

그래프 트랜스포머 기반 표현학습과 연결성 제약 클러스터링 기법을 활용한 수도권 지역화 연구

전혜민*·이상일**

Graph Transformer-Based Representation Learning and Spatially Constrained Clustering: A Regionalization Study of the Seoul Metropolitan Area

Hyemin Jeon* · Sang-Il Lee**

요약 : 본 연구는 그래프 트랜스포머 기반 표현학습과 연결성 제약 클러스터링을 결합한 통합적 지역화 프레임워크를 제안하고, 이를 2020년 수도권 1,125개 읍면동 자료에 적용하였다. 기존 지역화 연구는 사회·경제적 속성에 기초한 등질지역 접근과 인구 이동 등 공간적 상호작용에 기초한 기능지역 접근으로 나뉘어 발전해 왔으나, 두 접근은 입력 데이터의 구조가 달라 통합적으로 활용되기 어려웠다. 본 연구는 공간 단위를 노드로, 지역 간 인구 이동을 엣지로 하는 지리적 그래프를 구성하고, 그래프 트랜스포머를 통해 각 지역의 사회·경제적 속성, 인구 이동 관계, 그래프 구조 및 지리적 위치를 통합한 지역 표현 벡터를 생성하였다. 이후 이 벡터를 SKATER 알고리즘에 투입하여 공간적 연결성을 만족하는 지역화 결과를 도출하였다. 클러스터 유효도 평가를 위해 전역적 자족도와 SCSA 기반 응집도·분리도 평가를 적용한 결과, $k=8$, $k=13$, $k=20$ 이 주요 후보로 도출되었다. $k=8$ 에서는 수도권의 광역적 하위 권역과 강남 업무 지구의 독립성이 확인되었고, $k=13$ 에서는 북한 연결 지역, 서해 중부 도서 지역, 서울남부 신도시 지역 등이 분화되었다. $k=20$ 에서는 서울 내부의 삼분 구조, 동탄의 독립성, 서해 북단 도서지역의 특수성이 보다 세밀하게 드러났다. 이러한 결과는 제안된 프레임워크가 등질지역적 유사성과 기능지역적 결속성을 함께 고려하면서, 수도권의 다층적 지역 구조를 공간적으로 연속된 권역으로 도출할 수 있음을 보여준다. 또한 본 연구는 그래프 트랜스포머를 지역화 문제에 적용한 국내외적으로 드문 사례로서, GeoAI 기반 지역 구조 분석의 방법론적 확장 가능성을 제시한다.

주요어 : 그래프 트랜스포머, 지역 표현학습, 연결성 제약 클러스터링, SKATER, 딥 그래프 인포맥스, 지역화, 수도권, GeoAI

Abstract : This study proposes an integrated regionalization framework that combines graph transformer-based representation learning with spatially constrained clustering and applies it to 1,125 eup, myeon, and dong units in the Seoul metropolitan area as of 2020. Previous regionalization studies have largely followed two separate approaches: homogeneous regionalization based on socioeconomic attributes and functional regionalization based on spatial interactions such as migration flows. To integrate these approaches, this study constructs a geographical graph in which spatial units are represented as nodes and interregional migration flows as edges. A graph transformer is then used to learn regional representation vectors that integrate socioeconomic attributes, migration relationships, graph structure, and geographical location. The learned vectors are subsequently used as input for the SKATER algorithm to derive spatially contiguous regions. To evaluate cluster validity, this study employed global self-containment and SCSA-based compactness and separation measures. The results identified $k=8$, $k=13$ and $k=20$ as major candidate solutions. The $k=8$ solution revealed broad subregional structures of

본 논문은 전혜민(2025)의 석사학위 논문을 수정·보완한 것임.

* 서울대학교 지리교육과 석사(MA, Department of Geography Education, Seoul National University), geohyemnm9962@snu.ac.kr

** 서울대학교 지리교육과 교수(Professor, Department of Geography Education, Seoul National University), si_lee@snu.ac.kr

the metropolitan area and the independent role of the Gangnam business district. The $k=13$ solution further distinguished areas such as the northern border region, the central western island region, and the southern new-town region of Seoul. The $k=20$ solution captured a more detailed structure, including the tripartite division of Seoul, the independence of Dongtan, and the distinctive characteristics of the northwestern island region. These results suggest that the proposed framework can incorporate both homogeneous similarities and functional cohesion while deriving spatially contiguous regions that reveal the multi-layered regional structure of the Seoul metropolitan area. In this respect, this study provides a rare example of applying graph transformer-based representation learning to regionalization and demonstrates its potential for extending GeoAI-based regional structure analysis.

Key Words : Graph Transformer, Regional Representation Learning, Spatially Constrained Clustering, SKATER, Deep Graph Infomax, Regionalization, Seoul Metropolitan Area, GeoAI

1. 서론

최근 지리학에서는 인공지능, 특히 딥러닝을 공간데이터 분석에 적용하려는 GeoAI 연구가 빠르게 확산되고 있다. GeoAI는 공간데이터 분석에 AI를 적용하여 지리적 의사결정을 도출하려는 융합적 연구 흐름으로 이해될 수 있다(Smith, 1984; Alastal and Shaqfa, 2022; Huang *et al.* (eds.), 2025). 초기 GeoAI 연구는 주로 래스터 형식의 이미지 데이터를 활용한 분석에 집중되었으나(강영욱, 2023; Grekousis, 2019), 최근에는 포인트, 라인, 폴리곤, 그래프와 같은 벡터 기반 공간데이터에도 AI 기법을 적용하려는 시도가 확대되고 있다(Mai *et al.*, 2022). 이러한 흐름은 지리학의 공간분석이 개별 공간 객체의 분류나 예측을 넘어, 공간 객체들 사이의 관계와 상호작용을 함께 학습하는 방향으로 확장되고 있음을 보여준다. 이는 공간 단위의 속성과 공간 단위 사이의 관계를 동시에 고려해야 하는 지역화 연구에도 중요한 방법론적 함의를 갖는다.

이러한 맥락에서 그래프 자료구조와 그래프 딥러닝은 지리학 연구에 중요한 방법론적 가능성을 제공한다. 그래프는 노드와 엣지로 구성되는 자료구조로, 공간 단위와 그들 사이의 관계를 동시에 표현할 수 있다. 지리학적 맥락에서 개별 지역은 노드로, 지역 간 인접성이나 이동, 통근, 교류와 같은 공간적 상호작용은 엣지로 나타낼 수 있다. 또한 지역의 사회·경제적 속성은 노드 특성으로, 지역 간 상호작용의 강도와 유형은 엣지 특성으로 표현할 수 있다. 따라서 그래프 자료구조는 지역의 속성과 지역 간 관계를 하나의 분석 틀 안에 통합할 수 있다는 점에서 지리학적 분석에 적합하다(Zhang *et al.*, 2022).

그래프 딥러닝의 핵심 과제 중 하나는 그래프 표현학습이다. 그래프 표현학습은 그래프의 구조적 정보를 보존하면서 노드, 엣지 또는 전체 그래프를 잠재 공간의 벡터로 변환하는 과정이다(Chen *et al.*, 2020). 지리학적으로 볼 때, 노드 표현학습은 개별 지역을 고차원 벡터로 표현하는 지역 표현학습으로 이해할 수 있다. 이때 생성된 지역 표현 벡터는 지역 자체의 속성뿐 아니라 다른 지역과의 관계를 함께 반영하므로, 지역 구조 분석, 예측, 분류, 클러스터링과 같은 후속 과제에 활용될 수 있다(Li and Moura, 2020; Ye *et al.*, 2022; Zhang *et al.*, 2022; Yang *et al.*, 2024).

본 연구는 그래프 표현학습 방법 중 그래프 트랜스포머에 주목한다. 그래프 트랜스포머는 트랜스포머의 셀프-어텐션 메커니즘을 그래프 구조 데이터에 적용한 모형이다(Dwivedi and Bresson, 2020). 셀프-어텐션은 입력 요소들 사이의 중요도를 동적으로 학습하고, 이를 바탕으로 각 요소의 표현을 갱신하는 과정이다(Bahdanau *et al.*, 2014; Vaswani *et al.*, 2017). 그래프 트랜스포머에서는 이러한 과정이 노드 사이에서 이루어지며, 엣지 정보가 어텐션 계산에 함께 활용된다. 기존 그래프 신경망은 이웃 노드의 중요도를 동적으로 학습하지 못하거나(Kipf and Welling, 2016), 엣지 속성을 명시적으로 반영하는 데 한계를 보였지만(Veličković *et al.*, 2017; Liang *et al.*, 2022), 그래프 트랜스포머는 노드 간 가중치를 동적으로 갱신하고 다변량 엣지 속성도 반영할 수 있다(Dwivedi and Bresson, 2020). 이는 지역 속성과 공간적 상호작용이 복합적으로 얽혀 있는 지리적 현상을 분석하는 데 유용하다.

이러한 방법론적 가능성은 지역화 연구와 직접적으로 연결된다. 지역화(regionalization)는 공간 단위를 내부적으로 유사하고 지리적으로 연속된 더 큰 지역으로 묶는 과정

이다(Assunção *et al.*, 2006). 지역화의 결과는 각 공간 단위 하 하나의 지역에만 속한다는 상호 배제의 원리, 하위 지역의 합이 전체 지역을 구성한다는 전체 포괄의 원리, 그리고 한 지역 내 모든 공간 단위가 공간적으로 연결되어야 한다는 연결성 제약의 원리를 충족해야 한다(이상일·이몽현, 2020; Duque *et al.*, 2007). 전통적으로 지역화 연구는 등질지역 접근과 기능지역 접근으로 나뉘어 발전해 왔다. 등질지역은 유사한 사회·경제적 속성을 공유하는 영역을 의미하고, 기능지역은 통근권이나 생활권처럼 지역 간 기능적 상호작용에 의해 결속되는 영역을 의미한다(손승호, 2004a).

두 접근은 개념적으로 밀접하게 관련되어 있음에도, 활용하는 자료 구조의 차이로 인해 오랫동안 분리되어 왔다. 등질지역 연구는 주로 개별 공간 단위의 사회·경제적 속성 데이터를 활용하는 반면(신정엽, 2007; 송민경·장훈, 2010), 기능지역 연구는 공간 단위 쌍 사이의 흐름을 나타내는 OD 데이터를 활용한다(이상일, 2012; 제갈영, 2013; 이재건·이건학, 2022). 이처럼 두 접근은 주성분분석, 요인분석, 군집분석 등 유사한 분석 기법을 공유하면서도(손승호, 2004b; 신정엽, 2007; 송민경·장훈, 2010; 제갈영, 2013), 분석 단위와 데이터 차원의 불일치로 인해 통합적 지역화 연구로 발전하는 데 한계가 있었다. 그러나 실제 지역 구조는 등질성과 기능성 중 어느 하나만으로 설명되기 어렵다. 지역의 사회·경제적 속성과 공간적 상호작용은 상호의존적 관계를 이루며(손승호, 2004b; 한국도시지리학회, 2020), 지역 구조를 구성하는 하위 지역 역시 등질지역과 기능지역이 혼재된 형태로 나타난다(남영우, 2015). 또한 공간적 상호작용은 출발지와 도착지의 지역 특성과 밀접하게 관련되며, 이는 중력 모형과 배출-흡인 요인 모형에서도 확인된다(이소영 등, 2023; Zipf, 1946; Lee, 1966; Roy and Thill, 2004). 따라서 지역 구조를 종합적으로 이해하기 위해서는 지역 속성과 공간적 상호작용을 함께 고려하는 통합적 지역화 접근이 필요하다.

