

다각형 용기의 품질 향상을 위한 딥러닝 구조 개발

Development of Deep Learning Structure to Improve Quality of Polygonal Containers

윤 석 문*, 이 승 호*

Suk-Moon Yoon*, Seung-Ho Lee*

Abstract

In this paper, we propose the development of deep learning structure to improve quality of polygonal containers. The deep learning structure consists of a convolution layer, a bottleneck layer, a fully connect layer, and a softmax layer. The convolution layer is a layer that obtains a feature image by performing a convolution 3x3 operation on the input image or the feature image of the previous layer with several feature filters. The bottleneck layer selects only the optimal features among the features on the feature image extracted through the convolution layer, reduces the channel to a convolution 1x1 ReLU, and performs a convolution 3x3 ReLU. The global average pooling operation performed after going through the bottleneck layer reduces the size of the feature image by selecting only the optimal features among the features of the feature image extracted through the convolution layer. The fully connect layer outputs the output data through 6 fully connect layers. The softmax layer multiplies and multiplies the value between the value of the input layer node and the target node to be calculated, and converts it into a value between 0 and 1 through an activation function. After the learning is completed, the recognition process classifies non-circular glass bottles by performing image acquisition using a camera, measuring position detection, and non-circular glass bottle classification using deep learning as in the learning process. In order to evaluate the performance of the deep learning structure to improve quality of polygonal containers, as a result of an experiment at an authorized testing institute, it was calculated to be at the same level as the world's highest level with 99% good/defective discrimination accuracy. Inspection time averaged 1.7 seconds, which was calculated within the operating time standards of production processes using non-circular machine vision systems. Therefore, the effectiveness of the performance of the deep learning structure to improve quality of polygonal containers proposed in this paper was proven.

요 약

본 논문에서는 다각형 용기의 품질 향상을 위한 딥러닝 구조 개발을 제안한다. 딥러닝 구조는 convolution 층, bottleneck 층, fully connect 층, softmax 층 등으로 구성된다. Convolution 층은 입력 이미지 또는 이전 층의 특징 이미지를 여러 특징 필터와 convolution 3x3 연산하여 특징 이미지를 얻어 내는 층이다. Bottleneck 층은 convolution 층을 통해 추출된 특징 이미지상의 특징들 중에서 최적의 특징들만 선별하여 convolution 1x1 ReLU로 채널을 감소시키고 convolution 3x3 ReLU를 실시한다. Bottleneck 층을 거친 후에 수행되는 global average pooling 연산과정은 convolution 층을 통해 추출된 특징 이미지의 특징들 중에서 최적의 특징들만 선별하여 특징 이미지의 크기를 감소시킨다. Fully connect 층은 6개의 fully connect layer를 거쳐 출력 데이터가 산출된다. Softmax 층은 입력층 노드의 값과 연산을 진행하려는 목표 노드 사이의 가중치와 곱을 하여 합하고 활성화 함수를 통해 0~1 사이의 값으로 변환한다. 학습이 완료된 후에 인식 과정에서는 학습 과정과 마찬가지로 카메라를 이용한 이미지 획득, 측정 위치 검출, 딥러닝을 활용한 비원형 유리병 분류 등을 수행하여 비원형 유리병을 분류한다. 제안된 다각형 용기의 품질 향상을 위한 딥러닝 구조의 성능을 평가하기 위하여 공인시험기관에서 실험한 결과, 양품/불량 판별 정확도 99%로 세계최고 수준과 동일한 수준으로 산출되었다. 검사 소요 시간은 평균 1.7초로 비원형 머신비전 시스템을 사용하는 생산 공정의 가동 시간 기준 내로 산출되었다. 따라서 본 논문에서 제안한 다각형 용기의 품질 향상을 위한 딥러닝 구조의 성능의 그 효용성이 입증되었다.

