

일반논문 (Regular Paper)

방송공학회논문지 제27권 제2호, 2022년 3월 (JBE Vol.27, No.2, March 2022)

<https://doi.org/10.5909/JBE.2022.27.2.228>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

변화 주목 기반 차량 흠집 탐지 시스템

이 은 성^{a)}, 이 동 준^{a)}, 박 건 희^{b)}, 이 우 주^{a)}, 심 동 규^{a)}, 오 승 준^{b)†}

Change Attention-based Vehicle Scratch Detection System

EunSeong Lee^{a)}, DongJun Lee^{a)}, GunHee Park^{b)}, Woo-Ju Lee^{a)}, Donggyu Sim^{a)}, and
Seoung-Jun Oh^{b)†}

요 약

본 논문에서는 카셰어링 서비스(car sharing service)에서 차량 상태 무인 검수를 위한 흠집 탐지 딥 러닝 모델을 제안한다. 기존의 차량 상태 검수 시스템은 대여 전, 후 사진에서 각각 흠집을 탐지하는 딥 러닝 모델과 탐지된 두 흠집 영상을 수작업으로 대조하여 새롭게 발생한 흠집을 탐색하는 두 단계로 구성되어 있다. 따라서 수동작업이 필요한 두 단계 모델을 한 단계로 줄이는 무인 흠집 탐지 모델을 위성영상에서 변화를 탐지하는 딥 러닝 모델에 전이 학습을 적용하여 구축한다. 그리고 광택 처리된 자동차 표면의 휘도가 비등방성이고 비전문가인 이용자가 일반 카메라로 촬영하기 때문에 정반사(specular reflection)가 흠집 탐지 성능에 크게 영향을 미친다. 따라서 정반사광으로 발생하는 오탐지를 감소시키기 위하여 정반사광 성분을 제거하는 전처리 과정을 적용한다. 이용자가 휴대폰 카메라로 촬영한 데이터에 대해 제안하는 시스템은 주관적인 측면과 정밀도(precision), 재현율(recall), F1, Kappa 척도면에서 각각 67.90%, 74.56%, 71.08%, 70.18%로서 높은 일치도를 보인다.

Abstract

In this paper, we propose an unmanned vehicle scratch detection deep learning model for car sharing services. Conventional scratch detection models consist of two steps: 1) a deep learning module for scratch detection of images before and after rental, 2) a manual matching process for finding newly generated scratches. In order to build a fully automatic scratch detection model, we propose a one-step unmanned scratch detection deep learning model. The proposed model is implemented by applying transfer learning and fine-tuning to the deep learning model that detects changes in satellite images. In the proposed car sharing service, specular reflection greatly affects the scratch detection performance since the brightness of the gloss-treated automobile surface is anisotropic and a non-expert user takes a picture with a general camera. In order to reduce detection errors caused by specular reflected light, we propose a preprocessing process for removing specular reflection components. For data taken by mobile phone cameras, the proposed system can provide high matching performance subjectively and objectively. The scores for change detection metrics such as precision, recall, F1, and kappa are 67.90%, 74.56%, 71.08%, and 70.18%, respectively.

Keyword : car sharing, deep learning, change detection, change attention, specularity removal

1. 서론

다양한 공유경제가 활성화되고 있고 그중에서 차량 공유 서비스인 카셰어링이 주목받고 있다. 카셰어링은 기존의 렌터카 서비스에서 발전되어 시간 단위로 애플리케이션을 통해 비대면으로 차량을 대여, 반납하는 서비스로 유연하고 간편한 방법에 기반을 둔 좋은 접근성으로 시장이 빠르게 성장했다. 한국의 카셰어링 시장은 13년 약 17만 명의 이용자에서 약 977만 명의 이용자로 매년 지속해서 성장하고 있다^[1].

차량은 키잉(keying)과 같은 의도적인 손상부터 교통사고, 도로 낙하물 등과 같은 다양한 원인으로 외관에 흠집이 발생할 수 있다^[2]. 카셰어링 서비스의 핵심은 차량이므로, 지속적인 관리 및 모니터링이 필요하다. 현재의 카셰어링은 사용자가 차량을 대여 시 차량 외관의 사진을 촬영하게 되어있어 이 사진으로 차량을 모니터링한다. 카셰어링 업체 중 하나인 쏘카 같은 경우 하루평균 7~8만 장, 최대 11만 장의 사진이 업로드된다. 만약 이러한 다량의 업로드된 사진을 수작업 모니터링하고 검수할 경우 많은 인적자원이 투입된다^[3].

따라서 이러한 차량 상태 모니터링을 무인화하기 위해 딥 러닝(deep learning) 기반의 차량 흠집 탐지 연구가 진행되었다. 흠집 탐지를 위해 쏘카의 경우 U-Net 기반의 흠집 탐지 모델을 개발하여 차량의 흠집을 탐지하여 사진 검수의 필요인력을 줄이고, 검수 과정의 시간을 줄여 기존의 수작업으로 검수하던 방법보다 효율적인 일 처리가 가능하게 만들었다^[3]. 이 외에 Zhang은 단일 차량 사진을 입력받아

개선된 Mask RCNN을 이용해 차량의 흠집 영역을 분류하는 방법을 제안했다^[4]. Waqas은 FIA(fake image analysis) 모듈을 이용해 가짜 이미지를 걸러내고 전이 학습(transfer learning)을 적용한 MobileNet을 이용해 단일 차량 사진의 흠집을 검출하는 방법을 제안했다^[5]. Zhu는 단일 차량 사진에서 객체 탐지(object detection), 영상 분할(image segmentation), 영상 분류(image classification)로 이루어진 통합 프레임워크를 통해 차량 흠집을 분류했다^[6].

하지만 이와 같은 딥 러닝을 도입한 기존 흠집 탐지 시스템은 문제를 가지고 있다. 기존 시스템은 흠집 발생을 탐지하기 위해 대여 전·후 차량의 사진을 카셰어링 이용자가 직접 촬영하여 업로드를 하고 그림 1 (a)의 기존 두 단계의 차량 흠집 탐지 시스템(convolutional two step vehicle scratch detection system) 과 같이 이용자가 업로드한 사진에 대해 각각 객체 탐지를 통해 모든 흠집을 탐지한다. 따라서 검수 과정에서 새롭게 생긴 흠집인지 아닌지 판단하기 위해 두 장의 흠집 탐지 결과 사진을 비교하는 후처리 과정에서 사람의 검수가 필요하다^{[3][8]}. 즉, 기존 흠집 탐지 시스템은 추가적인 인력이 투입되는 과정이 추가로 포함되어 있다. 이러한 문제를 해결하기 위해 그림 1 (b)의 제안하는 한 단계의 차량 흠집 탐지 시스템(proposed one step vehicle scratch detection system)과 같이 업로드 된 차량의 대여 전·후 사진의 변화 탐지(change detection)를 통해 과거에 생긴 흠집과 새롭게 생긴 흠집을 구별하여 새롭게 생긴 흠집만 검출하는 완전 무인 흠집 탐지 모델이 필요하다.

