

딥러닝(ConvLSTM) 기반 도시성장 예측 연구 : 성장관리계획 수립 적용을 중심으로*

Urban Growth Prediction Using Deep Learning(ConvLSTM)
: Application to Growth Management Planning

이혜준 Lee Hyejun**, 진재특 Chin Jae Teuk***

Abstract

Urban growth prediction has increasingly incorporated AI-driven modeling approaches in planning practice, yet questions remain regarding effective model conditions and their role in decision-making. This study examines the application of a ConvLSTM-based AI model to identify performance-sensitive conditions and to clarify the division of roles between AI and planning practice in urban growth management. Using time-series spatial data from 2000 to 2020 in Cheonan, Chungcheongnam-do, Korea, the model predicts urban growth for 2025 under varying spatial resolutions and input configurations. The results show that predictive performance improves at a 100×100 m resolution compared to 500×500 m, and when development constraints are explicitly included as input features. The findings suggest that AI captures latent spatial constraints to generate quantitatively grounded development potential, while planners retain a qualitative role in aligning outcomes with policy objectives and public acceptance. This study contributes to refining deep learning applications and proposes a complementary framework that integrates insights from the model into growth management.

Keywords: Deep Learning, Urban Growth Model, ConvLSTM, Land Use Change, Urban AI

I. 서론

도시성장은 시가지 확장과 토지 이용 구조의 재편을 포괄하는 복합적인 공간 변화과정으로, 적절한 관리 체계가 동반되지 않은 무계획적 확산은 환경파괴, 기반 시설 부족 등 다양한 부정적 영향을 초래한다(Dadashpoor and Etemadi 2024). 최근 국내 규제

완화와 개발 압력이 가중됨에 따라 비도시지역을 중심으로 산발적인 확산이 발생하며, 체계적인 관리의 필요성이 증대된다(김성희, 김동근 2020).

이러한 정책적 요구에 부응하여 2021년 「국토의 계획 및 이용에 관한 법률」에 성장관리계획이 신설되었다. 비도시지역 내 성장관리계획 수립을 통한 선제적인 난개발 관리가 법제화됨에 따라(성장관리계획

* 이 논문은 2024년도 서울시립대학교 기초·보호학문 및 융복합 분야 R&D 기반조성사업에 의하여 지원되었음. 본 논문은 이혜준(2026)의 석사학위 논문 "Urban AI 기반 도시성장 예측: 딥러닝(ConvLSTM)과 머신러닝 기반 셀룰러 오토마타(CA-ANN) 모형 성능 비교"의 일부를 수정·보완한 것임.

** 서울시립대학교 국제도시개발학과 박사과정(제1저자) | Ph.D. Student, Dept. of International Urban Development, Univ. of Seoul | Primary Author | hyejunlee.77@uos.ac.kr

*** 서울시립대학교 첨단녹색도시개발학과 부교수(교신저자) | Associate Prof., Dept. of Sustainable Urban Development, Univ. of Seoul | Corresponding Author | jchin@uos.ac.kr

수립지침 2021) 도시성장 예측 모델의 중요성 또한 강조되고 있다.

전통적으로 셀룰러 오토마타(CA: Cellular Automata) 및 로지스틱 회귀 모델, ABM(Agent Based Model)이 도시성장 예측에 사용되었다. 인공지능의 급속한 발전과 함께 도시성장 예측에 머신러닝 및 딥러닝 기반 모형이 사용되면서, 빅데이터의 복잡한 변수 간 관계를 알고리즘으로 반영하며 기존 모형의 제약을 극복하고 있다.

본 연구는 ConvLSTM(Convolutional Long Short-Term Memory)을 활용하여 천안시의 도시성장을 예측하는 것을 목적으로 한다. 먼저 딥러닝 모형의 예측 성능이 제약 조건 반영과 공간 해상도에 따라 어떻게 변화하는지를 규명한다. 딥러닝 모형으로 예측한 결과를 실제 도시계획 의사결정 과정에 통합할 때, AI 에이전트와 계획가 사이의 역할 분담 구조에 대하여 탐색하고자 한다.

ConvLSTM은 시계열 데이터 학습을 통해 개발이 제한된 지역을 명시적으로 제시하지 않아도, 도시성장의 물리적 제약 조건을 스스로 학습할 수 있다고 가정하였다. 개발이 엄격하게 제한된 지역인 습지 지역을 포함한 모델과 제외한 모델을 비교하였다.

공간 해상도가 높아질수록 셀별 세부 공간 패턴이 더 많이 반영되므로, 예측 모델이 더욱 정교하게 학습할 수 있다고 판단하였다. 이를 비교하기 위하여 동일한 조건에서 공간 해상도만 달리하였을 때의 성능 차이를 비교하였다.

H1. ConvLSTM은 개발불능지의 인위적 제척 없이도, 데이터에 내재한 물리적 제약 조건을 학습하여 도시성장 패턴을 더 잘 재현할 수 있다.

H2. ConvLSTM 도시성장 예측 모델은 500m 공간 해상도 대비 100m 해상도에서 도시성장을 더 잘 재현한다.

본 연구는 ConvLSTM 기반의 예측 결과를 성장관

리계획 수립 의사결정 체계에 통합함으로써, 인공지능의 예측, 시뮬레이션을 통해 인간의 인지 능력을 강화하는 'AI-강화 계획' 모델을 구체화하고자 한다. 이러한 예측 결과를 실제 도시계획 체계에 통합하기 위해 다음과 같은 연구 질문을 설정하였다. "딥러닝 기반 모델을 도시계획 과정에 통합할 때, AI 에이전트와 도시계획가의 역할은 어떻게 구분되는가?"

ConvLSTM 모델을 활용하여 천안시의 도시성장을 예측함으로써 다음과 같은 의의가 있다. 첫째, 제약 조건과 공간 해상도 시나리오 설정을 통해, 입력 데이터의 변동에 따른 모델의 예측성능이 얼마나 강건한지 검증한다. 둘째, 물리적 제약 조건을 딥러닝 모형이 데이터로부터 직접 학습할 수 있는지 규명한다. 셋째, 예측 결과와 성장관리계획 간의 정합성을 분석함으로써, ConvLSTM의 정량적 분석 결과를 도시계획 의사결정 체계 내에 포함하는 프레임워크를 제안한다.

본 연구는 제2장에서 도시성장의 정의와 도시성장 예측모형의 방법론적 변화를 분석하며, AI와 계획가의 역할 분담 구조를 고찰한다. 제3장에서는 딥러닝 기반 예측모형의 데이터 구축 및 설계 방법론을 기술하고, AI와 계획가의 주체별 역할 규명을 위한 분석 프레임워크를 정립한다. 제4장에서는 ConvLSTM의 실증 결과를 정량적, 정성적으로 제시하고, 이를 알고리즘적 측면에서 해석한다. 분석결과를 성장관리계획 수립 과정에 적용하여 실무적 활용 가능성을 검증한다. 제5장에서는 주요 연구 결과를 요약하고 정책적 시사점, 연구의 한계를 기술하였다. 이를 통해 인공지능이 도시계획 의사결정을 지원하는 과정을 규명한다.

II. 선행연구 고찰

1. 도시성장의 정의

도시성장은 학문적 접근에 따라 다양한 의미로 정의되며 Clark(1982)는 도시성장을 “특정 경제와 사회에서 인구가 도시로 집중되면서 도시의 중요성이 확대되는 공간적, 인구학적 과정”으로 정의하였다. 이후 도시성장론에 대한 다학제적 접근이 확대되면서 도시성장은 물리적, 인구학적, 경제적 과정이 상호작용하는 복합적 현상으로 정의되어 왔다(윤병훈 2017).

물리적 과정으로서의 도시성장은 토지이용의 전환, 경관 구조의 변화, 시가지 지역의 공간적 확산과 융합이 반복되면서 도시공간이 물리적으로 재구성되는 과정을 의미한다. 이때 공간적 확산은 도시 주변부 개발지의 증가, 도시 면적의 물리적 확장, 개발지 총량의 증가를 의미한다. 또한 비도시지역의 건조환경으로의 전환, 외곽 지역의 조직적 토지 확장 및 신규 개발 등을 포함한다(Angel 2023).

인구학적 과정으로서의 도시성장은 산업화로 인한 사회변동의 결과로, 농촌의 인구가 도시로 이동하면서 인구 분포가 재편되는 현상을 의미한다(Bhatta, Saraswati, and Bandyopadhyay 2010). 이러한 인구의 이동은 도시성장의 물리적 변화의 결과이면서 동시에 동인으로 작용한다.