Key words : Deep Learning, Machine Vision, Convolution Layer, Bottleneck Layer, Fully Connect Layer, Softmax Layer

* Dept. Electronic Engineering, Hanbat National University

★ Corresponding author

E-mail : shlee@cad.hanbat.ac.kr, Tel : +82-42-821-1137

Manuscript received Sep. 23, 2021, revised Sep. 27, 2021, accepted Sep. 27, 2021.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

I. 서론

4차 산업혁명시대에서 검사장비의 자동화, 전장화, 고도화 등은 산업 분야에서 중요성이 부각되고 있으며 사용 분야가 점점 확대되고 있다. 머신비전 검사 시스템은 기계에 인간의 시각과 판단 능력을 불어 넣어 사람이 눈을 통해 인지하고 뇌로 판단하는 기능을 소프트웨어와 하드웨어 시스템을 통해 구현하는 기술로, 생산제품의 외관에 대한 검사나 측정을 카메라와 사람 대신 영상 보드, 소프트웨어 등이 수행한다. 머신비전 검사 시스템은 하드웨어, 광학계 및 소프트웨어 모두의 기능을 통합시켜 구현되기 때문에 전문성 및 높은 기술력을 필요로 하며, 특히 최근의 머신비전 검사 시스템은 단순한 측정에서 벗어나 이미지 처리, 판단의 과정 등을 상황 및 용도에 맞게 조절할 수 있도록 진화하고 있다. 머신비전 검사 시스템의 소프트웨어는 하드웨어를 통해 측정된 데이터를 가지고 판단하는 종합적인 역할을 수행하여 측정된 데이터 값들을 통합하고, 분석을 통해 판단을 내리는 두뇌의 역할을 한다. 소프트웨어의 경우, 사용자가 원하는 사양에 맞춰 커스터마이징이 가능하기 때문에 최종 사용자의 사용용도에 딱 맞춘 서비스 제공이 가능한 것이 특징이다. 소프트웨어는 알고리즘을 통해 원데이터(Raw-Data)를 분석하고, 전체 기계를 제어하는 중요한 역할을 담당하기 때문에 기술적인 장벽이 높은 실정이다. 최근에는 AI 기술이 발전함에 따라 머신비전의 검사 영역이 점차 확대되고 있다. 그러나, 기존 머신비전 검사 시스템으로는 원형 유리병은 검사가 가능하지만 비원형 유리병의 경우에는 대부분 작업자가 직접 육안으로 검사하고 있는 실정이다.

따라서, 본 논문에서는 기존 머신비전 애플리케이션으로는 해결하기 어려웠던 문제들을 더욱 강력하고 안정적인 방식으로 해결할 수 있는 다각형 용기의 품질 향상을 위한 딥러닝 구조 개발을 제안한다[1][2].

II. 본론

1. 다각형 용기의 품질 향상을 위한 딥러닝 구조

비원형 유리병 생산 공정의 품질 향상을 위한 딥러닝 구조의 개요도는 그림 1과 같이 convolution

층, bottleneck 층, fully connect 층, softmax 등으로 이루어져 있다[3]. 입력 이미지의 크기는 검사 시스템의 카메라 해상도 및 제품과 카메라의 거리에 적합한 224x224로 한다.

