

# CNN 기반 철도차량 차체-대차 연결부의 결함 평가기법 연구

권석진, 김민수\*

한국철도기술연구원 차세대철도차량본부

## Flaw Evaluation of Bogie connected Part for Railway Vehicle Based on Convolutional Neural Network

Seok-Jin Kwon, Min-Soo Kim\*

Division of Advanced Railroad Vehicle, Korea Railroad Research Institute

**요약** 철도차량의 대차는 열차 주행을 위한 핵심적인 장치이다. 철도차량의 대차에서 피로결함은 운행 중 기대되지 않거나 과도한 하중, 용접결함, 재료 결함 등의 다양한 요인에 의해 발생할 수 있다. 철도차량의 사고를 방지하기 위해서 차체-대차연결부의 손상을 검출하고 발생 결함에 대한 정확한 평가가 요구된다. 이러한 철도차량의 차체-대차 연결부는 초음파 비파괴 검사를 통하여 건전성을 확보하고 있으나 결함 발생에 대한 학습기법을 이용한 판정방법이 필요하다. 최근 미세한 결함이나 유사한 결함을 높은 인식율로 검출하기 위하여 딥러닝 기법에 관한 여러 연구가 진행되고 있다. 본 연구에서는 철도차량의 차체-대차 연결부의 결함 검출능력을 위하여 용접부의 인공결함 시편에 대하여 데이터베이스 구축하였으며, 웨지형 초음파 센서를 이용하여 차체-대차 연결부에 대한 비파괴 검사를 수행하였다. 부가적으로 인적 오류를 최소화하기 위하여 결함판단 학습기법인 합성곱 신경망기법(Convolutional Neural Network)을 적용하였다. 그 결과 합성곱 신경망기법 기법을 이용하여 철도차량의 차체-대차 연결 용접부의 균열을 99.98% 이상 균열성 결함으로 판별할 수 있었으며 철도차량 차체-대차 연결부의 비파괴검사시 본 연구의 기술이 적용 가능함을 확인할 수 있었다.

**Abstract** The bogies of railway vehicles are one of the most critical components for service. Fatigue defects in the bogie can be initiated for various reasons, such as material imperfection, welding defects, and unpredictable and excessive overloads during operation. To prevent the derailment of a railway vehicle, it is necessary to evaluate and detect the defect of a connection weldment between the car body and bogie accurately. The safety of the bogie weldment was checked using an ultrasonic test, and it is necessary to determine the occurrence of defects using a learning method. Recently, studies on deep learning have been performed to identify defects with a high recognition rate with respect to a fine and similar defect. In this paper, the databases of weldment specimens with artificial defects were constructed to detect the defect of a bogie weldment. The ultrasonic inspection using the wedge angle was performed to understand the detection ability of fatigue cracks. In addition, the convolutional neural network was applied to minimize human error during the inspection. The results showed that the defects of connection weldment between the car body and bogie could be classified with more than 99.98% accuracy using CNN, and the effectiveness can be verified in the case of an inspection.

**Keywords** : Convolutional Neural Network, Railway Bogie, Damage, Weldment, Defect

본 논문은 한국철도기술연구원의 주요사업과제의 연구비 지원을 받아 작성하였습니다.

\*Corresponding Author : Min-Soo Kim(Korea Railroad Research Institute)

