

CNN 기법의 이미지 학습을 통한 시험성적서 판정 모델 연구

김정민^{1,2}, 염슬기¹, 고진환^{2*}
¹국방기술품질원, ²경상국립대학교 전자공학과

A Study on the Model for Determining Test Report through Image Deep Learning of CNN Techniques

Jung Min Kim^{1,2}, Seul Ki Yeom¹, Jinhwan Koh^{2*}

¹Defense Agency for Technology and Quality

²Department of Electronic Engineering, GyeongSang National University

요 약 시험성적서는 제품이 요구사항을 만족하는지 확인하고 이를 문서로 남기기 위해 활용된다. 품질관리에서 이러한 시험성적서의 확인은 중요한 절차이지만, 복잡한 체계의 경우 문서의 양이 많아 직접 확인하기 어려운 문제가 있다. 이에 본 연구에서는 CNN 기법을 활용하여 시험성적서의 합격과 불합격 판정을 자동으로 처리해주는 모델에 대해 연구하였다. 여러 산업에서 품질관리 시 활용하는 시험성적서의 자동 판정은 품질보증의 효율화에 기여할 것으로 판단된다. 시험 데이터는 성적서 양식에 규격을 중앙값으로 하는 정규분포 난수를 활용하여 생성하였고, 1개, 3개, 6개의 시험데이터를 가진 시험데이터를 생성하였다. 딥러닝 네트워크는 CNN을 기반으로 Convolutional Layer, Pooling Layer를 포함한 학습 네트워크를 구성하였고, 데이터가 1개 초과 시 Addition Layer를 통해 병렬 합산하였다. 시험데이터 학습 결과 99% 이상의 정확도를 확인하였다. 학습 결과를 토대로 일반적인 시험성적서에 활용할 수 있는 딥러닝 네트워크 모델을 제시하였다. 각 Layer의 Hyper Parameter에 대한 규칙을 정립하여 N개의 데이터에 대한 시험성적서 분석 시 적용할 수 있게 하였다. 제시된 딥러닝 네트워크 모델을 통해 다양한 산업의 시험성적서에 대해 사람이 직접 확인하지 않고도 품질관리를 효율적으로 할 수 있다. 또한 분야를 확장하여 문서를 확인하는 여러 분야의 업무효율화에 기여 할 것으로 예상된다.

Abstract Test reports are used only to verify that a product meets the requirements, and they are then left as filed documents. In quality control, verifications from these test reports are an important procedure, but in complex systems, there are problems that are difficult to verify directly due to the large number of documents. Thus, we present a model that automatically handles acceptance and rejection of test reports using CNN techniques. Test reports that contain one, three, and six types of test data were generated using a normal distribution random number with a standard as the median. The deep learning network is based on a CNN and is configured with a learning network (including a convolutional layer and a pooling layer), which is added in parallel through an Addition Layer when the data exceed 1. Test-data learning confirmed accuracy of more than 99%. We also present a deep learning network model that can be utilized in general test reports based on the learned results. Through the presented deep learning network model, test report management can be efficiently conducted during quality management without a human checking it. And it can be utilized not only for dimensions but also for various quality elements.

Keywords : Quality Management, Deep Learning, CNN, Test Reports, Image Process

*Corresponding Author : Jinhwan Koh(Gyeongsang National University)

email: jikoh@gnu.ac.kr

Received August 3, 2021

Accepted September 3, 2021

Revised August 20, 2021

Published September 30, 2021

1. 서론

품질관리에 딥러닝을 활용하는 사례가 늘고 있다. 용접 이미지를 촬영하여 표면 이미지를 딥러닝 학습을 통해 학습하고 용접 비드의 품질검사를 수행하거나[1], 스마트폰 촬영 영상을 이용하여 딥러닝을 통해 위조지폐 판별을 하는 모델에 대한 연구도 수행되었다[2]. 이외에도 딥러닝을 다양하게 활용하여 품질관리를 효율화 시키고자 하는 연구가 많이 진행되고 있다[3,4].