등질지역과 기능지역은 지역 구조의 서로 다른 측면을 강조하지만, 실제 대도시권의 공간 구조에서는 두 측면이 분리되어 작동하지 않는다. 지역의 인구 구성, 산업 구조, 주거 형태, 지가, 교통 접근성과 같은 속성은 특정 지역이 어떤 지역과 강하게 연결되는가에 영향을 미치며, 반복적인 이동 관계는 다시 지역의 중심성, 주변성, 생활권적 결속성을 드러낸다. 따라서 지역화에서 중요한 것은 속성 자료와 흐름 자료를 병렬적으로 비교하는 것이 아니라, 지역 속

성과 지역 간 관계가 결합되어 형성하는 지역 구조를 함께 파악하는 것이다. 그래프 모형은 공간 단위를 노드로, 지역 간 상호작용을 엣지로 표현함으로써 속성적 유사성과 관계적 결속성을 동일한 구조 안에서 학습할 수 있다는 점에서 본 연구의 목적에 적합하다. 본 연구에서 인구 이동 자료를 사용한 것은 통근만으로 포착하기 어려운 주거 이동과 생활권 재편의 효과를 반영하기 위한 것이며, 수도권의 지역 구조가 단순한 직장-주거 통행 관계를 넘어 주거 선택, 신도시 개발, 도서·접경 지역의 이동 제약과도 관련된다는 점을 고려한 것이다.

이러한 통합적 지역화 접근을 구현하기 위해서는 지역의 사회·경제적 속성과 지역 간 공간적 상호작용을 동일한 분석 틀 안에서 함께 학습할 수 있는 방법이 필요하다. 그래프 트랜스포머는 노드 특성과 엣지 특성을 동시에 반영하고, 다변량 엣지 속성을 어텐션 계산에 활용할 수 있다는 점에서 이러한 요구에 부합한다. 그러나 그래프 트랜스포머를 지역화 연구에 직접 적용한 사례는 국내외적으로 아직 매우 제한적이다. 특히 지리적 그래프에서 노드 특성, 다변량 엣지 특성, 위치 정보를 통합적으로 학습하고, 이를 연결성 제약 클러스터링과 결합하여 공간적으로 연속된 지역 구획을 도출하는 접근은 충분히 축적되어 있지 않다.

따라서 본 논문의 주된 연구 목적은 그래프 트랜스포머 기반 표현학습과 연결성 제약 클러스터링을 결합하여, 지역의 사회·경제적 속성과 공간적 상호작용을 동시에 반영하는 통합적 지역화 프레임워크를 제안하는 데 있다. 이를 위해 공간 단위를 노드로, 지역 간 인구 이동을 엣지로 설정한 지리적 그래프를 구축하고, 그래프 트랜스포머 인코더를 통해 각 공간 단위의 지역 표현 벡터를 생성한다. 이 과정에서 정답 레이블이 없는 상황에서도 그래프의 구조적 패턴을 학습할 수 있도록 딥 그래프 인포맥스(Deep Graph Infomax, DGI) 기반 자기지도 학습을 결합한다(Veličković *et al.*, 2018). 이후 생성된 지역 표현 벡터를 SKATER 알고리즘에 투입하여 공간적 연결성을 만족하는 지역화를 수행한다(Assunção *et al.*, 2006). 이때 그래프 트랜스포머는 등질지역 연구에서 중시해 온 지역 속성과 기능지역 연구에서 중시해 온 공간적 상호작용을 하나의 지역 표현 벡터로 통합하고, 연결성 제약 클러스터링은 이 벡터를 바탕으로 지리적으로 타당한 지역 구획을 산출한다.

본 연구는 제안한 프레임워크를 수도권 지역화에 적용한다. 수도권은 우리나라의 인구, 경제, 주거, 교통 기능이 집중한 핵심 대도시권인 동시에, 서울 중심부, 신도시, 외곽

농촌지역, 산업지역, 도서지역 등 다양한 하위 지역 구조가 공존하는 공간이다. 본 연구는 2020년 수도권 읍면동을 분석 단위로 설정하고, 인구, 경제활동, 주거, 교통 관련 변수를 노드 특성으로, 읍면동 간 인구 이동을 엣지 특성으로 활용한다. 이를 통해 그래프 트랜스포머 기반 지역 표현학습이 수도권의 다차원적 지역 구조를 어떻게 포착하는지 살펴보고자 한다.

2. 그래프 트랜스포머 기반 표현학습과 연결성 제약 클러스터링을 결합한 통합적 지역화 프레임워크

본 장에서는 그래프 트랜스포머 기반 표현학습과 연결성 제약 클러스터링을 결합한 통합적 지역화 프레임워크를 제시한다. 제안된 프레임워크는 먼저 공간 단위를 노드로, 지역 간 인구 이동을 엣지로 하는 지리적 그래프를 구성하고, 그래프 트랜스포머를 이용하여 각 공간 단위의 사회·경제적 속성, 공간적 상호작용, 그래프 구조 및 지리적 위치를 통합한 지역 표현 벡터를 생성한다. 이후 생성된 지역 표현 벡터 간 비유사도를 바탕으로 SKATER 알고리즘을 적용하여 공간적으로 연결한 지역을 도출하고, 전역적 자족도와 SCSPA 기반 응집도·분리도 평가를 통해 유효한 클러스터 수를 결정한다. 따라서 본 프레임워크는 등질지역 연구에서 중시한 속성적 유사성과 기능지역 연구에서 중시한 관계적 유사성을 통합하면서, 지역화 결과의 공간적 연속성을 동시에 보장하는 절차로 구성된다. 이러한 구성은 그래프 기반 표현학습과 연결성 제약 지역화를 연결한다는 점에서 본 연구의 방법론적 차별성을 이룬다.

1) 그래프 트랜스포머 기반 표현학습

(1) 지역 표현학습과 그래프 트랜스포머

표현학습은 원 데이터를 잠재 공간의 벡터로 변환하여 데이터의 중요한 특징과 구조를 포착하는 학습 방법이다(Bengio *et al.*, 2013). 그래프 자료구조에 적용되는 표현학습은 그래프의 구조적 정보를 보존하면서 노드, 엣지 또는 전체 그래프를 임베딩 벡터로 변환하는 과정으로 이해할 수 있다(Chen *et al.*, 2020). 본 연구에서 지역 표현학습은

공간 단위를 노드로 하는 지리적 그래프의 노드 임베딩 과정이다. 즉, 각 지역의 사회·경제적 속성과 지역 간 공간적 상호작용을 함께 고려하여 개별 지역을 고차원 지역 표현 벡터로 변환하는 것이다. 이렇게 생성된 지역 표현 벡터는 지역의 속성적 유사성과 관계적 유사성을 동시에 반영하며, 이후 연결성 제약 클러스터링의 입력값으로 사용된다.

본 연구는 지역 표현학습을 위해 Dwivedi and Bresson (2020)이 제안한 그래프 트랜스포머(Graph Transformer)를 활용한다(그림 1). 그래프 트랜스포머는 트랜스포머의 셀프-어텐션 메커니즘을 그래프 구조 데이터에 맞게 변형한 모형으로, 노드 간 관계의 중요도를 동적으로 학습한다. 기존의 GCN(Graph Convolution Network)은 이웃 노드의 정보를 집계할 때 고정된 가중 구조에 의존하고(Kipf and Welling, 2016), GAT(Graph Attention Network)는 이웃 노드의 중요도를 동적으로 학습할 수 있으나 엣지 속성을 충분히 반영하지 못한다는 한계를 가진다(Veličković *et al.*, 2017). 또한 Region2Vec은 공간적 상호작용을 엣지 가중치로 활용한다는 점에서 진전된 방법이지만, 엣지 정보를 단변량 가중치로 처리한다는 제약이 있다(Liang *et al.*, 2022; 2025).

그림 1은 본 연구에서 사용한 그래프 트랜스포머의 기본 구조를 보여준다. 다만 본 연구는 이 기본 구조를 그대로 적용한 것이 아니라, 지리적 그래프의 특성을 반영하기 위해 엣지 특성 행렬, 쿼리방식의 공간 연결 행렬, 중심점 경위도와 좌표를 결합한 포지셔널 인코딩을 추가하였다. 이러한 확장 구조는 다음 절에서 구체적으로 설명한다. 이러한 확장은 지리적 그래프에서 특히 중요하다. 이상일·김현미(2021)는 연령대별 전입·전출 플로우 분석을 통해 전연령 합산 자료에서는 드러나지 않는 생애주기별 인구이동 패턴을 도출하였고, Kim and Lee(2025) 역시 연령 특수적 MEI(Migration Effectiveness Index)를 통해 전연령 MEI에서 상쇄되는 인구이동 구조의 변화를 포착하였다. 이는 공간적 상호작용을 단변량 엣지 가중치로 환원하기보다 다변량 엣지 속성으로 처리할 필요가 있음을 보여준다. 이에 비해 그래프 트랜스포머는 노드 특성과 엣지 특성을 동시에 학습할 수 있으며, 특히 다변량 엣지 속성을 어텐션 계산에 반영할 수 있다는 점에서 지역화 연구에 적합하다.

(2) 입력 자료와 포지셔널 인코딩

본 연구에서 지리적 그래프는 다음과 같이 구성된다. 공간 단위 i 는 노드로, 지역 i 와 지역 j 사이의 인구 이동은 엣지로 정의된다. 노드 특성 벡터는 $\alpha_i \in \mathbb{R}^{d_\alpha}$, 엣지 특성 벡터




그림 1. 그래프 트랜스포머의 기본 아키텍처
출처: Dwivedi and Bresson(2020)을 재구성함.

는 $\beta_{ij} \in \mathbb{R}^{d_e}$ 로 나타낸다. 여기서 노드 특성은 지역의 인구, 경제, 주거, 교통 관련 속성을 포함하고, 엣지 특성은 지역 간 인구 이동의 규모와 유형을 포함한다. 이와 더불어 각 노드의 그래프 내 위치와 실제 지리적 위치를 반영하기 위해 포지셔널 인코딩 벡터 $\lambda_i \in \mathbb{R}^{d_{PE}}$ 를 구성한다.

이때 포지셔널 인코딩은 그래프 트랜스포머가 노드의 위치 정보를 학습할 수 있도록 하는 핵심 장치이다. 본 연구에서는 그래프 라플라시안 고유벡터를 활용한 포지셔널 인코딩에 기초하되(Dwivedi and Bresson, 2020; Kreuzer *et al.*, 2021), 복수의 위치 정보를 결합하는 방식을 적용하였다(Rampášek *et al.*, 2022). 특히 포지셔널 인코딩의 입력 자료로 엣지 특성 행렬, 쿼인 방식의 이항 연결 행렬, 지역 중심점의 경위도 좌표를 함께 사용하였다. 엣지 특성 행렬은 인구 이동에 기반한 그래프의 위상적 구조를 반영하고, 이항 연결 행렬은 공간 단위 사이의 실제 연결 관계를 반영하며, 중심점 경위도 좌표는 현실 세계에서의 지리적 위치를 반영한다. 따라서 이 세 자료를 결합한 포지셔널 인코딩은 기능적 관계, 공간적 인접성, 절대적 지리 위치를 함께 고려한 지역 위치 표현으로 이해할 수 있으며, 전통적인 지리학의 핵심 개념인 사이트와 시추에이션을 그래프 표현학습의 맥락에서 통합적으로 반영하려는 시도로 볼 수 있다.