email: mskim@krii.re.kr

Received October 7, 2020

Revised October 20, 2020

Accepted November 6, 2020

Published November 30, 2020

### 1. 서론

고속차량의 운행을 통해 대량의 인적·물적 자원이 도시와 도시 사이에서 원활히 교류할 수 있는 장점이 있지만, 운행 중에 발생하는 안전사고는 막대한 인적, 경제적 손실을 발생시킬 수 있는 위험성을 수반하게 된다. 철도 차량 대차는 열차의 차체 하중을 모두 지지하면서 주행하는 핵심장치이며, KTX-산천에 적용된 관절 대차와 같은 타입은 사고 시 충격을 흡수하여 탈선사고시 충격을 감소시키기도 한다[1]. 2018년 12월 강릉-서울 KTX 산천 열차 10량 전체가 탈선한 사고가 발생했지만, 관절 대차의 충격 흡수를 통해 인명피해를 방지한 사례가 있다. 철도차량용 대차는 운행 중 빈번한 피로 하중이 장기간 작용하게 되며, 이러한 하중은 대차의 용접부 또는 응력 집중부에 결함이 발생될 가능성이 높다[2]. 2018년 12월 일본의 고속열차 신칸센 대차프레임의 용접부에서 균열이 발생하여 운행을 중지하는 사례가 있었다[3]. 이러한 대차 용접부의 결함을 검사하고 결함의 특성을 판별하는 것은 고속차량의 운행시 안전사고의 발생 위험을 낮추고 효율적인 운행이 가능하도록 하는 필수적인 사항이다. 최근, 미세한 균열이나 유사한 결함을 높은 정확도로 검출하기 위해 딥러닝 기법을 적용하여 결함 데이터를 학습하고 학습된 모델로 대상 결함을 검출하는 기법들에 관한 연구가 활발히 진행되고 있다[4-10].

본 연구에서는 철도차량 차체-대차연결부의 결함을 판별하기 위해 표준 결함을 내재한 용접부 시험편을 제작하였고, 표준 결함에 대한 초음파 신호를 수집하여 데이터베이스를 구성하였다.

이러한 차체-대차연결부의 용접부 결함에 대한 초음파 신호 데이터베이스를 기반으로 합성곱 신경망(CNN, Convolutional Neural Network)을 학습하여, 결함 판별의 성능을 평가하였으며 결함검출능력을 높이고자 하는데 본 논문의 목적이 있다.

### 2. 결함신호 취득 및 데이터베이스 구축

#### 2.1 결함학습용 용접부 시험편

CNN의 학습에 앞서 초음파 결함신호 데이터베이스를 구성하기 위해 용접부 표준 결함 시험편을 제작하였다. 시험편은 500mm의 V개선 용접부를 중앙에 포함한 500×200×10mm 크기의 강재 시험편을 대상으로 하였다. 결함은 용접부에 발생하는 결함을 두 종류로 단순

화시켜, 균열성 결함인 바닥 노치(BN: Bottom Notch)와 체적성 결함인 평저공(FBH: Flat Bottom Hole)을 삽입하였다.

Table 1. Flaw specification in weldment specimens  
Unit: [mm]

Flaw number	1	2	3	4	5	
1	Length	10	10	10	10	10
	Depth	1	2	3	4	5
2	Length	5	10	15	20	25
	Depth	3	3	3	3	3
3	Radius	2.5	2.5	2.5	2.5	2.5
	Depth	1	2	3	4	5
4	Length	10	10	10	10	10
	Depth	1.5	2.5	3.5	4.5	5.5
5	Radius	2	2	2	2	2
	Length	4	6	8	10	12
	Depth	3	3	3	3	3
6	Radius	4	-	2	6	-
	Length	-	7	5	-	4
	Depth	2.5	2	2.5	3	3.5

\* Flaw width: > 0.1mm  
\* Butt welding

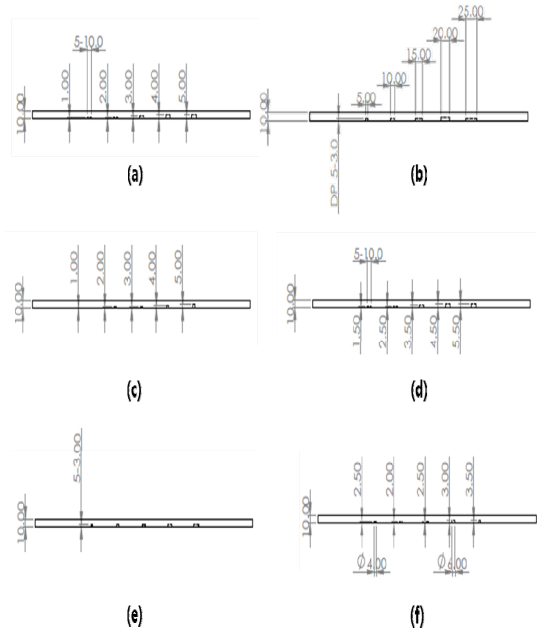


Fig. 1. Design of specimen for weldment  
(a) Specimen 1 (b) Specimen 2 (c) Specimen 3  
(d) Specimen 4 (e) Specimen 5 (f) Specimen 6