경제적 과정으로서의 도시성장은 인구와 자본, 산업이 도시로 집중되면서 지식의 확산과 인적자본의 축적이 이루어지고, 이러한 상호작용이 도시를 경제활동의 중심으로 발전시키는 것을 의미한다(Black and Henderson 1999). 이는 도시화, 산업화, 경제공간의 재배치 과정과 밀접하게 연관된다. 본 연구에서는 토지이용 전환을 중심으로 한 물리적 과정에 중점을 두어 도시성장을 분석한다.

2. 딥러닝 기반 도시성장 예측 모델로의 변화

CA는 전이 규칙에 따른 셀의 상태 변화와 자기조직화 원리에 기반하여 도시 시뮬레이션에 적용되었다. CA는 토지이용 간의 국지적 상호작용을 과거의 개발이 미래의 공간 패턴에 영향을 미친다는 가정을 전제로 도시성장을 시뮬레이션한다(Santé, García and Miranda 2010).

CA는 중력이론이나 최대 엔트로피 이론과 같은 공간 상호작용 이론에 기반한 공간 상호작용 모델이 가진 한계를 개선하며 비선형성과 시공간적 동태성을 반영할 수 있다(Li and Gong 2016). 그러나 도시성장을 모사하기 위한 전이 규칙의 매개변수를 연구자가 정의해야 하므로, 복잡한 변수 간의 비선형적인 상관관계를 고려한 전이 규칙을 설정해야 한다는 점에서 한계가 존재한다.

이를 극복하기 위해 CA는 머신러닝 기법과 결합하여 전이 규칙을 자동으로 탐색하는 연구가 수행됐다. CA 및 MC(Markov Chain) 모델에 머신러닝을 적용한 하이브리드 예측 모델이나 머신러닝 알고리즘을 활용한 예측 모델이 제안된다. 구체적으로 CA-ANN(Artificial Neural Network)과 CA-RF(Random Forest), CA-CNN(Convolutional Neural Network), 의사결정나무 등의 모형이 도시 성장을 예측하는 데 활용되었다(김근한, 최희선, 김동범 외 2020). 그러나 이러한 모형은 도시 데이터의 시공간적 특성인 공간적 자기상관과 이질성을 충분히 고려하지 못한다는 한계가 지적된다.

도시 데이터의 시공간적 특성을 고려하기 위해 CNN(Convolutional Neural Network)과 RNN(Recurrent Neural Network)을 기반으로 한 ConvLSTM, PredRNN과 같은 모형이 등장하였다. ConvLSTM은 장기 의존성 문제를 개선한 LSTM의 시계열 처리 능력과 CNN의 공간 데이터 처리 능력을

통합한 딥러닝 모델로 시공간 정보 동시 학습이 가능하다.

딥러닝 기반 접근은 빅데이터에 대한 분석, 분석과 정의의 자동화가 가능하며 데이터 노이즈에 대한 강건성을 갖는다는 점에서 전통적인 도시성장 예측 모델을 보완하고 있다. 특히 ConvLSTM 기반 도시확장 예측 모델은 시공간 정보를 동시에 보존하며 학습하는 특성을 갖는다는 점에서 주목받고 있다. 그러나 CNN 기반의 신경망 모형은 비유클리드 데이터의 직접적인 학습이 어려우며, 고정된 수용영역에 의존한 인접 관계를 고려한다는 구조적 한계가 있다(Guan, Xing and Li 2023).

GNN(Graph Neural Network)은 도시 지식 그래프의 개체관계나 네트워크상의 흐름과 같은 비유클리드 데이터 학습이 가능하다는 특징을 갖는다. GNN은 노드 분류, 링크 예측, 그래프 분류와 같은 그래프 관련 태스크를 입력 데이터부터 최종 출력까지 전체 과정을 하나의 통합된 모델로 학습하는 종단 간 방식으로 해결하는 딥러닝 모델이다(Wu, Pan and Chen 2021).

GNN에 시간 학습 기법을 결합하여 공간 및 시간 차원의 동태를 동시에 포착할 수 있게 한 STGNN(Spatio-Temporal GNN), 그래프 어텐션 메커니즘을 통해 개체 간 상호작용의 이질성을 반영한 GAT(Graph attention network), 어텐션 메커니즘을 기반으로 한 Spatio-Temporal Graph Transformer 등으로 발전하고 있다(Yu, Ma and Ren 2020).

3. 도시계획에서 인공지능의 적용

도시계획 내 인공지능의 확산은 Urban AI, AI urbanism, GeoAI 등 다양한 담론을 형성하고 있다. 방법론 및 학문적 배경 차이에도 불구하고, 이들 담론은 도시 빅데이터를 알고리즘 기반 분석, 시뮬레이션, 예측하여 도시의 사회, 공간적 문제에 대한 의사결정

을 지원한다는 점에서 공통점이 있다(Boutayeb, Lahsen-Cherif and Khadimi 2025).

Urban AI는 도시 인공지능 전반을 아우르는 총론적인 개념으로 소르본 대학에서 12개 도시의 전문가들이 관련 사례를 공유하면서 소개된 바 있다(이세원, 이기훈 2024). 초기에는 Urban AI를 도시 데이터 세트로부터 학습하는 알고리즘들의 집합으로 정의하였으며, 이후 도시의 복잡성, 정책적 맥락, 하이브리드성을 내포하는 일반적인 인공지능과 차별화된 개념으로 구체화되었다(Popelka, Narvaez Zertuche and Beroche 2023).

인공지능을 활용한 데이터 기반의 분석과 예측, 최적화 등은 스마트시티 발전의 핵심 요소이다. Urban AI는 관점에 따라 스마트시티의 연장선으로 이해되기도 하며, 도시 설계, 계획, 거버넌스 등에 미치는 비가시적인 영향을 포괄하는 통합적인 패러다임으로 이해되기도 한다(Caprotti, Cugurullo and Cook 2024).

인공지능은 도시계획을 대체하기보다는 보조하고 강화하는 도구로 기능하며, 의사결정 지원을 통해 계획 과정의 질을 높이는 데 활용될 수 있다(Batty 2018). 특히 딥러닝은 인공지능경망 알고리즘의 접근성 확대와 클라우드 기반 서비스의 확산으로 도시 분석의 보편적인 도구로 확산되고 있다.

시공간 딥러닝 기반 예측 모델은 Urban AI의 핵심적 특성인 복잡성과 정책적 맥락을 반영한다는 점에서, Urban AI의 하위 개념으로 이해될 수 있다. 시공간 딥러닝 예측 모델은 다층적으로 상호작용하는 도시 시스템을 변수화하여 연산 과정에 통합한다. 이를 통해 도시의 복잡성을 수용하는 분석 체계로 기능한다. 딥러닝 기반 분석은 블랙박스 문제로 인해 설명력이 제한되는 한계가 존재하지만(Batty 2023), 인간의 직관으로 인식하기 어려운 시공간적 특성을 학습할 수 있다는 점에서 여전히 유용하다.

도시 및 지역계획 수립 과정에서 AI의 활용은 AI

에이전트의 자율성과 계획가의 개입 정도에 따라 5단계로 구분할 수 있다(〈표 1〉 참조).

전통적 및 AI-보조 계획 단계에서는 계획가의 책임이 매우 높으나 AI-에이전트는 계획 과정을 지원하는 수준에 머물러 낮은 자율성을 갖는다.

‘AI-보조 단계’에서 AI는 데이터의 수집, 처리, 시각화 등 반복적인 기초 업무를 지원하여 계획수립의 효율성을 높인다. 또한 현황분석 시 지원 보고서 등을 생성함으로써 계획가의 분석 업무를 보조한다. 계획가는 AI의 기술적 지원을 바탕으로 이해관계자와의 소통을 주도하며 의사결정을 내린다(Fu 2024).

‘AI-강화 단계’부터 AI는 인간의 인지 능력을 확장하는 파트너로서 기능하며, 기존의 분석 역량으로는 수행하기 어려운 빅데이터의 잠재적 패턴을 식별하거나, 시뮬레이션 및 예측 등을 수행한다(Yigitcanlar, Senadheera and Marasinghe 2024).

도시계획가는 계획의 목표 설정과 같은 정책적 가치 판단에 집중하고, AI가 처리한 연산 결과를 비판적으로 해석하여 최종 계획을 수립한다.