구체적으로는 엣지 특성 행렬과 이항 연결 행렬로부터

각각 그래프 라플라시안 고유벡터를 계산하고, 이 두 고유벡터 집합과 중심점 경위도 좌표를 레이어 정규화를 통해 분포가 유사하도록 변환하였다. 이후 각 입력을 다층 퍼셉트론(Multilayer Perceptron, MLP) 층에 통과시킨 뒤 결합하여 d_{PE} 차원의 포지셔널 인코딩 벡터 λ_i 를 생성하였다. 이 과정은 그래프의 구조적 위치와 실제 지리적 위치를 동시에 반영함으로써, 일반적인 그래프 트랜스포머를 지리적 그래프 분석에 맞게 조정하는 역할을 한다.

(3) 엣지 특성을 반영한 그래프 트랜스포머 인코더

그래프 트랜스포머의 입력으로 사용하기 위해 노드 특성, 엣지 특성, 포지셔널 인코딩은 공통 임베딩 차원 d 로 변환된다. 노드 특성 벡터 α_i , 엣지 특성 벡터 β_{ij} , 포지셔널 인코딩 벡터 λ_i 은 각각 다음과 같이 선형 변환된다.

$$\hat{\mathbf{h}}_i^0 = \mathbf{A}^0 \alpha_i + \mathbf{a}^0 \quad \text{식 (1)}$$

$$\mathbf{e}_{ij}^0 = \mathbf{B}^0 \beta_{ij} + \mathbf{b}^0 \quad \text{식 (2)}$$

$$\lambda_i^0 = \mathbf{C}^0 \lambda_i + \mathbf{c}^0 \quad \text{식 (3)}$$

여기서 $\hat{\mathbf{h}}_i^0$ 는 선형 변환된 초기 노드 표현, $\mathbf{e}_{ij}^0$ 는 초기 엣지

표현, λ_i^0 는 변환된 포지셔널 인코딩이다. $\mathbf{A}^0, \mathbf{B}^0, \mathbf{C}^0$ 는 각각 노드 특성, 엣지 특성, 포지셔널 인코딩을 공통 임베딩 차원 d 로 변환하기 위한 가중치 행렬이며 $\mathbf{a}^0, \mathbf{b}^0, \mathbf{c}^0$ 는 이에 대응하는 편향 벡터이다. 이 선형 변환은 서로 다른 차원을 갖는 입력 자료를 그래프 트랜스포머에서 함께 처리할 수 있도록 동일한 임베딩 공간으로 사상하는 과정이다.

이후 변환된 포지셔널 인코딩은 초기 노드 표현에 더해져 최종적인 초기 노드 임베딩을 구성한다.

$$\mathbf{h}_i^0 = \mathbf{h}_i^0 + \lambda_i^0 \quad \text{식 (4)}$$

따라서 초기 노드 임베딩 $\mathbf{h}_i^0$ 는 지역의 속성 정보와 위치 정보를 함께 포함한다. 이와 같이 포지셔널 인코딩을 노드 표현에 더함으로써, 그래프의 위상적 구조와 현실 세계의 지리적 위치가 이후 그래프 트랜스포머의 어텐션 계산 과정에 반영될 수 있다.

그래프 트랜스포머의 핵심은 엣지 특성을 고려한 셀프-어텐션이다. 각 레이어 l 과 헤드 k 에서 노드 표현 $\mathbf{h}_i^l$ 는 쿼리, 키, 밸류 벡터로 선형 변환된다. 일반 트랜스포머에서는 쿼리와 키의 내적을 바탕으로 어텐션 점수를 계산하지만, 본 연구에서 사용한 그래프 트랜스포머는 여기에 엣지 표현 $\mathbf{e}_{ij}^l$ 을 함께 반영한다. 어텐션 점수는 다음과 같이 계산된다.

$$s_{ij}^{k,l} = \left(\frac{\mathbf{Q}^{k,l} \mathbf{h}_i^l \cdot \mathbf{K}^{k,l} \mathbf{h}_j^l}{\sqrt{d_k}} \right) \cdot \mathbf{E}^{k,l} \mathbf{e}_{ij}^l \quad \text{식 (5)}$$

$$w_{ij}^{k,l} = \text{softmax}_j(s_{ij}^{k,l}) \quad \text{식 (6)}$$

여기서 $\mathbf{Q}^{k,l}$ 과 $\mathbf{K}^{k,l}$ 는 각각 레이어 l 과 헤드 k 에서 사용되는 쿼리와 키 투영 행렬이다. $\mathbf{E}^{k,l}$ 는 엣지 표현 $\mathbf{e}_{ij}^l$ 를 어텐션 계산에 반영하기 위한 엣지 투영 행렬이다. d_k 는 각 헤드의 차원으로, 전체 임베딩 차원 d 와 헤드 수 H 에 대해 $d_k = d/H$ 로 정의된다. 마지막으로 $w_{ij}^{k,l}$ 는 노드 i 가 노드 j 로부터 정보를 받을 때의 정규화된 어텐션 가중치이다. 이 식의 핵심은 노드 간 중요도가 노드 특성만으로 결정되는 것이 아니라, 두 노드 사이의 엣지 특성에 의해 조정된다는 점이다. 따라서 인구 이동과 같은 공간적 상호작용은 단순한 사후 해석 변수가 아니라, 지역 표현 벡터를 학습하는 과정에 직접 반영된다.

각 헤드에서 계산된 이웃 노드의 밸류 벡터는 어텐션 가중치에 따라 집계되고, 여러 헤드의 결과는 결합되어 새로운 노드 표현을 형성한다.

$$\mathbf{h}_i^{(\text{attn})} = \mathbf{O}_h^l \parallel_{k=1}^H \left(\sum_{j \in N_i} w_{ij}^{k,l} \mathbf{V}^{k,l} \mathbf{h}_j^l \right) \quad \text{식 (7)}$$

여기서 $\mathbf{V}^{k,l}$ 는 레이어 l 과 헤드 k 에서 사용되는 밸류 투영 행렬이고, $\mathbf{O}_h^l$ 은 여러 헤드에서 계산된 노드 표현을 결합한 뒤 다시 공통 임베딩 차원으로 변환하는 출력 투영 행렬이다. H 는 어텐션 헤드의 수, $\parallel$ 는 벡터 결합을 의미한다. 멀티-헤드 어텐션은 서로 다른 투영 공간에서 노드 간 관계를 학습하므로, 단일 어텐션보다 다양한 관계 패턴을 포착할 수 있다. 이후 노드 표현과 엣지 표현은 잔차 연결, 레이어 정규화, 피드-포워드 네트워크를 거쳐 다음 레이어의 입력으로 갱신된다. 최종적으로 마지막 레이어에서 산출된 노드 표현 $\mathbf{h}_i$ 가 지역 i 의 지역 표현 벡터가 된다.

(4) DGI 기반 자기지도 학습과 하이퍼 파라미터 설정

지역화 문제에서는 정답 레이블이 존재하지 않기 때문에 본 연구는 그래프 트랜스포머 인코더를 딥 그래프 인포맥스(Deep Graph Infomax, DGI)와 결합하여 자기지도 학습을 수행한다(Veličković *et al.*, 2018). DGI는 원 그래프에서 생성된 노드 임베딩과 그래프 전체의 요약 벡터 사이의 상호 정보량을 최대화하도록 학습하는 대조적 자기지도 학습 방법이다. 본 연구에서는 그래프 트랜스포머 인코더를 통해 원 그래프의 노드 임베딩 $\mathbf{H}$ 를 생성하고, 모든 노드 임베딩의 평균에 비선형 변환을 적용하여 그래프 요약 벡터 $\mathbf{s}$ 를 계산한다.

$$\mathbf{s} = \sigma \left(\frac{1}{N} \sum_{i=1}^N \mathbf{h}_i \right) \quad \text{식 (8)}$$

이후 원 그래프에서 생성된 노드 임베딩과 요약 벡터의 쌍은 긍정 쌍으로, 노드 특성 행렬을 행 단위로 셔플하여 만든 변형 그래프의 노드 임베딩과 요약 벡터의 쌍은 부정 쌍으로 간주된다. 판별자는 두 쌍이 동일한 그래프 구조에서 나온 것인지 구분하도록 학습되며, 이 과정에서 그래프 트랜스포머 인코더는 지역의 속성, 공간적 상호작용, 그래프 전체 구조를 반영하는 지역 표현 벡터를 생성한다.

그래프 트랜스포머 모형의 주요 하이퍼 파라미터는 임베

딩 차원 수, 어텐션 헤드 수, 멀티-헤드 어텐션 블록 수이다. 지역화 문제에서는 참값 레이블이 존재하지 않기 때문에 정확도나 평균제곱오차와 같은 일반적인 지도학습 성능 지표를 사용할 수 없다. 이에 본 연구는 동일한 하이퍼 파라미터 조합에서 여러 랜덤 시드로 생성된 지역화 결과가 얼마나 일관되게 나타나는지를 기준으로 모형을 선택하였다. 이를 위해 임베딩 차원 수는 [16, 32, 64, 128], 헤드 수는 [1, 2, 4], 멀티-헤드 어텐션 블록 수는 [1, 3]으로 설정하고, 총 24개 조합에 대해 그리드 서치를 수행하였다. 각 조합별로 세 개의 랜덤 시드를 사용하여 지역 표현 벡터를 생성하고, 이를 SKATER 알고리즘에 투입하여 $k=20$ 의 지역화 결과를 산출하였다. 이후 동일 조합에서 생성된 세 개의 지역화 결과 사이의 일관성을 ARI와 NMI로 평가하고, 두 지표의 순위를 종합하여 최종 하이퍼 파라미터를 결정하였다. 그 결과 임베딩 차원 수 128, 헤드 수 1, 멀티-헤드 어텐션 블록 수 1, 에포크 수 50을 최종 설정으로 사용하였다.

이상의 절차를 통해 본 연구의 그래프 트랜스포머 기반 표현학습은 개별 지역의 사회·경제적 속성, 지역 간 인구 이동 관계, 그리고 그래프 구조 및 지리적 위치 정보를 하나의 지역 표현 벡터로 통합한다. 이 벡터는 등질지역 연구에서 중시한 속성적 유사성과 기능지역 연구에서 중시한 관계적 유사성을 함께 반영하며, 다음 절에서 설명하는 연결성 제약 클러스터링의 입력 자료로 사용된다. 다만 이러한 하이퍼 파라미터 설정은 예측 정확도를 극대화하기 위한 지도학습적 최적화가 아니라, 정답 레이블이 없는 지역화 문제에서 안정적인 지역화 결과를 산출하기 위한 제한적 탐색으로 이해할 필요가 있다. 에포크 수 50과 임베딩 차원 수 128은 여러 랜덤 시드 간 지역화 결과의 일관성을 기준으로 선택된 경험적 설정이다. 다만 고차원 임베딩에서 거리 집중 문제가 발생할 가능성을 완전히 배제할 수 없으므로, 향후 연구에서는 에포크 수와 임베딩 차원에 대한 체계적인 민감도 분석이 필요하다.

