

신경망과 전이학습 기반 표면 결함 분류에 관한 연구

김성주*·김경범**†

*한국교통대학교 대학원, **† 한국교통대학교 기계자동차항공공학부

A Study on the Classification of Surface Defect Based on Deep Convolution Network and Transfer-learning

Sung Joo Kim* and Kim Gyung Bum**†

*Graduate school, Korea National University of Transportation,

**† Aeronautical & Mechanical Design Engineering, Korea National University of Transportation

ABSTRACT

In this paper, a method for improving the defect classification performance in low contrast, ununiformity and featureless steel plate surfaces has been studied based on deep convolution neural network and transfer-learning neural network. The steel plate surface images have low contrast, ununiformity, and featureless, so that the contrast between defect and defect-free regions are not discriminated. These characteristics make it difficult to extract the feature of the surface defect image. A classifier based on a deep convolution neural network is constructed to extract features automatically for effective classification of images with these characteristics. As results of the experiment, AlexNet-based transfer-learning classifier showed excellent classification performance of 99.43% with less than 160 seconds of training time. The proposed classification system showed excellent classification performance for low contrast, ununiformity, and featureless surface images.

Key Words : Deep learning, Deep convolution neural network, Defect classification, Transfer-learning

1. 서 론

산업기술의 발전에 따라 생산량이 비약적으로 성장함에 따라 단순한 생산량이 아닌 품질에 대한 수요가 증가하는 추세에 있다. 이러한 품질 수요 중에는 소비자가 별도의 장비 없이 접근 가능한 표면에 대한 품질이 중요한 부분을 담당하고 있다. 이 중 철강제품에 관한 표면 품질을 보증하기 위한 검사장비에 대한 연구가 이루어지고 있다[1]. 이러한 검사장비에서 결함의 종류를 분류하는 분류기는 중요한 역할을 담당하고 있다.

이러한 표면결함 자동 검사 장치의 분류기 성능을 높이기 위해Ghorai, S.[2]과 Kim, GB.[3]은 SVM(Support vector

machine)을 이용하였고, Yazdchi, M. R.[4]과 Caleb, P.[5]은 BP-NN(Back propagation neural network)을 이용하였다. 이들 연구는 열연 및 냉연 강판 등의 철강 제품에 대해 90%이상의 높은 분류 성능을 갖는 분류기를 구성하였다. 이러한 연구들의 경우 상대적으로 표면의 형상이 양호한 제품에 편향된 경향이 있다. 반면 철강후판은 잡음이 많아 영상의 클래스 간 유사성과 클래스 내 다양성이 높아 분류에 어려운 점이 많다. 또한 기존의 SVM 또는 신경망을 이용한 분류기의 경우 연구자가 직접 특징 데이터를 추출하기 때문에 뚜렷한 특징을 추출하지 못하면 분류가 어려운 문제가 있다. 이러한 문제를 해결하기 위해 He, D.[6]은 심층 컨볼루션 신경망을 이용하여 자동으로 특징을 추출할 수 있으며 높은 분류성능을 가지는 분류방법을 연구하였다. 그러나 이러한 연구의 경우 분류기의 특징상 많

†E-mail: kimgb@ut.ac.kr

은 입력 데이터를 요구하며 이는 데이터의 확보가 어려운 경우 적용이 어려운 단점이 있다.

따라서 철강 후판과 같은 저대비, 불균일, 무특징 특성을 가지는 표면의 분류를 위해 자동적으로 특징의 추출이 가능하고 분류 성능이 강력한 심층 컨볼루션 신경망을 이용하여 분류하였다[7]. 또한 심층 컨볼루션 신경망이 가지는 단점을 보완하기 위해 사전에 학습된 신경망을 이용하여 구조를 간략화 하는 전이학습 신경망을 이용한 분류기를 구성하였다.

