

무인체 탑재용 이중영상 스캐닝을 통한 딥러닝 기반의 구조물 균열 평가 기술

Deep Learning-Based Structural Crack Evaluation Technique Through UAV-Mounted Hybrid Image Scanning



안 윤 규*
An, Yun-Kyu



장 근 영**
Jang, Keun-Young

1. 서론

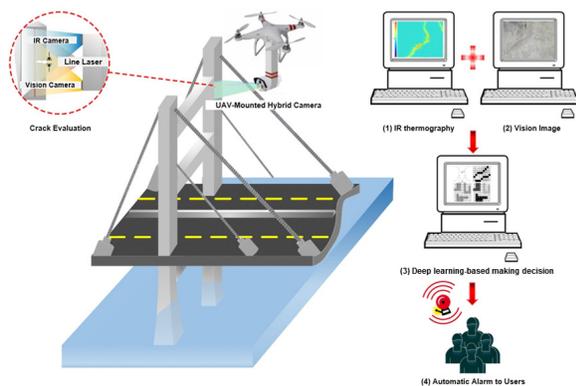
현대 사회에서 도로, 철도, 교량, 댐, 재방, 항만 등과 같은 사회기반시설(SOC)은 경제, 사회, 문화 등 다양한 측면에서 인간의 삶에 직·간접적인 영향을 미치고 있다. 국내의 경우 SOC 개발 사업은 1960년대 이후 급격한 경제 성장의 토대가 되어왔으며, 현재에도 삶의 질을 높이기 위한 다양한 시도로 이어지고 있다. 2015년 한국시설안전공단 통계에 따르면, 국가관리대상 시설인 1·2종 시설물 중 30년 이상의 사용연수를 가진 노후화 시설물의 개수와 비중이 2,862개(4%)였으며, 2030년경에는 26,209

개(36.9%)로 급격한 노후화 추세가 전망되고 있다¹⁾. 이와 같은 SOC의 급격한 노후화는 사용성 저하 및 예기치 못한 사고로 이어질 수 있으며, 이는 개인의 인명, 재산 피해뿐만 아니라 심각한 사회적 문제를 불러일으킬 수 있다. 따라서, 기존의 SOC 유지관리에 대한 보다 체계적인 관리 대책이 필요한 실정이다. 이와 맞물려, 최근 뜨거운 감자로 떠오른 4차 산업혁명의 흐름에 따라 신기술의 발전은 가속화되고 있으며, 특히 드론, 로봇 등의 무인체 기반의 자동화 기술의 개발은 SOC 유지관리에 새로운 지평을 열어주고 있다. 실제로, 임팩트 에코 장치가 설치된 클라이밍 로봇을 통해 교량의 손상을 진단하거나²⁾, 드론에 내장된 카메라를 통해 인력 접근이 어려운 구조물의 표면 균열을 평가하는 등 새로운 유지관리 기술들이 제안되고 있다³⁾. 이와 같은 다양한 유지관리 센싱 기술이 개발되면서, 점차 데이터의 양은 증가하게 되고, 전문가가 직접 데이터를

* 세종대학교 건축공학과 교수
Department of Architectural Engineering, Sejong University

** 세종대학교 건축공학과, 석사과정
Department of Architectural Engineering, Sejong University

처리하는 기존 방식의 변화가 일기 시작하였다. 최근 각광받고 있는 인공지능(Artificial Intelligence) 기술이 그 대안으로 떠오르고 있다. 특히, 딥러닝(Deep learning) 기술은 불확실성이 큰 SOC의 대용량 데이터로부터 유의미한 데이터를 추출하거나 구분지어 유지관리에 최종 의사결정을 위한 과학적 근거로 활용하는데 매우 적합하다고 할 수 있다. 예컨대, 기존에 전문가의 육안검사나 이미지 프로세싱으로 평가에 한계점이 많았던 도로 아스팔트의 균열 검출이나⁴⁾, 콘크리트에 발생한 균열을 자동으로 검출하기 위한 용도로 사용되고 있다⁵⁾. 본고에서는 <Fig. 1>에 나타낸 바와 같이 무인체에 탑재하기 위한 이중영상 스캐닝 시스템을 소개하고, 이로부터 취득된 대용량 데이터를 딥러닝 기반으로 처리하는 자동화 구조물 균열 평가 기술을 소개하고자 한다.