비전에서의 3D 재구성, 객체 탐지, 인식, 목표 추적, 변화 탐지 알고리즘들은 대부분 빛에 의한 정반사가 없다는 가정하에 만들어진다^[9]. 카셰어링 서비스에서 입력으로 사용되는 사진은 다양한 원인으로 정반사가 발생한다. 카셰어링 서비스 이용자는 일반적으로 휴대폰 사진을 이용해 대여 전·후 사진을 촬영하며 사진 촬영에 비전문가이다. 그리고 코팅된 차량 표면은 램버시안 반사율을 갖지 않아 정반사로 인한 잡음이 발생한다. 이러한 잡음은 흠집 탐지 성능에 악영향을 끼칠 수 있으므로 이용자가 촬영한 사진에서 오탐지의 원인이 되는 정반사를 제거할 필요가 있다^[10].

따라서 본 논문에서는 무인으로 새로운 흠집을 탐지하기 위해 변화 탐지 모듈을 사용한다. 또한, 흠집 탐지의 성능을

a) 광운대학교 컴퓨터공학과(Department of Computer Engineering, Kwangwoon University)

b) 광운대학교 전자공학과(Department of Electronic Engineering, Kwangwoon University)

‡ Corresponding Author : 오승준(Seung-Jun Oh)

E-mail: sjoh@kw.ac.kr

Tel: +82-2-940-5102

ORCID: <https://orcid.org/0000-0002-5036-3761>

※ 이 논문은 2021년도 광운대학교 우수연구자 지원 사업에 의해 연구되었음.

※ The present research has been conducted by the Excellent researcher support project of Kwangwoon University in 2021.

· Manuscript received February 8, 2022; Revised March 21, 2022; Accepted March 21, 2022.

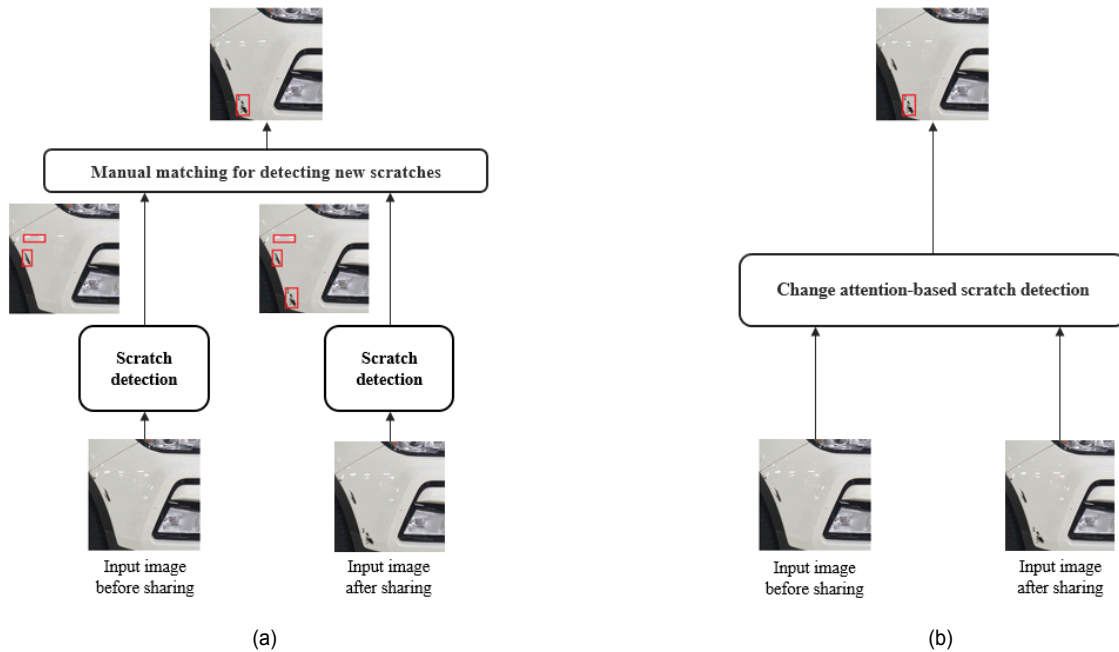


그림 1. 차량 흠집 탐지 시스템 예시 (a) 기존 두 단계 시스템 (b) 제안하는 한 단계 시스템
 Fig. 1. Example of the vehicle scratch detection system: (a) Conventional two step system, (b) Proposed one step system

높이기 위해 전처리 과정으로서 반사 제거(specularity removal)를 추가한 변화 주목 기반 흠집 탐지 시스템을 제안한다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구에 대해 설명하고, 3장에서는 제안하는 방법에 대해 자세하게 설명한다. 그리고 4장에서는 제안하는 방법의 실험 결과와 그 분석을 하고 5장에서 결론을 맺는다.

II. 관련 연구

1. 반사 제거

카셰어링 서비스는 일반적으로 모바일 어플리케이션을 통해 차량 대여 반납이 이루어진다. 사용자가 직접 대여할 때와 반납할 때 찍어서 올린 사진들을 비교하여 차량 흠집 발생을 판단하게 된다. 이러한 서비스 환경에서 자동으로 흠집을 검출하는 과정에서는 다음과 같은 두 가지 원인 때문에 오류가 증가할 수 있다. 먼저 일반적으로 이용자는 사

진 촬영에 비전문가이고 임의의 장소에서 어플리케이션 상에서 휴대폰 사진기를 사용하여 촬영하기 때문에 화질이 양호하지 않다. 두 번째 요인은 차량 표면의 휘도가 등방성을 가지지 않는다는 점이다. 관찰자가 바라보는 각도와 관계없이 같은 겉보기 밝기를 가질 때 램버시안 반사율(Lambertian reflectance)을 갖는다고 하는데 차량 표면의 휘도는 비등방성이어서 램버시안 반사율을 갖지 않는다. 그림 2에서 보여주듯이 램버시안 반사율을 갖지 않는 차량 표면 사진은 광원의 위치에 따라 하이라이트(highlight)를 가진다. 이런 하이라이트가 흠집 탐지 시스템의 오류를 발생시키는 주요 요인이 될 수 있다. 영상의 화소 값은 정반사 성분(specular component)과 난반사 성분(diffuse component)으로 구성되어 있다^[23]. 광택 처리된 자동차 표면 영상은 비등방성을 가진 정반사 성분이 크기 때문에 변화 탐지 분야에서는 그림 2에서 보여주는 하이라이트로 인하여 오탐지의 요인이 될 수 있다^[24]. 그러므로 영상의 각 화소 값에서 난반사 성분과 정반사 성분을 분리하여 방향에 덜 민감한 난반사 성분은 유지하면서 정반사 성분을 제거하는 전처리 과정이 필요하다. 이와 같은 문제를 해결하기 위해 Nayar은




그림 2. 정반사로 인하여 발생한 하이라이트의 예
 Fig. 2. Example of scratch detection errors caused by specular reflection

