

인공지능 기반 플랜트 도면 내 심볼 객체 자동화 검출

신호진*, 전은미*, 권도경**, 권준석**, 이철진*†

*중앙대학교 화학신소재공학부, **중앙대학교 소프트웨어학부

Automatic Recognition of Symbol Objects in P&IDs using Artificial Intelligence

Ho-Jin Shin*, Eun-Mi Jeon*, Do-kyung Kwon**, Jun-Seok Kwon**, Chul-Jin Lee*†

*School of Chemical Engineering and Materials Science, Chung-Ang University,

**School of Computer Science and Engineering, Chung-Ang University

ABSTRACT : P&ID(Piping and Instrument Diagram) is a key drawing in the engineering industry because it contains information about the units and instrumentation of the plant. Until now, simple repetitive tasks like listing symbols in P&ID drawings have been done manually, consuming lots of time and manpower. Currently, a deep learning model based on CNN(Convolutional Neural Network) is studied for drawing object detection, but the detection time is about 30 minutes and the accuracy is about 90%, indicating performance that is not sufficient to be implemented in the real world. In this study, the detection of symbols in a drawing is performed using 1-stage object detection algorithms that process both region proposal and detection. Specifically, build the training data using the image labeling tool, and show the results of recognizing the symbol in the drawing which are trained in the deep learning model.

초록 : P&ID(Piping and Instrument Diagram)는 플랜트의 장치 및 계장 정보를 집약적으로 담고 있는, 엔지니어링 핵심도면이다. 한 장의 P&ID에는 심볼로 표현된 수백 여개의 정보들이 존재하며, 이에 대한 디지털 전산화 작업이 수작업으로 진행되고 있어 많은 인력과 시간이 소요된다. 기존 연구들은 CNN 모델을 이용하여 도면 객체 검출에 성공하였으나, 도면 한 장당 약 30분, 인식률은 90% 정도로 현장에서 구현하기에는 부족한 성능이다. 따라서 본 연구에서는 영역 검출과 객체 인식을 동시에 처리하는 1-stage 객체 검출 알고리즘을 제안하였다. 이미지 레이블링 오픈소스 툴을 이용하여 학습 데이터를 구축하고 딥러닝 모델 학습을 통해 도면 내 심볼 이미지 인식 방법을 제안한다.

Key words : Imaged Drawing Recognition (이미지 도면 인식), Piping and Instrumentation Diagram (배관계장도), Artificial Intelligence (인공지능), Image Processing (이미지 처리), Neural network image recognition model (신경망 이미지 인식 모델)

1. 서론

1.1 P&ID의 정의 및 기능

P&ID(Piping and Instrumentation diagram)는 장치와 배관, 계장류의 연결, 공정의 흐름과 제어의 관계를 도식화한 것으로, 플랜트 산업의 핵심 도면이다. 업계별로 약간의 차이는 존재하나, 대부분의 산업에서는 정해진 규정에 따라 기호와 약어를 사용하여 각 기기에 대한 정보들이 도면에 표기된다. 이는 현장의 엔지니어가 프로세스에 대해 이해할 수 있게 하고 기계장치가 어떻게 연결되어 있는지 정보를 제공한다.

P&ID는 설계 단계 뿐 아니라 운영과 유지보수 단계에서까지 지속적으로 수정 및 관리된다. 그러나 현업에서는 도면을 픽셀화된 이미지나 PDF 형태로 공유되는 경우가 많아, 엔지니어링 회사에서는 P&ID 관리를 위해 다시 새롭게 그려내는 경우가 많다. 단순 반복적인 수작업을 통한 전산화작업은 인력소모와 업무의 비효율성을 야기시켜 업계의 생산성에 부정적인 요소로 작용된다. 이를 개선하기 위해서는 하드카피 형식으로 전달받은 도면을 CAD 형태의 P&ID 파일로 변환해주는 기술이 요구된다. 그 중에서도 도면을 구성하는 설계 정보를 자동으로 인식하는 전산화 모듈 개발이 필요하다.

