

의사결정나무를 활용한 2030년 도시 확장 예측*

김근한¹⁾ · 최희선²⁾ · 김동범³⁾ · 정예림⁴⁾ · 진대용⁵⁾

- ¹⁾ 한국환경정책 · 평가연구원 환경계획연구실 전문연구원 ·
²⁾ 한국환경정책 · 평가연구원 환경계획연구실 선임연구위원
³⁾ 공주대학교 지리학과 연구원 · ⁴⁾ 서울대학교 환경대학원 연구원
⁵⁾ 한국환경정책·평가연구원 환경데이터전략센터 전문연구원

Urban Sprawl prediction in 2030 using decision tree*

Kim, Geun-Han¹⁾ · Choi, Hee-Sun²⁾ · Kim, Dong-Beom³⁾ · Jung, Yee-Rim⁴⁾ and Jin, Dae-Yong⁵⁾

- ¹⁾ Korea Environment Institute Division for Environmental Planning, Research Specialist,
²⁾ Korea Environment Institute Division for Environmental Planning, Chief Research Fellow,
³⁾ Kongju National University Department of Geography, Researcher,
⁴⁾ Seoul National University Graduate School of Environmental Studies, Researcher,
⁵⁾ Korea Environment Institute, Center for Environmental Data Strategy, Research Fellow.

ABSTRACT

The uncontrolled urban expansion causes various social, economic problems and natural/environmental problems. Therefore, it is necessary to forecast urban expansion by identifying various factors related to urban expansion. This study aims to forecast it using a decision tree that is widely used in various areas. The study used geographic data such as the area of use, geographical data like elevation and slope, the environmental conservation value assessment map, and population density data for 2006 and 2018. It extracted the new urban expansion areas by comparing the residential, industrial, and commercial zones of the zoning in 2006 and 2018 and derived a decision tree using the 2006 data as independent variables. It is intended to forecast urban expansion in 2030 by applying the data for 2018 to the derived decision tree. The analysis result confirmed that the distance from the green area, the elevation, the grade of the environmental conservation value assessment map, and the distance from the industrial

* 본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 한국환경정책 · 평가연구원(KEI)에서 수행하였음(과제번호 20UMRG-B158194-01).

First author : Kim, Geun-Han, Korea Environment Institute, Research Specialist,
Tel : +82-44-415-7752, E-mail : ghkim@kei.re.kr

Corresponding author : Jin, Dae-Yong, Korea Environment Institute, Research Fellow,
Tel : +82-44-415-7643, E-mail : dyjin@kei.re.kr

Received : 2 November, 2020. **Revised** : 18 December, 2020. **Accepted** : 17 November, 2020.

area were important factors in forecasting the urban area expansion. The AUC of 0.95051 showed excellent explanatory power in the ROC analysis performed to verify the accuracy. However, the forecast of the urban area expansion for 2018 using the decision tree was 15,459.98km², which was significantly different from the actual urban area of 4,144.93km² for 2018. Since many regions use decision tree to forecast urban expansion, they can be useful for identifying which factors affect urban expansion, although they are not suitable for forecasting the expansion of urban region in detail. Identifying such important factors for urban expansion is expected to provide information that can be used in future land, urban, and environmental planning.

Key Words : *urban expansion, forecast, decision tree, geographical data*

I. 서 론

급속한 도시지역의 무질서한 확장은 인프라의 압력, 교통체증의 악화, 도시민들의 건강 악화와 같은 사회·경제적인 문제뿐만 아니라 오픈스페이스 및 농지의 손실, 탄소 흡수원의 상실, 생물종다양성의 감소, 지하수 오염 및 재난 위험의 증가 등 자연·환경적인 문제들도 야기한다(Macdonald et al., 2011; Bhatta, 2010). 이러한 다양한 피해를 야기하는 도시 확산을 방지하고 예방하기 위해서는 도시 확산과 관련된 다양한 요인들과 이러한 요인들이 도시 확산에 미치는 영향을 파악하는 것이 필요하다. 나아가 도시 확산과 관련된 요인들을 활용하여 도시 확장을 예측하고, 이러한 예측을 기반으로 도시를 관리하는 것은 도시 연구에 있어서 중요한 부분이다(Ghavami et al., 2017).

