

## U-Net 모델을 이용한 비정상 인쇄물 검출 방법

홍순현 남현길 박종일\*

한양대학교

soonpod@hanyang.ac.kr, skagusrlf@hanyang.ac.kr, jipark@hanyang.ac.kr

## Anomaly Detection in printed patterns using U-Net

Hong, Soon-Hyun Nam, Hyeon-Gil Park, Jong-Il

Hanyang University

## 요약

본 논문에서는 U-Net 모델을 이용하여 정교하고 반복되는 패턴을 가진 인쇄물에 대한 비지도 학습을 통한 딥러닝 기반 이상치 탐지(Anomaly Detection) 방법을 제안하였다. 인쇄물(카드)의 비정상 패턴 검출을 위하여 촬영한 영상으로부터 카드 영역을 분리한 이미지로 구성된 Dataset을 구축하였고 정상 이미지와 동일한 이미지를 출력하기 위해, 정상 이미지와 마스크 이미지 쌍의 Training dataset을 U-Net으로 학습하였다. Test dataset의 이미지를 입력으로 넣어 생성된 마스크 결과를 원본 마스크 이미지와 비교하여 이상 여부를 판단하는 본 논문의 방법이 정상, 비정상 인쇄물을 잘 구분하는 것을 확인하였다. 또한 정상과 비정상 이미지 각각을 학습한 지도학습 기반 CNN 분류 방법을 입력 영상과 복원 영상 간의 복원 오차를 비교하여 객체의 이상 여부를 판별하는 본 논문의 방법과 비교 평가하였다. 본 논문을 통해 U-Net을 사용하여 별도로 데이터에 대한 label 취득 없이 이상치를 검출할 수 있음을 확인할 수 있었다.

**키워드** : 인공지능, 딥러닝, 이상치탐지, 비정상탐지, 비지도학습

## 1. 서론

이상치 탐지(Anomaly Detection)란 자료에서 예상과는 다른 패턴을 보이는 개체 또는 자료를 찾는 분야이며 영상 처리에서의 이상치 검출 기법은 시간에 따른 이미지의 동적인 변화를 찾거나 정적인 이미지에서의 비정상을 찾는 것을 목적으로 한다. 그 중에서 정교하고 반복되는 패턴을 가진 인쇄물의 경우 비정상 영역을 검출하기 위해 패턴 특성에 맞는 컴퓨터 기반 알고리즘을 개별적으로 다르게 적용해야 했다. 또한 배경과 조명의 영향을 많이 받아서 feature 추출이 제대로 이루어지지 않는 경우에 패턴을 검출하기 쉽지 않다.

최근에는 딥러닝을 이용한 이상치 탐지 연구가 활발하게 이루어지고 있는데, 특히 대부분의 자료가 정상으로 분류되고 극소수 자료가 비정상 자료인 특성을 고려한 준지도, 비지도 학습이 주를 이루고 있다.[1] 본 논문에서는 딥러닝 알고리즘 중 대표적 비지도 방식인 Autoencoder에 착안하여 U-Net 기반의 이상치 탐지 방식을 제시하고자 하였다. 2절에서는 딥러닝을 이용한 대표적인 이상치 탐지 학습 방법론에 대해 설명하였고 3절에서는 비지도 학습 방식을 사용하는 딥러닝 네트워크를 선정하고 그 이유를 설명하였다. 그리고 4절에서는 Dataset 구성과 U-Net으로 학습시킨 방법에 대해 설명하였다. 또한 5절에서는 U-Net을 통해 학습된 결과를 이용하여 이상치를 판정한 본문의 방식과 CNN(Convolutional Neural Network) 기법으로 학습시킨 영상 분류 네트워크 방식과 비교 평가한다. 본 논문은 U-Net 네트워크를 활용하여 비지도 학습 기법을 통해 정상 이미지 샘플만을 사용하여 이상치를 검출할 수 있음을 확인하였다.




