

준지도 대조 학습 기법을 활용한 그래프 이상 탐지

Graph Anomaly Detection via Semi-supervised Contrastive Learning

김환(Hwan Kim)¹ 임성수(Sungsu Lim)²

요약

그래프 이상 탐지 연구는 다양한 도메인에서 많은 관심을 받고 있고, 최근에는 그래프 신경망(GNNs) 기반의 접근 방법들이 크고 복잡한 그래프를 효과적으로 처리하고 우수한 성능을 보여주었다. 비정상 데이터의 레이블링에 비용이 많이 들어가기 때문에 과거의 연구들은 주로 비지도 학습 기반의 방법들을 사용했다. 하지만 탐지된 비정상 노드는 원치 않거나 상관없는 노드일 수도 있다. 이러한 문제 해결을 위해 비정상 정보가 선행 지식으로 활용하는 준지도 학습 방법이 효과적일 것이다. 그러나 적은 양의 이상 정보를 효과적으로 활용하는 것은 준지도 학습의 주요 챌린지 중 하나이다. 본 논문에서는 이러한 이슈들을 해결하기 위해 대표 정상/비정상 특징을 고려하는 준지도 대조 학습 프레임워크 SAD-CL을 제안한다. SAD-CL은 정상과 비정상 정보의 대표패턴을 효과적으로 추출하여 학습하는 기존보다 강화된 대조 학습 기법으로 여러 실험을 통하여 우수한 그래프 이상탐지 성능을 입증하였다.

주제어: 그래프 이상 탐지, 준지도 학습, 대조 학습, 이상 노드 탐지.

¹ 충남대학교 컴퓨터공학과, 석박통합과정.

² 충남대학교 컴퓨터공학과, 부교수, 교신저자.

+ 이 논문은 2023년도 해양수산부 재원으로 해양수산과학기술진흥원의 지원을 받아 수행된 연구임 (20210650, 해양 디지털 항로표지 정보협력시스템 개발).

+ 논문접수: 2023년 11월 13일, 최종 심사완료: 2023년 12월 27일, 게재승인: 2023년 12월 27일.

Abstract

Graph anomaly detection has drawn significant attention in various domains. Moreover, recent approaches based on Graph Neural Networks (GNNs) have demonstrated superior performance in effectively handling large and complex graph data. Previous research mainly utilized unsupervised learning-based methods with a focus on normal samples, as labeling abnormal data can be time-consuming and costly. However, detected anomalous nodes may be unwanted or irrelevant. Leveraging semi-supervised learning with the use of abnormal information as prior knowledge can address this issue. Nevertheless, effectively utilizing a small amount of abnormal information remains a major challenge in semi-supervised learning. In this paper, to address these issues, we propose a semi-supervised contrastive learning framework, SAD-CL. SAD-CL not only effectively extracts representative patterns of normal information but also of abnormal information. Through various experiments, we demonstrate that the performance of SAD-CL in graph anomaly detection.

Keywords: Graph anomaly detection, Semi-supervised learning, Contrastive learning, Anomalous node detection.

1. 서론

그래프 이상 탐지는 주로 다수의 노드와 유의미하게 차이 나는 노드를 식별하는 것을 목표로 하며, 이는 사기 탐지 [1] 및 IoT 네트워크 침입 탐지 [2]와 같은 다양한 도메인 [3, 4]에서 큰 주목을 받고 있다. 초기 연구 [5, 6, 7]는 주로 도메인 지식 및 통계적 방법에 의존했다. 최근에는 심층 학습 접근 방식이 큰 규모의 고차원 데이터를 효과적으로 처리하고 데이터에서 패턴을 추출하여 수동 특성 제작의 부담 없이 만족스러운 성능을 달성할 수 있음이 입증되었다 [8, 9]. 그래프 신경망 (GNNs)은 더 최근에 메시지 전달 메커니즘을 통해 그래프 표현 학습에서 높은 표현 능력을 통해 이상을 효과적이고 직관적으로 탐지할 수 있도록 설계되었다 [10, 11]. GNNs의 메시지 전달 메커니즘은 모든 메시지를 동등하게 다루며, 상대적 중요성이나 관련성을 고려하지 않는다 [12]. 종종 특정 메시지나 인접한 노드가 더 가치 있는 정보를 운반할 수 있으므로, 이러한 중요한 메시지나 노드를 효과적으로 포착하는 것이 그래프 이상 탐지의 핵심일 수 있다 [13, 14].