<Fig. 1> Hybrid image scanning system embedded on to UAVs

2. 이중영상 균열 평가 기술

2.1 구조물 균열 평가 기술의 소개

구조물 균열 평가에 가장 널리 사용되는 방법은 육안 평가로, 전문 인력의 역량에 따라 그 신뢰도의 차이가 발생할 수 있으며, 노동집약적인 단점이 있다⁶⁾. 이와 같은 단점을 보완하기 위해 다양한 비파괴 검사 기술들이 제안되어 왔다. 탄성파를 이용한 균열 평가 방법은 가장 널리 사용되고 있는 비파괴

기술로 부착식 센서 혹은 접촉식 탐촉자를 활용하여 탄성과 응답을 계측하는 방식이 일반적이다^{7),8)}. 최근에는 비접촉식 혹은 원격 탄성과 가진 및 계측이 가능한 레이저 초음파 기법에 대한 연구도 활발히 진행 중이다. 이와 같은 탄성과 기반의 기술은 균열 검출의 민감도가 매우 높은 장점을 지니나, 국부적인 균열 평가에 그치는 경우가 많고, 균열 진단을 위한 신호 해석이 복잡하다는 단점이 있다. 특히, SOC에 가장 널리 쓰이는 콘크리트 구조물의 경우, 탄성과 감쇄율이 매우 커서 계측된 신호의 신호대 잡음비(SNR)가 낮거나, 불균질한 재료특성으로 인하여 신호 해석이 난해한 경우가 보통이다. 다음으로 와상 전류(Eddy current) 기술이 균열 평가에 이용되고 있으나, 전자기 현상을 유도해야 하므로 전도성 물체가 아니면 균열을 평가할 수 없다는 한계점이 있다⁹⁾. 또 광학 센서(Fiber optic sensor)를 이용한 구조물 진단 방법이 있다. 광학 센서는 그 크기가 작고 비용이 적게 들며 전자파의 간섭을 받지 않아 신뢰도 높은 계측을 할 수 있다는 장점이 있다. 다만 수명이 짧아 지속적인 계측이 어렵다¹⁰⁾. 다른 방법으로 플래시, 와상 전류, 레이저 등의 열원을 활용하여 열파를 가하고 이를 계측하는 열화상 기법이 있으며 구조물 재료특성에 관계없이 적용 가능하며 효과적인 균열 검출 기법이다. 특히, 레이저를 활용한 열화상 기법은 레이저가 갖는 일직진성(Directionality) 및 비발산성(Non-divergence) 등으로 인해 열원의 조작성이 간편하고 쉽고 빠르게 열파를 생성할 수 있다¹¹⁾. 다만 영상의 시야각(Field Of View, FOV)의 한계를 가지며, 과도한 정밀도로 인하여 표면의 불균일 점을 균열로 평가하는 오보의 가능성이 존재한다.

다양한 비파괴 균열 평가 기술들이 제안되어 왔으나 SOC 적용에 기술적 한계점을 지니고 있다. 최근 카메라 성능의 급격한 발전과 더불어 비전 영상 기반의 균열 평가 기법이 널리 연구되고 있다. 표면 균열 검출만이 가능하지만, 상대적으로 저비용으로 계측이 가능하고, 직관적 해석이 가능하며, 비교적

간단한 데이터 프로세싱으로 균열 진단이 가능한 장점이 있다. 최근에는 드론에 고성능 비전 카메라를 부착하여 이미지를 취득, 이미지 프로세싱을 통해 균열 평가를 하는 기법들이 제안되고 있다. 이는 인력 접근이 어려운 부분이 많은 SOC 구조물의 특성상 적용이 불가능했던 다수의 비파괴 기술들의 한계점을 뛰어넘는 획기적인 시도라고 볼 수 있다. 다만, 비전 영상을 통한 균열 평가 기법은 촬영 각도나 조도, 구조물 표면 이물질 등의 주변 환경에 의해 오보가 생길 가능성이 있다. 특히, FOV의 한계로 인해 교량이나 댐과 같은 대규모 SOC 구조물의 균열 평가에는 어려움이 따른다.

