

공정의 선후행관계를 이용한 공종 이미지 분류 성능 향상

정상원¹ · 정기창^{2*}

¹한국산업융합연구원 선임연구원 · ²한국산업융합연구원 원장

Enhancing Work Trade Image Classification Performance Using a Work Dependency Graph

Jeong, Sangwon¹, Jeong, Kichang^{2*}

¹Senior researcher, Korea Institute of Industry Convergence

²President, Korea Institute of Industry Convergence

Abstract : Classifying work trades using images can serve an important role in a multitude of advanced applications in construction management and automated progress monitoring. However, images obtained from work sites may not always be clean. Defective images can damage an image classifier's accuracy which gives rise to a needs for a method to enhance a work trade image classifier's performance. We propose a method that uses work dependency information to aid image classifiers. We show that using work dependency can enhance the classifier's performance, especially when a base classifier is not so great in doing its job.

Keywords : Image Classification, Deep Learning, Progress Monitoring, Construction Management, Dependency Graph

1. 서론

1.1 연구의 배경 및 목적

공정 관리는 건축 프로젝트에 필요한 공종에 대해 각 공종별로 완료의 정도를 파악하는 업무를 지칭한다. 전통적으로 공정 관리는 건설 관리자 등 대상 공종에 전문 지식이 있는 사람이 건설 현장에서 매일 또는 주기적으로 공사의 진척도를 평가하는 방식으로 이루어진다. 이러한 전통적인 방식은 시간이 많이 소요될 수 있고, 비용이 높다(Navon, 2007). 이에 따라 자연스럽게 진척도 평가의 주기도 짧아질 수밖에 없는데 이는 효과적인 공정 관리를 방해한다. 이에 따라 인간이 공정 관리에 미치는 부정적인 영향을 줄이기 위해 공정 관리를 자동화하는 연구가 활발하다(Ibrahim et al., 2009).

공정 관리를 자동화하기 위해서는 여러 가지 세부 프로세스가 필요하다. 몇 가지 필요한 프로세스를 지목하자면, 공

종 판별(인식) 및 공정률 판단(Kim, 2019), 시각적 공간적 데이터 수집의 자동화(EI-Omari and Moselhi, 2011), 그리고 건설 현장 데이터와 BIM (Building Information Modeling) 데이터의 연동 등을 생각할 수 있다(Tang et al., 2019). 모든 프로세스가 중요하지만, 가장 기본이 되는 프로세스는 공종 인식이라고 볼 수 있다. 이 프로세스는 건설 관리자가 건설 현장에서 공사를 보고 이 공사가 무슨 공사인지를 인지하는 활동과 같기 때문이다.

공종을 판별하기 위해서는 여러 데이터 소스를 사용할 수 있다. 데이터는 통상 이미지와 레이저 스캔이 사용되는데 장 단점이 존재한다. 이미지는 레이저 스캔보다 빠르고 데이터의 수집이 쉽지만, BIM과의 연동이 상대적으로 어렵다는 단점을 가지고 있다. 건설 현장과 BIM과의 연동은 통상 포인트 클라우드(Point Cloud)라는 정보를 이용해 기하학적으로 이루어지는데, 레이저 스캔을 통해 얻은 정보로 포인트 클라우드를 생성하기가 더욱 쉬우므로 건설 현장과 BIM과의 연동이 이미지 기반 기술보다 쉽다는 장점이 있다. 하지만, 레이저 스캔은 이미지보다 시간과 비용이 더 오래 든다는 단점이 있다. 또한, 두 기술 모두 완벽한 정확도로 대상 공종을 분류해 내지 못한다. 예를 들어, Kim (2019)에서 사용한 Convolutional Neural Network (CNN)의 한 아키텍처

* **Corresponding author:** Jeong, Kichang, Korea Institute of Industry Convergence, Seoul 05116, Korea

E-mail: therza@hanmail.net

Received December 10, 2020; **revised** January 7, 2021

accepted January 12, 2021

인 ResNet은 13개의 서로 다른 공중으로 분류된 이미지 데이터셋을 91%의 정확도로 분류하였다. 또한, Lee and Jeon (2018)은 InceptionNet (Szegedy et al., 2016)을 사용하여 27개의 서로 다른 공중으로 분류된 데이터셋에서 92.6%의 성능을 보여주었다. 90%가 넘는 정확도는 가히 큰 발전이라고 할 수 있으나, 신뢰성 높은 자동 공정 관리 시스템을 만들기에는 부족할 수 있다. 또한, 아무리 이미지 분류의 일반적인 성능이 개선된다고 하더라도 건설 현장의 다양한 환경 변화로 인한 이미지 데이터 질의 변동으로 인해 공중 분류 프로세스의 성능은 보장할 수 없다. 따라서 불안정한 공중 분류 프로세스를 보조할 추가 정보가 필요하다.

본 연구에서는, 항상 완벽하게 작동하기 힘든 공중 분류 프로세스를 보조하기 위한 수단으로 공정표에서 얻을 수 있는 공중별 선·후행 관계와 현재까지 완료된 공정, 이 두 가지 정보를 사용하는 방법을 제안한다. 쉽게 이야기하면, 공중 선·후행 관계와 완료된 공정 두 가지 정보가 있으면 공중 분류 프로세스가 고려해야 할 선택지가 줄어들기 때문에, 더욱 높은 성능을 낼 수 있는 것이다. 이에 따라, 이미지 기반 공중 분류 프로세스의 다양한 정확도를 가정하였을 때 공중별 선·후행 관계와 공중별 완료도를 알면 전체 공정 분류 프로세스의 정확도를 얼마나 개선할 수 있는지를 시뮬레이션을 통해 보인다.

2. 관련 연구

2.1 공정 관리 자동화

공정 관리를 자동화하기 위한 시도는 꾸준히 이뤄져 왔다. Kopsida et al. (2015)에서는 공정 자동 관리를 정보 취득(Data Acquisition), 정보추출(Information Retrieval), 공정률 예측(Progress Estimation), 그리고 시각화(Visualization) 이렇게 총 4가지 단계로 나누어 설명한다. 본 연구의 저자들은 이에 의사 결정(Decision Making)을 추가하여 공정 관리 자동화를 하나의 완성된 피드백 루프(Loop)로 생각하며, 이는 다음 (Fig. 1)에서 확인할 수 있다.