도시 확산의 요인 및 영향을 파악하고 도시 확산을 예측하기 위해서는 토지이용의 변화를 추출하고, 이러한 변화를 중심으로 도시의 복잡한 변수 사이의 관계 및 영향을 파악하는 것이 일반적이는데, 이를 위해 기존에는 CA(Cellular Automata)기법 등이 사용되어왔다(Arsanjani et al., 2013; Wang et al., 2019). 그러나 이러한 CA 방법론은 선형모델이기 때문에 도시 확산과 같이 비선형적인 현실을 예측하기에는 한계가 있다. 이러한 문제점을 해결하기 위해 최근에는

설명력이 높은 기계학습 모델들과 같은 AI 분석 방법론들이 개발되고 있다(Arsanjani et al., 2013; Ruiz and Shi, 2018; Wang et al., 2019). 이는 기존의 셀 기반 단순 규칙으로 복잡한 도시 현상을 설명하는 기존의 CA방법과 달리 현실의 복잡한 인과관계에 대하여 설명력이 더 높다는 점에서 주목받고 있다.

이에 본 연구에서도 이러한 기계학습 기법 중 하나이며, 다양한 분야에서 적용 및 활용되고 있는 의사결정나무 기법을 활용하여 도시 확장 예측 지도를 구축해보고자 하였다. 의사결정나무는 하향식 분류 알고리즘으로 선형성, 정규성, 등분산성 등의 가정 없이 활용 가능한 비모수적 방법이며, 분류모형 구축결과가 나무 구조에 의해 표현이 되기 때문에 해석이 쉽다는 특징이 있다(Won and Hwang, 2018). 이러한 장점으로 인해 의사결정나무는 홍수 취약지도, 산사태 취약지도, 지하수 용출 확률지도, 노천 광산의 경사면 붕괴 예측 등 다양한 분야에서 활용되고 있다(Chen et al., 2018; Chen et al., 2020; Wu et al., 2020; Bui X., 2020)

본 연구에서는 2006과 2018년의 공간정보를 포함한 데이터들과 의사결정나무 기법을 적용하여 도시 확산에 영향을 미치는 영향인자들을 검토하였다. 그리고 의사결정나무 분석 결과를 2006년 데이터에 적용해 예측한 2018년 도시지역과 실제 2018년 도시지역과의 비교, ROC 분

석 및 AUC 계산을 통해 의사결정나무를 이용한 도시 확장지역 예측 방법론의 활용 가능성을 검토하고자 했다. 그리고 2018년 데이터에 의사결정나무 기법의 분석 결과를 적용함으로써 우리나라의 2030년 도시 확장지역을 예측하였다.

II. 활용 데이터와 분석방법론

1. 데이터의 수집 및 가공

본 연구에서는 도시의 확장을 예측하기 위해 신규 도시지역으로 변화된 지역을 추출해 종속 변수로 설정하고, 이를 기반으로 다양한 독립변수들과의 관계를 분석하여 새로이 확장되는 도시지역을 예측하게 된다. 많은 연구에서는 도시지역으로의 변환지역을 추출하기 위해 위성영상을 활용하여 토지피복지도를 작성하고, 이러한 토지피복지도의 변화를 이용하여 도시지역의 확장과 관련된 관계를 분석하는 연구방법을 채택하고 있다(Kang and Park, 2000; Son et al., 2009). 하지만 환경부에서 제공하고 있는 대분류 토지피복지도는 분류 정확도에 있어서 한계점이 있다. 중분류·세분류 토지피복지도의 경우에는 정확도는 높으나, 세분류의 경우 우리나라 전체를 구축하는데 9년의 시간이 걸리는 등 활용에 한계가 있다(단, 2019년부터 매년 갱신 중). 즉 2010년 북한강·남한강 일대의 현황과 2018년 전라남도·광주 일대의 토지피복 현황은 약 9년의 시점 차이가 발생하는 것이다.

따라서 본 연구와 같이 전국을 대상으로 동일 시점의 토지피복 현황을 추출하여 분석하는 경우에는 활용에 한계가 있어 본 연구에서는 용도지역도를 활용하였다. 이는 토지개발을 통해 발생한 토지의 형질 변경이 반영된 용도지역도는 전국을 대상으로 매년 주기적으로 갱신되고 있고 자료 수집이 용이하기 때문이다. 또한, 용도지역은 전국에 대해 중복되지 않게 지정되어 있다는 장점이 있다. 따라서 본 연구에서는 신규로 확장된 도시지역을 용도지역의 주거지역, 상

업지역, 공업지역을 도시지역으로 검토하였으며, 2006년과 2018년의 주거, 상업, 공업지역을 비교하여 신규로 확장된 지역을 신규도시지역으로 고려하고 각각의 용도지역으로부터의 거리를 활용해 분석하였다.