제안된 분류기를 이용할 경우, 기존의 분류기가 가지는 강력한 분류 성능은 보유하면서 별도의 특징 추출이 필요하지 않기 때문에 현장 적응성을 가지는 분류기로 사료된다.

2. 조명메커니즘에 따른 철강 후판 결함영상 획득

철강 후판의 결함으로는 스케일(Scale: SL), 스캐프(Scab: SB), 띠크랙(Line-crack: LC), 스타크랙(Star-crack: SC), 이물흙(Foreign-material: FM) 등이 있다. 이러한 결함들 중 스케일과 스캐프의 경우 불규칙하고 비교적 광범위한 영역에 표면 불규칙성을 가지는 공통점을 가지고 있다. 하지만 스케일의 경우 표면에 개재물의 형태로 불규칙성이 형성되며 스캐프의 경우 표면을 침식한 형태로 불규칙성이 형성되는 점에서 다르다. 또한 스케일은 후처리를 통해 제거가 용이하기 때문에 치명적인 결함으로 분류하지 않는다. 띠크랙의 경우 선형으로 표면 불규칙성을 이루고 있으며, 스타크랙의 경우 비교적 소형의 표면 불규칙성이 군집을 이룬 형태를 갖는다. 이물흙의 경우에는 표면 불규칙성이 공정중 침투한 물체의 형태를 가지는 특성을 가지고 있다. 이러한 결함의 영상을 Fig.1에 나타내었다.




Fig. 1. Surface defects of steel plate.




Fig. 2. Our illumination mechanism.

철강 후판이 표면 결함을 가지고 있는 경우 비교적 평탄한 비결함영역과 표면의 불규칙성을 가지는 결함영역으로 나누어진다. 이 중 비교적 평탄한 비결함영역의 경우 정반사가 주로 발생한다. 반면 표면의 불규칙성을 가지는 결함영역의 경우 확산반사가 주로 발생한다.

이 반사 특성을 이용하여 영상을 획득하기 위해 이전 연구에서 구성한 Fig.2의 조명계를 이용하여 각 대표결함에서 640*480픽셀의 영상 100장씩을 획득하였다[8]. 그러나 Fig.1의 영상을 보면 알 수 있듯 각 대표결함 영상은 잡음이 많고 결함 및 비결함영역의 대비가 낮은 것을 확인할 수 있다. 따라서 본 연구에서는 각 대표결함영상의 강력한 특징 데이터를 추출하고 이를 분류하는 분류기를 구성하고 이를 비교하여 최적의 분류기를 선정하고자 한다.

3. 심층 컨볼루션 신경망 기반 분류

본 연구에서는 인공신경망을 이용하여 철강후판의 대표결함영상의 특징을 추출하고 분류를 진행할 것이다. 인공신경망은 인간의 신경 뉴런을 수학적으로 모델링하여 다수의 군집을 분류하는 분류기이다. 인공신경망은 다수의 입력 데이터를 수용하는 입력층, 분류를 특징을 추출하고 추출한 오류를 활성화하여 입력을 순환시키는 은닉층, 최종적으로 특징데이터를 이용하여 각 데이터의 라벨을 부여하는 출력층으로 이루어져 있다. 인공신경망을 형성할 때 위와 같은 방법을 사용하는 인공신경망을 오류역전파 신경망(Error back propagation neural network)[9]이라 한다. 이러한 오류 역전파 신경망을 Fig.3으로 도시하였다.




Fig. 3. Neural network of error back propagation.

위와 같은 인공신경망을 구성할 때 각 층의 요소를 2차원의 마스크를 이용할 경우 이를 컨볼루션 신경망(Convolution neural network; CNN)이라 한다. 기존의 신경망의 경우 입력 값을 활성화 시키는 함수를 Sigmoid 또는 Hyperbolic-tangent 함수를 이용하였다. 그러나 이들 활성화 함수는 입력으로 이용되는 오류의 최대 크기가 1로 제한되기 때문에 은닉층이 깊어질수록 오류 값이 Fig 4와 같이 감소하다 소멸하는 Gradient vanishing 현상이 발생하게 된다. Gradient vanishing 현상이 발생하게 되면 신경망의 분류 성능을 높이기 위해 구성된 은닉층에 의해 분류기가 무력화되는 문제가 발생하게 된다.




