

18CTAP
-C1332
91-02

보안 과제(), 일반 과제(O) / 공개(O), 비공개() 발간등록번호()

국토교통기술촉진연구사업 최종보고서

R&D / 18CTAP-C133291-02

도로망 유지관리 정보 생성을 위한 일반 차량 탑재 모바일 기기 기반 도로 균열 검출 및 도로 미래 수명 예측 기술 최종보고서

2019. 6.

주관연구기관 / 연세대학교 산학협력단

국토교통부
국토교통과학기술진흥원

도로망 유지관리 정보 생성을 위한 일반 차량 탑재 모바일 기기 기반 도로 균열 검출 및 도로 미래 수명 예측 기술
최종보고서
2019
국토교통과학기술진흥원
국토교통부

연구개발 최종보고서 · 요약서

I. 인쇄 규격

1. 크기: A4 신판(가로 210mm * 세로 297mm)
2. 제본: 좌철
3. 용지
 - 가. 표지: 백상지(150g/㎡)
 - 나. 내용: 백상지(80g/㎡)
4. 인쇄 방법
 - 가. 표지: 바탕 백색, 활자 흑색
 - 나. 내용: 흑색 지정 활자

II. 편집 순서

1. 표지
2. 제출문
3. 보고서 요약서
4. 요약문
5. 본문 목차
6. 본문
7. 뒷면지

III. 참고 사항

전자 조판 인쇄 시에는 이에 준한다.

18CTAP
-C1332
91-02

도로망 유지관리 정보 생성을 위한 일반 차량 탑재 모바일 기기 기반 도로 균열 검출 및 도로 미래 수명 예측 기술

최종보고
서

2019
국토교통과학기술진흥원

국토교통부

보안 과제(), 일반 과제(O) / 공개(O), 비공개()발간등록번호()

국토교통기술촉진연구사업 최종보고서

R&D / 18CTAP-C133291-02

도로망 유지관리 정보 생성을 위한 일반 차량 탑재 모바일 기기 기반 도로 균열 검출 및 도로 미래 수명 예측 기술 최종보고서

2019. 6.

주관연구기관 / 연세대학교 산학협력단

국토교통부
국토교통과학기술진흥원

제출문

제 출 문

국토교통과학기술진흥원 귀하

'도로망 유지관리 정보 생성을 위한 일반 차량 탑재 모바일 기기 기반 도로 균열 검출 및 도로 미래 수명 예측 기술'(연구개발 기간 : 2017. 6. ~ 2019. 3.) 과제의 최종보고서 1부를 제출합니다.



주관연구기관명 : 연세대학교 산학협력단 (대표자) 이 원 용	(인)
협동연구기관명 :	(대표자) (인)
참여기관명 :	(대표자) (인)

주관연구기관책임자: 김 형 관
협동연구기관책임자:
참여기관책임자:

국토교통부소관 연구개발사업 운영규정 제29조에 따라 최종보고서 열람에 동의합니다.

보고서 요약서

보고서 요약서

과제 고유 번호	18CTAP-C13 3291-02	해당 단계 연구 기간	2018.01.01~ 2019.03.30	단계구분	2/2 (최종)
연구사업명	중사업명	국토교통기술촉진연구사업			
	세부사업명				
연구과제명	대과제명	도로망 유지관리 정보 생성을 위한 일반 차량 탑재 모바일 기기 기반 도로 균열 검출 및 도로 미래 수명 예측 기술			
	세부과제명				
연구책임자	김 형 관	해당단계 참여연구원 수	총: 15 명 내부: 15 명 외부: 명	해당단계 연구비	정부:220,000천원 민간: 천원 정부외: 천원 상대국: 천원 계:220,000천원
		총 연구기간 참여연구원 수	총: 16 명 내부: 16 명 외부: 명	총 연구비	정부:370,000천원 민간: 천원 정부외: 천원 상대국: 천원 계:370,000천원
연구기관명 및 소속 부서명	연세대학교 산학협력단			참여기업명	
국제공동연구	상대국명:			상대국 연구기관명:	
위탁연구	연구기관명:			연구책임자:	

※ 국내·외의 기술개발 현황은 연구개발계획서에 기재한 내용으로 같음

연구개발성과의 보안등급 및 사유	
-------------------------	--

9대 성과 등록·기탁번호

구분	논문	특허	보고서 원문	연구시설 · 장비	기술요약 정보	소프트 웨어	화합물	생명자원		신품종	
								생명 정보	생물 자원	정보	실물
등록·기 탁 번호											

국가과학기술종합정보시스템에 등록된 연구시설·장비 현황

구입기관	연구시설 · 장비명	규격 (모델명)	수량	구입연월일	구입가격 (천원)	구입처 (전화)	비고 (설치장소)	NTIS 등록번호

요약(연구개발성과를 중심으로 개조식으로 작성하되, 500자 이내로 작성합니다)

보고서 면수

요약문

연구개발 목표	본 연구는 도로망의 결함 상태를 신속히 파악하여 최적의 도로 경영전략을 도출할 수 있도록 (1) 고속 운행(시속 ~80km/hr) 중인 차량에 장착된 모바일 기기 영상에서 도로의 균열 분석 정확도 90% 및 미검출율 20% 미만을 달성하고, (2) 도로 구간별 현 상태, 기후 변화 시나리오, 외부 환경 변수들을 고려한 퍼지 추론 기반 도로 열화곡선을 구성하는 기술을 개발하여 도로 미래 수명 예측 정확도를 획기적으로 개선하고, 도로 최적 유지관리 단위를 도출하는 기술을 기반으로 도로 구간별로 효율적 유지관리 예산을 가능하게 하여 우리나라 도로 유지관리 비용 5% 감소를 목표로 함.				
연구개발 내용	핵심성과 1. 소셜 센싱 기반 도로망 포장 균열 분석 기술 - 영상에서 도로의 결함을 찾아내고, 그 결함 정보와 위치 정보를 중앙 서버로 전송하여 지역별 도로 열화 상태 및 패턴을 추출하는 기술 단위성과 1-1 모바일 영상 품질 보정 및 도로면 추출 기술 단위성과 1-2 GNSS (Global Navigation Satellite System) 기반 도로면 위치 정보 영상 연계 및 도로면 영상 투영변환 기술 단위성과 1-3 딥 러닝 기반 도로 포장 균열 검출 기술 핵심성과 2. 미래 도로 수명 예측 시스템 개발을 위한 빅 데이터 기반 열화 모델 및 기후 변화 영향 평가 모델 - 지속적으로 업데이트 되는 도로 상태 정보를 통해 구간별 열화 상태 모델 기술과 미래 기후 변화 영향 평가 기술을 통합해 구간별 도로 미래 수명을 예측하는 기술 단위성과 2-1 도로 기후 변화 영향 평가 기술 단위성과 2-2 미래 도로 수명 예측 기술 및 도로 최적 유지관리 단위 도출 기술 개발				
연구개발성과	최종성과물: TRL 4단계의 포장 도로 균열 분석 및 열화 상태 모델링 소프트웨어				
활용계획 및 기대효과	경제적 기대효과 - 도로 결함 탐지 비용 감소, 도로 결함의 신속한 수선을 통한 사용자 피해 및 추가 파손 방지. 선진국 인프라 유지관리 시장 진출 기술적 기대효과 - 제한된 프로세싱 환경과 영상 데이터의 처리, 퍼지 추론 시스템 등 다양한 분야 이론 융합으로 높은 학술적 성과 및 원천 기술 확보 사회적 파급효과 - 예방적 유지보수로 포장도로 유지관리의 비용을 절감하고 차량운행 안전성이 높은 사회기반시설을 확보 인재양성 기대효과 - 건설, 시설물관리, 정보통신기술, 컴퓨터비전, 인공지능 방법론을 아우를 수 있는 융합분야 연구자 및 기술자를 양성 학술적 기대효과 - 다양한 학문 분야의 최첨단 기술들을 기반으로, 제한된 프로세싱 환경과 빅 데이터의 처리, 불확실성 기반 열화 상태 모델링 등 새로운 이론 및 기술 개발				
국문핵심어 (5개 이내)	도로망	유지관리	열화 모델	퍼지 추론	컴퓨터 비전
영문핵심어 (5개 이내)	R o a d n e t w o r k	M a i n t e n a n c e	D e t e r i o r a t i o n m o d e l	F u z z y I n f e r e n c e	C o m p u t e r v i s i o n

※ 국문으로 작성(영문 핵심어 제외)

< 목 차 >


1. 연구개발과제의 개요	8
2. 연구수행내용 및 성과	14
3. 목표 달성도 및 관련 분야 기여도	67
4. 연구개발성과의 활용 계획 등	70
붙임. 참고 문헌	75

<별첨> 주관연구기관의 자체평가 의견서

1. 연구개발과제의 개요

가. 연구개발의 필요성

(1) 연구개발의 개요



[그림 1-1] 연구의 최종 목표 및 최종 성과물.

(가) 최종연구목표

본 연구는 도로망의 유지관리 비용 절감 및 운행 안전성 제고를 위해, 운행 중인 차량에 장착된 모바일 기기(블랙박스 또는 휴대폰)로 취득한 영상 기반 포장도로의 균열 분석 및 도로 구간별 열화 상태 모델링 기술을 연구 개발한다.

(나) 최종 성과물


소셜센싱 기반 도로망 균열 분석 기술 - 도로의 차량들에 장착된 차량용 블랙박스나 휴대폰으로 촬영한 영상에서 도로의 결함을 찾아내고, 그 결함 정보와 위치 정보를 중앙 서버로 전송하여 지역별 도로 열화 상태 및 패턴을 추출함을 의미한다. 차량 속도 80km/hr 이하에서 모바일 기기(블랙박스 또는 휴대폰)로 취득한 영상에서 도로의 균열을 90%이상 정확도로 검출하는 것을 목표로 한다.

미래 도로 수명 예측 시스템 개발을 위한 빅 데이터 기반 열화 모델 및 기후변화 영향 평가 모델 - 도로 미래 수명 예측 시스템은 지속적으로 업데이트 되는 도로 상태 정보를 통해 구간별 열화 모델 기술과 미래 기후변화 영향 평가 기술을 통합해 구간별 도로 미래 수명 예측 정확도를 획기적으로 개선하고 최적 도로 유지관리 단위를 도출하여 구간별 차별화된 유지관리 비용 투입을 통해 도로 유지관리 비용을 5% 이상 절감하는 것을 목표로 한다.

나. 연구개발 대상의 국내외 현황

(1) 국내 도로 유지관리 현황

2017년 기준 한민국의 도로 총연장 110,691km의 연간 보수비용은 약 3조 3천억 원이며, 이 중 포장도보수가 9,297억 원으로 가장 크다. 도로 인프라가 갖춰진 이후 상당한 금액이 매년 도로 유지관리 비용으로 사용되고 있다.



[그림 1-2] 2017년 국내 도로등급별 보수비 및 보수 공종별 보수비.
(http://www.rsis.kr/maintenance_summary.htm)

1970~2000년의 기간 동안 40,244km이던 도로 연장이 88,774km로 2배 이상 급격히 증가하여 향후 노후화된 도로의 비중 또한 급격히 증가하였다. 한국건설산업연구원에서 도로 노후화 상황을 감안하여 추산한 결과 2020년 도로 유지보수 예산 3.2조 원, 2025년 4.5조 원이 필요할 것으로 예상하고 있다. 노후화된 도로의 포장 수명 공용성이 관리기준 이하로 떨어진 후 적시에 예방적 유지관리를 이행하지 못할 경우 공용성이 급격히 나빠지며 이는 사후 유지관리 비용을 크게 증가시키는 원인이 될 수 있다. 해외의 사례로 선진국인 미국의 경우 1995년 이후 현재까지 도로 운영 및 유지관리 항목 예산이 전체 도로 예산에서 45~50%로 매우 큰 비중을 차지하고 있으며, 서유럽 국가의 경우 교통 분야 유지보수를 위한 투자액이 GDP의 1%를 차지한다(우리나라의 경우 교통 분야 유지보수 예산 GDP의 0.26%로 도로 투자비 대비 유지보수비 비중은 20~30%로 비교적 낮은 수준).

(2) 도로 포장 상태 관리 현황 및 균열 분석의 한계

도로망을 관리하기 위해서는 도로의 세 가지 상태 인자인 균열, 소성변형, 종단평탄성을 조사하고 분석해야 한다. 현재 국내에서는 PES(Pavement Evaluation Surveyor) 1, 2와 같은 특수 차량을 운행하여 도로 포장 상태를 조사하고 있다. 그러나 특수 차량 및 관리 인력의 부족으로 극히 일부 도로 구간에 대해서만 전문적인 모니터링이 수행되고 있다. 2017년 국토교통부에서

도로포장관리시스템 조사대상구간으로 일반국도 3,141km를 조사하였다. 조사장비의 기술적 한계가 존재하는데, 도로 포장 상태의 주요 인자인 균열에 대한 분석은 분석 프로그램의 정확성이 높지 않아 자동 분석이 현실적으로 수행되지 못하고 있으며, 인력을 활용한 균열 분석으로 낮은 효율성을 보이고 있다.

(3) 국내 학계의 도로 균열 분석 연구 현황

[표 1-1] 국내 학계 도로 균열 분석 연구 현황.

번호	연도	논문 제목	학술지명	연구 요약
1	2002	Image Gradient 방법을 사용한 도로노면의 균열검출시스템 개발	수원대학교 논문집	- 영상 전처리하여 균열을 강조하고, 가우시안/소벨 필터를 사용한 이미지 블리링, 허프변환을 사용하여 도로 균열 검출 - 차량 전방 CCD 카메라 3대를 장착하여 도로 영상 취득
2	2004	비디오 영상을 이용한 도로노면 균열관리시스템 개발	대한토목학회	- 일반 차량 지붕에 삼각대를 설치하여 전후 도로 포장 비디오를 취득함 - 영상 내 균열 측정 방법 설명 없음
3	2007	수치영상을 이용한 도로 노면관리시스템 개발	한국지리정보 학회지	영상 내 균열 추출 방법 제시 없음

국내에서 도로 포장 균열을 검출하려는 연구 노력이 부족하여 도로 포장 균열 분석의 중요성에도 불구하고 해외에 비해 기술력이 매우 부족한 실정이다. 표1-1에서, 논문 1에서만 영상 내 균열을 추출하는 방법을 제시하였다. 논문 1의 영상 전처리 과정에서 균열을 두드러지게 강조하기 위해 밝기값을 보정한 후 가우시안/소벨 필터를 사용하여 노이즈(Noise)를 제거하였다. 영상에서 균열을 감지하기 위해 허프 변환(Hough Transform)을 활용하였다. 그러나 논문에서 균열 검출 모델의 정확도 및 균열 검출율에 대한 정량적 분석이 부재하고 테스트 데이터의 수 또한 10장으로 부족하여 제시한 모델의 신뢰성이 검증되지 못했다. 세 논문 모두 균열 종류에 대한 구분 방법 제시가 없어 도로의 열화 상태 모델링을 위한 정보를 제공하지 못했다.

(4) 국외 학계의 도로 균열 분석 연구 현황

영상을 활용하여 자동화된 도로 균열 분석을 위한 연구 및 기술 개발을 현재 활발히 수행 중이나, 실용화 수준으로 근접하지 못하고 있다. 그 이유로는 (1)영상을 통해 균열을 인식하고 이를 정량화 하는 데 어려움이 있고, (2)도로 상태는 균열의 종류에 따라 달라지는 데 균열의 종류를 분류하는 기술의 일반화(Generalization) 성능이 낮다. 도로망의 특정 구간에 대한 균열 분석을 통해 데이터에 근거한 미래 도로상 모델링 연구도 드물어 이론 정립 및 기술 개발이 요원한 실정이다.

[표 1-2] 국외 학계 도로 균열 분석 연구 현황.

번호	국외 학계의 영상 분석 기법을 활용한 도로 균열 분석의 최신 연구 문헌
1	Oliveira, H., and Correia, P. L. (2013). "Automatic road crack detection and characterization." IEEE Transactions on Intelligent Transportation Systems, 14(1), 155-168.
2	Shen, G (2016). "Road crack detection based on video image processing." IEEE Proc., Systems and Informatics (ICSAI), 912-917.
3	Shi, Y., Cui, L., Qi, Z., Meng, F., and Chen, Z. (2016). "Automatic road crack detection using random structured forests." IEEE Transactions on Intelligent Transportation Systems, 17(12), 3434-3445.
4	Wu, L., Mokhtari, S., Nazef, A., Nam, B., and Yun, H.-B. (2016). "Improvement of Crack-Detection Accuracy Using a Novel Crack Defragmentation Technique in Image-Based Road Assessment." Journal of Computing in Civil Engineering, 30(1), 04014118.
5	Zalama, E., Gmez-García-Bermejo, J., Medina, R., and Llamas, J. (2014). "Road Crack Detection Using Visual Features Extracted by Gabor Filters." Computer-Aided Civil and Infrastructure Engineering, 29(5), 342-358.
6	Zhang, L., Yang, F., Zhang, Y. D., and Zhu, Y. J (2016). "Road crack detection using deep convolutional neural network." IEEE Proc., Image Processing (ICIP), 3708-3712.

대부분의 논문에서 균열을 탐지하기 위해 영상을 취득하는 장비로 특수차량(예: PES 1,2)에 탑재된 카메라를 사용하거나 인력이 직접 카메라로 균열 영상 데이터를 수집한다. 영상은 바닥면을 수직으로 찍은 정사(Orthogonal) 영상이 많이 활용되고 있다. 비디오를 활용하려는 시도도 수행되고 있으나 아직 초기 연구 단계이다([표1-2]의 논문 2). 도로 영상에서 균열을 분석하려는 방법들로 Canny, CrackTree, CrackIT, FFA, CrackForest 등 다양한 방법들에 제시되고 있으며 성능들이 취득한 영상 데이터셋의 특성에 따라 달라져 일반화 성능이 높은 알고리즘의 개발이 필요하다. 영상 데이터에서 적절한 특징점을 분류기의 입력값(Input)으로 주기 위해 게이보 필터(Gabor Filter)과 같은 공간 필터링을 전처리 과정으로 수행하였다. 균열의 종류(예: 피로, 거북등, 블록, 종방향, 횡방향, 반사 균열 등)를 구분하기 위해 기계 학습 기반 분류기(Classifier)를 사용하였으며, 균열의 종류를 구분한 후에 결함의 영향 강도를 판단하여 열화곡선을 도출하려는 연구는 없다. 표 1-2의 논문 6에서 최근 높은 성능을 보여주는 심층학습 알고리즘인 CNN(Convolutional Neural Network)를 사용한 시도가 있었으나, 알고리즘의 일반화 성능을 광범위한 실제 데이터에 대해 실험하지 못하여 신뢰성이 확보되지 못하였다. 블랙박스 또는 휴대폰의 차량 장착 위치인 전면부에서 도로 상태를 검출하는 연구는 없다. 촬영 관점(Perspective View)가 달라질 시에 균열 탐지 알고리즘이 목표 성능을 확보하는지에 대한 새로운 연구가 필요하다.

(5) 현재 도로 포장 균열 분석 기술의 문제점

도로 포장의 균열은 도로 포장 형식에 따라 그 종류가 달라진다. 균열의 종류를 구분하는 문제는 도로의 미래 열화 상태를 예측하는데 핵심적인 자료로 사용되므로 필수적이다. 아스팔트 포장의 균열 종류로는 피로 균열, 거북등 균열, 블록 균열, 종방향 균열, 횡방향 균열, 반사 균열이 있음. 시멘트 콘크리트 포장의 경우 우각부 균열, 내구성균열, 가로 및 세로 균열, 망상 균열이 있다. 그 외 포트홀, 단차, 스폐링 등의 포장 손상 형태가 존재한다. 다양한 균열 종류와 포장 손상 형태를 영상에서 자동으로 구분해 내는 연구가 부족하고 단순 포장 균열 또는 일부 손상 유형만 검출하는 방법론이 대부분이라 한계를 지닌다. 특수 차량으로 정사(Orthogonal) 영상을 획득하는 것이 아니라 일반 차량 내부에 거치된 모바일 기기에서 취득한 전방 영상에서 도로 포장면을 추출하기 위해서는 추가적인 처리 알고리즘 개발이 필요하다. 구체적으로는 도로 표식, 도로 시설물, 일반 차량 등의 제거가 필요하다. 또한 외부 조명 변화에 대한 처리, 기상 환경에 따른 영상 품질 저하의 보정, 영상 내 도로면의 기하 보정 등이 있다.

(6) 현재 도로 열화 상태 모델링 기술의 문제점


현재 도로 열화 상태를 도출하는 기술은 기후변화 영향을 도로자체와 도로 주변환경에 대한 물리적 수치를 활용하여 측정할 수 있다. 하지만 이러한 물리적 수치를 얻기 위해서는 지점별로 많은 측정 비용 및 시간이 소요된다. 그리고 지점별로 기후변화 영향을 도출하더라도 도로 유지관리를 위한 거시적 기후변화 영향을 도출하는 데는 한계가 있다. 도로는 구간별로 교통량과 기후 영향 등이 달라 노후화 속도가 다르다. 도로의 열화 속도 차이를 기반으로 최적 도로 유지관리 단위를 도출한다면 유지관리 구간별로 다른 기술을 적용하거나 예산을 투입하는 양을 조절하여 도로 유지관리 전략의 수립과정을 변화시킬 수 있을 것이다.

다. 연구개발의 중요성 및 창의성 · 혁신성

(1) 포장 도로 예방적 관리의 중요성

포장 도로의 최상부인 마모층은 차량 운행 환경, 외부 기상 조건, 설계 및 포장 형식에 따라 정도는 달라지나 지속적으로 손상된다. 포장 도로 손상 정도에 따라 차량 운행의 사용성 및 안전성이 떨어진다. 초기 포장 손상시 유지보수가 적절히 이루어지지 않으면 설계수명이 크게 떨어져 포장도로로써 수명을 상실하게 되고, 도로 개량 시기를 앞당겨 도로 보수 비용을 크게 상승시킨다. 그림 1-3은 포장도로의 생애주기에 따른 도로 상태를 나타낸다. 포장 도로 생애주기에서 Rehabilitation 및 Reconstruction 수준의 도로 복구 또는 재포장이 요구되는 상태까지 방치할 경우 도로 관리 비용이 급격히 상승하게 된다. 미국 Department of Transportation의 Federal Highway Administration(FHWA)에서 도로 포장의 예방적 유지 보수 투자가 투자액 대비 4~10 배의 비용 절감 효과와 사용성 제고 효과가 있음을 보고하였다. 다수의 연구 결과에 기반한 2017년 FHWA 보고서 내용은 포장도로 관리의 예산 절감, 사용성, 안전성 증대를 위해서는 예방적 관리가 매우 중요함을 나타낸다. 도로망의 예방적 관리를 위해서는 포장 도로의 손상 정도에 대한 정보를 신속히 획득해야 한다. 본 연구과제에서는 국가 도로망 전체를 저비용, 고효율로 모니터링 할 수 있는 핵심 기술 개발을 목표로 하고 있어 미래 대비를 위한 중요성이 매우 크

다.



[그림 1-3] 일반적인 포장도로 상태 곡선 생애주기 (US FHWA 2017
https://www.fhwa.dot.gov/pavement/pub_details.cfm?id=1035).