본 연구에서는 도시지역으로의 확장과 관련한 지형적 특성을 살펴보기 위해 표고와 경사를 분석에 활용하였으며, 개발 수요 분석을 위해 통계청에서 제공하는 집계구 단위의 인구밀도 데이터를 활용했다. 또한 인근도로로부터의 거리를 ArcGIS의 거리계산 기능을 활용함으로써 접근성도 고려했다.

국토의 환경성과 규제적 특성을 반영할 수 있도록 국토환경성평가지도를 활용하였는데, 국토환경성평가지도는 공간정보를 기반으로 국토의 환경수준을 객관적으로 5단계로 구분한 지도를 말한다(Jeon et al., 2007; Jeon et al., 2008; Jeon et al., 2010; Kim et al., 2012; Song et al., 2012). 본 연구에서는 국토의 환경생태적 우수성을 고려하기 위해 국토환경성평가지도의 환경생태적 평가 결과를 활용하였고, 토지의 이용과 관련된 규제성을 검토하기 위해 법제적 평가 결과를 활용하였다. 국토환경성평가지도는 각각의 래스터마다 1~5등급 값을 value 값으로 가지고 있어 해당 등급 값의 추출을 통해 개발지역과 국토환경성평가지도의 환경생태적·법제적 평가결과를 매치할 수 있었다. 또한 환경생태적, 법제적 평가 1등급으로부터의 거리를 추출하여 분석에 활용하였으며(Table 1), 이렇게 수집한 데이터들은 식(1)과 같이 정규화(Normalization) 하였다.

$$Normalization_X = (X - X_{min}) / (X_{max} - X_{min}) \quad (1)$$

2006년과 2018년 용도지역은 Table 2와 같다. 2006년 용도지역을 살펴보면 주거지역은 2,179km², 상업지역은 267km², 공업지역은 807km²로 나타났으며, 이러한 도시지역의 면적의 합은 3,253km²이며, 도시지역 중 개발지역으로 포함되지 않는 녹지

Table 1. Data for analysis utilization

Data		Source
Newly development region		Zoning District (2006 - 2018)
Elevation		DEM (2006 and 2018)
Slope		
Population		Statistics Korea (2006 and 2018)
Distance from road		Road network map (2006 and 2018)
Distance from each Zoning District	Residential zone	Zoning District (2006 and 2018)
	Commercial zone	
	Industrial zone	
	Green zone	
	Plan managed zone	
	Production managed zone	
	Conservation managed zone	
	Agricultural and forest zone	
Natural environment conservation zone		
Ecological assessment of Environmental Conservation Value Assessment Map (ECVAM)		ECVAM (2006 and 2018)
Legal assessment of ECVAM		
Distance from ecological assessment grade 1 in ECVAM		
Distance from legislative assessment grade 1 in ECVAM		

역은 12,677km² 였으며, 농림지역은 51,032km², 관리지역은 25,905km², 자연환경보전지역은 12,209km² 였다. 2018년 기준 용도지역에서 주거지역은 2,684km², 상업지역은 335km², 공업지역은 1,198km²로 면적의 합은 4,217km²이며, 도시지역의 녹지지역은 12,629km² 였으며, 농림지역은 49,351km², 관리지역은 27,223km², 자연환경보전지역은 11,923km²으로 나타났다. 본 연구에서 개발지역이라고 판단한 주거, 공업, 상업지역의 면적의 합은 2006년 3,253km²에서 2018년 4,217km²로 964km²가 증가한 것으로 분석되었다.

2. 도시확장 예측 방법론

의사결정나무는 입력변수의 조합을 통해 출력변수 값을 예측(분류 또는 회귀)하기 위한 의사결정 규칙을 만들고, 이를 나무 형태로 표현하여 의사결정나무를 형성한다. 먼저 해결하고

자 하는 문제에 대해 정의를 내리고 이를 위한 학습 및 테스트 데이터 셋을 구축한다. 다음으로는 학습을 통해 의사결정나무를 구축하고 새로 입력되는 데이터(테스트 데이터 셋)에 대해 예측을 수행한다. 이후 예측 성능 분석을 통해 구축된 모형에 대한 평가를 수행하고, 모형의 미세조정(fine-tuning)을 통해 최적의 모형을 구성한다. 추가적으로 나무 구조의 분류기준 해석을 통해 입력변수의 중요도를 분석 및 활용할 수 있다.