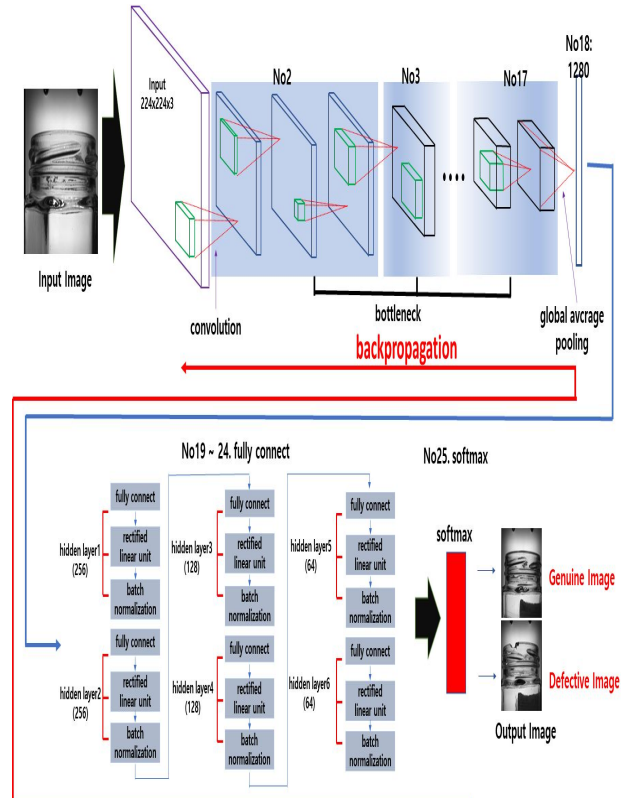


Fig. 1. Diagram of Deep Learning Architecture.

그림 1. 딥러닝 구조의 개요도

한편, 표 1은 비원형 유리병 생산 공정의 품질 향상을 위한 딥러닝 구조를 나타내고 있다. Bottleneck 연산은 총 16번 수행하며 필터는 1x1, 3x3, 1x1의 필터이고 필터 개수는 No.2부터 각각 16, 24, 24, 32, 32, 32, 64, 64, 64, 64, 96, 96, 96, 160, 160, 160 개이다. No.18까지 연산 후, No.19인 fully connect 연산은 모든 추출 특징을 연결하여 최종 특징 벡터를 생성하는 역할이며, 단순히 특징 벡터를 이어 붙여서 총 1,280개의 특징 벡터를 추출한다. 마지막 No.19에서는 fully connect 층까지 진행된 1,280개의 특징 벡터를 신경망의 입력으로 넣고 신경망 출력층의 노드 수를 학습시키는 클래스의 수로 설정한다. 비원형 유리병 검사의 경우, 학습시키는 클래스가 양품/불량 2개이므로 softmax층 노드는 2개로 설정된다[4].

Table 1. Deep Learning Architecture.

표 1. 딥러닝 구조

No.	Type	Filters	Size/Stride	Output Size
1	convolution2d	32	3×3/2	112×112
2	bottleneck	16	3×3/1	112×112
3	bottleneck	24	3×3/2	
4	bottleneck	24	3×3/2	56×56
5	bottleneck	32	3×3/2	
6	bottleneck	32	3×3/2	
7	bottleneck	32	3×3/2	28×28
8	bottleneck	64	3×3/2	
9	bottleneck	64	3×3/2	
10	bottleneck	64	3×3/2	
11	bottleneck	64	3×3/2	14×14
12	bottleneck	96	3×3/1	
13	bottleneck	96	3×3/1	
14	bottleneck	96	3×3/1	7×7
15	bottleneck	160	3×3/1	
16	bottleneck	160	3×3/1	
17	bottleneck	160	3×3/1	7×7
18	global average pool			1,280
19	fully connect			256
20	fully connect			256
21	fully connect			128
22	fully connect			128
23	fully connect			64
24	fully connect			64
25	softmax			2

가. Convolution 층

그림 2와 같이 convolution 층은 입력 이미지 또는 이전 층의 특징 이미지를 여러 특징 필터와 convolution 3x3 연산하여 특징 이미지를 얻어 내는 층이다. 특징 필터는 비원형 유리병의 특징을 부각시키는 역할을 한다. 그림 3은 비원형 유리병 이미지의 convolution 연산 과정을 나타낸다. 활성화 함수는 그림 4와 같이 CNN에서 보편적으로 많이 쓰이는 ReLU 함수를 활용하여 특징들을 비선형으로 나누어 분류를 용이하게 한다.




Fig. 2. Convolution Operation Process.

그림 2. Convolution 연산 과정




Fig. 3. Convolution Operation Process of Non-Circular Glass Bottle Image.

그림 3. 비원형 유리병 이미지의 convolution 연산 과정




Fig. 4. ReLU Function.

