda}$: 평균 태양 복사 조도 ($Watt/(m^2 \mu m)$)

θ_s : 태양 천저각, d : 태양과 지구사이의 거리 (astronomical unit)

TABLE 1. Specification of Landsat TM data used in this study

Year	Spatial resolution	Spectral resolution	Radiometric resolution	Acquisition date
1991 (NFI: 1990~1991)	30×30m	Blue(0.45–0.52 μ m)	8 bits	1991. 08. 28
		Green(0.52–0.60 μ m)		1992. 05. 02
		Red(0.63–0.69 μ m)		
2011 (NFI: 2007~2011)	30×30m	NIR(0.76–0.90 μ m)	8 bits	2010. 10. 19
		MIR1(1.55–1.75 μ m)		
		MIR2(2.08–2.35 μ m)		2011. 04. 13

2) 고해상도 항공사진

본 연구에서는 제 3차 임상도 및 1:5,000 임상도 구축에 활용된 고해상도 항공사진을 토지피복분류에 활용하였다. 제 3차 임상도 구축에 활용된 항공사진(1991년 촬영)은 흑백영상으로 0.8m의 공간해상도를 가지고 있으며, 제 5차 임상도 구축에 활용된 항공사진(2011년 촬영)은 0.25m의 컬러영상이다. 고해상도 항공사진은 Landsat TM 자료의 토지피복분류를 위하여 표본 자료를 추출하는데 사용되었다.

3) 국가산림자원조사 자료 및 임상도

IPCC 가이드라인의 산림 정의를 충족하는 산림 경계 추출을 위해 국가산림자원조사(National Forest Inventory, NFI)에서 구축한 임상도를 활용하였다. 임상도에서 구분되는 산림은 산림면적 0.1ha 이상, 최소 수고 5m까지 자랄 수 있는 임목의 수관밀도가 10% 이상이며 최소폭 20m 이상인 토지로 죽림을 포함한다. 본 연구에서는 두시기 임상도(1991, 2011)를 각각 3차 NFI(1990~1991)와 5차(2007~2010) 및 6차 NFI(2011) 자료와 연계하여 사용하였다. 국가산림자원조사는 전국 산림의 약 640만 ha를 대상으로 실시하고 있

으며, 계통추출법(Systematic sampling)을 이용해 추출한 약 4,000여개의 고정 표본점(Permanent Sample Plot, PSP)에 대해서 현장 조사하고 있다. 각 고정표본점은 4개의 부표본점으로 구성된 집락표본점 형태로 배치된다. 이러한 현장조사를 통해 구축된 국가산림자원조사 자료는 다양한 정보를 포함하고 있으며, 구체적인 조사 내용은 임분 현황조사, 임목조사, 벌근/고사목/피해목 조사, 산림식생 조사(치수, 초본식생), 토양탄소 조사를 포함한다. 대전광역시와 세종특별자치시 주변 지역의 부표본점 분포현황은 그림 1과 같으며, 임상별 부표본점 분포현황은 표 2와 같다.

연구방법

본 연구에서는 토지피복변화에 따른 산림탄소저장량 분석을 위해 토지피복변화분류, 산림탄소저장량 추정, 토지피복변화에 따른 산림탄소저장량 분석, 모델 불확실성 분석의 네 과정으로 진행하였다.

1. 기계학습

기계학습은 인공지능의 한 분야로서 일반적

TABLE 2. The number of NFI samples by forest type and period

Period	Forest type	Number of NFI samples
1990~1991	Coniferous	338
	Deciduous	112
	Mixed	79
2007~2011	Coniferous	187
	Deciduous	344
	Mixed	294




FIGURE 1. Locations of the NFI samples around Daejeon and Sejong cities used in this study

으로 훈련자료를 바탕으로 자체적으로 학습을 통해 문제를 해결한다. 기계학습의 장점은 비모수 기법으로 훈련자료에 대한 가정이 없으며, 대부분의 기계학습이 비선형적이고 계층적인 관계도 잘 모의한다. 일부 기계학습의 경우에는 범주형 자료도 사용가능하며, 아주 적은 훈련자료로도 안정적인 결과를 보여주기도 한다. 하지만 많은 기계학습이 훈련자료의 구성에 민감하며, 경우에 따라 많은 훈련자료를 필요로 하기도 한다. 본 연구에서는 토지피복변화분류와 산

림탄소저장량 추정을 위해 기계학습 알고리즘 중 SVM(Support Vector Machine), SVR(Support Vector Regression), RF(Random Forest)를 이용하였다.

SVM과 SVR은 기계학습 알고리즘 중 원격탐사 분야에서 비교적 최근에 많이 활용된 기법으로 특히 토지 및 식생 분류에서 적은 훈련자료로도 높은 정확도를 보여주고 있다(Foody and Mathur, 2006). SVR은 SVM의 회귀(regression) 형태로 종속변수가 범주형이 아

나라 연속형인 경우이다. SVM은 훈련자료를 이용하여 클래스를 나누기에 최적인 초평면을 찾는 것에 기초하고 있으며, 커널함수를 통해 원 자료를 고차원 평면으로 변화시켜 보다 쉽게 최적의 초평면을 찾는다. 따라서 어떤 커널함수를 사용하는가가 SVM의 수행 능력에 중요한 영향을 미치며, SVM에서 커널함수가 유효하기 위해서는 반드시 Mercer's Theorem을 만족해야 한다. 많이 사용되고 있는 커널함수로는 선형, 다항식, 가우시안, 시그모이드(sigmoid), Radial Basis Function(RBF) 등이 있다. 본 연구에서는 다른 커널 함수들보다 안정적이고 좋은 결과를 보여주는 RBF 커널함수(Xu *et al.*, 2012; Ramedani *et al.*, 2014)를 적용하였다. RBF 커널함수에는 크게 두 가지 파라미터가 사용되는데 파라미터를 결정하기 위한 다양한 최적화기법(Shevade *et al.*, 2000; Chapelle *et al.*, 2002; Keerthi and Lin, 2003; Huang and Wang, 2006) 중 격자 찾기(grid search) 기법을 적용하였다.