기존 방법들은 그래프 이상 탐지를 위해 주로 정상 샘플에 더 집중하는 비지도 학습 기반의 연구들이 진행되었으며 [5, 10, 11, 15-18], 비정상 샘플을 라벨링 하는 것이 노동 집약적이며 특정 도메인 지식이 필요하기 때문이다. 유감스럽게도, 감지된 비정상은 노이즈나 우리가 관심 없는 데이터 사례로 나타날 수 있으며, 그 이유 중 하나는 비정상을 찾는 선형 지식이 부족하기 때문이다 [19, 20]. 선형 지식이나 비정상 인식 정보가 없으면, 비지도 학습 접근 방식에서 정확히 원하는 결과를 얻기가 효과적이지 않을 수 있다 [21].

준지도 학습은 제한적인 이상 정보를 사전지식으로 얼마나 효율적으로 활용하는지에 따라서 기존의 비지도 학습의 단점을 해결하는 하나의 방법이 될

수 있다 [22]. 하지만 적은 양의 이상 정보를 사전 지식으로 사용하는 것은 2가지 이유로 쉽지 않다:

(1) 대표 표현 샘플: 아주 적은 양의 레이블 정보만 존재하기 때문에 정확한 이상 패턴의 특징을 표현하기 어렵다 [20]. 실제 시나리오에서 조금의 이상 정보는 활용할 수 있으므로 적은 양의 정보를 가지고 높은 탐지 효율을 보이는 연구가 필요하다.

(2) 중요 표현 학습: 적은 양의 정상과 비정상 샘플 중에서 중요한 정상/비정상 표현 특징을 잡아내는 것은 주요 챌린지 중 하나이다 [23].

위 2가지 이슈와 기존의 비지도 대조 학습이 갖고 있던 준지도 학습에 비해 비효율적인 레이블 정보의 활용과 노이즈에 상대적으로 취약하다는 약점을 해결하기 위해서 대표 정상/비정상 특징을 고려하는 준지도 대조 학습 프레임워크를 제안한다. 구체적으로 제안하는 방법은 소수의 이상 정보를 효과적으로 활용하기 위해 대표적인 비정상/정상 특징을 선택하고 선택된 대표 특징들은 대조학습 기법과 같이 사용되어 같은 클래스의 특징들은 당기고 (Pull) 다른 클래스의 특징들은 밀어내면서 (Push) 학습되게 된다.

본 연구의 장점을 요약하면 다음과 같다.

- **효율적인 정상/비정상 정보의 활용:** 제안하는 방법은 정상/비정상 레이블에서 전체 정상/비정상 패턴을 대표할 수 있는 특징들을 효과적으로 추출하여 사용한다.
- **강화된 대조 학습 기법:** 기존의 정상 레이블에만 집중한 대조 학습 기법을 본 논문에서는 비정상 레이블도 같이 고려할 수 있는 강화된 대조 학습 기법을 제안한다.
- **그래프 이상 탐지 정확도 향상:** 제안하는 SAD-CL 프레임워크와 일련의 실험들을 통하여 그래프에서의 이상 노드 탐지 성능의 향상을 입증하였다.

2. 관련 연구

그래프 이상 탐지는 전통적인 기계학습 기법에서부터 최신 그래프 신경망(GNN) 기반의 접근법에 이르기까지 다양한 연구들이 진행되고 있다. 기존의 비지도 학습들의 한계를 해결하기 위해 최근에는 다양한 준지도 학습 기반의 기법들이 연구되고 있다.

2.1 전통적인 기법

초기의 그래프 이상 탐지 기법 [24]들은 그래프의 구조나 속성값만을 고려하였는데, 그 후에 커뮤니티를 활용한 확률모델 CODA [25]가 소개되었고, AMEN [7]은 Ego-graph를 활용한 이상 탐지 기법을 제안하였다. 추가적으로, 이상 탐지에 노드 속성값을 더 효율적으로 사용해하고자 제안한 기법들이 있고 [26], ANOMALOUS [6]에서는 잔차 분석 기법을 활용한 이상 탐지 방법을 제안하였다.

2.2 비지도 GNN 기반 기법

GNN의 등장으로 [4, 12], 그래프 이상 탐지를 위한 다양한 GNN 기반 접근 방식이 GNN 기술의 급격한 성장과 함께 제시되었다. DOMINANT [10]은 먼저 구조 및 속성 정보를 인코딩하고 이후 비정상 노드 탐지를 위해 구조 및 속성 특징을 디코딩하는 GCN 기반 그래프 오토인코더(GAE)를 제안하였다. CoLA [27]는 지역 하위 그래프를 샘플링하고 이를 대상 노드와 비교하는 비정상 노드 탐지를 위해 대조적인 자기 지도 학습을 제안하였으나 이러한 방법들은 실제 세계 네트워크에서 효과적으로 작동하지 않을 수 있는데, 이는 이상 패턴이 훨씬 더 불규칙하기 때문이다. 이를 보완하기 위하여 ANEMONE [28]는 Patch 단위와 Context 단위의 다중 스케일 대조 학습 기법을 제안하였다. SpecAE [11]은 컨볼