‘AI-자동화 단계’에서는 AI와 계획가의 역할 비중이 역전된다. AI가 자기 학습과 자동화 능력을 통해 도시계획의 전 과정을 주도하며 계획안 작성을 수행한다(Liao, Li and Guo 2025). 계획가는 계획의 문제를 정의하고, 목표를 설정하는 정책적 가치 판단에 집중한다. 동시에 AI가 수행하는 계획의 과정을 감독하고 결과물을 모니터링한다.

‘AI-자율 단계’는 강한 인공지능이 계획의 전 과정을 인간의 개입 없이 완전히 자동화하는 단계이다. AI는 스스로 도시 문제를 정의하고 해결책을 도출하는 의사결정이 가능하다. 계획가의 개입이 매우 제한되며, 도시의 작동 메커니즘과 사회적 수용성에 대한 지식을 바탕으로 AI가 도출한 문제 정의가 타당한지

표 1 도시 및 지역계획에서 AI 에이전트와 계획가의 역할

의사결정 분담 단계	AI 에이전트의 자율성	계획가 참여도	도식
전통적 계획	없음 (계획 과정 외)	높음 (계획가 전적 책임)	
AI-보조 계획	낮음 (준비 및 지원)	높음 (계획 과정에 직접 참여)	
AI-강화 계획	중간 (식별, 예측, 시뮬레이션)	중간 (계획 과정을 감독, 관리)	
AI-자동화 계획	높음 (계획가 설정 목표를 기반으로 계획수립)	낮음 (계획 과정을 관리 및 감독)	
AI-자율화 계획	높음 (자기 학습 및 의사결정 알고리즘을 통한 계획수립)	매우 낮음 (계획 과정에서 배제)	

주: 회색 음영은 본 연구에서 수행한 의사결정 분담 단계를 의미함.
자료: Peng, Lu, Liu and Zhai(2024, 7) 재구성.

모니터링하는 기능에 국한된다.

본 연구는 AI가 예측 및 시뮬레이션을 수행하는 'AI-강화 단계'에 해당하며 이 단계를 중심으로 AI와 계획가의 구체적인 협업 구조를 제시한다. Urban AI의 도입으로 인한 AI 자율성의 범위와 계획가의 상호작용 구조에 대한 이론적 담론을 확장하여, 실제 계획 과정에 적용한다.

4. 기존 연구와의 차별성

본 연구는 천안시를 대상으로 ConvLSTM 기반의 도시성장 예측을 수행하고 이를 현행 성장관리계획과 비교 및 고찰한다는 점에서 다음과 같은 차별성을 확보하였다.

첫째, 데이터의 연산 효율성을 고려한 딥러닝 기반의 시공간 학습 모델을 채택하여 도시성장을 분석하였다. 기존의 CA 및 머신러닝 기반 연구는 전이 규칙의 수동 설정, 공간적 자기 상관성의 간접적인 반영 등의 한계가 지적되어 왔다(Jin, Liang and Fang 2024).

본 연구는 CNN의 공간 특징 추출과 LSTM의 시간적 종속성 학습 능력을 결합한 ConvLSTM을 도입하여 시계열 공간정보를 통합적으로 학습하였다. 최근 GNN 등 그래프 기반 모델이 대두되고 있으나, 본 연구에서는 연산의 경량성 측면에서 우위를 가지는 ConvLSTM을 예측모형으로 채택하였다.

둘째, 제약 조건 및 공간 해상도 시나리오 변화에 따른 예측 모델의 안정성을 검증하고, ConvLSTM의 공간적 제약 조건에 대한 내재적 학습 능력을 확인하였다. 기존의 연구들은 주로 동일 데이터 세트에 대한 모델 간 성능 비교나, 미래 성장 예측을 위한 정책 시나리오에 집중했다(Nam and Lee 2025).

본 연구는 입력 데이터의 조건 변화에도 불구하고 ConvLSTM이 도시성장을 일관되게 재현하는지에 주목하였다. 물리적 제약 조건을 모델이 데이터로부터

직접 학습하는지를 확인함으로써 기존 연구와 차별화된다.

마지막으로, ConvLSTM의 예측 결과와 현행 성장관리계획 간의 정합성을 분석하였다. 이는 성장관리정책의 제도적 한계를 정성적으로 분석한 선행연구와 차별화된다(구형수 2016).

본 연구는 성장관리계획 구역을 딥러닝 예측 결과와 비교하여, 잠재적 개발 가능성과 중점관리 대상지역 간의 불일치를 정량적으로 분석하였다. 이를 통해 단편적 지표에 의존해 설정되는 중점관리대상지역 지정을 고도화할 수 있는 방안을 제시한다. 나아가 'AI-강화 단계'에서의 구체적인 의사결정 지원 프레임워크를 제안함으로써 인공지능의 시뮬레이션 결과와 계획가의 정책적 판단이 상호작용하는 의사결정 체계를 구체화하였다.

III. 방법론

1. 연구의 범위

본 연구의 공간적 범위는 충청남도 천안시이며 분석 단위는 100m와 500m 격자이다. 천안시는 교통 접근성이 우수하고 수도권의 개발 규제를 회피하려는 산업입지 수요가 높다. 또한 비계획적 소규모 개발행위가 빈번하게 발생하고 있어 본 연구의 분석 대상으로 설정하였다.

2000년부터 2020년까지 5년 간격의 시계열 데이터를 구축하였다. 이를 바탕으로 2020년 예측 결과를 활용해 모델 성능을 검증하였으며, 2025년의 도시성장을 단기 예측하였다. 데이터 간격을 5년으로 설정하여 도시성장 변화가 누적되어 시계열적 추세가 모델에 반영되도록 하였다.

2. 데이터 전처리

도시성장의 시공간적 변화를 예측하기 위한 타겟 변수로 토지피복도의 시가화 지역을 활용하였다. 입력 변수로는 토지피복도(농업지역, 산림지역, 습지, 수역)와 함께 각 셀의 인구수, 사업체 수, 종사자 수, 철도역 및 전철역까지의 거리, 고속도로 진출입구까지의 거리, 산업단지로부터의 거리, 택지개발지구로부터의 거리를 사용했다(〈표 2〉 참조).

토지피복도는 랜드셋 위성영상을 기반으로 한 GLC_FCS30D를 활용하였고 시가화 지역, 농업지역, 산림지역, 초지, 습지, 나지, 수역으로 재분류하였다(정종철 2024). 30m 해상도의 데이터를 100m 및 500m 격자로 다운샘플링하였다. 이때 각 격자 내에서 가장 많은 면적을 차지하는 항목을 해당 셀의 토지 이용으로 설정하였다.

인구, 사업체, 종사자 격자는 통계청에서 제공하는 인구 통계 격자, 사업체 통계 격자, 종사자 격자를 활용하였다. 해당 데이터는 집계된 인구를 100m, 500m 격자 단위로 제공하는데, 격자 식별 아이디를 기준으로 결합하여 공간 데이터로 가공하였다.

철도역 및 전철역 접근성과 고속도로 진출입구는 각 셀의 중심에서 가장 가까운 시설까지의 유클리드 거리를 측정하였다. 천안시 경계부의 셀이 시 외부에 있는 시설과의 거리가 더 가까운 경우를 고려하기 위해, 천안시 경계로부터 바깥으로 각각 20km, 25km의 버퍼를 설정하여 해당 버퍼 내에 속한 시설을 대상으로 접근성을 측정하였다. 각 철도역 및 전철역의 개통 연도와 고속도로 진출입구 준공 연도 데이터를 활용하여 시계열 접근성 자료를 구축하였다.

산업단지 접근성과 택지개발지구의 접근성은 각 셀의 중심점에서 가장 가까운 산업단지의 중심점과

표 2 도시성장 예측변수 및 데이터 출처

구분	변수	정의	단위	데이터 출처	시간적 범위
토지피복도	시가화 지역	시가화 지역 이진형 토지피복도	이진형 (0,1)	GLC_FCS30D, Zenodo ¹⁾	2000년, 2005년, 2010년, 2015년, 2020년
	농업지역	농업지역 이진형 토지피복도			
	산림지역	산림지역 이진형 토지피복도			
	습지	습지 이진형 토지피복도			
	수역	수역 이진형 토지피복도			
사회경제	인구	각 셀에 거주하는 인구의 수	명	SGIS(통계지리정보서비스), 통계청	
	사업체	각 셀에 위치하는 사업체 수			
	종사자	각 셀에 종사하는 인구의 수			
접근성	철도역 및 전철역	각 셀에서 가장 가까운 철도역 및 전철역까지의 유클리드 거리	m	V-WORLD 디지털트윈 국토, 국토교통부	
	고속도로 진출입구	각 셀에서 가장 가까운 고속도로 진출입구까지의 유클리드 거리		한국도로공사 공공데이터 포털, 한국도로공사	
도시계획	산업단지	각 셀에서 가장 가까운 산업단지 중심점까지의 유클리드 거리		V-WORLD 디지털트윈 국토, 국토교통부	
	택지개발지구	각 셀에서 가장 가까운 택지개발지구 경계까지의 유클리드 거리		택지정보시스템, 한국국토정보공사	

1) GLC_FCS30D (Global Land Cover with Fine Classification System Dynamic)는 유럽연합의 오픈 리서치 저장소인 Zenodo에서 제공하며 EU의 연구 및 프로그램을 통해 수행된 프로젝트 결과물을 저장하고 공유하는 저장소임(Zenodo 2025).