RF는 원격탐사분야에서 분류기법으로 많이 활용되고 있으며, 범주형 변수를 종속변수로 이용하여 수고나 바이오매스 등 연속성 변수에 대한 추정 연구에서도 활발히 이용되고 있다(Ahmed *et al.*, 2015; Dube *et al.*, 2014; Gleason *et al.*, 2012; Yu *et al.*, 2011; Zhang *et al.*, 2014). RF는 다양한 tree-based 기계학습들 중 bootstrapping 방법을 이용하여 수많은 결정나무를 구축하고 그 결과를 이용하여 결과를 예측한다(Hastie *et al.*, 2009). 결정나무는 기본적으로 입력 자료와 추정변수의 연관성을 설명하는 규칙 기반의 이진 결정 구조로 이루어져 있다. RF는 결정나무의 훈련자료에 대한 민감도를 보완하기 위해 크게 두 가지의 무작위(Randomness) 함수를 도입하였다(Breiman, 2001). 첫 번째 무작위 함수는 훈련자료로 전체 훈련자료에서 일부만 사용하고 나머지(Out-of-bag data)는 교차검증(Cross-validation)을 통해 내부적으로 모델을 평가하는데 사용한다. 두 번째 무작위 함수는 나무의 각 노드에서 무작위로 선택된 일부의

입력 변수만 사용하며, 일반적으로 \sqrt{n} (n 은 입력변수의 수)의 무작위로 선택된 일부의 입력 변수가 사용된다. RF는 이러한 수많은 서로 독립적인 결정나무들을 만들어 그 결과를 취합하며 구체적인 메커니즘은 Breiman(2001)에 자세히 설명되어 있다. 본 연구에서는 기본적으로 500개의 나무를 구축하였으며, 각 노드에서의 입력변수의 수로 \sqrt{n} 을 사용하였으며, 결과를 취합할 때에는 weighted majority voting 기법을 사용하였다.

2. 토지피복변화분석

1990년대 초와 2010년대 초의 토지피복의 변화를 살펴보기 위해 두 가지 토지피복 탐지 방법을 적용하였다. 첫 번째는 분류 후 비교법(Post-classification Comparison)으로 각 시기의 영상을 이용하여 임지, 농경지, 초지, 습지, 주거지, 기타로 범주를 나누어 토지피복 분류를 수행하였으며, 분류된 두 시기의 토지피복도를 비교함으로써 변화를 탐지하였다. 두 번째는 변화분류법(Change Classification)으로 두 시기 영상을 함께 이용하여 임지, 농경지, 초지, 습지, 주거지, 기타의 범주를 조합한 변화된 토지피복과 변화하지 않은 토지피복을 한번에 분류하여 변화를 탐지하였다.

토지피복분류는 기계학습 중 SVM과 RF를 통해 분류를 수행하였다. 기계학습에 이용된 분류 후 비교법의 표본 자료는 1km의 규칙적인 간격으로 표본점을 추출하였으며, 표본점의 위치에서 반경 100m 이내의 영역이 동일한 토지피복이 판독되지 않는 경우에는 해당 표본점 주위의 균질한 토지피복을 보여주는 지역을 찾아 표본점을 이동시켰다. 추출된 표본개수는 총 2,700개(1991~1992년)와 1,538개(2010~2011년)였으며 7:3의 비율로 무작위로 나누어 각각 훈련 및 검증자료로 사용하였다. 변화분류법에 사용된 표본 자료는 변화된 토지피복과 변화하지 않은 토지피복 범주를 바탕으로 표본들을 재구성하였다.

토지피복분류에 사용된 변수는 Landsat TM

TABLE 3. Input variables used in the land cover change classification

Comparison after classification		Change classification
1991 ~ 1992	Reflectance of 1991 year (6 bands)	Reflectance of 1991 year (6 bands) Reflectance of 2010 year (6 bands) NDVI of 1991 year NDVI of 2010 year DEM Slope Aspect
	Reflectance of 1992 year (6 bands)	
	NDVI of 1991 year	
	NDVI of 1992 year	
	DEM	
	Slope	
2010 ~ 2011	Reflectance of 2010 year (6 bands)	DEM Slope Aspect (Aspect is transformed with Beers' transform ($\cos(\text{Aspect} - 45) + 1$) into the linear variable)
	Reflectance of 2011 year (6 bands)	
	NDVI of 2010 year	
	NDVI of 2011 year	
	DEM	
	Slope	
	Aspect	

반사도 자료와 NDVI(Normalized Difference Vegetation Index) 식생지수, 고도(DEM, Digital Elevation Model), 경사, 향 자료이다. 고도자료로는 30m 공간해상도의 SRTM(Shuttle Radar Topography Mission)을 사용하였으며, 대상지역에서 20년 동안 고도의 변화가 없다고 가정하였다. 그리고 변화 범주를 동시에 분류할 시 너무 다양한 시계열 자료를 사용하면 오히려 오분류가 커질 수 있다는 가정에 따라 판독을 통해 각 시기를 대표할 수 있는 하나의 영상을 사용하였다. 구체적으로 토지피복분류에 사용된 변수는 표 3에 나와 있다. 분류 후 비교법에서는 각 시기별 토지피복분류에 총 17개의 입력변수가 사용되었고, 변화분류법에서는 한 번의 분류에 역시 총 17개의 변수가 사용되었다.

토지피복분류 결과를 정량적으로 평가하기 위해 일반적으로 사용되는 분류 정확도 통계 값들을 활용하였다. 본 연구에서는 사용자 및 생산자 정확도(User's and Producer's accuracy), 전체정확도(Overall accuracy), Kappa 값이 이용되었다. 이러한 정확도는 오차 매트릭스(Error matrix)로부터 계산하였다.

3. 산림탄소저장량 추정

산림탄소저장량 추정은 그림 2와 같은 과정으로 수행하였다. 지형변수를 제외하고는 Landsat

TM 영상을 바탕으로 반사도, 밴드비율, 식생지수를 추출한 후 RF, SVR의 기계학습 알고리즘을 이용하여 산림탄소저장량을 추정하였다. 산림탄소저장량 추정에 사용된 변수는 표 4에 요약되어 있으며, 토지피복변화분석에서 사용한 변수에 식생지수를 추가하였다.

참조자료로 사용된 NFI자료는 각 시기별로 무작위로 7:3으로 나누어 각각 훈련자료와 검증자료로 사용하였다. 1990년~1991년 산림탄소저장량 추정에는 총 529 표본 중 370의 표본이 훈련자료로 사용되었고, 나머지 159개의 표본이 검증용으로 사용되었다. 또한 2007년~2011년 산림탄소저장량 추정에는 총 825개의 표본 중 577개의 표본이 훈련자료로, 248개의 표본이 검증용으로 사용되었다.