2) 연결성 제약 클러스터링

(1) SKATER 알고리즘

지역화는 공간 단위들을 속성적으로 유사한 집단으로 묶는다는 점에서 클러스터링의 한 유형으로 볼 수 있다. 그러나 일반적인 클러스터링과 달리 지역화에서는 클러스터 내부의 유사성뿐만 아니라 공간적 연속성이 함께 요구된다. 즉, 하나의 지역으로 묶인 공간 단위들은 서로 공간적으로

연결되어 있어야 하며, 이러한 연결성 제약은 지역화 결과의 지리적 타당성을 보장하는 핵심 조건이다(Guo, 2009). 지역화를 위한 연결성 제약 클러스터링 알고리즘은 다양하게 개발되어 왔다. 대표적인 방법으로는 AZP(Openshaw, 1977), SKATER(Assunção *et al.*, 2006), REDCAP(Guo, 2008), Max-p 지역(Duque *et al.*, 2012) 등이 존재한다. 본 연구에서는 그래프 트랜스포머 기반 표현학습을 통해 생성된 지역 표현 벡터를 일반 클러스터링에 직접 투입하지 않고, 연결성 제약을 명시적으로 반영하는 SKATER(Spatial 'K'luster Analysis by Tree Edge Removal) 알고리즘을 적용하였다. SKATER는 클러스터 수가 많거나 지역 간 구분이 모호한 상황에서도 우수한 성능을 유지하면서도 계산 복잡도가 크지 않아 넓은 연구 범위에도 적용 가능하다고 판단하였기 때문이다(Aydin *et al.*, 2018; 2021). 또한 지역화 문제에서 종종 발생하는 사슬 효과(chaining effect)로부터 상대적으로 강건하여 클러스터링 결과의 현실 적용성이 높다는 점도 SKATER를 선택하는 데 영향을 주었다(Lattimer and Lattimer, 2022).

SKATER는 최소 신장 트리(Minimum Spanning Tree, MST)의 엣지를 제거함으로써 공간적으로 연속된 클러스터를 생성하는 지역화 알고리즘이다(Assunção *et al.*, 2006). SKATER는 공간 단위 간 연결 관계를 엣지로, 공간 단위 간 비유사도를 엣지 가중치로 설정한 뒤, 연결성을 유지하는 방식으로 연구 지역을 여러 하위 지역으로 분할한다. 본 연구에서 공간 단위 간 비유사도는 원자료의 개별 변수에서 직접 계산하지 않고, 그래프 트랜스포머 기반 표현학습을 통해 생성된 지역 표현 벡터 사이의 거리로 정의한다. 지역 i 와 지역 j 의 m 차원 지역 표현 벡터를 각각 $\mathbf{x}_i, \mathbf{x}_j$ 라고 하면, 두 공간 단위 사이의 비유사도는 다음의 유클리드 거리로 계산된다.

$$d(i, j) = d(\mathbf{x}_i, \mathbf{x}_j) = \left[\sum_{l=1}^m (x_{il} - x_{jl})^2 \right]^{1/2} \quad \text{식 (9)}$$

여기서 x_{il} 과 x_{jl} 은 각각 지역 i 와 지역 j 의 지역 표현 벡터에서 l 번째 성분을 의미한다. 이 거리는 지역의 사회·경제적 속성, 공간적 상호작용, 그래프 구조, 지리적 위치 정보가 통합된 잠재 공간에서의 거리이다. 따라서 SKATER에 투입되는 비유사도는 단순한 속성 차이나 이동량 차이가 아니라, 그래프 트랜스포머가 학습한 통합적 지역 표현의 차이를 의미한다.

SKATER는 이 비유사도를 엣지 가중치로 사용하여 MST를 구성한 뒤, 클러스터 내 편차 제곱합을 가장 크게 줄이는 엣지를 순차적으로 제거함으로써 사전에 지정한 수의 연결 클러스터를 생성한다. 이처럼 SKATER는 지역 표현 벡터 공간에서의 응집성을 높이면서도, 공간 연결 구조를 이용해 지역화 결과의 연속성을 유지한다. 본 연구에서 그래프 트랜스포머는 “무엇이 유사한 지역인가”를 학습하고, SKATER는 “그 유사성을 바탕으로 어떻게 공간적으로 연결된 지역을 구성할 것인가”를 결정하는 역할을 담당한다.

(2) 유효 클러스터 결정

SKATER 알고리즘은 사전에 클러스터 수 k 를 지정해야 한다. 그러나 지역화 연구에서 적절한 k 를 결정하는 것은 단순한 기술적 문제가 아니라, 도출된 지역 구조의 해석 가능성과 직접적으로 관련된다. k 가 지나치게 작으면 이질적인 공간 단위들이 하나의 지역으로 묶여 클러스터의 성질을 만족하지 못하고, 반대로 k 가 지나치게 크면 유사한 공간 단위들이 강제로 분할되어 지역 구조를 제대로 포착하기 어렵다. 따라서 본 연구에서는 임의의 k 를 고정하지 않고, 클러스터링 품질을 평가하는 지표들을 종합적으로 고려하여 유효한 클러스터 수를 결정하였다. 클러스터 유효성을 평가할 때 핵심적으로 고려되는 기준은 클러스터 내부의 응집도(compactness)와 클러스터 간 분리도(separation)이다. 우수한 클러스터링 결과는 응집도와 분리도가 모두 높게 나타나야 한다(Halkidi *et al.*, 2001). 이에 본 연구는 먼저 자족도(self-containment)를 통해 유효한 k 의 후보를 제한하고, 이후 Chen *et al.*(2024)이 제안한 지역화 문제의 클러스터 수 결정 방법을 활용하여 응집도와 분리도를 동시에 평가하였다.

자족도는 클러스터의 내적 응집성을 평가하는 지표로, 전역적 자족도와 국지적 자족도로 구분된다. 전역적 자족도는 최종 클러스터링 결과에서 총 이동 가운데 클러스터 내부 이동이 차지하는 비중을 의미하며(제갈영, 2013), 지역화 결과가 기능지역적 관점에서 어느 정도 내부 결속성을 갖는지를 보여준다. 국지적 자족도는 개별 클러스터의 적절성을 평가하는 지표로, 공급-측면 자족도와 수요-측면 자족도로 나뉜다(이상일 등, 2012; 이상일·이소영, 2021). 본 연구에서는 클러스터 수 후보를 결정하기 위한 기준으로 전역적 자족도를 사용하였다.

기존 연구에서는 유의한 클러스터링의 전역적 자족도 기준을 대체로 60~70% 수준으로 보아왔다(이상일 등, 2012).

그러나 본 연구의 SKATER 입력 자료는 인구 이동 OD 행렬 자체가 아니라, 사회·경제적 속성과 인구 이동 정보를 함께 학습한 그래프 트랜스포머 기반 지역 표현 벡터이다. 따라서 인구 이동 자료만을 사용한 기능지역화 연구와 동일한 기준을 적용하기보다는, 전역적 자족도 50% 이상을 유효한 클러스터 수 후보의 최소 기준으로 설정하였다.

다음으로, 전역적 자족도 기준을 만족하는 k 후보에 대해 SCSA(Spatially Constrained Statistical Approach) 기반 클러스터 유효성 평가를 수행하였다. SCSA는 지역화 문제에서 적절한 클러스터 수를 설정하기 위해 Chen *et al.*(2024)이 제안한 방법으로, 클러스터 내부 응집도와 클러스터 간 분리도를 동시에 고려한다. 본 연구에서는 각 클러스터 수에 대해 응집도와 분리도를 0과 1 사이의 값으로 계산하고, 두 값이 모두 1인 이상점 (1, 1)과의 유클리드 거리를 산출하였다. 이 거리가 작을수록 응집도와 분리도가 균형 있게 높은 지역화 결과로 판단하였다.

따라서 본 연구의 유효 클러스터 결정 절차는 두 단계로 요약된다. 첫째, 전역적 자족도를 통해 기능지역적 내부 결속성을 일정 수준 이상 확보한 k 후보를 선별한다. 둘째, 이 후보들에 대해 SCSA 기반 응집도와 분리도를 계산하고, 이상점 (1, 1)과의 거리가 작은 결과를 중심으로 유효한 클러스터 수를 선정한다. 이러한 절차는 지역 속성과 공간적 상호작용을 함께 학습한 지역 표현 벡터의 특성에 부합하며, 기능지역적 타당성과 클러스터링의 구조적 품질을 동시에 고려한다는 점에서 본 연구의 통합적 지역화 프레임워크와 연결된다.

3. 수도권 지역화 연구

1) 연구 지역과 입력 데이터

본 연구의 분석 대상은 서울특별시, 인천광역시, 경기도로 구성된 수도권이다. 수도권은 우리나라 인구와 경제활동이 가장 집중된 대도시권이자, 서울을 중심으로 한 통근, 통학, 주거 이동, 산업 입지 변화가 복합적으로 전개되는 지역이다. 따라서 수도권은 행정구역 경계를 넘어서는 기능적 연계와 지역 간 분화가 동시에 나타나는 대표적인 지역화 연구 대상이라고 할 수 있다. 본 연구는 2020년 행정구역 체계를 기준으로 수도권의 읍면동을 공간 단위로 설정하

였으며, 섬 지역을 제외하지 않고 수도권 전체를 분석 대상으로 포함하였다. 최종 분석에 사용된 공간 단위는 총 1,125개이다.¹⁾

본 연구의 입력 데이터는 그래프 트랜스포머 기반 표현 학습에 사용되는 노드 특성 행렬과 엣지 특성 행렬, 그리고 SKATER 알고리즘의 연결성 제약을 구성하기 위한 공간 연결 행렬로 구분된다. 수도권 인구 이동 그래프에서 노드는 개별 읍면동이며, 엣지는 읍면동 간 인구 이동으로 정의된다. 따라서 노드 특성 행렬은 각 읍면동의 사회·경제적 속성을 나타내고, 엣지 특성 행렬은 읍면동 사이의 인구 이동 관계를 나타낸다. 두 행렬을 구성하는 자료의 기준 시점은 모두 2020년이다.