Fig. 4. Gradient vanishing.

이 현상이 발생하는 것을 막기 위해 본 연구에서는 ReLu(Rectified linear unit)함수를 이용하여 활성화를 진행하였다[10]. 이 함수를 활성화 함수로 이용하게 될 경우 Fig. 5와 같이 입력이 지속적으로 증가하는 모습을 보이기 때문에 은닉층이 많아져도 그라디언트가 소멸하지 않는 장점이 있다.

본 연구에 이용할 심층 컨볼루션 신경망의 경우 SVM과 기존의 인공신경망과 달리 별도의 특징추출과정을 거




Fig. 5. ReLu activation function.




Fig. 6. Deep convolution neural network.

치지 않고 분류를 진행 가능한 장점이 있다. 이 장점은 본 연구에서 철강후판과 같은 저대비, 불균일, 무특징 특성을 가진 영상에 대한 특징 추출이 어려운 부분을 개선시킬 수 있을 것으로 기대되었다. 본 연구에서는 철강 후판 영상을 이용하여 분류실험을 진행하였으며 신경망의 구조를 Fig. 6에 나타내었다.

심층 컨볼루션 신경망과 같은 다수의 은닉층을 운용하는 신경망의 경우 간단하지만 다량의 계산이 필요하다. 이는 소수의 고성능 계산장치인 CPU보다 다량의 계산에 적합한 GPU를 이용하는 것이 유리하다는 것을 의미한다. 따라서 이 분류실험에서는 Table 1의 성능을 가지는 GPU를 이용하여 실험을 진행하고자 한다.

본 연구에서는 Table 1의 GPU를 이용하여 각 영상의 크기가 640*480픽셀인 영상을 각 대표결합에서 30장씩을 이용하여 분류기를 학습시켰다. 그 후 각 대표결합에서 70장씩을 이용하여 학습시킨 분류기의 성능을 시험하였다. 이 실험의 개요를 Fig. 7로 나타내었다.

Table 1. GPU specifications

Name	NVIDIA GeForce GTX 750Ti
Core clock rate	1033MHz
CUDA Core	640
Memory size	2GB
Memory clock rate	5400MHz

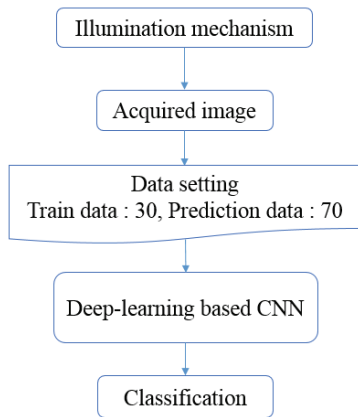


Fig. 7. Classification schematic.

심층 컨볼루션 신경망을 구성하여 분류실험을 진행할 때 중요한 매개변수로는 분류기 구성에 이용된 은닉층 수, 컨볼루션 층의 마스크 크기, 분류기 학습의 반복 횟수, 학습율 등이 있다. 이러한 매개변수를 고려하여 분류기를 구성한 분류기의 분류성과 학습 및 시험에 소요된 시간에 대한 데이터 중 분류성능이 높은 데이터 일부를 Table 2에 나타내었다.

Table 2의 실험결과 마스크의 크기가 11*11일 때의 실험이 9*9일 때의 실험에 비해 분류 성능이 높음을 알 수 있었다. 또한 은닉층의 수가 많은 경우 구성에 필요한 시간이 증가하고 성능이 저하되는 것을 확인 할 수 있었다.