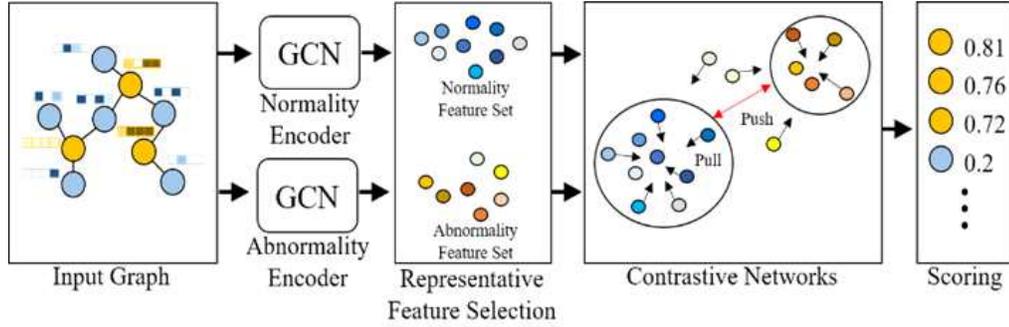
루션 메커니즘의 과도한 Over-smoothing 문제를 완화하기 위해 Laplacian sharpening 기법을 사용하여 전역 및 커뮤니티의 이상을 감지하려고 시도하였다. HCM [29]은 자가 지도 방식의 hop-count 기반 서브그래프를 기반으로 전역 및 지역 맥락 이상을 고려하였고 ComGA [17]는 커뮤니티 구조의 구조 정보, 전체 그래프의 속성 및 구조 특징을 활용하여 전역, 지역 및 구조 이상의 탐지를 시도하였다.

2.3 준지도 GNN 기반 기법

준지도 학습 방식 기반의 이상 탐지 연구에서는 여러 방법들이 제시되었으며, 이러한 방법들은 레이블 정보를 레이블이 지정되지 않은 노드로 전파시킨다 [21]. 준지도 학습 방식으로 이상 현상을 감지하는 GNN 기반의 대표적인 방법으로는 Kumagai 등은 그래프 이상 탐지를 위한 준지도 학습 방식에서 간단한 GCN 기반 임베딩 방법을 제시하였고 [28], MetaGDN [20]은 그래프 이상 노드를 정상 노드와 분리하기 위해 소수의 레이블을 활용하는 Cross-Network Meta-Learning 알고리즘을 사용하는 그래프 이상 탐지 네트워크 (GDN)를 소개하였다. 본 논문에서는 기존의 방법들의 단점인 클래스 불균형 문제를 완화하는 그래프 이상 탐지 방법인 준지도 학습 기반의 대조 학습 방법 (SAD-CL)을 제안한다 (그림 1).

3. 문제 정의

정의 1. 속성 그래프. 속성 그래프는 $G = (V, E, X)$ 로 표현되고 V 는 노드의 집합으로 $V = \{v_1, v_2, \dots, v_n\}$ 이고 $|V| = n$, E 는 엣지의 집합으로 $|E| = n$, X 는 노드의 속성으로



[그림 1] 제안하는 프레임워크 (SAD-CL)

$X \in \mathbb{R}^{n \times d}$ 로 표현된다. 또한, 인접행렬은 A 이고 $A_{ij} = 1$ 은 노드 v_i 와 v_j 사이의 연결이 있다는 것이고, 반대로 $A_{ij} = 0$ 은 노드 사이의 연결이 없다는 것이다.

문제 1. 이상 노드 탐지. 속성 그래프 G 가 주어졌을 때, 본 연구에서 풀고자 하는 문제는 각각의 노드 v_i 의 이상 점수 k_i 를 매기는 것이다. 이상 점수 k_i 는 노드 v_i 의 비정상 정도를 수치로 나타내는 것으로 이 점수를 바탕으로 각 노드의 랭킹이 매겨지고 이를 기반으로 이상 노드를 선정한다.

4. 제안하는 방법 (SAD-CL)

본 논문에서 제안하는 프레임워크는 크게 3개의 부분으로 나눌 수 있다. 첫째로, Representative Feature Selection, 둘째로, Contrastive Networks, 마지막으로 이상 점수 Anomaly Scoring 부분이다.