택지개발 지구 경계까지의 유클리드 거리를 측정하였으며, 산업단지와 택지개발지구 내의 셀의 거리는 0으로 계산하였다. 산업단지 지정일과 택지개발지구 지정일 정보를 활용하여 시계열 데이터를 구축했다.

3. ConvLSTM 기반 도시성장 예측 방법론

ConvLSTM은 CNN과 LSTM 구조적 장점을 결합한 모형으로, LSTM의 입력과 상태 전이 및 게이트 연산을 합성곱으로 대체함으로써 인접 격자 간의 공간적 상관관계를 내부적으로 반영한다. 이를 통해 시계열적 변화와 공간적 패턴을 동시에 학습할 수 있어 도시 성장 예측 문제에 활용된다.

1) ConvLSTM 모델 설계

ConvLSTM이 시계열적 변화와 공간적 패턴을 동시에 학습할 수 있도록, 시점, 공간 축의 격자 구조, 변수 채널을 입력값으로 구성하였다. 데이터를 높이와 너비, 변수 채널의 3차원 배열 형태로 입력하여 시공간 패턴을 학습하였다. 구글코랩과 텐서플로를 활용하여 연산을 수행하였다.

$$\begin{aligned} i_t &= \sigma(W_{xi} * x_t + W_{hi} * h_{t-1} + b_i) \\ f_t &= \sigma(W_{xf} * x_t + W_{hf} * h_{t-1} + b_f) \\ C_t &= f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * x_t + W_{hc} * h_{t-1} + b_c) \\ o_t &= \sigma(W_{xo} * x_t + W_{ho} * h_{t-1} + W_{co} * C_t + b_o) \\ h_t &= o_t \circ \tanh(C_t) \end{aligned} \quad \langle \text{식 1} \rangle$$


〈식 1〉의 x_t 는 시점 t 의 입력 텐서로, 시가화 예측과 관련된 입력 변수와 관련된 12개의 채널을 의미한다. h_t 는 현재 시점의 은닉상태이며 C_t 이전 시점의 셀 상태이다. i_t, f_t, o_t 는 각각 입력, 망각, 출력 게이트를 나타내며 시그모이드 함수(σ)를 통해 정규화되어 0~1 범위의 값을 갖는다.

W_{xi}, W_{hi}, W_{ci} 은 각각 입력, 은닉상태, 셀 상태에 대한 합성곱 커널이며 본 연구에서는 3x3 커널과 16개의 필터를 사용하였다. b_i 는 각 게이트 및 셀 상태에 해당하는 편향 항이다.

〈그림 1〉과 같이 2025년의 시가화 지역을 예측하기 위해서 2000~2020년의 토지피복도와 관련 변수를 ConvLSTM에 입력하여 2020년과 2025년의 시가화 확률을 도출하였다.

셀별로 0-1 사이의 확률값을 연속적으로 가지는

그림 1 ConvLSTM 기반 도시성장 예측 흐름도



시가화 확률지도에서 2025년의 시가화 지역을 판별하기 위해, 2020년의 실제 토지피복도와 시가화 확률지도를 비교하여 시가화 영역으로 판별되는 픽셀 수가 같아지는 임계값을 산출하였다. 이 임계값 이상의 확률을 가진 셀을 2025년 시가화 영역으로 판별하였다.

2) 예측모형 성능 평가 기준

모델의 예측 성능 평가는 2020년 도시화 확률 예측 지도와 토지피복도를 통해 실제 도시화 지역을 비교하여 평가하였다. 평가지표로 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1-score, IoU (Intersection over Union)를 활용하였다(〈식 2~6〉 참조).

이때 TP(True Positive)는 모델이 실제 도시지역을 정확히 예측한 픽셀 수를 의미하며, TN(True Negative)은 모델이 비도시지역을 정확히 예측한 픽셀 수이다. FP(False Positive)는 실제로는 비도시지역이나 모델이 도시지역으로 예측한 경우를 나타내고, FN(False Negative)은 실제로는 도시지역이나 모델이 비도시지역으로 예측한 경우를 의미한다.

정확도는 전체 예측 셀 중 도시지역을 도시로, 비도시지역을 비도시로 예측한 셀의 비율로서, 모델의 전반적인 예측 정확도를 나타낸다. 재현율은 실제 도시지역 중에서 모델이 올바르게 도시지역으로 판별한 비율을 나타낸다. F1-score는 정밀도와 재현율의 조화 평균으로, 두 지표 간의 균형을 종합적으로 평가할 수 있는 지표이다. IoU는 실제 도시화 지역과 예측된 도시화 지역 간의 교집합을 합집합으로 나눈 값으로 공간적 일치 정도를 평가할 수 있다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad \langle \text{식 2} \rangle$$

$$Precision = \frac{TP}{TP + FP} \quad \langle \text{식 3} \rangle$$

$$Recall = \frac{TP}{TP + FN} \quad \langle \text{식 4} \rangle$$

$$F1\text{-score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad \langle \text{식 5} \rangle$$

$$IoU = \frac{TP}{TP + FP + FN} \quad \langle \text{식 6} \rangle$$

4. ConvLSTM 기반 도시성장 예측모형의 정책적

적용 검토

ConvLSTM 기반 도시성장 예측모형의 정책적 활용성을 검토하기 위해, 난개발을 방지하고 계획적인 개발을 유도하기 위하여 수립하는 법정 계획인 성장관리계획을 분석 대상으로 설정하였다. 성장관리계획 수립에 ConvLSTM 모형의 적용 가능성을 확인하기 위해 다음과 같은 분석과정을 거쳤다.

첫째, 성장관리계획에 관련된 데이터를 구축하기 위하여 천안시에서 기수립한 「천안시 성장관리계획 구역 지정 및 성장관리계획 수립」 보고서와 성장관리계획구역 공간 데이터(2025년 9월 기준)를 구축하였다(천안시 2024). 이를 통해 현행 성장관리계획의 수립 지침 분석범위와 구역의 공간적 범위를 명확히 하였다.

둘째, 성장관리계획의 수립지침 중 분석의 대상이 되는 수립 단계에 관하여 문헌 연구에서 도출한 도시 및 지역계획에서 AI와 계획가의 역할(〈표 1〉 참조)과 ConvLSTM 실증분석 결과(H1, H2)를 통합하여 분석틀을 설계하였다. 이를 통해 ConvLSTM 정책적 도입에 따른 인공지능과 계획가의 역할 분담 구조를 규명하였다.

셋째, 실증분석 결과 ConvLSTM으로 도출한 2025년 천안시 개발확률 지도와 성장관리계획구역을 GIS 상에서 중첩 분석하였다. 이를 통해 계획구역의 확률 분포 차이를 시각화하였다.

넷째, 계획구역당 확률 분포를 정량화하기 위해 각 계획구역의 평균 개발확률, 총개발확률, 개발 강도를 산출하였다. 평균 개발확률이란 각 구역 내에 속하는

확률의 평균값을 의미하며 구역 내부의 격자들이 전반적으로 높은 확률을 보이는지를 확인할 수 있다. 총개발확률은 각 구역에 속한 확률의 총합으로 구역의 면적이 넓을수록 큰 값을 갖는다. 한편 개발 강도는 총개발확률을 단위 면적당 수치로 환산한 것으로 면적 대비 개발확률이 얼마나 강하게 나타나는지를 확인할 수 있으며 <식 7>과 같이 산출한다.

$$I_i = \sum_{j=1}^n P_j / A_i \quad \langle \text{식 7} \rangle$$

이때 I_i 는 i 구역의 개발 강도로 단위는 $1/\text{km}^2$ 이다. P_j 는 i 구역 내 j 번째 격자의 시가화 예측 확률, A_i 는 i 구역의 전체 면적(km^2)이다.