(2) 연구개발의 창의성 · 혁신성

소셜 센싱을 활용한 국가 도로망 모니터링 기술은 기존의 시설물 모니터링 방식과 상이한 새로운 방법으로써, 사람들이 널리 사용하는 모바일 기기의 센싱 능력을 활용하여 가용 정보의 양을 극대화 하는 창의적 발상이다. 일반 차량에 장착된 모바일 기기로 취득한 영상에서 도로 포장 손상 정보를 추출하기 위해 본 과제에서 연구, 개발하는 기술들은 도로공학, 건설 경영, 컴퓨터 비전, 머신 러닝 등의 다학제 융합적 연구를 통한 기술 혁신이 수반된다. 도로 포장의 손상 정보와 기후변화가 도로에 미치는 종합적 영향을 미래 열화 속도의 변화로 예측하기 위해 전문가 지식을 활용하는 창의적 방법이다. 지속적으로 업데이트 되는 실시간 정보를 바탕으로 변화하는 미래 도로 상태와 수명을 최적 유지관리 구간별로 다르게 예측하여 도로 유지관리 전략의 수립과정을 변화시킬 수 있는 도전적 연구이다.

본 과제에서 확보한 핵심 기술을 활용하면 포장 도로의 정보를 수집하는 비용이 절감되고, 실시간 도로 손상 정보 및 기후 영향 평가를 통해 미래 도로 열화 상태를 예측할 수 있어 포장 도로의 예방적 유지 보수를 가능하게 할 것이다. 본 과제 제안 기술이 국가 도로망 단위의 모니터링 패러다임을 전환시킬 수 있는 혁신성을 갖추고 있다.

2. 연구수행내용 및 성과

가. 단위성과 1-1: 도로 포장면 추출 기술

(1) 연구의 목적

도로 포장면 관리를 위해 포장면의 상태를 정확히 파악하는 일은 중요하다. 포장면 상태 파악이 적시에 이루어지지 않을 때 포장면의 결함은 도로의 파손으로 이어지고 차량 통행 문제, 안전사고, 유지관리 비용의 증가를 유발할 수 있다. 이 문제를 해결하기 위해서 본 연구진은 블랙박스 이미지를 활용한 도로 데이터의 빠른 획득 및 업데이트가 필요하다고 판단하였다. 블랙박스 이미지는 하늘, 차량 및 다른 물체들을 포함하고 있다. 따라서 블랙박스 이미지로부터 도로 포장면 결함 검출을 수행하기 위한 대상을 제한하는 과정이 필요하다. 본 연구는 블랙박스 이미지 내 도로 결함을 검출하기 위한 선제적 연구 단계로서, 심층학습 기반의 도로 포장면 추출 방법을 제시한다. 본 연구의 최종 결과는 도로 이용자의 편의와 안전을 높일 뿐만 아니라 관리 주체의 효율적인 유지관리 및 운영을 가능하게 할 것이다.

(2) 관련 연구

교통 관리, 도시 계획, 지도 업데이트, 그리고 도로 모니터링 등을 효율적으로 수행하기 위해 이미지 기반의 도로 포장면을 추출하는 연구들이 수행되어왔다. 이미지 분석을 통한 도로 포장면 추출 연구 중 도로 포장면과 도로 차선의 시각적인 차이를 이용한 연구들이 있다. Southall and Taylor (2001)은 차선을 검출하기 위해 허프 변환 알고리즘을 사용하여 차선의 방향을 찾고 확률적 도로 모양 예측을 수행했다. Sun et al. (2006)은 도로 포장면과 대비되는 차선의 색깔 및 강도(Intensity)를 이용하기 위해 이미지에서 HSI(Hue Saturation Intensity) 채널을 추출하여 차선을 검출하였다. 하지만, 차선의 시각적 특징에 기반하여 도로 포장면을 추출하는 방법들은 차선이 퇴색된 경우에 어려움을 겪을 수 있다. Kong et al. (2009)는 측정된 도로의 소실점을 이용해 도로 경계를 대표하는 두 가지 주요 선을 찾아 도로 포장면을 추출하였다. 이 방법은 도로의 경계를 파악하기 어려운 이미지, 그리고 도로 위 많은 차량이 있을 경우에 소실점을 찾기 어렵다는 문제가 있다.

심층학습 중 하나인 CNN은 2012년 이미지 분류 대회인 ILSVRC(ImageNet Large Scale Visual Recognition Competition)에서 우수한 성능을 선보인 이후로 영상 분류 및 객체검출에서 폭넓게 활용되고 있다. CNN 모델은 Convolutional layer(이하 Conv층), Pooling layer(이하 Pool층) 그리고 Fully-connected layer(이하 FC층) 등 크게 3가지 층(Layer)으로 구성된다. Conv층은 층의 입력값과 Conv층을 구성하는 필터(Filter)와의 합성곱(Convolution) 연산을 수행한다. Pool층은 이전 층의 결과값을 작은 크기로 축소(Downsampling)하는 역할을 한다. FC층은 이전 층의 모든 노드(Node)와 연결되어 있으며 주로 CNN의 뒷부분에 위치하여 각 클래스(Class)에 속하는 확률을 계산하는 역할을 한다. CNN 모델은 FC층의 최종 출력값 중 가장 높은 확률을 갖는 클래스를 입력 이미지에 대한 클래스로 예측한다. CNN 모델을 구성하는 각층의 가중치(Weight)는 역전파(Backpropagation)

과정을 통해 학습된다.

이미지 분석에 뛰어난 성능을 보이는 CNN 모델은 다양한 종류의 데이터에서 도로 추출을 수행하기 위해 활용되었다. FCN(Fully Convolutional Network)(Long et al. 2015)는 CNN 모델의 구조를 변형해 이미지를 분할하는 모델 중 하나이다. Kampffmeyer et al. (2017)는 도로를 포함한 리모트 센싱(Remote Sensing) 이미지에서 FCN 모델과 구역 단위로 이미지를 분석하는 CNN 모델을 결합하여 단일 모델을 활용했을 때보다 좋은 이미지 분할 성능을 도출하였다. Wei et al. (2017)은 FCN 모델의 가중치를 항공사진 내 도로 추출에 맞게 학습시킨 RSRCNN(Road Structure Refined Convolutional Neural Network)을 제안하였다. Teichmann et al. (2018)은 자율 주행 차량을 위한 장면 분석을 수행하기 위해 KITTI 데이터셋(Geiger et al. 2013)을 활용했다. 이 연구는 이미지 내에서 물체 검출 및 분할을 동시에 수행하기 위해 FCN 모델의 구조를 변형한 MultiNet을 개발하였다.


(3) 연구 방법

본 연구는 임의의 블랙박스 이미지로부터 픽셀 단위로 도로면을 추출하기 위해 CNN 모델을 활용하였다. 본 연구진은 CNN 모델 중 픽셀 단위로 이미지를 분할하는 FCN 모델을 이용하였다. Teichmann et al. (2018)은 FCN 모델에 기반해 개발된 MultiNet을 이용해, KITTI 데이터셋(Geiger et al. 2013)의 데이터로 도로 포장면을 추출할 때 평균 92% 이상의 정밀도를 달성하였다. KITTI 데이터셋은 차량 위에 설치된 카메라로 획득된 이미지셋이라는 점에서 블랙박스 카메라를 통해 확보된 데이터셋과 유사한 시각적 특징을 가진다. KITTI 데이터셋으로 수행된 성공적인 연구 결과를 기반으로, 본 연구는 도로 포장면 추출을 위해 FCN 모델을 사용하였다.

본 연구에서 사용된 FCN 모델은 VGG-16(Simonyan and Zisserman 2014) 기반의 인코더-디코더(Encoder-Decoder) 네트워크이다. VGG-16은 13개의 Conv층과 3개의 FC층, 5개의 Pool층으로 구성된 깊은 신경망의 구조를 갖는다(그림 2-1 참고). Long et al. (2015)의 실험에서, VGG-16의 가중치를 FCN 모델의 초기 가중치로 사용하고 새로운 데이터셋을 이용해 해당 이미지 분할에 최적화된 가중치를 학습한다. 본 연구에서는 ImageNet 데이터셋(Deng et al. 2009)에서 학습된 가중치가 도로 추출을 위한 초기 가중치로 사용되었다. FCN 모델은 이미지의 전반적인 특징(Global Feature)과 국부적인 특징(Local Feature)을 모두 사용하는 CNN 모델로, FC층을 포함하지 않는다. FCN 모델을 통한 이미지 분할 과정은 크게 세 가지로 구성되어 있다. 첫 번째로, Downsampling 과정을 통해 추출된 특징맵(Feature-Map)안에서도 핵심적인 특징들이 보존된다. 두 번째로, 이렇게 추출된 핵심특징과 초기 단계에서 추출된 특징들이 결합되어 정교화 된다. 마지막으로, 같은 클래스로 분류된 픽셀 결과들이 모여져 하나의 분할 이미지가 만들어진다. FCN 모델의 구조는 그림 2-2와 같다.



[그림 2-1] VGG-16 구조.



[그림 2-2] FCN 모델의 구조 (Long et al. 2015).

(4) 실험 및 결과

(가) 데이터 준비

본 연구에서는 심층학습 기술을 활용한 도로 포장면 추출 기술 개발을 위하여 4대의 차량에 설치된 블랙박스(모델명: 루카스 LK-919 QAD 2채널)로부터 약 1.2TB에 달하는 동영상 데이터를 확보하였다. 수집된 동영상의 해상도는 $2,560 \times 1,440$ 이다. 이 중 전방 블랙박스 동영상을 대상으로 도로를 주행하는 장면을 찾아 도로 및 차량, 나무, 건물 등을 포함하는 352장의 프레임을 임의로 추출하였다. 수집된 블랙박스 이미지는 심층학습 모델 중 하나인 CNN 모델을 학습시키는데 활용되었다.

도로 포장면을 추출하는 기술을 개발하기 위해 기계학습(Machine Learning)의 한 방법론인 지도학습(Supervised Learning)을 활용하였다. 지도학습은 데이터에 대한 명시적인 정답(Label)이 주어진 상태에서 컴퓨터를 학습시키는 방법이다. 본 연구에서 명시적인 정답은 이미지 내에서 도로를 나타내는 픽셀을 지정하는 것이다. 이를 위하여 상용 프로그램인 Labelme를 활용하여 사용자가 직접 다각형을 지정하고 배경과 도로로 주석을 달아주었다. 블랙박스 이미지에 항상 포함되는 차량의 보닛(Bonnet) 부분은 심층학습 모델이 인식할 필요가

없도록 다각형에 포함시키지 않았다.

이미지 레이블링 작업을 마치면 사람이 직접 설정한 주석의 정보(다각형을 구성하는 꼭지점의 좌표 및 다각형에 해당하는 클래스(Class))를 xml 파일 형태로 저장하였다. 그림 2-3의 왼쪽 그림에서, 자주색으로 표시된 다각형은 도로 부분을 나타내며 연두색으로 표시된 다각형은 도로가 아닌 배경 부분을 나타낸다. 본 연구에서는 매트랩(MATLAB)을 활용하여 xml 파일에 기록된 정보를 기반으로 주석명이 배경인 구역의 픽셀은 (255,0,0), 주석명이 도로인 구역의 픽셀은 (0,255,255), 그리고 주석이 없는 구역은 (255,255,255)의 RGB값으로 설정하였다. 각 블랙박스 이미지에 대해 그림 2-3의 오른쪽 그림과 같은 레이블 이미지가 생성되었다. 총 352장의 레이블 이미지가 생성되었으며, 이들은 CNN 모델 학습에 활용되었다.




[그림 2-3] 블랙박스 이미지 레이블링 예시.

(나) 모델 학습 및 결과

본 연구에서는 ILSVRC에 활용된 사전학습 가중치(Pretrained Weights)를 불러와 학습 과정에 활용하였다. 학습과정에서 FCN 모델의 가중치들은 본 연구에서 사용된 학습 데이터셋에 맞도록 미세 조정(Fine-Tuning)되었다. 임의의 블랙박스 이미지를 모델에 입력하였을 때, 픽셀 단위로 각 클래스(도로 / 도로가 아닌 부분)에 속할 확률이 각각 출력된다. 본 연구에서는 각 픽셀별로 모델의 예측값을 계산하여 도로에 속할 확률이 0.5가 넘는 경우 그 픽셀을 도로로 판단하였다.

기술의 성능을 평가하기 위해 테스트 이미지의 정밀도(Precision)와 재현율(Recall)을 계산하였다. 정밀도란 도로 포장면으로 예측한 이미지 내 픽셀 중 실제로 도로 픽셀이 차지하는 비율이고 재현율이란 실제로 도로 포장면이 있는 이미지 내 픽셀 중 모델이 예측한 도로 픽셀의 비율이다. 120장의 테스트 이미지로 실험한 결과 정확도와 정밀도, 재현율의 평균값은 각각 98.33%, 97.74%, 그리고 95.21%로 나타났다. 이에 따라 본 연구에서 목표로 했던 90%의 정확도(Accuracy)를 달성하였다. 그림 2-4는 도로 포장면 추출 예시를 보여준다. 다섯 개의 예시로부터 도로 포장면 추출이 잘 수행된 것을 확인할 수 있다. 첫 번째, 두 번째, 그리고 다섯 번째 행에서 본 연구의 도로 포장면 추출 기술이 도로와 차량의 경계를 잘 구분하는 것을 확인할 수 있다. 세 번째 행은 도로 포장면 추출이 직선 도로 뿐만 아니라 교차로 지점에서도 잘 수행됨을 보여준다.




(a)

(b)

[그림 2-4] 도로 포장면 추출 결과의 예시: (a)블랙박스 원본 이미지; (b)도로 포장면 추출 결과.

도로 포장면 추출의 결과는 차후 연구로 수행될 도로 균열 검출 단계에서 중요한 역할을 한다. 도로 영역이 도로가 아닌 영역으로 분류될 경우, 균열 검출 대상에서 제외되기 때문에 실제로 균열이 존재했더라도, 차후 수행되는 균열 검출 단계에서 이를 검출할 수 없다. 또한 도로가 아닌 영역이 도로 영역으로 분류될 경우, 균열 검출의 빈도가 상승할 수 있다. 그림 2-5는 잘못 분류된 도로 포장면 추출 결과를 보여준다. 그림에서 빗금으로 표시된 영역은 도로 영역이지만 도로가 아닌 배경 구역으로 분류된 영역이다. 대부분의 테스트 이미지에서 도로 포장면 추출이 잘 수행되었기 때문에 균열 검출을 위한 방법론에 본 연구 결과를 사용하기에 문제 없다고 판단하였다.



[그림 2-5] 도로 포장면 추출 오류 예시: (a)블랙박스 원본 이미지; (b)도로 포장면 추출결과. 빗금친 영역은 잘못 분류된 영역을 나타냄.

(5) 결론

본 연구에서 사용된 블랙박스 이미지는 도로면 이외의 다른 물체들을 포함하고 있다. 균열은 크기와 모양이 일정하지 않기 때문에 그 시각적 특징이 명확하지 않고, 노이즈가 많거나 복잡한 배경을 가진 블랙박스 이미지에서 검출되기 쉽지 않다. 따라서, 균열 검출을 수행하는 연구의 선행 연구로서 도로 포장면을 추출하는 과정이 수행되었다. 도로 포장면 추출의 성능은 균열 검출에 중요한 역할을 할 것이다. 도로 포장면 추출의 성능은 98.33%의 정확도, 97.74%의 정밀도, 그리고 95.21%의 재현율을 보였다. 따라서, 본 연구의 결과를 균열 검출 연구에 적용하기에 문제가 없다고 판단하였다. 본 연구는 차량, 나무, 구름 등 블랙박스 이미지 내 도로 외 다른 사물을 효과적으로 제거함으로써, 차후 균열 검출 기술의 성능을 향상시킬 수 있을 것이다.

나. 단위성과 1-2: GNSS(Global Navigation Satellite System) 기반 도로면 위치 정보 영상 연계 및 도로면 영상 투영변환 기술

(1) 연구의 목적

프레임별 도로면 위치 정보는 차량의 OBD(On-Board Diagnostics) 데이터로부터 직접 취득될 수 있으며 영상 투영변환 기술은 이미 완성도 높은 기술이다. 블랙박스 동영상 프레임마다 균열 검출이 수행되고, 영상 투영변환(Perspective Transform) 기술이 적용되고, 그리고 위치 정보가 함께 저장될 수 있다. 즉 위치 정보가 포함된 균열 검출결과를 프레임별로 수집할 수 있다.

하지만 프레임별 균열 검출결과를 수집하면 구간별 도로 상태평가를 위한 핵심성과2에 기여하기 어렵게 된다. 또한, 프레임별 이산적 균열 검출결과를 수집하면 두 가지 문제가 발생한다. 첫째, 단일 프레임에 모두 보이지 않을 정도로 긴 균열이 존재할 수 있다. 둘째, 하나의 균열이 여러 프레임에 중복으로 검출될 수 있다. 도로의 연속적이고 종합적인 상태평가를 위해서 이산적으로 검출된 균열 정보가 하나의 정보로 통합되어야 한다. 다시 말해서, 전방을 촬영한 블랙박스 비디오가 평면도의 모자이크(Mosaic) 단일 이미지로 변환되어야 한다.

도로면 모자이크가 생성되는 전형적인 방법은 기존 프레임의 이미지가 새로운 프레임 이미지로 덮어쓰기(Overwriting) 당하는 방식이다. 도로면 모자이크가 생성되는 또 하나의 방법은 기존 프레임의 이미지와 새로운 프레임의 이미지가 서로 혼합(Blending)되는 방법이다. 본 연구에서는 각 방법을 덮어쓰기 방법(Overwriting Based Method) 및 혼합하기 방법(Blending Based Method)이라고 명명한다.

하지만 덮어쓰기 방법과 혼합하기 방법에서 프레임마다 균열 검출 품질이 고려되지 않는다는 한계가 있다. 덮어쓰기 방법으로 모자이크가 만들어지면, 균열 검출 품질이 높은 프레임에서의 균열 정보가 균열 검출 품질이 낮은 프레임에서의 균열 정보로 덮어쓰기 당할 수 있다. 혼합하기 방법으로 모자이크가 만들어지면, 균열 검출 품질이 높은 프레임에서의 균열 정보가 균열 검출 품질이 낮은 프레임에서의 균열 정보와 동등하게 사용된다.

균열 검출 품질이 높은 프레임에 더 높은 가중치가 부여되면서 균열 모자이크가 생성된다면 생성된 균열 모자이크의 품질이 높아질 것이다. 지금까지 이미지 별 균열 검출 품질 예측을 위한 연구 및 균열 정보에 특화된 모자이크 생성을 위한 연구는 부족한 실정이다. 따라서 본 연구는 프레임별 균열 검출 품질 예측 및 균열 검출 품질에 기반을 둔 균열 모자이크 생성방법을 제안한다.

(2) 관련 연구

(가) 도로면 균열정보 통합 연구

도로면 균열 정보 통합을 위해 다양한 장비가 사용되었다. 첫째, 균열 정보가 3차원 점군 데이터(Point Cloud)로 통합될 수 있다. Sukumar et al. (2006), Yu et al. (2007), Miraliakbari et al. (2014), 그리고 Guan et al. (2015)은 3차원 레이저 센서와 비디오 카메라

라를 이용하여 균열 정보를 포함한 3차원 점군 데이터를 생성했다. Barsi et al. (2006)은 스테레오 카메라(Stereo camera)를 이용하여 균열 정보를 포함한 3차원 점군 데이터를 생성했다. 둘째, GPS 연계(GPS-tagging)를 수행하여 균열 정보가 하나의 지도 위에 통합될 수 있다. Jahanshahi et al. (2012)는 RGB-D(RGB-Depth) 카메라를 이용하여 도로면 균열 검출을 수행하고 각 이미지에 해당하는 GPS 정보를 수집하였다. Medina et al. (2010)와 Zalama et al. (2014)는 카메라를 이용하여 도로면 균열 검출을 수행하고 각 이미지에 해당하는 DGPS(Differential Global Positioning System) 정보를 수집하였다. 그러나 3차원 레이저 센서, 스테레오 카메라, RGB-D 카메라, 그리고 DGPS는 일반인이 쉽게 소유할 수 있는 기성품이 아니다. 따라서 이러한 특수장비들을 사용한 정보 추출은 제한적일 수밖에 없다.

기성품이 저가의 GPS와 함께 도로면 균열 검출에 사용된 연구도 파악되었다. Huang et al. (2005)은 도로면 균열을 휴대용 카메라로 촬영하였다. Radopoulou et al. (2016)은 차량 뒷면 주차용 카메라를 사용하였다. Mertz et al. (2014)는 차량의 대시보드에 설치된 스마트폰을 사용하였다. Yan et al. (2018)은 차량의 전방에 설치된 카메라를 이용하였다. 위의 연구자들은 프레임별 도로면 균열 정보와 GPS 정보를 연계하였다. 그러나 이산적인 균열 정보가 하나의 연속적인 균열 정보로 통합되는 연구는 수행되지 않았다.

이산적인 이미지를 연속적인 단일 모자이크 이미지로 통합하기 위하여 블랙박스 카메라가 사용된 연구도 존재한다. Guo et al. (2014, 2016)와 Meguro et al. (2017)은 GPS와 INS(Inertial Navigation System)를 기반으로 도로면 모자이크를 생성하였다. Naumann et al. (2016)과 Sikirić et al. (2011)은 GPS를 기반으로 도로면 모자이크를 생성하였다. Geiger et al. (2009)와 Sikirić et al. (2010)은 블랙박스 카메라로 촬영된 이미지만 사용하여 도로면 모자이크를 생성하였다. 이러한 도로면 모자이크 만드는 방법들을 블랙박스 원본 이미지 대신 균열 정보 이미지에 적용하면 균열 모자이크를 생성할 수 있다. 그러나 프레임별 균열 검출 성능이 고려된 균열 모자이크 생성 연구는 없었다.

(나) 이미지 품질 평가 연구

균열 검출 품질을 예측하는 연구는 많이 부족한 실정이나 이미지 품질 평가(Image Quality Assessment)와 관련된 많은 연구가 수행되어왔다. 이미지 품질은 주관적 방법(Subjective Method)과 객관적 방법(Objective Method)으로 평가될 수 있다. 주관적 방법은 관찰자의 판단을 기반으로 평가가 이루어지는 방법이고 객관적 방법은 계산 모델을 기반으로 평가가 이루어지는 방법이다. 이미지 품질 평가는 많은 경우에 그 기준이 부족하여 어려움을 겪는다. 따라서 객관적 평가 방법의 성능을 입증하기 위하여 주관적 평가와의 유사성을 활용하기도 한다 (Sheikh et al. 2004; Mohammadi et al. 2014).


다양한 컴퓨터 비전 분야에서 높은 성능을 보여온 CNN은(Gao et al. 2019) 최근에 이미지 품질 평가에도 사용되어졌다. Ji et al. (2019), Fang et al. (2019), Chen et al. (2018), Zeng et al. (2018), 그리고 Yan et al. (2019)는 다양한 종류의 이미지 품질 평가를 위하여 CNN 모델을 사용하였다. Gu et al. (2019)는 2015년에 ILSVRC 대회에서 우승한 ResNet(He et al. 2016) 모델을 사용하였다. Chen et al. (2019)는 ResNet(He et al. 2016)의 일부인 잔류 블록(Residual block), Conv층, 그리고 일괄 정규화(Batch Normalization)등을 사용하였다. 이미지 품질 평가 연구를 위하여 여러 CNN 모델들이 개발된

것처럼 균열 검출 품질을 예측하기 위하여 새로운 CNN 모델이 개발될 수 있다.