4.1 대표 특징 선택

주어진 입력 그래프에서 레이블 되지 않은 노드와 소수의 레이블 된 노드를 중심으로 Ego-network 형태의 부분그래프를 추출한다. 본 연구에서는 간단

하게 레이블 되지 않은 노드의 샘플을 정상 노드라고 간주한다. 이렇게 샘플링 된 정상/비정상 부분 그래프를 그래프 컨볼루션 레이어를 활용하여 각각 따로 인코딩을 하고 아래 식 (1)과 같다.

$$H_i^{(l)} = \Phi(\tilde{D}_i^{-\frac{1}{2}} \tilde{A}_i \tilde{D}_i^{-\frac{1}{2}} H_i^{(l-1)} W^{(l-1)}), \quad (1)$$

$\tilde{A}_i = A_i + I$ 은 부분그래프의 인접행렬이고, \tilde{D}_i 은 로컬 부분그래프의 차수행렬, $W^{(l-1)} \in \mathbb{R}^{d^{(l-1)} \times d^{(l)}}$ 은 $(l-1)$ 번째 레이어의 가중치 행렬이며, $\Phi(\cdot)$ 은 ReLU와 같은 활성화 함수, $H_i^{(l-1)}$ 은 $(l-1)$ 번째 레이어를 통해 학습된 은닉 표현이다. 이렇게 얻어진 정상/비정상 각각의 부분 그래프의 은닉표현 H 의 분포에서 Mean 값을 본 연구에서는 전체 정상/비정상 레이블을 가장 잘 표현하는 대표 표현으로 활용한다.

4.2 대조학습 네트워크

앞서 선택한 대표 특징과 타겟 노드 v_i 간의 대조 학습을 진행하기 전에 v_i 을 MLP 레이어를 활용하여 아래 식 (2)와 같이 임베딩 한다. v_i 의 속성 벡터

는 $x^{(i)}$ 로 표시되고 타겟 노드 임베딩 $z^{(i)}$ 는 다음과 같다.

$$z^{(i)} = MLP(x^{(i)}). \quad (2)$$

식 (1)과 (2)를 통하여 $h^{(i)}$ 와 $z^{(i)}$ 는 같은 임베딩 공간에 투영되고, 대조 학습 네트워크를 통해 이 두 표현 간의 관계를 학습한다. 구체적으로, 본 연구에서는 두 표현 간의 유사도 정도를 계산하기 위해 Bilinear 레이어가 사용되었고 이는 아래 식 (3)과 같다.

$$s^{(i)} = Bilinear(h^{(i)}, z^{(i)}). \quad (3)$$

더 효율적인 특징 대조 학습을 위해서 본 논문에서는 Negative sampling 기법을 사용한다. 이 기법은 Positive 점수 $s^{(i)}$ 에서 아래 식 (4)에 의해서 Negative 점수 $\tilde{s}^{(i)}$ 를 계산한다.

$$\tilde{s}^{(i)} = Bilinear(h^{(j)}, z^{(i)}), \quad (4)$$

$h^{(j)}$ 는 Ego-net의 중심에 위치한 레이블 정보를 활용한 노드 v_j 에서 얻을 수 있다. 두 스코어 $s^{(i)}$ 와 $\tilde{s}^{(i)}$ 를 통하여 정상과 비정상 대표 특징 간의 대조 네트워크가 학습되는데 이때 목적함수는 아래 식 (5)와 같은 Jensen-Shannon Divergence [29] 목적함수를 활용한다.

$$L = -\frac{1}{2n} \sum_{i=1}^n (\log(s^{(i)}) + \log(1 - \tilde{s}^{(i)})), \quad (5)$$

학습 스테이지에서 정상 데이터 L_n 와 비정상 데이터 L_a 가 같이 학습되고 전체 목적 함수는 아래 식

(6)과 같다.

$$L = \alpha L_n + (1 - \alpha)L_a, \quad (6)$$

$\alpha \in [0, 1]$ 이고 이는 정상/비정상 손실 함수 사이의 중요도의 밸런스를 맞춰주는 Trade-off 파라미터이다.

4.3 이상 점수

모델이 다 학습된 이후에 SAD-CL은 Scoring 함수를 활용하여 각 노드의 이상 점수를 계산한다. 주어진 타겟 노드 v_i 에서 정상- 그리고 비정상-단위의 R 개의 ego-network을 추출한다. 본 연구에서는 Positive와 Negative 점수 사이의 차이를 기본 이상 점수 b 로 사용하고 이는 아래 식 (7)과 같다.

$$b_{label,j}^{(i)} = (\tilde{s}_{label,j}^{(i)} - s_{label,j}^{(i)}), \quad (7)$$