이미지 센서 앞에 편광 필터를 배치하여 반사 구성요소를 컬러 영상에서 분리하는 것을 제안했다^[25]. 하지만 추가 편광 필터를 사용하는 것은 많은 데이터를 가진 실제 영상 시스템에 적용하기 힘들다. 이를 해결하기 위해 Tan은 최대 색도-명도 공간과 카메라 잡음 분석에 기초하여 색상이 균일한 물체 표면의 정반사광과 난반사광을 분리하는 방법을 제안했다^[26]. 동일한 난반사를 지닌 색상의 물체에서만 정반사를 제거할 수 있고, 다중 색상 표면을 처리할 때 영상 분할과 같은 전처리가 필요한 문제점이 있어서 Tan은 specular-to-diffuse 방법으로 순수 난반사가 포함된 픽셀을 구하고, 최대 색도를 이웃 픽셀의 색도로 반복적으로 이동함으로써 정반사의 특성을 줄여 영상 분할과 같은 SF(specular-free) 영상을 얻어 전처리 없이 정반사광을 제거했다^[27]. 이 방법은 반복적인 프레임워크와 복잡한 상호작용 때문에 처리 시간이 매우 길다. 상기한 문제들을 해결하기 위하여 Shen은 MSF(modified specular-free)를 이용해 기존 방법 대비 빠른 속도로 정반사광을 제거한 알고리즘을 제안했다^[28].

2. 변화 탐지

서로 다른 시간에 촬영된 동일한 위치의 영상에서 변화 영역을 탐지하는 변화 탐지는 원격 탐사(remote sensing)^{[10][11][12][13]}, 비디오 감시(video surveillance)^{[14][15]}, 의료 진단 및 치료(medical diagnosis and treatment)^{[16][17]}, 수중 탐사(underwater sensing)^{[18][19]} 등 다양한 분야에 적용되어 많은 연구가 이루어지고 있다. 최근 딥 러닝의 발전으로 변화 탐

지 분야에서 원격 탐사가 큰 비중을 차지하고 있다^[20]. 딥 러닝 기반 원격 탐사 변화 탐지 알고리즘은 크게 두 가지로 나눌 수 있다^{[21][22]}. 첫 번째는 후 분류 비교(post classification comparison)로 입력 영상을 사전에 정의된 여러 클래스로 분류한 후 라벨을 화소 별로 비교하여 변화를 탐지한다. 따라서 두 영상을 분류할 때 높은 정확도가 필요하며, 누적 오류가 발생할 가능성이 크다. 두 번째는 후 비교 분석(post comparison analysis)으로 종단 간(end to end) 프레임워크를 기반으로 하여 각 입력 영상에서 유사 특징 맵(similarity-feature map)을 생성한 뒤 분석해 변화를 탐지한다.

Chen은 세 개의 FCN(fully convolutional network)을 종단 간 스크래치(scratch) 학습시켜 기존 기계 학습(machine learning) 기반 변화 탐지보다 정확도와 속도를 높였지만, 정합 오차, 변위 오차 등으로 변화 영역 가장자리에 오탐지가 발생한다^[12]. Collins는 주목 메커니즘(attention mechanism)기반 BAM(basic spatial-temporal attention module)과 PAM(pyramid spatial-temporal attention module)을 사용하여 정확도를 높였지만^[14], 두 모듈은 두 피쳐 맵 간의 차이를 계산하는 척도 모듈에 영향을 받는 문제가 발생하고, 학습을 위한 원격 탐사 데이터 수가 적어 스크래치 학습의 정확도가 낮은 문제를 가지고 있다. 상기한 문제들을 해결하기 위하여 [13]에서는 사전 학습된 CNN(convolutional neural networks) 모델을 미세조정하여 변화 탐지 성능을 높인 종단 간 프레임워크인 변화 주목 모듈 기반의 CADNet(Change Attention based Dense siamese Network)을 제안하였다. 그림 3은 CADNet의 구조를 보여준다. 제안하는 시

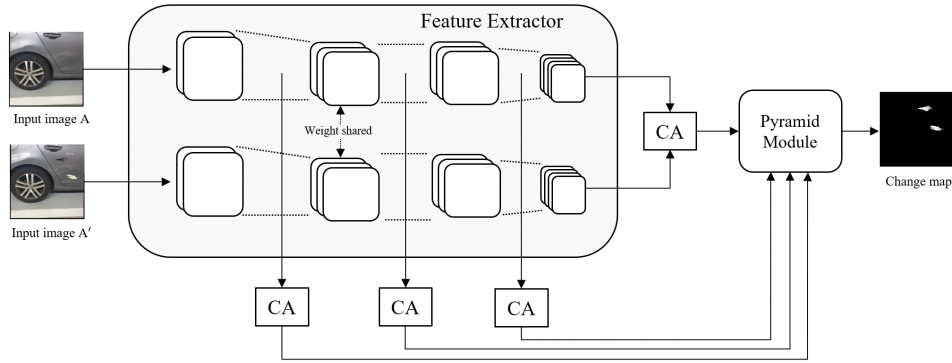


그림 3. CADNet 구조
Fig. 3. CADNet Architecture

시스템은 차량 대여 전, 후 사진에서 새로 생긴 흠집만을 탐지하는 것 즉, 전, 후 사진 간의 변화 특성을 탐지하는 것이기 때문에 CADNet을 훈련 모델로 택하여 모델의 가중치를 재보정하는 전이학습(transfer learning)^{[30][31]}을 적용한다.

III. 변화 주목 기반 차량 흠집 탐지 시스템

본 논문에서는 입력으로 대여 전, 후 두 영상을 받아서 새로운 흠집을 탐지하는 변화 주목 기반 무인 차량 흠집 탐지 시스템을 제안한다. 시스템의 구조는 그림 4와 같이 두 입력 데이터에 대한 전처리 과정인 반사 제거 모듈과 대여 기간에 새롭게 발생한 흠집만을 탐지하는 변화 탐지 딥 러닝 모듈로 구성된다.

1. 반사 제거

흠집 탐지 시스템의 입력 영상은 차량 대여자가 임의의 장소에서 휴대폰 사진기로 촬영한 것이고 일반적으로 차량 표면에서 정반사에 의한 잡음이 크게 발생한다. 이 잡음은 흠집 탐지 성능을 크게 저하할 수 있으므로 정반사 때문에 발생한 잡음 성분을 제거해야 한다. 정반사 성분을 제거하는 방법으로 Shen 알고리즘이 있다^[28]. 이 알고리즘은 영상 분할, 반복적인 프레임워크, 픽셀 간 지역적 상호작용(local interaction) 없이 각 픽셀 단계에서 정반사 성분을 제거하면서, 실