새로운 CNN 모델이 개발된다면 대표적인 CNN 모델들과의 성능 평가 비교가 필요하다. 대표적인 CNN 모델에는 GoogLeNet(Szegedy et al. 2015), ResNet(He et al. 2016), 그리고 Inception(Szegedy et al. 2016, 2017)등이 있다. GoogLeNet(Szegedy et al. 2015)과 ResNet(He et al. 2016)은 각각 ILSVRC대회에서 2014년과 2015년에 우승한 모델이다. Inception(Szegedy et al. 2016, 2017)은 GoogLeNet에서 발전된 모델이다. 본 연구에서 균열 품질 평가를 위한 새로운 CNN이 개발되었고 대표적인 CNN 모델들과의 성능 비교가 수행되었다.

(3) 연구 방법론

본 연구의 전체적인 프레임워크는 그림 2-6에 나타나있다. 입력값은 블랙박스 동영상이고 출력값은 이진 균열 모자이크이다. 제안된 프레임워크는 총 네 개의 세부 단계로 구성 된다: (a)프레임별 도로면 균열 검출; (b)균열 검출 품질 예측; (c)균열 검출 품질 기반 모자이크 생성; (d)균열 정보 이진화(Binarization). 각 단계는 다음의 (가)~(라) 소제목들에서 상세하게 설명된다. 그림 2-6에서 보여지는 균열 확률 이미지 및 균열 확률 모자이크는 균열로 예측된 확률이 클수록 해당 픽셀이 높은 강도(Intensity)값을 가진다. 그림 2-6에서 보여지는 이진(binary) 균열 모자이크 이미지에서 흰 부분은 균열이고 검은 부분은 비균열이다.



[그림 2-6] 제안된 방법론에 대한 전체적인 프레임워크: (a)프레임별 도로면 균열 검출; (b) 균열 검출 품질 예측; (c)균열 검출 품질 기반 모자이크 생성; (d)균열 정보 이진화.

(가) 프레임별 도로면 균열 검출

블랙박스 이미지에서 픽셀 단위 균열 검출을 수행하기 위하여 단위 성과 1-3-①의 CNN 모델이 사용되었다. 단위 성과 1-3-①의 균열 검출 모델은 ResNet-152(He et al. 2016) 기반의 인코더-디코더 네트워크이다. 균열 검출 모델에서 입력값은 블랙박스 이미지이고 출력값은 이진 균열 이미지이다. 본 연구에서 균열 검출 모델의 출력값인 이진화된 데이터를 그대로 사용하는 대신 이진화 직전의 소프트 맥스 함수(softmax function) 결과값이 사용되었다. 각 픽셀의 소프트 맥스 값은 해당 픽셀이 균열로 예측된 확률을 나타낸다. 그림 2-7은 픽셀 단위 균열 검출의 결과 예시를 보여준다. 그림 2-7(b)는 그림2-7(a)에서 도출된 균열 확률 이미지로, 균열로 예측된 확률이 클수록 각 픽셀은 높은 강도값을 가진다.



(a) 블랙박스 카메라로 촬영된 이미지



(b) 도출된 균열 확률 이미지


[그림 2-7] 픽셀 단위 균열 검출 결과.

이진 균열 이미지 대신 균열 확률 이미지가 사용되는 이유는 다음과 같다. 균열 확률 이미지가 이진 균열 이미지로 변환되면, 0%와 100% 사이의 값을 갖던 픽셀값이 0% 또는 100%로 변환된다. 균열 확률 이미지와 이진 균열 이미지가 사용될 때 각각 다른 균열 모자이크 결과를 야기한다. 가령, 균열 확률 모자이크에 균열일 확률이 각각 5%, 55%, 그리고 60%인 중복된 픽셀 3개가 있다고 가정하면, 이들을 평균할 경우 균열일 확률이 40%이다. 하지만 이진화 작업이 수행되었다면 해당 픽셀의 균열일 확률이 각각 0%, 100%, 100%가 되어 평균값은 67%가 된다. 본 연구진은 40%가 67%보다 타당하다고 판단하여 이진 균열 이미지 대신 균열 확률 이미지를 사용하였다.

(나) 균열 검출 품질 예측

균열 검출 연구의 결과를 평가하기 위해 일반적으로 F1-점수(F1-Score)가 사용된다. F1-점수는 Trade-Off 관계인 정밀도와 재현율을 모두 반영하는 지표이다. 따라서, 특정 프레임의 F1-점수가 높을수록 해당 프레임에서 수행된 균열 검출 결과가 신뢰받을 수 있을 것이다. 본 연구는 프레임별 F1-점수를 해당 프레임의 균열 검출 품질로 사용하였다.

본 연구에서는 균열 검출 품질을 CDQ(Crack Detection Quality)라고 명명하고, CDQ 예측을 위한 새로운 CNN 모델인 CDQ-Net(CDQ prediction Network)을 제안한다. CDQ-Net의 구조는 그림 2-8에 나타난다. CDQ-Net에서 입력값은 블랙박스 이미지에서 도로면이 포함된 관심지역(Region Of Interest)이고 출력값은 CDQ이다. CDQ-Net은 총 4개의 Conv층, 1개의 전체 평균 풀링층(Global Average Pooling layer), 그리고 1개의 FC층으로 구성된다.



[그림 2-8] CDQ-Net의 구조 (Conv (7 × 7)/4; 필터의 크기가 7 × 7이고 보폭이 4인 Conv층).


그림 2-8은 CDQ-Net의 구조를 보여준다. Conv층은 이미지를 입력받은 후 필터의 크기는 7 × 7이고 보폭(Stride)은 4인 합성곱 연산, 일괄 정규화, 그리고 활성화 함수(Activation Function)를 거쳐 특징맵을 출력한다. 이때, CDQ-Net에서 사용된 활성화 함수는 ReLU (Rectified Linear Unit)이다. CDQ-Net의 Pool층은 전체 평균 풀링층을 지칭하며 각 채널의 평균값을 구하는 역할을 수행한다. CDQ-Net의 결과는 3차원의 텐서(Tensor)가 아닌 1차원의 값으로 출력되어야 하기 때문에 Pool층은 Conv층을 통과한 특징맵의 차원을 축소한다. 특징맵을 입력받은 Pool층의 결과는 512개의 뉴런(Neuron)을 가진다. FC층은 Pool층의 출력값을 입력받아 1개의 뉴런값(CDQ 값)으로 변환시킨다. FC층에서는 드롭 아웃(Dropout) 50%가 적용되어 CDQ-Net의 과적합(Overfitting) 문제를 방지한다. 각 Conv층의 필터 개수 (64, 128, 256, 512), 전체 평균 풀링 층 및 FC층은 ILSVRC2015의 우승 네트워크인 ResNet(He et al. 2016)과 유사하게 설정하였다.

CDQ-Net의 구조가 대표적인 CNN 모델들과 크게 다른 부분은 Conv층의 개수, 필터의 크기, 그리고 보폭의 크기이다. 먼저, CDQ-Net은 이미지 분석에 좋은 성능을 가진 다른 CNN 모델들보다 적은 수의 Conv층으로 이루어져 있다. 앞서 언급한 ResNet, GoogLeNet, Inception 등은 수백만에서 수천만 장의 이미지로 구성된 데이터셋으로 학습되므로, 깊은 CNN 구조에서도 충분히 학습될 수 있다. 하지만 본 연구진이 확보한 균열이 표시된 블랙박스 이미지의 수는 수백 장에 불과하므로 적은 수의 CNN 파라미터를 학습시키기 위해 층의 개수가 적은 얇은 구조(Shallow Structure)의 네트워크를 제작하였다. 반면, CDQ-Net의 필터의 크기와 보폭의 크기는 다른 CNN 모델들보다 크게 설정되었다. 그 이유는 얇은 구조의 네트워크를 이용하여 해상도가 높은 이미지를 처리해야 하기 때문이다. 152개의 Conv층으로 이루어진 ResNet-152는 224 × 224 크기의 이미지를 처리하기 위해, 필터 크기를 3 × 3, 그리고 보폭을 2로 설정하였다. CDQ-Net 입력이미지의 크기는 540 × 1,536 이고, 4개의 Conv층을 통과하는 입력값의 크기를 줄여나가기 위해 7 × 7 크기의 필터와 보폭 4를 적용하였다.

(다) 균열 검출 품질 기반 모자이크 생성

모자이크 생성의 전체적인 프레임워크는 그림 2-9에 나타난다. 제안된 프레임워크는 다음

과 같이 네 단계로 구성된다: (1)단일 프레임의 투영변환; (2)차량 이동 경로 추정; (3)프레임 간 강제변환. (4)균열 확률 모자이크 이미지 생성. 각 단계에 대한 설명은 아래와 같다.



[그림 2-9] 도로면 모자이크 생성 프레임워크.

첫째, 투영변환 단계에서는 사시도(Oblique-View) 이미지를 평면도(Top-View) 이미지로 변환한다. 본 단계에서는 블랙박스 이미지로부터 균열 검출 모자이크 제작에 필요한 관심 영역

을 추출하고 해당 영역에 투영변환을 적용하는 것을 목표로 한다. 본 단계의 관심 영역을 차량이 주행하고 있는 차선의 도로로 정의하고, 해당 도로 부분을 추출하여 소실점을 결정한다. 소실점 이상치(Outlier)로 인한 투영변환의 오류를 줄이기 위해 각 프레임에서 도출된 소실점을 해당 프레임의 투영변환에 활용하지 않고 해당 영상 데이터의 평균값으로 고정 소실점을 결정한다. 고정 소실점을 도출하는 자세한 과정은 다음과 같다. 우선 사시도 이미지에서 차량이 주행 중인 차로의 좌우 두 개의 차선들을 검출하여 두 차선의 가상의 교점인 소실점을 도출한다. 그 다음 블랙박스 촬영한 동영상에서 추출한 프레임에서 도출된 소실점들의 분포를 정규분포로 가정하고 신뢰도 90% 내의 소실점들을 선별한다. 이때 선별된 소실점들의 평균값이 고정 소실점으로 결정된다. 고정 소실점을 활용하여 각 프레임 별로 원본 블랙박스 이미지의 위 65%, 아래 20%, 좌우 20%를 잘라내고 남은 이미지의 윗변, 밑변, 그리고 아래 양 끝점과 고정 소실점을 연결한 두 직선으로 구성된 사다리꼴 모양의 이미지를 추출한다. 본 단계의 투영변환은 고정 소실점을 기반으로 추출된 사다리꼴 모양의 이미지를 직사각형으로 변환하는 2차원 기하학적 관계를 의미한다. 평면 투영변환이 제대로 수행되지 않는 이미지는 강제변환 단계에서 연속적인 두 프레임 간의 왜곡된 기하학적 관계를 야기할 수 있다. 이러한 기하학적 왜곡은 모자이크 생성 단계에서 오류를 발생시킬 수 있다. 따라서 본 연구는 고정 소실점을 사용함으로써 모자이크 생성의 오류 누적을 방지하고자 하였다.

둘째, 차량 이동 경로 추정 단계에서는 앞서 검출된 두 개의 차선들 간의 중심 곡선을 도출한다. 검출된 차선들은 각각 이차 함수로 피팅(Fitting)되고, 두 함수 위 좌표들의 수평방향(x방향) 중점들은 새로운 이차 함수로 피팅되어 두 차선의 중심 곡선을 표현한다. 이는 직선 차선뿐만 아니라 곡선 차선에서도 연속적인 두 프레임 간의 기하학적 관계를 도출하기 위함이다. 차량이 직선 차선을 주행하는 경우 연속적인 프레임 간의 주행방향(y방향)의 변위만을 고려하면 된다. 하지만 곡선 차선을 주행하는 경우 차량의 y방향의 변위뿐만 아니라 x방향의 변위도 발생한다. 본 단계에서 곡선 차선을 주행할 때를 고려함으로써 본 방법론의 범용성을 높였다.

셋째, 강제변환 단계에서는 연속된 두 프레임들 간 최적의 기하학적 관계를 도출하여 두 프레임을 하나의 이미지로 통합한다. 한 프레임에서 차량 이동 경로 곡선(두 차선의 중심 곡선)의 맨 아래에 있는 끝점과 중심 곡선 위에 있는 모든 픽셀들 간의 x, y방향 변위(Δx , Δy) 및 접선($\Delta \theta$)은 다음 프레임과의 기하학적 관계를 결정하는 데 사용된다. 한 프레임과 그 다음 프레임간의 변위를 정량화하기 위하여 프레임 간의 중복되는 영역 내의 모든 픽셀 간 이미지 밝기값의 평균제곱오차(Mean Squared Error)가 계산된다. 본 연구에서는 이러한 평균제곱오차 값이 최소일 때 연속적인 두 프레임이 최적으로 연결되는 것으로 정의하였다.

넷째, 모자이크 이미지 생성 단계에서는 연속적인 평면도 모자이크 이미지를 생성하는 것이 목표이다. 앞서 첫째 단계에서 투영변환된 프레임들은 셋째 단계에서 도출된 최적의 기하학적 관계에 따라 강제변환된다. 강제변환 단계가 반복되면서 앞서 블랙박스 동영상으로부터 추출된 모든 프레임들은 하나의 이미지로 통합되어 도로면 모자이크 이미지를 구성한다.

위의 네 단계를 통해 원본 블랙박스 동영상으로부터 도로면 모자이크 이미지를 생성할 수 있다. 모자이크 이미지를 만들 때 일반적으로 활용되는 덮어쓰기 방법 또는 혼합하기 방법을 균열 확률 모자이크 이미지 제작에 활용할 경우, 균열 검출 품질을 고려하지 않은 모자이크 이미지가 생성된다. 본 연구는 균열 검출 결과로부터 도출된 해당 프레임의 F1-점수값을 프레임 내 모든 픽셀의 균열 검출 품질(CDQ)값으로 이용한다. 균열 검출 품질이 높게 예측된 픽셀에 더 높은 가중치를 부여할 수 있도록 각 프레임 별 도출된 CDQ값에 따라 균열 확률값들

을 가중평균하여 균열 확률 모자이크를 생성한다.

(라) 균열 정보 이진화

균열 확률 모자이크가 이진 균열 모자이크로 이진화되기 위하여 최적의 임계값이 결정되어야 한다. 투영변환 단계에서 발생하는 균열 예측 확률값의 왜곡으로 인해 이진화를 위한 최적의 임계값이 항상 50%라고 확신하기 어렵기 때문이다. 균열 확률 모자이크로부터 임계값에 따라 다른 이진 균열 모자이크가 생성되며, 수동 레이블링으로 제작된 참값과 비교하여 산출되는 품질(F1-점수)도 달라진다. 따라서 다수의 균열 확률 모자이크들의 0%에서 100% 사이의 임계값에 따른 평균 F1-점수를 산출하고, 평균 F1-점수가 가장 높을 때의 임계값을 최적의 임계값으로 결정한다. 새로운 균열 확률 모자이크를 이진 균열 모자이크로 변환할 때 사전에 산출된 최적의 임계값이 사용된다.

(4) 실험 및 결과

실험에 사용된 모든 블랙박스 이미지는 Qrontech LK-919 QAD 제품으로 촬영되었다. 초당 프레임 수(Frames Per Second)는 30이었고 해상도는 $1,440 \times 2,560$ 이다. 실험이 수행된 컴퓨터의 운영체제는 Ubuntu 16.04이며 Intel Core i7-7700 CPU 및 GeForce GTX 1080 Ti GPU로 구성되었다. 제안된 방법론을 평가하기 위해 두 가지 실험을 수행하였다.

(가) CDQ-Net 성능 평가


블랙박스 동영상에서 추출된 419장의 이미지가 CDQ-Net의 학습 및 성능 평가를 위해 사용되었다. 학습(Training), 검증(Validation), 그리고 평가(Test) 데이터셋은 각각 272, 64, 83장의 이미지로 구성되었다. 각 이미지에 대한 CDQ 값은 단위 성과 1-3-①의 픽셀 단위 균열 검출 모델 예측 결과와 LEAR Image Annotation tool 프로그램을 활용하여 수작업으로 생성된 균열 정답지(Ground Truth)(그림 2-10)를 비교하여 산출된 F-1 점수이다. CDQ를 예측하기 위하여 다양한 CNN 모델들을 실험하였다. 첫째, 합성곱 필터의 크기가 7×7 이고 보폭이 4인 Conv층으로 구성된 CNN 모델들을 구성하여 최적의 Conv층의 개수 및 필터의 개수를 찾기 위한 실험을 수행하였다([표 2-1]). 둘째, 합성곱 필터의 크기가 3×3 이고 보폭이 2인 Conv층이 쌓인 CNN 모델들을 구성하여 본 네트워크와의 성능을 비교하기 위한 실험을 수행하였다. 단, 첫 번째 Conv층의 필터 크기는 7×7 이고 보폭은 4이다([표 2-2]). 셋째, ResNet-50, ResNet-101, ResNet-152, Inception V3 및 Inception ResNet V2와 비교 실험을 수행하였다. 다섯 네트워크의 초기 가중치(Initial Weight)는 ImageNet으로 사전학습되었다.

[표 2-1] 7×7 유형 CDQ-Net 후보들의 합성곱 필터 크기.

채널 수 \ Conv층의 개수	1	2	3	4	5
64	7×7	7×7	7×7	7×7	7×7
128		7×7	7×7	7×7	7×7
256			7×7	7×7	7×7
512				7×7	7×7
1024					7×7

[표 2-2] 3×3 유형 CDQ-Net 후보들의 합성곱 필터 크기.

채널 수 \ Conv층의 개수	2	3	4	5	6	7	8
64	7×7	7×7	7×7	7×7	7×7	7×7	7×7
128	3×3	3×3	3×3	3×3	3×3	3×3	3×3
128		3×3	3×3	3×3	3×3	3×3	3×3
256			3×3	3×3	3×3	3×3	3×3
256				3×3	3×3	3×3	3×3
512					3×3	3×3	3×3
512						3×3	3×3
1024							3×3



[그림 2-10] 모자이크 이미지 내 균열 정보 수동 레이블링.

최적의 CDQ-Net을 구하기 위한 학습 환경은 다음과 같다. 학습 반복 수(Epoch), 손실함수(Loss Function), 그리고 최적화 알고리즘(Optimization Algorithm)은 각각 1,000, 평균제곱오차, and Adam(Kingma et al. 2014)이다. 네트워크 학습의 최적 파라미터(Conv층의 개수 및 필터의 개수, 미니 배치 크기)를 구하기 위해 다양한 실험들이 수행되었다. 각 모델에 대한 성능 평가는 평균제곱오차를 기준(Metric)으로 표 2-3, 표 2-4, 그리고 표 2-5에 요약되었다. 실험 결과, 합성곱 필터의 크기가 7×7 이고 보폭이 4인 Conv층 4개로 구성된 CNN 모델이 미니 배치 크기 2로 학습되었을 때 가장 높은 성능을 보였다. CDQ-Net과 대표적인 CNN 모델들(ResNet-50, ResNet-101, ResNet-152, Inception V3 및 Inception ResNet V2) 간의 성능 비교는 표 2-6에 요약되었다. 본 연구에서 제안된 CDQ-Net은 대표적인 CNN 모델들과 비교했을 때 가장 좋은 성능을 보였다.

[표 2-3] 7×7 유형 CDQ-Net 후보들의 평균제곱오차(%).

미니 배치 크기	Conv층의 개수	1	2	3	4	5
1		13.84	13.33	11.85	13.08	13.81
2		13.13	9.22	9.38	7.96	11.75
4		11.52	8.21	8.43	8.51	10.38

[표 2-4] 3×3 유형 CDQ-Net 후보들의 평균제곱오차(%).

미니 배치 크기	Conv층의 개수	2	3	4	5	6	7	8
1		11.73	13.59	13.49	13.48	13.03	19.66	12.79
2		10.26	10.28	11.76	10.47	10.45	8.81	10.03
4		9.44	9.57	8.75	8.5	9.15	8.58	9.39

[표 2-5] 대표적인 CNN 모델들의 평균제곱오차(%).

미니 배치 크기	대표적인 CNN 모델	ResNet50	ResNet101	ResNet152	Inception V3	Inception ResNet V2
1		27.99	13.67	19.01	14.13	13.22
2		9.14	12.03	(없음)*	10.33	8.77
4		9.8	(없음)*	(없음)*	9.09	(없음)*

*GPU 메모리가 부족할 때

[표 2-6] 최적의 미니 배치 크기일 때의 CDQ-Net과 대표적인 CNN 모델들의 평균제곱오차(%).

CDQ 예측을 위한 CNN 모델	최적의 미니 배치 크기	평균제곱오차(%)
CDQ-Net	2	7.96
ResNet50	2	9.14
ResNet101	2	12.03
ResNet152	1	19.01
Inception V3	4	9.09
Inception ResNet V2	2	8.77


(나) CDQ 기반 균열 모자이크 생성 성능 평가

블랙박스 이미지 4,500장이 균열 모자이크 생성 성능 평가에 사용되었다. 본 4,500장의 이미지는 50개의 서로 다른 블랙박스 동영상으로부터 추출되었으며, 한 블랙박스 동영상마다 90장의 연속적인 프레임들이 추출되었다. 하나의 균열 모자이크가 생성되는데 한 개의 동영상에 쓰였으므로 총 모자이크 50개가 성능 평가에 사용되었다. 균열 모자이크 정답지는 앞서 실험에서 쓰인 LEAR Image Annotation tool 프로그램을 활용하여 생성되었다. 제안된 균열 모자이크 생성 방법의 성능은 다음과 같이 평가되었다. 모자이크 50개 중에서 49장을 균열 모자이크 이진화를 위한 최적 임계값을 계산하고 나머지 1장으로 F1-점수를 측정하였다. 이와 같은 방식으로 모자이크 이미지 50장에 대한 F1-점수들의 평균값을 계산하였다. 이는 균열 모자이크 생성 방법의 성능을 측정하는데 활용되었다.

제안된 균열 모자이크 생성 방법은 모자이크를 생성하는 대표적인 두 가지 방법(덮어쓰기 방법 및 혼합하기 방법)과 비교되었다. 50개의 모자이크에 대한 F1-점수들의 평균값이 덮어쓰기 방법 또는 혼합하기 방법의 성능을 평가하는데 활용되었다. 제안된 균열 모자이크 생성 방법, 덮어쓰기 방법, 그리고 혼합하기 방법의 성능 비교가 표 2-7에 요약되었다. F1-점수 기준으로 제안된 균열 모자이크 생성방법의 성능이 가장 뛰어난 것으로 나타났다. 그림 2-11은 각 방법의 균열 검출 결과 예시를 보여준다.

[표 2-7] 모자이크 생성 방법에 따른 성능 평가.

모자이크 생성 방법	정밀도	재현율	F1-점수
CDQ 기반	0.5175	0.6748	0.5838
덮어쓰기 기반	0.8251	0.2634	0.3969
혼합하기 기반	0.3427	0.8543	0.4870



[그림 2-11] 각 방법에 따른 균열 모자이크 생성 결과물 예시.