Table 2. Experimental result of deep convolution neural network(learning rate: 0.0001, Kernel: ReLu)

Parameters		Number of classification error	Performance	Elapsed time
Iteration No. of hidden layer Convolution size	300 4 11	SL: 40	67.1%	1790.1 s
		SB: 16		
		LC: 18		
		SC: 6		
		FM: 35		
Iteration No. of hidden layer Convolution size	300 6 11	SL: 53	63.1%	1974.9 s
		SB: 16		
		LC: 22		
		SC: 7		
		FM: 31		
Iteration No. of hidden layer Convolution size	400 4 9	SL: 58	56.3%	1969.1 s
		SB: 16		
		LC: 29		
		SC: 17		
		FM: 33		

이는 분류기 구성에 있어 마스크의 크기가 크면 효과적으로 영상의 크기를 감소시키면서 특징을 추출하기 때문인 것으로 판단된다. 또한 은닉층의 수와 학습율은 분류기에 큰 영향을 보이지 않는 경향을 보이는 것을 확인하였다. 그러나 위 실험의 경우 매개변수의 변화에 대하여 유의미한 변화가 발생했다고 보기 어려우며, 오 분류율이 높고 진행에 필요한 시간이 1600초 이상으로 큰 것을 알 수 있다. 그 이유로는 신경망이 특징추출까지 모두 담당하여 GPU에 부과되는 부하가 크고 입력 데이터가 부족한 문제가 있는 것으로 판단되었다. 따라서 이 분류기의 문제점을 해결하기 위해 특징을 자동으로 추출하는 부분을 가지고 있으며 구조가 간단한 분류기를 모색하였다.

4. 전이학습 신경망을 이용한 분류실험

심층 컨볼루션 신경망의 경우 기존의 분류기에 비해 특징추출에 유리한 특성이 있다. 그러나 심층신경망의 특성상 다수의 입력데이터가 필요하고 구조가 복잡하여 신속하고 정확한 분류가 필요한 본 연구에는 부적합한 면이 있다. 이 단점을 개선하기 위해 전이학습 신경망을 실험에 이용하였다. 전이학습 신경망은 Alexnet[11], FRCNN[12] 등의 사전 학습된 모델을 이용하여 분류기를 구성하였다. 각 사전학습 모델의 구조와 이를 이용한 전이학습 신경망의 구조를 Fig 8과 Fig 9에 나타내었다. 전이학습 신경망은 Fig 8의 구조를 가지고 있는 신경망 모델에서 Fig 9에 나타난 방법을 이용하여 신경망의 후반부에 있는 분류층은 새로 학습시키고 특징 추출부분만 그대로 가져와 분류기를 구성하였다.

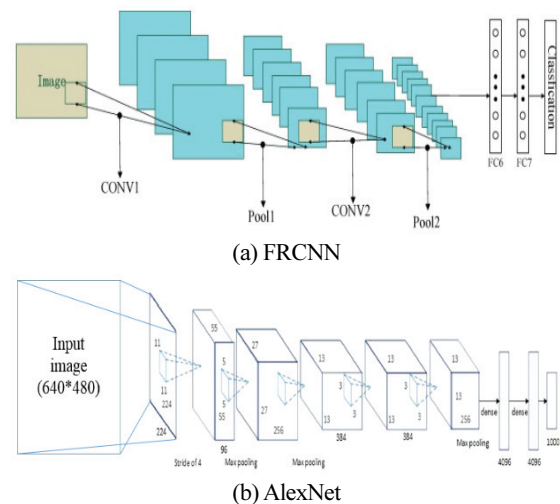


Fig. 8. Pre-trained model.

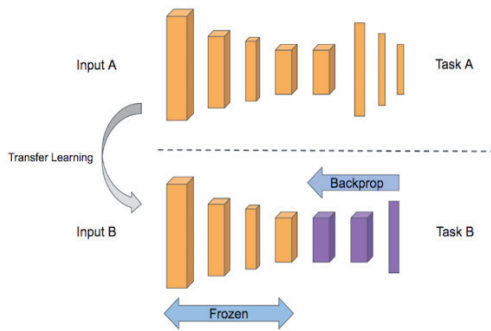


Fig. 9. Transfer-learning neural network.