그림 4. ReLU 함수

나. bottleneck 층

그림 5와 같이 convolution 층을 통해 추출된 특징 이미지의 특징들 중에서 최적의 특징들만 선별하여 convolution 1x1 ReLU로 채널을 감소시키고 convolution 3x3 ReLU를 실시한다. 이후 다시 convolution 1x1로 채널수를 복구시킨다.

Convolution 연산을 마친 후 다시 입력과 합쳐지기 위하여 원래의 크기로 복원한다. 역전파 학습시에 출력층에서 입력층으로 오차값이 전파되는 과정을 거치게 되는데, 이때 전파되는 오차 값은층을 지날수록 그 값이 줄어들게 된다. 그러나 그림 5와

같이 입력과 출력이 직접적으로 연결되면 오차값을 직접 전달받는 구조이기 때문에 전파되는 오차값이 줄지 않기 때문에 더욱 빠른 학습이 가능하다. 내부의 convolution 1x1의 경우 데이터 크기에 영향이 없지만 필터수를 조절하여 차원을 줄이는 역할을 수행한다. 입력 데이터가 convolution 1x1 과정을 거치지 않고 수행한다면 고차원의 데이터를 연산해야 하기 때문에 처리속도가 상대적으로 늦어지고 메모리 점유율이 증가한다.

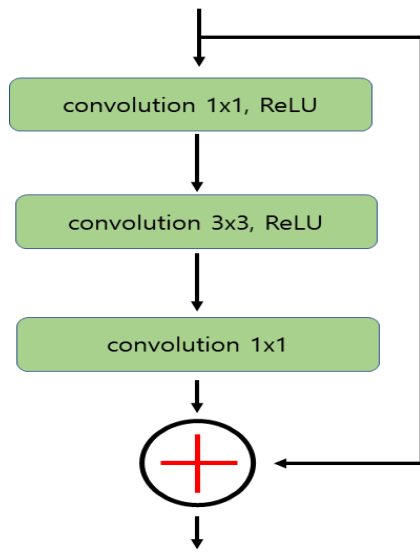


Fig. 5. Bottleneck Operation Process.
그림 5. Bottleneck 연산 과정




Fig. 6. Global Average Pooling Operation Process.
그림 6. Global Average Pooling 연산 과정

Bottleneck 층을 거친 후에 수행되는 global average pooling 연산과정은 그림 6과 같이 convolution 층을 통해 추출된 특징 이미지의 특징들 중에서 최적의 특징들만 선별하여 특징 이미지의 크기를 감소시키는 과정이다. 따라서 필요 없는 특징 이미지들

을 제거하기 때문에 연산 속도가 빠르게 되고, 특징 이미지가 추출된다.

다. Fully connect 층

그림 7과 같이 6개의 fully connect layer[5]를 거쳐 출력 데이터가 산출된다. hidden layer 1과 hidden layer 2는 256개의 노드를 사용하며, hidden layer 3과 hidden layer 4는 128개의 노드를 사용하고, hidden layer 5와 hidden layer 6에서는 64개의 노드를 사용하여 특징을 추출한다.