(5) 결론

본 연구는 도로면 유지관리를 위한 새로운 균열 모자이크 생성방법을 개발하였다. 본 연구는 차량용 블랙박스 동영상상을 이용한 균열 검출 품질 기반 균열 모자이크 이미지 생성 방안을 제시하였다. 본 연구에서 제안된 균열 검출 품질 예측 모델은 최하의 평균제곱오차(7.96%)를 기록하며 기존의 대표적인 CNN 모델들(ResNet50, ResNet101, ResNet152, Inception V3, and Inception ResNet V2)보다 뛰어난 성능을 보였다. 제안된 균열 검출 품질 기반 균열 모자이크 생성 방법은 최고의 F1-점수(0.5765)를 기록하며 기존 균열 모자이크 생성 방법들

(덧어쓰기 방법 및 혼합하기 방법)보다 뛰어난 성능을 보였다.

본 연구에서 제안된 균열 모자이크 생성방법의 성능을 향상할 수 있는 여지가 남아있다. 첫째, 균열 검출 및 균열 검출 품질 예측 방법이 모두 심층학습 모델이므로 모델 자체를 개선하거나 학습 데이터를 늘린다. 둘째, 프레임별 품질뿐만 아니라 프레임 내 픽셀 단위에서도 가중치를 부여한다. 전방을 향해 촬영된 이미지가 획득되므로 가까운 도로에 해당하는 픽셀일수록 더 높은 가중치를 주거나 먼 도로에 해당하는 픽셀을 전혀 고려하지 않는다.

다. 단위성과 1-3-①: 심층학습 기반 도로 포장 균열 검출 기술 (픽셀 단위)

(1) 연구의 목적

본 연구에서는 CNN 모델 중 하나인 인코더-디코더 네트워크를 활용하여 차량용 블랙박스 이미지로부터 픽셀 단위의 도로 포장 균열을 검출하는 기술을 개발하였다. 인코더 네트워크는 잔류 네트워크(Residual Network)의 Conv층으로 구성되며, 디코더 네트워크는 Deconvolutional Layer(이하 DeConv층)으로 구성된다. 본 연구에서 사용된 네트워크는 도로 포장의 균열을 감지하도록 설계되었고 블랙박스 이미지의 모든 픽셀을 의미론적 세분화(Semantic Segmentation)를 통해 ‘균열’ 또는 ‘비균열’으로 분류하였다. 대규모 이미지 데이터셋을 사용하여 사전학습 가중치를 미세 조정하기 위한 학습 방법인 전이학습은 불충분한 수의 학습 이미지를 보유한 본 연구의 한계를 극복하기 위해 적용되었다. 실험 결과는 본 연구의 인코더-디코더 네트워크가 블랙박스 이미지에서 픽셀 단위로 도로 균열을 검출하는데 최적화되었음을 보여주었다.

이미지 처리 및 기계 학습 알고리즘을 이용한 균열 탐지 방법은 수동 검사 또는 특수 차량을 활용한 방법과 비교하여 도로 포장 상태를 모니터링을 비교적 효율적이고 안전하게 수행할 수 있다. 이전의 연구자들은 자동 도로 균열 탐지를 위한 정교한 방법들을 제안했지만, 기존의 탐지 방법은 블랙박스 카메라로 촬영한 이미지를 분석하는 데 사용하기 어렵다. 블랙박스 이미지에서 균열을 감지하는 것은 세 가지 측면에서 어려움이 있다. 첫째, 블랙박스 이미지는 도로 노면뿐만 아니라 빌딩, 차량, 나무 및 보행자 등 다른 물체를 포함한다. 둘째, 블랙박스 이미지의 품질은 주행 조건, 시간 및 기상 조건에 따라 크게 달라진다. 셋째, 블랙박스 이미지는 차량의 블랙박스 카메라의 위치에 따라 왜곡된다. 본 연구는 이러한 문제들을 해결하기 위해 CNN 모델 중 하나인 인코더-디코더 네트워크를 활용하여 차량용 블랙박스 이미지로부터 픽셀 단위의 도로 포장 균열을 검출하는 기술을 개발하였다.

(2) 관련 연구

(가) 이미지 기반 균열 감지 연구

이미지를 활용한 균열 감지를 위해 다양한 기술들이 사용되었다. Jahanshahi and Masri (2012)는 3D 장면을 재구성하여 균열 두께를 정량화하는 방법을 제안했다. Nishikawa et al.

(2012)는 여러 이미지 필터를 반복적으로 적용하여 균열 검출에 최적화된 다중 순차 이미지 필터를 개발했다. Zalama et al. (2014)는 Gabor 필터와 AdaBoost 알고리즘을 사용하여 세로 및 가로 균열(Longitudinal and Transverse Crack)을 검출하는 방법을 제시했다. Cheng et al. (2003)은 포장 이미지에서 픽셀 단위 균열 검출을 위한 임계치화 방법(Thresholding)을 제안했다. Ying and Salari (2010)는 Beamlet 변환 알고리즘을 사용하여 균열 세그먼트를 수직, 수평, 횡단 및 블록의 네 가지 유형으로 분류했다. Shen (2016)은 회색 변환, 이미지 평활화(Smoothing) 및 이미지 형태 처리를 이용한 포장 균열 인식 방법을 제안했다. O'Byrne et al. (2014)는 대비 강화 및 색상 감소 작업, Sobel 엣지 검출기, 클러스터링 기반 필터링 기술 및 SVM(Support Vector Machine)을 사용하여 사회기반시설의 표면 이미지에 적용할 수 있는 균열 분할 기법을 제안했다. Yeum and Dyke (2015)는 UAV로 획득한 이미지를 사용하여 볼트 근처의 균열을 식별하는 교량 검사 기술을 제안했다.

도로 포장의 상태를 자세히 평가하기 위해서는 폭, 모양 및 길이와 같은 균열의 기하학적 특징에 대한 정보를 수집해야 한다. 픽셀 단위의 균열 검출은 이미지 내 수백만 개에 달하는 픽셀을 대상으로 균열 여부를 모두 판단해야하기 때문에 그 난이도가 높다. 이러한 균열 검출을 위해 깊은 신경 네트워크를 사용하려는 시도가 있었다. 특히, CNN은 인간이 정의한 특징을 활용하지 않고도 입력 이미지에서 의미있는 정보를 추출할 수 있기 때문에 여러 연구자들의 주목을 끌고 있다. Zhang et al. (2017)은 3D 아스팔트 표면의 픽셀 수준 포장 균열을 감지하기 위한 CNN 모델(CrackNet)을 제안했다. 뒤이어, Zhang et al. (2018)은 모델의 매개변수를 제거하면서 은닉층(Hidden Layer)을 추가하여 원본 CrackNet을 수정하는 CrackNet II를 제안했다. CrackNet 및 CrackNet II는 Pool층이 없기 때문에 입력층과 동일한 해상도를 가진다. 따라서 두 네트워크는 매우 높은 수준의 계산 능력을 요구한다. 고해상도의 블랙박스 이미지를 처리하기 위해 계산상 더 효율적인 균열 감지 모델이 필요하다. Zhang et al. (2018)은 픽셀 수준의 포장 균열 탐지를 위한 재귀 네트워크 (CrackNet-R)를 제안했다. CrackNet-R은 원래의 CrackNet과 비교하여 속도와 탐지 정확도면에서 우수한 성능을 보였다. Huang et al. (2018)은 지하철 터널에서 균열을 탐지하기 위해 FCN을 사용한 심층 학습 기반의 방법론을 제안했다. Dung (2019)은 VGG-16에 기반한 인코더-디코더 네트워크를 사용하여 콘크리트 균열 감지를 위한 방법을 제안했다. Zou et al. (2019)는 인코더-디코더 네트워크를 사용하여 도로 포장면 이미지의 균열을 검출하는 방법을 제안했다. 다양한 심층 학습 기반 균열 감지 방법이 도로 및 사회기반시설의 균열 감지에 적용되었지만 블랙박스 이미지에서 도로 균열을 감지하는 연구는 충분하지 않다.

(나) 의미론적 세분화 관련 연구


의미론적 세분화는 경계를 추출하고 이미지를 인지적 관점에서 의미있는 단위로 분리하는 기술이다. FCN은 임계화(Thresholding), 엣지 감지(Edge Detection) 및 지역 동질성(Regional Homogeneity) 측면에서 기존의 의미론적 세분화 기술보다 우수한 성능을 보인다(Long et al. 2015). FCN은 확률적 자동 인코더(Probabilistic Auto-Encoder)의 구조를 본따 깊은 컨볼루션 인코더-디코더 네트워크로 발전했다(Huang et al. 2007). Conv층, Pool층, 활성화 함수 및 FC층과 같은 반복된 다중 층으로 구성된 일반적인 CNN과 달리 인코더-디코더 네트워크는 인코더 네트워크와 디코더 네트워크의 두 가지 별도의 심층 신경 네트워크

를 사용한다. 이 네트워크는 장면 이해(Kendall et al. 2015), 자율 운전(Teichmann et al. 2016), 생물 의학 이미지 세분화(Ronneberger et al. 2015), 의미론적 세분화(Badrinarayanan et al. 2017; Pohlen et al. 2017) 등 다양한 분야에서 활용된다. SegNet(Badrinarayanan et al. 2015)은 의미론적 세분화를 위한 인코더-디코더 네트워크를 구현하는 첫 시도였다. SegNet의 인코더 네트워크는 VGG-16의 13개 Conv층을 활용한다. SegNet의 디코더 네트워크의 역할은 픽셀 수준의 예측을 수행할 때 입력 이미지의 해상도를 유지하면서 인코더 네트워크의 최종 계층의 핵심 특징을 이용하는 것이다. SegNet의 성능을 향상시키기 위해 사전 학습된 네트워크(Zheng et al. 2015)에 추가 네트워크 연결, 추가 교육 데이터를 사용한 사전 교육(Liu et al. 2015), Deconvolutional network(Noh et al. 2015; Dumoulin and Visin 2016)와 max-pooling index를 재사용하는 업샘플링(Noh et al. 2015, Badrinarayanan et al. 2017) 등 다양한 기술들이 적용되어왔다.

ZFNet(Zeiler and Fergus 2014)은 CNN의 중간층의 모습을 시각화하기 위해 제안되었다. CNN은 Pool층에서 가장 높은 값을 가진 특징만을 추출하고 활성화 함수를 통해 특징을 전달하여 출력값을 생성한다. 그러나, Pool층에서 최대값을 갖는 셀의 정확한 위치는 손실된다. 정보 손실을 최소화하기 위해, ZFNet은 위치 정보, 즉 가장 높은 활성화 값을 갖는 셀의 인덱스를 저장한다. 결과적으로, ZFNet의 CNN 특징맵의 시각화 결과는 디컨볼루션 프로세스에 성공적으로 활용될 수 있다.

(3) 연구 방법론


본 연구의 목표는 블랙박스 이미지에 나타나는 균열을 성공적으로 탐지하고 설명하는 것이다. 균열의 검출은 블랙박스 이미지의 모든 픽셀이 ‘균열’ 또는 ‘비균열’으로 분류되도록 픽셀 단위로 수행되었다. 본 연구진은 블랙박스 이미지에서 픽셀 수준의 균열 감지를 위한 인코더-디코더 네트워크를 제안한다. 네트워크는 인코딩 프로세스에 ResNet을 사용하는 반면, 디코딩 프로세스에 SegNet, FCN 및 ZFNet에 사용되는 디컨볼루션(Deconvolution) 기술을 사용하였다. 네트워크의 입력 이미지의 해상도는 너비, 높이 및 채널에 대해 각각 $1,920 \times 1,080 \times 3$ 이다. 해상도가 $60 \times 34 \times 2,048$ 인 최종 특징맵은 디코더 네트워크의 입력과 인코더 네트워크의 출력이다. 디코더 네트워크는 1×1 Conv층을 사용하여 특징맵을 처리하고 대응하는 인코더 네트워크로부터의 정보를 사용하여 디컨볼루션 기법을 수행한다. 그림 2-12는 네트워크 프로세스를 보여준다. 그림 2-12의 출력 이미지에서 빨간색으로 표시된 픽셀은 균열로 분류된 픽셀을 나타낸다.



[그림 2-12] 인코더-디코더 네트워크 프로세스.

(가) 인코더 네트워크

인코더의 역할은 입력 이미지를 처리하여 이미지의 특징을 추출하는 것이다. SegNet이 VGG-16을 사용하여 특징맵 추출을 통해 의미론적 세분화를 수행함에도 불구하고 두 가지 이유에서 픽셀 수준의 균열 예측 성능을 보장할 수 없다. 첫째, 블랙박스 이미지는 운전 조건과 시간에 따라 각 이미지마다 고유의 배경을 가지고 있다. 둘째, 블랙박스 이미지의 균열은 외부 조명 및 날씨의 변화로 인해 균일하지 않다. 이에 따라 본 연구진은 ImageNet 및 COCO 2015 대회에서 VGG-16보다 우수한 성능을 발휘한 ResNet을 인코더 네트워크로 선택하였다. ResNet의 우수한 성능을 감안할 때, ResNet이 균열 감지에 알맞은 특징맵을 추출할 것으로 기대하였다. 인코더 네트워크로 활용된 ResNet은 기존 CNN 모델의 가중치 학습 방법과 달리 각 층의 입력값과 출력값의 차이인 잔차(Residual)를 학습시켜 모델의 층이 깊어지면서 발생할 수 있는 기울기 사라짐 문제(Gradient Vanishing Problem: 네트워크의 앞쪽 층(Layer)의 파라미터들이 거의 학습되지 않는 문제)를 해결하였다. 단위성과 1-1에서 활용된 VGG의 경우 층의 개수가 16개 또는 19개인 것에 반해, ResNet은 훨씬 더 깊은 구조를 가지고 있으며 ResNet-34, ResNet-50, ResNet-101, ResNet-152 등 깊이에 따라 여러 종류가 있다. 따라서 본 연구진은 ResNet이 균열 검출을 위한 특징을 추출하는데 VGG보다 더 적합하다고 판단하였다. 인코더 네트워크의 최종 결과물은 폭, 높이 및 필터 수에 대해 각각 $60 \times 34 \times 2,048$ 의 해상도를 갖는다. 인코더 네트워크를 통과 한 1/8, 1/16 및 1/32 크기의 피쳐맵은 디코더 네트워크에서 사용된다. 그림 2-13은 152개의 층(하나의 Pool층과 151개의 Conv층)으로 구성된 ResNet-152를 개략적으로 보여준다. ImageNet 데이터셋으로 사전 학습된 ResNet 네트워크를 사용하여 제안된 인코더 네트워크의 매개 변수를 학습시켰다.



[그림 2-13] 인코더 네트워크: ResNet-152.

(나) 전이 학습


많은 수의 매개 변수를 가진 CNN은 학습 데이터의 양이 충분하지 않을 때 잘 학습되지 않을 수 있다. 따라서 CNN은 대개 많은 양의 레이블링 이미지 데이터셋을 필요로 한다. 그러나 블랙박스 이미지에서 균열의 실제 위치가 픽셀 수준에서 수동으로 기록되어야 하므로 이 유형의 연구에서는 충분한 수의 레이블링 이미지를 얻는 것이 어렵다. 전이 학습은 CNN의 무작위로 초기화 된 가중치를 사용하는 대신 대규모 데이터 세트로 사전 학습된 가중치를 사용하여

다른 도메인의 모델에 대용량 데이터로 학습된 모델의 지식을 전달하는 방법이다. 이 학습 방법은 CNN의 수렴을 가속할 뿐만 아니라 소량의 학습 데이터로 학습된 모델의 성능을 향상시킬 수 있다. 전이 학습은 건설 장비 탐지(Kim et al. 2018), 포장 균열 탐지(Gopalakrishnan et al. 2017; Zhang et al. 2018), X선 영상을 이용한 수하물 인식(Akçay et al. 2016)과 같은 다양한 분야의 문제를 상대적으로 적은 학습 데이터로도 성공적으로 해결해왔다. 따라서 본 연구에서는 인코더 네트워크를 학습하는데 전이 학습을 활용하였다.

(다) 디코더 네트워크

디코더 네트워크의 역할은 입력 이미지와 같은 크기를 갖도록 특징맵의 크기를 확대하는 것이다. 제안된 네트워크의 디코더에서 FCN의 스킵-커넥션(Skip-Connection) 방식이 사용되었다. 인코더에서 보유하던 정보 (1/16 및 1/8 크기의 특징맵)는 디코딩 프로세스에서 선택적으로 활용된다. 그림 2-14에 묘사된 것과 같이 $120 \times 68 \times 2$ 의 1/16 크기 특징맵이 생성되는 경로는 두 가지가 있다. 특징맵의 한 세트는 $60 \times 34 \times 2$ 해상도의 특징맵의 디컨볼루션 기술을 적용하여 생성된다. 다른 특징맵 세트는 인코더 프로세스로부터 얻어진 기존 1/16 크기의 특징맵에 기반하여 생성된다. 인코더로부터 가져온 특징맵은 $120 \times 68 \times 2$ 해상도의 특징맵을 생성하기 위해 1×1 필터로 합성곱 과정을 거쳐 생성된다. 생성된 1/16 크기의 특징맵의 두 세트는 산술적으로 더해져 동일한 해상도를 갖는 결합된 특징맵을 생성한다. 이 과정을 반복하여 1/8 크기의 결합된 특징맵을 얻는다. 결합된 1/8 크기의 특징은 입력 이미지와 동일한 크기로 8배만큼 확장되어 소프트맥스(Softmax)층을 통과한다. 디코더의 결과물의 해상도는 $1,920 \times 1,080 \times 2$ (너비, 높이 및 클래스 수)이다. 소프트맥스 함수의 값은 개별 픽셀이 특정 클래스에 속할 확률을 정한다. 디코더 네트워크는 픽셀별로 높은 확률을 갖는 클래스를 예측 클래스로 결정한다. 디코더 네트워크의 출력은 각각 "균열" 및 "비균열" 클래스를 나타내는 1과 0으로 구성된 이진 이미지(Binary Image)이다. 디코더 네트워크의 세 층은 최대 풀링(Max Pooling) 프로세스에서 위치 정보를 저장하는 ZFNet의 디컨볼루션 기술과 인코더 맵에 객체의 경계 정보(Boundary Information)를 저장하는 SegNet의 디컨볼루션 기술을 사용한다.


파이썬으로 구현된 알고리즘은 다음과 같다. 수집된 블랙박스 이미지와 각 이미지에 해당하는 레이블 이미지를 인코더-디코더 네트워크에 학습시켰다. 단위성과 1-1과 마찬가지로 각 이미지에 대한 경로를 텍스트 파일에 저장하면, 파이썬은 이를 불러와 인코더와 디코더 네트워크를 학습시켰다. 학습시간을 감소시키기 위해 사전학습 가중치를 불러와 학습 과정에 활용하였다. 임의의 블랙박스 이미지를 모델에 입력하였을 때, 픽셀 단위로 각 클래스(균열 및 비균열)에 속할 확률이 각각 출력된다. 알고리즘은 픽셀별로 모델의 예측값을 계산하고 도로에 속할 확률이 0.5가 넘는 경우 그 픽셀을 균열로 판단한다.



[그림 2-14] 디코더 네트워크 (Bang et al. 2019).

(4) 실험 및 결과

본 연구에서는 5대의 차량에 블랙박스 카메라를 설치하여 서울특별시 및 근교의 도로 이미지를 획득하였다. 동영상은 초당 30프레임으로 구성되었으며 해상도는 $2,560 \times 1,440 \times 3$, 확보한 데이터의 용량은 총 2.1TB이다. 이 데이터는 도로 포장의 픽셀 단위의 균열 검출을 위한 인코더-디코더 모델을 학습시키는데 활용되었다. 도로 포장면의 균열을 검출하는 기술을 개발하기 위해 이전 도로 포장면 추출 기술 개발 연구와 같이 심층학습 구조를 활용하였다. 균열의 경우 그 크기가 일정하지 않고, 이미지 내에서 차지하는 픽셀 수가 적기 때문에 다각형을 활용할 시 레이블링을 정확하게 하는 것은 어렵다. 이에 따라 본 연구에서는 픽셀 단위의 이미지 레이블링이 가능한 LEAR Image Annotation tool을 활용하였다. 사용자가 마우스를 활용하여 균열로 판단되는 부분을 수동으로 지정한 후 그림 2-15의 위쪽 그림의 왼쪽에 보이는 파일 목록에서 다음 차례로 레이블링을 수행할 이미지를 선택하면, 그림 2-15의 아래쪽 그림과 같은 레이블 이미지가 자동으로 저장된다.




[그림 2-15] LEAR Image Annotation tool 예시.

본 연구에서는 ResNet-152를 기반으로 하는 인코더-디코더 네트워크를 구성하는 변수를 조절하여 도로 포장면에서 픽셀 단위로 균열을 검출하기 위한 기술을 개발하였다. 본 연구에서는 단위 성과 1-1의 도로 포장면을 나타내는 픽셀 대신 균열을 나타내는 픽셀로 정밀도와 재현율의 측정방식이 대체되어 활용되었다. 100장의 테스트 이미지로 실험한 결과, 정확도와 정밀도, 재현율의 평균값은 각각 99.84%, 77.68%, 71.98%로 나타났다. 테스트 결과는 그림 2-16과 같이 출력된다.



[그림 2-16] 도로 포장 픽셀 단위 균열 검출 예시.


균열 검출에 최적화된 네트워크를 설계하기 위한 실험을 수행하였다. 학습 데이터 427장 중 100장을 검증 데이터셋으로 분류하여 심층학습 네트워크 학습의 최적 파라미터(학습 횟수 및 학습률)를 정했다. 먼저, 표 2-8와 같이 최적의 인코더를 찾기 위해 검증 데이터셋을 활용하여 VGG-16, ResNet-50, ResNet-101, ResNet-152, ResNet-200을 인코더로 활용하고 제안된 방법으로 디코더를 수행한 네트워크와 기존 인코더-디코더 네트워크인 SegNet의 균열 검출 성능을 비교하였다. 실험 결과에서, ResNet-152를 인코더로 활용한 네트워크가 픽셀 수준의 균열 감지에 가장 적합하다는 것을 파악할 수 있다. 그림 2-17는 네트워크의 최적 학습 횟수를 구하기 위해 ResNet-152를 인코더로 활용한 네트워크의 학습 횟수에 따른 학습 손실(Training Loss)과 검증 손실(Validation Loss)을 보여준다. 두 손실값은 100,000회 학습 횟수 이후 특정 수준으로 수렴되기 때문에 네트워크의 학습 횟수는 100,000으로 설정하였다. 표 2-8는 100장의 검증 데이터셋에 대한 학습률별 균열 검출 성능(F1-점수)을 보여준다. 표 2-8에서 0.00001은 최적의 결과를 얻는 학습률임을 알 수 있다. 또한 표 2-8과 그림 2-18의 결과는 ResNet-152를 인코더로 활용한 네트워크가 균열 검출에 최상의 성능을 보임을 보여준다.



[그림 2-17] ResNet-152 인코더에 대한 학습 반복횟수에 따른 재현율, 정밀도, F1-점수, 학습 손실 및 검증 손실.

[표 2-8] 검증 데이터셋에 대한 학습률에 대한 균열 검출 성능 (F1-점수)의 비교.