본 연구에서는 의사결정나무에서 분류와 회귀를 위해 가장 많이 사용되는 알고리즘 중 하나로서 Breiman이 개발한 분류나무와 회귀나무의 구현이 가능한 CART(Classification And Regression Tree)를 이용하여 분석에 활용했다. CART의 알고리즘은 불확실성을 의미하는 지니 지수(Gini Index)를 이용한다. 이러한 지니지수

Table 2. Table of overall zoning district

Year	Type		Area (km ²)
2006	Development region	Residential zone	2,179
		Commercial zone	267
		Industrial zone	807
	Green zone		12,677
	Agricultural and forest zone		51,032
	Managed zone		25,905
	Natural environment conservation zone		12,209
2018	Development region	Residential zone	2,684
		Commercial zone	335
		Industrial zone	1,198
	Green zone		12,629
	Agricultural and forest zone		49,351
	Managed zone		27,223
	Natural environment conservation zone		11,923

는 식(2)와 같이 확률에서의 복원추출 개념을 적용한다. 즉, 2번 복원추출 했을 때의 불확실성을 계산하고, 불확실성이 작은 항목과 조건을 이용하여 자식노드를 구성한다(Kim et al., 2016; Triantakonstantis and Mountrakis, 2012; Cheng et al., 2010; Muata and Bryson, 2007; Esposito et al., 1997; Kim and Koehler, 1994).

$$G(A) = 1 - \sum_{c=1}^l P_k^2 \quad (2)$$

본 연구에서 의사결정트리의 각 노드는 세 가지의 요소로 구성된다. 첫 번째 행에 나타나는 숫자는 노드의 레이블 또는 클래스(0은 비개발을 의미하고 10은 개발을 의미)를 나타낸다. 즉 이 노드에 속하는 (학습)데이터 들은 확률적으로 첫 번째 행에 적혀있는 클래스에 속할 가능성이 높다는 것을 의미한다. 두 번째 행은 노드의 순도 또는 확률(분류강도)을 의미하며, 노드의 색상 및 진하기로 표현된다. 왼쪽의 숫자는 첫 번째 클래스(0)에 속할 확률을 의미하며, 오른쪽 숫자는 두 번째 클래스(10)에 속할 확률을

의미한다. 세 번째는 각 노드가 전체 (학습)데이터에 대해 차지하는 비중을 의미한다. 즉 (학습)데이터의 비중을 100%로 했을 때 이 노드에 속하는 데이터의 비중을 의미한다. 만약에 전체 데이터가 우리가 학습기를 구축할 때 활용한 (학습)데이터의 분포와 유사하다면 각 노드에서의 데이터 비중은 분류 확률로 생각할 수 있으며, 실질적으로 분류 시에는 최하층에 있는 단말노드를 기준으로 하여 분류가 수행된다.

본 연구에서는 의사결정나무의 지니지수를 이용하여 2030년 도시지역의 확장을 예측했다. 이를 위해 우선 2006년과 2018년의 용도지역 중 주거지역, 상업지역, 공업지역을 추출하여 신규로 확장된 지역을 신규 도시지역으로 지정하였으며, 종속변수로 분석에 활용했다. Table 1의 다양한 데이터들을 독립변수로 활용했으며, 해당 데이터들은 모두 10m ground sampling distance(GSD)의 래스터 파일로 구축하였으며, 동일한 위치에 래스터 격자가 위치하도록 분석 환경을 일치시켰다. 분석을 위한 속성 값 추출을 위해 래스터 리샘플링 작업을 통해 50m와 500m 간격의 포인트를 생성하고 이를 활용하여

중속변수와 독립변수들의 값들을 추출한 후 분석에 활용할 정형데이터를 구축했다.

신규 도시지역으로 변경된 지역의 값들을 추출하기 위해 전국을 50m 간격의 포인트를 활용하여 속성 값을 추출하였으며, 개발이 발생하지 않은 지역의 속성 값을 추출하기 위해 500m 간격의 포인트를 활용하였다. 이렇게 추출한 포인트들은 하나의 파일로 병합하였으며, 그 결과 샘플 포인트의 전체 수는 506,577개로, 이중 중속 변수인 도시지역으로 변경된 지역의 포인트는 233,238였다. 이렇게 구축한 정형데이터를 이용하여 의사결정나무 분석을 수행했다. 분석 결과 도출한 노드별 도시지역으로 변화할 확률 값을 추출하였으며, 2018년 데이터에 적용하여 노드의 구분 및 확률 값을 적용하여 2030년 도시지역 확장 확률 지도를 구축했다.

III. 결과 및 고찰

1. 의사결정나무 분석 결과 및 도시 확장 예측 지도 구축

2006년 데이터를 이용하여 2018년 신규 도시 지역으로 변화한 지역을 분류하기 위한 의사결정나무 분석을 수행하여 Figure 1과 같은 의사결정나무를 도출했다. 의사결정나무를 구축하는데 활용된 데이터는 용도지역의 녹지지역으로부터의 거리, 공업지역으로부터의 거리, 지형 항목 중 표고 자료가 평가에 활용되었다. 국토환경성평가지도의 환경생태적 평가와 법제적 평가가 활용되었으며, 규제적 성격이 강한 법제적 평가 1등급으로부터의 거리와 보전지역으로부터의 거리, 농림지역으로부터의 거리와 주거지역으로부터의 거리가 평가에 활용되었다.