행 속도와 분리 정확도 면에서 우수한 성능을 제공한다. Shen 알고리즘 동작을 요약하면 다음과 같다. 정반사 제거(SF: specular free) 영상을 얻기 위해 그림 4의 입력 영상 A, A'의 화소 위치 x,y 에 대한 RGB 채널의 화소값(pixel value)을 각각 $P_r(x,y), P_g(x,y), P_b(x,y)$ 로 나타내고 이 중에서 최소값인 $P_{min}(x,y)$ 을 $\min\{P_r(x,y), P_g(x,y), P_b(x,y)\}$ 로 정의한다. 영상의 모든 화소에 대하여 $P_{min}(x,y)$ 와 영상에서 계산된 임계값(threshold value) T_p 를 비교하여 화소 위치 x,y 에서 정반사 화소, 난반사 화소 둘 중 하나로 구분한다. 이때 임계값 T_p 는 식 (1)로 정해진다.

$$T_p = \mu_p + \eta\sigma_p \quad (1)$$

식 (1)에서 μ_p 와 σ_p 는 입력 영상의 모든 픽셀에 대한 $P_{min}(x,y)$ 의 평균과 표준편차이고, η 는 영상의 정반사 단계와 관련되는 가중치로서 값이 커질수록 $P_{min}(x,y)$ 의 평균보다 큰 임계값으로 정해진다. 식 (1)의 임계값 T_p 를 이용해 x,y 위치의 화소가 정반사 화소 혹은 난반사 화소로 판단되는데 $P_{min}(x,y)$ 가 T_p 보다 작으면 x,y 위치 화소의 최소값이 $P_{min}(x,y)$ 의 평균보다 값이 작으므로 물체의 색상을 표현하는 난반사 화소로 정의되고, 그렇지 않을 경우 정반사 화소로 정의되어 화소값을 보정하여 정반사 성분을 제거한다. 결과적으로 x,y 위치의 화소에 대한 RGB 값들은 식 (2)와 같다. 식 (2)에서 $P_{SF,i}$ 는 정반사가 제거되도록 수정된 화소값이고 $i = r,g,b$ 다.

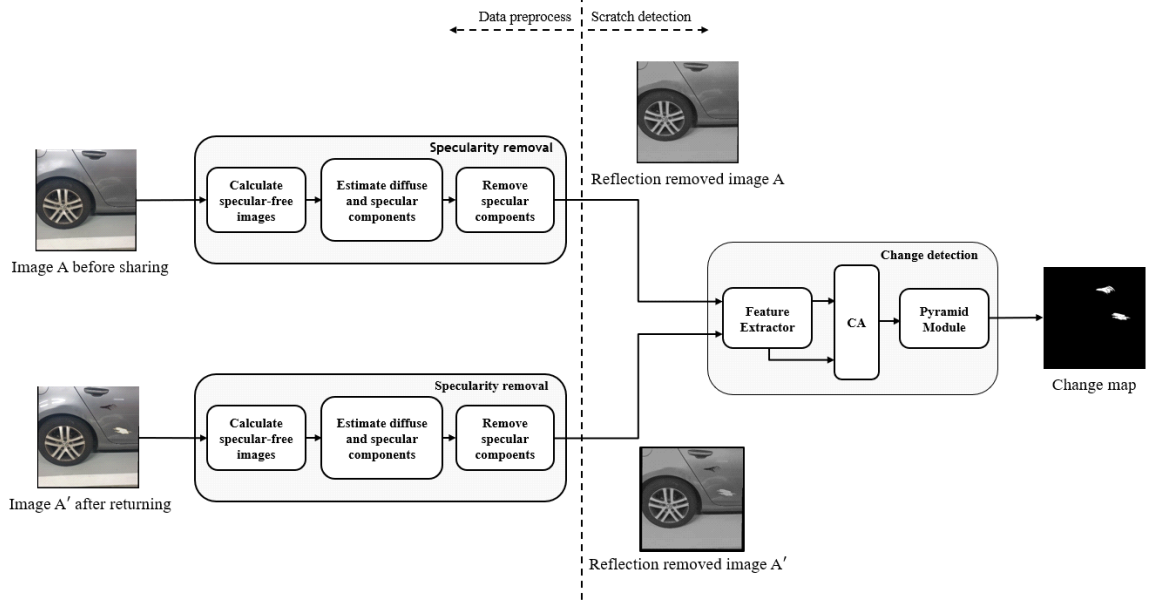


그림 4. 제안하는 변화 주목 기반 차량 흠집 탐지 시스템 블록도
Fig. 4. Block diagram of the proposed change attention-based vehicle scratch detection system

$$P_{SF,i}(x,y) = \begin{cases} P_i(x,y) - k(P_{min}(x,y) - T_p), & \text{if } T_p < P_{min}(x,y) \\ P_i(x,y), & \text{otherwise} \end{cases} \quad (2)$$

T_p 와 $P_{min}(x,y)$ 의 비교를 통해 x,y 의 화소가 정반사가 강한 화소로 판단되면 해당 화소값으로 RGB 각 채널 화소값인 $P_i(x,y)$ 에서 정반사 성분을 제거한 값을 사용한다. 이때 정반사 성분은 $P_{min}(x,y)$ 에서 T_p 를 뺀 값을 사용하며, 제거 수준은 0부터 1사이의 값으로 정해지는 비례상수 k 로 조절하며 k 가 클수록 정반사를 크게 제거한다. x,y 위치의 화소가 난반사 화소로 판단되면 제거할 정반사 성분이 없으므로 RGB 각 채널의 화소값인 $P_i(x,y)$ 를 그대로 사용한다.

코팅된 차량 표면은 램버시안 반사율을 갖지 않아 정반사 영향이 매우 크다. 그러므로 Shen 알고리즘을 제안하는 흠집 탐지 시스템의 전처리로 적용해 정반사 성분을 제거한다. 본 논문에서는 차량 영상에 적합한 비례상수 k 는 다음 장에서 실험적으로 정한다.

2. 변화 탐지

인간의 시각 처리는 정보의 일부에 선택적으로 집중한

다. 이를 모방한 방법인 주목 방법(Attention mechanism)는 컴퓨터 비전 분야에서 입력 영상에 대해 모든 화소에 동일한 가중치를 부여하는 대신 중요한 부분에 초점을 맞춘다^[37]. CADNet은 주목 방법을 이용해 의미 분할 분야에서 특징 표현을 향상하기 위해 자기 주목 모듈 형태인 DANet (dual attention network)^[29]의 공간 주목 모듈을 공동 주목 모듈 형태로 수정하여 사용했다. 이러한 변화 주목 모듈은 영상의 변화된 특징을 주목하여 탐지할 수 있어, 카셰어링 서비스의 차량 외관 검수 시스템에서 대여 전, 후 기간 새롭게 발생한 흠집을 탐지하는데 적합하다. 하지만 CADNet은 위성 영상을 기반으로 건물의 변화를 탐지하기 위해 학습이 이루어져 있다. 이때 CNN기반 딥 러닝 모델은 기존에 다루지 않았던 새로운 영상이 주어지면 자기 학습을 통한 스크래치(scratch) 학습 시 충분한 성능을 내지 못하고 학습에 많은 시간이 소요된다^[36]. 그래서 기존 모델을 새로운 영상에 대해 전이 학습을 적용할 경우 일반화 성능이 향상되고 학습 비용이 절감된다^[33]. 따라서 본 논문에서는 차량의 새로운 흠집을 탐지하기 위해 모델의 가중치를 재보정하는 전이 학습을 적용한다.