2.2 균열 평가를 위한 이미지 프로세싱

정밀한 균열 평가를 위하여 일련의 데이터 프로세싱 과정을 거치게 된다. 우선, 스캐닝으로 취득된 이중영상 이미지는 카메라 렌즈에 의해 생기는 렌즈 왜곡 때문에 실제 균열의 크기를 정확하게 반영하지 못한다. 따라서 정확한 균열 정량화 및 비전 이미지와 열화상 이미지의 균등한 비교를 위해 이미지 왜곡 보정 과정을 거치게 된다. 교정 마커를 평면에 붙인 상태로 다양한 각도에서 여러 이미지를 촬영하여 카메라 내부·외부 파라미터를 추출한 후, 이를 통해 발생한 왜곡을 보정할 수 있다¹²⁾.

다음으로 스캐닝을 통해 얻은 이미지를 통합하는 과정이 필요하다. 카메라를 통한 균열 평가는 FOV의 한계로 인해 교량과 같은 대형 구조물의 균열 평가가 어렵다. 이와 같은 한계를 극복하기 위하여 시공간 통합 좌표 변환 프로세스를 수행한다. 드론이 정해진 경로를 이동함에 따라 얻어지는 이중영상에는 정해진 FOV 내에서 시간에 따라 변화하는 공간의 이미지들을 취득하게 된다. 여기서 레이저로 가진 열파의 영향을 받는 영역을 관심 영역(Region Of Interest, ROI)으로 정하고, 해당 영역만을 프로세싱하게 된다. 시공간 통합 좌표 변환은 다음 수식(1)에 따라 수행된다.

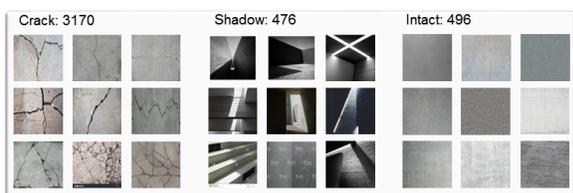
$$\begin{bmatrix} x^* \\ y \\ t^* \end{bmatrix} = \begin{bmatrix} 0 & 0 & v & 0 \\ 0 & 1 & 0 & -\mu(x) \\ 1/v & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} x \\ y \\ t \\ 1 \end{bmatrix} \quad (1)$$

이때 $\mu(x) - 2\sigma \leq y \leq \mu(x) + 2\sigma$ 이며, $\mu(x)$ 는 가진 라인형태의 레이저의 중앙 기준점, σ 는 표준편차, v 는 스캐닝 속도, $[x^*, y, t^*]$ 는 변환된 좌표축을 나타낸다. 해당 프로세스를 통해 각 이중영상 이미지는 FOV의 제한에서 벗어나 전체 ROI 상에서 균열 정보를 확인할 수 있도록 공간적으로 통합된 이미지로 변환된다. 특히, 열화상 이미지에서 라인 레이저를 통해 국부적으로 발생하였던 열파를 전체 ROI에 대해서 동시에 균등한 열파가 발생하는 이미지로 통합하는 결과를 얻어낼 수 있다.