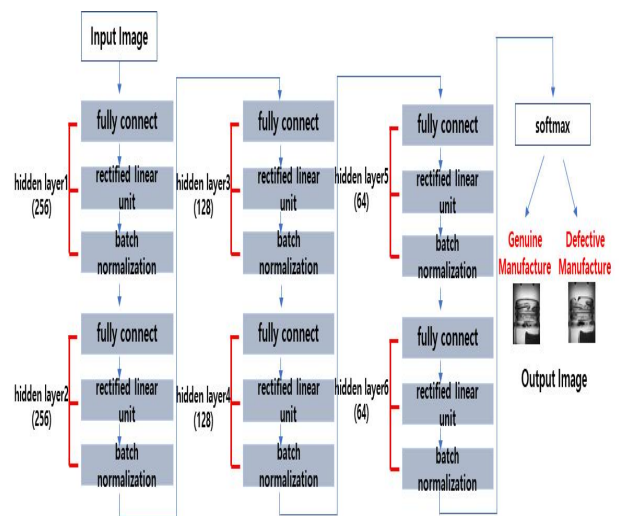


Fig. 7. Structure Diagram of Fully Connect Layer.
그림 7. Fully Connect 층의 구조도

라. Softmax 층

입력층 노드의 값과 연산을 진행하려는 목표 노드 사이의 가중치와 곱을 하여 합하고 활성화 함수 (sigmoid function)를 통해 0~1 사이의 값으로 변환한다[6]. 실제 활성화 함수는 계단함수가 본 구조이지만 신경망 연산에서 필요한 미분연산을 위해 미분 가능한 활성화 함수로 계단함수를 대체한다. 식(1)은 위의 연산과정에 대한 수식이고 그 구조는 그림 8과 같다. 그림 2의 in은 노드들이 가지는 값이고 bias는 입력이 모두 0이어도 기본적으로 가지는 수치를 위해 존재한다. w는 각 노드간의 가중치이며 out은 다음 층의 노드가 가지는 수치이다. 식 (2)는 활성화 함수를 수식으로 표현한 것이고, 그림 9는 활성화 함수(sigmoid function)의 그래프를 나타내고 있다.

입력층과 은닉층 간의 연산이 마치고 나면 은닉층과 출력층 간에 앞선 연산과정을 반복하게 된다.




Fig. 8. Computational Structure of Good and Bad Products.
그림 8. 양품과 불량품의 연산 구조




Fig. 9. Sigmoid Function.
그림 9. 활성화 함수

$$out_0 = f\left(\sum_{k=0}^{n-1} (w_{k0} \cdot in_{n-1}) + w_{n0}\right) \quad (1)$$

$$out = f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

Softmax 층을 거치고 최종적으로 수행하는 backpropagation은 목표값과 출력값의 오차를 구조의 역방향으로 입력하여 가중치를 수정하며, 학습이 진행될수록 오차를 감소시켜 원하는 결과가 출력되도록 하는 학습 알고리즘이다. 총 200개의 학습 데이터에 대하여 학습을 수행하였으며, loss가 일정이상 올라가면 backpropagation을 통해 loss를 감소시켜서 정확도 향상의 효과를 얻었다.

2. 딥러닝을 이용한 비원형 유리병 학습 및 인식

딥러닝을 이용한 비원형 유리병 생산 공정의 학습 과정에서는 카메라를 이용한 이미지 획득, 측정 위치 검출, 딥러닝을 활용한 비원형 유리병 학습 등을 수행한다. 인식 과정에서는 카메라를 이용한 이미지 획득, 측정 위치 검출, 딥러닝을 활용한 비원형 유리병 분류 등을 수행한다. 그림 10은 딥러닝을 활용한 비원형 유리병 생산 공정의 학습 및 인식 과정을 나타내고 있다.




Fig. 10. Training and Recognition Process of Non-Circular Glass Bottle.
그림 10. 원형 유리병의 학습 및 인식 과정

가. 카메라를 이용한 이미지 획득

이미지 획득 스위치를 눌러서 카메라에 트리거 신호가 전달되면, 카메라는 Ethernet 라인을 통해 PC에 이미지 데이터를 전송하여 이미지 데이터를 획득한다. 그림 11은 이미지 획득 과정을 나타내고 있다.