체계 품질관리에 있어서 시험성적서의 확인은 필수적인 품질보증 방법 중에 하나이다. 국방품질보증기관인 국방기술품질원도 품질관리를 위해 계약업체로부터 전산으로 시험성적서를 제출받아 확인하는 절차를 수행하고 있다. 항공기나 함정 등 복잡한 무기체계의 경우 품질관리를 위해 관리하는 시험성적서가 매우 방대하다. 주요 구성품의 시험성적서가 오차가 있을 경우 생산에서의 조립불가 혹은 상위 조립체의 기능불량과 직결되기 때문에 중요한 품질관리 방법 중 하나이다.

국방기술품질원의 경우 6년간 전산으로 제출받은 성적서는 약 18만 건으로 그 양이 매우 방대하다[5]. 담당자가 직접 눈으로 진위 여부를 확인하기 위해서는 성적서 1장당 약 10분이 소요되며, 복잡한 무기체계의 경우 더 길릴 품질요소들이 많다. 이에 시험성적서의 합격과 불합격을 자동으로 판단하는 딥러닝 모델은 연구가치가 높다고 볼 수 있다.

본 논문에서는 측정된 시험성적서의 합격/불합격 판정을 자동으로 수행하는 딥러닝 모델에 대해 연구하였으며, 이를 통해 시험성적서 품질관리의 정확성을 향상시키고 시간절약에 도움을 주고자 하였다.

기존의 딥러닝을 통한 문자인식은 이미지를 컴퓨터 데이터로 변환하여 이미 알고 있는 정보와 비교하여 처리를 하는 경우가 대부분이다[6].

하지만 본 논문에서는 시험성적서 이미지의 합격과 불

합격에 관한 정보만 입력한 후, 학습을 통해 새로운 시험성적서의 합부 판정을 하는 딥러닝 모델을 설계하고자 하였다.

연구절차는 학습을 위한 빅데이터 생성, 시험성적서의 판단을 위한 딥러닝 모델 연구, 실제 학습결과 분석 순으로 수행하였다.

2. 본론

2.1 연구개요

본 연구는 컴퓨터로 작성된 시험성적서를 이미지로 인식하여 딥러닝 네트워크를 통해 합격과 불합격 분류를 하는 모델을 만드는 것을 목적으로 한다.

시험성적서는 해당 품목의 치수, 기능 등의 요구사항을 확인하기 위해 수행하는 시험의 부산물이다.

관리자가 모든 시험을 입회할 수 없기 때문에 품질관리부서는 시험성적서를 확인하여 요구사항의 만족을 확인하고 있다.

Requirement	Actual	Media
11.00 ± 0.30	11.57	V.C
22.00 ± 0.30	22.22	CMM
18.50 ± 0.30	18.49	CMM

Fig. 1. Test Report image

일반적인 부품 생산 과정에서 치수 시험성적서는 3차원 측정기(CMM), 버니어캘리퍼스, 줄자 등으로 측정된 값을 컴퓨터로 입력하여 Fig. 1과 같은 치수 성적서가 작성된다. 치수 시험성적서의 구성요소는 요구도(Requirement), 측정값(Actual), 측정도구(Media)로 구성되며 요구도와 실제값을 비교하여 해당 품목이 품질을 만족하는지 확인




Fig. 2. Convolutional Neural Network layer architecture

할 수 있다.

이러한 이미지는 딥러닝을 위한 학습데이터 생성에도 적합하다. 본 연구에서는 시험성적서 양식에 측정데이터를 입력하여 학습데이터를 생성하였다.

학습에 필요한 딥러닝 네트워크는 이미지 분석에 가장 적합하다고 판단되는 CNN(Convolutional Neural Network)을 사용했다. CNN 알고리즘은 이미지의 미세한 특징들을 잡아내는 부분적인 신경망들의 가중치를 공유하는 방식으로 기존의 완전연결 신경망 방식보다 구조를 단순화 할 수 있다[7].

이번 학습에 사용될 CNN의 구조는 Fig. 2와 같다. Convolutional Layer의 구성요소는 Filter Size, Filter Number, Stride 등이 있다.