4. 불확실성 분석

어떠한 분석과정에서든 입력 자료가 가지는 불확실성과 분석 과정 중에 발생하는 불확실성이 존재하게 되며 이는 분석 결과에 영향을 미치게 된다. 자료에 대한 불확실성은 자료를 만들어 낼 때 발생하는 측정 오차에 의해서 주로 발생하게 되며, 모델에 의한 불확실성은 주로 모델의 파라미터 값에 기인한다(Refsgaard *et al.*, 2007). 특히, 모델에 입력되는 자료가 추정에 의한 자료인 경우에는 불확실성이 증가하

TABLE 4. Input variables used in forest carbon estimation

Variables	Conversion formula
TM bands 1~7 (except for thermal band)	Reflectance
Normalized difference vegetation index	$\frac{Band4 - Band3}{Band4 + Band3}$
II(Infrared Index)	$\frac{Band4 - Band5}{Band4 + Band5}$
Soil-adjusted vegetation index(SAVI)	$\frac{(1 + L)(Band4 - Band3)}{Band4 + Band3 + L}$
Band ratio	$\frac{Band5}{Band4}$, $\frac{Band5}{Band7}$, $\frac{Band7}{Band2}$, $\frac{Band4}{Band3}$, $\frac{Band7}{Band4}$
Tasseled cap(TC) brightness (Crist and Cicone, 1984)	$0.3037(Band\ 1) + 0.2793(Band\ 2) + .4743(Band\ 3) + 0.5585(Band\ 4) + 0.5082(Band\ 5) + 0.1863(Band\ 7)$
TC greenness (Crist and Cicone, 1984)	$-0.2848(Band\ 1) - 0.2435(Band\ 2) - 0.5436(Band\ 3) + 0.7243(Band\ 4) + 0.0840(Band\ 5) - 0.1800(Band\ 7)$
TC wetness (Crist and Cicone, 1984)	$0.1509(Band\ 1) + 0.1973(Band\ 2) + 0.3279(Band\ 3) + 0.3406(Band\ 4) - 0.7112(Band\ 5) - 0.4572(Band\ 7)$
Elevation	Unit: m
Slope	Unit: °
Aspect	Aspect is transformed into the linear variable with Beers' transform ($\cos(\text{Aspect} - 45) + 1$).

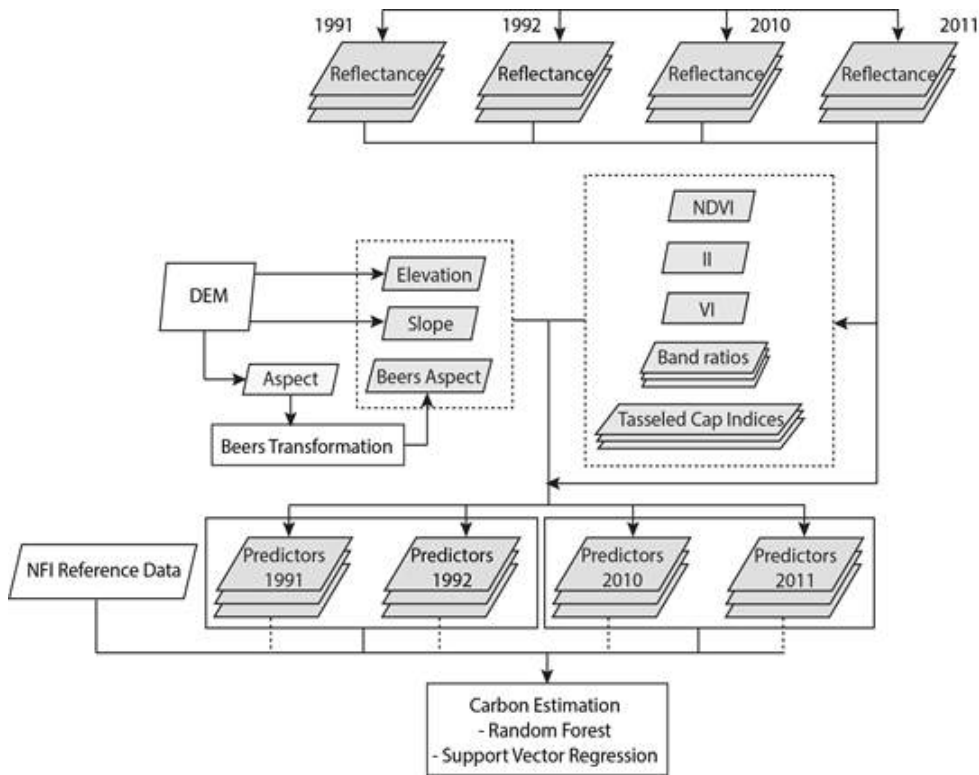


FIGURE 2. Flow diagram of forest carbon estimation

게 된다. 본 연구에서 사용된 기계학습 방법들은 일반적으로 입력자료의 구성에 따라 민감하게 반응하는 경우가 많다. 특히 NFI기반 탄소 저장량 표본의 수가 많지 않은 경우에는 어떤 식으로 훈련/검증 자료를 나누느냐에 따라 결과가 다르게 나올 수 있다. 그래서 본 연구에서는 입력자료 변화에 따른 모델의 불확실성을 분석하기 위해 무작위 샘플링을 통한 100개의 7대 3의 훈련 및 검증 자료를 구축하였으며, 이를 알고리즘에 적용하여 모델을 검증하였다. 검증 결과는 RMSE(Root Mean Square Error)와 RRMSE(Relative Root Mean Square Error)로 나타내었으며, 불확실성을 공간적으로 나타내어 산림탄소저장량 추정 결과에 따른 불확실성을 분석하였다.

결과 및 고찰

1. 토지피복변화분석 결과

SVM과 RF를 이용하여 분류 후 비교법과 변화분류법을 수행한 결과 SVM이 높은 분류 정확도를 보여주었다. SVM을 이용한 분류 후 비교법과 변화분류법은 비슷한 분류 정확도를 보여주었으며, 표 5, 6에 정확도 평가 결과를 요약하였다. 분류 후 비교법에서는 다른 토지피복 범주에 비해 임지와 수계지역의 정확도가 높게 나왔으며, 변화분류법에서는 대부분의 범주에서 90% 이상의 높은 정확도를 보였으나 산림/농지, 농지/초지에서 생산자 정확도가 낮게 나타나는 경향을 보여주었다. 산림에서 농지나 초지로 변한 범주에서 분류 정확도가 낮게 나온 이유는 SVM에서 식생지수로 각 변화를 구분하기

TABLE 5. Accuracy assessment summary of post-classification comparison with SVM (UA: User's Accuracy, PA: Producer's Accuracy, OA: Overall Accuracy)