먼저, 정보 취득이란 건설 현장에서 정보를 수집하고 이를 데이터베이스로 전송하는 프로세스를 통칭하는 말이며, 수집하는 정보의 종류와 이러한 정보를 수집하는 방법, 수집하는 방법의 고도화 등 여러가지 방면으로 연구가 이루어지고 있다. 건설현장에서 수집할 수 있는 정보의 종류에는 사진이나 동영상 같은 시각적 정보나 작업반장 등의 인력이 작성하는 정성적 정보 등이 있다. 다음으로, 이러한 정보를 수집하는 방법에는 이미지(Rebolj et al., 2008; Ibrahim et al., 2009), 레이저 스캐닝(Hajian and Becerik-Gerber, 2010), RFID(Hammad and Motamedi, 2007) 등이 있다. 수집하는

방법의 고도화는 수집 방법이 얼마나 자동화되었는가를 의미하는데, 사람이 직접 사진이나 레이저 스캐너 등으로 수집하는 것이 수동적인 수집의 방법이다. 수집 방법을 고도화하기 위해 지상 로봇(Kim et al., 2018)을 사용하기도 하고, 드론(Dupont et al., 2017)을 사용할 수도 있다. 이 둘을 연동하여 정보수집의 질을 높이려는 시도도 있다(Asadi et al., 2020). 다만, 드론을 사용하는 정보수집 연구는 드론 실내 주행의 어려움과 실내에서 자율 주행의 어려움 등으로 인해 실증 연구가 활발하게 이루어지지 않고 있다.

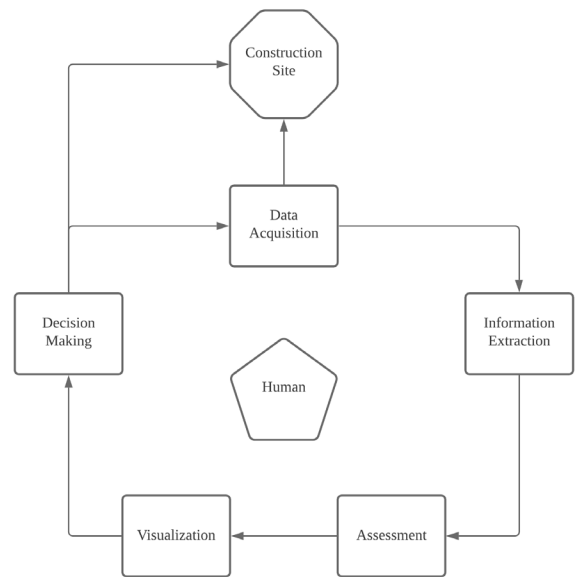


Fig. 1. Automated progress monitoring pipeline

정보추출은 획득한 데이터에서 유의미한 정보를 발굴해 내는 과정이다. 예를 들어, 로봇이 건설 현장을 돌아다니면서 촬영한 사진이나 레이저 스캔 등을 가지고 포인트 클라우드(Point Cloud)데이터(Wang et al., 2020)를 합성하는 작업을 생각할 수 있다. 포인트 클라우드는 어떤 공간의 외벽과 내벽을 수없이 많은 점(Point)으로 사상(Mapping)하여 공간의 구조 등을 시각화하거나 데이터화 하는 기술을 의미한다. 포인트 클라우드로 BIM상에 존재하는 건설 현장의 정보와 실제 건설 현장의 정보를 양방향으로 사상(Wang et al., 2015)하여 이후에 건설 현장에서 발생하는 데이터와 관련된 정보의 위치, 사진 등에 포함된 공중, 또는 물체를 자동으로 추론할 수 있게 하는 것이 정보추출에서 가장 중요한 기술 중 하나이다. 또한, 현장에서 얻은 이미지를 자동으로 애노테이트(Annotate)하는 것도 정보추출의 한 예이다. 이처럼 정보추출은 날 것의 정보에 의미를 부여하는 작업을 의미한다.

다음으로 추출된 정보를 가지고 공사 프로젝트, 더욱 구체적으로는 공정률에 대해 평가(Assessment)를 해야 한다. 이

를 평가하기 위해서는 계획 공정표(As-planned)를 등록하고, 이예다가 공사가 진행되는 도중 추출된 정보(As-built)를 적용해야 한다. 이처럼 두 가지 정보(계획과 실제)를 동시에 보여주기 위해서는 시각화가 중요해지는데, 이는 시각화가 사람이 복잡한 정보를 이해할 때 큰 도움이 되기 때문이다. 특히 두 가지 정보를 동시에 보여주는 데에는 증강 현실(Augmented Reality)이 효과적이며(Fard and Pena-Mora, 2007), 이와 관련해 다양한 연구가 진행되어왔다(Kopsida et al., 2015).

마지막으로, 의사 결정은 공정 관리에 있어서 가장 중요한 부분이다. 공사 프로젝트에 영향을 미치게 되는 결정적인 프로세스이기 때문이다. 의사 결정을 더욱 쉽게 하고, 더 나아가 인공지능을 통해 의사 결정을 하려는 노력이 이루어지고 있지만 의사 결정은 고도의 지능이 필요한 작업인 만큼 건설 분야를 넘어선 여러 분야의 발전이 이루어져야 그 가능성을 논할 수 있다. 현재로서는 (건설 현장에서의) 의사 결정자가 의사 결정을 더욱 쉽게 하려고 다양한 IoT 장비에서 얻은 정보를 활용하는 방법(Louis and Dunston, 2018), BIM 정보를 사용해서 위험요소를 식별하는 데 도움을 주는 연구(Kim et al., 2018) 등이 있다.

자동화에는 단계가 있다. 자동화가 없는 완전 수동부터 사람이 조금씩만 개입하는 부분 자동화, 그리고 사람이 필요 없는 완전 자동화까지. <Fig. 1>의 5개의 프로세스는 시계 방향으로 돌아가면서 자동화의 어려움이 커진다. 시계 방향으로 돌아갈수록 처리해야 하는 정보가 복잡해지고, 수행해야 하는 작업도 난이도가 높아진다. 따라서 공정 관리 자동화를 이루기 위해서는 단계별로 사람이 프로세스의 다양한 방면에서 개입하는 부분 자동화의 방향으로 나아가는 것이 바람직하다고 보인다.

2.2 이미지를 이용한 공중 판별

건설 현장에서는 방대한 양의 이미지가 발생한다. Han and Golparvar-Fard (2017)이 조사한 바에 따르면, 건축 면적 약 70,000m² 이하의 일반적인 건설 프로젝트에서 건설 프로젝트의 총 기간 동안 평균적으로 400,000장 정도의 이미지가 생성된다고 한다. 이는 데이터 수집 자동화 등을 위한 무인 항공기나 지상 데이터 수집 로봇 같은 장비에서 생성될 수 있는 정보를 제외한 수치이다.

건설 프로젝트에서 이미지는 다양한 사용처가 존재한다. 발생하는 이미지를 잘 관리하고, 잘 활용하면 여러 가지 건설 관리 업무에 도움이 되거나 이를 더 쉽고 빠르게 할 수 있다. 이미지는 공중 판별과 공정 관리(Rebolj et al., 2008; Ibrahim et al., 2009)에 필수적인 정보이다. 또한, 생산성 추적(Yang et al., 2015)이나 안전상태 점검(Wu et al., 2019) 등

인적자원을 관리하는 업무에도 사용할 수 있으며 추후 분쟁 중재(Kangari, 1995) 등의 법적 사용처에 근거자료로 사용할 수도 있다.