1.2 선행 연구 사례

엔지니어링 도면들의 전산화 처리 작업에 많은 인력과 시간이 소모되는 문제를 해결하기 위해 최근에는 딥러닝 기술의 발전으로 최신 이미지 프로세싱 기술들을 접목하여 도면 자동 인식 기술을 개발하는 연구들이 시도되고 있다.

특히 이미지 분석에 최적화된 심층 신경망 중 하나인 Convolutional Neural Network(CNN)은 대용량의 이미지셋에 대해서 이미지 분류 알고리즘의 성능을 평가하는 대회인 ImageNet Large Scale Visual Recognition Challenge(ILSVRC)에 처음 도입되어 26%에 머물던 오류율을 16%까지 급격히 낮추었다. 2014년에 우승한 GoogLeNet(1)은 오류율 6.67%로 객체 인식과 분류에서 인간 수준의 성능을 보였다. 이후, You Only Look Once(YOLO)(2), Single Shot Detector(SSD)(3),

Region-CNN(R-CNN)(4) 등 다양한 객체 검출 알고리즘들이 개발되었다.

Yu et al.(5)는 적은 양의 데이터로 학습하고자 P&ID의 라인, 텍스트, 테이블, 심볼을 대상으로 Alexnet의 CNN모델(6)을 이용하여 객체의 유형에 맞는 이미지 전처리 단계와, 학습 데이터 구조 구축방법에 대한 방법론을 제시하였다. 그러나 9 개의 심볼 클래스에 대해서 90% 수준의 인식률과 30분의 검출시간의 성능을 보이는 모델을 개발하였다. 이는 현실 적용 측면에서는 다소 한계점이 있다.

따라서 본 연구에서는 타겟 심볼 클래스를 35개로 확장하였고, 실시간 객체 검출 기술에 활발히 적용되고 있는 YOLO9000(7) 모델을 적용하여 P&ID 내 심볼 객체 검출 테스트 결과를 보인다.

2. 본론

2.1 P&ID 내 심볼 이미지의 종류와 특성

P&ID 내 존재하는 심볼 이미지의 종류는 ①Equipment, ②Piping, ③Valve, ④Instrumentation 크게 4가지로 구분된다. P&ID 내 심볼들의 특성은 Vendor사 또는 설계사의 표준 지침을 따르기 때문에 프로젝트별로 일부 차이가 존재하나, 대부분의 설계사항에 대해서는 국제 규격을 따르므로 정형화가 되어있어 차이가 크지 않다. 다만 각각의 심볼들이 갖는 사이즈가 다양하여 딥러닝 모델 구현 시, 이에 대한 고려가 필요하다. 또한 각각의 도면들은 정적인 특성을 지니기 때문에 객체 검출에 용이하다. 뿐만 아니라 흰색 바탕에 흑색으로 표현되어 있어 경계구분이 복잡하지 않아 심볼 이미지 검출에 방해가 되는 요소가 많지 않다.

2.2 P&ID 내 심볼 객체 검출 모델

YOLO 알고리즘은 최신 이미지 검출 알고리즘 기술 중 하나로, 하나의 네트워크를 통해 객체의 위치와 클래스 분류를 동시에 인식하는 1-stage가 특징이다. 기존의 알고리즘들에 비해 비교적 빠른 검출 시간과 높은 정확도를 가지며, 다양한 도메인에서 좋은 성능을 보인다. 한편, 겹쳐진 객체에 대하여 예측 성능이 떨어진다는 단점이 있으나,

인공지능 기반 플랜트 도면 내 심볼 객체 자동화 검출

P&ID에는 심볼들이 중첩되어 그려지는 경우가 거의 없어 고려하지 않았다. Figure 1은 본 연구에 적용된 YOLO 알고리즘의 검출 시스템 구조이다.