위 식에서 $label$ 은 정상/비정상(n/a)을 표현하고 $j \in [1, \dots, R]$ 이다. 그 후에, 본 연구에서는 기본 이상 점수의 평균값(식 (8))을 Negative pair의 점수 $\bar{b}_{label,j}^{(i)}$ 를 구하고 표준편차값(식 (9))을 활용해 이상 점수 $y_n^{(i)}$ 와 $y_a^{(i)}$ 를 정의한다. 최종적으로 노드 v_i 의 이상 점수 $y^{(i)}$ 는 아래 식 (10)과 같이 정의된다.

$$\bar{b}_{label,j}^{(i)} = \sum_{j=1}^R \frac{b_{label,j}^{(i)}}{R}, \quad (8)$$

$$y_{label}^{(i)} = \sqrt{\frac{\sum_{j=1}^R (b_{label,j}^{(i)} - \bar{b}_{label,j}^{(i)})^2}{R}}, \quad (9)$$

$$y^{(i)} = \alpha y_n^{(i)} + (1 - \alpha)y_a^{(i)}. \quad (10)$$

식 (6)과 마찬가지로 $\alpha \in [0, 1]$ 이고 정상/비정상 사이의 중요도의 밸런스를 맞춰주는 Trade-off 파라미터이다.

5. 실험 설계

5.1 데이터셋

본 실험에서는 세 가지의 널리 알려진 인용 네트워크 데이터셋을 활용하였다 (Cora, CiteSeer, PubMed). 이 데이터셋들의 기본 정보들은 표 1에 요약하였다. 기본적으로 이 인용 네트워크들에는 이상치 레이블이 없기 때문에 본 실험에서는 이전 방법 [10, 26]을 따라서 동일한 수의 구조적, 속성적 이상 노드를 주입하였다. 직관적으로 작은 클릭에서는 일부 노드가 평균보다 훨씬 더 긴밀하게 연결되어 있으며, 이는 실제 세계 네트워크에서는 전형적인 구조적 이상 상황으로 간주될 수 있다 [32]. 클릭을 생성할 때 노드를 무작위로 선택하여 완전히 연결한 후 이를 구조적 이상 노드로 표시한다.

[표 1] 실험 데이터셋의 기본 정보

	Cora	CiteSeer	PubMed
# Nodes	2,708	3,327	19,717
# Edges	5,429	4,732	44,338
# Attributes	1,433	3,703	500
# Anomalies	150	150	600

속성 이상 주입은 노드의 속성을 교란하여 생성된다 [33]. 구체적으로 무작위로 선택된 노드들의 주변 노드 k 개를 후보로 샘플링한 후, 선택된 노드와 주변노드들 간의 거리가 가장 큰 노드를 선택된 노드의 속성으로 변경하고 이를 속성적 이상 노드로

간주한다.

5.2 비교 모델

본 연구에서 이상 탐지의 성능을 비교하기 위해 제안하는 모델 SAD-CL과 4개의 대표 모델과 2개의 대조 학습 기반의 모델, 총 6개의 모델과의 성능 비교 실험을 진행하였다.

- **AMEN** [7]: AMEN은 Ego-network 분석 기반의 이상 탐지 모델이다. 이 모델은 Ego-network 노드들의 상관관계를 분석하여 비정상 노드를 탐지한다.
- **Radar** [5]: Radar는 잔차 분석 기반의 방법이다. 속성정보의 잔차와 네트워크 구조 정보를 특징화하여 그래프 이상 탐지에 활용한다.
- **ANOMALOUS** [6]: ANOMALOUS도 마찬가지로 잔차 분석 기반의 방법이다. CUR decomposition과 잔차 분석을 Joint learning 프레임워크를 활용하여 이상 탐지를 수행한다.
- **DOMINANT** [10]: DOMINANT는 그래프 신경망을 비지도 학습 방법으로 활용하는 가장 대표적인 방법 중 하나이다. 이 방법은 그래프 오토인코더 모델을 활용하여 그래프의 구조와 속성 정보를 복원하고 복원 에러를 동시에 활용하여 각 노드의 비정상 정도를 평가한다.
- **CoLA** [27]: CoLA도 마찬가지로 그래프 신경망 기반의 비지도 학습 방법으로 대조 학습 기법을 활용하여 타겟 노드와 부분그래프의 관계를 학습하여 이상 탐지를 수행한다.

- **ANEMONE** [31]: ANEMONE도 그래프 신경망 기반의 비지도 학습 방법이며 대조 학습 기법을 활용하는데 Patch-레벨과 Context-레벨의 대조 학습을 동시 진행하여 이상 탐지를 수행한다.