그림 1. (a) 인쇄물 예시, (b) 정상 인쇄물 패턴, (c) 비정상 인쇄물 패턴

## 2. 딥러닝을 이용한 이상치 탐지

이상치 탐지에서 매우 드물게 나타나거나 새로운 종류의 이상치가 등장했을 경우, 모든 샘플에 대한 label을 활용하여 이미지를 분류하는 것은 불가능에 가깝다. 따라서 label에 대한 정보가 없는 이미지를 다루게 되고, 그 정도에 따라 세 가지로 나눌 수 있다.

\*교신저자

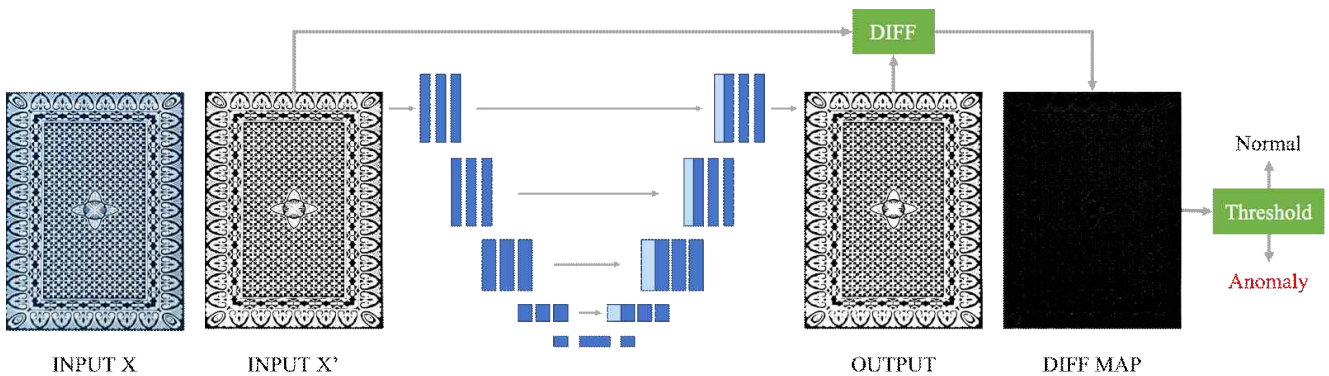


그림 2. 비정상 인쇄물 검출을 위한 U-Net 네트워크 구조

### 2.1 지도 학습 (Supervised Learning)

지도 학습은 주어진 Training Dataset에 정상 샘플과 비정상 샘플의 data와 label이 모두 존재하는 학습 방법이다. 비정상 샘플을 다양하게 보유하거나 패턴이 크게 다른 물체를 분류하는 경우에는 분류가 쉽지만 정상 샘플보다 비정상 샘플의 발생 빈도가 적은 Class Imbalance 문제를 겪게 되어 학습이 제대로 이루어지지 않을 수 있다.

### 2.2 준지도 학습 (Semi-supervised Learning)

Class-Imbalance가 매우 큰 경우 정상 샘플만 이용해서 모델을 학습하기도 하는데, 이를 준지도 학습이라고 한다. 이 방법론은 label이 표시된 데이터와 표시되지 않은 데이터를 모두 훈련에 사용하는 것이다. 대표적인 연구로 딥러닝을 기반으로 One-Class Classification 방법론을 사용하는 Deep SVDD[2]이 있다. 정상 샘플만 있어도 학습이 가능하다는 장점이 있지만 지도학습 방법론에 비해 상대적으로 판정의 정확도가 떨어진다는 단점이 있다.

### 2.3 비지도 학습 (Unsupervised Learning)

위의 학습 방법들은 수많은 샘플 중 어떤 것이 정상 샘플인지 알기 위해서 반드시 정상 샘플에 대한 label을 얻는 과정이 필요하다. 이러한 점 때문에 대부분의 데이터가 정상 샘플이라는 가정을 하여 label 취득 없이 학습을 시키는 비지도 학습 기반 이상치 탐지 방법론을 고려할 수 있다. 비지도 학습 기반 이상치 탐지를 위해 대표적으로 오토인코더 (Autoencoder)를 이용하여 결함(비정상)을 찾아내는 연구가 대표적으로 이루어지고 있다.[3, 4]

## 3. 제안 방법

### 3.1 학습 방식

정상과 비정상 샘플에 대한 label을 갖고 있는 경우, 분류를 위해 일반적인 CNN(Convolutional Neural Network)에 각 샘플을 입력으로 넣고 학습시키면 정상 여부를 판별할 수 있다. 하지만 이상치 탐지의 경우 학습을 위해 label을 포함하고 있는 데이터를 구하기가 어렵기 때문에 label을 전제로 하는 지도학습 방식을 취하지 않았다.