Year	1991~1992		2010~2011	
	UA(%)	PA(%)	UA(%)	PA(%)
Forest	96.94	98.87	94.66	96.88
Agriculture	92.13	89.24	90.23	90.23
Grass	90.00	75.00	92.31	90.00
Water	100.00	100.00	100.00	100.00
Residential	81.41	90.07	90.10	86.67
Others	100.00	59.38	78.13	83.33
OA(%)	92.83		91.29	

TABLE 6. Accuracy assessment summary of change classification with SVM (UA: User's Accuracy, PA: Producer's Accuracy, OA: Overall Accuracy)

	UA(%)	PA(%)		UA(%)	PA(%)
Forest	98.70	98.92	Grass to others	100	88.89
Forest to agriculture	100.00	33.33	Water	100.00	100.00
Forest to grass	89.23	98.31	Water to agriculture	100.00	100.00
Forest to residential	88.33	85.48	Residential	90.94	92.03
Forest to others	85.71	88.24	Others	100.00	77.42
Agriculture	89.48	95.64	Others to forest	100.00	87.50
Agriculture to grass	88.89	64.00	Others to agriculture	100.00	100.00
Agriculture to residential	87.21	85.71	Others to grass	92.86	97.01
Agriculture to others	88.46	86.79	Others to water	100.00	100.00
Grass	95.45	93.33	Others to residential	93.62	70.97
OA(%)	92.89				

TABLE 7. Area statistics of land use based on the post-classification comparison method with SVM

Year	Daejeon (unit: km ²)		Sejong (unit: km ²)	
	1991~1992	2010~2011	1991~1992	2010~2011
Forest	281.69	288.21	228.93	219.11
Agriculture	115.72	101.65	180.81	158.58
Grass	2.67	5.34	4.69	16.64
Water	22.53	22.53	8.62	8.62
Residential	109.74	116.34	38.04	51.61
Others	7.44	5.72	5.49	12.02
Total area	539.79	539.79	466.58	466.58

TABLE 8. Area statistics of land use based on the change classification method with SVM

Year	Daejeon (unit: km ²)		Sejong (unit: km ²)	
	1991	2010	1991	2010
Forest	291.20	285.08	241.48	219.72
Agriculture	117.33	96.10	176.17	156.97
Grass	2.42	7.69	5.83	21.32
Water	23.27	23.27	8.10	6.81
Residential	89.15	122.30	20.71	55.18
Others	16.57	5.50	14.57	6.86
Total area	539.94	539.94	466.86	466.86

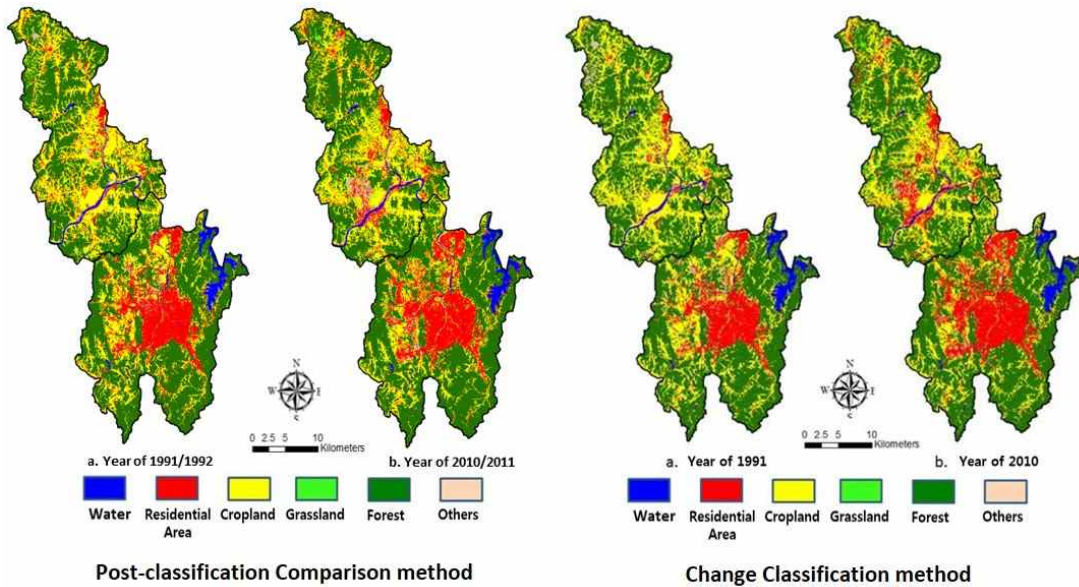


FIGURE 3. The spatial distribution of land uses based on the post-classification comparison method(left) and change classification method(right) using SVM in Daejeon/Sejong cities. Classes which are not designated as water, residential area, cropland, grassland, and forest are classified as others

어려웠기 때문에 생각되며, 이는 대기의 영향으로 인해 나타난 것으로 판단된다.

SVM기반 토지이용분류 결과를 이용한 토지이용 항목별 면적 통계는 표 7, 8과 같다. 분류 후 비교법에 기초한 토지이용 항목별 면적 통계에 따르면 대전시에서의 임지 면적은 6.52km²가 증가하였으며, 세종시에서의 임지 면적은 9.82km² 감소하였다. 변화분류법에 기초한 토지이용 항목별 면적 통계에 따르면 대전시에서의 임지 면적은 6.12km² 감소하였으며, 세종시에서의 임지 면적은 21.76km² 감소하였다. 분류 후 비교법에 의한 토지이용 변화는 여러 가지 요인으로 인해 임지, 농경지, 주거지 사이에서 오분류가 많이 발생하였다. 이러한 오분류는 분류에 이용된 영상들의 수집된 계절이 다르고 수집 당시의 환경이 달라 각 토지이용 항목별 경계부위에 오분류가 집중되었으며, 영상사이의 위치오차 또한 오분류를 증가시킨 것으로 생각된다. 또한 SVM 모델의 정확도는 높게 나왔지만 검증자료가 토지이용이 해당위치 주변에서 균질하고 쉽게 판독이 되는 위치에서만 추출되어 분류에 영향을 끼친 것으로 생각된다. 분류 후 비교법과 달리 변화분류법은 예상되지 않는 토지이용의 변화를 사전에 차단할 수 있는 장점이 있으나 모든 토지이용변화를 추출하거나 특정 항목의 변화가 발생한 지역이 매우 작아 훈련자료를 충분히 추출할 수 없는 단점이 있다. 따라서 본 연구에서는 일부 변화항목에 대

해 충분한 참조자료를 추출하지 못해 모든 참조자료를 훈련자료로 사용하였고, 정확도 평가도 동일한 훈련자료를 사용하여 정확도가 다소 증가한 것으로 생각되나 분류 후 비교법의 훈련 정확도와 검증 정확도 차이와 비슷한 정도의 차이를 보여준다고 가정할 수 있다.