전이 학습은 다음과 같이 이루어진다. 먼저 미리 학습된

모델 앞단의 n 개 층(layer)의 가중치를 가져와 목표 모델에 사용한다. 그 후 오차 역전파(backpropagation)를 시행하는데 이때 두 가지 방법이 존재한다. 첫 번째는 앞단 n 개 층의 값은 변하지 않고 뒷단의 층만 갱신하는 것이다. 두 번째는 모든 층의 값을 갱신하는 것으로 이를 미세 조정(fine-tuning)이라고 한다. 두 가지 방법은 데이터 세트(dataset)의 크기와 모델 앞단의 n 개 층의 매개변수 수에 따라 정해진다. 데이터 세트의 양이 적고, 매개변수의 양이 많을 때 과적합(overfitting)을 막기 위해 첫 번째 방법을 사용한다^[32]. 하지만 첫 번째 방법을 이용해 전이 학습을 시킬 때 기존의 데이터 세트와 전이 학습을 수행할 데이터가 유사하지 않으면 성능 향상이 이루어지지 않아, 전체 모델에 전이 학습을 적용하는 것이 성능이 더 적합하다^[33]. CADNet은 학습에 사용한 위성 영상에서 네모난 형태의 건물 변화를 탐지하지만, 차량 흠집 변화 탐지에서는 길고 날카로운 형태의 흠집을 탐지하는 것이기 때문에, 제안하는 모델의 매개변수를 전이 학습을 통하여 미세 조정할 필요가 있다. 따라서 본 논문에서는 위성 영상 기반으로 사전 학습된 모델의 매개변수 전체를 차량 흠집 데이터 세트로 전이 학습을 통해 미세 조정한다.

IV. 실험 결과 및 분석

변화 주목 기반 차량 흠집 탐지 시스템은 파이토치(Pytorch)를 이용해 구현하였으며, Nvidia GeForce GTX 1080 Ti GPU를 이용하여 실험하였다. 배치 크기(batch size)는 2를 사용하였고, 초기 학습률(initial learning rate)은 10^{-4} 를 사용했다. 그리고 최적화기(optimizer)로 Adam (adaptive moment estimation)을 사용하였으며, β_1, β_2 는 각각 0.9, 0.999다. 손실 함수는 이진 교차 엔트로피 손실 함수(binary cross entropy loss function)를 사용하여 변화 맵과 정답 사이의 손실을 최소화하도록 네트워크를 학습하며 식 (3)과 같다. 이때 y 는 정답 레이블(true label), y' 은 예측 레이블(predicted label)이다.

$$L(y, y') = \begin{cases} -\log y' & y = 1 \\ -\log(1 - y') & y = 0 \end{cases} \quad (3)$$

차량 흠집 탐지 시스템은 비슷한 위치에서 촬영된 한 쌍

의 차량 사진에서 흠집 발생 여부를 판단한다. 따라서 유사한 환경에서 촬영되고 흠집 유무가 다른 한 쌍으로 이루어진 차량 사진 필요하다. 그러나 현재 상기한 차량 흠집 공개 데이터 세트가 없으므로 제안하는 시스템을 학습시키기 위하여 2개의 영상이 한 쌍으로 이루어진 데이터 세트를 제작할 필요성이 있다. 또한, 카셰어링 서비스에서 입력 영상은 일반 사용자가 휴대폰 사진기를 이용해 촬영하므로 전문기기가 아닌 휴대폰 사진기로 촬영되어야 한다. 따라서 데이터 세트는 다음의 과정을 거쳐 제작되었다. 휴대폰 사진기를 이용해 1024×1024 크기의 125대의 차량 사진을 직접 촬영한 영상을 사용하였다. 그리고 각 영상을 256×256 크기로 분할한 후 감마 보정(gamma correction)을 통해 데이터를 증강하여 [13]의 데이터 세트와 유사한 양을 구축하였다. 감마 값으로 {0.7, 0.85, 1.0, 1.15, 1.3}을 사용하여 10,000장의 사진을 만든 후 제작된 의사 흠집(pseudo defects)을 이 중 6,000장에 덧붙였다. 의사 흠집은 실제 흠집이 발생한 차량 사진에서 흠집을 100종류 추출한 후 영상 회전과 배율을 조절하여 제작되었다. 나머지 4,000장은 의사 흠집을 덧붙이지 않고 실험을 진행하였다. 실험에 사용한 데이터 세트의 정보는 표 1과 같다.

표 1. 실험에 사용한 데이터 세트
Table 1. Experimental Datasets

Dataset	Image size	Number of Patch (Train/Val/Test)
Vehicle image with scratch	256×256	4200/600/1200
Vehicle image without scratch	256×256	2800/400/800

그림 5는 256×256 크기로 분할된 영상에 의사 흠집을 덧붙이고 감마 보정이 들어가는 과정으로 각 행의 두 가지 예시를 보여준다. (a)와 같이 영상을 256×256 크기로 분할하고 (b)처럼 의사 흠집을 회전과 배율을 조절한다. 이때 의사 흠집 부분이 정답이 되고 이를 이용해 정답 영상들을 제작하였다. 마지막으로 (a)에 감마보정을 넣고 의사 흠집을 덧붙여 (d)와 같이 데이터 세트를 구성하는데 두 예시의 경우 감마 값으로 0.7이 사용됐다.

제안하는 방법의 성능은 변화 탐지 측정 지표인 정밀도(precision), 재현율(recall), F1, Kappa 등으로 평가하였다^[34]. Shen 알고리즘이 적용되지 않은 $k = 0$ 과 적용된 경우

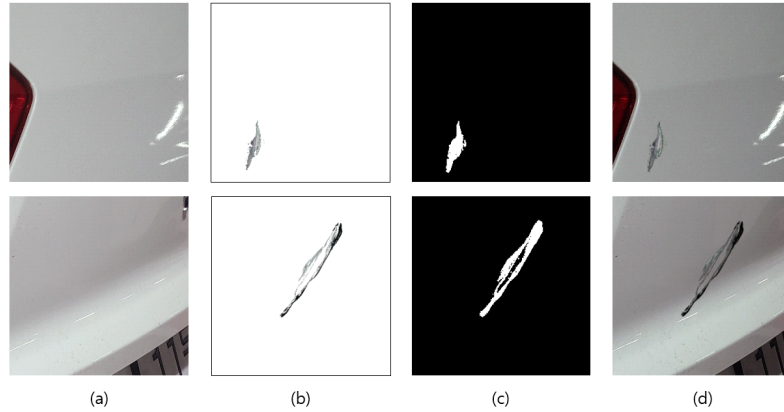


그림 5. 데이터 세트 제작 과정: (a) 입력 영상, (b) 회전, 배율 조절된 의사 흠집, (c) 정답, (d) 의사 흠집 추가된 감마 보정 영상 (감마 값 = 0.7)
 Fig. 5. Dataset creation process: (a) Input image, (b) Rotated and scaled pseudo defect, (c) Ground truth, (d) Embedded pseudo defect image with gamma correction (gamma value = 0.7)