마지막으로, 앞선 프로세스를 통해 공간적으로 통합된 열화상 이미지는 표면 불균일 및 다양한 계층 노이즈에 노출되어 있고, 따라서 균열 시각화 및 노이즈 제거를 위한 부가적인 프로세스가 필요하다. 특히, 특정 이미지 안에서의 미세 균열은 큰 균열의 영향으로 그 특성치가 드러나지 않을 가능성이 있다. 이와 같은 한계점은 위상 맵핑 프로세스를 통해 극복 가능하며, 다양한 크기의 균열이 특정 이미지에 공존하는 경우에 있어 균열 평가의 성능을 극대화시킬 수 있다. 위상 맵핑 프로세스는 힐버트 변환(Hilbert transform)을 통해 각 픽셀 값의 즉시적 위상 값을 추출해 낼 수 있고, 이를 다시 해당 이미지에 매핑하는 과정이다. 본 과정을 통해 각 픽셀 값들이 $-\pi$ 에서 π 사이의 값으로 평준화되며, 큰 균열의 존재 여부와 상관없이 미세 균열로부터 발생한 특성치를 극대화 및 시각화하게 된다. 하지만, 이와 같은 위상 맵핑 프로세스는 균열 특성치 뿐만 아니라 노이즈 성분도 증가시키는 결과를 낳게 되고, 이는 스캐닝 방향의 공간 미분 과정을 통해 제거 가능하다. 이와 같은 일련의 프로세싱 과정을 통해 균열 특성치만을 시각화하는 것이 가능하다.

2.3 딥러닝 기반의 균열 정보 추출

딥러닝 기반의 균열 추출을 위해서는 균열의 특 성치에 대한 학습이 된 인공신경망의 구축이 필요 하다. 이를 위해 <Fig. 2>에 나타난 바와 같이 다양 한 균열 영상 3,170, 비균열 영상 972 종류를 인공 신경망에 학습시켰으며, Fully-connected layer와 Classification output layer를 전이 학습(Transfer learning)을 통해 균열 특성치 검출용 인공신경 망으로 재구축하였다⁴³⁾. 이때, 데이터 확장(Data augmentation)을 통해 다양한 균열 형태를 학습시 킴으로써 학습 데이터의 질을 높이고, 균열 추출의 정확도를 높이고자 하였다. 인공신경망에 데이터 학습이 완료되면, 상기 이미지 프로세싱으로 취득 된 비전 이미지에 나타난 균열을 자동으로 평가할 수 있다. 이때 합성곱 인공신경망(Convolutional Neural Network, CNN)을 활용하였으며, 균열 추 출의 신뢰도를 높이기 위해서는 마스크의 크기 및 임계처리(Thresholding)의 최적화가 필요하다. 마 지막으로, 비전 이미지로부터 자동 추출된 균열 정 보에 대해 열화상 이미지에서 얻어진 균열 정보와 정합함으로써 딥러닝 과정에서 발생한 오보를 최소 화할 수 있다.



<Fig. 2> Training images

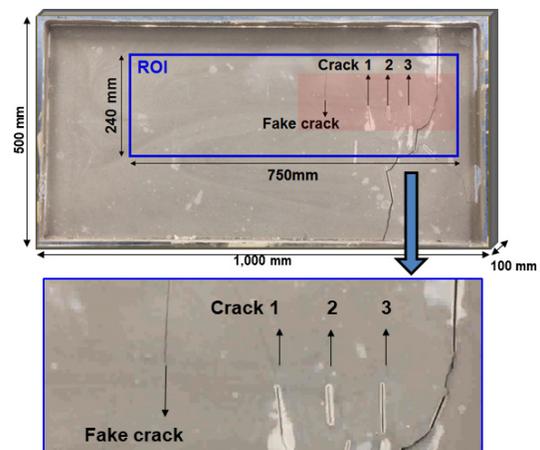
3. 실내검증 실험 및 결과

이종영상 스캐닝 기반의 요소 기술 개발 및 검증 을 위해 실내 실험을 진행하였으며, <Fig. 3>에 보 는 바와 같이 균열이 모사된 콘크리트 시험편을 준 비하였다. 콘크리트 시험편은 시멘트, 실리카샌드, 플라이애시, 고성능감수제, 물을 <Table 1>에 나타 난 바와 같이 배합하였다. 콘크리트 시험편의 크기

는 1,000×500×100mm³이며, <Fig. 3>과 같이 우측면에만 균열 모사를 위해 500μ m 두께의 아크 릴 조각을 양생 시 삽입하였고, 다양한 크기의 균열 이 발생하였다. 또한, 오보 테스트를 위하여 펜을 이용하여 가짜 균열을 표면에 모사하였다.