한편, 준지도 학습 방식과 마찬가지로 본 논문 역시 One-Class의 정상 샘플만을 학습시키는 방식으로 한 종류의 이상치에 대해 실험하였다. 하지만 제안하는 연구의 방식은 여러 종류의 이상치가 포함이 된다고 가정하여도 정상 데이터에 대한 레이블을 따로 부여하지 않을 수 있다는 것과, 여러 종류의 정상 패턴과 그에 따른 여러 종류의 이상치가 포함이 된다고 하여도 이상치 탐지가 가능한 방식이라는 점에서 비지도 학습 방식을 취한다고 할 수 있다.

### 3.2 U-Net 네트워크를 통한 이상치 탐지

오토인코더는 입력을 압축하는 Encoding과, 이를 다시 원본과 가깝게 복원해내는 Decoding 과정으로 진행이 되며 이를 통해 데이터의 중요한 정보들만 압축적으로 학습할 수 있는 네트워크이다. 학습된 모델에 비정상 이미지가 들어왔을 때 출력 값과 입력 값의 차이가 클 것이라는 것을 가정하였고 입력 값 대비 출력 값이 다른 정도에 따라 비정상으로 판단할 수 있다. 하지만 오토인코더를 기반으로 한 네트워크는 Encoding과 Decoding 과정에서 차원 축소로 인한 정보의 손실을 가져와 정확도가 높지 않고, 하이퍼파라미터 값에 민감하다는 단점을 지닌다. 그런 이유로 본 논문에서는 공간 정보 손실을 방지할 수 있도록 개선된 네트워크인 U-Net을 활용하기로 하였다. Decoding 영역에서의 Pooling Layer를 Up-sampling 영역으로 대체하고 Encoding 영역에서 출력된 결과물을 Decoding 영역과 Concat함으로써 이미지 크기에 관계없이 적용 가능하며 Localization과 Context 인식에 모두 좋은 성능을 보여주어 본 실험에서의 인쇄물 패턴 검출에 적합하다고 판단하였다.

## 4. 실험

### 4.1 Dataset 구성

U-Net은 학습을 위해 검출 대상 이미지와 목표 영상이 될 마스크 이미지 쌍을 입력으로 받는다. 학습을 위해서 150개의 정상 Color Image와 학습의 목표 영상이 될 0과 1값만을 가지는 마스크 이미지 150개를 이용하였다. 다양한 조명과 각도에서 데이터를 수집하였으며 학습 과정에서 공간 정보를 보존하기 위해 모든 입력 쌍의 카드 영역만을 같은 Scale로 변환하였다. 또한 인쇄물의 패턴이 상하좌우가 대칭인

특성을 이용하여 4등분으로 증강하여 Dataset을 구성하였다.

#### 4.2 U-Net 기반의 비정상 인쇄물 검출 과정

본 연구에서 제안된 딥러닝 모델을 이용한 비정상 인쇄물 검출 모델은 그림 2와 같다. U-Net 네트워크를 기반으로 마스크 처리한 입력 영상과 네트워크의 결과 간의 차이 영상을 획득하여 비정상 인쇄물임을 판단하였다. 실험 과정에서 정상 Dataset만으로 네트워크를 학습하였고 효과적인 학습을 위해서 Learning Rate를 0.01, 영상의 Scale을 0.3으로 설정하여 30 Epoch만큼 학습하였으며 학습이 완료된 네트워크에 Test Dataset을 적용하여 모델을 검증하였다. 정상 샘플과 정상 복원 샘플의 복원 오차와 비정상 샘플과 비정상 복원 샘플의 복원 오차를 비교함으로써 이상 여부를 판단하는 임계값을 결정할 수 있었다. 각 개체의 이상 여부를 판단하기 위해서는 이 모델의 출력 값이 임계값과 비교하여 클 경우 이상으로 간주하였다.