Fig. 2. Weldment specimen with 2-class flaws  
(a) FBH (b) BN




Fig. 3. Ultrasonic testing methods using wedge angle  
(a) Half-skip (b) One-skip

Table 1은 용접부의 표준 시험편이 포함하는 결함 부 시험편을 나타낸다. 총 6개의 용접부 시험편에 17개의 균열성 결함, 13개의 체적성 결함을 가공하였으며, Fig. 2는 결함 가공이 완료된 6번 시험편을 나타낸다. 시험편 (1), (2), (4)는 균열성 결함을 각각 5개씩 포함하고 있으며, 결함 폭은 0.1mm 이상의 가능한 작은 폭으로 가공하였다. 시험편 (3), (5)는 체적성 결함을 각각 5개씩 포함하고 있다. 시험편 (6)은 균열성 결함 2개와 체적성 결함 3개를 포함하고 있으며, 각 결함의 길이, 깊이, 직경 등은 Table 1과 같다. 모든 시험편에서, 결함과 결함 사이의 거리는 중심 기준으로 60mm이다.

## 2.2 결함 신호 초음파 취득 시험

5MHz, 0.25" 접촉식 초음파 센서를 이용하여 pulse-echo 결함 반사 신호를 취득하였다. 결함 신호는 하나의 결함 당 One-skip과 Half-skip 방식을 이용하여 취득하였다. One-skip은 결함 부리의 반대편 표면에 초음파를 반사시켜 결함 신호를 취득하는 방법이며, Half-skip은 결함 부리에 초음파를 직접 반사시켜 결함 신호를 취득하는 방법이다.

One-skip은 주로 검사 대상의 구조적인 문제로 결함

예상 부분에 직접 입사가 불가능할 경우 사용하는 방법으로, 본 연구에 활용된 시험편은 구조가 단순하여 One-skip 방법이 필수적이지 않지만, 데이터의 다양성을 위해 One-skip 신호 또한 취득하여 CNN 학습에 필요한 데이터를 확보하였다. Fig. 3은 검사 방식에 대해 보여준다.

초음파 센서의 입사각은 초음파 빔이 결함 부리에 45°로 입사하도록 조정하였으며, 0 ~ 40μs 범위에서 샘플링 주파수 100MHz로 신호를 취득하였다.

Table 2. Flaw signal data

Flaw type	Flaw #
FBH	71
BN	102
Total	173

Table 3. Augmented database

Flaw type	Flaw #
FBH	1065
BN	1530
Total	2595

## 2.3 결함 신호 데이터베이스 구축

초음파 취득 시험을 통해 Table 2와 같은 용접부 초음파 결함 반사 신호를 취득하였다. 다만 60개의 초음파 신호는 CNN을 적절하게 학습하기에는 부족한 숫자이기 때문에, 데이터 증대 (Data augmentation) 기법을 활용하였다. 데이터 증대는 컴퓨터비전 분야에서 매우 유용하게 사용되는 방법으로, 이미 존재하는 데이터를 바탕으로 일부를 변형시켜 인공적으로 데이터의 양을 늘리는 방법이다. 시간 영역 1차원 데이터의 증대에 자주 사용되는 기법인 time-shifting은 원신호를 중심으로 시간축으로 평행 이동시켜 데이터를 증대시키는 방법이다. 이는 초음파 신호의 관점에서 결함 신호의 시간축 상 위치가 변경되는 것으로, 초음파 센서와 결함 사이의 거리가 다른 새로운 신호로 CNN을 학습하는 효과를 나타낸다.

취득한 초음파 신호의 time-shifting을 위해서 결함 신호를 중심으로 2048개의 샘플링 포인트만큼 분리하였다. 분리한 신호를 ±50, ±100로 이동하기 위해서 신호의 시작과 끝부분에 100개 지점의 값을 0으로 교체하였다(Zero-padding). Fig. 4는 time-shifting의 결과로 생성된 신호를 나타낸다.

Time-shifting을 통해 5배로 증대된 데이터를 보다 증대시키면서 잡음 환경에 대한 데이터를 CNN에 학습시키기 위해 잡음 패턴을 추가하였다(Add-noise). 잡음은 백색 가우시안 잡음(WGN: White Gaussian Noise)을 추가하였으며, 원신호에 신호대잡음비(SNR: Signal to Noise Ratio) 20, 15의 잡음을 추가하였다[11].