5.3 성능 지표

본 연구에서 제안하는 SAD-CL 프레임워크의 이상 탐지 성능을 측정하기 위한 지표로 ROC-AUC를 사용한다. 이 ROC-AUC는 많은 이전 연구에서 이상 탐지 성능을 평가하기 위해 널리 사용되는 지표이다 [5-6, 10]. ROC 곡선은 실제 True positive 비율 (비정상을 비정상으로 예측)을 기준으로 False positive 비율 (정상을 비정상으로 예측)을 그린 곡선으로, 실제 비정상 레이블과 이상 탐지 결과에 따라서 그려지게 된다. AUC값은 ROC 곡선 아래 영역을 나타내며, 임의로 선택된 비정상 노드가 정상 노드보다 높은 순위로 평가될 확률을 나타낸다. 1에 가까운 AUC값일수록 높은 탐지 성능을 가지고 있다는 것을 의미한다.

6. 실험 결과

6.1 이상 탐지 결과

이 섹션에서는 SAD-CL 프레임워크와 비교 모델들 간의 성능을 비교 평가하였고 각 방법들의 AUC 값은 표 2에 정리하였다. 이 결과에서 관찰할 수 있는 것들은 아래와 같다:

- 제안하는 SAD-CL은 대부분의 데이터셋에서 비교 모델의 성능보다 좋은 성능을 보여주었고, 특히 Cora 데이터셋에서 최신 방법 대비 AUC값

이 2.62% 이상 향상되어 세 데이터셋 중에서 가장 큰 폭의 개선을 보였다. 이를 통해, SAD-CL이 효율적인 대조 학습을 통하여 정상 노드뿐만 아니라 비정상 노드에서도 잘 동작함을 알 수 있다.

- 그래프 신경망 기반의 방법과 비교하여 AMEN, Radar, ANOMALOUS와 같은 전통적인 방법은 만족스러운 결과를 얻을 수 없었는데 이 방법들은 고차원의 노드 속성과 희소하고 복잡한 네트워크 구조를 효율적으로 다루기에는 너무 얇은 매커니즘을 가지고 있기 때문으로 보인다.

[표 2] 이상 탐지 결과(AUC) 결과 비교

Methods	Cora	CiteSeer	PubMed
AMEN	62.66	61.54	77.13
Radar	65.87	67.09	62.33
ANOMALOUS	57.70	63.07	73.16
DOMINANT	81.55	82.51	80.81
CoLA	88.69	90.47	95.32
ANEMONE	90.57	91.89	95.48
SAD-CL (ours)	93.19	93.72	93.54

- 그래프 오토인코더 기반의 DOMINANT와 비교하였을 때, SAD-CL은 모든 데이터셋에서 괄목할만한 성능 향상을 달성하였다. 주요 이유는 SAD-CL은 단순히 원본 데이터를 재구성하는 대신에 각 레이블의 대표 표현을 선택하여 대조 학습에 활용하면서 제한된 레이블 정보를 효과적으로 활용하기 때문이다.
- SAD-CL은 대조 학습을 활용한 방법인 CoLA와 ANEMONE보다 Cora와 CiteSeer 데이터셋에서는 향상된 성능을 보여주었으나 PubMed 데이터

셋에서는 이전 두 방법들보다 조금 못 미치는 성능을 보여주었다. 예상되는 이유는 PubMed 네트워크는 다른 두 네트워크에 비해 크기가 훨씬 크고 커진 크기에 비해 속성의 수가 너무 적기 때문인 것으로 보인다.

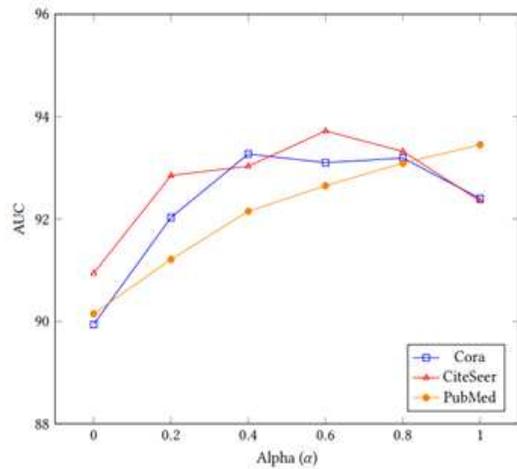
각 네트워크에서의 결과들을 보면 네트워크 특징에 따른 성능 변화를 관찰할 수 있다. 구체적으로 세 데이터셋 중에서 이상치의 개수 대비 속성 개수의 비율이 높은 네트워크는 Cora와 CiteSeer이고 비율은 각각 9.5와 24.6이고 비율이 낮은 네트워크는 PubMed이고 값은 0.8이다. 비율값이 1보다 큰 Cora와 CiteSeer의 경우에는 기존 연구들 대비 우수한 성능을 보여주었으나 값이 1보다 작은 PubMed의 경우에는 기존보다 조금 비효율적인 성능을 보여주었다. 네트워크의 구조적 정보를 추가적으로 고려한다면 PubMed 같은 네트워크에서도 이전 방법들 대비 좋은 성능을 보여줄 수 있을 것으로 기대한다.