표 2. k 값에 따른 흠집 탐지 결과
 Table 2. Scratch detection results based on k values

	Precision (%)	Recall (%)	F1 (%)	Kappa (%)
$k = 0$	55.38	79.58	65.31	64.09
$k = 0.46$	59.60	79.15	68.00	66.91
$k = 0.64$	61.75	78.59	69.16	68.13
$k = 0.82$	64.13	77.38	70.13	69.16
$k = 1$	67.90	74.56	71.08	70.18

로 나누어서 성능을 평가하였고, Shen 알고리즘을 적용한 경우에는 정반사 제거 수준을 조절하는 매개변수 k 값에 따라 평가하였다. 본 논문에서는 Shen이 사용한 k 값을 고려하여 $k = 0.46, 0.64, 0.82, 1$ 인 네 가지 경우로 실험하였다. 표 2는 k 값에 따른 전처리를 적용한 모델의 성능을 보여준다. k 가 증가하면 정반사 성분을 강하게 제거하게 되며 실제로 흠집이 존재하는 영역이 감소하여 재현율이 감소한 결과를 보여주었지만, 흠집으로 잘못 탐지하던 정반사 성분이 제거되어 정밀도가 증가하였다. 또한, 실제 서비스에서 흠집의 형태를 정확하게 찾는 것보다 흠집의 위치를 찾는 것이 중요함으로 정밀도가 향상된 것은 중요한 의미를 가진다. $k = 1$ 인 경우와 반사 제거를 적용하지 않은 경우를 비교하였을 때 재현율이 5.02% 감소하였지만, 정밀도, F1, Kappa는 각각 12.52%, 5.77%, 6.09% 증가하여 가장 좋은 성능을 보였다. 특히 F1과 Kappa 값은 각각 71.08%, 70.18%로서 성능평가 지침을 제시한 [35]에 근거

하였을 때 상당한(substantial) 일치도를 보였다.

그림 6은 세 가지 영상의 경우에 대하여 k 의 변화에 따른 모델의 주관적 결과를 보여준다. 첫 번째 행과 두 번째 행에서는 $k = 0.64$ 이상일 때, 하이라이트 때문에 발생한 오탐지의 영향이 완전히 줄어든 것을 확인할 수 있다. 세 번째 행에서는 k 가 증가할수록 오탐지의 영향이 줄어들다가, $k = 1$ 일 때 오탐지가 모두 없어졌다. 그러나 두 번째 행과 세 번째 행에서 $k = 1$ 일 경우 실제 흠집의 영역에도 영향을 미쳐 낮은 k 값 대비 탐지된 흠집이 작아진 것을 볼 수 있다. 즉, k 가 증가함에 따라 탐지된 흠집의 일부분이 사라지는 현상이 발생하고, 그에 따라 흠집 탐지기로 흠집 전체를 온전히 탐지하지 못하는 경우가 존재한다. 하지만 카세어링 서비스에서의 흠집 탐지의 목적은 흠집 생성 여부를 확인하는 것이다. 제안하는 흠집 탐지 시스템의 탐지 결과는 흠집의 기본적인 위치를 유지하면서 흠집 생성 여부를 잘 판단하고 있다. 결과적으로 $k = 1$ 인 경우 흠집이 손상되는 현상이 있지만 위치와 생성 여부를 잘 판단하고 있으며 하이라이트로 인해 발생한 오탐지가 가장 적다.

객관적 평가 결과는 $k = 1$ 일 때 F1, Kappa가 각각 71.08%, 70.18%로서 가장 좋은 성능을 나타냈고, 주관적 평가 결과 역시 $k = 1$ 일 때 가장 좋은 성능을 나타냈다. 따라서 본 논문에서는 빛 반사로 인한 오탐지를 최대한 줄이기 위해 $k = 1$ 을 선택한다.




그림 6. 값에 따른 차량 흠집 탐지 결과: (a) 입력 영상 1, (b) 입력 영상 2, (c) 정답, (d) $k = 0$, (e) $k = 0.46$, (f) $k = 0.64$, (g) $k = 0.82$, (h) $k = 1$
 Fig. 6. Vehicle scratch detection results based on values: (a) Input image 1, (b) Input image 2, (c) Ground truth, (d) $k = 0$, (e) $k = 0.46$, (f) $k = 0.64$, (g) $k = 0.82$, (h) $k = 1$

V. 결론

카셰어링 서비스에서 차량을 대여한 후에 발생한 흠집을 탐지하기 위하여 대여 전, 후 촬영된 사진에서 새롭게 생긴 흠집을 찾는 것은 중요하다. 기존의 차량 상태 검수 시스템은 대여 전, 후 사진에서 각각 흠집을 탐지하는 딥 러닝 모델과 탐지된 두 흠집 영상을 수작업으로 대조하여 새롭게 발생한 흠집을 탐색하는 두 단계로 구성되어 완전한 무인화 시스템이 아니다. 본 고에서는 카셰어링 서비스에서 필요한 차량 상태 무인 검수를 위하여 기존의 두 단계 구현된 모델을 한 단계로 구현한 변화탐지 기반 무인 흠집 탐지 시스템을 제안하였다. 제안하는 시스템은 위성 영상에서 변화를 탐지하는 딥 러닝 모델에 전이 학습을 적용하여 구축하였다. 그리고 카셰어링 서비스에서 흠집 탐지 시스템의 입력 영상은 비전문가인 이용자가 일반 카메라로 촬영하며, 촬영 대상인 자동차 표면은 램버시안 반사율을 갖지 않아 정반사로 인해 발생한 잡음이 흠집 탐지 성능에 크게 영향을 미친다. 따라서 정반사 때문에 발생하는 오탐지를 감소시키기 위해 정반사 성분을 제거하는 전처리 과정을 적용했다. 제안하는 시스템은 이용자가 휴대폰 사진기로 촬영한 데이터에 대해 정밀도, 재현율, F1, Kappa 척도면에서 각각 67.90%, 74.56%, 71.08%, 70.18%로서 상당한 일치도를 보였다. 또한, 주관적인 결과 면에서도 오탐지를 줄이고, 새로 발생한 흠집과 그 위치를 정확하게 탐지함으로써

써 완전 무인 흠집 탐지의 가능성을 보였다.