마지막으로 개발 강도를 기준으로 상위 20개와 하위 20개 구역을 추출하였다. 해당 구역의 성장관리계획 구역 설정 유형이 정량적 지표와 정합성을 갖는지, ConvLSTM이 포착한 새로운 개발 징후가 존재하는지를 비교하여 모델의 정책적 지원 가능성을 검토하였다.

IV. 분석 결과

1. 제척 여부에 따른 성능 비교

본 절에서는 ConvLSTM이 데이터에 내재화된 공간적 제약을 학습하는지를 검증하였다. 습지는 개발이 엄격히 제한된 지역으로, 통상적인 개발 가능성 분석 시 제척되는 대상이다. 습지는 토지 피복도상 명확히 구분되는 항목으로, 모델이 지형적 제약 조건을 내재적으로 학습할 수 있는지 확인하기 위하여 분석 대상으로 설정하였다.

분석 결과 ConvLSTM은 습지를 제척하지 않고 포함했을 때 예측성능이 더 우수한 것으로 나타났다(<표 3> 참조). 이는 가설 H1, 'ConvLSTM은 개발불

능지의 인위적 제척 없이도, 데이터에 내재한 물리적 제약 조건을 학습하여 도시성장 패턴을 더 잘 재현할 수 있다.'를 지지한다.

습지를 제외하면 도시지역으로 정확히 판별하는 경우(TP)가 감소하고, 도시지역을 비도시지역으로 오분류(FN)하거나 비도시지역을 도시지역으로 잘못 예측하는 경우(FP)가 매우 증가하였다. 비도시지역을 비도시지역으로 판별하는 경우(TN)는 제척 여부에 따른 변화 폭이 미미하였다(<그림 2-(a), (b)> 참조).

특히 습지 격자의 평균 예측 확률값을 비교한 결과, 인위적으로 습지를 제척한 모델(0.03)에 비해 습지를 포함시킨 모델(0.01)의 평균 시가화 확률이 더 낮게 산출되었다. 이는 ConvLSTM이 습지가 시가화 가능성이 낮은 지역이라는 속성을 시계열 패턴을 통해 스스로 학습하여 공간적 제약 조건을 모델에 반영하였음을 입증한다. 반면 습지를 제외하면 인위적인 제척 과정에서 발생하는 학습 데이터의 공간적 연속성의 단절과 맥락 정보의 손실이 발생하였기 때문에

표 3 제척 여부와 해상도에 따른 ConvLSTM 성능

	(a)	(b)	(c)
공간 해상도	100m	100m	500m
제척 여부	제척 O	제척 X	제척 X
Accuracy	0.9574	0.9774	0.9727
Precision	0.6814	0.8310	0.7677
Recall	0.6814	0.8310	0.7677
F1-score	0.6814	0.8310	0.7677
IoU	0.5168	0.7109	0.6230
TP	6,602	8,052	271
FP	3,087	1,637	82
FN	3,087	1,637	82
TN	132,241	133,691	5,565
시가화 지역셀 (%)	9,689 (6.7%)	9,689 (6.7%)	353 (5.9%)
비시가화 지역셀 (%)	135,328 (93.3%)	135,328 (93.3%)	5,647 (94.1%)
Total	145,017	145,017	6,000


F1-Score(0.6814), IoU(0.5168)가 낮게 나타났다.

이러한 결과는 ConvLSTM이 입력 데이터에 포함된 공간적 제약을 스스로 식별하고 이를 모델에 내재화하는 공간제약 학습 능력을 갖추고 있음을 입증한다. 이는 연구자의 주관적 판단에 의존하는 제척 방식의 한계를 극복한다.

2. 해상도에 따른 성능 비교

가장 우수한 성능을 보인 100m 공간 해상도의 습지를 제척하지 않은 (b) 모델과 다른 조건은 동일하되 공간 해상도만 500m로 조정된 경우를 (c)로 설정하였다. 시뮬레이션 결과 100m 해상도의 모델(Model

그림 2 제척 여부 및 공간 해상도에 따른 ConvLSTM 예측 결과



주: 1) (a) 100m 공간 해상도의 제척 적용 2020년 예측 결과, (b) 100m 공간 해상도의 제척 미적용 2020년 예측 결과, (c) 500m 공간 해상도의 제척 미적용 2020년 예측 결과, (d) 100m 공간 해상도의 제척 미적용 2025년 예측 결과
2) 범례의 Color bar는 색상별 개발 확률 분포를 나타냄.

b)이 500m 해상도의 모델(Model c)보다 전반적으로 도시성장을 더 정확히 재현하였다. 이는 H2 'ConvLSTM 도시성장 예측 모델은 500m 공간 해상도 대비 100m 해상도에서 도시성장을 더 잘 재현한다.'를 지지하는 결과이다.

F1-score, IoU의 평가지표를 비교한 결과 100m 공간 해상도에서 재현 성능이 높았다. 이는 비도시지역을 정확하게 판별하는 경우(TN)는 큰 차이가 없으나, 해상도가 높아질수록 복잡한 도시 패턴을 세밀히 학습해 도시지역을 정확하게 판별(TP)하기 때문이다(<그림2-(b), (c)> 참조).

공간 해상도를 100m×100m로 설정했을 때 예측 성능이 향상된 이유는 100m 해상도가 500m 해상도에 비해 천안시의 도시공간 구조와 블록의 크기를 반영하는 데 정보의 손실을 최소화하는 크기이기 때문으로 해석된다. 500m 격자 해상도는 하나의 셀이 차지하는 면적이 넓어 도시지역과 녹지 지역 등 서로 다른 용도가 혼재되어 토지피복 정보가 지나치게 단순화되기 때문이다.

저해상도의 공간 이미지는 추출 가능한 세부 정보가 부족하여 알고리즘이 관련 특성을 포착하는 데 한계가 있다(Vali, Comai and Matteucci 2020). 이러한 공간적 이질성의 단순화는 교통 접근성 및 도시계획 변수를 구축하는 과정에서 데이터의 왜곡을 심화한다.

반면, 100m의 해상도에서는 천안시 도심을 기준으로 하나의 셀이 블록을 2~3개 포함하며, 이는 각 셀이 도시의 공간적 이질성을 충분히 반영할 수 있는 적절한 크기라고 판단된다.

이를 통해 도시별 물리적 특징과 블록의 크기를 고려한 적절한 해상도의 선택은, 입력 변수의 왜곡을 최소화하고 모델의 예측성능을 확보하기 위한 조건임을 확인하였다.

3. 2025년 시가화 예측 비교

가장 우수한 성능을 보인 100m 공간 해상도의 습지를 포함한 모델 (b) 시나리오를 적용하여 천안시의 2025년 시가화 지역을 예측하였다. 예측 결과 2025년 천안시의 도시지역 면적은 ConvLSTM 106.55㎢로 산출되었으며, 2020년 시가화 면적인 96.89㎢보다 넓게 예측하였다.

천안시 기존 도심지역인 동 지역을 중심으로 시가화가 진행되며, 기존 도심지 내부의 충전식 개발과 인접 경계의 확장이 심화할 것으로 전망된다. 도심지를 중심으로 남측의 풍세면과 북측의 성환읍의 기개발된 중소규모 시가화 지역을 중심으로 소규모 경계 확장이 나타날 것으로 보인다(<그림 2-(d)> 참조).

전반적으로 시가화 지역 간의 공간적 연결성이 강화되는 개발 패턴이 도출되었으며, 북측의 도시지역 간의 연속적 확장 패턴을 강하게 예측하여 도시지역의 면적이 증가할 것으로 전망되었다.

반면 동남측 비도시지역의 비율이 높은 지역에서는 분산된 점적 개발 패턴에 대해 도시지역으로의 전환이 거의 일어나지 않을 것으로 예측하였다. 이는 CNN의 연산 과정 중 소객체가 소실되는 현상에 의한 것으로 해석되며, 딥러닝 모델이 미세한 점적인 변화를 포착하는 데 구조적 한계가 있음을 보여준다.

ConvLSTM은 도시의 연속적인 변화 양상과 응집된 성장 패턴을 강하게 재현하는 특성이 있음을 보여준다. ConvLSTM은 거시적인 차원에서 도시 공간 구조 변화나 광역적 성장 추세를 예측하는 데 적합한 구조적 특성을 지녔음을 시사한다.