이미지를 어떤 작업에 사용하는가의 이면에는 이미지를 어떻게 사용하는가에 대한 이해 또한 중요하다. 때때로 이미지는 그 자체로써 의미가 없을 수 있다. 그 이미지에서 추출한 새로운 정보가 가치를 가질 때가 많기 때문이다. 예를 들어, H빔이 찍힌 사진이 있다고 가정해보자. 이 이미지를 서술하는 정보인 "H빔이 찍힌 사진"이라는 말이 없다면 이 이미지는 단순히 RGB값의 행렬일 뿐 그 이상의 가치를 지니지 않는다. 이처럼 아무런 의미가 없는 이미지가 무엇을 포함하는 이미지인지로 분류하는 것이 바로 이미지 분류(Image Classification)이다. 단지 이미지가 무엇을 포함하는지를 넘어 이미지상에 어떤 위치에 무슨 물건이 있는지를 알고 싶을 때도 있다. 예를 들어, 이미지상에 인부가 어디 어디에 자리 잡고 있는지를 감지하는 문제는 객체 검출(Object Detection)이라는 문제의 한 응용이다.

3. 문제의 정의 및 연구의 방법

본 단원에서는 이미지를 사용해 공중을 분류하는 시스템을 보조하기 위해 공중 간 선·후행 관계를 어떻게 사용하는지를 설명하고, 이런 선·후행 관계가 어떤 데이터 구조(Data structure)로 표현되어 있는지를 보여준다. 또한, 문제의 직관적인 이해를 돕고 성능 향상의 사례를 보여주기 위한 장난감 문제를 설정한다.

3.1 공중 판별 시스템에 대한 이해

이미지를 이용해 공중을 분류하는 일은 분류기(Classifier)에 의해서 이루어진다. 가장 기초적인 이미지 분류기는 단일 표현(Single Representation)의 정보를 입력받는다. 이미지를 이용한 공중 분류기는 이미지만을 입력받는 것이다. 하지만, 본 연구에서는 이러한 이미지를 입력으로 하는 이미지 분류기의 예측값 \hat{y} , 공중 선·후행 관계(Dependency), 그리고 이 선·후행 관계에 존재하는 공중 중 최소한으로 완료된 공중(Cursor)을 입력으로 하는 새로운 판별기(Predictor, 본 연구에서는 classifier 과 구별하기 위해 판별기로 명명)를 만들고, 이를 사용해 최종 공중 판별의 정확성을 향상시키는 것을 목표로 한다. 또한, 이를 통해 얼마만큼의 성능 향상을 기대할 수 있는지를 분석한다. 이 관계는 <Fig. 2>에서 볼 수 있다.

3.1.1 가짜 분류기(Pseudo Image Classifier)

현대의 이미지 분류기는 통상 CNN을 사용한다. 합성곱(Convolution operation)을 이용해 신경망의 레이어에서 레

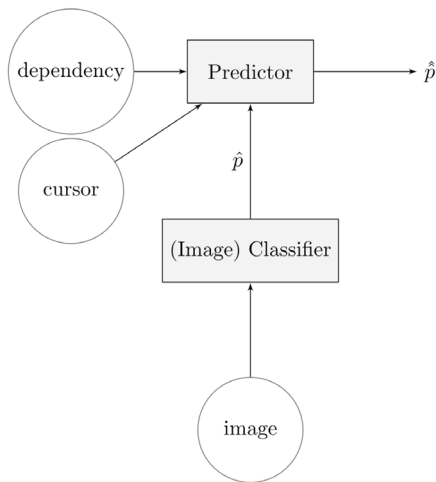


Fig. 2. Overall pipeline of an enhanced work trade predictor

이러한 정보를 변환하고 전파(transform & propagate)하는 특징 추출기(Feature extractor)가 이미지 데이터셋에 존재하는 이미지들의 속성(Attribute)을 잘 포착하고, 이를 사용해 입력된 이미지가 어떤 클래스에 속하는지를 Classifier(본 연구에서 사용되는 명칭 classifier과 의미하는 범위가 다름)이 훌륭하게 학습하기 때문이다. 이러한 CNN을 학습시키기 위해서는 통상 대규모의 데이터셋이 필요하다. 한 예로 컴퓨터 비전 분야에서 기념비적인 데이터셋인 ImageNet (Deng et al., 2009)에는 14,197,122장의 이미지가 있다. 하지만 우리는 공종에 대한 거대한 데이터셋을 보유하고 있지 않기 때문에 CNN을 학습시키는 데 큰 어려움이 따른다. 따라서 이를 대체할 가짜 분류기가 필요하다.

데이터셋의 부재 등의 이유로 공종 분류기를 개발하지 않은 관계로 다른 이미지 데이터셋에 대해 훈련된 이미지 분류기를 본 연구에 사용하고, 이를 가짜 분류기로 명명한다. 이미지 데이터셋은 그 종류에 따라 속성이 크게 다를 수 있다. 직관적인 예를 들어 동물을 포함하는 이미지 데이터셋과 인공적인 물체(Man-made)로 이루어진 데이터셋의 이미지적 특성을 다르다는 것을 생각할 수 있다. 자연에서 발생한

물체들은 대체로 곡선을 많이 포함하는 반면에 인공적인 물체들은 대부분 직선으로 이루어져 있기 때문이다. 이와 같이 공종 이미지 데이터셋도 타 이미지 데이터셋과 이미지 특성이 다를 가능성이 농후하다. 이에 복잡하지 않은 MNIST (LeCun and Cortes, 2010) 이미지 데이터셋을 사용해 가짜 이미지 분류기를 학습시킴으로써 이미지 데이터셋에 대한 가정을 최소화한다.

본 연구에서는 MNIST 데이터셋에 대해 AlexNet 아키텍처를 사용하는 가짜 이미지 분류기를 훈련시켰다. 단일 아키텍처로 총 4가지의 정확도(0.52, 0.64, 0.78, 0.9)를 가지는 모델을 만들었는데, 이는 실제 현장에서 날씨나 이미지 상태의 불규칙성 때문에 이미지 분류기의 성능이 다를 수 있음을 반영하기 위함이다. 마지막으로 위에 4개의 모델을 학습할 때, 서로 다른 성능을 가지는 모델을 만들기 위해 모델마다 하이퍼-파라미터(Hyper-parameter)를 다르게 해서 학습시켰다. 자세한 내용은 3.2에서 논한다.

3.1.2 선·후행 관계(Relationship) 그래프와 커서(Cursor)

공공간의 선·후행 관계는 <Fig. 3>에서 볼 수 있듯이 유방향 비순환 그래프(Directed Acyclic Graph; DAG)의 구조를 사용해서 표현할 수 있다. 유방향 비순환 그래프란, 정점(vertex)와 정점을 연결하는 간선(edge)에 방향성이 존재하고, 순환성이 없는(순환성이 없다면 어떠한 정점을 출발해 나왔을때 다시는 그 정점으로 돌아갈 수 없다) 그래프를 의미한다. 실제 공종 선·후행 관계에서는 고립된 정점 혹은 서브 그래프(Isolation)가 존재할 수 있으나, 본 연구에서는 고립이 없는 것을 가정한다. 이를 공정표에 대입하여 생각하면 주공정선만 고려했다는 것으로 이해할 수 있다.