2. 산림탄소저장량 추정 결과

산림탄소저장량은 RF, SVR의 두 가지 기계학습 알고리즘을 이용하여 추정하였다. RF를 이용한 산림탄소저장량 추정 결과는 표 9에 나와 있으며, SVR을 이용한 산림탄소저장량 추정 결과는 표 10에 나와 있다. RF의 경우 전반적으로 검증 오차 RRMSE가 1991년~1992년에는 63%, 2010년~2011년에는 47%로 나타났다. SVR의 경우 RF와 비교하여 훈련 정확도가 상당히 높은 특징을 보여주었으며, 검증 오차 RRMSE가 1991년~1992년에는 32%, 2010년~2011년에는 45%로 RF와 비슷하게 나타났다. 추정된 산림탄소저장량으로 계산한 변화량은 Jung *et al.*(2014)의 kNN과 RTA(Regression Tree Analysis)로 추정한 산림탄소저장량 변화량과 비교하였을 때, 전반적으로 적은 양의 변화량을 보였으며, 산림경계에서는 그림 4와 같이 산림탄소저장량이 마이너스가 되는 패턴을 보여주었다. 기계학습 결과에서 알 수 있듯이 2차원적인 분광정보만으로는 고밀도 산림지역의 탄소를 효과적으로 정량화하기에 어려운

TABLE 9. Summary of forest carbon stock estimation results using RF

	Variables in 1991		Variables in 1992		Variables in 1991/1992	
	Calibration	Validation	Calibration	Validation	Calibration	Validation
R ²	0.068	0.147	0.073	0.189	0.081	0.168
RMSE (tonC/ha)	9.320	10.640	9.320	10.370	9.240	10.500
RRMSE(%)	61.700	64.300	61.600	62.700	61.100	63.500
	Variables in 2010		Variables in 2011		Variables in 2010/2011	
	Calibration	Validation	Calibration	Validation	Calibration	Validation
R ²	0.108	0.129	0.055	0.064	0.131	0.132
RMSE (tonC/ha)	24.720	25.040	25.510	25.930	24.330	24.930
RRMSE(%)	47.500	46.900	49.000	48.500	46.700	46.600

TABLE 10. Summary of forest carbon stock estimation results using SVR

	Variables in 1991		Variables in 1992		Variables in 1991/1992	
	Calibration	Validation	Calibration	Validation	Calibration	Validation
R ²	0.264	0.102	0.468	0.176	0.783	0.125
RMSE (tonC/ha)	8.360	11.140	7.150	10.650	4.830	10.900
RRMSE(%)	55.300	67.400	47.300	64.400	31.900	65.900
	Variables in 2010		Variables in 2011		Variables in 2010/2011	
	Calibration	Validation	Calibration	Validation	Calibration	Validation
R ²	0.256	0.149	0.179	0.044	0.623	0.098
RMSE (tonC/ha)	22.750	24.640	23.690	26.450	16.630	26.230
RRMSE(%)	43.700	46.100	45.500	49.500	31.900	49.100

TABLE 11. The statistics of estimated forest carbon stock using SVR

Period	Average	Standard deviation	Minimum	Maximum
1991	14.16	5.18	0	44
2011	49.20	14.13	0	113
1991~2011	17.91	21.80	-38	104

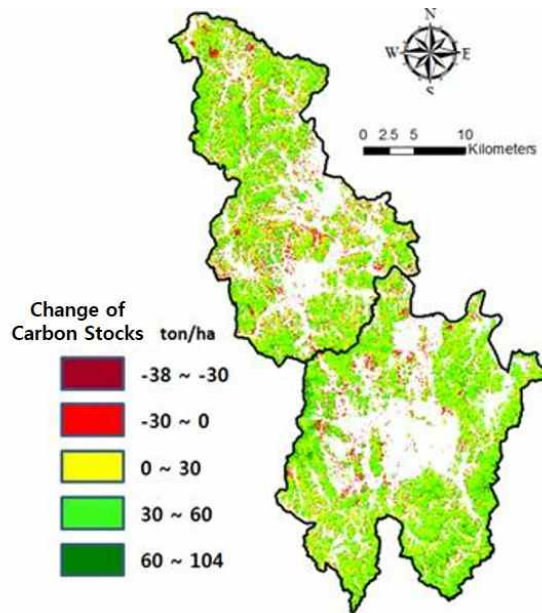


FIGURE 4. Change of carbon stocks using SVR between 1991 and 2001

것으로 판단되며, 일반적으로 탄소저장량을 과소 추정하는 경향을 보여주었다. 이러한 문제점은 산림의 3차원 정보를 제공하는 라이다나

SAR와 같은 자료를 활용하면 일부 해결할 수 있을 것으로 생각된다. 본 연구에서 두 가지 기계학습 알고리즘 중에서 SVR이 산림탄소저장

량 추정에 가장 적합하다고 판단하여 불확실성 분석과 토지이용변화와의 연계분석에는 SVR를 이용한 산림탄소저장량 추정 결과를 이용하였다. 두 시기의 SVR기반 산림탄소저장량 통계 값은 표 11과 같다.

3. 토지피복에 따른 산림탄소저장량 변화

산림탄소저장량 변화가 양의 값을 가지면 산림이 탄소를 흡수했다고 판단할 수 있으며, 산림탄소저장량 변화가 음의 값을 가지면 산림이 탄소를 배출했다고 판단 할 수 있다. 대전/세종시의 20여년(1991~2011)의 산림탄소변화는 SVR 기계학습을 이용하였을 경우 평균 17.91 tonC/ha로 온실가스가 지상부바이오매스에 고정되어 지상부바이오매스가 탄소흡수기능을 하였음을 알 수 있다(표 11). 이를 토지피복변화 형태별로 살펴보면 산림이 그대로 산림으로 유

지되는 지역의 경우 산림의 성장으로 인해 33.23tonC/ha의 탄소흡수를 하였으며 산림 이외의 다른 토지피복형태가 산림으로 변한 지역의 경우 이보다 큰 36.83tonC/ha의 흡수가 진행된 것으로 추정되었다. 산림이 다른 토지피복으로 바뀐 경우 (-)의 값인 -7.35tonC/ha, 즉 배출이 일어난 것으로 추정되었다(표 12). 특히 그림 5에 따르면 택지개발로 인해 대전/세종시에 빨간색으로 표시된 산림전용이 군집의 형태로 많이 발생했고 산림 경계에서 조금씩 타 용도로의 전환이 일어났음을 알 수 있다. 급격한 도시 개발이 진행된 세종시는 대전시에 비해 산림이 타 용도로 변환된 면적이 넓었으며, 이에 따른 탄소저장변화량도 대전시에 비해 (-) 값이 크게 나타났다.