네트워크		학습률				
		0.001	0.0001	0.00001	0.000001	0.0000001
기존 인코더-디 코더 네트워크	SegNet	4.26%	9.79%	12.01%	9.82%	7.65%
	VGG-16	12.98%	16.32%	19.88%	17.42%	16.96%
	ResNet-50	11.48%	35.96%	51.39%	33.02%	21.03%
	ResNet-101	4.69%	29.04%	55.45%	33.77%	25.56%
	ResNet-152	12.02%	34.06%	70.21%	40.33%	26.77%
제안된 디코더를 활용한 네트워크	ResNet-200	22.13%	19.70%	34.47%	21.65%	17.35%



[그림 2-18] 다양한 CNN 인코더를 사용한 균열 감지 결과의 비교 (캡처 된 이미지의 일부만 표시됨): (a) 테스트 이미지; (b) (a)의 실제 균열 위치를 빨간색으로 표시한 그림; (c) SegNet으로 균열을 검출한 결과; (d) VGG-16을 인코더로 사용하는 네트워크로 균열을 검출한 결과; (e) ResNet-50을 인코더 네트워크로 사용하는 네트워크로 균열을 검출한 결과; (f) ResNet-101을 인코더 네트워크로 사용하는 네트워크로 균열을 검출한 결과; (g) ResNet-152를 인코더 네트워크로 사용하는 네트워크로 균열을 검출한 결과; (h) 전이학습없이 ResNet-152를 인코더 네트워크로 사용하는 네트워크로 균열을 검출한 결과; (i) ResNet-200을 인코더 네트워크로 사용하는 네트워크로 균열을 검출한 결과 (Bang et al. 2019).

데이터셋을 구성하는 527장의 이미지는 날씨와 사진 촬영 시간을 기준으로 밝은 이미지와


어두운 이미지로 구분된다. 강수 확률이 20% 이하인 오전 11시부터 오후 5시 사이에 촬영된 이미지를 밝은 이미지로 분류하고 나머지 이미지는 어두운 이미지로 분류하였다. 527장의 이미지는 158장의 밝은 이미지(30%)와 369개의 어두운 이미지(70%)로 구성되었으며 3 대 7 비율은 학습 및 테스트 데이터에서 유지되었다. 표 2-9의 결과는 어두운 환경(강수 확률이 20% 이상이거나 오전 8시부터 오전 11시 사이, 혹은 오후 5시 이후)에서 촬영한 이미지가 밝은 환경에서 촬영한 이미지보다 균열 검출에 있어 훨씬 좋은 결과를 나타냄을 보여준다. 도로 표면에 그림자를 유발하는 강한 햇빛은 균열이 감지되는 것을 방해하였다. 해당 결과는 흐린 날, 아침 또는 늦은 오후에 촬영된 블랙박스 이미지가 도로 모니터링에 효과적으로 활용될 수 있음을 보여준다.

어두운 조건에서 촬영된 블랙박스 이미지를 균열 검출에 활용한 결과 정확도, 재현율과 정밀도는 각각 99.95%, 82.59%와 83.72%로 나타났다. 본 연구는 특정 조건에서 수집된 이미지들을 활용하는 것이 도로 노면 상태를 모니터링 하는데 더 유리함을 밝혔다. 뿐만 아니라, 정확도 90% 이상 및 미검출률 20% 이하라는 단위성과 1-3 목표를 달성하였다.

[표 2-9] 기상 조건에 따른 학습 및 테스트 이미지의 수와 균열 검출의 성능.

	밝은 이미지	어두운 이미지	총합
학습 이미지 수	128	299	427
테스트 이미지 수	30	70	100
재현율	40.33%	82.59%	71.98%
정밀도	45.43%	83.72%	77.68%
정확도	99.77%	99.95%	99.89%


그림 2-19는 100장의 테스트 이미지 중에서 두 장의 이미지, 즉 성능이 가장 높은 경우 [그림 2-19(a)]와 가장 낮은 경우 [그림 2-19(d)]를 보여준다. 그림 2-19(b)에서 볼 수 있듯이 그림 2-19(a)에는 단순한 형태의 균열만이 존재한다. 그림 2-19(c)에서, 재현율(86.12%), 정밀도(90.65%) 및 IoU(Intersection Over Union)(79.10%)를 달성하였다. 그림 2-19(d)는 그림 2-19(e)에서 파악할 수 있듯이 다양한 모양과 길이의 균열이 존재한다. 그림 2-19(f)에서, 재현율(46.75%), 정밀도(11.74%) 및 IoU(19.51%)를 달성하였다. 그림 2-19(d)에서 균열의 위치와 형상을 판단하는 것은 쉽지 않다. 위 결과는 도로 균열의 참값을 정의하는 데 전문 지식이 필요하다는 것을 암시한다. 또한 단순하지 않은 형태의 균열을 검출하는데 본 네트워크가 아직 충분한 성능을 발휘하지 못한다는 것을 파악할 수 있다.



[그림 2-19] 최상의 결과를 나타내는 이미지의 예와 최악의 결과를 산출하는 이미지의 예:
 (a)가장 높은 성능을 보인 이미지; (b)(a)의 실제 균열을 빨간색으로 표시한 이미지;
 (c) (a)의 균열을 해당 네트워크로 검출한 이미지; (d)가장 낮은 성능을 보인 이미지;
 (e) (d)의 실제 균열을 빨간색으로 표시한 이미지; (f) (d)의 균열을 해당 네트워크로 검출한
 이미지 (Bang et al. 2019).

그림 2-20은 본 네트워크의 균열 예측 결과 오류의 예를 보여준다. 그림 2-20(a)와 그림 2-20(b)는 거짓 음성, 즉 실제 균열이지만 균열로 예측되지 않은 오류의 예를 보여준다. 그림 2-20(a)를 보면, 태양 빛에 반사되어 도로 이미지가 제대로 촬영되지 않았음을 파악할 수 있다. 이에 따라 균열과 배경간의 분류가 적절히 수행되지 않았다. 그림 2-20(b)는 차량 앞 유리의 반사와 도로 균열이 차지하는 면적이 일치하여 네트워크가 혼동을 일으키는 예시를 보여준다. 이러한 이미지들은 도로의 균열을 파악하는데 적절하지 않기 때문에, 도로 균열 검출에서 제외될 필요가 있다. 그림 2-20(c)와 그림 2-20(d)는 거짓 양성, 즉 실제 균열이 아닌 픽셀이 균열로 예측된 예시를 보여준다. 그림 2-20(c)는 건물 사이의 틈이 균열로 잘못 식

별 된 상황의 예시이다. 네트워크는 전선이나 건물 사이 등 균열과 기하학적으로 유사한 객체를 균열로 착각할 수 있다. 그림 2-20(d)는 실제 균열을 둘러싼 균열이 아닌 주변 픽셀이 균열로 예측된 이미지를 보여준다. 이러한 결과는 네트워크를 혼동시킬 수 있는 이미지들을 필터링해주는 알고리즘에 대한 필요성을 암시한다.



[그림 2-20] 사전 학습된 ResNet-152 인코더의 테스트 결과에서 오류의 예: (a),(b)거짓 음성(False-negative) 오류의 예; (c),(d)거짓 양성(False-positive) 오류의 예 (Bang et al. 2019).

(5) 결론

본 연구는 블랙박스 이미지에서 균열 감지를 위해 깊은 컨벌루션 인코더-디코더 네트워크를 활용하려는 첫 번째 시도이다. 블랙박스 이미지에 나타나는 균열을 탐지하기 위해 인코더-디코더 네트워크를 사용하여 유망한 결과를 얻는 데 있어 이전의 다른 연구는 성공하지 못했다. 다양한 네트워크의 비교 분석은 본 연구에서 제시된 인코더-디코더 네트워크가 크게 향상된 균열 검출 성능을 보여줄 수 있도록 설계되었음을 입증한다. 본 연구의 인코더-디코더 네트워크는 F1-점수가 74.72%이고 IoU가 59.65%인 최상의 성능을 제공한다. 이 결과는 차량에 탑재된 블랙박스 카메라가 기존의 도로 모니터링의 데이터 수집 방법을 보완할 수 있다는 가능성을 보여준다.

제안된 균열 탐지 방법을 개선하기 위한 두 가지 해결책, 즉 데이터 중심 접근법과 알고리즘 접근법을 제시한다. 데이터 중심 접근 방식은 서로를 보완하는 깊은 학습과 빅 데이터를 활용하는 것이다. 깊은 학습은 빅 데이터의 지원 없이는 눈에 띄는 성공을 달성하지 못했다. 본 연구에서 제안된 균열 탐지 방법은 ImageNet 데이터셋의 1,500만 장 이상의 이미지를 기반으

로 하는 전이 학습을 사용하였다. 즉, 제안된 방법은 이미 빅 데이터 접근법에 의존하고 있다. 하지만, ImageNet 데이터셋은 도로 포장 이미지, 특히 블랙박스 카메라로 확보된 이미지를 포함하지 않는다. 따라서, 다양한 상황의 블랙박스 카메라로 촬영한 도로 이미지 데이터를 네트워크 학습을 위해 추가한다면 도로 포장의 균열을 보다 향상된 성능으로 검출할 수 있을 것이다. 알고리즘 접근법은 사전, 또는 사후 처리의 다양한 부분을 직접 제어하는 데 사용된다. 예를 들어 사전 처리 알고리즘을 개발하여 균열로 오인 될 수 있는 영역을 제거하고 관심 영역만 추출 할 수 있다. 자율 주행을 위한 도로 포장면 추출 연구(Teichmann et al. 2016)와 창반사 제거 연구(Shih et al. 2015)에서 보인 기술은 균열 감지 성능을 향상시키는 데 사용될 수 있다. 두 가지 접근법이 적용된다면 광범위한 도로망을 적시에 모니터링하고 보다 효율적인 도로 관리 전략을 수립할 수 있을 것이다.

라. 단위성과 1-3-②: 심층학습 기반 도로 포장 균열 검출 기술 (구역 단위)

(1) 연구의 목적

결함이 있는 도로 표면을 적시에 발견하고 보수하는 것은 도로 인프라의 내구성 향상에 필수적이다. 결함 상태를 파악하기 위해서는 사람이 육안으로 결함 정보를 조사하거나 도로 상태 모니터링을 위한 특수 차량을 활용하는 방법이 있다. 기존의 모니터링 방법을 통한 도로 표면의 결함 정보 수집은 많은 시간과 인적 비용이 들며 이를 개선할 필요가 있다. 차량의 주행 정보를 기록하기 위해 블랙박스 기기의 설치가 증가하고 있으며 기기 내 카메라의 품질 또한 향상되고 있기 때문에 이 장치는 도로 포장의 결함을 탐지하는 데 효과적으로 활용될 수 있다. 본 연구는 도로 포장면의 모니터링을 효율적으로 수행할 수 있는 방법을 제안한다. 이 방법은 차량 내 블랙박스 카메라로 촬영된 영상을 활용하여 도로 포장의 균열을 자동으로 검출하는 기술이다. 균열 검출은 블랙박스 카메라에서 확보되는 대용량의 영상 데이터를 신속하게 처리할 수 있는 ‘구역’ 단위로 수행되었다.

(2) 관련 연구

균열, 패치(Patch), 그리고 포트홀(Pothole) 등의 도로 포장면의 결함을 자동으로 검출하기 위한 많은 연구가 수행되어 왔다. 균열이 얇은 선형이며 주변의 포장면보다 어두운 픽셀값을 가진다는 특징을 이용하여 이미지 내에서 균열을 검출하는 방법론들이 제안되어 왔다. 하지만 불규칙한 방향 및 그림자로 인한 밝기 변화 때문에 균열 검출을 위한 규칙을 정하여 감지하는 것은 어려움이 있다(Gopalakrishnan et al. 2017; Zou et al. 2012).


2012년 발표된 깊은 합성곱 신경망 AlexNet의 개발 이후 심층학습이 주목 받기 시작했다. AlexNet은 심층 인공 신경 네트워크를 사용하여 이미지 분류에서 우수한 결과를 얻는 CNN이다. 지속적인 컴퓨팅 기능 개발과 엄청난 양의 데이터 축적으로 매년 더 나은 성능의 이미지 분석 모델이 개발되었다. 심층학습은 균열 검출을 위한 연구에도 사용되었다. 심층학습을 활용한 균열 검출은 균열에 대한 가정 없이 입력 이미지에서 직접 그 특징을 추출 할 수 있기 때

문에 균열을 잘 분석 할 수 있다. Zhang et al. (2016)은 CNN이 균열의 존재 유무를 성공적으로 판단할 수 있음을 보여주었다. 일반적인 영상 처리에서 효과적인 분류기로 입증된 VGG와 ResNet도 균열 검출에 적용되어 좋은 결과를 보였다(Feng et al. 2017; Gopalakrishnan et al. 2017).

또한 이미지 전체의 부분 이미지가 균열을 포함하는지 판단하기 위해 구역 기반의 균열 검출에 심층학습이 적용되어왔다. 구역 단위 연구들 중 CNN의 구조를 직접 설계한 연구들이 있다(Cha et al. 2017; Chen and Jahanshahi 2018; Wang et al. 2017; Wang and Hu 2017; Zhang et al. 2018). Wang et al. (2017)은 아스팔트의 균열을 검출하기 위해 3개의 Conv층을 사용한 CNN을 제안하였다. Wang and Hu (2017)는 구역 이미지의 크기를 64×64 로 정하여 균열의 종류를 구분했다. Zhang et al. (2018)은 구역 이미지의 크기를 두 가지로 선정했고, 도로 포장면 이미지의 결함을 균열 및 실링 균열(Sealed Crack)로 분류하였다. 그 외의 연구들에서는 구역 이미지 내의 모서리 또는 가장자리에 있는 균열을 놓치지 않도록 이미지의 영역을 중복시켜 검출 대상에 포함시켰다(Cha et al. 2017; Chen and Jahanshahi 2018).

(3) 연구 방법

본 연구에서 제안하는 균열 검출 방법이 그림 2-21에 제시되었다. 제안된 방법은 두 가지 단계를 통해 블랙박스 이미지로부터 균열을 검출한다. 첫 번째 단계는 도로 추출이고 단위성과 1-1에서 개발한 심층학습을 활용한 도로 포장면 추출 기술을 적용하는 것이다. 두 번째 단계는 구역 단위의 균열 검출이며 이를 수행하기 위해 CNN 구조가 설계되었다. 두 모듈 사이에서 첫 번째 모듈의 출력 이미지를 특정 크기로 제한시켜 두 번째 모듈의 입력이미지로 사용하였다.



[그림 2-21] 단위성과 1-3-②에서 제시하는 균열 검출의 전체 과정 (Park et al. 2019).

블랙박스 이미지에서 균열 검출의 대상인 도로 영역이 추출되어도 그 영역이 차량으로부터 물리적으로 멀리 떨어져 있거나 차량 앞유리에 의해 왜곡된 부분이면 균열 관찰이 어렵다. 본 연구는 균열 검출의 대상을 추출된 도로 영역에서 균열 관찰이 가능한 부분으로 제한하였다. 이러한 방식으로 추출된 이미지의 크기는 너비가 720 픽셀이고 높이는 240 픽셀이다.

본 연구에서는 1차년도에서 개발된 구역 단위 균열 검출을 위한 CNN 모델을 개선시켰다.

최종적으로 CNN 모델은 구역 이미지를 세 가지 클래스(균열, 차선, 손상되지 않은 도로)로 분류한다. 균열 검출에 적합한 CNN 모델을 개발하기 위해 CNN 모델을 구성하는 필터의 크기와 층(Layer)의 수를 조정하였고 나머지 요소는 동일하게 설정하였다. 필터의 수는 CNN 모델의 층을 통과하면서 증가하며 각 Pool층 다음에 필터의 크기를 변경시켰다. Conv층 출력 결과의 크기는 Pool층을 통해서만 감소한다. 2개의 FC층을 CNN 모델의 끝에 배치하였다. 표 2-10과 표 2-11에 제시된 필터 크기 조건과 층의 개수 조건을 조합하여 총 16개의 CNN 모델 후보가 제안되었다. 예를 들어, ‘S1D1’ 는 하나의 필터 크기 (3×3)만을 사용하고 3 개의 Conv층으로 이루어져있다. 마찬가지로 ‘S1D2’ 는 하나의 필터 크기 (3×3)를 갖는 5 개의 Conv층으로 이루어져있다.

[표 2-10] Conv층의 필터 크기 조건.

후보	필터 크기
S1	3×3
S2	5×5
S3	7×7
	5×5
	3×3
S4	9×9
	7×7
	5×5 (3×3)


[표 2-11] Conv층의 층(Layer) 수 조건.

후보	필터 크기
D1	$C_1(16)-P-C_2(32)-P-C_3(48)-P$
D2	$C_1(16)-C_2(16)-P-C_3(32)-C_4(32)-P-C_5(48)-P$
D3	$C_1(16)-C_2(16)-P-C_3(32)-C_4(32)-P-C_5(48)-C_6(48)-C_7(48)-P$
D4	$C_1(16)-C_2(16)-C_3(16)-P-C_4(32)-C_5(32)-C_6(32)-P-C_7(48)-C_8(48)-C_9(48)-P$


* $C_N(n)$: n개의 필터로 이루어진 N번째 Conv층, P: Pool층

(4) 실험 및 결과

구역 단위 균열 검출 기술 개발을 위해 1차년도보다 체계화된 조건 아래에서 CNN 모델이 선정되었으며 보다 많은 양의 학습이미지로 학습되었다. 블랙박스 이미지를 확보하기 위해 앞서 블랙박스 영상에서 도로 내 균열을 포함하는 312장의 이미지 프레임($1,920 \times 1,080 \times 3$)을 추출하였다. 학습과 검증과정을 위해 이 중 192장의 이미지가 활용되었으며, 40×40 크기의 구역 이미지는 1차년도 과제 수행 시 제시한 방법대로 각 이미지 내에서 사용자가 원하는 지점을 클릭하여 생성되었다. 그림 2-22는 8개의 원하는 지점과 이 8개의 지점을 중심으로 생성된 균열 이미지를 보여준다. 그림 2-22에서 빨간색으로 표시된 십자(十)는 데이터 획득을 위해 마우스로 클릭한 지점이다. 차선 및 손상되지 않은 도로에 대한 학습 데이터도 동일한 방식으로 준비되었다. 앞에서 언급된 192장의 이미지 중 164장의 블랙박스 이미지로부터 세 클래스에 대해 각각 2,500개의 40×40 픽셀 크기 이미지가 생성되었다. 각 이미지를 90° , 180° 및 270° 로 회전시켜 학습에 사용할 데이터의 양을 늘렸고, 최종적으로 30,000장의 학습 데이터를 얻었다. 생성된 학습 데이터의 예가 그림 2-23에 나와 있다. 검증 단계에서 활용되는 데이터셋은 학습 데이터와 동일한 방식으로 제작되었으며 각 클래스 당 12,000장의 이미지로 이루어져 있다.




(a)




(b)

[그림 2-22] 균열 검출 모델의 학습을 위한 데이터 생성 과정: (a)블랙박스 이미지와 십자(十) 모양으로 표시된 선택 지점; (b) 40×40 으로 생성된 균열 이미지 (Park et al. 2019).




[그림 2-23] 학습 이미지의 예시: (a)균열; (b)차선; (c)손상되지 않은 도로 (Park et al. 2019).

그림 2-24는 16개의 CNN 모델의 검증 정확도를 보여준다. 그림 2-24(a)와 그림 2-24(b)는 각각 3×3 그리고 5×5 크기의 필터로만 구성된 CNN 모델의 성능을 보여준다. 그림 2-24(c)와 그림 2-24(d)는 여러 크기의 필터로 구성된 CNN 모델의 성능을 보여준다. 검증 결과를 통해 S2D4가 가장 좋은 성능을 가진 것을 확인하였다. 검증 결과의 정확도를 기반으로, S2D4가 균열 검출 모델로 선정되었다(그림 2-25 참고). 선정된 모델은 총 9개의 Conv층, 3개의 Pool층, 그리고 2개의 FC층으로 구성되어 있다.




[그림 2-24] 16개의 CNN 모델 후보의 균열 검출 검증의 정확도: (a)S1 집합; (b)S2 집합;

(c) S3 집합; (d) S4 집합 (Park et al. 2019).




[그림 2-25] 균열 검출을 위해 제안된 CNN의 구조.

본 연구에서는 테스트를 위해 120장의 블랙박스 이미지를 사용하였다. 블랙박스 이미지는 도로면 추출을 위한 CNN 모델을 통과한 후, 균열 검출이 가능한 고정된 영역에 해당하는 240×720 크기의 이미지로 추출되었다. 그림 2-26은 세 장의 블랙박스 이미지와 그 이미지로부터 240×720 크기로 추출된 이미지의 예시를 보여준다. 추출된 이미지는 다시 40×40 크기의 구역 이미지로 나뉜다.




[그림 2-26] 도로 추출 이미지의 예시: (a)원래 블랙박스 이미지; (b)240 × 720크기로 추출된 이미지 (Park et al. 2019).

40 × 40 이미지에서 모서리나 가장자리에 균열이 있을 경우는 균열이 검출되지 않을 수도 있기 때문에, 40 × 40 크기의 사각형 이미지로부터 수평 및 수직 방향으로 20픽셀 거리에 위치한 사각형 이미지 역시 테스트 이미지로 활용되었다(그림 2-27 참고). 생성된 구역 이미지 중, 도로면 검출 과정에서 도로면 이외의 영역이 포함된 구역 이미지는 균열 검출 대상에서 제외된다. 최종적으로, 120장의 블랙박스 이미지에서 균열 이미지 3,360장, 차선 이미지 3,184장, 그리고 손상되지 않은 이미지 9,942장이 생성되었다. 각각의 구역 이미지별로 CNN 모델의 예측값이 계산되어 세 클래스 중 균열에 속할 확률이 가장 높은 경우, 그 이미지는 균열 이미지로 판단된다.




[그림 2-27] 테스트 이미지 생성 방법.

학습된 CNN 모델을 테스트하기 위해 1차년도에 비해 3배 이상 늘어난 양의 이미지가 사용되었다. 테스트를 위한 블랙박스 이미지 120장에서 만들어진 16,486장의 구역 이미지(40 × 40)를 대상으로 수행된 균열 검출의 정확도와 정밀도, 재현율은 각각 90.45%, 90.81%, 74.40%로 나타났다. 그림 2-28에서 빨간색 테두리의 이미지는 균열이미지로 검출된 구역 이미지를 나타낸다. 그림 2-28(a)와 그림 2-28(b)는 각각 밝은 도로면과 어두운 도로면 이미지에서 수행된 균열 검출 결과이다. 그림 2-28(c)는 다른 이미지들에 비해 노면의 질감이 복잡한 이미지에서 수행된 균열 검출 결과이다. 분석하기 어려운 복잡한 질감을 가진 도로면 조건에서도 본 연구의 균열 검출 방법이 잘 수행되는 것을 확인했다.



[그림 2-28] 도로 균열 검출 결과 1/2: (a) 밝은 도로면; (b) 어두운 도로면; (c) 질감이 복잡한 도로면 (Park et al. 2019).