6.2 민감도 분석

이 섹션에서는 파라미터 α 값과 사용된 이상 레이블의 변화에 따른 성능 변화를 분석하였다.

- 정상/비정상 간의 밸런스를 잡아주는 파라미터 α 의 변화에 따른 AUC값의 변화는 그림 2와 같다. 그림 2에서 볼 수 있듯이 Cora 데이터셋은 α 값이 0.4일 때 가장 좋은 성능을 보였고 CiteSeer는 α 값이 0.6 그리고 PubMed는 α 값이 1일 때 가장 최적화 된 성능을 보여주었다. 이 실험을 통하여 너무 낮은 α 값은 최적화 된 성능을 보여주지 못한다는 것을 확인하였고 0.4 이상의 α 값에서 준수한 성능을 보인다고 할 수 있다.
- 성능의 변화는 전체 이상 레이블 정보의 1, 5,

10%를 각각 사용하여 Cora와 CiteSeer 데이터셋에서 측정하였다. 각각의 사용된 이상 레이블의 수는 1%일 때 2개, 5% 10개, 10% 15개가 사용되었다. 이 비율에 따른 성능 변화는 표 3과 같고 Cora와 CiteSeer 둘 다 비율이 10%일 때 가장 좋은 성능을 보였다. 하지만 비율이 가장 낮을 때의 성능도 가장 최신 기법의 성능과 비슷하거나 앞서는 수치로 소수의 레이블 정보도 효과적으로 사용되는 것으로 볼 수 있다.



[그림 2] 파라미터 α 의 변화에 따른 AUC 변화

[표 3] 이상 비율에 따른 성능 변화

Anomaly Ratio	Cora	CiteSeer
1%	90.18	92.11
5%	91.08	92.06
10%	93.19	93.73

7. 결론 및 향후 연구

본 논문은 속성 네트워크의 이상 탐지 문제에 대해 준지도 대조 학습을 처음으로 활용한 SAD-CL을 제안하였다. SAD-CL 프레임워크는 레이블 된

노드 정보와 레이블 되지 않은 노드 정보의 대표 특징을 선택하여 이 선택된 두 특징을 대조 학습 기법과 잘 정의된 손실함수 및 Scoring 함수를 통하여 각 노드의 이상 점수가 계산되고 이를 바탕으로 효율적으로 이상 노드를 탐지한다. 제안된 방법의 우수성을 입증하기 위해 일련의 실험을 진행하였고 대부분의 데이터셋에서 우수성을 입증하였다.

본 연구는 그래프 이상 탐지 문제를 준지도 학습 방법과 대조 학습 매커니즘을 동시에 활용하여 접근하는 최초의 연구로 이전의 방법들보다 개선된 성능을 보이며 향후 연구로의 가능성을 보여주었다. 향후 연구에서는 대조 학습 기반의 이상 탐지 방법을 이종 그래프, 공간-시간 그래프 및 동적 그래프 등 더 복잡한 네트워크/그래프 데이터로 확장할 것이며 각 레이블의 대표 특징을 추출하는데 메모리 기반의 매커니즘을 활용하여 더 정확한 표현을 선택할 수 있도록 할 것이다.

참고 문헌

[1] G. Zhang et al., "eFraudCom: An E-commerce Fraud Detection System via Competitive Graph Neural Networks," *ACM Transactions on Information Systems*, vol. 40, no. 3, 2022, pp. 47:1-47:29.

[2] X. Zhou et al., "Hierarchical Adversarial Attacks Against Graph-Neural-NetworkBased IoT Network Intrusion Detection System," *IEEE Internet of Things Journal*, vol. 9, no. 12, 2022, pp. 9310-9319.

[3] L. Akoglu et al., "Graph-based Anomaly Detection and Description: A Survey," *Data Mining and Knowledge Discovery*, vol. 29, no. 3, 2015, pp. 626-688.

[4] H. Kim and S. Lim, "Graph Anomaly Detection with Graph Neural Networks: Current Status and

Challenges," *IEEE Access*, vol. 10, 2022, pp. 111820-111829.

[5] J. Li et al., "Radar: Residual Analysis for Anomaly Detection in Attributed Networks," *IJCAI*, 2017, pp. 2152-2158.

[6] Z. Peng et al., "ANOMALOUS: A Joint Modeling Approach for Anomaly Detection on Attributed Networks," *IJCAI*, 2018, pp. 3513-3519.