Table 4. CNN structure

Layers	Filter size / stride	Feature map #	Dimension	Padding
1	Input	-	20481	-
2	Conv 1	161 / 81	32	Same
3	Max Pool	21	-	-
4	Conv 2	31 / 21	64	Same
5	Max Pool	21	-	-
6	Drop-out 1	0.25	-	-
7	Dense	300	-	-
8	Drop-out 2	0.5	-	-
9	Output	5	-	-

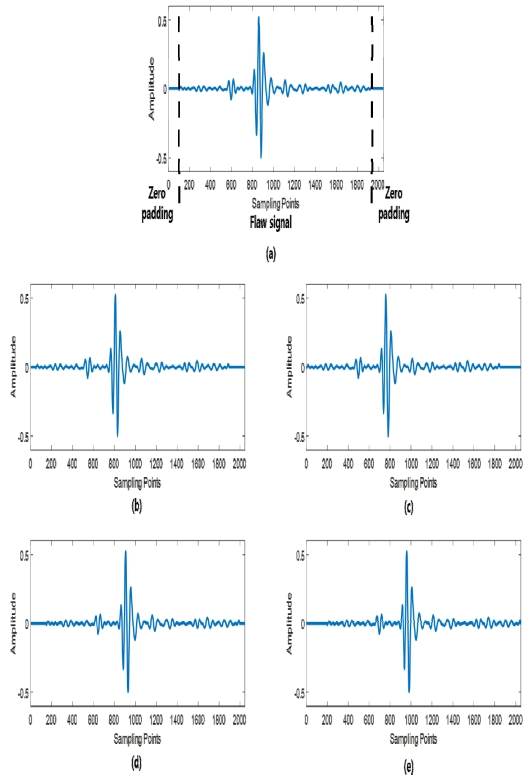


Fig. 4. Data augmentation by time-shifting  
 (a) original signal and time-shifted signal of (b) -50  
 (c) -100 (d) +50 (e) +100 points

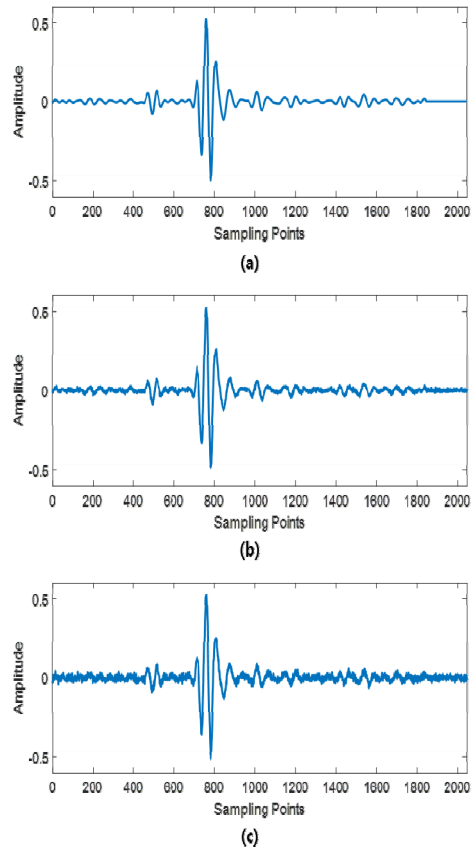


Fig. 5. Data augmentation by add-noise  
 (a) original signal and SNR (b) 20 (c) 15

Fig. 5는 잡음 추가의 결과로 생성된 신호를 나타낸다. 결과적으로, time-shifting을 통해 5배 증대된 데이터를 add-noise를 통해 3배로 더 증대하여, 원신호로부터 15배 증대된 데이터를 확보하였다. 증대된 데이터베이스는 Table 3과 같다.