커서는 판별의 순간에 최소 어디까지 공사가 진행되었는지에 대한 정보이다. 여기서 말하는 최소란 커서가 불완전한 정보일 수 있음을 고려하는 것이다. 선·후행 관계 정보는 커서 없이 공종 판별에 아무런 도움도 줄 수 없다. 커서가 있어야 공종 판별을 수행하는 데 있어 고려해야 할 클래스의 정

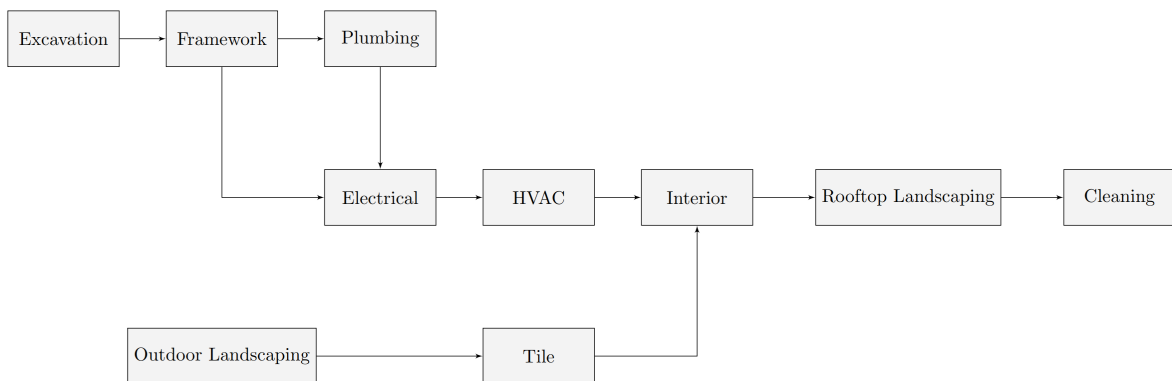


Fig. 3. Toy dependency graph

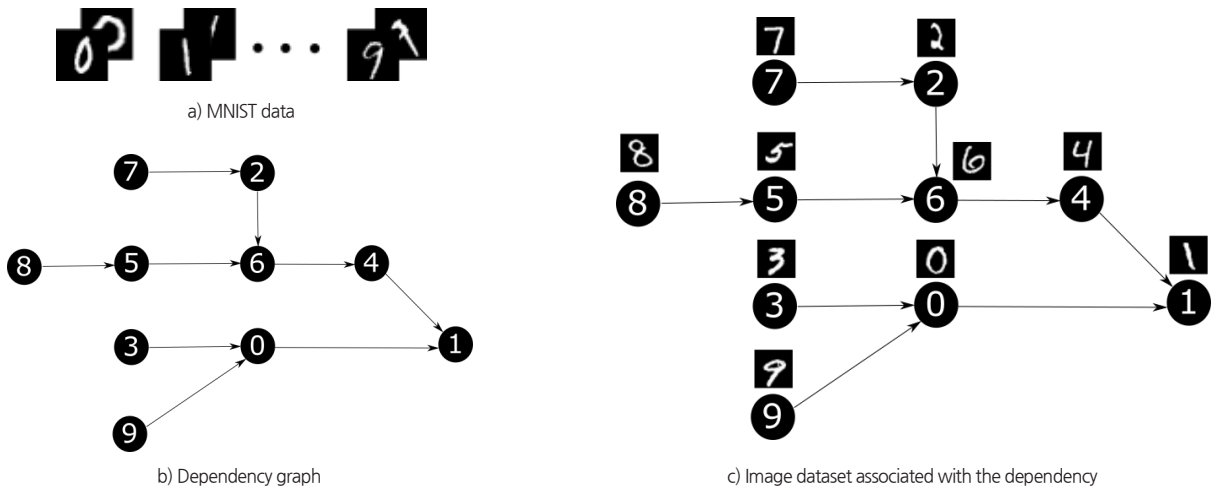


Fig. 4. Dependency graph and image dataset association

보가 줄어들고, 따라서 올바른 판별을 할 가능성이 커지기 때문이다. 일반적으로, 커서가 최후의 작업에 가까우면 가까워질수록 더욱 높은 판별 정확도를 관측할 수 있고, 가장 처음에 있으면 아무런 정확도의 향상을 관측할 수 없다. 극단적인 예로 마지막 공정만을 남겨놓고 있는 현장을 생각할 수 있다. 이러한 현장에서 촬영된 사진은 마지막 작업일 가능성이 거의 100%에 가까울 것이다. 따라서 판별기는 위 작업을 판별하는데 실수를 할 가능성이 거의 없어진다. 선택지가 하나 남아있기 때문이다.

본 연구에서 사용하는 데이터셋은 10개의 클래스를 가지고 있다. 따라서 선·후행 관계 그래프에서 정점의 개수도 10개로 데이터셋의 클래스랑 1대 1 사상이 되어야 한다. 만약 선·후행 관계와 MNIST 데이터셋을 연동한다면 다음 (Fig. 4) 같은 관계도를 볼 수 있다. 여기서 보면 아무런 선·후행 관계를 가지고 있지 않던 숫자 이미지 데이터셋 (Fig. 4(a))에 선·후행 관계 (Fig. 4(b))가 부여되어 (Fig. 4(c))의 형태를 갖추었다.

3.1.3 판별기 (Predictor)

먼저, 본 연구에서 분류기(Classifier)와 판별기(Predictor)라고 부르는 프로세스에 대한 혼란을 방지하기 위해 부연설명을 가미한다. 분류기와 판별기는 궁극적으로 수행하는 작업이 같은데, 그 작업은 입력받은 정보를 이용해 그것이 무슨 공종인지에 대한 확률 벡터를 출력하는 일이다. 따라서 분류기의 출력과 판별기와 출력은 동일하다고 볼 수 있다. 하지만 서로 다른 이 두 개의 프로세스는 입력되는 정보에 그 차이가 있는데, 분류기는 이미지를 입력 데이터로 하고 판별기는 분류기가 출력하는 확률 벡터와 공정의 선·후행 관계, 그리고 선·후행 관계상의 커서를 입력으로 하는 것이다. 또한 분류기는 CNN으로, 학습의 대상이고 판별기는 단순 알고리즘으로 학습할 필요가 없이 정해진 작업을 수행하

는 프로세스이다.

분류기에서 설명하여야 할 것은 어떻게 분류기가 서로 다른 정보를 합산하여 판단을 내리나에 대한 것이다. 본 연구에서는 가장 직관적이고 간단한 방법으로 이를 합산한다. 이는 예를 통해서 이해하는 것이 가장 쉽다. 가령 두 가지 공종 A와 B가 있다고 가정하고 선·후행 관계는 A->B라고 하자. 만약 커서가 A에 있다면 어떠한 사진을 주어도 그것은 A 공종의 사진이 아닐 것이다. 왜냐하면, A 공종은 이미 끝났기 때문이다. 이처럼, 분류기는 판별기가 출력한 확률 벡터에서 완료된 공종에 해당하는 값을 제거하고, 이 공종들에게 분배되어 있던 확률값들의 합을 살아남은 공종의 확률에 분배한 다음 가장 큰 값을 가진 공종을 최종 답안으로 선택한다. 분류기의 정확히 어떠한 작업을 하는지는 (Fig. 5)의 도식에서 찾아볼 수 있다.