노드 특성 행렬은 총 45개 변수로 구성하였다(표 1). 이들 변수는 수도권 내 지역 분화를 설명하는 핵심 차원으로 판단되는 인구, 경제활동, 주거, 교통 조건을 포괄하도록 선정하였다. 즉, 인구 구성과 이동 특성, 경제적 중심성, 주거 구조, 시설 접근성의 차이를 통해 각 읍면동의 등질지역적 특성을 표현하고자 하였다. 인구 관련 변수에는 총 인구수, 5세 단위 연령대별 인구 비율, 중위연령, 성비, 외국인 비율, 가구 규모별 비율, 인구이동 유효도 지수(Migration Effec-

tiveness Index, MEI)가 포함된다. 이 가운데 MEI는 순이동을 총이동으로 나눈 값에 100을 곱한 지표로, 지역 인구 이동의 편향성의 정도를 나타낸다(이상일·이소영, 2023; Plane, 1984). 경제활동 관련 변수는 산업별 사업체 수 비율, 총 사업체 수, 총 종사자 수로 구성하였으며, 세 변수 모두 국가데이터처의 2020년 경제총조사 데이터를 통해 구득하거나 계산하였다²⁾. 주거 관련 변수는 주택 유형, 점유 형태, 건축 연한, 개별공시지가 등을 포함하였다. 교통 관련 변수는 교육시설, 의료시설, 판매시설, 광역교통시설에 대한 대중교통 및 도로 접근시간을 사용하였다.³⁾

엣지 특성 행렬은 국가데이터처 마이크로데이터 통합서비스(MDIS)의 2020년 국내인구이동통계를 이용하여 구축하였다. 엣지 특성은 읍면동 간 총 이동 수와 성별 전입·전출 인구수로 구성하였다. 일반적인 인구 이동 분석에서는 출발지와 도착지 사이의 이동량을 OD 행렬로 표현하는 경우가 많지만, 본 연구에서는 엣지에 복수의 속성을 부여하기 위해 다이어덕 행렬을 사용하였다(이상일·김현미, 2021). 이는 그래프 트랜스포머가 단순한 이동량 가중치가 아니라, 성별 전입·전출 구조를 포함한 다변량 엣지 특성을 학습할 수 있도록 하기 위한 것이다. 또한 인구 이동은

표 1. 노드 특성 행렬 변수

주제	범주	변수(45개)	출처
인구	총 인구수	지역 내 총 인구수	국가데이터처 2020 인구총조사
	연령대별 인구 비율	0-84세는 5세 단위 구분(17개), 85세 이상은 집계하여 사용	
	중위연령	지역의 중위연령	
	성비	지역의 성비	
	외국인 비율	지역의 외국인 비율	
	가구 규모별 비율	1인 가구 비율, 2인 가구 비율, 3인 이상 가구 비율	
	인구이동 유효도 지수 (MEI)	순이동 / 총이동 × 100	국가데이터처 MDIS 국내인구이동통계
경제 활동	산업체별 사업체 수 비율	1차 산업군 비율, 2차 산업군 비율, 3차 산업군 비율, 4차 산업군 비율, 교육 산업 비율, 의료 및 복지 산업군 비율, 문화 및 여가 산업군 비율	국가데이터처 2020년 경제총조사
	총 사업체 수	지역의 총 사업체 수	
	총 종사자 수	지역의 총 종사자 수	
주거	주거 형태별 비율	아파트 비율, 단독주택 비율, 공동주택 비율	국가데이터처 2020년 주택총조사
	지가지수	2019년 대비 2020년 지가 지수	한국부동산원
	개별공시지가	상하위 10% 제외 면적 가중 평균 공시지가	국토교통부
교통	시설별 교통접근성 지표	교육시설, 의료시설, 판매시설, 광역교통시설 대중교통 및 도로 일평균 접근시간	한국교통연구원




그림 2. 지역 표현 벡터에 기반한 수도권 읍면동의 MST

행정동 경계를 넘어서는 거주지 변화로 정의되는 것이 타당하므로, 행정동 내부 이동은 분석에서 제외하였다(이상일·조대현, 2024).

공간 연결 행렬은 SKATER 알고리즘에서 지역화 결과의 공간적 연속성을 보장하기 위해 사용된다. 본 연구에서는 기본적으로 쿼인 방식의 이항 연결 행렬을 구성하였다. 쿼인 방식은 두 공간 단위가 경계선 또는 꼭짓점을 공유할 경우 연결한 것으로 간주하는 방식으로, 읍면동 단위의 불규칙한 공간 단위 간 인접 관계를 포괄적으로 반영할 수 있다. 다만 수도권에는 강화도, 영종도, 대부도 등 섬 또는 반도적 성격을 갖는 공간 단위가 포함되어 있으며, 이들을 단순한 평면상의 경계 접촉 여부만으로 처리할 경우 실제 이동 가능성과 불일치하는 문제가 발생할 수 있다. 기존 수도권 지역화 연구에서는 섬 지역을 연구 대상에서 제외하는 경우가 많았지만(구형모, 2010; 이몽현, 2012; 제갈영, 2012), 이는 섬 지역과 본토 사이의 공간적 상호작용을 분석에서 제거함으로써 수도권 지역 구조를 온전히 파악하기 어렵게 만든다. 따라서 본 연구는 섬 지역을 분석 대상에 포함하고, 교량 또는 항로를 통해 실제 이동이 가능한 경우 두 지역이 연결한 것으로 간주하여 연결성을 보정하였다.

이상의 입력 데이터 구성은 본 연구의 통합적 지역화 프레임워크와 직접적으로 연결된다. 노드 특성 행렬은 각 읍

면동의 속성적 유사성을, 엣지 특성 행렬은 읍면동 간 기능적 연결을, 공간 연결 행렬은 지역화 결과의 지리적 연속성을 반영한다. 따라서 본 연구의 입력 데이터는 등질지역적 속성과 기능지역적 관계를 동시에 학습하고, 그 결과를 공간적으로 연결한 지역 구획으로 전환하기 위한 기초 자료로 활용된다. 그래프 트랜스포머를 통해 산출된 각 읍면동의 지역 표현 벡터는 이후 SKATER 알고리즘에서 공간 단위 간 차이를 계산하는 기준으로 사용된다. 본 연구는 이 벡터 간 거리에 기반하여 최소 신장 트리를 구성하였으며, 이는 공간적으로 연속된 지역 구획을 도출하기 위한 기본 구조가 된다. 그림 2는 지역 표현 벡터에 기반해 구성된 수도권 읍면동의 MST를 보여준다. 그림 2는 특정 클러스터 수에서 분할된 지역화 결과가 아니라, SKATER 알고리즘에서 엣지 제거가 이루어지기 전의 전체 최소 신장 트리이다. 즉, 1,125개 읍면동을 모두 연결하되 지역 표현 벡터 간 유클리드 거리의 총합이 최소가 되도록 구성된 트리 골격을 의미한다. 이후 SKATER는 이 MST에서 엣지를 순차적으로 제거하여 사전에 지정된 수의 연결 클러스터를 생성한다.

2) 클러스터 유효도 평가

본 연구에서는 그래프 트랜스포머 기반 표현학습을 통해

생성된 지역 표현 벡터를 SKATER 알고리즘에 투입하여 $k=2$ 부터 $k=50$ 까지 지역화 결과를 산출하였다. 클러스터 수 k 가 달라지면 지역화 결과의 공간적 스케일과 해석 가능성이 달라지므로, 본 절에서는 전역적 자족도와 SCSA 기반 응집도·분리도 평가를 통해 유효한 클러스터 수를 검토한다. 전역적 자족도는 전체 이동 가운데 클러스터 내부 이동이 차지하는 비중을 나타내며, 지역화 결과의 기능지역적 내부 결속성을 평가하는 기준으로 사용된다(제갈영, 2013). 또한 본 연구는 클러스터 내부의 응집도와 클러스터 간 분리도를 동시에 고려하기 위해 Chen *et al.*(2024)의 SCSA를 적용하였다.

먼저 전역적 자족도를 이용하여 유효한 클러스터 수의 후보를 제한하였다. 기존 기능지역화 연구에서는 유의한 지역화 결과의 전역적 자족도 기준을 대체로 60~70% 수준으로 설정해 왔다(이상일 등, 2012). 그러나 이러한 기준은 주로 인구 이동 OD 자료 자체를 사용한 지역화 연구에서 제시된 것이다(이상일 등, 2012; 제갈영, 2013; 김을식 등, 2015). 본 연구에서 SKATER의 입력 자료는 인구 이동 OD 행렬이 아니라, 사회·경제적 속성과 인구 이동 관계를 함께 학습한 지역 표현 벡터이다. 따라서 기존 기준을 그대로 적용하기보다는 전역적 자족도 50% 이상을 유효 클러스터 수 후보의 최소 기준으로 설정하였다. 이는 인구 이동의 기

능적 결속성을 일정 수준 이상 확보하면서도, 속성적 유사성까지 함께 반영한 지역화 결과를 평가하기 위한 절충적 기준이다.

본 연구는 전역적 자족도 계산에 앞서 그래프 트랜스포머의 포지셔널 인코딩 구성 단계에서 공간 연결 정보를 반영하는 방식에 따른 차이를 검토하였다. 구체적으로 동일한 쿼리방식의 공간 연결 구조를 바탕으로 이항 연결 행렬과 행 표준화 연결 행렬을 각각 포지셔널 인코딩 입력으로 사용하고, 하나의 클러스터에 포함되는 최소 행정동 수 제약을 0, 2, 5, 10으로 달리하여 전역적 자족도의 변화를 비교하였다. 다만 SKATER 단계에서 공간적 연속성을 보장하기 위해 사용한 허용 경로는 두 경우 모두 동일한 쿼리방식의 연결 구조에 기반한다. 따라서 그림 3에 나타난 전역적 자족도의 차이는 SKATER의 연결 제약 자체가 달라졌기 때문이 아니라, 그래프 트랜스포머 표현학습 단계에서 공간 연결 정보가 서로 다르게 인코딩되었기 때문으로 해석된다. 그 결과 이항 연결 행렬을 사용한 경우가 행 표준화 연결 행렬을 사용한 경우보다 전반적으로 높은 전역적 자족도를 보였으며, 최소 행정동 수 제약을 부여하지 않은 경우의 결과가 가장 우수하였다. 이에 따라 이후 분석에서는 이항 연결 행렬을 사용하고 최소 행정동 수 제약을 부여하지 않은 지역화 결과를 기준으로 삼았다. 이 조건에서 전역적 자족도




그림 3. 클러스터 개수별 전역적 자족도

50% 이상을 만족하는 클러스터 수는 $k=2$ 부터 $k=34$ 까지로 나타났다.

다음으로, 전역적 자족도 기준을 만족하는 $k=2$ 부터 $k=34$ 까지의 후보에 대해 SCSA 기반 유효도 평가를 수행하였다(그림 4). SCSA는 각 클러스터링 결과의 응집도와 분리도를 0과 1 사이의 값으로 산출한 뒤, 이상점 (1, 1)과의 거리를 계산한다. 따라서 이상점과의 거리가 작을수록 응집도와 분리도가 균형 있게 높은 지역화 결과로 판단할 수 있다. 분석 결과, SCSA 기반 이상점과의 거리가 가장 낮은 클러스터 수는 $k=2$ 로 나타났다.

그러나 본 연구에서는 $k=2$ 를 최종 지역화 결과의 후보에서 제외하였다. 이는 $k=2$ 가 정량적 유효도 지표상 우수한 값을 보이더라도, 본 연구의 분석 목적에 부합하는 해석 가능한 지역화 결과로 보기 어렵기 때문이다. 본 연구의 목적은 수도권 전체를 소수의 거대 권역으로 양분하는 데 있는 것이 아니라, 수도권 내부에서 나타나는 하위 지역 구조와 공간적 분화를 탐색하는 데 있다. $k=2$ 의 결과는 수도권을 매우 거시적인 두 권역으로 나누기 때문에, 서울 중심부와 주변부, 인천·경기 서부, 경기 남부, 경기 북부 및 동부 등 수도권 내부의 다핵적이고 이질적인 지역 구조를 충분히 포착하기 어렵다.