Convolutional Layer는 Fig. 3과 같이 입력데이터와 Filter를 합성곱해서 결과를 추출한다. Fig. 3을 살펴보면 $[4 \times 4]$ 크기의 데이터를 $[3 \times 3]$ Filter와 합성곱하여 $[2 \times 2]$ 의 출력을 얻는 것을 볼 수 있다.

Filter Number를 늘리면 $[2 \times 2]$ 결과 값을 여러 개 가질 것이며, Convolutional Layer에서는 추출하고자 하는 특징의 수와 Filter Number가 연관관계를 가지고 있다.




Fig. 3. Convolutional Layer

Pooling Layer는 데이터의 특징을 살리며 압축해주는 Layer이다. Max Pooling Layer의 경우 Filter의 크기만큼의 데이터 중 최댓값을 대푯값으로 출력하며 나머지 데이터는 삭제된다.

Average Pooling Layer는 Filter의 크기만큼의 데이터를 평균하여 하나의 데이터로 바꾸어준다.

Fig. 4는 데이터 중 최댓값을 출력하는 Max Pooling Layer의 예시이다. Filter에 해당하는 4개의 데이터 중 최댓값인 4를 대푯값으로 설정해서 $[4 \times 4]$ 의 데이터를

$[3 \times 3]$ 의 데이터로 압축해 준다.




Fig. 4. Max Pooling Layer

그 후 출력된 데이터를 활성화 함수인 Relu Layer를 통해 활성화 하고 Fully Connected Layer로 전달한다. 전달된 값을 확률적인 값으로 바꾸어주는 Softmax Layer를 통해 해당 데이터의 합격/불합격일 확률을 알 수 있다.

마지막으로 Classification Layer를 통해 높은 확률의 값을 결과 값으로 가지게 된다.

연구를 위한 딥러닝 네트워크 설계 및 학습은 매트랩 (MATLAB)의 심층신경망 디자이너를 사용하였다. 심층 신경망 디자이너는 검증된 딥러닝 네트워크를 사용하거나 원하는 네트워크를 쉽게 설계할 수 있는 장점을 가지고 있다.




Fig. 5. MATLAB Neural Network Designer

심층신경망 디자이너를 통해 Network Layer와 Hyper Parameter를 입력하고 연결해주면 딥러닝 네트워크를 설계하고 학습시킬 수 있다.

본 연구에서는 1개의 치수에 대한 시험성적서 학습부터 3개 치수 시험성적서, 6개 치수 시험성적서에 대한 딥

러닝 네트워크를 설계하고 결과를 분석하였다. 이를 통해 N개의 치수 시험성적서를 판단하는 CNN 모델을 제시하고, 설계에 사용되는 CNN Layer의 Hyper Parameter들의 결정방법에 대해 정립하였다.

2.2 학습데이터 이미지 생성

시험성적서 이미지는 컴퓨터로 양식에 데이터를 입력하고 출력하여 시험성적서가 완성되기 때문에, 학습 데이터를 생성하기 수월하다. 학습데이터 생성에 주요한 가정은 다음과 같다.

측정 데이터는 치수 규격을 중앙값으로 가지는 정규분포 난수로 생성했다. 치수 데이터 특성을 생각하면 중앙값을 크게 벗어나는 경우는 없을 것이다. 10cm $\pm$ 1cm의 길이를 가지는 봉을 생산할 때, 공정상의 결함으로 규격을 벗어나는 부품이 만들어 질 수는 있지만 봉의 길이가 20cm가 되거나, 0cm가 되는 부품은 나오지 않을 것이다. 이러한 가정을 통해 치수데이터 생성은 원하는 규격 치수를 중앙값으로 가진 정규분포 난수를 사용하여 생성하였다.

Requirement	Actual
11.00 $\pm$ 0.30	

Fig. 6. Blank Data Image (1st)

우선 1개의 치수에 관한 시험성적서인 Fig. 6과 같이 1차 시험성적서 양식을 만들고 MATLAB의 정규분포 난수생성 함수를 사용하여 유효숫자가 4이며 중앙값을 11.00으로 가지는 3000개의 학습용 시험성적서 이미지를 생성했다. 검증데이터 또한 학습데이터와 별개로 200개를 생성하였다.