참고 문헌 (References)

- [1] Gyeonggi Research Institute(GRI), Growing Pains of Car Sharing Services, Beyond Conflicts and Regulations to the Future Gyeonggi Research Institute(GRI) No.440, 2020 Nov. 15. <https://www.dbpia.co.kr/journal/articleDetail?nodeId=NODE10541172>
- [2] Korea Consumer Agency, Survey Car sharing Terms of Use and Advertisements, 1-79, 2017 May. <https://www.dbpia.co.kr/journal/articleDetail?nodeId=NODE07456356>
- [3] Developing Car Damage Detection Model using Semantic Segmentation. (accessed 2020. Feb. 13) doi: <https://tech.socarcorp.kr/data/2020/02/13/car-damage-segmentation-model.html>
- [4] Q. Zhang, X. Chang and S. Bian Bian, "Vehicle-Damage-Detection Segmentation Algorithm Based on Improved Mask RCNN," IEEE Access, Vol.8, pp.6997 - 7004, Jan. 06, 2020. doi: <https://doi.org/10.1109/ACCESS.2020.2964055>
- [5] U. Waqas, N. Akram, S. Kim, D. Lee and J. Jeo, "Vehicle Damage Classification and Fraudulent Image Detection Including Moiré Effect Using Deep Learning", 2020 IEEE Canadian Conference on Electrical and Computer Engineering, Aug. 30 - Sep. 2 2020. (accessed Nov. 19, 2020) doi: <https://doi.org/10.1109/CCECE47787.2020.9255806>
- [6] X. Zhu, S. Liu, P. Zhang and Y. Duan, "A Unified Framework of Intelligent Vehicle Damage Assessment based on Computer Vision Technology," 2019 IEEE 2nd International Conference on Automation, Nov. 22-24 2019.

- doi: <https://doi.org/10.1109/AUTEEE48671.2019.9033150>
- [7] H. S. Malik, M. Dwivedi, S. N. Omakar, S. R. Samal, A. Rathi, E. B. Monis, B. Khanna and A. Tiwari, "Deep Learning Based Car Damage Classification and Detection," *Advances in Artificial Intelligence and Data Engineering*, Vol.1133, pp 207-221, Aug 2020.
<https://easychair.org/publications/preprint/RIQ2>
- [8] A. Artusi, F. Banterle, and D. Chetverikov, "A Survey of Specularity Removal Methods," *COMPUTER GRAPHICS forum*, Vol.30, No.8, pp. 2208 - 2230, 2011.
doi: <https://doi.org/10.1111/j.1467-8659.2011.01971.x>
- [9] C. G. P. Suescún, J. O. P. Arenas and R. J. Moreno, "Detection of Scratches on Cars by Means of CNN and R-CNN," *International Journal on Advanced Science, Engineering and Information Technology*, Vol.9, No.3, pp.745-752, 2019.
doi: <http://dx.doi.org/10.18517/ijaseit.9.3.6470>
- [10] R. C. Daudt, R. L. Saux, and A. Boulch, "Fully convolutional siamese networks for change detection," *Proceedings of the 2018 25th IEEE International Conference on Image Processing (ICIP)*, pp. 4063-4067, 2018. (accessed Sep. 6 2018)
doi: [10.1109/ICIP.2018.8451652](https://doi.org/10.1109/ICIP.2018.8451652)
- [11] M. E. A. Larabi, S. Chaib, K. Bakhtj, and M. S. Karoui, "Transfer Learning for Changes Detection in Optical Remote Sensing Imagery," *Proceedings of the IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan*, pp.1582-1585, 2019.
doi: <https://doi.org/10.1109/IGARSS.2019.8900296>
- [12] H. Chen, and S. Zhenwei, "A Spatial-Temporal Attention-Based Method and a New Dataset for Remote Sensing Image Change Detection," *Remote Sensing*, Vol.12, No.10, pp.1-23, May 2020.
doi: <https://doi.org/10.3390/rs12101662>
- [13] G. Hwang, W.J. Lee, and S.J. Oh, "Change Attention based Dense Siamese Network for Remote Sensing Change Detection," *Journal of Broadcast Engineering*, Vol.26, No.1, pp.14-25, Jan 2021.
doi: <https://doi.org/10.5909/JBE.2021.26.1.14>
- [14] R. T. Collins, A. J. Lipton and T. Kanade, "Introduction to the special section on video surveillance," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 22, No. 8, pp. 745-746, Aug 2000.
doi: <https://doi.org/10.1109/TPAMI.2000.868676>
- [15] C. Stauffer and W. E. L. Grimson, "Learning patterns of activity using real-time tracking," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 22, No. 8, pp. 747-757, Aug 2000.
doi: <https://doi.org/10.1109/34.868677>
- [16] M. Bosc, F. Heitz, J. P. Armspach, I. Namer, D. Gounot and L. Rumbach, "Automatic change detection in multimodal serial MRI: Application to multiple sclerosis lesion evolution," *Neuroimage*, Vol. 20, pp. 643-656, 2003.
doi: [https://doi.org/10.1016/s1053-8119\(03\)00406-3](https://doi.org/10.1016/s1053-8119(03)00406-3)
- [17] D. Rey, G. Subsol, H. Delingette and N. Ayache, "Automatic detection and segmentation of evolving processes in 3D medical images: Application to multiple sclerosis," *Med. Image Anal*, Vol.6, No.2, pp.163-179, Jun 2002.
doi: [https://doi.org/10.1016/s1361-8415\(02\)00056-7](https://doi.org/10.1016/s1361-8415(02)00056-7)
- [18] D. R. Edgington, K. A. Salamy, M. Risi, R. E. Sherlock, D. Walther and C. Koch, "Automated event detection in underwater video," *Oceans 2003. Celebrating the Past ... Teaming Toward the Future (IEEE Cat. No.03CH37492)*, Vol.5, pp. 2749-2753, 2003.
doi: <https://doi.org/10.1109/OCEANS.2003.178344>
- [19] K. Lebart, E. Trucco and D. M. Lane, "Real-time automatic sea-floor change detection from video," *Oceans Conference Record*, Vol. 2, No. 7, pp. 1337-1343, 2000.
doi: <https://doi.org/10.1109/OCEANS.2000.881789>
- [20] L. Khelifi and M. Mignotte, "Deep Learning for Change Detection in Remote Sensing Images: Comprehensive Review and Meta-Analysis," *IEEE Access*, Vol. 8, pp. 126385 - 126400. (accessed Jul. 8 2020)
doi: <https://doi.org/10.1109/ACCESS.2020.3008036>
- [21] Y. Liu, C. Pang, Z. Zhan, X. Zhang, and X. Yang, "Building Change Detection for Remote Sensing Images Using a Dual Task Constrained Deep Siamese Convolutional Network Model," *arXiv preprint, arXiv:1909.07726*, 2019.
doi: <https://doi.org/10.48550/arXiv.1909.07726>
- [22] Y. Zhan, K. Fu, M. Yan, X. Sun, H. Wang and X. Qiu, "Change Detection Based on Deep Siamese Convolutional Network for Optical Aerial Images," *IEEE Geoscience and Remote Sensing Letters*, Vol.14, Issue: 10, pp.1845 - 1849, Oct. 2017.
doi: <https://doi.org/10.1109/LGRS.2017.2738149>
- [23] S. A. Shafer, "Using color to separate reflection components", *Color Res. Appl.* 10, 210 - 218, 1985.
doi: <https://doi.org/10.1002/col.5080100409>
- [24] K. Yoon, Y. Choi and I.S. Kweon, "Fast Separation of Reflection Components using a Specularity-Invariant Image Representation," *2006 International Conference on Image Processing, Atlanta, Georgia, USA*, pp. 973-97, Oct 2006.
doi: <https://doi.org/10.1109/ICIP.2006.312650>
- [25] S. K. Nayar, X. S. Fang, and T. Boulton, "Separation of reflection components using color and polarization," *International Journal of Computer Vision*, Vol. 21, pp.163-186, Feb 1997.
doi: <https://doi.org/10.1023/A:1007937815113>
- [26] R. T. Tan, K. Nishino, and K. Ikeuchi, "Separating reflection components based on chromaticity and noise analysis," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 26, pp.1373-1379, Oct 2004.
doi: <https://doi.org/10.1109/TPAMI.2004.90>
- [27] R. T. Tan and K. Ikeuchi, "Separating reflection components of textured surfaces using a single image," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 27, Iss.2, pp. 178 - 193, Feb 2005.
doi: <https://doi.org/10.1109/TPAMI.2005.36>
- [28] H.L. Shen and Q.Y. Cai, "Simple and efficient method for specularity removal in an image," *Virtual Journal for Biomedical Optics*, Vol. 4, Iss.7, May. 6 2009.
doi: <https://doi.org/10.1364/AO.48.002711>
- [29] J. Fu, J. Liu, H. Tian, Y. Li, Y. Bao, Z. Fang, and H. Lu, "Dual attention network for scene segmentation." *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach,