[7] B. Perozzi and L. Akoglu, "Scalable Anomaly Ranking of Attributed Neighborhoods," *SDM*, 2016, pp. 207-215.

[8] M. Längkvist et al., "A Review of Unsupervised Feature Learning and Deep Learning for Time-Series Modeling," *Pattern Recognition Letters*, vol. 42, 2014, pp. 11-24.

[9] J. Wang et al., "Deep Learning for Sensor-based Activity Recognition: A Survey," *Pattern Recognition Letters*, vol. 119, 2019, pp. 3-11.

[10] K. Ding et al., "Deep Anomaly Detection on Attributed Networks," *SDM*, 2019, pp. 594-602.

[11] Y. Li et al., "SpecAE: Spectral AutoEncoder for Anomaly Detection in Attributed Networks," *CIKM*, 2019, pp. 2233-2236.

[12] T. N. Kipf and M. Welling, "Semi-Supervised Classification with Graph Convolutional Networks," *ICLR*, 2017.

[13] P. Veličković et al., "Graph Attention Networks," *ICLR*, 2017.

[14] S. Xiao et al., "Graph Neural Networks in Node Classification: Survey and Evaluation," *Machine Vision and Applications*, vol. 33, 2022, pp. 4:1-4:19.

[15] H. Fan et al., "AnomalyDAE: Dual Autoencoder for Anomaly Detection on Attributed Networks," *ICASSP*,

2020, pp. 5685-5689.

[16] Y. Liu et al., "Anomaly Detection on Attributed Networks via Contrastive Self-Supervised Learning," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 6, 2022, pp. 2378-2392.

[17] X. Luo et al., "ComGA: Community-Aware Attributed Graph Anomaly Detection," *WSDM*, 2022, pp. 657-665.

[18] Y. Pei et al., "ResGCN: Attention-based Deep Residual Modeling for Anomaly Detection on Attributed Networks," *Machine Learning*, vol. 111, no. 2, 2022, pp. 519-541.

[19] K. Ding et al., "Meta Propagation Networks for Graph Few-shot Semi-supervised Learning" *AAAI*, Vol. 36, 2022, pp. 6524-6531.

[20] K. Ding et al., "Few-shot Network Anomaly Detection via Cross-network Meta-learning" *WWW*, 2021, pp. 2448-2456.

[21] S. Tian et al., "SAD: Semi-Supervised Anomaly Detection on Dynamic Graphs," *IJCAI*, 2023.

[22] X. Ma et al., "A Comprehensive Survey on Graph Anomaly Detection with Deep Learning," *IEEE Transactions on Knowledge and Data Engineering*, 2021.

[23] G. Pang et al., "Deep Learning for Anomaly Detection: A Review," *Computing Surveys*, vol. 54, no. 2, 2021, pp. 38:1-38:38.

[24] M. M. Breunig et al., "LOF: Identifying Density-Based Local Outliers," *SIGMOD*, 2000, pp. 93-104.

[25] J. Gao et al., "On Community Outliers and their Efficient Detection in Information Networks," *KDD*, 2010, pp. 813-822.

[26] G. Pang et al., "Deep Anomaly Detection with

Deviation Networks," *KDD*, 2019, pp. 353-362.

[27] Y. Liu et al., "Anomaly Detection on Attributed Networks via Contrastive Self-Supervised Learning," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 6, 2022, pp. 2378-2392.

[28] A. Kumagai et al., "Semi-supervised Anomaly Detection on Attributed Graphs," *IJCNN*, 2021, pp. 1-8.

[29] T. Huang et al., "Hop-Count Based Self-supervised Anomaly Detection on Attributed Networks," *ECML/PKDD*, 2022, pp. 225-241.

[30] P. Veličković et al., "Deep Graph Infomax," *ICLR*, 2019.

[31] M. Jin et al., "ANEMONE: Graph Anomaly Detection with Multi-Scale Contrastive Learning," *CIKM*, 2021, pp. 3122-3126.

[32] D. B. Skillicorn, "Detecting Anomalies in Graphs," *IEEE ISI*, 2007, pp. 209-216.

[33] X. Song et al., "Conditional Anomaly Detection," *IEEE Transactions on Knowledge and Data Engineering*, 2007, vol. 19, no. 5, pp. 631-645.



김 환

2013년 한남대학교 법학과 학사
2019년-현재 충남대학교 석박통합과정
관심분야: 데이터마이닝, 그래프마이닝,
그래프 이상탐지, 그래프 기계학습



임성수

2009년 KAIST 수리과학 학사
2011년 KAIST 수리과학 석사
2016년 KAIST 지식서비스공학 박사
2018년-현재 충남대학교 부교수
관심분야: 데이터마이닝, 그래프마이닝, 그래프 기계학습