이 분류기는 사전에 구성된 우수한 분류성능을 가지는 분류기의 특징 추출부분을 차용하여 구성하였다. 따라서 분류기 구성에서 많은 복잡성을 요구하는 특징 추출부분의 간소화가 가능한 장점이 있다. 본 연구에서는 FRCNN과 AlexNet기반의 전이학습 신경망을 구성하여 분류실험을 진행하고 이 실험의 결과를 Table 3과 Table 4에 나타내었다.

Table 3. FRCNN based transfer-learning CNN experimental result(learning rate: 0.001)

Parameters		Number of classification error	Performance	Elapsed time
Iteration	200	SL: 13	80%	123.2 s
		SB: 14		
		LC: 14		
		SC: 16		
Iteration	300	FM: 13	80%	200.7 s
		SL: 13		
		SB: 14		
		LC: 14		
Iteration	400	SC: 16	82.3%	251.5 s
		FM: 13		
		SL: 13		
		SB: 8		
Iteration	500	LC: 4	78.9%	316.3 s
		SC: 13		
		FM: 19		
		SL: 17		
		SB: 11		
		LC: 27		
		SC: 3		
		FM: 16		

Table 3과 Table 4의 실험 데이터를 분석한 결과 반복수가 일정 이상 증가할 경우 분류성능이 저하되고 소요시간이 증가되는 현상을 관찰할 수 있었다. 이는 반복수가 증가할수록 구조가 복잡해져 분류기의 성능저하로 이어진 것으로 보인다. 또한, 90%미만의 분류성능을 보이는 FRCNN과 달리 AlexNet기반의 분류기에서 확연히 높은 성능을 보이는 것을 확인할 수 있었다. 이는 입력의 크기가 크고 특징 추출자의 깊이가 더 깊기 때문에 이러한 성능차이를 보이는 것으로 판단된다.

Table 4. AlexNet based transfer-learning CNN experimental result(learning rate: 0.001)

Parameters		Number of classification error	Performance	Elapsed time
Iteration	10	SL:	98%	57.6.2 s
		SB: 0		
		LC: 1		
		SC: 0		
Iteration	30	FM: 6	99.4%	159.0 s
		SL: 0		
		SB: 0		
		LC: 0		
Iteration	40	SC: 0	99.4%	183.7 s
		FM: 2		
		SL: 0		
		SB: 0		
Iteration	50	LC: 0	99.4%	310.8 s
		SC: 0		
		FM: 2		
		SL: 0		

이 실험의 결과 AlexNet사전학습모델 기반의 전이학습 신경망에 학습율을 0.001로, 반복횟수를 30회로 설정하였을 때 분류성능이 99.4%으로 만족할 만한 성능을 가지는 것을 알 수 있었다. 이 실험에 이용한 데이터는 5가지의 절강후판의 대표결함에서 30장의 영상을 이용하여 분류기를 학습시키고 시험을 위해 70장의 영상을 이용한 결과 소요시간이 160초 미만으로 신속한 분류가 가능한 것을 확인하였다.

5. 결론

본 연구에서는 저대비, 불균일, 무특징의 표면특성에

의해 클래스 간 유사성과 클래스 내 다양성을 가지는 철강 후판의 분류기를 구성하여 성능을 비교하는 실험을 진행하였다. 실험 결과 심층 컨볼루션 신경망의 경우 별도의 특징추출이 필요하지 않으나 분류 성능이 저조하고 신경망을 구성하는 것에 많은 시간이 소요되는 문제가 있었다. 이 문제를 개선하기 위해 진행된 사전학습모델 기반의 전이학습 신경망을 이용한 결과 AlexNet 기반 전이학습 분류기의 학습 반복횟수를 30회로, 학습율을 0.001로 설정했을 때 99.43%의 우수한 분류 성능이 산출되었다.