또한 SCSA 기반 이상점과의 거리는 클러스터 내부의 응

집도와 클러스터 간 분리도의 균형을 평가하는 지표이지만, 그 최소값이 항상 연구 목적상 가장 적절한 클러스터 수를 의미하는 것은 아니다. 특히 클러스터 수가 매우 작을 경우, 전체 연구 지역이 거대한 몇 개의 권역으로 통합되면서 지표상 안정적인 값이 산출될 수 있으나, 이는 지역 구조의 세부적 해상도와 해석 가능성을 보장하지 않는다. 지역화 결과는 정량적 유효도뿐 아니라 지리적 의미와 선행 연구와의 비교 가능성을 함께 고려하여 판단할 필요가 있다.

수도권 지역 구조에 관한 기존 연구들 역시 수도권 내부에 복수의 하위 권역이 존재함을 전제로 지역화를 수행해 왔다. 구형모(2010), 이상일 등(2012), 제갈영(2013), 손승호(2014) 등은 분석 자료와 방법은 다르지만, 수도권을 단순한 이분 구조가 아니라 복수의 하위 기능권 또는 생활권으로 구분하였다. 따라서 $k=2$ 는 수도권이 큰 스케일에서 강한 기능적 결속성을 갖는다는 점을 보여주는 참고 결과로는 의미가 있지만, 수도권 내부의 지역적 분화와 하위 권역 구조를 해석하기 위한 최종 분석 대상으로는 부적절하다.

$k=2$ 를 제외하면, SCSA 기반 이상점과의 거리가 상대적으로 낮아지는 지점은 $k=8$, $k=13$, $k=20$ 에서 확인된다(그림 4). 구체적으로 이상점과의 거리는 $k=8$ 에서 0.387, $k=13$ 에서 0.389, $k=20$ 에서 0.392로 나타났다. 세 값의 차이는 크지 않지만, 각 k 는 서로 다른 공간 해상도의 지역




그림 4. 클러스터 개수별 SCSA 기반 이상점과의 거리

구조를 보여준다. $k=8$ 은 수도권권을 비교적 큰 권역 단위로 구분하여 광역적 구조를 파악하는 데 유용하고, $k=13$ 은 광역적 구조와 중간 규모의 하위 지역 구분 사이에서 절충적인 결과를 제시한다. 반면 $k=20$ 은 수도권 내부의 다양한 하위 지역 구조를 비교적 세밀하게 드러내면서도, k 가 20을 넘어가는 구간에서 나타나는 과도한 분할 이전의 결과로 볼 수 있다.

이상의 결과는 클러스터 수 결정이 단일 지표의 기계적 최적화만으로 이루어지기 어렵다는 점을 보여준다. 전역적 자족도는 인구 이동의 내부 결속성을 평가하는 데 유용하지만, k 가 작을수록 높아지는 경향이 있어 지역 내부 구조를 충분히 드러내지 못할 수 있다. 반면 SCSS 기반 평가는 응집도와 분리도를 동시에 고려한다는 장점이 있지만, 수치상 최적점이 반드시 연구 목적에 부합하는 해석 가능한 지역 구분을 의미하는 것은 아니다. 따라서 본 연구에서는 유효도 지표의 정량적 결과와 함께 수도권 지역 구조에 관한 선행 연구, 지도화된 지역화 결과의 해석 가능성, 그리고 연구 목적에 적합한 공간 해상도를 종합적으로 고려할 필요가 있다. 이에 따라 본 절에서는 $k=2$ 를 제외하고, 전역적 자족도 기준을 충족하면서 SCSS 기반 이상점과의 거리가 상대적으로 낮게 나타난 $k=8, k=13, k=20$ 을 주요

후보로 선정하였다. 다음 절에서는 이 세 클러스터 수에 따른 지역화 결과를 각각 검토하고, 수도권 지역 구조의 공간적 스케일과 해석 가능성을 비교한다.

3) 지역화 결과와 해석

본 절에서는 선정된 세 가지 지역화 결과를 지도화하여 비교하고, 수도권 지역 구조가 공간적 스케일에 따라 어떻게 다르게 드러나는지를 해석한다.

먼저 $k=8$ 의 지역화 결과는 수도권의 거시적 하위 권역을 파악하는 데 유용하다(그림 5). $k=8$ 일 때 SCSS 기반 이상점과의 거리는 0.387로 $k=2$ 를 제외한 후보 중 가장 낮게 나타났으며, 전역적 자족도는 74.3%로 산출되었다. 이 결과에서는 $k=2$ 에서 분리되었던 경기 동부 외곽 지역이 별도의 권역으로 유지되는 가운데, 나머지 수도권 대부분이 경기 북동부, 강화도 인근 지역, 경기 남부, 인천 및 경기 중서부, 강남 업무지구, 경기 남동부 등으로 분화된다. 전체적으로는 비교적 큰 면적과 인구 규모를 갖는 권역들이 형성되지만, 강남 업무지구는 예외적으로 작은 면적에도 불구하고 독립적인 지역으로 탐지된다. 해당 권역은 15개




그림 5. $k=8$ 지역화 결과

읍면동, 약 25.5km², 약 37.9만 명 규모로, 다른 권역에 비해 면적은 매우 작지만 초기 분할 단계부터 별도로 구분된다. 이는 강남 업무지구가 주변 지역과 구별되는 사회·경제적 속성과 내부 이동 관계를 가질 가능성을 보여준다. 실제로 해당 권역은 사업체 및 종사자 규모, 지가, 교통 접근성 등 업무 중심지와 관련된 입력 변수에서 두드러지는 특성을 보이며, 이러한 속성적 차이가 인구 이동 관계와 결합되어 독립적인 권역으로 포착된 것으로 해석할 수 있다. 즉, $k=8$ 결과는 수도권의 큰 권역 구조를 보여주는 동시에, 강남 업무지구와 같이 기능적·속성적 특성이 강하게 응축된 핵심 지역이 지역화 과정에서 조기에 분리될 수 있음을 확인시켜 준다.

$k=13$ 의 지역화 결과는 $k=8$ 에서 확인된 거시적 권역을 보다 중간 규모의 하위 지역으로 세분화한다(그림 6). 이때 SCSPA 기반 이상점과의 거리는 0.389로 $k=8$ 과 거의 차이가 없으며, 전역적 자족도는 66.6%로 나타난다. 전역적 자족도는 클러스터 수가 증가할수록 낮아지는 경향이 있으므로, 이는 자연스러운 변화로 볼 수 있다. $k=13$ 에서 새롭게 주목되는 점은 $k=8$ 결과에서 큰 권역으로 묶였던 지역들이 분리되면서, 수도권 주변부와 신도시권의 구조가 더 뚜렷하게 드러난다는 것이다. 북한 연접 지역, 서해 중부

도서 지역, 서울 남부 신도시 지역, 경기도 남서부 지역이 인천 및 경기 중서부 지역으로부터 분리되어 각각 독립적인 하위 권역으로 포착된다. 또한 광주·이천 일대가 서울 권역으로부터 분리되어 독자적인 지역을 형성한다. 이 결과는 수도권이 단순히 서울을 중심으로 동심원적으로 확장된 구조라기보다, 외곽부의 접경성, 도서성, 신도시 개발, 남부 산업·주거권의 성장 등이 복합적으로 작용하는 다핵적 구조임을 보여준다.

$k=13$ 결과에서 특히 중요한 점은 두 개의 대규모 권역이 여전히 높은 내부 결속성을 보인다는 것이다. 가장 큰 권역(클러스터 1번)은 462개 읍면동, 약 1,447km², 약 1,038만 명 규모로 형성되며, 공급 측면 자족도와 수요 측면 자족도는 각각 75.8%와 74.0%로 높게 나타난다. 또 다른 대규모 권역(클러스터 6번)도 300개 읍면동, 약 1,530km², 약 768만 명 규모로 형성되며, 공급 측면과 수요 측면 자족도가 각각 71.7%와 71.5%로 나타난다. 이는 $k=13$ 수준에서도 수도권 내부에 대규모 기능적 결속권이 유지되고 있음을 의미한다. 반면 북한 연접 지역, 서해 도서 지역 등은 인구 규모와 자족도가 상대적으로 낮지만, 공간적 위치와 물리적 단절성, 제한된 연결 구조 때문에 독립적인 지역으로 포착된다. 따라서 $k=13$ 은 수도권의 대규모 기능권과 주변부 특




그림 6. $k=13$ 지역화 결과

수지역을 동시에 보여주는 중간 해상도의 지역화 결과로 해석할 수 있다.

$k=20$ 의 지역화 결과는 세 후보 가운데 가장 세밀한 수도권 지역 구조를 제시한다(그림 7). 이때 SCSA 기반 이상 점과의 거리는 0.392이고, 전역적 자족도는 54.2%로 계산된다. 이는 전역적 자족도 기준을 충족하면서도 지역을 가장 세분화한 결과이다. $k=20$ 에서는 기존의 광역 권역이 더 작은 하위 권역으로 나뉘면서 서울 내부 구조, 신도시권, 도서지역, 경기 외곽부의 차이가 보다 선명하게 드러난다. 특히 서울이 세 개의 권역으로 분할된 점이 두드러진다. 이전 단계까지 서울은 대체로 강남권과 비강남권으로 구분되었으나, $k=20$ 에서는 비강남권이 다시 한강 이남 및 북서부 지역과 북동부 지역으로 분리된다. 이는 서울 내부에서도 사회·경제적 속성의 차이와 이동 관계의 차이가 함께 작동하고 있음을 보여준다. 특히 한강 이북 지역이 동서로 구분되는 것은 두 지역 사이의 사회·경제적 이질성뿐 아니라, 북한산과 같은 물리적 장벽이 지역 간 상호작용을 제약하는 효과를 간접적으로 반영한 결과로 해석할 수 있다.

$k=20$ 의 결과에서 또 하나 주목할 점은 동탄이 독립적인 지역으로 등장한다는 것이다. 동탄은 2기 신도시 개발을 통해 성장한 대표적인 수도권 남부 신도시로, $k=20$ 결과

에서는 서울이나 주변 도시권에 완전히 종속되지 않고 별도의 권역으로 구분된다. 이는 동탄 일대가 주변 지역과 구별되는 신도시형 주거·인구 구조와 이동 관계를 보였기 때문으로 해석할 수 있다. 다만 이러한 결과를 곧바로 완전한 자족 중심지의 형성으로 단정하기보다는, 수도권 남부 신도시권의 분화 가능성을 보여주는 결과로 이해하는 것이 적절하다. 기존 연구에서도 동탄과 같은 신도시 지역의 성장과 자족성 형성 가능성이 논의되어 왔다는 점에서, 이 결과는 수도권 남부의 신도시 기반 지역 구조 변화를 반영하는 것으로 볼 수 있다(윤택림, 2017; 손승호, 2018).

또한 $k=20$ 에서는 서해 북단의 연평도, 백령도, 대청도, 소청도 등이 별도의 클러스터로 포착된다. 이들 도서지역은 물리적 거리와 접근성 측면에서 본토와 뚜렷이 구분되지만, 기존 수도권 지역화 연구에서는 분석 대상에서 제외되는 경우가 많았다. 본 연구는 이들 섬 지역을 분석 대상에 포함하고, 항로 등을 고려하여 연결성을 보정함으로써 수도권 주변부의 도서적 지역 구조를 함께 드러냈다. 다만 이 클러스터에는 해로를 통해 연결성이 부여된 인천광역시 중구 연안동도 함께 포함된다. 이는 서해 북단 도서지역의 연결 후보가 제한적이기 때문에, 연결된 항만 지역의 정보가 강하게 반영된 결과로 해석할 수 있다.