1차 학습데이터는 3000개의 데이터 2,280개의 데이터가 합격 데이터이고 나머지는 불합격 데이터였다.

Requirement	Actual	Media
100 $\pm$ 4		CMM
22.0 $\pm$ 0.5		CMM
1.20 $\pm$ 0.03		V.C

Fig. 7. Blank Data Image (2nd)

Fig. 7은 3개의 치수 데이터에 대한 2차 학습데이터이다. 2차의 학습데이터의 경우는 3개의 데이터 중 하나

라도 벗어날 시 불합격으로 판단이 되어 불합격 데이터가 더 많아질 것으로 생각되어 난수 생성 확률을 조정하였다. 1개의 데이터가 요구치를 벗어날 확률을 약 0.2로 잡으면 3개의 치수 모두 합격인 합격 데이터가 생성될 비율은 0.512로 설정된다.

표준 정규분포 표를 통해 규격을 벗어나지 않는 비율이 0.7994의 값인 1.28을 참고했고 중앙값 조절을 통해 3000개의 학습용 시험성적서 이미지를 생성했다. 마찬가지로 6개의 치수를 가진 3차 학습데이터의 경우도 하나의 치수가 규격을 벗어날 확률을 0.1로 잡아 0.531의 비율로 기준을 정하고 표준 정규분포 표를 통해 값을 찾은 후 데이터를 생성하였다.

그 결과로 준비된 학습데이터는 Table. 1과 같다. 이미지 학습 시 딥러닝 네트워크가 단순히 이미지를 기억하고 동일한 데이터에 대해서만 판단을 할 수 있기 때문에 학습데이터와 검증데이터는 분리하여 생성하였다.

Table 1. Image Data Creation

Specification		Learning Data	Validation Data
1 st Data	11.00 $\pm$ 0.30	3,000	200
2 nd Data	100 $\pm$ 4	3,000	200
	22.0 $\pm$ 0.5		
	1.20 $\pm$ 0.03		
3 rd Data	100 $\pm$ 4	5,000	300
	22.0 $\pm$ 0.5		
	1.20 $\pm$ 0.03		
	3.2 $\pm$ 0.1		
	1.50 $\pm$ 0.15		
	4.00 $\pm$ 0.01		

2.3 딥러닝 네트워크 설계

시험성적서 이미지를 분석하기 위해 사용한 딥러닝 네트워크는 CNN 구조이다. 1차 딥러닝 네트워크는 1개의 Fig. 8와 같이 단순한 CNN 구조로 설계하였다.

1차 딥러닝 네트워크는 Input Layer를 통해 앞서 생성한 1차 데이터 이미지를 받는다. 1차 데이터는 [931 x 312]의 크기를 가지고 있는 이미지 데이터 3,000개이다.

Input Layer를 통해 [931 x 312]의 이미지를 받고나면 Hidden Layer를 통해 이미지를 학습하게 된다. Hidden Layer는 Convolutional Layer, Relu Layer, Average Pooling Layer, Fully Connected Layer, Softmax Layer로 이루어져 있으며, 이미지 특징 추출과 압축, 파라미터 생성을 통해 학습한다. Output Layer는

Table 2. Hyper Parameter List

Layer	Hyper Parameter
Convolutional Layer	Filter Size
	Filter Number
	Stride
Pooling Layer	Max/Average

Convolutional Layer의 Filter Size와 Filter Number는 시험성적서에서 기입된 실제 치수와 상관이 있다. Filter Size는 Fig. 12와 같이 입력된 시험치수의 이미지 크기를 모두 포함하여야 한다. Filter Number는 소수표현에 쓰이는 점을 포함하여 유효숫자와 관련 있다. 해당 그림에서는 Filter Number를 5이상으로 설정했으며, 90% 이상의 유효한 학습결과를 얻을 수 있었다.




Fig. 12. Filter Size/Number Parameter

Filter Size와 Filter Number가 치수 데이터 크기와 유효숫자(소수점 포함)보다 작은 경우는 Fig. 13과 같이 동일한 딥러닝 네트워크를 사용하더라도 정확도와 손실 함수가 수렴하지 않고 진동하는 결과를 가져왔다.