ALGORITHM 1: Predictor procedure

```

Input : P – Probability vector of an image output by an image classifier
       D – Dependency information
Output: y – A prediction of a class that an input image belongs to
1 r ← 0 /* probability residual to be redistributed to probabilities of incomplete
tasks */
2 i ← 0 /* task counter */
3 j ← 0 /* number of completed tasks */
4 d ← 0 /* amount of probability to be distributed to incomplete tasks'
probabilities */
5 for p ← P do
6 c ← TASKCOMPLETE(D, i) /* determines whether a task is complete or not.
Returns true if a task is complete */
7 if c == true then
8 r ← P[i] /* accumulate residual probability */
9 P[i] ← 0 /* probability of an image belonging to class indexed i becoming
0, because the task is already completed. */
10 j ← j + 1
11 end
12 i ← i + 1 /* update task counter */
13 end
14 d ← r / (len(P) - j) /* Value to be distributed to probabilities of incomplete tasks
*/
15 i ← 0 /* task counter reset */
16 for p ← P do
17 c ← TASKCOMPLETE(D, i) /* determines whether a task is complete or not.
Returns true if a task is complete */
18 if c == false then
19 | P[i] ← d /* distribute residual probability */
20 end
21 i ← i + 1 /* update counter */
22 end
23 y ← argmax(P) /* return final prediction */
    
```

Fig. 5. Predictor procedure

3.2 연구의 방법

위에서 설명하였듯 우리는 MNIST 데이터셋에 대해 총 4개의 서로 다른 정확도를 가지는 이미지 분류기 모델을 학습시켰다. 모델의 성능은 MNIST의 테스트셋에 대해 테스트를 진행했을 때의 결과값을 의미한다. 모든 모델의 아키텍처는 같지만, 학습 Epoch와 Learning Rate를 다르게 하여 서로 다른 성능을 가진 간단한 CNN 모델을 학습시켰다. 모델들의 성능과 모델들을 학습할 때 사용한 하이퍼-파라미터는 <Table 1>과 같다. Model 1과 Model 2는 기록된 성능은 다른데 하이퍼-파라미터는 같다. 이러한 결과가 나온 것은 같은 하이퍼-파라미터를 사용하더라도 학습의 결과가 항상 같지 않은 신경망 학습의 비결정적(Non-deterministic)인 성격 때문이다.

Table 1. Classifier models

Model ID	Model Performance	Epoch	Learning Rate
Model 0	52%	1	0.2
Model 1	64%	1	0.1
Model 2	78%	1	0.1
Model 3	90%	2	0.01

다음으로, 선·후행 관계를 사용했을 때 성능의 증감을 시험하기 위해 다수의 DAG 그래프를 무작위로 생성시켰다. DAG 그래프는 다시 또 3개의 군집으로 나누었다. 그래프 군집은 <Table 2>에서 확인할 수 있다.

Table 2. Graph group details

Group	Max. Out-degree	Num of Instances
A	1	100
B	2	100
C	3	100

출력 차수(Out-degree)란 유방향 그래프에서 어떠한 정점에서 나오는 간선의 개수를 의미한다. 최대 출력 차수가 2개라는 소리는 하나의 정점에서 1개 또는 2개의 간선이 나올 수 있음을 의미하고 간선이 나오지 않을 수는 없다. 고립이 없는 그래프를 가정하기 때문이다. 간선의 개수가 다른 그래프 군집을 설정하는 것의 의미는 서로 다른 특성이 있는 공정표를 고려할 수 있는 데 있다. 쉽게 접할 수 있는 공정표들을 살펴보면 대부분 정점에서의 출력 차수가 1인 경우가 많다. 하지만, 특수한 공사의 경우 출력 차수가 높은 공종이 많을 수도 있어서 이렇게 서로 다른 특성이 있는 그래프 군집을 설정한 것이다.

3.3 장난감 문제를 이용한 실증 연구

좀 더 현실과 가까운 예제를 통해 공종 판별 성능향상의 직관적인 이해를 돕기 위해 <Fig. 3>의 공종 선·후행 관계 그래프를 가지고 본 연구가 제시하는 방법을 검증해 보았다. <Fig. 3>의 선·후행 관계에는 총 10개의 공종이 존재하며, 이를 MNIST의 숫자에 <Table 3>과 같이 배정하였다. MNIST의 숫자와 커서의 숫자가 대응되도록 구성하였다.

Table 3. Work trade allocation

Work Trade	MNIST Class (Cursor ID)
Excavation	0
Framework	1
Plumbing	2
Electrical	3
Outdoor Landscaping	4
HVAC	5
Tile	6
Interior	7
Rooftop Landscaping	8
Cleaning	9

4. 결과

우리는 개별적으로 3개의 그래프 군집에서 판별기의 성능 향상을 살펴볼 것이다. 그래프 군집 A는 출력 차수가 1을 초과하지 않는 그래프로 이루어져 있고, 그래프 군집 B는 출력 차수가 2를 초과하지 않는 그래프로 이루어져 있다. 그리고 마지막으로 군집 C는 출력 차수가 최대 3인 그래프로 이루어져 있다. 출력 차수가 높으면 높을수록 그래프가 복잡해지고, 이는 더욱 복잡한 공정표에 상응하는 그래프가 되는 것이다. 따라서 세 개의 그래프 군집에 대한 성능 비교를 통해 공정표의 복잡성에 따른 성능의 향상 또는 감퇴를 관찰할 수 있다.

다음으로는 모델별 성능향상을 비교한다. 모델별 성능향상의 정도를 살펴보면 실전에서 서로 다른 성능을 내는 이미지 분류기에 공정의 선·후행 관계 정보를 사용하면 어느 정도의 성능향상을 기대할 수 있는지를 알 수 있다.

마지막으로는 더욱 쉬운 이해를 위해서, 장난감 문제에서 커서의 위치에 따른 판별기의 정확도를 면밀하게 살펴보면 서 마무리 지을 것이다.

4.1 그래프 군별 결과

그래프 군별로 성능의 차이를 확인하면 어떠한 그래프군에서 더 큰 성능향상을 관측할 수 있었는지를 알 수 있다.




Fig. 6. Result comparison among different graph groups

〈Fig. 6〉에 있는 각각의 커널 밀도 함수들은 각 그래프 군에 속하는 100개의 서로 다른 그래프에 대해 테스트한 4개의 모델의 성능향상의 정도를 보여준다. X축은 성능향상의 정도를, Y축은 그 성능향상 정도가 관측된 빈도수를 사용해 추측된 밀도를 나타낸다. Y축의 값이 크면 클수록 관측될 확률이 높은 것이다.