Figure 1 The YOLO detection system⁽²⁾

2.3 P&ID 내 심볼 객체 검출 환경

Table 1은 데이터 학습 및 검출에 사용된 컴퓨터 환경과 테스트 도면에 대한 정보이다.

Table 1 Computer specification and P&ID drawings information

Hardware	CPU : Intel Xeon Gold 6132 @ 2.60GHz GPU : GeForce RTX 2080 11GB RAM : 32GB
Software	OS : CentOS Linux 7 CUDA : 10.0 Pytorch : 1.0.1
P&ID Drawings	P&ID : 상용 프로젝트 용 실제 도면 샘플 Size (pixel) : 8270 x 5847

2.4 P&ID 심볼 객체 검출 모델 학습

본 연구에서는, 알고리즘을 이용하여 딥러닝 모델 학습을 통해 35 개의 서로 다른 심볼을 분류할 수 있는 기술을 구현하였다. 학습에 사용된 도면의 개수는 20장이다. 인식 대상 심볼들에 대한 정보는 Table 2의 내용과 같다. 현업 엔지니어링 업계로부터 제공받은 P&ID에 대해 오픈소스로 공개된 툴을 이용하여 레이블링을 진행하여 학습 데이터를 구성하였다. 각각의 레이블링에 대한 규칙은 vendor사로부터 제공받은 규칙을 따른다. 인식이 낮은 클래스에 대한 인식률 향상과, 도면에 자주 나타나지 않는 심볼들의 학습데이터 개수를 늘리기 위해 사이즈 변경, 회전과 같은 Data Augmentation을 추가적으로 수행하여 충분한 학습

데이터를 구축하였다.

Table 2 Class information trained in the model

Symbol	Class #	Example
Valve	6	Gate
Actuator	8	Gate pressure
Sensor & Utility	10	Inst_console
Fitting	10	Blind-spectacle
OPC	1	OPC

2.5 P&ID 심볼 객체 검출 모델 테스트 결과

학습한 모델을 이용하여 총 70장의 도면에 대해 테스트를 수행하였다. 35개의 클래스 중에서 26개의 클래스에 대해 95% 이상의 F1-score값을 얻었으며, 한 장의 P&ID 당 약 2분정도의 검출 시간이 소요되었다. Figure 2는 테스트

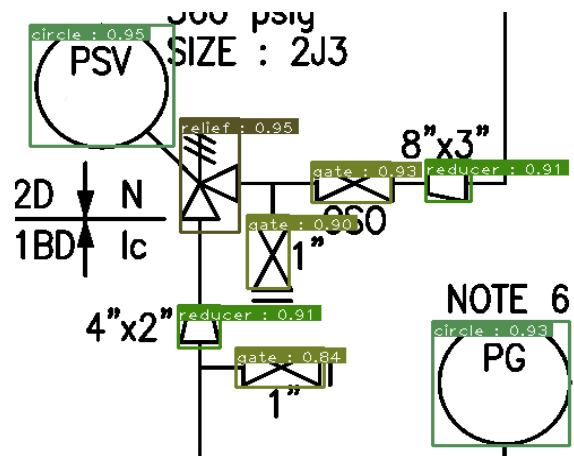


Figure 2 Test results of cropped P&ID

결과의 일부분이다. 심볼 각각의 클래스를 알맞게 예측하였으며 bounding box도 일치하는 것을 확인할 수 있다. Table 5는 참고한 논문의 모델과의 성능비교에 대한 표이다. 본 연구에 사용된 모델의 정확도가 가장 높으며, 검출시간은 평균 33분에서 2분 정도로 약 94%의 소요시간을 단축하였다.