TABLE 12. Changes of forest carbon stocks using SVR according to the land cover change

Types of land cover change	Change of carbon stocks (tonC/ha)
Forests (no change)	33.23
Other land covers to forests	36.83
Forests to other land covers	-7.35

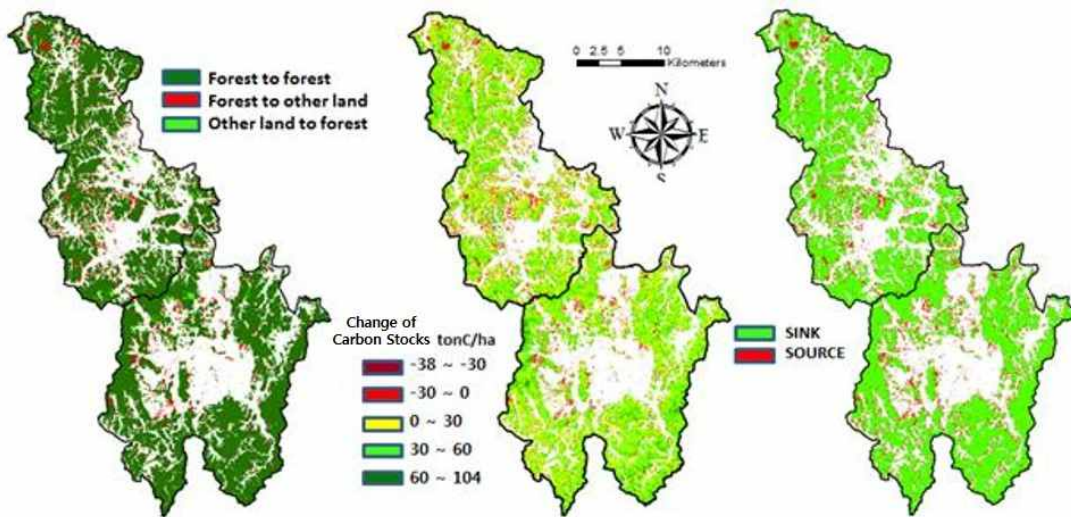


FIGURE 5. Land cover change(left), spatial distribution of carbon stock change(middle), and carbon sink and source based on the carbon stock change(right)

4. 불확실성 분석

무작위 샘플링을 통한 훈련 및 검증 자료를 구축하여 참조자료의 구성에 따른 SVR 알고리즘의 불확실성을 분석한 결과가 표 13에 나타나 있다. 평균 RMSE는 2011년이 1991년에 비해 두 배 이상 높았으나 평균 RRMSE는 오히려 작았으며 이는 전반적으로 산림 탄소량이 1991년에 비해 2011년에 크게 증가한 영향으로 볼 수 있다. 연구 지역 전체에 걸친 불확실성의 범위는 그림 6과 같이 1991년 탄소지도

의 경우 1.42~14.79%, 2011년 탄소지도의 경우 0.72~93.32%의 분포를 보였다. 일부 높은 불확실성을 보여주는 지역은 대부분 추정된 탄소량이 매우 작은 경우(< 5 tonC/ha)에 해당하였으며, 주로 화소 내에서 다양한 토지피복이 섞여있는 산림 경계부분에서 나타났다. 두 시기 탄소지도의 평균 불확실성은 1991년의 경우 3.45%, 2011년의 경우 2.75%로 낮아지는 경향을 보였다.

TABLE 13. Summary of the uncertainty analysis of carbon stocks using SVR for 1991~1992 and 2010~2011

	Daejeon/Sejong	
	1991~1992	2010~2011
Average of RMSE(tonC/ha)	9.94	25.11
Standard deviation of RMSE(tonC/ha)	0.97	0.92
Average of RRMSE	64.16%	47.85%
Standard deviation of RRMSE	5.75%	1.91%

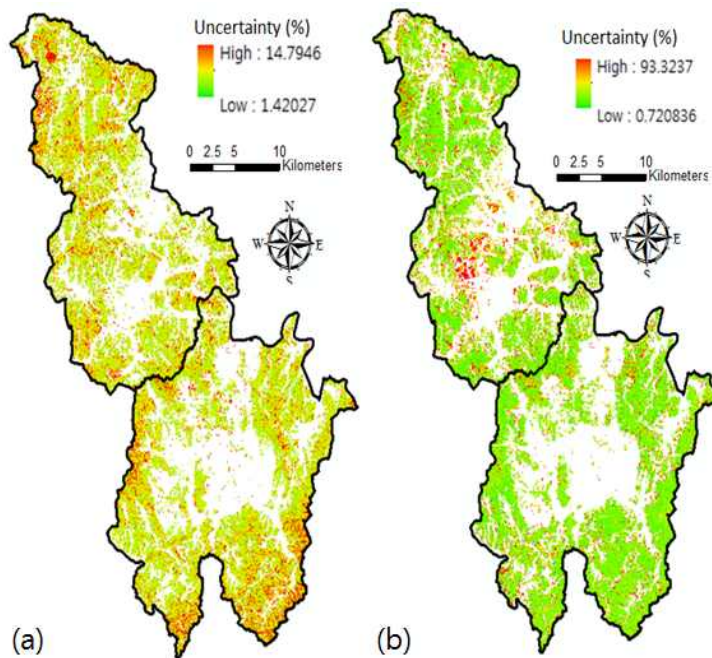


FIGURE 6. Spatial distribution of uncertainty based on 100 times simulation of SVR with randomly selected carbon samples of (a) 1990~1991 (b) 2007~2011