반면, 비도시지역의 미시적인 공간 변화와 점적 개발 패턴을 모델의 한계로 인해 잘 포착하지 못하므로 공간적 규모와 도시성장 유형에 부합하는 모델을 선별해 상호 보완적으로 해석해야 한다.

4. ConvLSTM 실증분석 결과를 활용한 성장관리계획 수립 지원 체계 검토

ConvLSTM 기반 도시성장 예측 결과를 성장관리계획 수립 의사결정에 활용함으로써, 인간과 AI의 혼합형 의사결정 모델을 구체화하였다. 천안시는 총 6단계의 계획수립 절차를 통해 성장관리계획 구역을 지정하고 있다.

〈표 4〉에 따르면 개발 가능지 분석을 통해 기개발지, 개발불능지, 개발억제지를 제척한 계획관리지역을 성장관리계획구역으로 지정한다.

표 4 천안시 성장관리계획 수립 절차

단계	세부내용
1	기초조사 - 상위 및 관련계획 검토 - 천안시 일반현황 분석
2	성장관리계획구역 검토대상지 설정 천안시 계획관리지역 검토
3	개발가능지 도출 - 기개발지 분석 - 개발불능지 분석 - 개발억제지 분석 - 계획관리지역 내 제척
4	성장관리계획구역 지정 및 중점관리대상지역 선정 - 읍면동별 인구증가율, 지가변동률, 개발행위허가 및 공장개발 건수 검토 - 개발 가능지별 중심지 인접성 및 교통 접근성 검토 - 평가 부문별 점수 산정을 통한 중점관리대상지역 선정
5	성장관리계획구역 유형구분 구역별 현황을 고려한 유형 구분
6	부문별 계획 수립 기반시설계획, 건축물 관련 계획

자료: 천안시 2024, 5.

이 중 4단계인 ‘성장관리계획구역 지정 및 중점 관리 대상 지역 선정’을 통해 개발 압력이 높아 선제적인 난개발 방지가 필요한 지역을 선정한다(천안시 2024). 천안시의 성장관리계획구역은 개발 압력이 높은 지역은 중점 관리 대상 지역(주거형, 산업형, 일반형), 개발 압력이 낮은 지역은 비중점 관리 대상 지역(관리형)으로 분류된다.

현행 체계에서는 읍·면·동별 인구증가율, 지가변동률 점수, 개발 가능지별 점수를 단순 합산하여 50점 이상인 지역을 중점관리대상지역으로 선정한다. 이러한 단순 합산 방식은 천안시의 개발 가능성을 정밀하게 평가하는 데 한계가 있다.

본 연구는 중점 관리 대상 지역을 선정하는 과정에서 ConvLSTM 기반 도시성장 예측 결과를 적용하여 정량적 의사결정 지원 가능성을 검토하였다. ConvLSTM 모델은 데이터에 내재한 시공간적 패턴을 학습함으로써 인간의 인지 능력을 보완하는 ‘AI-강화 계획’의 성격을 가진다(〈표 5〉 참조).

ConvLSTM은 개발 가능성을 정량적으로 산출하며 계획가의 별도 개입 없이 데이터에 내재한 물리적 제약 조건을 내재적으로 학습한다. 계획가가 설정한 임계값에 따라 개발 가능성을 표출하고 시가화 지역으로 변환될 셀을 도출한다.

도시계획가는 전문지식과 행정적 목표를 반영하여 지역의 특성에 맞는 예측변수를 설정하고, 공간 해상도를 결정한다. 개발 압력 임계값을 설정하고 개발 확률지도와 개발 가능지역을 중첩 분석하여 중점 관

표 5 성장관리계획구역 지정 시 ConvLSTM 모델과 계획가의 역할 분담

세부 내용	구분	AI 에이전트의 역할	계획가의 역할
• 성장관리계획구역 지정 및 중점 관리 대상 지역 선정	• AI-강화 계획	• ConvLSTM 모델 등 인공지능 모델을 활용한 개발 가능성 산출 • 데이터에 잠재된 제약 조건의 내재적 학습 • 계획가가 설정한 임계값에 따른 개발확률 표출	• 지역 맞춤형 평가지표 및 분석 단위 설정 • 개발 압력 임계치 설정 및 GIS 중첩 분석을 통한 특정 구역의 개발 가능성 도출 • AI 구조적 한계에 대한 정성적 보완

리 대상 지역의 개발 가능성을 도출한다.

계획가는 ConvLSTM의 구조적 한계가 드러나는 지점들을 식별하고, 다른 인공지능 및 도시성장 모형을 통해 얻은 예측 결과를 상호 보완적으로 해석한다. 이를 통해 인공지능이 제시한 정량적 분석 결과에 계획가의 정성적 판단이 결합함으로써 더 실효성 있는 계획 수립이 가능해진다.

〈표 6〉과 〈그림 3〉은 ConvLSTM 기반의 예측 결과와 성장관리계획구역의 중첩 분석을 수행한 결과로, 행정구역별 평균 개발확률(Mean)은 0.14~0.20으로 유사하게 나타났다. 총개발확률(Sum)은 구역의 면적과 비례하여 성환읍, 성남면, 동면 순으로 높게 나타

났다. 반면 동지역의 안서동, 유량동, 직산읍, 성거읍은 총개발확률이 낮게 분석되었다.

면적 대비 개발확률인 개발 강도를 기준으로 비교한 결과, 성환읍, 직산읍, 풍세면이 19/km² 이상으로 가장 높은 수치를 나타냈으며, 성거읍, 광덕면, 안서동이 14/km² 이하로 가장 낮았다.

성장관리계획구역별로 정량 지표를 산출한 결과, 현행 중점 관리 대상 지역과 ConvLSTM 기반 개발 강도 사이에 공간적 불일치가 식별되었다. 구체적으로 성남면 20, 북면 37구역은 개발 압력이 낮아 비중점 관리 대상 지역(관리형)으로 설정되었으나, 본 모델의 분석 결과 개발 강도가 24.6/km² 이상으로 나타났다.

표 6 천안시 성장관리계획구역별 ConvLSTM 시가화 예측 확률 분포(상·하위 20개소)


상위	성장관리계획구역		Intensity (1/km ²)	Sum	Mean	하위	성장관리계획구역		Intensity (1/km ²)	Sum	Mean
	구역명	유형					구역명	유형			
1	목천읍1	중점	33.48	1.42	0.24	1	목천읍48	비중점	0.00	0.00	0.00
2	입장면26	중점	26.83	2.36	0.26	2	병천면23	비중점	0.00	0.00	0.00
3	성환읍2	중점	26.60	2.28	0.23	3	성남면5	중점	0.00	0.00	0.00
4	성남면6	중점	26.28	2.31	0.29	4	입장면14	중점	0.00	0.00	0.00
5	수신면4	중점	25.89	3.88	0.24	5	입장면23	중점	0.00	0.00	0.00
6	성환읍16	중점	25.67	13.46	0.24	6	광덕면22	비중점	3.90	0.25	0.04
7	풍세면4	중점	25.46	1.34	0.22	7	광덕면38	비중점	4.11	0.25	0.06
8	성거읍2	중점	25.34	16.96	0.25	8	성거읍3	중점	4.24	0.26	0.09
9	성환읍8	중점	25.31	23.46	0.25	9	광덕면35	비중점	4.96	0.48	0.06
10	성환읍11	중점	25.26	2.26	0.23	10	안서동1	비중점	4.99	0.25	0.06
11	목천읍7	중점	25.19	2.50	0.25	11	동면41	비중점	5.41	0.25	0.06
12	성환읍7	중점	24.92	103.16	0.25	12	목천읍47	비중점	5.41	0.25	0.06
13	성남면11	중점	24.88	4.45	0.26	13	병천면2	중점	5.42	0.25	0.08
14	성남면20	비중점	24.81	9.06	0.23	14	광덕면32	비중점	5.76	0.25	0.05
15	성환읍4	중점	24.77	1.93	0.24	15	광덕면40	비중점	5.92	0.24	0.12
16	입장면4	중점	24.73	2.35	0.26	16	수신면20	비중점	6.05	0.24	0.08
17	북면37	비중점	24.66	0.98	0.20	17	성환읍29	중점	6.23	0.26	0.09
18	성환읍18	중점	24.49	41.45	0.25	18	성거읍4	중점	6.24	0.26	0.07
19	성거읍7	중점	24.43	11.94	0.23	19	성거읍5	중점	6.44	0.52	0.09
20	성남면10	중점	24.34	13.12	0.24	20	광덕면42	비중점	6.71	0.24	0.12

주: 1) 개발 강도(Intensity)를 기준으로 정렬.