제안된 분류기의 경우 특징 추출이 자체적으로 이루어지기 때문에 다수의 입력 데이터와 신규 결함이 발생해도 재학습이 간단하여 범용성이 뛰어나다고 판단된다. 특히 본 연구에서 이용한 저대비, 불균일, 무특징의 특성을 가지는 표면 영상 데이터에 대한 분류에 유효한 결과를 보였다. 따라서 저대비, 불균일, 무특징 특성에 의해 클래스 간 유사성 및 클래스 내 다양성을 가지게 되는 영상에 대한 분류에 유용할 것으로 사료된다.

감사의 글

이 논문은 2020년 한국교통대학교 지원을 받아 수행하였음.

참고문헌

1. Neogi, N., "Review of Vision-Based Steel Surface Inspection Systems", EURASIP Journal on Image and Video Processing, Vol. 2014, No. 1, pp.1~5, 2014.
2. Ghorai, S., et al, "Automatic Defect Detection on Hot-Rolled Flat Steel Products", Institute of Electrical and Electronics Engineers Trans. on Instrumentation and Measurement, Vol. 62, NO. 3, pp.612~621, 2013.
3. Kim, SJ., Kim, GB., "A Study on the Defect Classification of Low-contrast · Uneven · Featureless Surface Using Wavelet Transform and Support Vector Machine", Journal of Semiconductor & Display Technology, Vol. 19, No. 3, pp.1~6, 2020.
4. Yazdchi, M. R., Mahyari, A. G., Nazeri, A., "Detection and Classification of Surface Defects of Cold Rolling Mill Steel Using Morphology and Neural Network", Institute of Electrical and Electronics Engineers, pp.1071~1076, 2008.
5. Caleb, P., Steuer, M., "Classification of surface defects on hot rolled steel using adaptive learning methods", Institute of Electrical and Electronics Engineers, Proc. 1, pp.103~108, 2000.
6. He, D., Xu, K., Zhou, P., "Defect detection of hot rolled steels with a new object detection framework called classification priority network", Computers & Industrial Engineering, Vol. 128, pp.290~297, 2019.
7. An, M. S., Kang, D. S., "Development of Image Analysis System Using Object Classifier based on Deep Convolutional Neural Network", The Journal of Korean Institute of Information Technology, Vol. 14, No. 5, pp.67~73, 2016.
8. Kim, S. J., Kim, G. B., "Optimum Illumination Mechanism for Steel Plate Inspection Using Wavelet Synthetic Image and Entropy-Based Discriminant Measure", Journal of Institute of Control, Robotics and Systems, Vol. 24, No. 9, pp.838~844, 2018.
9. Park, J. Y., Seo, B. S., "A Study on Resilient Back-Propagation Neural Network Model for Estimation of Welding Properties of Flux Cored Wire", Journal of the Korean Society of Marine Engineering, Vol. 42, No. 7, pp.531~538, 2018.
10. Han, J. S., Kwak, K. C., "Image Classification Using Convolutional Neural Network and Extreme Learning Machine Classifier Based on ReLU Function", The Journal of Korean Institute of Information Technology, Vol. 15, No. 2, pp.15~23, 2017.
11. Krizhevsky, A., Sutskever, I., Hinton, G., "ImageNet classification with deep convolutional neural networks", Communications of the ACM, Vol. 60, No. 6, pp.84~90, 2017.
12. Girshick, R., Donahue, J., Darrell, T., Malik, J., "Region-Based Convolutional Networks for Accurate Object Detection and Segmentation", Institute of Electrical and Electronics Engineers Transactions on Pattern Analysis and Machine Intelligence, Vol. 38, No. 1, pp.142~158, 2016.

접수일: 2021년 3월 9일, 심사일: 2021년 3월 17일,
게재확정일: 2021년 3월 18일