### 3. CNN의 설계 및 학습

#### 3.1 CNN의 구조 설계

CNN은 심층신경망(DNN: Deep Neural Network)의 한 갈래이며, 신경망 내에 합성곱 층을 가지고 있다. 합성곱 층은 임의로 정의된 여러 개의 합성곱 필터를 입력된 데이터에 적용하여 특징을 자동으로 추출하며, 합성곱을 여러 번 반복적으로 수행함으로써 신경망의 학습에 필요한 특징이 강조된 특징 맵 (Feature map)을 얻는

다. CNN의 학습은 합성곱 필터의 인자를 조절하여 특징 추출이 필요한 특징을 강조하는 방향으로 변화하도록 하는 과정을 의미한다. 이러한 특징 추출 과정에서, 일반적으로 풀링 (Pooling)을 통해 데이터의 차원을 줄여 연산량을 조절하는 과정이 필요하다. 합성곱과 풀링에 의해, CNN은 입력 데이터가 다음 층의 모든 노드와 연결되지 않으며, 대신 미리 정의된 합성곱 필터를 거친 데이터와 연결된다. 이러한 구조는 신경망을 낮은 레벨의 특징들에 더 집중할 수 있도록 하고, 이들의 조합을 통해 높은 레벨의 특징을 학습하도록 유도한다. 또한, 필터들은 합성곱 과정에서 수치가 변경되지 않기 때문에 특정 위치에서 학습한 특징을 다른 위치에서도 인식할 수 있는 능력을 갖는다. 학습에 사용된 CNN의 구조는 Table 4와 같다.

각 층에 적용된 활성화 함수는 Relu, 손실함수는 categorical cross entropy, 출력층에 적용되는 활성화 함수는 softmax, optimizer는 adam을 사용하였다[12-13].

### 3.2 FCN의 구조 설계

FCN(Fully Connected Network)는 심층신경망의 한 갈래이며, 기본적인 MLP(Multi Layer Perceptron) 구조를 따라 각 층의 노드가 다른 층의 노드들과 모두 연결되는 특징을 가진다. FCN은 CNN과 유사한 구조에서 특징 추출 과정을 생략하기 때문에, CNN에서 수행하는 특징 추출의 효율성을 검증하기 위해 좋은 비교 대상으로 사용될 수 있다. FCN 각 층에 적용된 활성화 함수, 손실함수, optimizer는 CNN과 동일하다.

### 3.3 검증데이터의 분리와 학습

CNN과 FCN의 학습이 올바르게 수행되는지 확인하기 위해 학습 정확도와 검증 정확도를 취득해야 한다. 학습 정확도는 내부 인자가 최적화되는 역전파 계산 과정에서 오류 수치에 따른 정확도이다. 즉, 최적 인자를 찾는 과정에서 오류의 전역 최소값을 적절하게 찾을 수 있는지 확인하는 과정이다. 또한, 검증 정확도는 학습이 한 세대 완료될 때마다 학습하지 않은 데이터를 입력시켜 제대로 분류할 수 있는지 확인하는 것이다. 이를 위해 Table 5와 같이 데이터베이스를 학습용 데이터와 검증용 데이터로 분리하여 CNN과 FCN의 학습을 진행하였다.

학습용 데이터를 활용해 CNN과 FCN을 학습하였다. 총 200 세대 (Epochs)에 걸쳐 초기 학습률 0.001로 학습하였으며, 각 세대마다 학습 이후 검증용 데이터로 검증을 수행하였다. CNN의 세대별 학습에 따른 정확도는

Fig. 6과 같다.

Table 5. Database division for K-fold cross validation

Flaw Type	Training	Validation	Total
FBH	965	100	1065
BN	1380	150	1530
Total	2345	250	2595




Fig. 6. Learning curve (accuracy) of CNN training




Fig. 7. Learning curve (validation accuracy) comparison of FCN / CNN training

CNN에서 사용되는 특징 추출의 효율을 검증하기 위해 FCN과 세대별 학습에 따른 정확도를 비교하였다. 비교는 검증 정확도로 수행하였다. 세대별 학습에 따른 정확도 비교는 Fig. 7과 같다.

검증 데이터에 대해서, CNN은 최대 100%의 분류 정

확도를 보인 반면, FCN은 최대 98.5%의 분류 정확도를 보였기 때문에, CNN에서 활용된 합성곱을 이용한 특징 추출이 가시적인 효과를 보인다고 할 수 있으며, CNN이 용접부 결함 분류 문제에서 전반적으로 더 나은 성능을 나타낸다.