〈Fig. 6(a)〉에서 〈Fig. 6(c)〉로 갈수록 그래프의 복잡도가 증가함에 따라 모델 0, 1, 2, 3의 밀도 함수가 수평으로 넓게 퍼지고, 중간값이 양의 방향으로 이동하는 것을 볼 수 있다. 이런 변화는 선·후행 관계 그래프가 복잡하면 복잡할수록 공중 판별의 성능향상의 폭이 커지고, 평균적인 성능 향상도 커진다는 것을 의미한다. 이를 통해 본 연구에서 제시하는 방법은 공정이 복잡한 건설 프로젝트에 더욱 유리하다는 것을 알 수 있다.

4.2 모델별 결과

〈Fig. 6〉의 모든 밀도 함수에서 우리는 성능이 떨어지는 CNN 모델을 사용했을 때보다 성능이 좋은 CNN 모델을 사용했을 때의 함수가 더욱 붓긋하고, 반대로 성능이 떨어지는 모델은 평평해진 것을 알 수 있다. 밀도 함수가 붓긋하다는 것은 같은 그래프 군집 안에 있는 그래프와 그래프 간에 성능 향상의 폭이 적다는 것을 의미한다. 이는 쉽게 이야기하면 성능 향상이 작다는 것이다. 따라서 우리는 성능이 떨어지는 이미지 분류기에 본 연구에서 제시하는 방법을 적용하면 더욱 큰 효용이 있을 것이라고 예상할 수 있다.

4.3 장난감 문제 결과

〈Table 4〉에서는 총 4개의 이미지 분류기 모델을 가지고 〈Fig. 3〉의 선·후행 관계 그래프를 〈Table 3〉와 같이 MNIST 이미지 데이터셋과 연동한 다음 이미지 판별기의 성능이 얼마나 향상되었는지를 보여준다. 〈Table 4〉의 Original 열은 이미지 분류기 모델의 성능, Enhanced 열은 판별기의 성능, 그리고 Diff. 열은 이 둘의 차이를 나타낸다.

마지막으로 Eliminated는 판별시 보여지지 않는 이미지의 수를 의미하며 위에서 언급하였듯이 테스트셋의 이미지 수는 총 10,000개이다.

먼저, 모든 모델은 커서가 0에 있을 때, 즉 Excavation 공종도 완료되지 않은 상태일 때 선·후행 관계를 통해 성능향상을 볼 수 없다. 고려해야 할 공종의 수에 변화가 없기 때문이다. 하지만, 커서가 1에 있을 때, 즉 Excavation이 끝난 것을 아는 상태에서는 모델 0부터 3까지 각각 대략 -3%, -3%, -0.08%, -0.06% 정도 성능의 하락이 관측되는 것을 알 수 있다. 이와 반대로, 커서가 7에 있을 때, 즉 Interior가 끝난 것을 아는 상태에서는 3%, -10%, 13%, 3%의 성능향상을 관측할 수 있다. 이처럼 커서의 위치에 따라 성능이 등락하는 이유는 고려해야 하는 공종의 수가 달라지기 때문이다. 대체적으로, 커서가 공정표의 끝으로 가면 갈수록 성능의 향상이 커지는 것을 알 수 있다.

다음으로, 같은 커서인데도 사용하는 이미지 분류기의 모델마다 성능의 차이가 있는 것을 관찰할 수 있다. 예를 들어 커서가 7에 있을 때, 모델 1은 성능 저하가 심한 반면에 모델 2는 성능향상이 크다. 이와 같은 현상은 이미 완료되었다고 아는 공종들에 대한 이미지 분류 성능이 각기 다를 수 있기 때문이다. 극단적인 예를 들어, 어떠한 모델이 Interior 이전의 공종들에 대한 분류 성능은 100%이고, Interior 이후 공종들에 대한 분류 성능은 0%라고 가정해보자. 만약 커서가 7에 있다면 이 모델을 사용한 판별기의 성능은 0%가 될 것이다. 왜냐하면, 이 모델이 유리한 Interior 이전 공종 이미지는 보여지지 않기 때문이다.

결과를 더 살펴보자면 커서가 0일 때와 4일 때 아무런 성능향상이 없는 것을 관찰할 수 있다. 커서가 0일 때와 4일 때는 공정표에서 아무런 완료 정보가 없을 때이기 때문에 이와 같은 수치를 볼 수 있는 것이다. 다음으로, 커서가 끝부분에 있을 때는 향상된 성능이 모두 최고치인 것을 알 수 있다. 이는 판별기가 선택해야 하는 선택지의 수가 1개밖에 남지 않았기 때문에 오류를 낼 수 없기 때문이다.

5. 결론

5.1 결과에 대한 고찰

우리는 MNIST 이미지 데이터셋과 랜덤으로 발생시킨 존재 가능한 다양한 공정표를 결합하여, 만약 공중 이미지 분류 시스템이 있을 때 추가로 이에 상응하는 공정표가 있다면 공중 판별에 성능향상을 기대할 수 있을지 없을지에 관한 연구를 시행하였다. 결과를 살펴보면 대체적으로 성능의 향상을 관측할 수 있다는 것을 알 수 있다. 하지만, 성능이 이미 좋은 이미지 분류기를 기초 분류기로 사용하는 판별기에서는 의미 있는 성능향상을 체감할 수 없었는데, 선행 연구에서 공중 이미지 분류기의 성능이 90%를 쉽게 넘는 것을 고려했을 때, 본 연구에서 제시하는 방법은 촬영 이미지 자체의 질이 떨어져서 이미지 분류기의 성능이 떨어지는 현상이나, 악천후 등의 이유로 이미지에 노이즈가 많은 경우에 보조수단으로 사용될 수 있을 듯하다. 추가적으로, Jeong (2020)에서 제시하는, 노이즈가 심한 이미지를 분류하는데 유리한 CNN을 공중 분류기로 사용한다면 더욱 큰 성능향상 또는 성능 보존을 경험할 수 있을 수도 있다.

5.2 가정과 한계

본 연구는 다음을 가정하고 있다. 다음 가정들은 본 연구가 현실에서의 문제 해결과 상이한 점을 보여주며 동시에 연구의 한계를 초래한다. 먼저 본 연구에서는 공정표에 대한 정보와 판별기가 받는 정보에 대해 가정을 하는데, 그 첫 번째는 공중을 판별할 때, 최소한 어디까지의 공사가 끝났는지에 대한 커서를 안다는 것이다. 즉, 공중 판별기가 항상 공사의 진행 상황에 대한 지식이 어느 정도 이상 있다는 것을 뜻하는 것이다. 현실에서 항상 어떤 정보를 완전히 지각하고 있다는 것은 강력한 가정이다. 실전에서는 정보의 불확실성, 허위 정보 등의 이유로 정보의 무결성을 보장하기 힘들기

때문이다. 다만, 건설관리학 측면에서는 우리는 계획된 공정에 의하여 공정의 순서가 정의되고 관리될 수 있다는 점을 고려할 수 있고, 이러한 계획된 공정 정보를 통하여 공중 판별의 성능을 높일 수 있는 가능성을 염두 할 수 있다.