Fig. 13. Filter Parameter Error

Convolutional Layer의 Stride는 Filter를 통해 이미지의 특징을 추출할 때 얼마나 띄엄띄엄 추출할 것인지에 대한 Parameter이다. Stride Parameter는 Filter Size의 약수가 되어 치수 이미지를 추출하지 못하고 넘어가는 경우를 방지하도록 설정하였다.

딥러닝 네트워크에서 이미지가 커질수록 학습 Parameter의 수를 줄여주는 Pooling의 중요성이 커진다. 시험성적서 학습용 딥러닝 네트워크에서는 Average Pooling Layer를 사용하면 학습을 완료하는 시간은 늘어나지만 정확도 그래프가 완만하게 올라간다. Max Pooling Layer를 사용하면 학습에 들어가는 시간은 줄어들지만, 결과 그래프가 다소 튀는 경향이 있었다.

정립한 네트워크를 확인해보기 위해 6개 데이터 분석을 위한 3차 네트워크를 설계하였다. Fig. 14는 3차 네트워크 구조이며, 1차 네트워크의 병렬 구조를 따르고 6개의 Layer를 Addition Layer로 합산하여 최종 Output Layer로 값을 전달한다.




Fig. 14. Test Report Classification Network (3rd)

3차 데이터 5,000개 학습을 진행했으며 결과는 다음과 같다.

3차 학습의 경우는 이미지의 크기가 [1156 x 642]로 크기 때문에, Max Pooling Layer를 사용한 네트워크로 학습하였다. 정확도 그래프가 중간에 튀는 경향이 있지만, 학습 결과 정확도는 100%에 도달하였다.

이러한 과정을 통해 제안된 네트워크 모델을 통해 N개의 데이터를 가진 시험성적서를 CNN을 활용하여 판단할 수 있음을 확인하였다.




Fig. 15. Learning Result (3rd CNN)

2.4 연구 결과

여러 개의 치수에 대한 시험성적서를 딥러닝을 통해 분석한 결과 Table. 3과 같은 결과를 얻었다.

Table 3. Test Result

Data Number	Accuracy	Image Size
1	99.5 %	931 x 312
3	99.0 %	1120 x 427
6	100 %	1156 x 642

데이터의 개수와 관련된 딥러닝 네트워크를 설계하고 시험성적서의 치수와 관련된 정보를 통해 각 Layer의 Hyper Parameter를 정해 학습을 수행하면, 일반적인 치수 시험성적서에 대한 합격과 불합격 판정을 할 수 있음을 확인하였다.

제안된 딥러닝 네트워크를 활용하면 사람이 직접 확인하지 않더라도 99% 이상의 정확도로 시험성적서를 합격/불합격 판정할 수 있다.

3. 결론

본 연구는 여러 산업에서 품질관리에 활용되는 시험성적서에 대해 자동으로 합격 불합격을 판단하는 딥러닝 네트워크 모델에 대해 연구하였다.

학습에 사용된 데이터는 1개, 3개, 6개 치수에 대한 시험성적서이며, 데이터 생성은 원하는 규격을 중앙값으로 하는 표준정규분포 난수를 활용하였다.

딥러닝 네트워크는 CNN을 기반으로 설계하였으며, 1개 초과 데이터에 대해서는 네트워크를 Additional layer를 통해 병렬로 설계하여 N개 치수에 대한 논리판단을 할 수 있음을 확인하였다. 이때 각 Layer의 Hyper

Parameter는 시험성적서 이미지의 문자 크기와 치수 개수를 통해 설정될 수 있음을 확인하였다.

품질관리에서 시험성적서 판리는 중요하지만 시간이 많이 걸리는 작업이다. 99%의 정확도를 가진 CNN 모델을 활용한다면 직접 눈으로 확인하는 것보다 나은 정확도로 짧은 시간에 모든 시험성적서를 확인 할 수 있을 것이다. 이에 품질관리에서 중요한 시험성적서 확인 절차에 걸리는 시간이 획기적으로 줄어들 것으로 예상된다.