학습 성능을 Confusion matrix를 통해 정량적으로 측정하였다. Confusion matrix는 데이터 분류 CNN의 성능을 정량적으로 나타내는 지표 중 하나로, 데이터를 분류하는 각 카테고리가 CNN에 의해 분류된 모든 경우를 확률로 변환하여 표시한다. 예를 들어, 학습이 완료된 CNN에 FBH 신호를 입력했을 때 FBH이라고 분류를 한다면 제대로 분류한 경우이고, BN이라고 응답한다면 제대로 분류되지 않은 경우이다. 분류 카테고리가 2개인 경우에 confusion matrix는 2×2 행렬로 표현되고, 그중 대각선 방향은 각 결함 신호가 제대로 분류된 경우를, 그 외 나머지는 결함 신호가 제대로 분류되지 않은 경우를 나타낸다. 250개의 검증 데이터에 대한 confusion matrix는 Table 6과 같다.

Table 6. Confusion matrix of validation dataset

True Label	Predicted Label		
	FBH	BN	
FBH	100	0	
BN	0	100	

Table 7. Classification of bogie weldment crack signal with trained CNN

Ultrasonic Data	Flaw Type	Probability (%)
Bogie data (1)	FBH	0.01
	BN	99.99
Bogie data (2)	FBH	0.02
	BN	99.98
Bogie data (3)	FBH	0
	BN	100

### 3.4 대차연결부 결함신호 취득 및 CNN 성능 검증

철도차량의 차체-대차연결부의 용접부에 대하여 손상에 대한 비파괴 검사를 수행하였다. Fig. 8과 같이 차체-대차연결부에 대하여 초음파 검사를 수행하였으며, 대차용접부에 대해 5MHz 0.325" 접촉식 초음파 센서를 이용하여 60° 굴절각으로 시험을 수행하였다. 또한, 2.5 ~ 7.5MHz 주파수 대역 필터와 100MHz 샘플링 주파수로 초음파 반사 신호를 취득하였다. 차체-대차연결부의 용접부 균열에 대한 초음파 검사를 수행한 결과, 3개의 균열 결함 신호를 확보하였다.



Fig. 8. Inspection zones ① and ② for connection weld between carbody and bogie




Fig. 9. Ultrasonic flaw signals for connection weld between carbody and bogie  
(a) zone ① (b) zone ② (c) between zone ① and ②



Fig. 9는 취득한 결함 신호들을 나타낸다. 취득한 3개의 균열 결함 신호를 결함 부분을 추출하여 학습을 완료한 CNN에 적용시켰을 때, 이를 이용해 판별한 결과는 Table 7과 같다.

#### 4. 결론

본 연구에서는 철도차량의 차체-대차연결부에 발생하는 결함을 CNN을 사용해 판별하기 위해서, 표준 결함을 내재한 용접부 시험편을 제작하여 바다 노치 및 평저공 반사 신호 173개를 취득하였으며, 데이터 증대기법을 활용하여 총 2595개의 용접부 초음파신호 데이터베이스를 구축하였다.

또한, CNN 구조를 설계하여 무작위로 선택된 2345개의 데이터로 CNN을 학습하고 250개의 데이터로 검증하여 100%의 정확도를 얻었다. 학습이 완료된 CNN을 이용해 철도차량의 차체-대차연결부에서 취득한 균열 결함 신호를 판별한 결과, 99.98% 이상의 확률로 균열성 결함인 바다 노치로 평가되었다. 설계된 CNN을 이용하여 철도차량 차체-대차 연결부의 결함신호를 높은 정확도로 평가할 수 있었다.

CNN을 학습한 초음파 신호의 취득 환경과 철도차량 차체-대차 연결부의 결함신호 취득 환경이 다르다는 관점에서, CNN의 신호 특징을 이해하는 성능이 매우 뛰어나며 철도차량 차체-대차 연결부 손상 검사에 CNN이 적용 가능함을 확인할 수 있었다.