그림 2-29에서 빨간색 테두리의 이미지는 균열 이미지가 균열 이미지로 올바르게 분류된 것이고 초록색과 파란색 테두리의 이미지는 잘못된 분류 결과를 보여준다. 균열 검출 결과 중 균열 이미지가 아닌 나머지 두 클래스(차선, 손상되지 않은 도로)가 균열 이미지로 분류된 결과는 파란색으로 표시되었다. 파란색 테두리 이미지의 특징은 구역 이미지 내에 선 모양의 그림자가 속해 있거나 어두운 차선의 가장자리를 포함하는 경우였다. 이는 반대로 차선 및 손상되지 않은 도로로 분류된 실제 균열 이미지인 구역 이미지들은 초록색으로 표시되었다. 초록색 테두리의 이미지들은 균열이 구역 이미지의 모서리에 위치하거나, 구역 이미지가 거북등 모양의 균열을 포함하는 경우 발생하였다. 수행된 균열 검출 기술은 1차년도에 비해 향상된 정밀도와 재현율을 보인다.



[그림 2-29] 도로 균열 검출 결과 2/2.

(5) 결론

본 연구는 심층학습을 이용하여 블랙박스 이미지에서 균열을 검출하는 방법을 제안하였다. 그림 2-30은 블랙박스 이미지를 입력 이미지로 사용한 균열 검출의 전체 과정을 보여준다. 단위성과 1-1에서 제시된 도로 포장면 추출 방법의 결과, 240×720 픽셀 크기의 도로 이미지가 구성되며 이후 구역 이미지 단위로 균열 검출이 수행되었다. 균열 검출은 40×40 픽셀 크기의 구역 이미지를 대상으로 수행되었다. 그림 2-30에서 가장 아래에 위치한 이미지에서 균열로 검출된 구역 이미지는 빨간색 테두리로 표시되었다. 균열 감지에 적합한 모델을 결정하기 위해 필터 크기와 CNN 모델의 깊이를 변경하여 총 16개의 CNN 아키텍처가 고안되었다. 선택된 CNN 모델은 16,486개의 테스트 이미지에 대해 90.81%의 정밀도, 74.4%의 재현율을 도출하며 높은 성능을 보였다. 제안된 방법은 다음과 같은 한계를 가진다. 첫째, 이 방법은 선형 그림자를 균열로 잘못 분류할 가능성이 있다. 선형 그림자는 도로 주변의 나무, 가로등 또는 중앙분리대에서 발생할 수 있다. 이 문제는 더 많은 이미지 데이터로 학습된 모델을 통해 해결될 수 있을 것이다. 둘째, 균열 검출을 위해 16개의 CNN 모델의 성능만 조사하였다. 이 외에도 많은 CNN 모델이 블랙박스 이미지의 균열 감지에 적합할 수도 있다. 필터 크기와 층의 개수 이외에 더 많은 변수를 조절하여 이 문제를 다룰 수 있을 것이다. 셋째, 제시된 방법은 단일 이미지를 분석하기 위해 제안되었다. 따라서 원본 영상 데이터는 단일 이미지 데이터를 생성하기 위해 사전에 처리되어야 한다. 원본 영상 데이터를 자동 처리한다면, 데이터 준비 및 분석 면에서 높은 수준의 효율성을 제공할 것이다.



[그림 2-30] 블랙박스 이미지에서의 균열 검출을 위한 전체 과정 (Park et al. 2019).

마. 단위성과 2-1: 생존분석을 이용한 기후인자별 열화 속도 영향 평가

바. 단위성과 2-2: 미래 도로 수명 예측 기술 개발 및 도로 최적 유지관리 단위 도출 알고리즘 개발

본 연구에서는 실패로 정의되는 어떤 사건이 발생하기까지 걸리는 시간을 분석하는 통계학적 방법인 생존 분석(Survival Function) 방법을 활용하여 도로 포장 상태 지수와 해당 도로 구간에 해당하는 기후인자로부터 기후인자 별로 도로 포장 상태에 미치는 영향을 분석하였다. 나아가 다변수의 영향을 정량적으로 고려하는 것이 가능한 Cox PH 모델(Cox Proportional Hazard Regression Model)을 활용하여 각 기후인자의 도로 포장 상태에 대한 영향을 정량적으로 산출하고 도로 포장 열화 곡선 수식을 도출하였다. 본 연구의 적용 가능성은 오하이오주의 사례 연구를 통해 입증되었다. 본 연구는 자산 관리자가 포장 도로의 생존 가능성을 제공함으로써 지속 가능한 유지 보수 계획을 수립하는 데 도움이 될 것으로 기대된다.

(1) 연구의 목적

기후 변화는 포장 도로 시스템의 지속 가능성을 위협하고 있다. 도로 시스템이 기후 위험에 미리 적응하지 않는다면, 사회적 및 경제적 손실을 초래할 수 있다. 따라서 기후 변화로 인한 미래의 위협에 대응할 수 있는 도로 시스템의 적응 전략은 도로 관리에 드는 비용을 최소화할 수 있는 필수조건이다. 도로 시스템의 적응 전략은 포장재의 내구성을 높이기 위한 새로운 재료의 추가, 도시의 열섬 효과를 줄이기 위한 포장재의 적용, 그리고 포장재의 에너지 수확 시스템(Energy Harvesting System)의 구축을 통한 전력 생산 등이 있다. 이러한 적응 전략을 도로 시스템에 성공적으로 적용하려면 자산 관리자가 기후 변화로 인한 도로 노후화를 정량적으로 파악해야 한다. 따라서 본 연구는 생존 분석과 Cox PH 모델을 활용하여 기후 변수를 설명 변수로 사용하고 기후 변화 시나리오를 사용하여 기후 변화가 포장에 미치는 영향을 정량적으로 평가할 뿐만 아니라 기후 변화로 인한 포장 도로의 수명 변화를 예측하는 방법을 제안한다.

(2) 관련 연구

(가) 생존 분석

생존 분석은 대상물의 생애가 지속되는 기간을 추정하기 위한 통계적 방법론이다. 생존 분석에서 생존율과 설명 변수(Explanatory Variable) 간의 관계를 나타내는 생존 함수는 비모수(Non-Parametric), 모수(Parametric) 및 반모수(Semi-Parametric) 등 세 가지 방법을 사용하여 유도할 수 있다. 비모수 방법은 확률 분포 유형을 선택하지 않고도 생존 함수를 도출할 수 있다는 이점이 있으나 생존율과 열대 지대, 온대 지대 및 극한 지대와 같은 범주형 설명 변수 사이의 관계만을 설명할 수 있다는 단점이 존재한다. 모수 방법을 사용한 생존 함수는 설명 변수의 계수를 추정하여 도출한다는 점에서 예측이 쉽지만 기존의 확률 분포가 사건의 발생

패턴을 표현하기에 적합하지 않은 경우에는 수명 예측에 적절하지 않다. 반모수 방법은 비모수 및 모수 방법의 특성을 모두 갖는 생존 함수를 생성하는 분석 기법이다. Cox PH 모델은 대표적인 반모수 생존 모델이며 교량의 수명에 영향을 미치는 요인들을 분석하는데 사용되었다. 본 연구에서는 기후 변수를 적용한 Cox PH 모델과 기후 변화 시나리오를 사용하여 기후 변화가 포장에 미치는 영향을 정량적으로 평가하였다.

포장 도로의 수명 분석에서, 실패 사례는 포장 상태가 최소 허용 수준에 도달했기 때문에 유지 보수가 필요한 포장 상태(Terminal Status)로 정의된다. 생존 분석의 주요 프로세스는 수명 T 가 특정 시간 t 보다 커질 확률로 정의되는 생존 함수를 유도하는 것이다. 생존 함수 $S(t)$ 는 다음과 같이 표현 될 수 있다(식 (2-1)).

$$S(t)=P(T\geq t)=1-F(t) \quad (2-1)$$

$F(t)$ 는 시간에 따른 포장 도로의 수명에 대한 누적 확률 분포 함수이다. 예를 들어, t 가 1일 때 $F(1)$ 은 포장 도로가 1년 내에 Terminal Status로 도달할 확률을 나타낸다. 생존 함수는 시간 t 가 지난 후에 실패에 도달 할 위험을 나타내는 위험 함수와 관련된다. 위험 함수는 시간 t 직전까지 포장 도로가 존속한다는 조건 하에서 시간 t 에서의 조건부 확률로 수학적으로 정의된다. 위험 함수 $h(t)$ 의 공식은 다음과 같다(식 (2-2)).

$$h(t)=\frac{f(t)}{S(t)} \quad (2-2)$$

여기서 $f(t)$ 는 시간 t 에 따른 포장 도로 수명의 확률 밀도 함수이다. 생존 분석 방법에서는 실패로 정의되는 사건을 정의해야 한다. 본 연구는 도로 포장 상태 지수에 기반하여 도로 포장의 실패를 정의하였다. ODOT에서 제공하는 PCR 지수 매뉴얼(Pavement Condition Rating System)을 활용하여 PCR 지수가 ‘Good’ (PCR=90)에서 ‘Fair to Poor’ (PCR=65) 미만으로 떨어지는 사건을 실패로 정의하였으며, PCR 지수가 90에서 65까지 떨어지는데 걸리는 시간을 생존시간으로 정의하였다.

(나) Cox PH 모델

식 (2-2)의 위험 함수를 구하기 위해 Cox PH 모델이 활용되었다. Cox PH 모델은 설명 변수가 생존 확률에 미치는 영향을 평가할 수 있는 회귀 모델이다. 본 연구에서 설명 변수는 도로 열화에 영향을 미치는 기후 인자들이다. 위험 함수는 다음과 같이 표현 될 수 있다(식 (2-3)).

$$h(t|X)=h_0(t)\exp(\beta_1x_1+\beta_2x_2+\cdots\beta_ix_i)=h_0(t)\exp(\beta\cdot X) \quad (2-3)$$

이 때, $h_0(t)$ 는 기본 위험 함수, x_i 는 i 번째 공변량, β_i 는 i 번째 공변량의 계수, β 는 β_i 로 구성된 집합, X 는 공변량으로 구성된 집합을 의미한다. $h_0(t)$ 는 비모수적 방법에 의해 계산되기 때문에 식 (2-3)은 $h_0(t)$ 로 표현된 비모수 항과 $\exp(\beta\cdot X)$ 로 표현된 매개 변수 항으로 구성된다. 비모수 $h_0(t)$ 에는 교통량, 교통하중, 도로포장의 종류, 그리고 도로포장면의 두께 등 다양한 도로

열화 원인이 포함되어 있다. $h_0(t)$ 는 비모수 생존 함수를 생성하는데 활용되는 Kaplan-Meier 방법을 활용하여 식 (2-4)와 같이 표현된다.

$$S_0(t) = \prod_{i=1}^t p_i \quad (2-4)$$

p_i 는 시간 $i-1$ 에서 살아남은 개체가 시간 i 에서 살아남을 조건부 확률이다. 포장 도로의 경우 시간 $i-1$ 에서 Terminal Status 상태에 도달하지 않았다고 가정할 때 시간 t 에서 양호한 포장 상태를 유지할 수 있는 조건부 확률은 식 (2-5)와 같이 표현될 수 있다.

$$p_t = \frac{n_t - d_t}{n_t} = 1 - \frac{d_t}{n_t} \quad (2-5)$$

n_t 는 $[t-1, t]$ 동안 양호한 도로 구간의 수이고, d_t 는 $[t-1, t]$ 동안 Terminal Status인 도로 구간 수이다. Kaplan-Meier 방법을 사용하면 $h_0(t)$ 는 식 (2-4)로부터 유도 될 수 있다. 식 (2-1), (2-2), (2-3)을 활용하여 생존 함수(식 (2-6))가 도출되었다.


$$S(t|X) = S_0(t)^{\exp(\beta \cdot X)} \quad (2-6)$$

X 는 공변산의 행렬, $S(t|X)$ 는 공변산의 행렬 X 에 대한 시간 t 에서의 생존 함수, β 는 계수의 행렬, $S_0(t) = \exp \left[- \int_0^t h_0(s) ds \right]$ 는 기본 생존 함수이다. 공변량의 계수 β 는 최대 부분 우도 추정법을 사용하여 추정할 수 있다. 즉 본 모델에서 기후 인자들이 도로 열화에 미치는 영향과 그 외 교통량, 교통하중, 도로포장의 종류, 그리고 도로포장면의 두께 등이 도로 열화에 미치는 영향이 동시에 고려된다.

(3) 연구 방법

본 연구의 목표는 블랙박스 이미지에 나타나는 균열을 성공적으로 탐지하고 설명하는 것이다. 그림 2-31을 참고하면, Cox PH 모델을 사용하여 도로 포장 수명에 미치는 기후 변화 영향을 평가하는 절차는 다음과 같이 네 단계로 구성되었다: (1)포장된 도로 상태 이력 및 기후 데이터 획득; (2)Terminal Status 정의 및 도로 수명 계산; (3)Cox PH 모델을 사용하여 포장 도로 서비스 수명 예측 공식 도출; (4)기후 변화 시나리오를 활용한 미래의 포장 도로 서비스 수명 예측. 앞서 도출된 생존 함수에 기후 변화 시나리오의 기후 인자 데이터를 활용하면 도로의 수명을 예측할 수 있다. 지역별 기후 인자 데이터를 통해 예측된 도로의 수명에 따라 도로 유지 보수를 위한 투자 우선순위가 도출되었다. 한정된 인적 및 물적 자원은 생존 함수에 기반하여 Terminal Status로 정의되거나 혹은 1년 내에 Terminal Status에 도달할 것으로 예측되는 도로 구간을 보수하는데 우선적으로 활용되었다. 단위성과 1에서 긴급하게 보수되어야 할 도로 구간의 균열 정보를 파악하는데 역점을 둔다면, 단위성과 2는 장기적인 관점에서

도로 구간 단위로 최적 유지관리의 우선순위를 도출하는 것을 목표로 한다.



[그림 2-31] Cox PH 모델을 사용하여 도로 수명에 기후 변화가 미치는 영향을 평가하는 절차.

(가) 도로 상태 및 기후 데이터 획득

첫 번째 단계는 포장 서비스 수명 분석의 전제 조건으로 데이터를 수집하는 것이다. 이 연구는 도로 포장 상태를 반영하기 위해 포장 지수(PCR(Pavement Condition Rating))를 사용하였다. 포장 지수는 도로 시스템을 체계적으로 관리하기 위해 포장 상태를 정량화한 수치이다. 도로 관리 기관에 따르면, 포장 지수는 다양하게 정의될 수 있다. 미국 오하이오주의 PCR은 0-100 범위의 값을 가진다. PCR이 100인 경우, 도로는 완벽한 포장상태로 간주된다. 반면, PCR이 65 미만이면 유지 관리 및 보수를 필요로 하는 열악한 포장상태로 간주된다. 한국의 고속도로 포장 상태 지수(HPCI(Highway Pavement Condition Index))는 0과 5 사이의 값

을 가지며 매우 양호한 상태를 나타내는 기준이 4이다. 만약 HPCI가 3보다 작을 경우, 도로 수리가 필요한 상태를 의미한다.

Cox PH 모델을 적용할 때 포장재에 미치는 기후 요인의 영향을 평가하기 위해 도로 조건을 특성화하는 공변량은 기후 인자가 선택되었다. 기후 변수를 공변량으로 선택하기 위해서는 먼저 (1)포장 상태에 영향을 미치고, (2)목표 지역에 지속적으로 기록되어야 하며, (3)기후에서 얻을 수 있어야한다 라는 조건이 충족되어야한다.

(나) 터미널 상태 정의 및 포장 도로의 서비스 수명 계산

두 번째 단계는 수집된 데이터를 생존 분석에 적합한 형식으로 변환하는 데이터 사전 처리이다. 도로의 생존 분석에 필요한 데이터 구성 요소는 도로 구간, 도로 서비스 수명 및 기후 요인이다. 이 중 도로 구간 및 기후 요인에 대한 데이터는 쉽게 접근할 수 있다. 그러나 도로 서비스 수명에 관한 데이터가 존재하지 않기 때문에, 별도로 정의한 Terminal Status를 바탕으로 계산되어야 한다. 도로 수명은 도로 건설 후 Terminal Status에 도달하는 데 걸리는 시간을 나타낸다. 이 연구에서, 포장 도로 수명은 건설 후 PCR이 특정 포장 지수 이하로 떨어지는 데 필요한 시간으로 정의되었다. 예를 들어, PCR 90이 도로 건설 후의 등급이고 PCR 65가 최소 허용 수준이면, 90에서 65까지 진행하는 데 필요한 시간이 도로 수명으로 정의된다.

도로 수명을 정의한 후에는 포장 도로 색인과 조사 시일을 기준으로 각 도로 구간의 수명을 계산할 수 있다. 이 때 일부 손실 데이터(Censored Data)가 존재하기 때문에 이를 적절히 처리해야 한다. 손실 데이터에는 Right-censored Data와 Left-censored Data 등 두 가지 유형이 있다. Right-censored Data는 도로 건설 시의 기록은 있으나 관측 중에 포장 도로 상태가 Terminal Status에 도달하지 않아 그 기록이 없는 경우이며, Left-censored data는 Terminal Status까지 도달하는데 걸리는 시간에 관련된 기록이 존재하지만 도로 건설 시의 기록이 없는 경우이다. 제안된 연구 방법론은 포장도로가 건설된 후 서비스가 가능한 기간을 예측하는 것을 목표로 하기 때문에 손실 데이터 중 Left-censored Data를 활용하지 않고 Right-censored Data만을 활용하였다.

(다) Cox PH 모델을 이용한 포장 도로 서비스 수명 예측식 도출

세 번째 단계는 Cox PH 모델을 사용하여 포장 수명 예측 모델을 도출하는 것이다. 생존 분석은 이전 단계에서 얻은 데이터를 회귀분석하여 수행되었다. 회귀분석의 결과인 공변량의 계수는 각 공변량이 시간에 따른 도로의 생존 확률에 영향을 미치는 정도를 나타낸다. 양의 계수는 식 (2-3)에 따라 공변량 값과 위험 사이의 양의 상관 관계를 나타낸다. 이 때, 공변량 값이 클수록 생존 확률은 더 빠르게 감소한다. 음의 계수의 경우 공변량 값이 클수록 생존 확률이 더 느리게 감소한다. 본 연구로 도출되는 계수는 각 기후 요인이 포장의 수명주기에 미치는 영향을 정량적으로 나타낸다.

Cox PH 모델에는 두 가지 유형의 유효성 검사가 필요하다. 첫 번째 방법은 Z-score를 계산하여 각 공변량의 중요성(Significant)을 확인하는 것이다. P-value는 Z-score 및 표준 정규 분포표를 참조하여 얻을 수 있다. P-value가 0.05 미만이면 해당 공변량은 도로 수명에 영향을 미치는 인자로 간주된다. 두 번째 유효성 확인은 Cox 회귀 모델을 구성하는 각 공변량

이 PH 가정을 따르는 지 확인하는 것이다. PH 가정은 시간 t 에서 추정된 i 번째 공변산의 계수인 $\beta_i(t)$ 와 시간 t 의 상관 관계를 분석함으로써 검증할 수 있다. $\beta_i(t)$ 의 특정 값이 t 에 대해 유의하다면(P-value < 0.05), PH 가정은 만족될 수 없다.

(라) 기후 변화 시나리오를 이용한 미래의 포장 도로 서비스 수명 예측

마지막 단계는 Cox PH 모델 및 기후 변화 시나리오를 사용하여 향후 도로 수명을 예측하는 것이다. 기후 변화 시나리오는 미래에 발생할 온실 가스 배출량을 대표할 수 있는 네 가지 대표적인 농도 경로(RCPs(Representative Concentration Pathways))에 제시되어있다. IPCC(Intergovernmental Panel on Climate Change)는 산업 혁명 이전의 온실 가스 배출량(RCP 2.6), 온실 가스 완화 정책이 상당히 효과를 거둘 때 온실 가스의 배출량(RCP 4.5), 온실 가스 완화 정책이 일부 구현되었을 때 온실 가스의 배출량(RCP 6.0), 완화 정책이 적용되지 않을 때 온실 가스의 배출량(RCP 8.5) 등 네 가지 RCP 시나리오를 제시하였다. 본 연구는 이러한 RCP 시나리오가 미래에 발생할 수 있는 기후 변화의 정도라고 가정하였다. RCP 시나리오에서 도출된 기후 인자들은 Cox PH 모델의 변수로 입력되었다.

생성된 Cox PH 모델의 결과는 시간에 따른 해당 도로의 생존 확률이다. 본 연구에서 자산 관리자는 시간 경과에 따라 각 도로 구간 별로 구축된 Cox PH 모델을 활용하여 모든 도로에서 수리가 필요한 도로의 비율을 추정할 수 있다. 이 예측을 기반으로 자산 관리자는 향후 유지 보수 예산을 예측하고 유지 관리 전략을 수립할 수 있다. Cox PH 모델을 적용할 때 포장재에 미치는 기후 요인의 영향을 평가하기 위해 도로 조건을 특성화하는 공변량은 기후 인자가 선택되었다. 기후 변수를 공변량으로 선택하기 위해서는 먼저 (1)포장 상태에 영향을 미치고, (2)목표 지역에 지속적으로 기록되어야 하며, (3)기후변화 시나리오에서 얻을 수 있어야 한다 라는 세 가지 조건이 모두 충족되어야 한다.


(4) 실험 및 토론

본 연구에서 생존 분석을 이용한 기후인자별 도로 포장 열화 속도 변화량을 산출하기 위해 도로 포장 지수와 해당 도로 구간의 기후인자 정보가 요구된다. 이를 위해 미국 ODOT(Ohio Department of Transportation)에서 제공하는 도로 포장 상태 지수인 PCR 자료와 미국 해양대기청 National Oceanic and Atmospheric Administration에서 제공하는 기상자료를 활용하였다([그림 2-32]). 미국 오하이오주 전체 1,413개 구간의 2000년부터 2016년까지의 PCR 자료를 이용하였으며, 기후 인자는 오하이오 주 64개 관측지점에 대한 최근 10년간의 연간 기상 자료를 이용하였다. 포장 수명에 영향을 미칠 수 있는 9가지 기후 요인이 기후 인자와 포장 도로의 관계를 연구한 기존 문헌에 기초하여 선택되었다([표 2-12]).

[표 2-12] 선택된 9개의 기후인자에 대한 설명.

기후 인자	설명
PrcpAnn	연간 평균 강수량 (mm)

SnowAnn	연간 평균 강설량 (mm)
Tavg	연간 평균 기온 (°C)
PrcpDay	연중 일간 강수량이 254 mm 이상인 날의 수
SnowDay	연중 일간 강설량이 254 mm 이상인 날의 수
RwithF	연중 강수가 발생하면서 일 최저 온도가 0°C보다 낮은 날의 수
FandM	연중 일 최대 온도는 0°C 이상이고 일 최저 온도는 0°C보다 낮은 날의 수
Trange	연교차 (Annual range of temperature) (°C)
Tover32	연중 일간 최대온도가 32°C 이상인 날의 수



[그림 2-32] 미국 오하이오 주 분석 대상 도로 구간 및 기상 관측 지점.