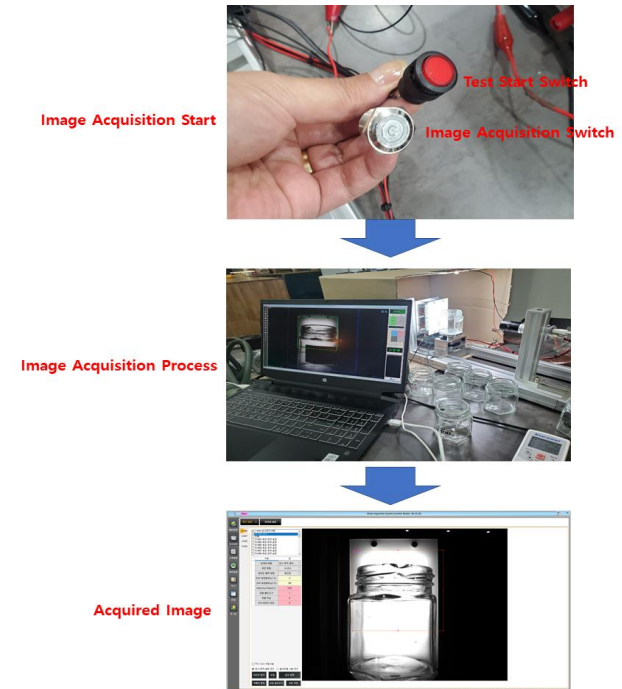


Fig. 11. Image Acquisition Process.

그림 11. 이미지 획득 과정

나. 측정 위치 검출

그림 12와 같이 검사하고자 하는 비원형 유리병의 ROI를 설정한 후에, 설정된 영역 사이즈 만큼의 영역을 획득하여 측정 위치를 검출한다.




Fig. 12. Measurement Position Detection Process.
그림 12. 측정 위치 검출 과정

다. 딥러닝을 활용한 비원형 유리병의 학습 및 분류 학습에 사용된 training 데이터는 2,000개이다. 그림 13은 학습에 사용된 데이터를 나타내고 있다.




Fig. 13. Training Data used for Learning.
그림 13. 학습에 사용된 데이터




Fig. 14. Build DB by Labeling.
그림 14. 라벨링하여 DB 구축

그림 14와 같이 양품 이미지에는 1로 라벨링을 하고, 불량품 이미지에는 0으로 라벨링을 하여 DB 구축하여 비원형 유리병의 학습을 수행한 후에 분류하게 된다.


3. 성능 실험

가. 실험 방법

① 양품/불량 판별 정확도

그림 15와 같이 유리병 10개(양품 5개, 불량품 5개)를 번갈아가며 머신비전 검사 시스템에 투입하여 양품 또는 불량품 여부를 검사하였다. 이를 총 10회 반복하여 총 100개의 유리병에 대해 검사를 실시하였다. 양품/불량 판별 정확도는 위 “검사 시간”을 평가하는 동안 투입된 유리병과 머신비전 검사 시스템에서 판별한 유리병의 검사 결과의 일치 여부를 확인하여 다음의 계산식으로 산출하여 평가하였다.

$$\text{양품/불량 판별 정확도}(\%) = (\text{정상적으로 판별된 횟수} / \text{검사한 전체 횟수}) \times 100$$



(a. Genuine Glass Bottle)

(b. Defective Glass Bottle)




Fig. 15. Test Configuration Environment.

그림 15. 테스트 구성 환경

② 검사 시간

그림 16과 같이 유리병 10개(양품 5개, 불량품 5개)를 번갈아가며 머신비전 검사 시스템에 투입하여 양품 또는 불량품 여부를 검사하였다. 이를 총

10회 반복하여 총 100개의 유리병에 대해 검사를 실시하였다. 검사를 실시하는 동안의 장면을 녹화한 후, 유리병이 안착된 검사대가 회전하기 직전과 노트북에 검사 결과가 표시된 직후 동안의 시간을 확인하여 검사 소요 시간을 평가하였다.




Fig. 16. Test Configuration Environment.
그림 16. 테스트 구성 환경

나. 실험 결과

① 양품/불량 판별 정확도

실험 결과는 표 2와 같이 양품/불량 판별 정확도 99%로, 머신비전의 세계최고 수준의 Vimec 회사 [7]와 동일한 결과를 산출하였다. 따라서 본 논문에서 제안한 다각형 용기의 품질 향상을 위한 딥러닝 구조의 성능의 그 효용성이 입증되었다.