2) 유형 구분에서 '중점'은 중점관리대상지역을, '비중점'은 비중점관리대상지역을 의미함.

3) 회색 음영은 개발 강도와 중점관리대상지역 설정이 불일치하는 사례임.

그림 3 2025년 ConvLSTM 예측 결과와 성장관리계획구역 중첩지도



주: 범례의 Color bar는 색상별 개발 확률 분포를 나타냄.

반면 성남면 5, 입장면 14 및 23구역은 중점 관리 대상 지역으로 설정되었으나 개발 강도가 0.00/㎢에 불과하여 개발 압력이 매우 낮은 지역으로 나타났다.

이러한 분석 결과는 현행 성장관리계획상 중점 관리 대상 지역과 실제 개발 압력 간의 공간적 불일치가 존재함을 시사한다. 개발 압력이 높은 지역에 낮은 수준의 관리 지침이 적용되어 도로, 상수도 등의 기반 시설 부하가 증가할 수 있다.

반대로 개발 압력이 낮은 지역에 인센티브가 과다하게 부여되어 계획의 실효성이 떨어지고, 난개발 방지라는 계획의 목적을 저해하는 요인이 될 수 있다. 따라서 향후 성장관리계획 수립 시 ConvLSTM과 같은 도시성장 예측 모델 도입을 통해, 데이터 기반의 중점 관리 대상 지역 평가 체계를 구축함으로써 현행 계획의 실효성을 제고할 수 있다.

V. 결론

1. 분석 결과 요약

본 연구는 ConvLSTM을 활용하여 천안시의 도시성장을 예측하였다. 기존 연구들이 모델 간의 성능 비교나 정책 시나리오 적용에 집중한 반면, 본 연구는 제척 여부와 공간 해상도 변화에 따른 예측성능을 비교하였다는 점에서 차별성이 있다. 또한, 예측 결과가 성장관리계획 수립 의사결정 과정에 통합될 때 AI와 도시계획가의 역할을 규명하여 ‘AI-강화 계획’의 구체적인 체계를 제시하였다.

이를 위해 2000년부터 2020년까지 5년 간격의 시계열 데이터를 구축하였으며, 입력 변수로 토지피복도, 사회경제 변수, 교통 접근성 변수, 도시계획 변수를 구축하였다. 2020년의 예측 결과로 ConvLSTM의 성능을 평가하고 2025년의 도시성장을 예측하였다.

주요 연구 결과는 다음과 같다.

첫째, ConvLSTM은 공간 제약정보를 제척하지 않았을 때 예측능력이 뚜렷하게 개선되었다. 이는 H1 ‘ConvLSTM은 개발불능지의 인위적 제척 없이도, 데이터에 내재한 물리적 제약 조건을 학습하여 도시성장 패턴을 더 잘 재현할 수 있다.’를 지지하는 근거이다. 습지 지역을 포함한 ConvLSTM 모형은 평균 예측 확률을 인위적으로 습지를 제척한 모델보다 낮은 평균 시가화 확률을 도출하였다. 이는 ConvLSTM이 데이터에 내재한 공간적 제약의 속성을 스스로 파악하여 학습하는 능력을 갖추고 있음을 보여준다.

둘째, ConvLSTM은 공간 해상도가 500m일 때보다 100m 해상도에서 예측능력이 개선되었으며, 이는 H2 ‘ConvLSTM 도시성장 예측 모델은 500m 공간 해상도 대비 100m 해상도에서 도시성장을 더 잘 재현한다.’를 지지하는 결과이다. 셀의 크기가 커질수록 각기 다른 토지피복 속성이 한 셀에 혼재되고, 변수의 특성이 평균화되면서 각 셀이 공간적 이질성을 반영하는데 왜곡을 초래한다. 도시 공간의 물리적 특징을 고려한 적절한 해상도의 선정이 예측능력을 확보하기 위해 중요한 조건임을 확인하였다.

셋째, ConvLSTM 예측 결과를 성장관리계획 의사결정 과정에 통합한 결과, AI 에이전트와 계획가의 상호 협력적인 의사결정 체계를 구체화하였다. AI 에이전트는 데이터로부터 제약 조건을 내재적으로 학습하여 개발 가능성을 산출하며 계획가는 지역의 특성과 정책적 목표에 부합하는 지표 및 임계치 설정 등의 역할을 한다. AI-강화 단계에서는 인공지능이 계획가의 전문지식을 대체하는 것이 아니라 기술적 판단을 보완하는 과정임을 의미한다. 따라서 개발 가능지역의 설정이나 개발 총량 산출 등 핵심적인 공간 계획 의사결정에는 계획가의 전문적인 판단과 경험적 통찰이 수반되어야 한다.

2. 정책적 시사점

본 연구는 딥러닝 기반 모델을 활용하여 도시성장을 예측하고 시뮬레이션함으로써, AI 강화 계획 단계의 적용 가능성을 보여준다. 본 모델의 예측 결과는 중심지 분석, 도시 스포를 완화 전략 수립, 성장관리계획 구역 지정 등 데이터 기반 도시계획의 의사결정을 지원하는 도구로 활용될 수 있다는 시사점을 가진다.

연구 결과 천안시의 도시성장이 급속한 외연적 확산보다는 기존 도심지역을 중심으로 한 충전식 개발과 경계 확장형 성장으로 전개될 가능성이 큰 것으로 예측되었다. 이에 따라 기존 도심지역 내 유흥지 개발을 고려한 재개발 및 도시재생 전략이 강조되어야 한다. 기존 도심에서 북측 및 동쪽으로 확장되는 개발 축을 따라 소규모 개발 패턴이 확산할 것으로 예측되므로, 해당 지역에 대한 난개발 관리 대책이 필요하다.

본 연구의 실증 분석 결과는 데이터 기반의 성장관리계획 수립을 위한 정책적 가이드라인으로 활용될 수 있다. ConvLSTM 모델을 통해 도출된 개발 강도와 현행 중점 관리 대상 지역 간의 공간적 불일치를 식별함으로써, 기존 지표 위주의 분석이 지닌 한계를 보완할 수 있음을 입증하였다.

특히 개발 압력이 높지만 비중점 관리 대상 지역으로 선정된 성남면과 북면 일대에 대하여 선제적인 난개발 관리를 위한 유형 재조정 및 모니터링 체계 강화가 필요하다. 반면 개발 압력이 낮게 도출되었으나 중점 관리 대상으로 선정된 성남면, 입장면 일대에 대하여 규제의 실효성을 재검토해야 한다.

3. 연구의 한계 및 향후 연구 방향

본 연구는 ConvLSTM 모델을 통해 시공간 예측의 활용 가능성을 탐구하였으나, 모델 구조상 도시 공간의 복잡성을 정밀하게 반영하는 데 한계가 있다.

CNN은 고정된 커널을 사용하여 국소적 상관성을 포착하므로 네트워크 구조나 전역적인 상관성을 포착하는 데 구조적 한계가 있다.

이는 앞선 분석에서 언급한 점적 개발 패턴의 포착 미비 문제의 근본적인 원인으로 판단된다. 향후 연구에서는 이를 극복하기 위해 공간을 네트워크 상호작용 구조로 파악하는 GNN 등의 그래프 기반 방법론으로의 확장이 요구된다.

딥러닝 모델의 주요한 장점은 빅데이터를 처리하는 데 있으나, 본 연구는 단일 도시와 제한된 변수만을 대상으로 수행하였다는 한계를 갖는다. 이는 딥러닝의 연산 능력을 충분히 활용하지 못한 측면이 존재한다. 향후 연구에서는 변수의 확장과 다수의 도시를 대상으로 한 교차검증을 통해 모델의 표준화 가능성을 정립할 필요가 있다.

실제 도시성장은 기개발지, 개발가능지, 개발억제지를 제외한 개발가능지를 중심으로 발생하며, 인접지자체 간의 상호작용을 수반한다. 본 연구에서는 모델의 적합성을 검증하기 위해 단일 제약 조건으로 통제하고 광역적 공간구조를 포함하지 못한 한계를 갖는다. 향후 연구에서는 도시성장에 영향을 미치는 토지이용 제약 요인과 인접 도시 간의 시공간적 상호작용을 모델에 반영하고자 한다.