다음으로, 본 연구는 이미 끝난 공중이 까짜 판별기에게 보여지지 않는다는 가정을 한다. 이는 현실에서 항상 성립하지는 않는다. 이러한 가정을 다시 이야기하면 데이터의 순서가 있다(Ordered)는 것을 의미한다. 이미지가 공정표에 따라 순서가 정렬되어있지 않는 상황에서는 본 연구에서 제안하는 방법이 효용을 가지지 못한다. 반면에, 공사 프로젝트가 진행됨에 따라 발생하는 사진을 가지고 공중을 판별할 때, 본 가정은 유의미한 가치를 지닌다. 예를 들어서 철근 배근, 거푸집 설치, 콘크리트 타설 3가지의 공중이 있는 공정표를 생각해보자. 철근 배근이 모두 끝나고 거푸집 설치 작업을 수행하고 있는 도중 수집할 수 있는 사진은 철근 배근 작업일 수가 없다.

마지막으로, 본 연구에서는 MNIST 데이터셋을 가지고 훈련한 이미지 분류기를 공중 이미지 데이터셋을 가지고 훈련한 이미지 분류기라고 가정한다. 어떠한 분류기를 학습했을 때, 이 분류기는 데이터셋 안의 클래스마다 상이한 정확도를 가질 수 있다. 예를 들자면, 호랑이를 분류하는 것에 대한 정확도가 돌고래를 정확하게 분류하는 정확도보다 낮을 수 있는 것이다. 이런 불균형은 여러 가지 이유로 발생할 수 있다. 데이터셋의 클래스 불균형(Class imbalance) 때문일 수도 있고, 각 클래스에 해당하는 객체의 이미지 복잡도 또는 분류 난이도가 높을 수도 있다.

각 클래스 별의 차이를 넘어, 공중 이미지 간에는 상관관계가 존재한다. 예를 들어 콘크리트 타설과 콘크리트 양생 두 작업은 상대적으로 이미지의 색감과 이미지에 등장하는 자재 등이 유사하다. 이처럼 유사한 두 클래스 간에는 오인 분류가 일어나기 쉽고, 이는 분류기가 출력하는 우도

Table 4. Toy problem results

Cursor	Model 0			Model 1			Model 2			Model 3			Eliminated
	Original	Enhanced	Diff.	Original	Enhanced	Diff.	Original	Enhanced	Diff.	Original	Enhanced	Diff.	
0	0.5181	0.5181	0	0.6417	0.6417	0	0.7761	0.7761	0	0.9078	0.9078	0	0
1	0.5181	0.4876	-0.0304	0.6417	0.6118	-0.0298	0.7761	0.7685	-0.0075	0.9078	0.9022	-0.0055	980
2	0.5181	0.4206	-0.0974	0.6417	0.5647	-0.0769	0.7761	0.7441	-0.0319	0.9078	0.8932	-0.0145	2115
3	0.5181	0.4209	-0.0971	0.6417	0.5571	-0.0845	0.7761	0.7266	-0.0494	0.9078	0.913	0.0059	3147
4	0.5181	0.5181	0	0.6417	0.6417	0	0.7761	0.7761	0	0.9078	0.9078	0	0
5	0.5181	0.4877	-0.0303	0.6417	0.5120	-0.1296	0.7761	0.7658	-0.0102	0.9078	0.9199	0.0121	4157
6	0.5181	0.5296	0.0115	0.6417	0.6199	-0.0217	0.7761	0.7701	-0.0059	0.9078	0.9105	0.0027	982
7	0.5181	0.5526	0.0345	0.6417	0.5360	-0.1056	0.7761	0.9093	0.1332	0.9078	0.9422	0.0344	6989
8	0.5181	0.5582	0.0401	0.6417	0.5138	-0.1278	0.7761	0.9520	0.1759	0.9078	0.9667	0.0589	8017
9	0.5181	1	0.4819	0.6417	1	0.3582	0.7761	1	0.2239	0.9078	1	0.0921	8991
	Average		0.0312	Average		-0.0217	Average		0.0428	Average		0.0186	

(Likelihood) 벡터에서 오인을 일으키는 클래스의 우도가 높게 나오는 상황을 초래한다. 어떠한 사진을 보여줬을 때 판별기는 그 사진이 속한 클래스와 비슷한 특성을 지닌 클래스로 잘못 분류할 가능성이 비슷하지 않은 특성을 지닌 클래스로 잘못 분류할 가능성보다 큰 것이다. 가짜 분류기는 이러한 MNIST의 애러빅 숫자 클래스 간 상관관계에 대한 정보를 학습하였다. 하지만 숫자 이미지와 공중 이미지는 서로 다르고 서로 다른 클래스 간의 상관관계도 다를 것이다.

이러한 클래스 간의 차이를 임의로 정의하거나 랜덤하게 발생시킬 수도 없는데, 클래스 간의 차이는 데이터셋의 내재한 분포와 특성의 일부이며, 이에 대한 가정은 곧 데이터셋에 대한 가정이 되기 때문이다. 따라서 본 연구에서는 클래스 간의 차이를 가정하지 않기 위해 무작위로 생성된 그래프에 대해 성능 검증을 진행한다. 또한, 가짜 분류기를 사용함으로써 발생하는 공중 이미지 분류기와 유사성을 줄이기 위해 우리는 다수의 시뮬레이션을 통해 결과물을 도출했다.

5.3 향후 연구의 방향

인공지능 시스템을 개발하는데 있어 서로 다른 여러 가지 정보를 같이 사용하는 것은 어렵다. 하지만, 어려움과 동시에 여러 가지의 다른 정보를 사용하는 것은 더욱 진보된 인공지능을 개발하는 데 있어 중요하다(Baltrušaitis et al., 2018). 따라서 공중 판별에서도 이미지만 사용하는 연구에서 더 발전하여, 다양한 주변 정보를 동시에 이용하는 방법을 탐구하거나, 본 연구와 비슷하게 BIM에서 얻을 수 있는 정보를 이용해서 판별의 성능을 향상시키는 노력을 기울여야 한다.

다음으로, 본 연구는 서로 다른 여러 특성을 지니고 있는 임의의 공정표를 자동으로 생성하여 연구를 수행하였다. 하지만, 본 연구에서 고려하는 공정표들의 특성과 실제 공사 현장에서 사용되는 공정표들의 특성은 다를 수 있는데, 향후에 실제 공정표를 사용해 연구를 하면 본 주제에 대해 더욱 깊이 탐구할 수 있을 것으로 보여진다.

공정표와 마찬가지로 본 연구에서는 실제 공중을 촬영한 사진이 아닌, 다른 이미지 데이터셋에 있는 이미지를 이미지 분류기에 학습시켜서 연구를 진행하였다. 추후에는 반드시 실제 공중 이미지를 사용해 연구해야 더욱 의미있는 연구로 거듭날 것으로 사료된다.