<Table 1> The material properties of concrete specimen(%)

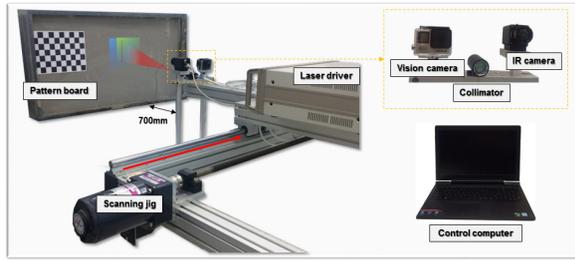
Cement (Type)	Silica sand	Fly ash	Super-plasticizer	Water
100 (Ⅲ)	100	15	0.9	35



<Fig. 3> Concrete specimen

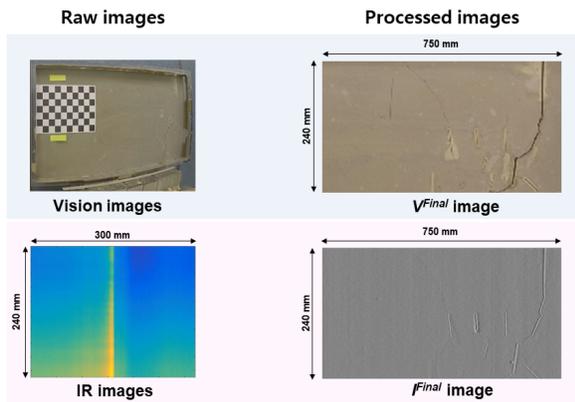
<Fig. 4>는 콘크리트 시험편을 스캐닝하기 위한 이종영상 시스템 전반을 나타낸다. 이종영상 시스 템을 탑재한 드론이 한 방향으로 스캐닝하는 것을 모사하기 위해, 이동식 지그(Jig)에 시스템을 설치 하여 지그를 수평 방향으로 23mm/s의 속도로 스캐 닝하였다. 실험에 사용된 레이저의 파장대는 940nm 로 비가시 영역에 해당하며, 라인 빔의 크기는 1× 135mm²이고, 111mW/mm²의 강도를 갖는다. 시험 편으로부터 700mm 거리에 위치한 라인레이저는 시험편의 표면에 열파를 가하며, 비전 카메라와 열 화상 카메라는 스캐닝과 동시에 이미지들을 취득한 다. 비전 카메라는 1,080×1,920, 열화상 카메라는 640×512의 해상도를 가지며, 모두 30Hz의 프레임 속도(Frame rate)를 가진다. 이와 같은 시스템의

각 장비는 상호 동기화되어 있고, 제어 컴퓨터에 의해 제어, 측정 및 프로세싱이 진행된다.



〈Fig. 4〉 Experimental setup

〈Fig. 5〉는 실내 검증 실험에서 취득된 이미지 프로세싱 결과를 나타내고 있다. 앞서 설명한 일련의 프로세싱을 거쳐 각 이미지는 국부적인 FOV의 한계에서 벗어나 전체 ROI 내에 존재하는 균열 정보를 시각화 한 것을 확인할 수 있다.