• 참고문헌

References

1. 구형수. 2016. 저성장시대의 비시가화지역 성장관리 과제와 개선방향. 국토연구 88권: 3-23.
Hyeongsu, K. 2016. Growth Management Policies for Non-urbanized Areas in a Low Growth Era. *The Korea Spatial Planning Review* 88: 3-23.
2. 김근한, 최희선, 김동범, 정예림, 진대용. 2020. 의사결정나무를 활용한 2030년 도시 확장 예측. 한국환경복원기술학회지 23권, 6호: 125-135.
Kim, G., Choi, H., Kim, D., Jung, Y., and Jin, D. 2020.

- Urban sprawl prediction in 2030 using decision tree. *Journal of the Korea Society of Environmental Restoration Technology* 23, no.6: 125-135.
3. 김성희, 김동근. 2020. 비도시지역 난개발 토지이용행태 분석 기법 연구: 토지이용의 분산과 혼재를 중심으로. 국토연구 105권: 145-164.
Kim, S. and Kim, D. 2020. Analysis method of disorderly land use behavior in non-urban areas: focused on land use diffusion and mixture. *The Korea Spatial Planning Review* 105: 145-164.
 4. 성장관리계획수립지침. 2021. 국토교통부훈령 제1428호(9월 14일 전부개정). 제1장 제2절.
Guidelines for the Establishment of Growth Management Plans. 2021. Ministry of Land, Infrastructure and Transport Directive No. 1428 (Fully Revised on September 14). Chapter 1, Section 2.
 5. 윤병훈. 2017. 도시성장 영향요인을 고려한 도시성장단계 평가기법 개발, 박사학위논문. 서울시립대학교.
Yoon Byunghoon. 2017. *Development of The Evaluation Model of Urban Growth Stage Considering Urban Growth Factors Based on The Connectivity between Core and Periphery*. Ph.D. diss., University of Seoul.
 6. 이세원, 이기훈. 2024. 도시 AI(Urban AI) 구현을 위한 정책 방향. 국토 510호, 6-16. 세종: 국토연구원.
Lee Sewon and Lee Gihun. 2024. Policy direction for urban AI (Urban AI) implementation. *Planning and Policy* 510, 6-16. Sejong: KRIHS.
 7. 정종철. 2024. Sentinel-2 시계열 영상을 활용한 토지피복변화 모니터링. 국토연구 121권: 143-154.
Jeong, J. C. 2024. The monitoring of land cover changes using time-series images of Sentinel-2. *The Korea Spatial Planning Review* 121: 143-154.
 8. 천안시. 2024. 천안시 성장관리계획구역 지정 및 성장관리계획 수립. 천안: 천안시.
Cheonan City. 2024. Designation of cheonan city growth management plan zone and establishment of growth management plan. Cheonan: Cheonan City.
 9. Angel, S. 2023. Urban expansion: Theory, evidence and practice. *Buildings and Cities* 4, no.1: 124-138.
 10. Batty, M. 2018. Artificial intelligence and smart cities. *Environment and Planning B: Urban Analytics and City Science* 45, no.1: 3-6.
 11. Batty, M. 2023. The emergence and evolution of urban AI. *AI & Society* 38: 1045-1048.

12. Bhatta, B., Saraswati, S. and Bandyopadhyay, D. 2010. Quantifying the degree-of-freedom, degree-of-sprawl, and degree-of-goodness of urban growth from remote sensing data. *Applied Geography* 30, no.1: 96-111.
13. Black, D. and Henderson, V. 1999. A theory of urban growth. *Journal of Political Economy* 107, no.2: 252-284.
14. Boutayeb, A., Lahsen-Cherif, I. and Khadimi, A. E. 2025. When machine learning meets geospatial data: a comprehensive geoai review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 18: 13135-13191.
15. Caprotti, F., Cugurullo, F., Cook, M., Karvonen, A., Marvin, S., McGuirk, P. and Valdez, A. M. 2024. Why does urban Artificial Intelligence (AI) matter for urban studies? Developing research directions in urban AI research. *Urban Geography* 45, no.5: 883-894.
16. Clark, D. 1982. *Urban Geography: An Introductory Guide*. Milton Park: Routledge.
17. Dadashpoor, H. and Etemadi, K. 2024. Defining urban growth: A meta-synthesis of studies. *GeoJournal* 89, no.5: 194.
18. Fu, X. 2024. Natural language processing in urban planning: A research agenda. *Journal of Planning Literature* 39, no.3: 395-407.
19. Guan, X., Xing, W., Li, J. and Wu, H. 2023. HGAT-VCA: Integrating high-order graph attention network with vector cellular automata for urban growth simulation. *Computers, Environment and Urban Systems* 99: 101900.
20. Jin, G., Liang, Y., Fang, Y., Shao, Z., Huang, J., Zhang, J. and Zheng, Y. 2024. Spatio-temporal graph neural networks for predictive learning in urban computing: a survey. *IEEE Transactions on Knowledge and Data Engineering* 36, no.10: 5388-5408.
21. Li, X. and Gong, P. 2016. Urban growth models: progress and perspective. *Science Bulletin* 61, no.21: 1637-1650.
22. Liao, C., Li, Y., Guo, R. and Li, X. 2025. Artificial intelligence for spatial analysis in cities. *Cities* 167: 106334.
23. Nam, J. and Lee, C. 2025. Forecasting urban expansion: A dynamic urban growth model using DS-ConvLSTM to simulate multi-land regulation scenarios. *Ecological Informatics* 88: 103136.
24. Peng, Z.-R., Lu, K., Liu, Y. and Zhai, W. 2024. The pathway of urban planning AI: From planning support to plan-making. *Journal of Planning Education and Research* 44, no.4: 1-15.
25. Popelka, S., Narvaez Zertuche, L. and Beroche, H. 2023. Urban AI Guide[report]. Paris: Urban AI. <https://urbanai.fr/wp-content/uploads/2023/03/Urban-AI-Guide-2023-V2.pdf> (accessed September 10, 2025).
26. Santé, I., García, A. M., Miranda, D. and Crecente, R. 2010. Cellular automata models for the simulation of real-world urban processes: A review and analysis. *Landscape and Urban Planning* 96, no.2: 108-122.
27. Vali, A., Comai, S. and Matteucci, M. 2020. Deep learning for land use and land cover classification based on hyperspectral and multispectral Earth observation data: A review. *Remote Sensing* 12, no.15: 2495.
28. Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C. and Yu, P. S. 2021. A comprehensive survey on graph neural networks. *IEEE Transactions on Neural Networks and Learning Systems* 32, no.1: 4-24.
29. Yigitcanlar, T., Senadheera, S., Marasinghe, R., Bibri, S. E., Sanchez, T., Cugurullo, F. and Sieber, R. 2024. Artificial intelligence and the local government: A five-decade scientometric analysis on the evolution, state-of-the-art, and emerging trends. *Cities* 152: 105151.
30. Yu, C., Ma, X., Ren, J., Zhao, H. and Yi, S. 2020. Spatio-Temporal Graph Transformer Networks for Pedestrian Trajectory Prediction. In *Proceedings of Computer Vision - ECCV 2020*, pp.507-523. Cham: Springer International Publishing.
31. Zenodo. <https://about.zenodo.org> (accessed October 26, 2025).

- 논문 접수일: 2026. 1. 14.
- 심사 시작일: 2026. 3. 13.
- 심사 완료일: 2026. 4. 13.

요약

최근 도시성장 예측 모형은 AI 기술과 결합하여 데이터 기반의 의사결정을 고도화하고 있다. 본 연구는 제척 여부와 공간해상도에 따른 ConvLSTM의 성능 변화를 비교하고, 향후 성장관리계획 수립 과정에서 AI를 계획의 도구로 적용할 때의 역할 분담 체계를 정립하는 데 목적이 있다. 충청남도 천안시를 대상으로 2000~2020년 데이터를 학습하여 2025년 도시성장을 예측한 결과, 제척을 하지 않은 100m 공간해상도에서 도시성장을 상대적으로 잘 예측하였다. 성장관리계획 수립 시 AI는 제약조건을 내재적으로 학습하여 개발 가능성을 도출하는 정량적 역할을 수행하며, 계획가는 주민 수용성 및 정책 목적을 고려하여 계획을 수립하는 정성적 역할을 수행한다. 본 연구는 공간해상도와 제척 여부에 따른 딥러닝 성능 개선의 조건을 규명하며, 인공지능과 계획가의 협업을 통해 계획 수립의 객관성과 정책적 수용성을 확보할 수 있는 상호보완적 협업 체계를 구체화하였다.

- **주제어:** 딥러닝, 도시 성장 모델, ConvLSTM, 토지 이용 변화, 도시 인공지능