결론

본 연구에서는 효율적인 탄소배출 규제를 수립하기 위해 토지피복변화가 빠르고 국가 산림 자원조사 표본점 배치가 부족한 도시지역인 대전/세종시를 대상으로 1991년~2011년 두 시기 동안 UNFCCC의 Tier 3와 Approach 3를 충족하는 토지피복변화에 따른 격자 기반 산림 탄소저장량을 추정하였으며, 그 결과는 다음과 같다. 연구는 토지피복변화분류, 산림탄소저장량 추정, 토지피복변화에 따른 산림탄소저장량 분석, 모델 불확실성 분석의 순으로 진행되었다. 토지피복분류는 시계열 Landsat TM 영상 자료를 바탕으로 분류 후 비교법과 변화분류법을 수행하여 1991년~2011년 사이의 대전/세종시의 토지피복을 분류하였다. RF와 SVM을 이용하여 토지피복분류를 수행하였으나 사용된 시계열 영상 사이의 위치오차가 존재하고, 자료가 수집된 계절이 달라 수계지역과 농경지, 그리고 각 토지피복항목의 경계부에서 오차가 증가하였다. 또한 훈련/검증 자료를 고해상도 항공사진으로부터 추출하였기 때문에 항공사진과 위성자료 사이의 시간 차이에 따른 오차도 존재하였다. 본 연구에서 사용된 방법 중에는 변화분류법의 SVM이 가장 적합하였으나, 일부 변화 항목에 대한 표본의 수가 매우 적어서 동일한 기준에서 정량적인 비교는 불가능하였다. 산림탄소저장량도 토지피복변화분류와 마찬가지로 시계열 Landsat TM 영상자료를 바탕으로 RF와 SVR을 이용하여 추정하였으나, NFI 자료와 비교하였을 때 전반적으로 낮은 상관성을 보여주어 2차원적인 분광정보만으로는 고밀도 산림지역의 탄소를 효과적으로 정량화하기 어려우며 일반적으로 과소 추정하는 경향이 있다고 판단된다. 토지피복변화분류 결과와 산림탄소저장량 추정결과를 바탕으로 토지피복변화별 산림탄소저장량을 살펴보았을 때, 산림이 유지된 지역은 산림탄소저장량이 증가하여 탄소의 흡수가 나타난 반면 산림이 타 용도로 변환된 지역은 산림탄소저장량이 (-) 값을 나타내어 탄소의 배출이 나타난 것을 알 수 있었다.

마지막으로 모델에 의한 불확실성을 공간적으로 나타냈으며, 그 결과 추정된 탄소량이 작은 지역에서 불확실성이 크게 나타났다. 본 연구의 과정에서 나타난 한계점들은 산림의 3차원 정보를 제공해 줄 수 있는 LiDAR나 SAR 등을 적절한 활용을 통해 보다 더 정밀하게 토지피복/이용 변화와 연계하여 산림탄소정보를 정량화 할 수 있다. 이와 더불어 기계학습에 사용되는 입력변수가 그 성능에 영향을 미치는 중요한 요소이므로 최적의 입력변수를 찾는 연구도 수행할 예정이다. [KAGIS](http://www.kagis.com)

REFERENCES

- Ahmed, O.S., S.E. Franklin, M.A. Wulder and J.C. White. 2015. Characterizing stand-level forest canopy cover and height using landsat time series, samples of airborne LiDAR, and the random forest algorithm. *ISPRS Journal of Photogrammetry and Remote Sensing* 101:89-101.
- Breiman, L. 2001. Random forests. *Machine Learning* 45:5-32.
- Chapelle, O., V. Vapnik, O. Bousquet and S. Mukherjee. 2002. Choosing multiple parameters for support vector machines. *Machine Learning* 46:131-159.
- Crist, E.P. and R.C. Cicone. 1984. A physically-based transformation of thematic mapper data - the TM tasseled cap. *IEEE Geoscience and Remote Sensing* 3:256-263.
- Dube, T., O. Mutanga, A. Elhadi and R. Ismail. 2014. Intra-and-inter species biomass prediction in a plantation forest: testing the utility of high spatial resolution spaceborne multispectral Rapideye sensor and advanced machine

- learning algorithms. *Sensors* 14(8): 15348–15370.
- Erdody, T. and L.M. Moskal. 2010. Fusion of LiDAR and imagery for estimating forest canopy fuels. *Remote Sensing of Environment* 114:725–737.
- Foody, G.M. and A. Mathur. 2006. The use of small training sets containing mixed pixels for accurate hard image classification: training on mixed spectral responses for classification by a SVM. *Remote Sensing of Environment* 103(2): 179–189.
- Fuchs, H., P. Magdon, C. Kleinn and H. Flessa. 2009. Estimating aboveground carbon in a catchment of the Siberian forest tundra: combining satellite imagery and field inventory. *Remote Sensing of Environment* 113:518–531.
- Gleason, C.J. and J. Im. 2011. A review of remote sensing of forest biomass and biofuel: options for small area applications. *GIScience and Remote Sensing* 48(2):141–170.
- Gleason, C.J. and J. Im. 2012. Forest biomass estimation from airborne lidar data using machine learning approaches. *Remote Sensing of Environment* 125:80–91.
- Goetz, S.J., A. Baccini, N.T. Laporte, T. Johns, W. Walker, J. Kelndorfer, R.A. Houghton and M. Sun. 2009. Mapping and monitoring carbon stocks with satellite observations: a comparison of methods. *Carbon Balance Management* 4(2):2–8.
- Hastie, T., R. Tibshirani and J.H. Friedman. 2009. *The Elements of Statistical Learning Data Mining, Inference, and Prediction*. Springer, 552pp.
- Huang, C.L. and C.J. Wang. 2006. A GA-based feature selection and parameters optimization for support vector machines. *Expert Systems with Applications* 31:231–240.
- Im, J.S., W.S. Han, J.H. Hwang, S.Y. Jeong, H.K. Cho and M.Y. Shin. 2009. Forest biomass estimation using satellite images and NFI data. *Korean Journal of Remote Sensing* 25(4):311–320 (임중수, 한원성, 황주호, 정상영, 조현국, 신만용. 2009. 위성영상자료 및 국가 산림자원조사 자료를 이용한 산림 바이오매스 추정. *대한원격탐사학회지* 25(4):311–320).
- Jung, J.H., J. Heo, S.H. Yoo, K.M. Kim and J.B. Lee. 2010. Estimation of aboveground biomass carbon stock in Danyang area using kNN algorithm and Landsat TM seasonal satellite images. *Journal of Korean Society for Geospatial Information System* 18(4): 119–129 (정재훈, 허준, 유수홍, 김경민, 이정빈. 2010. kNN 알고리즘과 계절별 Landsat TM 위성영상을 이용한 단양군 지역의 지상부 바이오매스 탄소저장량 추정. *한국지형공간정보학회지* 18(4):119–129).
- Jung, J.H., K.H. Uen, J. Heo, K.M. Kim and J.H. Im. 2014. Aboveground forest biomass estimation using satellite images - comparison and analysis of k-nearest neighbor method and regression tree analysis method. *Korean Journal of Remote Sensing* 30(5):651–654 (정재훈, 우엔 쿡 효, 허준, 김경민, 임정호. 2014. 위성영상을 활용한 지상부 산림 바이오매스 탄소량 추정-k-Nearest Neighbor 및 Regression Tree Analysis