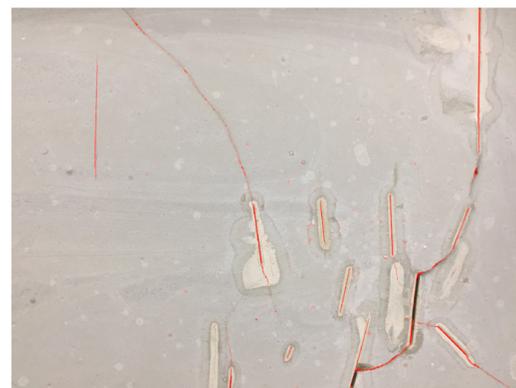


〈Fig. 5〉 Image processing results

균열의 특성치에 대한 학습이 된 인공신경망을 활용하여, 본 실험에서 일련의 프로세싱 과정으로부터 얻어진 비전 이미지를 테스트 이미지로 설정하여 자동화 균열 검출을 수행하였다. 마스크 사이즈는 20×20 으로 하여 $100\mu\text{m}$ 대역의 균열을 검출할 수 있도록 하였고, 임계값을 99%로 설정하여 최대한 노이즈를 배제한 결과를 얻었으며, 이를 테스트 이미지에 맵핑하면 〈Fig. 6〉과 같은 결과를 얻을 수 있다.

자동화 검출의 결과로 정확도(Accuracy) 99.71%,

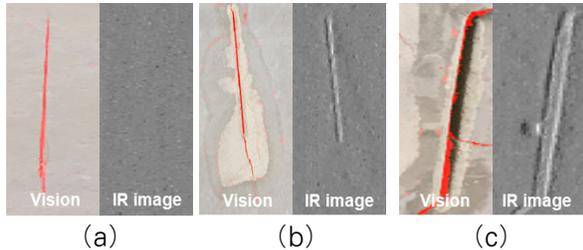
정밀도(Precision) 69.89%, 재현율(Recall) 90.29%를 나타내었다. 여기서 정확도란 비전 이미지의 전체 영역에서 딥러닝 프로세스에 의해 균열 및 건전 영역을 검출한 정도를 나타내는 것으로 가짜 균열과 노이즈 등을 제외하면 비교적 정확한 99.71%의 정확도를 나타냈다. 정밀도는 딥러닝 프로세스에 의해 균열이 아님에도 불구하고 균열로 오인한 비율을 포함하는 의미로, 〈Fig. 7〉 (a)와 (b)에 나타난 것과 같이 가짜 균열을 실제 균열로 검출한 오보(False positive) 및 콘크리트 시편 표면의 불균질성으로 인하여 69.89%의 상대적으로 낮은 정밀도를 보였다. 재현율은 실제 균열 검출이 누락된 비율을 포함하는 의미로, 대체로 균열을 검출하였으나, 〈Fig. 7 (c)〉와 같이 균열이지만 균열로 검출하지 못하는 오보(False negative)로 인해 90.29%를 기록하였다.



〈Fig. 6〉 Deep learning results using VFinal image with threshold 99% (Red line: crack feature)

비전 이미지에서의 딥러닝을 통한 자동화 균열 검출의 결과는 다양한 표면 상태 및 노이즈의 영향으로 오보의 가능성이 크기 때문에 해당 이미지를 열화상 이미지와 정합하여 균열 검출의 신뢰도를 향상시킬 수 있다. 정합의 결과로 정확도 99.99%, 정밀도 98.72%, 재현율 99.23%를 나타내었으며, 〈Table 2〉에 나타난 것과 같이 비전 이미지의 딥러닝 검출 결과와 약 정확도 0.18%, 정밀도 28.83%,

재현율 8.94%의 향상을 나타내었다. 이는 정합을 통해 나타난 오보가 최소화 되어 균열 검출의 신뢰도가 높아진 결과이다.