의사결정트리는 나무 상단의 변수가 데이터 분류 시 중요한 역할을 하는데 녹지 지역으로부터의 거리, 공업지역으로부터의 거리, 환경생태적 등급이 중요한 분류기준으로 나타남을 확인할 수 있다. 의사결정나무의 단말노드는 19개

로 구분하여 개발과 비개발을 예측했다. 가장 오른쪽 단말노드는 100%의 확률로 개발이 발생한 지역이며, 해당 단말노드까지 도달하기 위해서는 다음과 같은 조건을 만족해야 한다. 우선 녹지지역으로부터의 거리가 가깝고, 일정 높이 이하로 표고가 낮으며, 환경생태적평가가 5등급으로 기존 개발지역이나 개발 가능지역에서 개발 발생 확률이 100%로 것으로 나타났다. 그리고 반대로 가장 왼쪽에 위치한 단말노드는 3%의 확률로 개발이 발생할 것이라고 예측하였는데, 세부적으로 살펴보면 녹지지역과 공업지역으로부터의 거리가 멀고, 환경생태적평가 등급이 4등급 이하이며, 법제적평가 등급이 4등급 이하인 지역은 개발 발생 확률이 3%로 개발이 발생될 확률이 상당히 낮게 나타남을 알 수 있다.

이렇게 Figure 1의 의사결정나무 결과를 ArcGIS에서 제공하는 Raster Calculator의 con 함수를 Figure 2와 같이 2018년 데이터에 적용하여 Figure 3과 같이 우리나라 전체를 대상으로 10m GSD의 2030년 도시 확장 확률 지도를 구축했다. 자식노드가 없는 단말 노드까지 도달하기 위한 분기조건들을 조건 연산자인 con 함수에 작성함으로써 해당 단말노드까지 도달하기 위한 경로와 해당 경로에서 중속변수가 나타날 수 있는 확률을 각각의 경로마다 지정할 수 있다. 분석 결과 Figure 3의 2030년 도시 확장 예측 지도를 살펴보면, 기존 도시지역의 인근 지역들을 중심으로 도시지역이 확장될 것이라 예측되었으며, 100%의 확률로 도시지역의 확장으로 예측된 지역은 15,203km², 99%까지 포함한 도시지역의 확장 예측 지역은 15,834km²로 확대되는 것을 살펴볼 수 있다.

2. 정확도 검증

도시확장을 예측하기 위해 추출한 샘플링 추출 포인트 중 75% 지점은 학습에 이용했으며, 25% 지점은 검증을 위한 ROC 분석에 활용했다. ROC 분석 결과 Figure 4와 같이 기울기가 false