#### 5. 실험 결과

그림 3에서는 U-Net 네트워크의 결과 영상과 입력 마스크 간의 차이 영상을 보이고 있다. 그림 3(a)에 드러나는 영역은 비정상 샘플과 비정상 복원 샘플간의 복원 오차를 나타내는 차영상이다. 3(b)에 제시된 정상 복원 오차 영상과 비교하여 육안으로 대비를 확인할 수 있다.




그림 3. 차영상 (a) 비정상 샘플, (b) 정상 샘플

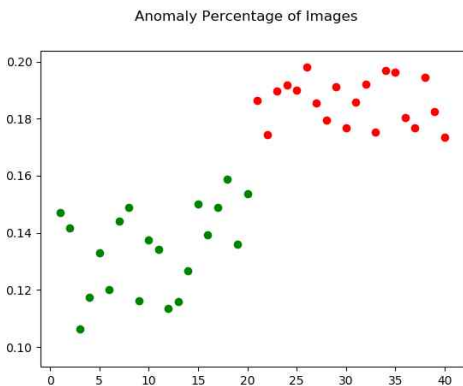


그림 4. 비정상(빨간색), 정상(초록색) 샘플의 복원 오차

그림 4는 정상 샘플 20개, 비정상 샘플 20개로 이루어진 Test Dataset에 대한 결과로서, 이미지의 전체 픽셀 대비 이상치 비율을 추정 한 값을 제시하였다. 정상 샘플의 경우 비정상 샘플의 경우보다 이상치 비율이 덜 검출되는 결과를 확인할 수 있다.

비교를 위해, 50개의 비정상 샘플을 포함한 Dataset을 구축하여 CNN 기반의 분류 네트워크로 학습시킨 결과를 본 논문의 방식과 비교 해보았다. CNN 기반 분류 기법은 60%의 검출 정확도를 보였다. 본 논문과 같이 대부분이 정상이고 미세하고 복잡한 패턴의 일부만을 이상치로 간주하는 경우에는 일반적인 CNN 기반 분류 네트워크에 크게 미치지 못하는 성능을 나타내었다. 실제 상황에서 Dataset을 구성한다면 학습 데이터의 불균형으로 인한 비정상 데이터의 확보가 어려운 문제를 겪을 수 있다.

#### 6. 결론

본 논문은 U-Net 네트워크를 활용하여 비지도 학습 기법을 통해 정상 이미지 샘플로부터 이상치를 검출하는 기법을 제안하였다. 정상 샘플과 비정상 샘플을 각각 테스트하여 제안한 네트워크를 검증하였으며 특정 임계값보다 클 경우 이상으로 간주할 수 있는 결과를 확인할 수 있었다.

본 연구는 기존의 영상처리와 머신러닝을 활용한 방식에 비해 Class-Imbalance한 상황에서 정상 데이터만으로 이상치를 검출할 수 있다는 점과 향후 다른 종류(패턴)의 이상치가 입력되는 상황에서도 이상치를 검출할 수 있다는 점에서 장점이 있다.

#### 감사의 글

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2019R1A4A1029800).

#### 참고 문헌

- [1] Chalapathy, Raghavendra & Chawla, Sanjay. Deep Learning for Anomaly Detection: A Survey. (2019)
- [2] Lukas Ruff, Robert Vandermeulen, Nico Goernitz, Lucas Deecke, Shoaib Ahmed Siddiqui, Alexander Binder, Emmanuel Müller, Marius Kloft, "Deep One-Class Classification," *Proceedings of the 35th International Conference on Machine Learning*, PMLR 80:4393-4402, 2018.
- [3] Bergmann, Paul & Löwe, Sindy & Fauser, Michael & Sattlegger, David & Steger, Carsten. Improving Unsupervised Defect Segmentation by Applying Structural Similarity to Autoencoders. 372-380. 10.5220/0007364503720380. (2019).
- [4] Baur, Christoph & Wiestler, Benedikt & Albarqouni, Shadi & Navab, Nassir. Deep Autoencoding Models for Unsupervised Anomaly Segmentation in Brain MR Images. (2018).