Table 2 Comparison of recognition performance for each class

Class	Precision	Recall	F1-Score
gate	1.00	0.99	1.00
globe	0.99	1.00	0.99
butterfly	0.99	0.97	0.99
check	0.98	0.97	0.98
ball	1.00	0.00	1.00
relief	1.00	1.00	1.00
3way_solenoid	0.99	1.00	0.99
gate_pressure	0.90	0.88	0.90
globe_pressure	0.97	0.96	0.97
butterfly_pressure	0.90	0.82	0.90
ball_shutoff	0.99	0.98	0.99
ball_pressure	1.00	0.00	1.00
ball_motor	1.00	1.00	1.00
plug_pressure	0.98	0.95	0.98
circle	1.00	1.00	1.00
inst_console	1.00	0.99	1.00
inst_console_dcs	1.00	1.00	1.00
inst_console_sih	0.99	0.99	0.99
logic_dcs	1.00	1.00	1.00
utility	1.00	1.00	1.00
specialty_items	0.99	0.98	0.99
logic	0.98	1.00	0.98
logic_local_console_dcs	1.00	1.00	1.00
reducer	0.99	0.98	0.99

Class	Precision	Recall	F1-Score
blind_spectacle_open	0.95	0.91	0.95
blind_insertion_open	0.71	0.55	0.71
blind_spectacle_close	0.96	0.92	0.96
blind_insertion_close	0.89	0.81	0.89
strainer_basket	0.89	0.80	0.89
strainer_conical	0.71	0.56	0.71
fitting_capillary_tubing	0.96	0.95	0.96
meter_ultrasonic	0.76	0.79	0.76
strainer_y	0.94	0.89	0.94
tube_pitot	1.00	1.00	1.00
opc	0.92	0.89	0.92

Table 3 Comparison of model performance with previous research

	Recognition Accuracy (%)	Detection Time(min)
Ref(5)	91.6	36.5
Ref(8)	87~93	30
본 모델	97.9	2

3. 결론

본 연구에서는 딥러닝 기반 객체 인식 모델인 YOLO 9000 모델을 P&ID 내 심볼 검출에 적용하여 결과를 분석하였다. P&ID 데이터셋을 학습하였고 35개의 다양한 심볼 클래스에 대해서 약 97.9%의 인식률을 달성하였고 검출시간은 한 장의 P&ID에 대해 2분 소요되었다. 그러나 노즐과 같이 비슷한 모양의 심볼이 많고 사이즈가 작은 클래스에 대해서는 성능이 좋지 않아 본 연구 인식 대상에는 포함시키지 않았다는 점에 한계가 있다. 추후 연구로는 이러한 한계점을 극복하기 위해 P&ID 데이터 속성에 맞는 특성값을 보완하여 전체 심볼 인식률을 향상시키고자 한다.

후기

본 연구는 서울시 산학연 협력사업(20191471)의 지원을 받아 수행된 연구임.

참고문헌

- [1] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A., 2015. "Going deeper with convolutions." In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1-9.
- [2] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A., 2016. "You only look once: Unified, real-time object detection." In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 779-788.
- [3] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.Y. and Berg, A.C., 2016, October. "Ssd: Single shot multibox detector." In European conference on computer vision, pp. 21-37. Springer, Cham.
- [4] Girshick, R., Donahue, J., Darrell, T. and Malik, J., 2014. "Rich feature hierarchies for accurate object detection and semantic segmentation." In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 580-587.
- [5] Yu, E.S., Cha, J.M., Lee, T., Kim, J. and Mun, D., 2019. "Features Recognition from Piping and Instrumentation Diagrams in Image Format Using a Deep Learning Network". Energies, 12(23), p.4425.
- [6] Krizhevsky, A., Sutskever, I. and Hinton, G.E., 2012. "Imagenet classification with deep convolutional neural networks." In Advances in neural information processing systems, pp. 1097-1105.
- [7] Redmon, J. and Farhadi, A., 2017. "YOLO9000: better, faster, stronger." In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 7263-7271.
- [8] Kang, S.O., Lee, E.B. and Baek, H.K., 2019. "A Digitization and Conversion Tool for Imaged Drawings to Intelligent Piping and Instrumentation Diagrams (P&ID)". Energies, 12(13), p.2593. 