그림 7. $k=20$ 지역화 결과

세 결과를 종합하면 $k=8$, $k=13$, $k=20$ 은 각각 수도권 지역 구조를 광역, 중간, 세부 스케일에서 보여주는 다중 해상도의 지역화 결과로 해석할 수 있다. 따라서 이들은 상호 대체적인 단일 최적해라기보다, 유사한 유효도 수준에서 수도권의 다층적 지역 구조를 드러내는 후보 결과로 이해하는 것이 적절하다. 이러한 결과는 그래프 트랜스포머 기반 지역 표현학습과 SKATER 알고리즘을 결합한 본 연구의 접근이 수도권의 등질지역적 속성과 기능지역적 관계를 동시에 반영할 수 있음을 보여준다. 강남 업무지구의 조기 분리, 신도시권의 독립적 포착, 도서 및 접경 지역의 분화는 단순한 사회·경제적 속성만으로도, 또는 인구 이동 OD 행렬만으로도 충분히 설명되기 어렵다. 본 연구의 지역화 결과는 노드 특성으로 표현되는 지역 속성, 엣지 특성으로 표현되는 인구 이동 관계, 포지셔널 인코딩을 통해 반영된 지리적 위치 및 연결 구조가 결합된 결과이다. 따라서 수도권 지역 구조는 단일한 최적 클러스터 수로 환원되기보다, 공간적 스케일에 따라 다르게 드러나는 다층적 구조로 이해하는 것이 적절하다.

지역화 결과의 해석은 학습된 잠재 벡터의 개별 차원을 직접 해석한 것이 아니라, 모형 입력에 사용된 사회·경제적 변수와 인구 이동 관계, 그리고 선행 연구에서 확인된 수도권 지역 구조를 종합적으로 고려하여 이루어졌다. 예를 들어 강남 업무지구는 사업체 및 종사자 규모, 지가, 교통 접근성 등 업무 중심지와 관련된 변수에서 주변 지역과 구별되는 특성을 보이며, 동탄 일대는 신도시형 주거 구조와 수도권 남부의 이동 관계 속에서 독립적인 권역으로 해석될 수 있다. 따라서 본 연구의 결과 해석은 잠재 벡터의 블랙박스 산출물을 사후적으로 명명한 것이라기보다, 입력 변수의 지역별 특성과 기능적 결속성을 함께 고려한 지리적 해석으로 이해할 필요가 있다.

한편, 본 연구의 접근이 사회·경제적 속성에 기반한 공간 제약 군집분석을 수행한 뒤 자족도를 사후적으로 평가하는 방식과 어떻게 다른지 확인하기 위해, 노드 특성 행렬만을 SKATER에 직접 투입한 결과와 비교하였다. 그 결과 북한 접경 지역, 서해 도서 지역, 경기 남동부 농촌 지역 등은 두 방법에서 모두 비교적 안정적으로 포착되었다. 이는 이들 지역이 사회·경제적 속성만으로도 주변 지역과 구분되는 특성을 지님을 의미한다. 그러나 그래프 트랜스포머 기반 지역화에서는 강남 업무지구가 초기 단계부터 독립적으로 분리되고, $k=20$ 에서 서울 내부 구조와 동탄의 독립성이 보다 뚜렷하게 나타났다. 또한 그래프 트랜스포머 기

반 결과는 사회·경제적 속성 기반 결과에 비해 지역 간 읍면동 수와 인구 규모의 불균형이 작고, 공급 및 수요 측면의 국지적 자족도 평균도 더 높게 나타났다. 이는 그래프 트랜스포머가 사회·경제적 속성뿐 아니라 지역 간 인구 이동 관계와 그래프 구조를 함께 학습함으로써, 등질지역적 유사성과 기능지역적 결속성을 동시에 반영한 지역화를 수행했음을 보여준다.

4. 결론

본 연구는 지역화 연구에서 오랫동안 분리되어 다루어져 온 등질지역 접근과 기능지역 접근을 통합하기 위해, 그래프 트랜스포머 기반 표현학습과 연결성 제약 클러스터링을 결합한 지역화 프레임워크를 제안하였다. 이를 위해 수도권의 1,125개 읍면동을 노드로, 읍면동 간 인구 이동을 엣지로 하는 지리적 그래프를 구성하고, 노드 특성, 엣지 특성, 포지셔널 인코딩을 함께 활용하여 각 지역의 표현 벡터를 학습하였다. 이후 학습된 지역 표현 벡터를 SKATER 알고리즘에 투입하여 공간적 연결성을 만족하는 지역화 결과를 도출하였다.

수도권을 대상으로 한 분석 결과, 그래프 트랜스포머 기반 지역화는 수도권의 지역 구조를 단일한 최적 구획으로 환원하기보다, 공간적 스케일에 따라 다르게 드러나는 다층적 구조로 포착하였다. 8개 권역 수준에서는 수도권의 광역적 하위 권역과 강남 업무지구의 독립성이 확인되었고, 13개 권역 수준에서는 북한 연결 지역, 서해 도서 지역, 서울 남부 신도시 지역, 경기도 남서부 지역 등 중간 규모의 하위 권역이 분화되었다. 20개 권역 수준에서는 서울 내부의 세 분화, 동탄의 독립성, 서해 북한 도서지역의 특수성이 보다 뚜렷하게 나타났다. 또한 사회·경제적 속성만을 사용한 지역화 결과와 비교할 때, 그래프 트랜스포머 기반 지역화는 지역 간 규모 불균형을 완화하고 국지적 자족도를 높이는 경향을 보였다. 이는 제안된 방법이 지역의 속성적 유사성과 기능적 결속성을 동시에 반영할 수 있음을 보여준다.

본 연구의 의의는 세 가지로 정리할 수 있다. 첫째, 사회·경제적 속성을 노드 특성으로, 인구 이동 관계를 엣지 특성으로 표현함으로써 등질지역과 기능지역을 하나의 지리적 그래프 안에서 함께 다룰 수 있는 가능성을 제시하였다. 둘째, 그래프 트랜스포머와 DGI 기반 자기지도 학습을 결합

하여, 레이블이 없는 지역화 문제에서도 지역의 속성, 관계, 위치 정보를 통합한 지역 표현 벡터를 생성할 수 있음을 보였다. 셋째, 학습된 지역 표현 벡터를 SKATER와 결합함으로써, 딥러닝 기반 표현학습의 유연성과 연결성 제약 지역화의 지리적 타당성을 함께 확보하였다.

다만 본 연구에는 몇 가지 한계가 있다. 첫째, 옛지 특성으로 사용한 인구 이동 자료는 주민등록상 거주지 이동에 기반하므로, 통근·통학이나 유동인구 자료가 포착하는 일상적 통행 관계와는 차이가 있다. 따라서 본 연구의 기능적 연계성은 생활권이나 통근권 자체가 아니라, 지역 간 주거 이동과 정착 관계를 통해 드러나는 기능적 관계로 이해할 필요가 있다. 향후 연구에서는 통근·통학, 생활이동, 유동인구 자료와의 비교가 필요하다. 둘째, 2020년 한 시점의 자료를 사용하였기 때문에 수도권 지역 구조의 시간적 변화와 안정성을 검토하는 데에는 한계가 있다. 셋째, 그래프 트랜스포머 기반 표현학습은 지역 속성과 관계를 통합적으로 반영할 수 있지만, 학습된 잠재 벡터의 개별 차원이 갖는 지리적 의미를 직접 해석하는 데에는 제약이 있다. 따라서 본 연구의 지역화 결과는 잠재 벡터 자체의 직접 해석이라기보다, 입력 변수의 공간적 분포, 인구 이동에 기반한 자족도 지표, 선행 연구에서 확인된 수도권 지역 구조를 종합적으로 연결한 해석으로 이해될 필요가 있다.

그럼에도 본 연구는 지역을 고정된 행정구역이나 단일 속성의 집합으로 보지 않고, 속성, 관계, 위치가 결합된 다층적 구조로 파악할 수 있음을 보여주었다. 그래프 트랜스포머 기반 표현학습과 연결성 제약 클러스터링을 결합한 본 연구의 프레임워크는 향후 생활권 분석, 대도시권 공간구조 연구, 권역 설정, 행정구역 재검토 등에 활용될 수 있는 GeoAI 기반 지역화 방법론의 한 사례가 될 수 있다.

주

- 1) 그래프를 구성하는 데이터의 기준 시점이 2020년이므로 행정구역 체계 역시 2020년을 기준으로 하였다. 다만 민간인 통계구역에 해당하는 경기도 파주시 장단면, 진서면, 진동면은 자료 공개의 한계와 행정구역 통합 이력을 고려하여 군내면과 합쳐하였고, 경기도 광주시 쌍령동과 탄벌동은 2020년 12월 분동 이전의 행정구역 체계를 사용하였다.
- 2) 산업별 사업체 수 비율에서 사용한 산업 분류는 한국표준사업분류를 바탕으로 성격이 유사한 산업끼리 모아 총 7개로 재범주화 하였다. 1차 산업군에는 농업, 임업 및 어업(A)과

광업(B)이, 2차 산업군에는 제조업(C)과 건설업(F)이, 3차 산업군에는 도매 및 소매업(G), 금융 및 보험업(K), 부동산업(L)이, 4차 산업군에는 정보통신업(J), 전문, 과학 및 기술 서비스업(M)이, 교육 산업에는 교육 서비스업(P)이, 의료 및 복지 산업군에는 보건업 및 사회복지 서비스업(Q)이, 문화 및 여가 산업군에는 숙박 및 음식점업(I)과 예술, 서비스 및 여가관련 서비스업(R)이 포함된다.

- 3) 개별공시지가는 국토교통부의 2020년 8월 13일 기준 필지별 자료를 행정동 단위로 집계하여 사용하였다. 필지별 단위면적당 가격은 면적 가중 평균으로 산출하였으며, 이상치의 영향을 줄이기 위해 상위 10% 값을 제외하였다. 교통 접근성 변수는 한국교통연구원의 시설편 교통접근성 지표를 사용하였고, 결국값은 해당 지표의 최대값으로 대체하였다.