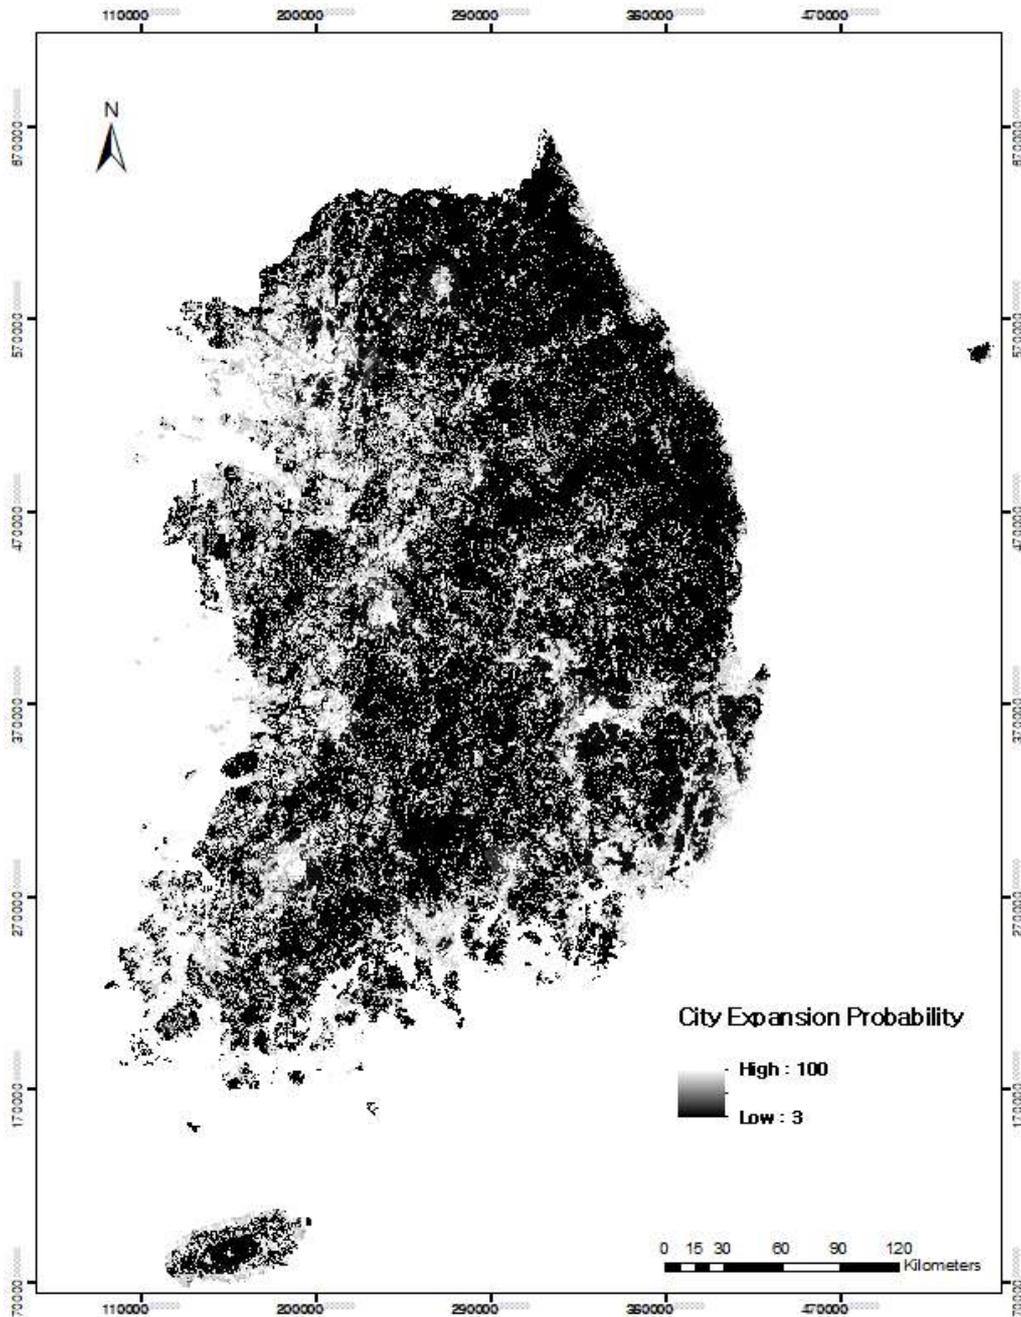


Figure 3. Urban Sprawl Probability Map

과의 비교를 통해 예측력을 검토하고자 하였다. 이를 위해 본 연구에서 의사결정나무 기법을 이용해 구축한 2018년의 도시 확장 예측 지도에서 도시 확장 예측이 99% 이상 나타난 지역들과

2018년 용도지역이 주거, 공업, 상업 지역인 도시지역과의 래스터 중첩을 통해 의사결정트리를 적용해 도출한 도시 확장 예측 결과의 활용 가능성을 검토하고자 하였다. 이러한 중첩분석

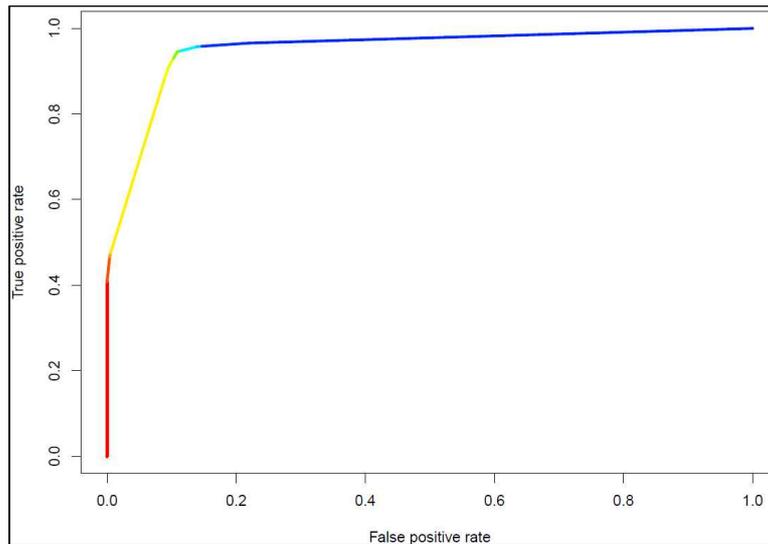


Figure 4. ROC analysis result of Urban Sprawl prediction

결과 의사결정나무를 활용한 도시 확장지역은 기존 도시지역보다 상당히 넓은 면적을 도시지역으로 예측하였다. 2018년 도시지역은 4,145km²이지만 의사결정 트리로 예측한 도시지역은 15,460km²로 상당한 차이가 있었다. 다만 용도지역의 도시지역만을 고려했을 때 도시지역은 86.27% 일치하는 것으로 나타났다.