〈Fig. 7〉 False alarms: due to
 (a) Fake crack (False positive case)
 (b) Noises (False positive case)
 (c) Non-detected crack (False negative case)

〈Table 2〉 Vision & IR image matching result(%)

	Vision	Vision/IR	Variation
Accuracy	99.71	99.99	0.18
Precision	69.89	98.72	28.83
Recall	90.29	99.23	8.94

4. 맺음말

본고에서 소개한 드론을 활용한 이중영상 스캐닝 기반의 균열 평가 시스템은 넓은 영역, 특히 인력 접근이 어려운 대형 구조물에 활용이 가능할 것으로 기대한다. 더욱이 본 기술은 딥러닝 알고리즘을 활용하여 균열 검출의 자동화를 수행하였고 비전 및 열화상 이미지의 이중영상 정보를 활용함으로써 균열 검출 성능을 향상시키고, 오보를 최소화 할 수 있다는 장점을 지닌다. 본고에서는 해당 요소 기술 개발만을 다루었으나 현재 시스템의 소형화 및 최적화 과정을 거치고 있고, 드론에 직접 장착하여 현장실험을 계획 중이다. 4차 산업혁명에 따라 건설 산업의 미래는 새로운 국면이 예상된다. 이와 같은 흐름에 보조를 맞추어 이와 같은 신기술에 대한 연구는 필수적이며 구조물의 유지관리 차원에서 상당

한 질적 향상을 가져올 것으로 기대된다. 나아가 본 기술은 SOC 구조물뿐만 아니라 기계시스템, 항공기, 반도체 등에 발생하는 균열 검출에도 적극 활용이 가능하기 때문에 요소기술 개발은 다양한 분야의 확장으로 이어질 수 있을 것으로 판단된다.

References

1. Korea Facilities Maintenance Association (www.fma.or.kr), 2017.
2. Li, B., Ushiroda, K., Yang, L., Song, Q., & Xiao, J., Wall-climbing Robot for Non-destructive Evaluation using Impact-echo and Metric Learning SVM, International Journal of Intelligent Robotics and Applications, Vol.1, 2017.
3. Kim, J., Kim, S., Park, J., & Nam, J., Development of Crack Detection System with Unmanned Aerial Vehicles and Digital Image Processing, Advances in Structural Engineering and Mechanics, 2015.
4. Zhang, L., Yang, F., Daniel Zhang, Y., & Zhu, Y. J., Road Crack Detection Using Deep Convolutional Neural Network, 2016 IEEE International Conference on Image Processing (ICIP), Vol.28, 2016.
5. Cha, Y.-J., Choi, W., & Bykzrk, O., Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks, Computer-Aided Civil and Infrastructure Engineering, Vol.29, 2017.
6. Chang, P. C., Flatau, A., & Liu, S. C., Review Paper: Health Monitoring of Civil Infrastructure, Structural Health Monitoring, Vol.2, 2003.
7. Sun, F., Wang, N., He, J., Guan, X., & Yang, J., Lamb Wave Damage Quantification Using GA-Based LS-SVM, Materials, Vol.10, 2017.
8. Dumoulin, C., & Deraemaeker, A., Real-time

- Fast Ultrasonic Monitoring of Concrete Cracking using Embedded Piezoelectric Transducers, *Smart Materials and Structures* Vol.26, 2017.
9. Chady, T., Enokizono, M., & Sikora, R., Crack Detection and Recognition using an Eddy Current Differential Probe, *IEEE Transactions on Magnetics*, Vol.35, 1999.
 10. Maheshwari, M., Annamdas, V. G. M., Pang, J. H. L., Asundi, A., & Tjin, S. C., Crack Monitoring using Multiple Smart Materials: Fiber-optic Sensors & Piezo Sensors, *International Journal of Smart and Nano Materials*, Vol.8, 2017
 11. An, Y. K., Min Kim, J., & Sohn, H., Laser Lock-in Thermography for Detection of Surface-breaking Fatigue Cracks on Uncoated Steel Structures, *NDT and E International*, Vol.65, 2014.
 12. Zhang, Z., A Flexible New Technique for Camera Calibration, *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.22, 2010.
 13. Krizhevsky, A., Sutskever, I., & Hinton, G. E., ImageNet Classification with Deep Convolutional Neural Networks, *Advances In Neural Information Processing Systems*, 2012.