공중 판별을 기초로 하는 응용 분야에는 공정 진척률 판단이 있다고 언급한 바 있다. 본 연구에서 제시하는 방안을 공정 진척률을 판단하는 시스템을 개발하는데 있어 사용하는 연구도 하나의 방향이 될 것으로 보여진다.

마지막으로, 결과에서 선·후행 관계 정보를 사용하였을 때 성능이 하락하는 관측점이 몇몇 있었다. 추후에 이러한

이유를 밝히는 연구를 한다면 선·후행 관계를 이용한 공중 판별 연구에 큰 의미가 있을 것이다.

References

- Asadi, K., Suresh, A.K., Ender, A., Gotad, S., Maniyar, S., Anand, S., and Wu, T. (2020). "An integrated ugv-uav system for construction site data collection." *Automation in Construction*, 112, 103068.
- Baltrušaitis, T., Ahuja, C., and Morency, L.P. (2018). "Multimodal machine learning: A survey and taxonomy." *IEEE transactions on pattern analysis and machine intelligence*, 41(2), pp. 423-443.
- Deng, J., Dong, W., Socher, R., Li, L.J., Li, K., and Fei-Fei, L. (2009). "Imagenet: A large-scale hierarchical image database." In *2009 IEEE conference on Computer vision and pattern recognition*, pp. 248-255.
- Dupont, Q.F., Chua, D.K., Tashrif, A., and Abbott, E.L. (2017). "Potential applications of uav along the construction's value chain." *Procedia Engineering*, 182, pp. 165-173.
- El-Omari, S., and Moselhi, O. (2011). "Integrating automated data acquisition technologies for progress reporting of construction projects." *Automation in Construction*, 20(6), pp. 699-705.
- Fard, M.G., and Peña-Mora, F. (2007). "Application of visualization techniques for construction progress monitoring." In *Computing in Civil Engineering*, pp. 216-223.
- Gil, D., Lee, G., and Jeon, K. (2018). "Classification of images from construction sites using a deep-learning algorithm." *35th International Symposium on Automation and Robotics in Construction and International AEC/FM Hackathon: The Future of Building Things*, ISARC 2018.
- Hajian, H., and Becerik-Gerber, B. (2010). "Scan to bim: factors affecting operational and computational errors and productivity loss." In *27th international symposium on automation and robotics in construction*, pp. 265-272.
- Hammad, A., and Motamedi, A. (2007). "Framework for lifecycle status tracking and visualization of constructed facility components." In *7th international conference on construction applications of virtual reality*, pp. 224-232.
- Han, K.K., and Golparvar-Fard, M. (2017). "Potential of big visual data and building information modeling for construction performance analytics: An exploratory study." *Automation in Construction*, 73, pp. 184-198.
- Ibrahim, Y., Lukins, T.C., Zhang, X., Trucco, E., and Kaka, A. (2009). "Towards automated progress assessment of work package components in construction projects"

- using computer vision.” *Advanced Engineering Informatics*, 23(1), pp. 93-103.
- Jeong, S. (2020). *Investigating Noise Robustness of Convolutional Neural Networks for Image Classification Using Gabor Filters* (Doctoral dissertation, Vanderbilt University).
- Kangari, R. (1995). “Construction documentation in arbitration.” *Journal of construction engineering and management*, 121(2), pp. 201-208.
- Kim, K., Cho, Y., and Kim, K. (2018). “Bim-driven automated decision support system for safety planning of temporary structures.” *Journal of Construction Engineering and Management*, 144(8), 04018072.
- Kim, P., Chen, J., and Cho, Y.K. (2018). “Slam-driven robotic mapping and registration of 3d point clouds.” *Automation in Construction*, 89, pp. 38-48.
- Kopsida, M., Brilakis, I., and Vela, P.A. (2015). “A re-view of automated construction progress monitoring and inspection methods.” In *Proc. of the 32nd cibw78 conference 2015*, pp. 421-431.
- LeCun, Y., and Cortes, C. (2010). *MNIST handwritten digit database*. <http://yann.lecun.com/exdb/mnist/>. Retrieved 2016-01-14 14:24:11, from <http://yann.lecun.com/exdb/mnist/>
- Louis, J., and Dunston, P.S. (2018). “Integrating iot into operational work flows for real-time and automated decision-making in repetitive construction operations.” *Automation in Construction*, 94, pp. 317-327.
- Navon, R. (2007). “Research in automated measurement of project performance indicators.” *Automation in Construction*, 16(2), pp. 176-188.
- Rebolj, D., Babić, N., Magdić, A., Podbreznik, P., and Pšunder, M. (2008). “Automated construction activity monitoring system.” *Advanced Engineering Informatics*, 22(4), pp. 493-503.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). “Rethinking the inception architecture for computer vision.” In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2818-2826.
- Tang, S., Sheldon, D.R., Eastman, C.M., Pishdad-Bozorgi, P., and Gao, X. (2019). “A review of building information modeling (bim) and the internet of things (iot) devices integration: Present status and future trends.” *Automation in Construction*, 101, pp. 127-139.
- Wang, C., Cho, Y.K., and Kim, C. (2015). “Automatic bim component extraction from point clouds of existing buildings for sustainability applications.” *Automation in Construction*, 56, pp. 1-13.
- Wang, Q., Tan, Y., and Mei, Z. (2020). “Computational methods of acquisition and processing of 3d point cloud data for construction applications.” *Archives of Computational Methods in Engineering*, 27(2), pp. 479-499.
- Wu, J., Cai, N., Chen, W., Wang, H., and Wang, G. (2019). “Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset.” *Automation in Construction*, 106, 102894.
- Yang, J., Park, M.W., Vela, P.A., and Golparvar-Fard, M. (2015). “Construction performance monitoring via still images, time-lapse photos, and video streams: Now, tomorrow, and the future.” *Advanced Engineering Informatics*, 29(2), pp. 211-224.
- Yeseol, K. (2019). “Automatic multi-label image classification model for construction site images (Unpublished doctoral dissertation).” Seoul National University Graduate School.

요약 : 이미지를 이용해 공중을 분류하는 작업은 건설 관리와 공정 관리와 같은 더욱 복잡한 어플리케이션에서 중요한 역할을 수행할 수 있다. 하지만, 공사 현장에서 수집한 이미지들은 항상 깨끗하지 않을 수 있고, 이와 같이 문제가 있는 이미지들은 이미지 분류기의 성능에 부정적인 타격을 입힐 수 있다. 이러한 가능성은 공중을 판별하는 시스템을 보조할 수 있는 데이터나 방법의 필요성을 부각한다. 본 연구에서 우리는 공중의 선후행 관계를 이용해 이미지 분류기를 보조하여 공중을 판별하는 시스템의 성능을 높이는 방법을 제시한다. 그리고 제시하는 방법이 공중 판별의 성능을 향상시킬 수 있다는 것을 보인다. 특히, 이미지 판별기의 성능이 좋지 않을 때 더욱 드라마틱한 성능의 향상을 경험할 수 있다는 것을 알 수 있었다.

키워드 : 이미지 분류, 딥러닝, 공정 관리, 건설 관리, 선후행관계