#### References

- [1] Science technology of high-speed train, The science times, April 19, 2004. Available From: <https://www.sciencetimes.co.kr/news>
- [2] H.K.Jun,S.J.Kwon,D.H.Lee,J.W.Seo, "Fatigue crack analysis in a bolster of a metro train," Engineering Failure Analysis, vol. 76, pp.44-54, 2017  
DOI: <https://doi.org/10.1016/j.engfailanal.2017.02.005>
- [3] Railway serious incident investigation report, RI2019-1-I, Japan Transport Safety Board, March 28, 2019. Available From: [https://www.mlit.go.jp/itsb/eng-rail\\_report/English/](https://www.mlit.go.jp/itsb/eng-rail_report/English/)
- [4] H.K Choi, K.S. Seo, "CNN Based detection of surface defects for electronic parts," Journal of Korean Institute of Intelligent Systems, vol. 27, no. 3, pp.195-200, 2017  
DOI: <https://doi.org/10.5391/JKIIIS.2017.27.3.195>
- [5] Y. Park, and I. S. Kweon, "Ambiguous surface defect image classification of AMOLED displays in smartphones," IEEE Trans. on Industrial Informatics, vol. 12, no. 2, pp.597-607, 2016  
DOI: <https://doi.org/10.1109/TII.2016.2522191>
- [6] R. Girshick, J. Donahue, T. Darrell, J. Malik, "Region-Based Convolutional Networks for accurate object detection and segmentation," IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 38, no. 1, pp.42-158, 2016  
DOI: <https://doi.org/10.1109/TPAMI.2015.2437384>
- [7] Y. K. Park, J. G. Park, H. I. On and D. J. Kang, "Convolutional Neural Network-based system for vehicle front-side detection," Journal of Institute of Control, Robotics and Systems, vol. 21, no. 11, pp.1008-1016, 2015  
DOI: <https://doi.org/10.5302/J.ICROS.2015.15.0163>
- [8] D. Tsai and H. Tsai, "Low contrast surface inspection of mura defects in liquid crystal displays using optical flow based motion analysis," Machine Vision and Applications, vol. 22, issue 4, pp. 629-649, 2011  
DOI: <https://doi.org/10.1007/s00138-010-0256-1>
- [9] M.K.Lee, K.S.Seo, "Comparison of Region-Based CNN methods for defects detection on metal surface," The Transactions of the Korean Institute of Electrical Engineers, vol.67, no.7, pp.865-870, 2018  
DOI: <https://doi.org/10.5370/KIEE.2018.67.7.865>
- [10] A.R.Kim,D.H.Kim,Y.S.Byun,S.W.Lee, "Crack detection of concrete structure using deep learning and image processing method in geotechnical engineering," Journal of the Korean Geotechnical Society, vol. 34, no. 12, pp.145-154, 2018  
DOI: <https://doi.org/10.7843/kgs.2018.34.12.145>
- [11] N.Munir, H.J.Kim, J.Park, S.J.Song, S.S.Kang, "Convolutional neural network for ultrasonic weldment flaw classification in noisy conditions," Ultrasonics, vol. 94, pp.74-81, 2019  
DOI: <https://doi.org/10.1016/j.ultras.2018.12.001>
- [12] N.Munir, H.J.Kim, S.J.Song, S.S.Kang, "Investigation of deep neural network with drop out for ultrasonic flaw classification in weldments," Journal of Mechanical Science and Technology, vol. 32, no. 7, pp.3073-3080, 2018  
DOI: <https://doi.org/10.1007/s12206-018-0610-1>
- [13] N.Munir, J.Park, H.J.Kim, S.J.Song, S.S.Kang, "Performance enhancement of convolutional neural network for ultrasonic flaw classification by adopting autoencoder," NDT & E International, vol. 111, pp.1-13, 2020  
DOI: <https://doi.org/10.1016/j.ndteint.2020.102218>

권 석 진(Seok-Jin Kwon)

[정회원]



- 2003년 3월 : Tohoku university  
기계지능공학과(공학박사)
- 1995년 1월 ~ 현재 : 한국철도기  
술연구원 책임연구원

〈관심분야〉

손상평가, 비파괴 센싱

---

김 민 수(Min-Soo Kim)

[정회원]



- 2003년 8월 : 숭실대학교 전기공  
학과(공학박사)
- 2005년 12월 ~ 현재 : 한국철도기  
술연구원 책임연구원

〈관심분야〉

철도차량 제동시스템, 인공지능