본 연구에서 제시하는 딥러닝 모델은 통해 컴퓨터로 작성된 치수 시험성적서에 한하여 결과를 확인하였으나, 손글씨 인식 딥러닝 네트워크와 결합한다면 손으로 쓰인 시험성적서의 판정에도 쓰일 수 있을 것이다. 또한 치수 뿐만 아니라 각도, 거칠기 등 여러 인자에 대한 자동화 판단이 가능하도록 연구가 수행되어야 품질관리 자동화가 진전될 것이다.

References

- [1] Min Seok Kim, Seung Min Shin, Dong Hyun Kim, Sehun RheeT, "A Study on the Algorithm for Determining Back Bead Generation in GMA Welding Using Deep Learning", *Journal of Welding and Joining*, The Korean Welding & Joining Society, Korea, Vol.36 No.2, pp74-81, April 2018. DOI: <https://doi.org/10.5781/JWJ.2018.36.2.11>
- [2] Beom-Hwi Choi, So-Jeong Eom, Chang-Min Kim, Hae-Yeoun Lee, "Counterfeit Bill Identification based on Deep Learning using Smartphone Camera Shooting Images", *The Journal of Korean Institute of Information Technology*, Korean Institute of Information Technology, vol.19 No.3, pp1-8, March 2021. DOI: <https://dx.doi.org/10.14801/ikiit.2021.19.3.1>
- [3] Tae Won Kim, Hae Woon Choi, "Study on Laser Welding of Al-Cu Dissimilar Material by Green Laser and Weld Quality Evaluation by Deep Learning", *Journal of Welding and Joining*, The Korean Welding and Joining Society, Vol.39 No.1, pp67-73, January 2021. DOI: <https://doi.org/10.5781/JWJ.2021.39.1.8>
- [4] Minyoung Kyoung, Hyunbeon Y, "A Deep Learning-Based Document Title Detection for Automatic Document Type Classification", *Journal of the Institute of Electronics and Information Engineers*, The Institute of Electronics and Information Engineers, Vol.55, pp53-61, September 2018. DOI: <https://doi.org/10.5573/ieie.2018.55.9.53>
- [5] Lee, Donghun, Jeon, Sooyune, Bae, Manjae, "A Study on Test Report Information Service Architecture for Preventing Forgery and Alteration in Defense

Industry", *Journal of Korea Academy Industrial Cooperation Society*, Korea Academy Industrial Cooperation Society, Korea, Vol.17 Issue 4, pp43-51, April 2016.

DOI: <http://dx.doi.org/10.5762/KAIS.2016.17.4.43>

- [6] J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shual, T. Liu, X. Wang, G. Wang, J. Cai, and T. Chen, "Recent advances in convolutional neural networks", *Pattern Recognition*, Vol 77, pp945-377 October 2017.

Available From: <https://arxiv.org/abs/1512.07108>

- [7] Kim Kitae, Lee Bomi, Kim Jong Woo, "Feasibility of Deep Learning Algorithms for Binary Classification Problems", *Journal of Intelligence and Information Systems*, Korea Intelligent Information System Society, Korea, Vol.23 Issue 1, pp95-108, March 2017.

DOI: <https://dx.doi.org/10.13088/jiis.2017.23.1.095>

고 진 환(Jinhwan Koh)

[정회원]



- 1999년 2월 : 시라큐스대학교 전기공학 박사 졸업
- 2003년 2월 ~ 현재 : 경상국립대학교 공과대학, 그린에너지연구원, 전자공학과 교수

〈관심분야〉

레이더시스템, 전자파신호처리, 마이크로프로세서

김 정 민(Jung Min Kim)

[정회원]



- 2017년 2월 : 한양대학교 전자공학부(공학사)
- 2017년 9월 ~ 현재 : 국방기술품질원 연구원
- 2020년 3월 ~ 현재 : 경상대학교 전자공학부 석사과정

〈관심분야〉

국방품질경영, 전자통신, 컴퓨터공학

염 슬 기(Seul-Ki Yeom)

[정회원]



- 2014년 2월 : 부산대학교 기계공학과 (공학석사)
- 2017년 6월 ~ 현재 : 국방기술품질원 연구원

〈관심분야〉

국방품질경영, 표준화