- California, USA, pp.3146-3154, 2019.
doi: <https://doi.org/10.48550/arXiv.1809.02983>
- [30] C. Tan, F. Sun, T. Kong, W. Zhang, C. Yang and C. Liu, "A Survey on Deep Transfer Learning," Artificial Neural Networks and Machine Learning, pp. 270-279. (accessed Oct 2018)
doi: [10.1007/978-3-030-01424-7_27](https://doi.org/10.1007/978-3-030-01424-7_27)
- [31] S. J. Pan and Q. Yang, "A Survey on Transfer Learning," IEEE Transactions on Knowledge and Data Engineering, Vol. 22, Iss.10, pp. 1345 - 1359, Oct. 2010.
doi: <https://doi.org/10.1109/TKDE.2009.191>
- [32] X. Xu, J. Lin, Y. Tao and X. Wang, "An Improved DenseNet Method Based on Transfer Learning for Fundus Medical Images," 2018 7th International Conference on Digital Home (ICDH), pp. 137-140, Nov. 30 - Dec. 1 2018.
doi: <https://doi.org/10.1109/ICDH.2018.00033>
- [33] J. Yosinski, J. Clune, Y. Bengio and H. Lipson, "How transferable are features in deep neural networks?" Advances in Neural Information Processing Systems, Vol.27, pp.3320-3328, Dec. 2014.
doi: <https://doi.org/10.48550/arXiv.1411.1792>
- [34] A. Asokan, and J. Anitha, "Change detection techniques for remote sensing applications: a survey." Earth Science Informatics, Vol.12, No.2, pp.143-160, March 2019.
doi: <https://doi.org/10.1007/s12145-019-00380-5>
- [35] L. Richard, and G. G. Koch. "The Measurement of Observer Agreement for Categorical Data." Wiley, International Biometric Society, Vol. 33, No. 1, pp. 159 - 74, 1977.
doi: <https://doi.org/10.2307/2529310>
- [36] S. Wang, D. Quan, X. Liang, M. Ning, Y. Guo and L. Jiao, "A deep learning framework for remote sensing image registration". ISPRS Journal of Photogrammetry and Remote Sensing, Vol.145, pp.148 - 164, 2018.
doi: <http://dx.doi.org/10.1016/j.isprsjprs.2017.12.012>
- [37] F. Wang and D.M.J. Tax. "Survey on the attention based RNN model and its applications in computer vision." arXiv preprint arXiv: 1601.06823, 2016.
doi: <https://doi.org/10.48550/arXiv.1601.06823>

저 자 소 개

이 은 성



- 2022년 2월 : 광운대학교 전자공학과 학사
- 2022년 3월 ~ 현재 : 광운대학교 컴퓨터공학과 석사과정
- ORCID : <https://orcid.org/0000-0001-6996-0809>
- 주관심분야 : 영상신호처리, 컴퓨터비전, 영상압축

이 동 준



- 2022년 2월 : 광운대학교 전자공학과 학사
- 2022년 3월 ~ 현재 : 광운대학교 컴퓨터공학과 석사과정
- ORCID : <https://orcid.org/0000-0002-7126-3751>
- 주관심분야 : 컴퓨터비전, 영상신호처리

박 건 희



- 2022년 2월 : 광운대학교 전자공학과 학사
- ORCID : <https://orcid.org/0000-0002-0897-9204>
- 주관심분야 : 컴퓨터비전, 시스템온칩, 마이크로프로세서

저 자 소 개



이 우 주

- 2018년 2월 : 광운대학교 전자공학과 학사
- 2020년 8월 : 광운대학교 전자공학과 석사
- 2021년 3월 ~ 현재 : 광운대학교 컴퓨터공학과 박사과정
- ORCID : <https://orcid.org/0000-0002-3388-3765>
- 주관심분야 : 영상신호처리, 컴퓨터비전, 고해상도 위성영상 처리



심 동 규

- 1993년 2월 : 서강대학교 전자공학과 공학사
- 1995년 2월 : 서강대학교 전자공학과 공학석사
- 1999년 2월 : 서강대학교 전자공학과 공학박사
- 1999년 3월 ~ 2000년 8월 : 현대전자 선임연구원
- 2000년 9월 ~ 2002년 3월 : 바로비전 선임연구원
- 2002년 4월 ~ 2005년 2월 : University of Washington Senior research engineer
- 2005년 3월 ~ 현재 : 광운대학교 컴퓨터공학과 교수
- ORCID : <https://orcid.org/0000-0002-2794-9932>
- 주관심분야 : 영상신호처리, 영상압축, 컴퓨터비전



오 승 준

- 1980년 2월 : 서울대학교 전자공학과 학사
- 1982년 2월 : 서울대학교 전자공학과 석사
- 1988년 5월 : 미국 Syracuse University 전기/컴퓨터공학과 박사
- 1982년 3월 ~ 1992년 8월 : 한국전자통신연구원 멀티미디어연구실 실장
- 1986년 7월 ~ 1986년 8월 : NSF Supercomputer Center 초청 학생연구원
- 1987년 5월 ~ 1988년 5월 : Northeast Parallel Architecture Center 학생연구원
- 1992년 3월 ~ 1992년 8월 : 충남대학교 컴퓨터공학부 겸임교수
- 1992년 9월 ~ 현재 : 광운대학교 전자공학과 교수
- 2002년 3월 ~ 2017년 12월 : SC29-Korea 전문위원회 대표위원
- ORCID : <https://orcid.org/0000-0002-5036-3761>
- 주관심분야 : 비디오데이터처리, 영상압축, 컴퓨터비전