본 연구에서는 PCR 지수가 90에서 65미만으로 떨어지는 사건을 실패로 정의하였으며, 그 기간의 일수를 생존시간으로 정의하여 도로 포장 상태에 대한 생존 분석을 수행하였다. 또한 Cox model를 활용하여 도로 포장 상태에 대한 기후인자의 영향을 정량적으로 파악하여 도로 포장 상태의 생존 확률(열화 곡선) 수식을 도출하였다(식 (5-4)). 수식에서 기후인자의 계수가 양수인 것은 도로 포장 열화 상태에 양의 상관관계 즉, 증가할수록 포장 상태가 빠르게 나빠짐을 의미하며, 계수가 음수일 경우는 그 반대의 상관관계를 가진다. 각 기후인자가 도로 수명에 미치는 영향의 유의성을 나타내는 P-value는 연간 평균 강수량(PrcpAnn: 0.00406), 연간 평균 기온(Tavg: 0.0283), 연중 강수가 발생하면서 일 최저 온도가 0°C보다 낮은 날의

수(RwithF: 0.0333), 연중 일간 최대온도가 32℃ 이상인 날의 수(Tover32: 0.0042) 등 네 가지 인자에서 0.05 이하의 값을 보였다. 즉, PrcpAnn, Tavg, RwithF, Tover32 등 네 가지 기후 인자는 도로 수명 예측에 유의한 영향을 미치는 것으로 도출되었다. 나머지 기후 요인은 포장 수명을 결정하기에 중요하지 않다고 간주되어(P-value가 0.05 이상) 도로 수명 예측 모델 구축에 활용되지 않았다.

본 연구는 도로 포장 열화에 대한 기후인자의 영향을 정량적으로 파악하여 수식을 도출하였다. 2개의 RCP 시나리오(4.5 및 8.5)는 설명 변수를 계산하기 위해 활용되었다. 표 2-13은 과거와 미래 시나리오에 대한 4가지 설명변수인 기후 인자들의 매개변수를 요약한 것이다. 그림 2-33의 도로 포장 수명 생존 함수의 예시를 참고하면, 70% 생존 확률에 도달하는 데 필요한 시간은 정상적인 기후의 경우 13.0년, RCP 4.5의 경우 12.1년, RCP 8.5의 경우 8.9년이다. 즉, 정상적인 기후 조건에서는 13년마다 도로 시스템 기능의 30%를 회복시키기 위해 유지 보수 비용과 계획을 확보하고 이행해야 한다. 같은 도로의 RCP 8.5의 경우 8.9 년마다 같은 양의 투자를 필요로 한다. 같은 도로의 80% 생존 확률에 도달하는데 필요한 시간을 계산하면 정상적인 기후에서는 11.2 년마다, RCP 8.5에서는 7.8 년마다 도로 유지 보수를 수행해야 하는 것으로 나타났다. 도로의 생존 확률은 시간이 갈수록 빠른 속도로 감소함을 그림 2-33에서 볼 수 있다. 이는 적시에 유지보수를 취하지 않는다면 그 후 더 빠른 속도로 포장 상태가 나빠짐을 보여준다.

[표 2-13] 두 기후 변화 시나리오 (RCP 4.5 및 RCP 8.5)에 따른 도로 포장의 생존 확률.


기후 인자	β	P-value
PrcpAnn	0.002358	0.040602
Tavg	-0.15594	0.028277
RwithF	0.027846	0.033327
Tover32	0.057196	0.004190

(5) 결론

일반국도의 도로 포장 균열 상태를 조사하는 방법에는 두 가지가 있다. 국토교통부의 도로포장유지보수 실무 편람에 따르면, 첫째는 사람이 직접 육안으로 확인하고 스케치하는 방법이고, 둘째는 노면 상태 조사 장비(PES)를 활용하는 방법이다. 육안으로 확인하는 방법에는 인력이 많이 투입되어야 한다는 부담이 있고, 노면 상태 조사 장비를 활용하는 방법에는 별도의 장비를 구매하고 운용해야 한다는 부담이 있다. 또한, 노면 상태 조사 장비가 활용되어도 현재 일반국도 도로면 균열 분석을 위한 이미지 프로세싱기법 성능이 부족하여 사람이 직접 균열을 검출한다. 하지만 본 연구는 일반 차량용 블랙박스 카메라를 기반으로 균열 검출 정확도 90% 이상 및 미검출률 20% 이하라는 단위성과 1-3의 목표를 달성하였다. 따라서 본 연구 성과의 활용으로 기존 도로면 균열 상태 조사에 소요되었던 인건비 및 특수 장비 구매 비용이 절감될 수 있을 것이다.

단위성과 1을 기반으로 일반 차량용 블랙박스 카메라를 활용하여 넓은 범위의 도로 포장면

을 모니터링 하는 것이 가능해지면서 선제적인 도로포장 유지관리가 가능해진다. 미국 FHWA (Federal Highway Administration)는 <Final Report: Effectiveness of Crack Sealing on Pavement Serviceability and Life>를 통해 PCR이 65인 도로를 대상으로 균열 실링(Crack Sealing)을 수행한다면 도로의 수명이 평균 1.69년 증가시키는 효과가 있음을 보고하였다. 따라서 본 연구를 활용하여 PCR이 65인 도로에 우선적으로 보수공법을 적용할 수 있다면, 정상적인 기후 조건에서 약 13년으로 예측되는 도로 수명을 14.69년으로 증가시킬 수 있을 것이다([그림 2-33]). 이는 100년을 기준으로 기존 약 7.7번의 도로 재건 작업(Rehabilitation)을 약 6.8번으로 감소시킬 수 있음을 의미한다. 도로 재건 작업에 같은 비용이 소요된다고 가정할 때, 본 연구를 활용한 선제적인 도로포장 유지관리 전략은 도로 유지관리 비용을 약 11.7% 절감시킬 수 있다.



[그림 2-33] 시간에 따른 도로 포장 수명 생존 함수(검정색: 정상적인 기후 조건, 파란색: RCP 4.5 시나리오, 빨간색: RCP 8.5 시나리오).

3. 목표 달성도 및 관련 분야 기여도

3-1. 목표

최종목표

고속 운행(~80km/hr) 중인 일반 차량 전면부에 장착된 모바일 기기(블랙박스 또는 휴대폰)로 취득한 영상을 기반으로 한 포장도로 균열 분석 및 도로 구간별 열화 상태 모델링 기술 개발

- 소셜센싱 기반 도로망 균열 분석 기술 개발

- 미래 도로 수명 예측 시스템 개발을 위한 빅데이터 기반 열화 모델 및 기후 변화 영향 평가 모델 개발

3-2. 목표 달성여부

구분 (연도)	세부 과제명	세부 연구 목표	연구개발 수행 내용	연구 결과
1차 연도 (2017)	핵심성과 1 : 소셜 센싱 기반 도로망 균열 분석 기술	단위성과 1-1 : 모바일 영상 품질 보정 및 도로면 추출 기술	① 도로 포장면 추출 기술	① 테스트 결과 픽셀 단위 정확도, 정밀도 및 재현율 각각 98.84%, 98.05%, 96.07%.
		단위성과 1-3 : 딥 러닝 기반 도로 포장 균열 검출 기술	① 픽셀 단위의 균열 검출 ② 구역(block) 단위의 균열 검출	① 테스트 결과 픽셀 단위 정확도, 정밀도 및 재현율 각각 99.84%, 86.09%, 59.67%. ② 테스트 결과 이미지 구역 단위 정확도, 정밀도 및 재현율 각각 91.46%, 73.45%, 73.94%.
	핵심성과 2 : 미래 도로 수명 예측 시스템 개발을 위한 빅 데이터 기반 열화 모델 및 기후 변화 영향 평가 모델	단위성과 2-1 : 도로 기후 변화 영향 평가 기술 개발	① 생존 분석 기반 도로 열화 속도 변화량 산출	① Cox model를 활용하여 기후인자의 영향을 고려한 도로 포장 상태의 생존 확률(열화 곡선) 수식 도출.
2차 연도 (2018)	핵심성과 1: 소셜 센싱 기반 도로망 포장 균열	단위성과 1-2: GNSS기반 도로면 위치 정보 영상 연계	① 도로면 영상 투영변환 기술 개발 ② 도로면 위치 정보	① 블랙박스 동영상에서 추출한 프레임별로 균열 검출을 수행함 (단위성과 1-3 활용). 그 결과를 정사영상으로

분석 기술	및 도로면 영상 투영변환 기술	영상 개발	투영변환 시킨 후 하나의 균열 모자이크 이미지로 정합 ② 일정 구간마다 도로 균열 상태를 보여주는 한 장의 모자이크 이미지를 생성한 후 위치 정보 영상 연계
	단위성과 1-3 : 딥 러닝 기반 도로 포장 균열 검출 기술	① 픽셀 단위의 균열 검출 ② 구역(block) 단위의 균열 검출	① 테스트 결과, 어두운 환경(강수 확률이 20% 이상이거나 8:00 ~ 11:00 사이, 혹은 17:00 이후)에서 촬영한 이미지의 픽셀 단위 정확도, 재현율 및 정밀도 각각 99.95%, 82.59%, 83.72%으로 나타나 정확도 90% 이상 및 미검출율 20% 미만의 목표 달성함 ② 테스트 결과, 이미지 구역 단위 정확도, 정밀도 및 재현율 각각 90.45%, 90.81%, 74.4%로 정확도 90% 이상 목표 달성
핵심성과 2 : 미래 도로 수명 예측 시스템 개발을 위한 빅 데이터 기반 열화 모델 및 기후 변화 영향 평가 모델	단위성과 2-1 : 생존분석을 이용한 기후인자별 열화 속도 영향	① 도로 열화에 유의미한 영향을 미치는 기후인자 도출	① 연간 평균 강수량, 연간 평균 온도, 연중 강수가 발생하면서 일 최저 온도가 0도보다 낮은 날의 수, 연중 일간 최대온도가 32도 이상인 날의 수 등 도로 열화에 유의미한 영향을 미치는 4가지 기후인자 도출
	단위성과 2-2: 미래 도로 수명 예측 기술 개발 및 도로 최적 유지관리 단위 도출 알고리즘 개발	① 기후 변화 시나리오에 기반한 도로 수명 예측 ② 도로 유지관리 단위 도출	① Cox model 및 생존분석을 활용한 두 가지 기후 변화 시나리오 (RCP 4.5, 8.5)에 따른 도로 포장의 생존 확률 계산 ② 지역별 기후 인자 데이터를 통해 예측된 도로의 수명에 따라 도로 유지관리 우선순위 도출

3-3. 목표 미달성 시 원인(사유) 및 차후대책(후속연구의 필요성 등)

세부 과제명	세부 연구 목표	미달성 목표	미달성 원인 및 차후대책
핵심성과 1: 소셜 센싱 기반 도로망 포장 균열 분석 기술	1-1. 모바일 영상 품질 보정 및 도로면 추출 기술	모바일 영상 품질 보정	단위성과 1-1에서 수행하고자 했던 모바일 영상 품질 보정 연구를 수행하지 않음. 단위 성과 1-1의 도로 포장면 추출 기술 및 단위 성과 1-3 심층학습 기반 도로 포장 균열 검출 기술에 관한 연구를 수행한 결과, 영상의 품질 보정이 없이도 만족할 만한 성과가 나오는 것으로 나타남.
	1-3. 심층학습 기반 도로 포장 균열 검출 기술	균열 종류 구분의 정확도	현재 균열 종류 구분 방법은 인력에 의존하기 때문에 한 종류로 규정하기 어려운 애매한 균열을 분류하는데 문제가 있음. 심층학습 모델은 사람이 정의하는 레이블 데이터를 활용하여 학습되기 때문에 애매한 균열 이미지가 포함된 데이터를 활용하면 올바르게 학습되기 어려움. 균열 종류를 구분하는 목적은 각 균열 종류에 따른 적합한 보수공법을 제시하기 위함임. 본 연구에서는 균열의 종류를 구분하는 대신 도로 포장 균열을 픽셀 단위와 구역 단위로 검출하는 2 가지 기술을 제안함. 픽셀 단위의 균열 검출 기술은 균열의 기하학적인 정보(길이, 모양 등)를 제공할 수 있음. 구역 단위의 균열 검출 기술은 대용량 블랙박스 데이터를 비교적 신속하게 처리할 수 있음.

4. 연구개발성과의 활용 계획 등

본 연구 성과는 다음의 네 단계를 통해 활용될 수 있다.

가. 연구개발성과의 활용 방안

(1) 1단계: 데이터 취득 및 전송

본 연구에서 사용한 데이터 취득 기기는 일반 차량용 블랙박스 카메라이다. 현재 블랙박스 카메라의 보급률에 근거할 때, 추가 비용 없이 넓은 범위의 도로에 대한 많은 양의 데이터를 쉽게 취득할 수 있을 것이라 기대된다. 블랙박스 카메라를 통해 취득한 영상 및 위치 정보는 중앙서버 컴퓨터로 전송되어 도로 균열 정보가 분석된다. 이를 통해 많은 비용이 드는 현재 도로 모니터링 방법 (육안 검사 및 PES 장비 활용)을 보완할 수 있다.

소셜센싱을 기반으로 모니터링을 수행하기 위해서 소셜센싱 자료를 확보할 방안이 마련되어야 한다. 본 연구진은 일반 시민이 데이터를 공유하도록 유도하기 위한 인센티브 제도를 제안한다. 지자체가 본 연구실적을 활용하여 경제적으로 도로상태를 평가하고 도로 유지관리 전략을 수립할 수 있다면 일반 시민에게 인센티브를 제공할 수 있는 여력이 생길 것으로 예상하기 때문이다. 즉 지자체가 수익을 낼 수 있는 비즈니스 모델을 기반으로 일반 시민들로부터 데이터를 취득한다.

(2) 2단계: 도로면 균열 검출

1단계에서 취득된 블랙박스 이미지 내에서 균열 검출을 수행한다. 짧은 시간 내에 균열을 검출하고자 한다면 구역 단위 균열 검출 기술을 활용하고, 정밀하게 균열을 검출하고자 한다면 픽셀 단위 균열 검출 기술을 활용한다.

(3) 3단계: 구간별 결함 지도 생성

프레임별 균열 검출 품질을 예측하고 해당 품질에 따라 가중평균하여 일정한 구간을 한 장의 이미지로 나타내는 균열 모자이크 이미지를 생성한다. 블랙박스에서 획득되는 GPS 기반 위치 정보는 모자이크 이미지에 태깅(Tagging)되어 도로 보수를 수행하는 실무자들에게 전달된다.

(4) 4단계: 미래 열화 상태 예측

구간별 균열 모자이크 이미지 및 위치 정보가 중앙서버 컴퓨터에 축적되어 데이터베이스를 구성한다. 누적된 시간에 따른 구간별 열화상태 정보와 도로 열화에 영향을 미치는 기후 인자의 기후 변화 시나리오 자료를 이용하여 Cox 모델과 생존 분석 모델에 기반한 미래의 도로면 열화 상태를 예측한다. 예측된 열화 정도에 따라 선제적인 유지보수 계획을 수립할 수 있으며 이는 도로 유지보수 비용절감에 기여할 수 있다.

나. 연구 성과의 실용화 방안

(1) 예상 기술 수요처

국내의 경우 도로 종류에 따라 관리 주체가 다름. 국토교통부(고속국도 및 일반국도), 지방국토관리청(일반국도), 한국도로공사(고속국도), 지자체(특별시도, 광역시도, 지방도, 시도, 군도, 구도)와 같은 관청과 공기업이 본 과제 제안 기술의 수요처가 될 수 있다. 해외의 경우도 도로 관리인 관청과 공기업이 주된 제안 기술 수요처가 되며, 민자 도로의 경우 민간 기업이 수요처가 될 수 있다.

본 과제에서 제안된 방법이 높은 성능을 보이기 위해서는 충분한 도로상태 데이터가 활용되어야 한다. 본 과제에서 개발된 기술이 특정 지역에서 높은 성능을 보이기 위해서는 해당 지역의 도로상태 데이터가 필요하므로 높은 성능으로 도로 열화 정도를 예측하기 원하는 기관들로부터 데이터를 확보할 수 있을 것이라 기대한다.

(2) 현장적용 방안(계획)

도로 포장 상태 조사 계획 대상이 되는 도로는 일부 구간이 아닌 전체 포장 도로망에 해당된다. 도로 종류별(고속국도, 일반국도, 지방도 등)로 데이터를 취득하고, 주야간, 우천시, 터널 진입부/내부 영상에 대해 데이터 베이스를 구축하고 균열 분석 성능을 확인한다. 도로 포장 형식(아스팔트 콘크리트 포장, 시멘트 콘크리트 포장)의 변화에 따른 균열 종류 구분 방법을 실험한다.

특정 지역의 도로 수명을 예측하기 위해서는 해당 지역의 도로 상태 데이터(PCR 등)가 필요하다. 지역별로 교통량, 교통하중, 도로포장의 종류, 그리고 도로 포장면의 두께 등이 다르기 때문이다. 또한, 기후 변화를 고려한 도로 수명 예측을 위해서는 해당 지역의 기후 데이터도 필요하다. 도로 상태 데이터 및 기후 데이터를 활용하여 특정 지역의 도로 유지관리 전력 수립에 이바지한다.

(3) 실용화 제품화 방안

본 과제의 제안 기술은 일반 차량에 장착될 수 있는 휴대폰, 블랙박스에 설치되는 어플리케이션 소프트웨어의 형태로 활용될 수 있다. 실제 차량 운전자들이 해당 앱을 설치하고 작동시키기 위해서 인센티브 제도의 수립과 같은 장려책 개발이 필요하다. 차량 보험료의 할인 또는 주유권 지급 등 사용자의 동기를 부여할 수 있는 장려책 개발과 관련된 추가 연구가 향후 필요할 것으로 예상된다.

(4) 미래 원천기술 확보

균열 분석과 관련된 원천 기술을 다수 확보하여 저비용으로 도로망 전체를 모니터링 할 수

있는 획기적인 도로 유지관리 운영 방법을 확보할 수 있다. 균열 분석을 위해 사용되는 CNN 기반 균열 인식(Recognition), 추출(Segmentation) 모델과, 도로 시설물, 차량, 보행자 등을 인식하는 인식 모델 개발은 향후 균열 분석뿐만 아니라 도로 시설물 관리, 자율 주행 차량의 주변 환경 인식 시스템으로도 활용될 수 있다.

(5) 신산업 창출

도로망이 광범위해 진 국가들(2017년 기준 대한민국 도로 총연장 110,691km, 연간 보수비용 3조 3천억 원, 2012년 기준 일본 도로 총연장 1,207,867km, 2012년 기준 미국 도로 총연장 6,540,839km)의 유지관리 비용이 증가하고 있는 현실을 비추어 볼 때, 사회기반시설물의 유지관리 기술의 개발을 통해 새로운 건설 시장을 창출할 수 있을 것으로 기대된다.

다. 기대효과



[그림 4-1] 연구 결과의 중요성 요약도.

(1) 연구 성과의 학술적 가치 측면

본 연구 과제에서 최종 목표로 하는 시스템 개발을 위해서는 다양한 학문 분야의 최첨단 기술들을 기반으로, 제한된 프로세싱 환경과 빅 데이터의 처리, 불확실성 기반 열화 상태 모델링 등 새로운 이론 및 기술 개발이 필요하다. 따라서 본 연구 과제의 성과가 분야 융합·통합적 학술 이론의 발전을 견인하는 역할을 할 것으로 기대된다.

(2) 연구 성과의 경제적 효과 측면

본 연구의 최종목표로 개발되는 도로망 균열 분석 및 구간별 열화 모델링 기술은 국가단위의 도로망을 관리하기 위한 최적 의사결정을 지원하는 핵심 정보를 제공하여 도로관리를 위한 예산 절감효과가 클 것으로 기대된다. 또한 실시간 도로상태 모니터링을 위해 사용자들이 스마트폰 또는 차량용 블랙박스과 같이 기존에 널리 사용되고 있는 자원을 활용함으로써 도로 모니터링에 대한 비용 절감 효과와, 도로결합의 적시 수선으로 인해 절감되는 비용이 매우 클 것으로 예상된다. 개발된 기술은 기존의 영상 내 균열 분석을 위한 해외 기술을 대체하고, 해외 시장 진출을 통해 새로운 수익 창출의 기회가 될 것으로 예상된다.

(3) 연구 성과의 산업적 확산 측면

기존의 도로 모니터링 방식은 특수 카메라 또는 레이저스캐너 장비를 착용하여 일부 도로만 검사할 수 있는 한계가 존재한다. 본 연구에서 제시하는 소셜 센싱 방식의 도로망 모니터링 방법은 비용 효과적이고 도로 전체의 실시간 모니터링을 가능하게 하여 전세계 도로 모니터링 패러다임을 혁신할 수 있을 것으로 기대된다. 도로망을 갖추고 있는 선진국들을 대상으로 제안 기술을 판매, 기술 이전 하였을 때 얻을 수 있는 수익이 클 것으로 기대된다.

(4) 연구 성과의 사회적 파급 효과 측면

본 연구 성과로 제시된 시스템을 통해 위치별 도로 결함 발생 패턴을 분석하고, 이에 따라 최적 대안(예: 재포장, 도로 포장 종류 변경, 수선 등)을 데이터에 근거하여 결정할 수 있어 차량운행 안전성이 높은 사회기반시설을 확보할 수 있다.

(5) 연구 성과의 창의적 인재양성 측면

본 연구 과제를 수행하며 한 분야에만 국한되지 않고 건설, 시설물관리, 정보통신기술, 컴퓨터비전, 인공지능 방법론을 아우를 수 있는 융합분야 연구자 및 기술자를 양성할 수 있다. 연구 기간 동안 지속적인 연구 인력 배출을 통하여 세계적 수준의 연구자를 배출하는데 일조할 것이다.

라. 타 연구와의 협업 방안

(1) 과제1: 인공지능망 알고리즘과 디블러링 기법을 이용하여 40km/h 주행속도로 터널의 균열을 검출할 수 있는 촬영 장비 및 균열 분석, 작도 자동화 패키지 프로그램 개발 ((주)태명이씨앤씨)

과제1은 터널의 균열을 자동으로 검출하는 방법을 개발하였다. 균열을 검출하기 위해 인공지능 신경망과 디블러링 기술을 사용하였고, 사용자의 편의를 위해 GUI 환경기반 균열 검출 프로그램을 개발하였다. 본 과제에서 개발된 도로 균열 검출을 위한 인공지능 신경망 모델과

과제1에서 개발된 터널 균열 검출을 위한 인공지능 신경망 모델을 비교함으로써 모델 간 상호 보완 및 개선을 할 수 있다. 또한, 두 과제에서 균열을 검출하기 위해 제작된 데이터를 상호 전이학습용으로 사용할 수 있다. 더 나아가 도로 균열 검출을 위한 GUI 환경기반 프로그램 개발을 위해 과제1의 연구 결과를 활용할 수 있다.

(2) 과제2: 도로교통 시스템 운영유지보수 관리비용 최소화 및 해외 시장 개척을 위한 원격검침형 AVC/ VDS/ WIM 융복합 시스템 개발과 Class I 급 PVDF 센서 국산화 ((주)노바코스)

과제2는 센서를 기반으로 교통량, 속도, 차종, 총중량, 그리고 온도를 측정한다. 센서 정보를 통해 노면 상태를 예측하고 누적 중량에 따른 노면 변화 정보를 제공한다. 과제2에서 개발된 센서를 활용함으로써 본 과제에서 비모수로 활용되었던 교통량 등의 데이터를 취득하여 모수로 활용할 수 있다. 또한, 두 과제의 노면 수명 예측모델을 비교함으로써 상호 보완 및 개선을 할 수 있다.