Table 2. Result of Certificate of Accreditation Agency.

표 2 공인시험성적서 결과

Number of Test	Number of Genuine Glass Bottle	Number of Defective Glass Bottle	Accuracy
100	99	1	99%

② 검사 시간

실험 결과는 표 3과 같이 검사 소요 시간은 평균 1.7초로, 비원형 머신비전 시스템을 사용하는 생산 공정의 가동 시간 기준 내로 산출되었다. 따라서 본 논문에서 제안한 다각형 용기의 품질 향상을 위한 딥러닝 구조의 성능의 그 효용성이 입증되었다.

Table 3. Result of Certificate of Accreditation Agency.

표 3 공인시험성적서 결과

Number of Test	Time of Test(second)		
	Minimum	Maximum	Average
100	1.56	1.83	1.70

III. 결론

본 논문에서는 다각형 용기의 품질 향상을 위한 딥러닝 구조를 제안하였다. 제안된 비원형 유리병 생산 공정의 품질 향상을 위한 딥러닝 구조의 성능을 평가하기 위하여 공인시험기관에서 실험한 결과, 양품/불량 판별 정확도 99%로 세계최고 수준과 동일한 수준으로 산출되었다. 검사 소요 시간은 평균 1.7초로 비원형 머신비전 시스템을 사용하는 생산 공정의 가동 시간 기준 내로 산출되었다. 따라서 본 논문에서 제안한 다각형 용기의 품질 향상을 위한 딥러닝 구조의 성능의 그 효용성이 입증되었다.

향후 연구 과제는 딥러닝을 활용한 비원형 유리병 생산 공정의 머신비전 검사 시스템이 산업현장에 실제 사용되어 제조공정의 품질관리의 극대화를 하여 제조 산업에 필요한 실증적 실험연구가 필요하다고 사료된다.

References

[1] Insung Cho, Jihong Lee, Sangjin Oh, "Development of The Flexible User-Friendly Real-Time Machine Vision Inspection System," *Journal of the institute of electronics engineers of Korea*, Vol.45, No.3, pp.42-50, 2008.

[2] Park Jung-Kee, Jung Won, "Automated Inspection System Using Image Processing Technology for Automotive Components," *journal of KCI*, Vol.4, No.3, pp.71-78, 1999.

[3] Seung-Tak Ra, Seung-Ho Lee, "Deep Learning Structure Suitable for Embedded System for Flame Detection," *Journal of IEEE Korea Council*, Vol.23, No.1, pp.112-119, 2019. DOI: 10.7471/ikeee.2019.23.1.112

[4] Lee Jaehong, Lee Seung-hye, "Deep Learning for Structural Analysis," *Journal of the Korean association for shell and spatial structures*, Vol.17, No.4, pp.10-15, 2017.

[5] Hoseung Kim, Seong-soo Han, Chang-sung Jeong, "Location-Based Saliency Maps from a Fully Connected Layer using Multi-Shapes," *Journal of KSII*, Vol.15, No.1, pp.166-179, 2021.


[6] Kang, Hyeong-Ju, "Successive Approximated

Log Operation Circuit for SoftMax in CNN,”
*Journal of the Korea Institute of Information and
Communication Engineering*, Vol.25, No.2, pp.
330-333, 2017. DOI: 10.6109/jkiice.2020.25.2.330

[7] <https://vimec.nl>

BIOGRAPHY

Suk-Moon Yoon (Member)



2009 : BS degree in Electronic
Engineering, Hanbat National
University

2020 : MS degree in Electronic
Engineering, Hanbat National
University

2021 ~current : Ph. D degree course
of Electronic Engineering, Hanbat
National University

Seung-Ho Lee (Member)



1986 : BS degree in Electronic
Engineering, Hanyang University

1989 : MS degree in Electronic
Engineering, Hanyang University

1994 : Ph. D degree in Electronic
Engineering, Hanyang University

1994 ~current : Professor, Department
of Electronic Engineering, Hanbat
National University