참고문헌

- 강영욱, 2023, “GeoAI 활용 분야와 연구 동향,” *대한지리학회지*, 58(4), 395-418.
- 구형모, 2010, *Delineating Spatially Constrained Commuting Zones with an Improved Measurement for Functional Regionalization*, 서울대학교 석사학위논문.
- 김을식·최석현·조무상, 2015, “기능지역(functional area) 개념을 활용한 지역고용 정책권역 설정에 관한 연구-수도권 지역을 중심으로,” *한국거버넌스학회보*, 22(3), 189-215.
- 남영우, 2015, *도시공간구조론*, 제2판, 법문사, 서울.
- 손승호, 2004a, *사회·경제적 속성과 공간상호작용으로 본 서울시의 지역구조*, 고려대학교 박사학위논문.
- 손승호, 2004b, “서울시 등질지역과 기능지역의 구조 분석,” *대한지리학회지*, 39(4), 562-584.
- 손승호, 2014, “서울대도시권 인구가동장의 사회·경제적 속성,” *한국도시지리학회지*, 17(1), 125-138.
- 손승호, 2018, “신도시 개발에 따른 화성시의 사회·경제적 공간재구조화,” *대한지리학회지*, 53(6), 847-862.
- 송민경·장훈, 2010, “군집분석을 이용한 수도권 도시의 유형화에 관한 연구,” *대한공간정보학회지*, 18(1), 83-88.
- 신정엽, 2007, “도시내부구조의 생태적 접근방법과 도시지역 선정 연구의 재조명,” *지리교육논집*, 51, 27-41.
- 윤택림, 2017, “신도시의 지역성을 찾아서: 동탄 신도시 사례 연구,” *구술사연구*, 8(1), 11-57.
- 이몽현, 2012, *Multivariate Spatial Cluster Analysis Using Mahalanobis Distance*, 서울대학교 석사학위논문.

- 이상일, 2012, “공간적 상호작용론의 본질과 연구 영역: 인문 지리학에 대한 통섭적 접근,” 한국지리학회지, 1(1), 137-151.
- 이상일·김감영·제갈영, 2012, “지오컴퓨테이션 접근에 의한 주택시장지역의 설정: 우리나라 수도권에의 적용,” 한국도시지리학회지, 15(3), 59-75.
- 이상일·김현미, 2021, “인구이동 플로의 연령-특수적 패턴 분석을 위한 방법론 연구-우리나라 시군구 단위 인구이동에의 적용,” 대한지리학회지, 56(5), 537-550.
- 이상일·이몽현, 2020, “무작위합역 절차의 다양성에 대한 시뮬레이션 연구,” 한국지도학회지, 20(3), 93-107.
- 이상일·이소영, 2021, “인구이동 플로의 지리적 시각화를 위한 개념적 명료화: 우리나라 2020년 인구이동에 대한 주제도 제작,” 한국지도학회지, 21(3), 23-42.
- 이상일·이소영, 2023, “인구이동이 인구재분포에 미치는 영향력의 시공간적 역동성 탐색: 우리나라 국내 인구이동에의 적용,” 한국지도학회지, 23(1), 1-19.
- 이상일·조대현, 2024, “우리나라 인구이동 데이터의 다양성과 상호보완성에 관한 연구-주민등록과 등록센서스 데이터의 비교를 중심으로,” 대한지리학회지, 59(4), 487-504.
- 이소영·배민철·주희선, 2023, “모바일 생활 통행데이터를 활용한 일간 인구이동 패턴 및 영향요인 분석: 경상남도의 직장인구와 방문인구 비교를 중심으로,” *Journal of Korea Planning Association*, 58(2), 5-21.
- 이재건·이건학, 2022, “코로나 19에 따른 도시 내 인구 이동 변화 탐색-서울시 생활이동 데이터에 기반한 통근 패턴을 중심으로,” 한국도시지리학회지, 25(2), 15-32.
- 전혜민, 2025, 그래프 트랜스포머 기반 표현학습과 연결성 제약 클러스터링을 활용한 수도권 지역화 연구, 서울대학교 석사학위논문.
- 제갈영, 2012, *Delineating Housing Market Areas in the Seoul Metropolitan Area Using a Geo-computational Approach*, 서울대학교 석사학위논문.
- 제갈영, 2013, “지오컴퓨테이션 접근에 기반한 수도권의 주택시장지역 설정,” 한국지리학회지, 2(1), 7-20.
- 한국도시지리학회, 2020, 도시지리학개론, 법문사, 서울.
- Alastal, A. I. and Shaqfa, A. H., 2022, GeoAI technologies and their application areas in urban planning and development: Concepts, opportunities and challenges in smart city (Kuwait, study case), *Journal of Data Analysis and Information Processing*, 10(2), 110-126.
- Aydin, O., Janikas, M. V., Assunção, R. and Lee, T.-H., 2018, SKATER-CON: Unsupervised regionalization via stochastic tree partitioning within a consensus framework using random spanning trees, *Proceedings of the 2nd ACM SIGSPATIAL International Workshop on AI for Geographic Knowledge Discovery*, Seattle, November 6, 33-42.
- Aydin, O., Janikas, M. V., Assunção, R. M. and Lee, T.-H., 2021, A quantitative comparison of regionalization methods, *International Journal of Geographical Information Science*, 35(11), 2287-2315.
- Assunção, R. M., Neves, M. C., Câmara, G. and da Costa Freitas, C., 2006, Efficient regionalization techniques for socioeconomic geographical units using minimum spanning trees, *International Journal of Geographical Information Science*, 20(7), 797-811.
- Bahdanau, D., Cho, K. and Bengio, Y., 2014, Neural machine translation by jointly learning to align and translate, *arXiv Preprint*, arXiv:1409.0473.
- Bengio, Y., Courville, A. and Vincent, P., 2013, Representation learning: A review and new perspectives, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828.
- Chen, F., Wang, Y.-C., Wang, B. and Kuo, C.-C. J., 2020, Graph representation learning: A survey, *APSIPA Transactions on Signal and Information Processing*, 9, e15.
- Chen, Y., Liu, Q., Yang, J., Cheng, X. and Deng, M., 2024, Spatially constrained statistical approach for determining the optimal number of regions in regionalization, *International Journal of Geographical Information Science*, 38(10), 2108-2147.
- Duque, J. C., Anselin, L. and Rey, S. J., 2012, The max-pr regions problem, *Journal of Regional Science*, 52(3), 397-419.
- Duque, J. C., Ramos, R. and Suriñach, J., 2007, Supervised regionalization methods: A survey, *International Regional Science Review*, 30(3), 195-220.
- Dwivedi, V. P. and Bresson, X., 2020, A generalization of transformer networks to graphs, *arXiv Preprint*, arXiv:2012.09699.
- Grekousis, G., 2019, Artificial neural networks and deep

- learning in urban geography: A systematic review and meta-analysis, *Computers, Environment and Urban Systems*, 74, 244-256.
- Guo, D., 2008, Regionalization with dynamically constrained agglomerative clustering and partitioning (REDCAP), *International Journal of Geographical Information Science*, 22(7), 801-823.
- Guo, D., 2009, Flow mapping and multivariate visualization of large spatial interaction data, *IEEE Transactions on Visualization and Computer Graphics*, 15(6), 1041-1048.
- Halkidi, M., Batistakis, Y. and Vazirgiannis, M., 2001, On clustering validation techniques, *Journal of Intelligent Information Systems*, 17, 107-145.
- Huang, X., Wang, S., Wilson, J. and Kedron, P. (eds.), 2025, *GeoAI and Human Geography: The Dawn of a New Spatial Intelligence Era*, Springer, Cham.
- Kim, S. and Lee, S.-I., 2025, An extension of migration effectiveness indices: Accounting for the impact of migration on population structure, *Population, Space and Place*, 31(5), e70049.
- Kipf, T. N. and Welling, M., 2016, Semi-supervised classification with graph convolutional networks, *arXiv Preprint*, arXiv:1609.02907.
- Kreuzer, D., Beaini, D., Hamilton, W., Létourneau, V. and Tossou, P., 2021, Rethinking graph transformers with spectral attention, *Advances in Neural Information Processing Systems*, 34, 21618-21629.
- Lee, E. S., 1966, A theory of migration, *Demography*, 3, 47-57.
- Lattimer, B. and Lattimer, A., 2022, Creating compact regions of social determinants of health, *arXiv Preprint*, arXiv:2209.11836.
- Li, Y. and Moura, J. M., 2020, Forecaster: A graph transformer for forecasting spatial and time-dependent data, *ECAI 2020: 24th European Conference on Artificial Intelligence*, Santiago de Compostela, 29 August-8 September, 1293-1300.
- Liang, Y., Zhu, J., Ye, W. and Gao, S., 2022, Region2Vec: Community detection on spatial networks using graph embedding with node attributes and spatial interactions, *Proceedings of the 30th International Conference on Advances in Geographic Information Systems*, Seattle, November 1-4, 1-4.
- Liang, Y., Zhu, J., Ye, W. and Gao, S., 2025, GeoAI-enhanced community detection on spatial networks with graph deep learning, *Computers, Environment and Urban Systems*, 117, 102228.
- Mai, G., Janowicz, K., Hu, Y., Gao, S., Yan, B., Zhu, R., Cai, L. and Lao, N., 2022, A review of location encoding for GeoAI: methods and applications, *International Journal of Geographical Information Science*, 36(4), 639-673.
- Openshaw, S., 1977, A geographical solution to scale and aggregation problems in region-building, partitioning and spatial modelling, *Transactions of the Institute of British Geographers*, 2(4), 459-472.
- Plane, D. A., 1984, A systemic demographic efficiency analysis of US interstate population exchange, 1935-1980, *Economic Geography*, 60(4), 294-312.
- Rampášek, L., Galkin, M., Dwivedi, V. P., Luu, A. T., Wolf, G. and Beaini, D., 2022, Recipe for a general, powerful, scalable graph transformer, *Advances in Neural Information Processing Systems*, 35, 14501-14515.
- Roy, J. R. and Thill, J., 2004, Spatial interaction modelling, *Papers in Regional Science*, 83(1), 339-361.
- Smith, T. R., 1984, Artificial intelligence and its applicability to geographical problem solving, *The Professional Geographer*, 36(2), 147-158.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. and Polosukhin, I., 2017, Attention is all you need, *Advances in Neural Information Processing Systems*, 30, 5998-6008.
- Veličković, P., Cucurull, G., Casanova, A., Romero, A., Lio, P. and Bengio, Y., 2017, Graph attention networks, *arXiv Preprint*, arXiv:1710.10903.
- Veličković, P., Fedus, W., Hamilton, W. L., Liò, P., Bengio, Y. and Hjelm, R. D., 2018, Deep graph infomax, *arXiv Preprint*, arXiv:1809.10341.
- Yang, X., Bo, S. and Wang, J., 2024, Classifying urban functional zones by integrating the homogeneity and structural similarity of POIs, *Journal of Urban Planning and Development*, 150(4), 04024052.
- Ye, X., Fang, S., Sun, F., Zhang, C. and Xiang, S., 2022, Meta graph transformer: A novel framework for spatial-temporal traffic prediction, *Neurocomputing*, 491,

544-563.

Zhang, Y., Zheng, X., Helbich, M., Chen, N. and Chen, Z.,
2022, City2vec: Urban knowledge discovery based
on population mobile network, *Sustainable Cities
and Society*; 85, 104000.

Zipf, G. K., 1946, The P1P2/D hypothesis: On the intercity
movement of persons, *American Sociological Review*,
11(6), 677-686.

교신: 이상일, 08826, 서울특별시 관악구 관악로 1, 서울대학교 사
범대학 지리교육과(이메일: si_lee@snu.ac.kr, 전화: 02-880-9028)

Correspondence: Sang-Il Lee, Department of Geography Education,
College of Education, Seoul National University, 1 Gwanak-ro,
Gwanak-gu, Seoul 08826, Republic of Korea (e-mail: si_lee@
snu.ac.kr, phone: +82-2-880-9028)

최초투고일 2026. 6. 2

수정일 2026. 6. 28

최종접수일 2026. 6. 29