이러한 분석결과는 의사결정나무의 특징이 반영되었다고 볼 수 있다. 샘플데이터를 활용한 의사결정나무를 적용한 분류에서는 최적의 분류를 통해 신규 개발지역들이 나타나는 조건들을 세부적으로 분류하였으나, 이를 우리나라 전체에 대해 실험으로 도출한 도시개발과 관련된 세부 조건으로 분류 및 적용하였을 때는 해당 도시개발과 관련된 조건을 만족하는 지역들이 기존 도시 면적보다 넓은 지역에 분포함을 알 수 있었다. 이러한 분석 결과를 고려해 보면 의사결정나무를 적용한 도시 확장 모형은 세밀한 도시 확장지역에 대한 예측보다는 도시 확장에 영향을 미치는 인자들을 파악하고, 정책적 활용에 있어서 지역적 개발 경향을 파악하는데 활용하는 것이 알맞을 것이라 판단된다.

IV. 결 론

도시 확장은 지역의 물리적 요인과 다양한 사회·경제적 요인이 복잡하게 얽혀 발생한다. 도시의 발전에 따라 필연적으로 확장이 발생하지만, 자연환경 파괴, 환경오염, 농지손실 등을 야기하기 때문에 도시 확장과 관련된 다양한 요인 간의 관계를 밝히고, 도시 확장을 예측하기 위해 노력해야 한다. 이에 본 연구에서는 데이터의 선형여부 및 정규화와 관련된 고려가 필요 없으며, 해석이 용이하다는 장점 때문에 다양한 분야에서 활용되고 있는 의사결정나무를 활용하여 도시 확장을 예측하고자 했다.

이를 위해 2006년과 2018년의 용도지역, 표고와 경사와 같은 지형데이터, 국토의 환경성과 토지의 이용 규제를 검토하기 위해 국토환경성 평가지도를 활용하였으며, 개발 압력을 고려하기 위해 인구밀도 데이터를 활용했다. 신규 도시 확장지역은 2006년과 2018년의 용도지역의 주거지역, 공업지역, 상업지역을 비교하여 신규 도시지역을 추출하였으며, 2006년의 데이터들을 독립변수로 이용하여 의사결정나무를 도출

했다. 또한 도출한 의사결정나무를 2018년 데이터를 적용하여 2030년 도시 확장을 예측하고자 하였다. 이러한 분석 결과의 정확도 검증을 위해 수행한 ROC 분석에서는 AUC는 0.95051로 우수한 설명력을 나타내었지만, 2018년을 기준으로 실제 도시지역과 예측한 도시 확장지역을 예측한 결과 2018년 도시지역은 4,145km²이지만 의사결정 트리로 예측한 도시지역은 15,460km²로 상당한 차이가 있었다. 다만 용도지역의 도시지역만을 고려했을 때 도시지역은 86.27%의 일치율을 보였다.

따라서 의사결정나무를 활용한 도시지역의 확장은 국토의 많은 지역에서 도시 확장을 예측하고 있는바 세부적인 도시지역의 확장을 예측하기에는 부적합하다고 판단된다. 다만 어떠한 인자들이 도시 확장에 영향을 미치는지 파악할 수 있었다. 이러한 도시 확장의 중요 인자들의 파악은 향후 국토계획, 도시계획, 환경계획에 활용할 수 있는 유용한 정보를 제공할 수 있을 것이라 판단된다. 향후 연구에서는 세밀한 도시 확장까지 예측할 수 있는 AI분석 기법의 적용 연구가 필요할 것으로 판단된다.