- 방법의 비교 분석. 대한원격탐사학회지 30 (5):651-654).
- Kattenborn, T., J. Maack, F. Faßnacht, F. Enßle, J. Ermert and B. Koch. 2015. Mapping forest biomass from space-Fusion of hyperspectral EO1-hyperion data and Tandem-X and WorldView-2 canopy height models. *International Journal of Applied Earth Observation and Geoinformation* 35:359-367.
- Keerthi, S.S. and C.J. Lin. 2003. Asymptotic behaviors of support vector machines with Gaussian kernel. *Neural Computation* 15:1667-1689.
- Kim, C.K., and S.H. Do. 2008. Planning research for applying the new IPCC guideline of national greenhouse gases responding to the climatic change convention. Korea Energy Economics Institute pp.1-170 (김찬규, 도승희. 2008. 기후변화협약 대응 국가온실가스 IPCC 신규 가이드라인 적용을 위한 기획연구. 에너지경제연구원 연구보고서. 1-170쪽).
- Kim, K.M., J.B. Lee, E.S. Kim, H.J. Park, Y.H. Roh, S.H. Lee, K.H. Park and H.S. Shin. 2011. Overview of research trends in estimation of forest carbon stocks based on remote sensing and GIS. *Journal of the Korean Association of Geographic Information Studies* 14(3):236-256 (김경민, 이정빈, 김은숙, 박현주, 노영희, 이승호, 박기호, 신휴석. 2011. 원격탐사와 GIS 기반의 산림탄소저장량 추정에 관한 주요국 연구동향 개관. 한국지리정보학회지 14(3):236-256).
- Kim, K.M., Y.H. Roh and E.S. Kim. 2014. Comparison of three kinds of methods on estimation of forest carbon stocks distribution using national forest inventory DB and forest type map. *Journal of the Korean Association of Geographic Information Studies* 17(4):69-85 (김경민, 노영희, 김은숙. 2014. 국가산림자원조사 DB와 임상도를 이용한 산림탄소저장량 공간분포 추정방법 비교. 한국지리정보학회지 17(4):69-85).
- Latifi, H., F.E. Fassnacht, F. Hartig, C. Berger, J. Hernández, P. Corvalán and B. Koch. 2015. Stratified aboveground forest biomass estimation by remote sensing data. *International Journal of Applied Earth Observation and Geoinformation* 38:229-241.
- Li, M., J. Im, L.J. Quackenbush and T. Liu. 2014. Forest biomass and carbon stock quantification using airborne lidar data: a case study over huntington wildlife forest in the Adirondack park. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Selected Topics in Applied Earth Observations and Remote Sensing* 7(7):3143-3156.
- Markham, B.L. and J.L. Barker. 1987. Radiometric properties of US processed Landsat MSS data. *Remote Sensing of Environment* 22(1):39-71.
- Muukkonen, P. and J. Heiskanen. 2007. Biomass estimation over a large area based on standwise forest inventory data and ASTER and MODIS satellite data: a possibility to verify carbon inventories. *Remote Sensing of Environment* 107(4):617-624.
- Neumann, M., S.S. Saatchi, L.M. Ulander and J.E. Fransson. 2012. Assessing performance of L- and P-band polarimetric interferometric SAR data in estimating

- boreal forest above-ground biomass. *IEEE Geoscience and Remote Sensing* 50(3):714-726.
- Park, H.J., H.S. Shin, Y.H. Roh, K.M. Kim and K.H. Park. 2012. Estimating forest carbon stocks in Danyang using kriging methods for aboveground biomass. *Journal of the Korean Association of Geographic Information Studies* 15(1):16-33 (박현주, 신휴석, 노영희, 김경민, 박기호. 2012. 크리깅 기법을 이용한 단양군의 산림 탄소저장량 추정 -지상부 바이오매스를 대상으로-. *한국지리정보학회지* 15(1):16-33).
- Popescu, S.C., R.H. Wynne and J.A. Scrivani. 2004. Fusion of small-footprint LiDAR and multispectral data to estimate plot-level volume and biomass in deciduous and pine forests in Virginia, USA. *Forest Science* 50(4): 551-565.
- Ramedani, Z., M. Omid, A. Keyhani, S. Shamshirband and B. Khoshnevisan. 2014. Potential of radial basis function based support vector regression for global solar radiation prediction. *Renewable and Sustainable Energy Reviews* 39:1005-1011.
- Refsgaard, J.C., J.P. Sluijs, A.L. Hojberg and P.A. Vanrolleghem. 2007. Uncertainty in the environmental modeling process - a framework and guidance. *Environmental Modeling & Software* 22:1543-1556.
- Shevade, S.K., S.S. Keerthi, C. Bhattacharyya and K.R.K. Murthy. 2000. Improvements to the SMO algorithm for SVM regression. *IEEE Neural Networks* 11:1188-1193.
- Wulder, M.A., J.C. White, R.A. Fournier, J.E. Luther and S. Magnussen. 2008. Spatially explicit large area biomass estimation: three approaches using forest inventory and remotely sensed imagery in a GIS. *Sensors* 8:529-560.
- Xu, C., F. Dai, X. Xu, and Y.H. Lee. 2012. GIS-based support vector machine modeling of earthquake-triggered landslide susceptibility in the Jianjiang river watershed, China. *Geomorphology* 145: 70-80.
- Yu, X., J. Hyypä, M. Vastaranta, M. Holopainen and R. Viitala. 2011. Predicting individual tree attributes from airborne laser point clouds based on the random forests technique. *ISPRS Journal of Photogrammetry and Remote Sensing* 66(1):28-37.
- Zhang, J., S. Huang, E.H. Hogg, V. Lieffers, Y. Qin and F. He. 2014. Estimating spatial variation in Alberta forest biomass from a combination of forest inventory and remote sensing data. *Biogeosciences* 11(10):2793-2808. [KAGIS](https://doi.org/10.5194/bg-11-2793-2014)