(3) 과제3: 기상환경 재현 도로 성능평가 실험시설 구축 (한국건설기술연구원)

과제3은 주요 기상 조건 및 도로환경을 재현하여 교통안전을 평가하고 실험할 수 있는 실험 시설을 구축하였다. 본 시설을 통해 악천후, 야간환경, 그리고 다양한 도로포장재 조건을 설정하고 실증실험을 수행할 수 있다. 미래의 기후변화 시나리오에 따른 도로 열화 실험을 실제로 수행함으로써 실증적인 데이터를 기반으로 도로 수명을 예측할 수 있다. 또한, 과제3의 실험시설을 통해 극한 기후 상황에서의 데이터 취득이 쉬워지므로 도로 수명 예측 알고리즘의 범용성을 높일 수 있다.

붙임. 참고문헌

- 국토교통부, 도로 및 보수 현황 시스템, <http://www.rsis.kr/> (2019년 4월 14일 접속)
- 국토교통부, 2015 도로포장관리시스템 최종보고서, 2016년 6월
- 국토교통부, 도로 포장 유지보수 실무 편람, 2013년 12월.
- 국토교통부, 2017 도로포장관리시스템 연구보고서, 2018년 6월.
- 국토교통부, 도로 및 보수현황 시스템, <http://www.rsis.kr/> (2019년 3월 12일 접속)
- 박철한, 이홍일 (2016) “건설이슈포커스: 국내 교통 인프라 유지보수 투자의향후 변화 추이, 한국건설산업연구원.
- 서동주 (2007). “수치영상을 이용한 도로 노면관리시스템 개발” 2007한국지리정보학회지 10권 1호, 35-46.
- 서호정, 방성덕, 윤여산, 박소민, 김형관 (2017). "기후 인자 영향을 고려한 도로 포장 수명의 생존 분석" 2017 한국건설관리학회 정기학술발표대회, 119-120.
- 손수국 (2002)“Image Gradient 방법을 사용한 도로 노면의 균열검출시스템 개발”수원대학교 논문집, 293-302.
- 윤여산, 방성덕, 백승현, 김형관 (2018). "도로 포장 모니터링을 위한 블랙박스 동영상 기반 도로 결함 지도 생성" 2018 대한토목학회 정기학술대회, 236-237.
- 이종출, 박운용, 서정훈, 박규열 (2004).“비디오 영상을 이용한 도로노면 균열관리시스템 개발”2004 대한토목학회 학술대회, 1889-1892.
- Ahmad, N., Wistuba, M., & Lorenzl, H. (2012, June). GPR as a crack detection tool for asphalt pavements: possibilities and limitations. In 2012 14th International Conference on Ground Penetrating Radar (GPR), pp. 551-555, IEEE.
- Akçay, S., Kundegorski, M. E., Devereux, M. & Breckon, T. P. (2016), Transfer Learning Using Convolutional Neural Networks for Object Classification within X-Ray Baggage Security Imagery, Proceedings of the 2016 IEEE International Conference on Image Processing, pp. 1057-1061.
- Baladi, G. Y., Dawson, T., Musunuru, G., Prohaska, M., & Thomas, K. (2017). Pavement Performance Measures and Forecasting and the Effects of Maintenance and Rehabilitation Strategy on Treatment Effectiveness (No. FHWA-HRT-17-095). United States. Federal Highway Administration.
- Badrinarayanan, V., Handa, A. & Cipolla, R. (2015), Segnet: A Deep Convolutional Encoder-Decoder Architecture for Robust Semantic Pixel-Wise Labelling, arXiv preprint arXiv:1505.07293.
- Badrinarayanan, V., Kendall, A. & Cipolla, R. (2017), Segnet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, IEEE transactions on pattern analysis and machine intelligence, 39(12), 2481-2495.
- Barsi, A., Lovas, T., & Kertész, I. (2006). The potential of lowend IMUs for mobile mapping systems. International Archives of Photogrammetry and Remote Sensing, 36(1), 4.

- Batrakov, D. O., Antyufeyeva, M. S., Antyufeyev, A. V., & Batrakova, A. G. (2017, June). GPR data processing for evaluation of the subsurface cracks in road pavements. In 2017 9th International Workshop on Advanced Ground Penetrating Radar (IWAGPR), pp. 1–6. IEEE.
- Bang, S., Park, S., Kim, H., and Kim, H. (2019). "Encoder–decoder network for pixel–level road crack detection in black–box images" *Computer–Aided Civil and Infrastructure Engineering*, 0(0), 1–15.
- Bland, J. M. & Altman, D. G. (1998), Survival Probabilities (the Kaplan–Meier Method), *Bmj*, 317(7172), 1572–1580.
- Cha, Y. J., Choi, W. & Büyüköztürk, O. (2017), Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks, *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361–378.
- Chen, F. C., & Jahanshahi, M. R. (2018). NB–CNN: Deep learning–based crack detection using convolutional neural network and Naïve Bayes data fusion. *IEEE Transactions on Industrial Electronics*, 65(5), 4392–4400.
- Chen, D., Wang, Y., Ren, H., & Gao, W. (2019). No–Reference Image Quality Assessment: An Attention Driven Approach. In 2019 IEEE Winter Conference on Applications of Computer Vision (WACV), pp. 376–385, IEEE.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009). Imagenet: A large–scale hierarchical image database. In 2009 IEEE conference on computer vision and pattern recognition, pp. 248–255.
- Diamanti, N., Redman, D., & Giannopoulos, A. (2010). A study of GPR vertical crack responses in pavement using field data and numerical modelling. In *Proceedings of the XIII International Conference on Ground Penetrating Radar*, pp. 1–6, IEEE.
- Dondi, G., Barbarella, M., Sangiorgi, C., Lantieri, C., & De Marco, L. (2011). A semi–automatic method for identifying defects on road surfaces. In *The International Conference on Sustainable Design and Construction 2011: ICSDC 2011: Integrating Sustainability Practices in the Construction Industry* American Society of Civil Engineers.
- E.L. Kaplan, P. Meier, Nonparametric estimation from incomplete observations, *Journal of the American statistical association* 53(282) (1958) 457–481.
- FHWA (2011), "Final report: Effectiveness of crack sealing on pavement serviceability and life"
- Fang, Y., Yan, J., Liu, X., & Wang, J. (2019). Stereoscopic image quality assessment by deep convolutional neural network. *Journal of Visual Communication and Image Representation*, 58, 400–406.
- Feng, C., Liu, M. Y., Kao, C. C., & Lee, T. Y. (2017). Deep active learning for civil infrastructure defect detection and classification. Mitsubishi Electric Research Laboratories. Available online: <https://www.merl.com/publications/docs/TR2017-034.pdf> (accessed on 6 June 2018).

- Gao, Z., Wu, Y., Bu, X., Yu, T., Yuan, J., & Jia, Y. (2019). Learning a Robust Representation via a Deep Network on Symmetric Positive Definite Manifolds. *Pattern Recognition*.
- Garbowski, T., & Gajewski, T. (2017). Semi-automatic inspection tool of pavement condition from three-dimensional profile scans. *Procedia Engineering*, 172, 310–318.
- Geiger, A. (2009). Monocular road mosaicing for urban environments. In *2009 IEEE Intelligent Vehicles Symposium*, pp. 140–145, IEEE.
- Geiger, A., Lenz, P., Stiller, C., & Urtasun, R. (2013). Vision meets robotics: The KITTI dataset. *The International Journal of Robotics Research*, 32(11), 1231–1237.
- Gopalakrishnan, K., Khaitan, S. K., Choudhary, A., & Agrawal, A. (2017). Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection. *Construction and Building Materials*, 157, 322–330.
- Gu, J., Meng, G., Xiang, S., & Pan, C. (2019). Blind image quality assessment via learnable attention-based pooling. *Pattern Recognition*, 91, 332–344.
- Guo, C., Meguro, J. I., Kojima, Y., & Naito, T. (2014). Automatic lane-level map generation for advanced driver assistance systems using low-cost sensors. In *2014 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 3975–3982, IEEE.
- Guo, C., Kidono, K., Meguro, J., Kojima, Y., Ogawa, M., & Naito, T. (2016). A low-cost solution for automatic lane-level map generation using conventional in-car sensors. *IEEE Transactions on Intelligent Transportation Systems*, 17(8), 2355–2366.
- Haas C., and Hendrickson C. Computer-based model of pavement surfaces. *Transportation Research Record*, 1260, 91–98, 1990.
- Haas C. Evolution of an automated crack sealer: a study in construction technology development. *Automation in construction*, 4(4), 293–305, 1996.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778.
- Huang, F. J., Boureau, Y.-L. & LeCun, Y. (2007), Unsupervised Learning of Invariant Feature Hierarchies with Applications to Object Recognition, *Proceedings of the 2007 IEEE conference on computer vision and pattern recognition*, pp. 1–8.
- Huang, B., Xie, C., & Li, H. (2005). Mobile GIS with enhanced performance for pavement distress data collection and management. *Photogrammetric Engineering & Remote Sensing*, 71(4), 443–451.
- Huang, H.-w., Li, Q.-t. & Zhang, D.-m. (2018), Deep Learning Based Image Recognition for Crack and Leakage Defects of Metro Shield Tunnel, *Tunnelling and Underground Space Technology*, 77, 166–176.
- Jahanshahi, M. R. & Masri, S. F. (2012), Adaptive Vision-Based Crack Detection Using 3d Scene Reconstruction for Condition Assessment of Structures, *Automation in*

- Construction, 22, 567–576.
- Ji, W., Wu, J., Shi, G., Wan, W., & Xie, X. (2019). Blind image quality assessment with semantic information. *Journal of Visual Communication and Image Representation*, 58, 195–204.
- Jo, Y. & Ryu, S. (2015), Pothole Detection System Using a Black-Box Camera, *Sensors*, 15(11), 29316–29331.
- Kampffmeyer, M., Salberg, A. B., & Jenssen, R. (2016). Semantic segmentation of small objects and modeling of uncertainty in urban remote sensing images using deep convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*, pp. 1–9.
- Kendall, A., Badrinarayanan, V. & Cipolla, R. (2015), Bayesian Segnet: Model Uncertainty in Deep Convolutional Encoder-Decoder Architectures for Scene Understanding, *arXiv preprint arXiv:1511.02680*.
- Kim, H., Kim, H., Hong, Y. W. & Byun, H. (2017), Detecting Construction Equipment Using a Region-Based Fully Convolutional Network and Transfer Learning, *Journal of Computing in Civil Engineering*, 32(2), 04017082.
- Kim Y. S., Haas C. T., and Greer R. Path planning for machine vision assisted, teleoperated pavement crack sealer. *Journal of Transportation Engineering*, 124(2), 137–143, 1998
- Kong, H., Audibert, J. Y., & Ponce, J. (2009, June). Vanishing point detection for road detection. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 96–103, IEEE.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pp. 1097–1105.
- Li, B., Wang, K. C., Zhang, A., & Fei, Y. (2019). Automatic Segmentation and Enhancement of Pavement Cracks Based on 3D Pavement Images. *Journal of Advanced Transportation*, 2019.
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., ... & Zitnick, C. L. (2014). Microsoft coco: Common objects in context. In *European conference on computer vision*, pp. 740–755, Springer, Cham.
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431–3440.
- Mandal, V., Uong, L., & Adu-Gyamfi, Y. (2018). Automated Road Crack Detection Using Deep Convolutional Neural Networks. In *2018 IEEE International Conference on Big Data (Big Data)*, pp. 5212–5215. IEEE.
- Medina, R., Gómez-García-Bermejo, J., & Zalama, E. (2010). Automated visual inspection of road surface cracks. In *International Symposium on Automation and Robotics in Construction (ISARC)*.

- Meguro, J., Ishida, H., Guo, C., Yamaguchi, K., & Kojima, Y. (2017). Automatic Orthographic Road Image Generation Using in Vehicle Sensors for ADAS. *International Journal of Automotive Engineering*, 8(AVEC14), 30–36.
- Mertz, C., Varadharajan, S., Jose, S., Sharma, K., Wander, L., & Wang, J. (2014). City-wide road distress monitoring with smartphones. In *Proceedings of ITS World Congress*, pp. 1–9.
- Miraliakbari, A., Hahn, M., & Maas, H. G. (2014). DEVELOPMENT OF A MULTI-SENSOR SYSTEM FOR ROAD CONDITION MAPPING. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*.
- Mohammadi, P., Ebrahimi-Moghadam, A., & Shirani, S. (2014). Subjective and objective quality assessment of image: A survey. *arXiv preprint arXiv:1406.7799*.
- Nair V., Hinton G. E. Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)*, pages 807–814, Haifa, Israel, 2010.
- Naumann, M., & Hellmund, A. M. (2016). Multi-drive road map generation on standardized high-velocity roads using low-cost sensor data. In *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, pp. 113–120. IEEE.
- Nishikawa, T., Yoshida, J., Sugiyama, T. & Fujino, Y. (2012), Concrete Crack Detection by Multiple Sequential Image Filtering, *Computer-Aided Civil and Infrastructure Engineering*, 27(1), 29–47.
- O'Byrne, M., Ghosh, B., Schoefs, F. & Pakrashi, V. (2014), Regionally Enhanced Multiphase Segmentation Technique for Damaged Surfaces, *Computer-Aided Civil and Infrastructure Engineering*, 29(9), 644–658.
- Offrell, P., & Magnusson, R. (2004). In situ photographic survey of crack propagation in flexible pavements. *International Journal of Pavement Engineering*, 5(2), 91–102.
- Oliveira, H., and Correia, P. L. (2013). "Automatic road crack detection and characterization.", *IEEE Transactions on Intelligent Transportation Systems*, 14(1), 155–168.
- Oloufa, A. A., Mahgoub, H. S., & Ali, H. (2004). Infrared thermography for asphalt crack imaging and automated detection. *Transportation research record*, 1889(1), 126–133.
- Park, S., Bang, S., Kim, H., and Kim, H. (2019), "Patch-based crack detection in black box images using convolutional neural network", *Journal of Computing in Civil Engineering*, 33(3)(04019017), 1–11.
- Pohlen, T., Hermans, A., Mathias, M. & Leibe, B. (2017), Full-Resolution Residual Networks for Semantic Segmentation in Street Scenes, *arXiv preprint*.
- Radopoulou, S. C., Brilakis, I., Doycheva, K., & Koch, C. (2016, May). A framework for automated pavement condition monitoring. In *Proceedings of Construction Research Congress*, pp. 770–779.
- Rajagopal, A. (2011). Effectiveness of crack sealing on pavement serviceability and life

- (No. FHWA/OH-2010/14). Ohio. Dept. of Transportation.
- Ronneberger, O., Fischer, P. & Brox, T. (2015), U-Net: Convolutional Networks for Biomedical Image Segmentation, International Conference on Medical image computing and computer-assisted intervention, Springer, pp. 234-241.
- Sheikh, H. R., & Bovik, A. C. (2004). Image information and visual quality. In 2004 IEEE International Conference on Acoustics, Speech, and Signal Processing (Vol. 3, pp. iii-709). IEEE.
- Shen, G (2016). "Road crack detection based on video image processing." IEEE Proc., Systems and Informatics (ICSAI), 912-917.
- Shih, Y., Krishnan, D., Durand, F. & Freeman, W. T. (2015), Reflection Removal Using Ghosting Cues, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 3193-3201.
- Shi, Y., Cui, L., Qi, Z., Meng, F., and Chen, Z. (2016). "Automatic road crack detection using random structured forests." IEEE Transactions on Intelligent Transportation Systems, 17(12), 3434-3445.
- Sikirić, I., Brkić, K., & Šegvić, S. (2010, May). Recovering a comprehensive road appearance mosaic from video. In The 33rd International Convention MIPRO (pp. 755-759). IEEE.
- Sikirić, I., Majić, A., & Šegvić, S. (2011, May). Using GPS positioning to recover a comprehensive road appearance mosaic. In 2011 Proceedings of the 34th International Convention MIPRO, pp. 877-882, IEEE.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Solla, M., Lagüela, S., González-Jorge, H., & Arias, P. (2014). Approach to identify cracking in asphalt pavement using GPR and infrared thermographic methods: Preliminary findings. Ndt & E International, 62, 55-65.
- Southall, B., & Taylor, C. J. (2001). Stochastic road shape estimation. In Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001, Vol. 1, pp. 205-212, IEEE.
- Sukumar, S. R., Yu, S., Page, D. L., Koschan, A. F., & Abidi, M. A. (2006, May). Multi-sensor integration for unmanned terrain modeling. In Unmanned Systems Technology VIII (Vol. 6230, p. 623008). International Society for Optics and Photonics.
- Sun, T. Y., Tsai, S. J., & Chan, V. (2006). HSI color model based lane-marking detection. In 2006 IEEE Intelligent Transportation Systems Conference, pp. 1168-1172, IEEE.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1-9.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the

- inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 2818–2826.
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. (2017, February). Inception-v4, inception-resnet and the impact of residual connections on learning. In Thirty-First AAAI Conference on Artificial Intelligence.
- Teichmann, M., Weber, M., Zoellner, M., Cipolla, R., & Urtasun, R. (2018, June). Multinet: Real-time joint semantic reasoning for autonomous driving. In 2018 IEEE Intelligent Vehicles Symposium (IV), pp. 1013–1020. IEEE.
- T.M. Therneau, P.M. Grambsch, Modeling survival data: extending the Cox model, Springer Science & Business Media 2013.
- Tong, Z., Gao, J., & Zhang, H. (2017). Recognition, location, measurement, and 3D reconstruction of concealed cracks using convolutional neural networks. *Construction and Building Materials*, 146, 775–787.
- Tsai, Y. J., Kaul, V., & Yezzi, A. (2013). Automating the crack map detection process for machine operated crack sealer. *Automation in Construction*, 31, 10–18.
- Transportation Information Mapping System (TIMS), Ohio Department of Transportation 2017.
- W. Cox & J. Love, The best investment a nation ever made: A tribute to the Dwight D. Eisenhower system of interstate and defense highways. DIANE Publishing 1998.
- Wang, S., Qiu, S., Wang, W., Xiao, D., & Wang, K. C. (2017). Cracking classification using minimum rectangular cover-based support vector machine. *Journal of Computing in Civil Engineering*, 31(5), 04017027.
- Wei, Y., Wang, Z., & Xu, M. (2017). Road structure refined CNN for road extraction in aerial image. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 709–713.
- Wu, L., Mokhtari, S., Nazef, A., Nam, B., and Yun, H.-B. (2016). "Improvement of Crack-Detection Accuracy Using a Novel Crack Defragmentation Technique in Image-Based Road Assessment." *Journal of Computing in Civil Engineering*, 30(1), 04014118.
- Xu, G., Chen, F., Wu, G., & Li, X. (2018). Active solution of homography for pavement crack recovery with four laser lines. *Scientific reports*, 8(1), 7198.
- Yan, W. Y., & Yuan, X. X. (2018). A low-cost video-based pavement distress screening system for low-volume roads. *Journal of Intelligent Transportation Systems*, 22(5), 376–389.
- Yan, Q., Gong, D., & Zhang, Y. (2019). Two-Stream Convolutional Networks for Blind Image Quality Assessment. *IEEE Transactions on Image Processing*, 28(5), 2200–2211.
- Yeosan Yoon, Seongdeok Bang, Francis Baek, and Hyoungkwan Kim (2019). "Pavement Crack Mosaicking Based on Crack Detection Quality" The 36th International Symposium on Automation and Robotics in Construction (ISARC 2019), Banff, Canada, 0–0.

- Yeum, C. M. & Dyke, S. J. (2015), Vision-Based Automated Crack Detection for Bridge Inspection, *Computer-Aided Civil and Infrastructure Engineering*, 30(10), 759–770.
- Ying, L. & Salari, E. (2010), Beamlet Transform-Based Technique for Pavement Crack Detection and Classification, *Computer-Aided Civil and Infrastructure Engineering*, 25(8), 572–580.
- Yu, S. J., Sukumar, S. R., Koschan, A. F., Page, D. L., & Abidi, M. A. (2007). 3D reconstruction of road surfaces using an integrated multi-sensory approach. *Optics and lasers in engineering*, 45(7), 808–818.
- Zakeri, H., Nejad, F. M., & Fahimifar, A. (2016). Rahbin: A quadcopter unmanned aerial vehicle based on a systematic image processing approach toward an automated asphalt pavement inspection. *Automation in Construction*, 72, 211–235.
- Zalama, E., Gómez-García-Bermejo, J., Medina, R., and Llamas, J. (2014). "Road Crack Detection Using Visual Features Extracted by Gabor Filters." *Computer-Aided Civil and Infrastructure Engineering*, 29(5), 342–358.
- Zamir, A. R., Sax, A., Shen, W., Guibas, L. J., Malik, J. & Savarese, S. (2018), Taskonomy: Disentangling Task Transfer Learning, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 3712–3722.
- Zeiler, M. D. & Fergus, R. (2014), Visualizing and Understanding Convolutional Networks, *European conference on computer vision*, Springer, pp. 818–833.
- Zeng, J., Chen, Y., & Qin, C. (2018, August). Finger-vein Image Quality Assessment Based on light-CNN. In *2018 14th IEEE International Conference on Signal Processing (ICSP)*, pp. 768–773, IEEE.
- Zhang, A., Wang, K. C., Fei, Y., Liu, Y., Chen, C., Yang, G., Li, J. Q., Yang, E. & Qiu, S. (2018), Automated Pixel-Level Pavement Crack Detection on 3d Asphalt Surfaces with a Recurrent Neural Network, *Computer-Aided Civil and Infrastructure Engineering*.
- Zhang, A., Wang, K. C., Fei, Y., Liu, Y., Tao, S., Chen, C., Li, J. Q. & Li, B. (2018), Deep Learning-Based Fully Automated Pavement Crack Detection on 3d Asphalt Surfaces with an Improved Cracknet, *Journal of Computing in Civil Engineering*, 32(5), 04018041.
- Zhang, A., Wang, K. C., Li, B., Yang, E., Dai, X., Peng, Y., Fei, Y., Liu, Y., Li, J. Q. & Chen, C. (2017), Automated Pixel-Level Pavement Crack Detection on 3d Asphalt Surfaces Using a Deep-Learning Network, *Computer-Aided Civil and Infrastructure Engineering*, 32(10), 805–819.
- Zhang, K., Cheng, H. & Zhang, B. (2018), Unified Approach to Pavement Crack and Sealed Crack Detection Using Preclassification Based on Transfer Learning, *Journal of Computing in Civil Engineering*, 32(2), 04018001.
- Zhang, L., Yang, F., Zhang, Y. D., and Zhu, Y. J (2016). "Road crack detection using deep convolutional neural network." *IEEE Proc., Image Processing (ICIP)*, 3708–3712.
- Zhang, S., Lippitt, C., Bogus, S., & Neville, P. (2016). Characterizing pavement surface distress conditions with hyper-Spatial resolution natural color aerial photography.

Remote Sensing, 8(5), 392.

Zou, Q., Cao, Y., Li, Q., Mao, Q., & Wang, S. (2012). CrackTree: Automatic crack detection from pavement images. Pattern Recognition Letters, 33(3), 227–238.

주 의

1. 이 보고서는 국토교통부에서 시행한 국토교통기술촉진연구사업의 연구보고서입니다.
2. 이 보고서 내용을 발표하는 때에는 반드시 국토교통부에서 시행한 국토교통기술촉진연구사업의 연구결과임을 밝혀야 합니다.
3. 국가과학기술 기밀 유지에 필요한 내용은 대외적으로 발표 또는 공개하여서는 안 됩니다.