References

- Arsanjani · Helbich and De Noronha Vaz. 2013. Spatiotemporal simulation of urban growth patterns using agent-based modeling: The case of Tehran. *Cities*, 32 : 33-42.
- Bhatta. 2010. Causes and consequences of urban growth and sprawl. In *Analysis of urban growth and sprawl from remote sensing data* (pp. 17-36). Springer, Berlin, Heidelberg.
- Bui. · Nguyen and Choi. 2020. Prediction of slope failure in open-pit mines using a novel hybrid artificial intelligence model based on decision tree and evolution algorithm. *Scientific Reports*. 10(1) : 1 - 17.
- Chen · Li · Hou · Wang · Wang · Panahi · Li · Peng · Guo and Niu. 2018. GIS-based groundwater potential analysis using novel ensemble weights-of-evidence with logistic regression and functional tree models. *Science of The Total Environment*. 634 : 853 - 867.
- Chen · Li · Xue · Shahabi · Li · Hong · Wang · Bian · Zhang and Pradhan. 2020. Modeling flood susceptibility using data-driven approaches of naïve Bayes tree, alternating decision tree, and random forest methods. *Science of The Total Environment*. 701, 134979.
- Cheng · Wang and Zhang. 2010. Implementation of a COM-based decision-tree model with VBA in ArcGIS. *Expert Systems with Applications*, 37(1) : 12-17.
- Ghavami · Taleai and Arentze. 2017. An intelligent spatial land use planning support system using socially rational agents. *International Journal of Geographical Information Science*. 31(5) : 1022-1041.
- Jeon · Hong · Lee · Lee and Sung. 2007. Introduction of the New Evaluation Criteria in the Forest Sector of Environmental Conservation Value Map Using LiDAR. *Korean Journal of environmental restoration technology*. 10(5) : 20-30 (in Korean with English summary)
- Jeon · Lee · Song · Sung and Park. 2008. Review of Compositional Evaluation Items for Environmental Conservation Value Assessment Map(ECVAM) of National Land in Korea. *Korean Journal of environmental restoration technology*. 11(1) : 1-13 (in Korean with English summary).
- Jeon · Song · Lee and Kang. 2010. Development Strategy for Utilization of ECVAM using the

- User Survey. *Korean Journal of environmental restoration technology*. 15(4) : 111-118 (in Korean with English summary).
- Kang and Park. 2000. A study on the urban growth forecasting for the Seoul metropolitan area. *The Korean Geographical Society*. 35(4) : 621-639 (in Korean with English summary).
- Kim · Jeon · Song · Kwak and Lee. 2012. Application of ECVAM as a Indicator for Monitoring National Environment in Korea. *Korean Journal of environmental restoration technology*. 11(2) : 3-16 (in Korean with English summary).
- Kim and Koehler. 1994. An investigation on the conditions of pruning an induced decision tree. *European Journal of Operational Research*, 77(1) : 82-95 (in Korean with English summary).
- Kim · Lee · Jung and Jung. 2016. Mapping the Assessment of Natural environment Outstanding Areas of North Korea Using Logistic Regression Analysis. *Journal of the Korean Cartographic Association*. 16(3) : 75-88
- Mcdonald · Green · Balk · Fekete · Revenga · Todd and Montgomery. 2011. Urban growth, climate change, and freshwater availability. *Proceedings of the National Academy of Sciences*. 108(15) : 6312-6317.
- Osei-Bryson. 2007. Post-pruning in decision tree induction using multiple performance measures. *Computers & operations research*, 34(11) : 3331-3345.
- Ruiz Hernandez and Shi. 2018. A Random Forests classification method for urban land-use mapping integrating spatial metrics and texture analysis. *International journal of remote sensing*, 39(4) : 1175-1198.
- Son · Jeon and Choi. 2009. GIS and statistical techniques used in Korea urban expansion trend analysis. *Korean Society for Geospatial Information Science*. 17(4) : 13-22(in English with Korean summary).
- Song · Kim · Jeon · Park and Lee. 2012. Improvement of the Criteria on Naturalness of the Environmental Conservation Value Assessment Map (ECVAM). *Korean Journal of environmental restoration technology*. 15(2) : 31-40 (in Korean with English summary).
- Triantakonstantis and Mountrakis. 2012. Urban growth prediction: a review of computational models and human perceptions. *Journal of Geographic Information System*. 4 : 555-587.
- Wang, Shu, Wang, Guo, Liu and Li. 2019. A random forest classifier based on pixel comparison features for urban LiDAR data. *ISPRS journal of photogrammetry and remote sensing*, 148 : 75-86.
- Won and Hwang. 2018. Simulating Land Use Change Using Decision Tree and SVM Model : A Case Study of North Korea's City after the Unification. *The Korea Spatial Planning Review*. 97 : 41-56 (in Korean with English summary).
- Wu, Ke, Chen, Liang, Zhao and Hong. 2020. Application of alternating decision tree with adaboost and bagging ensembles for landslide susceptibility mapping. *CATENA*, 187, 104396.